

Tartu Ülikool
Bioloogia-geograafiateaduskond
Geograafia Instituut

Otepää looduspargi metsatüüpide kaardistamine näidistele tugineva pidevõppe tarkvara abil

Magistritöö maastikuökoloogias ja keskkonnakaitses

Madli Linder

Juhendajad: teadur Kalle Remm,
vanemteadur Jane Frey

Tartu 2006

SISUKORD

1. SISSEJUHATUS	5
2. TAIMKATTE SUUREMÕÕTKAVALINE KAARDISTAMINE	6
2.1. TAIMKATTE KAARTIDEST JA NENDE LOOMISEL KASUTATUD METOODIKATEST	6
2.2. TAIMKATTE PROGNOOSIV KAARDISTAMINE	8
2.3. NÄIDISTELE TUGINEV JÄRELDAMINE	9
3. ANDMED JA METOODIKA.....	12
3.1. UURIMISALA	12
3.2. KAARDI- JA PILDIANDMED	13
3.2.1. Põhikaart	15
3.2.1.1. Andmekihid	15
3.2.1.2. Põhikaart eelklassifikaatorina	16
3.2.1.3. Põhikaardi rasteriseerimine	16
3.2.2. Mullakaart	17
3.2.2.1. Andmekihid	17
3.2.2.2. Mullakaardi rasteriseerimine ja andmete teisendamine	17
3.2.2.3. Sarnasusmaatriksid	18
3.2.3. Maapinna kõrgusmudel	19
3.2.3.1. Andmed	19
3.2.3.2. Andmekihi ettevalmistus	19
3.2.4. Ortofotod	20
3.2.4.1. Andmed ja andmekihid	20
3.2.4.2. Värvilahutus	20
3.2.5. Metsakorraldusfotod	21
3.2.5.1. Andmed ja andmekihid	21
3.2.5.2. Andmekihtide ettevalmistus	21
3.2.6. Landsat 7 ETM+ satelliidipildid	22
3.2.6.1. Andmed ja andmekihid	22
3.2.6.2. Andmekihtide ettevalmistus	23
3.2.7. Andmekihtidest arvutatud seletavad tunnused	24
3.2.7.1. Tunnustest ja nende valikust	24
3.2.7.2. Tunnuste arvutamise raadiused ja eelklassifikaatorite kasutus	27
3.2.7.3. Asendustunnused	27
3.3. VAATLUSANDMETE KOGUMISE METOODIKA	28
3.3.1. Välivaatlusandmete kogumise metoodika	28
3.3.2. Näidisalade valimine varasematest andmestikest	29
3.3.3. Näidisalade hulk ja paiknemine	30
3.3.4. Taimkatte näidisalade andmebaas	32
3.4. KAARDISTUSÜKSUSED	34
3.4.1. Metsatüübid	34
3.4.2. Tüübirühmade ja kasvukohatüüpide kirjeldused	35
3.4.2.1. Palumetsade tüübirühm	37
3.4.2.1.1. Pohla kasvukohatüüp	37
3.4.2.1.2. Lillaka kasvukohatüüp	37
3.4.2.1.3. Mustika kasvukohatüüp	38
3.4.2.2. Laanemetsade tüübirühm	39
3.4.2.2.1. Jänesekapsa-mustika kasvukohatüüp	39
3.4.2.2.2. Jänesekapsa kasvukohatüüp	39
3.4.2.3. Sürjametsade tüübirühm	40
3.4.2.3.1. Maasika kasvukohatüüp	40
3.4.2.4. Salumetsade tüübirühm	41
3.4.2.4.1. Sinilille kasvukohatüüp	41
3.4.2.4.2. Naadi kasvukohatüüp	42
3.4.2.5. Soostunud metsade tüübirühm	43
3.4.2.5.1. Sõnajala kasvukohatüüp	43

3.4.2.5.2. Angervaksa kasvukohatüüp.....	43
3.4.2.5.3. Sinihelmika kasvukohatüüp	43
3.4.2.6. Madalsoometsade tüübirühm.....	44
3.4.2.6.1. Madalsoometsa kasvukohatüüp.....	44
3.4.2.6.2. Lodumetsa kasvukohatüüp	44
3.4.2.6.3. Allikasoometsa kasvukohatüüp	45
3.4.2.7. Siirdesoometsade tüübirühm	45
3.4.2.7.1. Siirdesoometsa kasvukohatüüp	45
3.4.2.8. Rabametsade tüübirühm	46
3.4.2.8.1. Rabametsa kasvukohatüüp	46
3.4.2.9. Kõdusoometsade tüübirühm	46
3.4.2.9.1. Mustika-kõdusoometsa kasvukohatüüp.....	46
3.4.2.9.2. Jänesekapsa-kõdusoometsa kasvukohatüüp	47
3.4.2.10. Lammipajustike tüübirühm.....	47
3.4.2.10.1. Paju kasvukohatüüp	47
3.4.2.11. Metsastuv sööt.....	48
3.4.2.11.1. Metsastuv sööt.....	48
3.4.3. Puistutüüpide kirjeldused.....	48
3.4.3.1. Klasteranalüüsil põhinev klassifikatsioon	48
3.4.3.1.1. Männik	49
3.4.3.1.2. Kuusik	49
3.4.3.1.3. Hall-lepik	49
3.4.3.1.4. Arukaasik	49
3.4.3.1.5. Sookasega lehtmets ja leht-segamets.....	50
3.4.3.1.6. Muu lehtmets.....	50
3.4.3.1.7. Leht-segamets	50
3.4.3.1.8. Okas-segamets	51
3.4.3.1.9. Harvik/metsalage.....	51
3.4.3.1.10. Noor kaasik ja kase-segamets söödil	52
3.4.3.1.11. Pajustik.....	52
3.4.3.2. Koosluste nimedel põhinev klassifikatsioon.....	53
3.4.3.2.1. Männik	53
3.4.3.2.2. Kuusik	53
3.4.3.2.3. Hall-lepik	53
3.4.3.2.4. Kaasik	53
3.4.3.2.5. Muu lehtmets.....	54
3.4.3.2.6. Leht-segamets	54
3.4.3.2.7. Okas-segamets	54
3.4.3.2.8. Harvik/metsalage.....	55
3.4.3.2.9. Metsastuv sööt.....	55
3.4.3.2.10. Pajustik.....	55
3.5. PIDEVSTUUDIUMI ANDMEBAASID	56
3.5.1. Vaatlusandmete andmebaas.....	56
3.5.2. Andmekihtide andmebaas	56
3.5.3. Tehisõppe andmebaas.....	58
3.5.3.1. Funktsioontunnused.....	59
3.5.3.2. Argumenttunnused	61
3.5.3.3. Vaatlusvektorid	62
3.5.3.4. Logitabelid	64
3.5.3.5. Seletavate tunnuste tabel	64
3.5.3.6. Tulemuste tabel	65
3.6. KAARTIDE GENEREERIMISE METOODIKA JA TARKVARA	66
3.6.1. Tarkvara Pidevstuumium	66
3.6.1.1. Tehnilised eeldused	66
3.6.1.2. Algmenüü.....	66
3.6.1.3. Ruumimustrit kirjeldavate tunnuste arvutamine.....	67
3.6.1.3.1. Indeksi arvutamise parameetrid.....	67
3.6.1.3.2. Eelklassifikaator ja eraldised.....	67
3.6.1.3.3. Pildi- või kaardimustrit kirjeldavad indeksid Pidevstuumiumis	68
3.6.1.4. Tehisõpe	71
3.6.1.4.1. Tehisõppe ettevalmistused	71
3.6.1.4.2. Tehisõppe protseduur	71

3.6.1.4.3. Tehisõppe osad.....	72
3.6.1.4.3.1. Tunnuste valik ja kaalumine	72
3.6.1.4.3.2. Näidiste valik ja kaalumine	73
3.6.1.4.3.3. Aktuaalsused ehk unustamine	73
3.6.1.4.3.4. Valimite moodustamine	74
3.6.1.4.3.5. Sarnasuse arvutus.....	74
3.6.1.4.3.6. Otsuste langetamine	75
3.6.1.4.3.7. Hinnangute vastavus	76
3.6.1.4.3.8. Tehisõppe tulemuste salvestumine	76
3.6.1.5. Teadmiste kontroll.....	77
3.6.1.5.1. Kontrolltäpsuse arvutus.....	77
3.6.1.5.2. Näidiste uuestivalik	78
3.6.1.6. Hinnangute ehk prognooside arvutamine	78
3.6.1.6.1. Sarnasushinnangud	78
3.6.1.6.2. Hinnangud andmebaasi tabelisse.....	79
3.6.1.6.3. Hinnangud rasterkaardile	79
3.6.1.6.3.1. Kaardi interpoleerimine	81
3.6.2. Muu tarkvara	83
4. TULEMUSED JA ARUTELU	84
4.1. TEHISÕPPE TULEMUSED	84
4.1.1. Metsakasvukohatüübid.....	84
4.1.2. Metsade tüübirühmad	85
4.1.3. Puistutüübid	86
4.1.4. Metsatüübid	87
4.1.5. Metsa kasvukoha karbonaatsus ja niiskus	90
4.2. KAARDID	91
4.2.1. Metsa kasvukohatüübid.....	91
4.2.2. Metsade tüübirühmad	92
4.2.3. Metsa kasvukoha niiskus ja karbonaatsus	93
4.2.4. Metsa kasvukoha troofsuse ja niiskuse järgi prognoositud tüübirühmad	98
4.2.5. Tüübirühmade kaartide võrdlus.....	99
4.2.6. Puistutüübid	100
4.2.7. Tunnustest seni parimates prognoosikomplektides	102
4.3. SARNASUSHINNANGUD JA KAARTIDE USALDATAVUS	103
KOKKUVÕTE	106
VIITED.....	107
SUMMARY.....	113
LISAD.....	114
LISA 1. MICROSTATIONI PROGRAMMINAGA CELLIDEVÄRVID.BAS	115
LISA 2. MICROSTATIONI PROGRAMMINAGA KÕRGUSVÄRV.BAS	116
LISA 3. NÄIDISALADE ANDMEBAASIS OLEVATE ÜKSUSTE KLASTRIPUU.	117
LISA 4. ACCESS VBA PROGRAMMIMOODUL KAARDILEHTEDE_ANDMED.....	120
LISA 5. NÄIDISALADE FOTOD	121

1. Sissejuhatus

Magistritöö põhineb enamjaolt Otepää looduspargis 2005. a augustist 2006. a veebruarini läbi viidud taimkatte inventuuri projektil ja selle aruandel (koostajad Kalle Remm ja Madli Linder). Projekti peamiseks eesmärgiks oli pildi- ja kaardiandmete seostamine loodusvaatlustega statistiliste ja intellektitehnika meetodite abil. Projekti käigus kaardistati õpetusandmete ning kaugseire- ja kaardiandmete järgi, kasutades näidistele põhineva järeldamise ja pidevõppe metoodikat, käpaliste oodatavaid esinemiskohti ning loodi taimkatte esialgne hinnanguline kaart. Magistritöös on käsitletud taimkatte inventuuri metsade tehisõppe ning kaardistuse osa.

Projekti aruande koostamise käigus pandi esimest korda kirja Tartu Ülikooli geograafia instituudis Kalle Remmi poolt loodud programmi *Pidevstuudium* ja selle kasutamise tehnoloogilise protsessi kirjeldus, mis on täielikult ka magistritöös ära toodud. See on nii praeguste kui ka tulevaste kasutajate jaoks oluline töö, sest *Pidevstuudiumi* tehnoloogiline lahendus on originaalne ja samas keerukas. Magistritöö pealkirjas on *pidevõppe tarkvara* all mõeldud *Pidevstuudiumi* praeguses versioonis kasutatavat tehisõppe moodust. *Pidevõppe* viitab sellele, et süsteem on avatud, näidiseid ja tunnuseid võib õpet katkestamata ning juba õpitut unustamata pidevalt juurde lisada.

Magistritöö eesmärgid on järgmised:

- 1) luua Otepää looduspargi metsakasvukohatüüpide, metsade tüübirühmade, metsatüüpide ja puistutüüpide ning metsa kasvukohtade niiskuse ja karbonaatsuse esialgsed prognoosikaardid näidistele tugineva järeldamise ning pidevõppe metoodika abil;
- 2) katsetada ja võrrelda metsade tüübirühmade kaartide genereerimise kolme erinevat võimalust;
- 3) tuua välja puudujääke metoodikas ja lähteandmetes.

Kõik magistritöö tulemuste osas toodud hinnangulised kaardid on esialgsed, neid on kavas tulevikus välivaatlustega täpsustada.

Avaldan suurt tänu oma juhendajatele Kalle Remmile ja Jane Freyle. Otepää looduspargi taimkatte inventeerimise projektis osales välivaatlustes Jaanus Paal; Elle Roosluste, Mare Toom, Toomas Hirse ja Tiiu Kull abistasid taimede määramisel. Jaanus Remm ja Kaupo Kohv osalesid varasematel välitöödel, Jaanus Remm lisas ka 2005. a näidisalasid, Elle Meier ja Kristiina Sulbi lubasid kasutada oma vaatlusandmeid. Projekti rahastas Keskkonnainvesteeringute Keskus (leping nr 21, 4. augustist 2005). Kaartidel kasutatud Eesti Põhikaardi tausta kasutatakse vastavalt litsentsilepingule nr ST-02 00107.

2. Taimkatte suuremõõtkavaline kaardistamine

2.1. Taimkatte kaartidest ja nende loomisel kasutatud metoodikatest

Esimene kogu Eestit hõlmav ühtse metoodika järgi toimunud taimkatte suuremõõtkavaline kaardistamine viidi läbi aastatel 1934 – 1958, esialgu T. Lippmaa, seejärel L. Laasimeri juhtimisel ning nende välja töötatud taimkatteüksusi kasutades (Laasimer, 1965; Masing, 1979, 1991). Kaardistamine toimus vene nn üheverstalise topograafilise kaaardi alusel (mõõtkavas 1: 42 000), tulemused üldistati taimkatte kaartideks mõõtkavas 1: 200 000 ning 1: 600 000 (Laasimer, 1965; Masing, 1991). Kaardistamise välitööd kestsid kokku 21 aastat ja neist võttis osa 67 inimest (Laasimer, 1965).

1958. a alustati Eestis ajendatuna 1957. a rajatud looduskaitsealade taimkatte inventeerimise ja detailsema tundmaõppimise vajadusest looduskaitsealade taimkatte suuremõõtkavalist kaardistamist. Aluseks olid maa- ja metsakorralduse plaanid mõõtkavas 1: 5 000 ja 1: 10 000 ning tulemused üldistati üksikute looduskaitsealade kaartidena mõõtkavas 1: 5 000 kuni 1: 25 000 (Masing, 1991). Suuremate kaitsealade (Lahemaa rahvuspark, Haanja, Karula ja Otepää maastikukaitsealad) kaardistamisega tehti algust 1970. aastate lõpus (Kalda, 1991; Masing, 1991). Sel perioodil koostati ka taimkatte detailse kaardistamise juhendid (Eilart, Masing, 1961; Masing, 1966; Kalda, 1970; Marvet, 1970). Kuna valmistatud kaarte polnud võimalik kõigi kartograafia nõuete kohaselt vormistada ning trükkida, jäid nad laiemale kasutajaskonnale kättesaamatuks. 1950. aastate lõpus väljatöötatud metoodika sai aluseks suuremõõtkavalisele kaardistamisele järgnevatel aastakümnetel (Masing, 1991).

Taimkatte ruumilist paiknemist on uuritud ning väiksemaid alasid kaardistatud taimkatte kvantitatiivse uurimise käigus. Taimkatte kvantitatiivse hindamise eesmärgiks on teatud maa-ala taimkatte kirjeldamine, selle varieeruvuse uurimine või korrelatsiooni selgitamine taimkatte erinevuste ja kasvukohategurite vahel. Taimkatte kvantitatiivne kirjeldamine seisneb taimekoosluste puhul peamiselt kas koosluses esinevate liikide nimekirja koostamises koos liikide sageduste hinnangute või numbriliste väärtuste silmamõõdulise määramisega, või taimeliigi esinemise/puudumise kindlakstegemises uuritava koosluse väikestel proovipindadel. Nii geobotaanika kui ka taimegeograafia on suurel määral seotud taimede jaotumuse uurimisega. Üks põhilistest tulemustest kvantitatiivsete meetodite kasutamisel ökoloogias on jaotumuse (levikupildi) mustri täpsem määramine ja kirjeldamine. Muutused suuremas skaalas, mis huvitavad taimegeograafi, on kergesti kirjeldatavad ka kvalitatiivselt. Seetõttu pole vajadust kvantitatiivsete meetodite järele, kuigi need võivad osutada teatud juhtudel kasulikuks vahendiks erinevate levikumustrite võrdlemisel (Frey, 1969).

Taimkatte kaarte on loodud ka taimkatte inventuuride, näiteks metsa vääriselupaikade (Ek *et al.*, 1999) ja märgalade (Paal *et al.*, 1999) ning NATURA 2000 alade inventeerimise käigus.

Praegune kõige detailsem üleriigiline ühtsel metoodikal põhinev ning digitaalselt teostatud taimkatte kaart (GIS) on aastatel 1996-1998 satelliidipiltide põhjal loodud *CORINE* eraldise miinimumsuurusega 25 ha (mõõtkava 1: 100 000). Selliseid, kogu maapinda klassifitseerivaid, kuid taimkatteüksusi vaid väga üldistatult käsitlevaid kaardistusi on nimetatud maakattekaartideks (Meiner, 1999).

Praegusaegne suuremõõtkavaline, ühtse metoodika ja kvaliteediga teostatud kogu Eestit kattev tegeliku taimkatte kaart puudub. Suuremõõtkavalise kaardi all mõeldakse uurimuses mõõtkava 1: 10 000, keskmist eraldise suurust 1 ha, pikslisuurust 10 x 10 m.

Taimkatte suuremõõtkavaline kaart on vajalik ülevaate saamiseks nendest muutustest, mis on toimunud eelmise suuremõõtkavalise taimkattekaardi koostamisest möödunud aja jooksul. Uus kaart võimaldaks praegu kasutusel olevate taimkatteüksuste kontekstis hinnata ala looduslikku mitmekesisust detailsete üksuste – taimekoosluste ja kasvukohatüüpide tasemel, välja selgitada haruldaste ja ohustatud koosluste asukohad ning seisukorra, oleks objektiivseks aluseks loodusolude seire optimaalsel korraldamisel ja looduskaitse planeerimisel ning aitaks territoriaalse planeerimise ja territooriumi majandamise puhul otsuseid langetada.

Suuremõõtkavaline lauspinnaline välikaardistus on aeganõudev ja kallis. Üleriigilist välikaardistust tehakse vaid põhikaardistusel. Tugevasti liigestatud maastiku ühe ruutkilomeetri läbiuurimiseks ja ettevalmistatud kaardi- ja pildiandmete tõlgendamiseks taimkattekaardi märgisüsteemi kulub üks kuni kolm inimtööpäeva. Kaardistatava ala pindala Otepää looduspargis koos umbes 100 m laiuse väljapoole looduspargi piire jääva puhvertsooniga hõlmab ca 300 km². Sellise suurusega ala korral võib välikaardistusele kuluda 600 välitööpäeva. Seetõttu on lauseline välikaardistus taimkatte suuremõõtkavaliste kaardistuste puhul võimalik vaid juhul, kui kaardistatav ala on suhteliselt väike. Otepää looduspargi suuruse objekti puhul ja eriti juhul, kui silmas peetakse metoodika katsetamist taimkatte suuremõõtkavaliseks kaardistamiseks kogu Eesti ulatuses, on mõistlik kasutada prognoosivat kaardistust, mida saab vajadusel kombineerida välikaardistusega.

Suuremõõtkavaliste taimkatte prognoosikaartide genereerimise kõige paindlikum ja uutele andmetele avatuim lähenemisviis võiks olla näidistele tuginev järeldamine ja mitmesuguseid lähteandmeid (pildi- ja kaardi- ning vaatlusandmeid) kombineeritult kasutav tõenäosusliku kaardistamise metoodika. Kasvukohatüüpe või muid sarnaseid ruumilisi üksusi on kaardiandmetest varemgi tuletatud (Arold *et al.*, 1999; Remm, 2002). Ruumiliste muutujate või klassifikatsiooniüksuste kõrgusmudeli, mullaandmete ja üksikvaatluste järgi kaardistamise ja prognoosimise näiteid võib samuti maailmast leida (näiteks Klijn *et al.*, 1996; Bolstad *et al.*, 1998; Burrough *et al.*, 2001). Ka kaugseireandmete kasutamine taimkatte prognoosimisel on maailmas laialt levinud. Eestis on taimkatte kaardistamisel ning metsa inventeerimisel laialdaselt kasutatud nii satelliidipilte kui ka aerofotosid alates 1990. aastatest (Aaviksoo, 1995; Aaviksoo *et al.*, 1997; Aaviksoo *et al.*, 2000; Nilson *et al.*, 1999; Nilson *et al.*, 2000; Kuusk *et al.*, 2004; Meiner, 1999; Meiner, Aaviksoo, 2001; Palo, 1999), kuid kaugseire andmetele tugineval kaardistusel ei ole taimekoosluse tasemel üksusi seni enamasti eristatud, kuna lähteandmete detailsus ei ole piisav või ei ole seda nõudnud töö eesmärk. Detailsemad taimkatte kaardistused on tuginenud mahukatele välitöödele piiratud maa-alal, nende puhul on kasutatud üksnes ortofotode visuaalset interpreteerimist, mitte digitaaltöötlust (Palo, 1999). Aerofotod on siiani olnud peamiselt abivahendiks; neilt saadava informatsiooni täpsustamiseks valitakse välja võtmealad, kus toimub lauseline suuremõõtkavaline kaardistamine. Võtmealadest väljapoole jäävad alad kaardistatakse marsruutmeetodil (ka otstarbekamate marsruutide määramisel kasutatakse aerofotosid) või paralleelsetel mõõdistuskäikudel, mis katavad ettenähtud tihedusega kogu ala (Masing, 1979). Taimkattekaardi genereerimisel kaugseire- ja kaardiandmeid ning välivaatlusi kombineerituna kasutades saab eeldatavalt kaardistada nii ruumiliselt kui ka temaatiliselt detailsemaid taimkatteüksusi kui vaid ühte liiki kaugseire andmeid (Landsat TM kujutist või aerofotosid) kasutades. Samas laialdasemalt rakendatav metoodika olemasolevate aerofotode, satelliidipiltide ja kaardiandmete kombineeritud ning automatiseeritud kasutamiseks kasvukohatüüpide ja taimekoosluste kaardistamisel puudub (Remm, 2002).

Kogu Eesti kohta on olemas suuremõõtkavalised kaardi- ja kaugseireandmed (aerofotod, satelliidipildid, maapinna kõrgusmudel, mullakaart, põhikaart). Nende ning välivaatluste kooskasutamisel peaks olema võimalik kameraalselt ja suhteliselt kiirelt ülepinnaliselt genereerida uusi kaarte: maakattetüüpide, maakasutuse, taimkatte, kasvukohatüüpide ja liikide esinemistõenäosuse, võimalike kaardistusvigade ning maastikumuutuste hinnanguid jmt.

Loomulikult ei saa kameraalselt prognoositud kaardid olla päris täpsed. Samas sisaldavad kõik kaardid mingil määral vigu. 1: 10 000 mullakaarti, baaskaarti, põhikaarti on palju kritiseeritud. Ometi neid kaarte kasutatakse, sest need on kogu Eestit katvad ühtsed andmestikud. Ka välikaardistus ei ole absoluutne tõde. Prognoosivat kaarti on lihtne uuendada ning kaarti on alati võimalik vastavalt vajadusele ja võimalustele välitöödel täpsustada.

Otepää looduspargi territoorium, millele on omane väga mitmekesine pinnamood, mullastik ja taimkate, on kaardistamise seisukohast kahtlemata Eesti üks keerukamaid piirkondi, samas tuleneb sellest võimalus käsitleda siin saadud kogemusi ning kaardistamistööde meetodilisi arendusi kui pilootprojekti kogu Eestit hõlmava pidevalt uuendatava/täiendatava taimkattekaardi andmebaasi koostamiseks.

2.2. Taimkatte prognoosiv kaardistamine

Mingi nähtuse prognoosimiseks vajatakse kas statistilist mudelit, asjatundjat ehk eksperti või tehislisku ekspertsüsteemi. Taimkatte prognoosiva kaardistamise objektid on taimkatteüksuse või üksikliigi esinemistõenäosus, nende oodatav esinemisala või kõige tõenäolisem üksus uuritavas kohas.

Liikide leviku prognoosil ja elupaikade leviku modelleerimisel on enamasti kasutatud statistilise kirjeldamise ja modelleerimise meetodeid (Franklin, 1995; Guisan, Zimmermann, 2000; Remm, 2004a). Palju on kasutatud näiteks regressioonanalüüsi erinevaid vorme (Austin, 2002; Guisan, Zimmermann, 2000) ning ordineerimist, mis enamasti põhineb kanoonilisel vastavusanalüüsil. Tinglike tõenäosusjaotuste (*Bayesi mudelite*) järgi toimub suurem osa satelliidipõhisest taimkattekaardistusest (Remm, 2005b). Lisaks on kasutatud uuritava ala jagamist iga vaadeldud faktori järgi sobivaks ja mitesobivaks (*environmental envelopes*) (Brito *et al.*, 1999) ning klassifikatsioonimeetodeid. Viimatinimetatute hulka kuuluvad klassifikatsiooni- ja regressioonipuud ning kindlatel reeglitel või tõenäosusjaotustel põhinevad klassifikatsioonid; viimastest näiteks suurima tõepära klassifikatsioonid ja hägused klassifikatsioonid (Burrough *et al.*, 2001; Hall, Arnberg, 2002). Kõige sagedamini kasutatav meetod satelliidipildi interpreteerimiseks on suurima tõepära hinnangutel põhinev valvega klassifitseerimine. Suurima tõepära hinnangute kasutamine metsatüüpide eristamisel võib olla raskendatud (Aaviksoo *et al.*, 2000), seetõttu kombineeriti näiteks Eesti 1: 50 000 baaskaardi ning CORINE maakattetüüpide kaardi koostamisel arvutatud klassifikatsiooni selle usaldatavuse tõstmiseks satelliidipiltide visuaalse interpreteerimisega (Remm, 2004a).

Liikide või koosluste leviku prognoosimisel laialdaselt kasutatud otsuste puul põhinevaid tehnikaid (klassifikatsiooni- ja regressioonipuud) (De'ath, Fabricius, 2000; De'ath, 2002; Debeljak *et al.*, 1999; Debeljak *et al.*, 2001; Hansen *et al.*, 2001; Stankovski *et al.*, 1998; Kobler, Adamic, 2000) ning *k*-lähima naabri meetodit loetakse olenevalt masinõppe rollist iteratiivsel parima lahendi otsimisel kas statistiliste meetodite või tehisintellektimeetodite hulka kuuluvaks (Remm, 2004a). Metsakoosluste kaardistamisel on otsuste puud kasutanud näiteks Moore *et al.* (1991).

Intellektitehnika hulgast on lisaks otsuste puule tuginevatele ekspertsüsteemidele kasutatud tehisnärvivõrke (*artificial neural networks*, ANN) ja samuti ekspertsüsteemide hulka kuuluvat näidistele tuginevat järeldamist. ANNi on kasutanud näiteks Fitzgerald ja Lees (1992) maakatte/floristiliste klasside prognoosimiseks, Kimes *et al.* (1999) metsa kaardistamisel ja selle vanuse määramisel, Hilbert ja Ostendorf (2001) mineviku taimkatte modelleerimisel, Mas *et al.* (2004) metsade kadumise prognoosikaartide koostamisel. ANNi kasutatakse päris palju kujutise, eriti satelliidipildi töötlemisel (näiteks Fitzgerald, Lees, 1992; Kimes *et al.*, 1999; Mas *et al.*, 2004). Kunstlike närvivõrkude ökoloogias kasutamist on käsitlenud Lek *et al.* (1996), Lek ja Guégan (1999), Foody (1999). Sarnaste näidiste kasutamisel põhinevaid meetodeid on otsuste puudest vähem kasutatud ning need on ökoloogide seas tõenäoliselt vähem tuntud (Remm, 2004a). Sarnaseid analooge on kasutatud taimkatte prognoosiks ja kaardistamiseks (Osborne, Brearley 2000; Wilds *et al.*, 2000; Remm, 2002, 2004b; Bock *et al.*, 2005), paleoökoloogilistes rekonstruktsioonides (Birks, 1993; Flower *et al.*, 1997). Tugev näidistele tugineva prognoosimise koolkond on Soome metsakorralduses (Remm, 2005b), kus *k*-lähima naabri meetodit on metsade inventeerimisel kasutatud alates 1990. aastatest (Remm, 2004a). Piksli sarnasust etalonile on kasutatud metsakorralduse jaoks huvi pakkuvate pidevate muutujate, näiteks puidu tagavara prognoosimiseks (Tokola, 2000; Mäkelä, Pekkarinen, 2001; Kilpeläinen, Tokola, 1999; Muinonen *et al.*, 2001; Pekkarinen, 2002) või metsakahjustuste hindamisel (Heikkilä *et al.*, 2002) satelliidipiltide järgi. Näidistele tuginevat prognoosimist on kombineeritud pildikujutise eelneva eraldisteks segmenteerimisega (Mäkelä, Pekkarinen 2001; Pekkarinen, 2002).

2.3. Näidistele tuginev järeldamine

Ekspertsüsteemil võib olla teatud iseõppimise ehk kogemuse järgi kohanemise ehk tehisõppe võime ehk tehisintellekt. Tehisõppe tugineb suures osas dünaamilise mälu teooriale (Schank, Abelson, 1977; Schank, 1982), mille kohaselt langetatakse otsuseid uut situatsiooni varasemate kogemustega võrreldes ja kõige sarnasemaid näidiseid eeskujudena kasutades (Remm, 2004a).

Tehisõppe puhul võib eristada *innukat õpet* ja *laiska õpet* (*eager learning & lazy learning*). Innuka õppe puhul üldistatakse uus kogemus esimesel võimalusel ja algandmeid ei säilitata, järeltõlgitakse tehakse valmis reeglite järgi (*rule-based reasoning*, RBR). Innuka käsitluse eeliseks on suure hulga lähteandmete asendamine väiksema hulga üldistustega (Remm, 2004a, 2005b).

Laisa õppe puhul kogemuse üldistamisega ei kiirustata. Vaatlused ja kogemused hoitakse originaalkujul ning neid töödeldakse vaid otsese vajaduse korral. Andmetest tehakse prognoosimiseks järeltõlgitust nii otse kui võimalik, ilma vahepeal mudelit koostamata võimalikult vähe üldistades ning lahenduse leidmise vaheprodukte säilitamata. Otsuste langetamine toimub uut olukorda või uusi vaatlusandmeid mälus olevatega võrreldes (*case-based reasoning*, CBR). Näidistele tuginev järeldamine on statistilise modelleerimise alternatiiv ja äärmiselt empiiriline tehisintellektimeetod, mille puhul ei kulutata vahendeid (ennatlike) abstraktsioonide loomisele ning algandmeid saab kasutada mitme eri tüüpi ülesande lahendamiseks. Lisaks on süsteem avatud uutele andmetele, s.t vaatluste lisandumisel ei ole vajadust mudeli loomist otsast alustada, nagu statistiliste mudelite puhul (Remm, 2004a, 2005b). Mitteparameetrilised statistilised meetodid, näiteks üldistatud aditiivsed mudelid, võivad olla küll sama paindlikud kui tehisintellektimeetodid, kuid nõuavad siiski formaalset mudelit (Aha, 1998; Remm, 2004a, 2005b).

Näidistele tugineval prognoosival kaardistamisel otsitakse prognoositavale vaatlusele, objektile või kohale olemasolevate vaatluste hulgast kõige sarnasemaid näidiseid, eeldades seejuures, et kaardistatava nähtuse esinemistõenäosus on suurem kohtades, mis on sarnased kohtadele, kus nähtust on varem registreeritud. Näidisteks võivad olla juhuslikud objektid empiirilistest vaatlustest, sihilikult valitud tüüpiliseks peetavad eksemplarid või tüüpiliste näidiste konstruktsioonid. Selles uurimuses on tegemist teisena nimetatud variandiga – õpetusandmeteks on tüüpilisteks peetavate kohtade kirjeldused. Näidiste komplekt või selle koostamise reeglid väljendavad uurija arusaama klassifikatsiooniüksustest, muutes selle, ühest küljest väga paindliku ja universaalse klassifitseerimis- ja prognoosimeetodi suhteliselt subjektiivseks. Näidiste abil saab prognoosida nii pideva muutuja väärtust kui ka nominaalse muutuja klassikuuluvust (klassifitseerimine). Näidistele tuginev järelamine on lähedane mustrituvastusele (*pattern recognition*) – mõlemate lähenemisviiside puhul langetatakse otsuseid sarnasuse alusel. Näidistele tuginev süsteem erineb teistest ekspertsüsteemidest otsuste puu puudumise poolest (võib puududa) ning mustrituvastuse vallas juba aastakümneid tuntud k -lähima naabri meetodist tehisoõppe kasutuse poolest (Remm, 2004a, 2005b).

Sarnasusele tuginevate otsuste eeliseid modelleerivate meetodite ees on täheldatud juhtudel, kui muutujate jaotused ja muutujate koosmõjud ei ole lihtsalt kirjeldatavad. Keerukate nähtuste ja seoste korral, kus lihtsad abstraktsioonid pole tõepärased, on tulemused näidiste kasutamisel paremad ning lisaks on näidiste abil probleemide lahendamine intuiitiivselt hästi mõistetav. Kõik statistilised prognoosimeetodid põhinevad mingitel eeldustel, näiteks on diskriminantanalüüsi kasutamise eelduseks, et muutujad on normaaljaotusega ja pole korreleeritud. Enamik tehisintellektimeetoditest aga ei põhine normaaljaotuse eeldusel treeningandmetes. Laisa õppe eelis teiste meetodite ees ongi eelkõige suur paindlikkus. Lähteandmed võivad olla mistahes tüüpi ja mistahes jaotusega. Näidiste kasutamise ainus eeldus on, et objektide sarnasust peab olema võimalik arvuliselt mõõta ja võrrelda (Aha, 1998; Remm, 2005b).

Tehisintellekti kasutatav ekspertsüsteem hoiab oma teadmisi teadmiste baasis, mis võib sisaldada nii üldistusi (statistilisi parameetreid, reegleid, mudeleid) kui ka töötlemata lähteandmeid. Esimesel juhul nimetatakse teadmiste baasi *reeglite baasiks* (*rule-base*), teisel juhul *näidiste baasiks* (*case-base*) (Aha, 1998; Remm, 2005b).

Andmetöötlusmeetoditest hõlmab innukas õpe statistilist modelleerimist, mitmesuguste klassifikatsiooniskeemide loomist (otsuste puid) ja tehisnärvivõrke. Laisa õppe arvutuslikud meetodid kasutavad valdavalt kas k -lähimat naabrit, tõenäosuslikke hinnanguid või tunnusruumi segmenteerimist. Satelliidipildi tõlgitsemise viisidest oleks signatuuride kui maakatteklassi statistiliste üldistuste loomine innuka õppe väljendus, klassifitseeritavate pikslite võrdlemine õpetusalade üksikpikslitega aga laisale õppele vastav tegutsemisviis (Remm, 2004a, 2005b).

Nii nagu statistilised mudelidki, tuleb ka näidistele tuginev ekspertsüsteem õpetusandmetele sobitada ehk välja õpetada ehk optimeerida. Süsteemi optimeerimise põhivahendid on näidiste ja tunnuste valik ning neile parimaid prognoose tagavate kaalude leidmine. Tunnuste kaalumise võib lisaks parimate prognooside saamisele anda ka sisulist teavet faktorite mõju vahekordade kohta ning selle kohta, millised tunnused on olulisemad. Samuti saab näidiste kaalude järgi leida vaatlused, mis hinnatavaid klasse kõige paremini iseloomustavad ning ebatüüpilised, valesti määratud või teisi dubleerivad näidised kõrvale heita (Remm, 2004a, 2005b). Tunnuste ja vaatluste komplekti, sarnasuse arvutamise reeglid, otsuse langetamisel kasutatavate näidiste arvu ja sarnasuse kriitilised väärtused otsustab reeglina kasutaja, kuid võimalik on ka nende muutujate sobivaimate väärtuste automatiseeritud otsimine.

Näidistele tuginevaid järeldusi on kasutatud paljudes teadusharudes ja elualadel, kus teooriad ja seaduspärasused ei ole täiesti ranged, on aga olemas ulatuslikud empiirilised andmestikud ning kus varasemad kogemused (üksikjuhtumid) domineerivad deduktiivsete järelduste üle: meditsiinis, pedagoogikas, nõustamisel, projektide maksumuse ja finantsriskide hindamisel, tehniliste rikete diagnoosil, maastiku ja linnade ning ressursside kasutuse planeerimisel, kaitsejõududes, tekstiitöötuses, kõnetuvastuses, masintõlkes, pilditöötuses ning kujutiste ja mitmesuguste objektide tuvastuses, tarkvaraarenduses. Ökoloogiaski domineerivad üksikfaktid üldistuste üle ja järeldused on enamasti pigem näidiste-põhised kui teooriapõhised (Remm, 2004a).

Ülevaateid näidistele tugineva järeldamise kohta on kirjutanud näiteks Mitchell (1997), Wettschereck *et al.* (1997), Wilson ja Martinez (2000), Remm (2004a).

3. Andmed ja metoodika

3.1. Uurimisala

Otepää looduspark asub Valga maakonna põhjaosas Otepää, Palupera, Puka ja Sangaste valla maadel, maastikuliselt (Arold, 2005) Otepää kõrgustikul. 1180 km² suurusest Otepää kõrgustikust hõlmab Otepää looduspark hästi väljakujunenud künkliku reljeefiga kõrgustiku keskosa pindalaga 224,3 km² (19% kõrgustiku pindalast). Territooriumi ulatuselt on Otepää looduspark suurim maastikukaitseala Eestis (Otepää..., 2003; Arold, 2005).

Otepää kõrgustik on künklik-nõolise pinnamoega liustikukuhjelisel saarkõrgustikul kujunenud maastikurajoon (Arold, 2005). Kõige suurema osa Otepää kõrgustiku pindalast (umbes 50%) hõlmavad moreenkõrgustikud ja moreenkattega mõhnad, järgnevad (ligi 20%) fluvio- ja limnoglatsiaalsed mõhnastikud, väiksema osa moodustavad moreentasandike ja jääpaisjärvede abrasioonitasandikud ning keeruka ehitusega suurvormid. Iseloomulikud on üsna suure nõlvade kalde (5...30°) ja suhtelise kõrgusega (10...25 m) moreenkattega künkad ja mõhnad. Muldade lähtekivimiks on enamasti moreen (Hang, Karukäpp, 1979; Arold, 2005).

Kõrgustiku keskmine kõrgus on 126,6 m ü.m.p; 200 meetrini ja üle selle ulatuvaid kõrgendikke on 19 (Hang, 1976). Põhiline osa kaitsealast asub 100-175 m kõrgusel ü.m.p, kõrgeim punkt asub Kuutse mäel (217 meetrit ü.m.p) (Otepää..., 2003). Pühajärve vagumus jagab kõrgustiku ulatuslikumaks, kuid laugjamaks idaosaks ning väiksemaks, aga tervikuna kõrgemaks lääneosaks (Hang, 1976). Nii ida- kui edelaosas ilmneb kõrgendike paiknemises kirde-edelasihiline vööndilisus, mis märgib liustikuserva pikemaageid asendeid (Arold, 2005).

Muld- ja taimkatte kujunemisel on määravaks olnud pinnakatte valdavalt savikas koostis. Nii mõhnu katval 1...2 m paksusel moreenil kui ka moreenküngaste karbonaadirikkal veeriselisel saviliival ja liivsavil on kujunenud üsna viljakad leetjad ja leostunud mullad (Kont, 1986). Paljudes kohtades on viirudena punakaspruunil moreenil näivleetunud muldi. Üldiselt on muldkate väga vaheldusrikas, eriti väikesekünklikel aladel. Kõigil nõlvadel toimub sadeveega mingil määral mulla erosioon (Arold, 2005).

Järsakute ja väikeste põllulappide ning soo-heinamaade metsastumise arvel on Otepää kõrgustik muutunud metsarikkaks. Viimase 80 aasta jooksul on metsasus kõrgustikul suurenenud ligi kolm korda, olles praegu kaugseire andmeil (CORINE kaardi järgi) 46%, lisaks toimub söötide ning karjamaade metsastumine. CORINE kaardi järgi domineerivad kõrgustikul segametsad. Otepää kõrgustikul valdavad karbonaadirikkamal moreenil kujunenud hea niiskusvaruga muldadel kasvavad salumetsad (Arold, 2005). Küllaltki suurel alal on levinud ka laanemetsad, vähem on madalsoo-, kõdusoo- ning palumetsi (Otepää..., 2003). Õhukese moreenikihi mõhnade kuivadel nõlvadel ja fluviomõhnadel kasvavad sürjametsad. Madalamate ja karbonaadivaesemate kõrgendike näivleetunud muldadel on tüüpilised jänese kapsa laanekuusikud, kohati jänese kapsa-pohla-männikud. Liivast limnomõhnade toitekehvadel kuivadel leedemuldadel on iseloomulikud sambliku- ja kanarbikumännikud. Kõrgustiku kagunõlva sandurit katavad peamiselt palumännikud (Arold, 2005). Metsade kaitseks on loodud looduspargis kaks sihtkaitsevööndit: üks asukohaga Madsal ning teine Elva jõe ääres (Otepää..., 2003).

Otepää looduspargile on iseloomulik väikeste soode rohkus. Valdavalt on levinud madalsood (umbes 85% looduspargi soodest), kuid leidub ka allikasoid, järvi ümbritsevaid õõtsiksoid,

harvem siirdesoo- või rabalaike (Otepää..., 2003). Nõgude madalsoodele on iseloomulikud tarnakooslused, puis-madalsoodes sageli ka sookastikukooslused (Arold, 2005).

Siinsete maastike kujunemisel on läbi aegade olnud suur mõju inimtegevusel. Samas on just künklik pinnamood seadnud majandamisele omad piirid, mistõttu niidud ja põllulapid on killustatud ning väikesepindalised. Küngaste nõlvu katavad aruniidud, liigniisketes nõgudes ja jõeorgudes võib leida soostunud ja madalsooniite. Elva jõe ning Väike-Emajõe ääres esineb osaliselt säilinud lamminiite (Otepää..., 2003).

3.2. Kaardi- ja pildiandmed

Pildi- ja kaardiandmete kasutamiseks näidistepõhisel taimkatte ja kasvukohtade kaardistamisel valmistati kaardilehtede, millelt on kogutud Otepää looduspargis esinevate taimkatte üksuste näidisalade andmeid, kohta ette seletavate tunnuste andmekihid. Andmekihtidest arvutati näidisaladel ja hinnataval alal pildimustrit kirjeldavaid indekseid.

Tehisõppes ja prognoosis kasutatavatel ruumiandmete, eraldiste ja eelklassifikaatorite kihtidel peavad olema täidetud järgmised nõuded. Kõik kihid peavad olema salvestatud kokkupakkimiseta ja ridupidi binaarsetesse ilma heederita ühebaidilistesse rasterfailidesse (*Idrisi32 rst*-faili formaat). Iga andmekiht peab asuma omaette kataloogis. Kõik rasterfailid peavad olema Eesti Põhikaardi projektsioonis ja ristkoordinaatide süsteemis (LAMBERT-EST97) (Keskkonnaministri..., 2004) ja iga fail esindama ühte 10 × 10 km kaardilehte. Faili nimeks olgu kaardilehe neljakohaline number laiendiga *rst*, näiteks *5434.rst*. Ridade ja veergude arv rastris peab olema võrdne. Sama andmekihi failid peavad olema sama pikslisuurusega; pikslilikülje pikkus võib olla suvaline, ka murdarvuline.

Andmekihtide metaandmed fikseeritakse andmekihtide andmebaasis (ptk 3.5.1.1). 2006. a alguse seisuga oli andmebaasi *Pidevõppe_andmekihid.mdb* tabelis *Akihid Pidevstuudiumi* jaoks ette valmistatud 56 andmekihi metaandmed. Otepää looduspargi taimkattetunnuste tehisõppes kasutati andmekihtide hoidlas olevatest andmekihtidest 48 (tabel 3.2.1). Ühte andmekihtidest saab kasutada eelklassifikaatorina. Lisaks originaalandmekihtidele saab hinnanguliste kaartide genereerimisel *Pidevstuudiumis* kasutada eelnevalt valmis arvutatud seletavate tunnuste (asendustunnuste) kihte ning interpoleerimiseraldiste andmekihti. Eelklassifikaatori ja interpoleerimiseraldiste kihid võivad muuhulgas määratleda kaardistatava ala (ptk 3.5.1).

Järgnevates alapeatükkides on esitatud andmekihtide ettevalmistamise kirjeldus andmekihitüüpide (põhikaart, mullakaart, kõrgusmudel, ortofotod, metsakorraldusfotod ning satelliidipildid) kaupa.

Tabel 3.2.1. Seletavate tunnuste andmekihid. *Pkylg* — pikslikülje pikkus meetrites, *kataloog* — failide paiknemise kataloogi nime lõpuosa, *alates* — kihi andmete kehtivusaja algus, *kuni* — kihi andmete kehtivusaja lõpp, *baite* — baitide arv piksli kohta binaar-rastris, *Ote* — kasutus Otepää looduspargi taimkatte kaardistuses.


Pkylg	kataloog	alates	kuni	baite	Ote
5	...\PK-uusim	1.jaan.04	1.jaan.10	1	jah
5	...\PK-eelmine	1.jaan.99	1.jaan.04	1	jah
10	...\elev_dm	1.jaan.90	1.jaan.10	2	jah
10	...\muld_10	1.jaan.90	1.jaan.10	1	jah
10	...\muld_12	1.jaan.90	1.jaan.10	1	ei
10	...\muld_57	1.jaan.90	1.jaan.10	1	jah
10	...\loim	1.jaan.90	1.jaan.10	1	jah
1	...\Ortof-1m-R	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-G	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-B	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-Y	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-H	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-S	1.mai.02	1.juuni.03	1	jah
1	...\Ortof-1m-L	1.mai.02	1.juuni.03	1	jah
2,5	...\Metsakorraldusfoto-R	1.mai.99	1.aug.01	1	jah
2,5	...\Metsakorraldusfoto-G	1.mai.99	1.aug.01	1	jah
2,5	...\Metsakorraldusfoto-B	1.mai.99	1.aug.01	1	jah
2,5	...\Metsakorraldusfoto-L	1.mai.99	1.aug.01	1	jah
25	...\ETM-186_019-10-07-1999-B1	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-10-07-1999-B2	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-10-07-1999-B3	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-10-07-1999-B4	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-10-07-1999-B5	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-10-07-1999-B7	10.juuli.99	10.juuli.99	1	jah
50	...\ETM-186_019-10-07-1999-B62	10.juuli.99	10.juuli.99	1	jah
25	...\ETM-186_019-30-09-2000-B1	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B2	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B3	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B4	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B5	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B7	30.sept.00	30.sept.00	1	jah
50	...\ETM-186_019-30-09-2000-B62	30.sept.00	30.sept.00	1	jah
25	...\ETM-186_019-30-09-2000-B8	30.sept.00	30.sept.00	1	jah
25	...\ETM-187_019-16-05-2000-B1	16.mai.00	16.mai.00	1	jah
25	...\ETM-187_019-16-05-2000-B2	16.mai.00	16.mai.00	1	jah
25	...\ETM-187_019-16-05-2000-B3	16.mai.00	16.mai.00	1	jah
25	...\ETM-187_019-16-05-2000-B4	16.mai.00	16.mai.00	1	jah
25	...\ETM-187_019-16-05-2000-B5	16.mai.00	16.mai.00	1	jah
50	...\ETM-187_019-16-05-2000-B62	16.mai.00	16.mai.00	1	jah
25	...\ETM-187_019-16-05-2000-B7	16.mai.00	16.mai.00	1	jah
10	...\ETM-187_019-16-05-2000-B8	16.mai.00	16.mai.00	1	jah
25	...\ETM-186_019-23-05-2005-B1	31.mai.02	23.mai.05	1	jah
25	...\ETM-186_019-23-05-2005-B2	31.mai.02	23.mai.05	1	jah
25	...\ETM-186_019-23-05-2005-B3	31.mai.02	23.mai.05	1	jah
25	...\ETM-186_019-23-05-2005-B4	31.mai.02	23.mai.05	1	jah
25	...\ETM-186_019-23-05-2005-B5	31.mai.02	23.mai.05	1	jah
50	...\ETM-186_019-23-05-2005-B62	31.mai.02	23.mai.05	1	jah
25	...\ETM-186_019-23-05-2005-B7	31.mai.02	23.mai.05	1	jah
10	...\ETM-186_019-23-05-2005-B8	31.mai.02	23.mai.05	1	jah
25	...\ETM-187_018-06-07-2001-B1	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B2	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B3	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B4	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B5	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B62	6.juuli.01	6.juuli.01	1	ei
25	...\ETM-187_018-06-07-2001-B7	6.juuli.01	6.juuli.01	1	ei

3.2.1. Põhikaart

3.2.1.1. Andmekihid

1: 10 000 põhikaardi originaal-andmekihte on kaks ning need sisaldavad erinevast ajast pärit põhikaardi kaardistuse andmeid (tabelis 3.2.1 vastavalt *eelmine* ja *uusim* kihi kataloogi nimes; *PK* on põhikaardi lühend). Osade kaardilehtede kohta (kaardilehed numbritega 5434, 5435, 5444, 5445) on olemas kahe põhikaardi kaardistuse andmed. Kaardilehtede puhul, mille kohta teist kaardistust pole tehtud (5423, 5424, 5433, 5443), on põhikaardi mõlema kihi kataloogis samad failid. Eesti Põhikaardi lehtede paiknemise skeem Otepää looduspargi alal on toodud joonisel 3.2.1.

Erinevate aastate põhikaardikihtide kasutamine võimaldab eeldatavalt paremini ära tunda taimkatteüksusi, mille põhiala on kahe kaardistuse vahel muutunud — näiteks noorendikke, mis eelmisel põhikaardil olid raiesmikud ning üksust *noor mets söödil*, mis eelmisel põhikaardil oli *põld*, uuemal kaardistusel aga märgitud *nooreks metsaks*. Erinevate aastate põhikaardikihtide prognoosivõime erinevate taimkatteüksuste osas võib olla erinev, vastavalt sellele, kui detailselt erineval ajal midagi kaardistatud on. Näiteks on madalsoid osadel eelmise põhikaardi kaardistuse kaardilehtedel detailsemalt kujutatud kui uuemas kaardistusvoorus.



Joonis 3.2.1. Eesti Põhikaardi lehed Otepää looduspargi alal.

3.2.1.2. Põhikaart eelklassifikaatorina

Põhikaardikihte kasutatakse õpetuskohtade indeksite ning prognoosikaartide arvutamisel eelklassifikaatorkihtidena. Eelklassifikaatorklassideks on põhikaardi põhialad. Õpetusandmete mustriindeksite arvutamisel on põhikaart nn ruumiliseks eelklassifikaatoriks ehk ruumiliste piiride kihiks, mis võimaldab õpetusvaatluste indekseid arvutada vaid põhikaardi põhialade piires. Prognooside arvutamisel leitakse prognoositavale pikslile kõige sarnasem näidis ainult põhikaardi sama põhiala kui temaatilise eelklassifikaatori piirest. Kuna hinnangulised kaardid on piksliküljega 10 m, siis kasutati nende genereerimisel eelklassifikaatorkihina samuti 10 m piksliküljega uusimat põhikaardikihti (originaalkihi piksli küljepikkus on 5 m).

Põhikaardil kasutatud põhialade arv ja määratlused on eri aastatest pärit kaardistustes veidi erinev. Näiteks ei eristata uuematel põhikaardi kaardistustel (alates 2000. a) varem eraldi põhialana käsitletud *püsirohumaad rohumaast*, varasema *õue* asemel tehakse vahet *eraõuel* ja *tootmisõuel* ning *hukkunud puistu* on põhialast muudetud täiendalaks (Eesti põhikaardi..., 2000). Eelklassifikatsiooni kasutamine kiirendab kaardi arvutamist ning võimaldab põhikaardi maakatteklasside piiride kujul arvesse võtta kõige täpsemat ruumilist informatsiooni, säilitades seeläbi taimkatteüksuste kaardil põhikaardi põhialade piirid (Remm, 2002; Remm, 2004a).

Siiani on taimkatte prognoosimisel eelklassifikaatorina kasutatud vaid põhikaarti.

3.2.1.3. Põhikaardi rasteriseerimine

1: 10 000 digitaalne põhikaart on vektorformaadis. *Pidevstuudium* kasutab aga vaid rastervormis andmekihte. Põhikaardi põhialade rasteriseerimiseks ühtsesse binaarformaati saab kasutada erinevaid mooduseid. Järgnevalt on kirjeldatud kahte varianti, kuidas *Micristationi* vormingus põhialasid rasteriseerida. Allpool kirjeldatud teisendused *Microstationi* vormingust *ArcView* vormingusse on üleliigsed juhul, kui kõigi vajalike põhikaardi lehtede põhialade andmekiht on Riigi Maa-ametist saadud *ArcView* vormis.

Ühe võimalusena võib 10 × 10 km kaardilehe (neli 5 × 5 km põhikaardi lehte korraga) *psh*-failid *Microstationis* *dxg*-formaati konverteerida, avada need siis *Idrisi32s* vektorkihina ning seejärel sealsamas etteantud parameetritega rasterfaili rasteriseerida. Kui suurema eraldise sees olevad saarelised teist klassi alad on *dgn*-failis salvestatud sümbolina (*cell*), siis lähevad saared paraku kaduma ja kirjeldatud teisendusviis ei anna korrektseid tulemusi.

Saarelised eraldised konverteeruvad õigesti, kui kasutada rasteriseerimiseks tarkvarapaketti *ArcView*. Kõigepealt tuleb avada 10 × 10 km küljega kaardilehe neli *Microstationi* formaadis (*dgn*-laiendiga) vektorfaili *ArcView* vaates, konverteerida need sama programmi *shp*-vormingusse, ühendada seejärel neli 5 × 5 km küljega kaardilehte *ArcView*'s üheks *shp*-failiks ning viimane *grd*-vormi võrgustikuks (*grid*) konverteerida. Võrgustiku tekitamise käigus tuleb määratleda piksli suurus ja rastri piirid ning põhikaardi põhiala tunnusatribuut — värvikood piksliväärtuseks. Seejärel eksporditakse võrgustik *flt*-formaadis binaar-rastriks, mis omakorda imporditakse *Idrisi32* täisarvulisse rasterformaati.

ArcView loeb sümbolina salvestatud alade värvikoodi sümboli päisest, mitte komponentidelt, nagu *Microstation* seda teeb. *Microstationi* vormingus põhikaardi failides sümbolina salvestatud saareliste eraldiste päises värvikoodi enamasti ei ole. Seetõttu tuleb saareliste eraldiste kategooria õigeks ülekandmiseks värvikood enne teisendamisoperatsiooni sümbolite päisesse kanda. Komponentide värvikoodi komplekseraldise päisesse kirjutamiseks kasutati *Microstationi* programminaga *cellidevärvid.bas* (lisa 1).

Põhikaardi andmekihid rasteriseeriti piksliteks küljepikkusega 5 m.

3.2.2. Mullakaart

3.2.2.1. Andmekihid

1: 10 000 digitaalse mullakaardi andmekihte on kokku neli: lõimiseandmetega kiht (tabelis 3.2.1 sõna *loim* kataloogi nimes) ning 57, 12 ja 10 lihtsustatud mullaklassiga andmekihid (tabelis 3.2.1 sõna *muld* ning klasside arv kataloogi nimes).

3.2.2.2. Mullakaardi rasteriseerimine ja andmete teisendamine

Mullakaardist tuletatud andmekihtide ettevalmistamisel tuleb kõigepealt *Microstationi* või *ArcView* formaadis olevad mullakaardi failid samamoodi, nagu eelmises alapeatükis kirjeldatud, rasteriseerida (ptk 3.2.1.3). Iga rastrielemendi väärtuseks saab sellele vastavas kohas oleva vektoreraldise tunnusnumber. Seejärel tuleb käivitada programm *Mullarasteriseerimine*. Programmi dialoogiaknas tuleb sisestada sisend- ja väljundparameetrid (joonis 3.2.2). Rasteriseerimisel kasutatavad teisendamistabelid on andmebaasis *Mullarasteriseerimine.mdb* ning mullaeraldiste kirjeldused 1: 10 000 mullakaardi juurde kuuluvas andmebaasis (iga 10 × 10 km kaardilehe kohta on eraldi tabel). Failideks, millest programm loeb eraldiste numbrid, on eraldiste tunnusnumbritega binaar-rastrid. Failideks, kuhu programm kirjutab mullakoodid, on eelnevalt loodud tühjad binaar-rastrid.

Programm *Mullarasteriseerimine* leiab mullakaardi andmebaasist eraldise tunnusnumbrile vastava kirjelduse, teisendab koode ühest klassifikatsioonisüsteemist teise (lihtsustab klassifikatsiooni), jagab segaeraldiste pikslid eraldisele omistatud klassidesse vastavalt andmebaasis kirjas olevale klasside osakaalule selles eraldises ning omistab teisendatud koodide numbrilised väärtused väljundrastri pikslitele. Klassifikatsiooni lihtsustamine on vajalik, kuna erinevate koodide suur hulk (mis on osaliselt tingitud tekstilise koodi vigasest või varieeruvast kirjutamisviisist) takistab andmete automaattöötlust (Remm, 2002). Näiteks on 2006. a märtsikuu seisuga rasteriseeritud kaardilehtedelt mullarasteriseerimise andmebaasi kantud 8229 erinevat lõimisekoodi. Segaeraldiste puhul on sama eraldise kirjelduses näidatud kuni neli erinevat mullaliiki, kusjuures nende paiknemise kohta eraldiste sees andmed puuduvad. Mullaeraldised on enamasti suhteliselt suured ja asuvad vahelduva pinnamoega metsasel maastikul

Mullaliikide ja lõimiste lihtsustatud klassifikatsioonide üksused on andmebaasi *Mullarasteriseerimine.mdb* tabelites *Mullakoodid* ja *Lõimisekoodid*. Klassifikatsiooniüksuste üleminekutabelite nimed on *Mullaklassid* ja *Lõimiseklassid*. Need tabelid peavad sisaldama kõiki rasteriseeritud kaardilehtedel olevaid koode ja detailsema süsteemi koodidele vastavaid lihtsustatud klassifikatsiooni koode. Kui töödeldava kaardilehe andmebaasis on teisendus-tabelitest puuduvaid koode, siis kirjutab programm need eraldi tekstifaili. Iga üleminekutabelist puuduva koodi puhul peab inimene otsustama, millisele lihtsustatud klassile see vastab ning teisenduskirje üleminekutabelisse lisama.

Mullakaardi rasteriseerimine

☒ Lõimise rasteriseerimine
☐ Mullaliigi rasteriseerimine

Andmebaas, kus on teisendamistabelid
C:\mullarasteriseerimine\Mullarasteriseerimine.mdb vali

Andmebaas, kus on mullaeraldise kirjeldused
C:\ANDMED\muld_10t\muld-10t.mdb vali

m5444 mullatabeli nimi

Puuduvate koodide väljundfail
C:\mullarasteriseerimine\5444puudu.txt vali

Binaarraster eraldiste numbritega
C:\CBR\C-S\mullamlink\5444mullamlink.rst vali

Binaarraster, kuhu kirjutatakse mullakoodid
C:\CBR\C-S\muld_54\5444.rst vali

Katkesta 1000000 pikslite arv binaarrastrites Jätka

Joonis 3.2.2. Programmi *Mullarasteriseerimine* dialoogiaken.

3.2.2.3. Sarnasusmaatriksid

Looduses esinevad nähtused on enamasti pidevad ja üleminekulised, mitte diskreetsed. Seetõttu tuleb üsna sageli ette olukorda, kus mingi kasvukohatüüp esineb looduses mullal või lõimisel, millel see teooria kohaselt esineda ei tohiks.

Lihtsaim viis nominaalsete tunnuste vahelise sarnasuse määramiseks on klassikoodide vastavuse kontrollimine. Kui klass on sama, siis on vaatlused selle tunnuse poolest täiesti sarnased. Kui klass on erinev, siis sarnasus puudub. Näiteks kui üks vaatlus on keskmisel ja teine sügaval rabamullal, siis on need vaatlused mulla poolest sama vähe sarnased kui sügav rabamuld ja õhuke paepealne muld, kuigi esimesel juhul on tegemist vaid turbakihi tüseduse poolest erinevate mullaliikidega, teisel juhul aga nii veerežiimi kui karbonaatsuse telgede erinevates otsades paiknevate mullaliikidega. Keskmise ja sügava rabamulla ühendamine üheks klassiks muudaks need aga samatähenduslikeks.

Pidevstudium oskab nominaalsete tunnuste kategooriate vahelist sarnasust ehk nn oma-sarnasust vaatlustevahelise sarnasuse mõõtmisel arvestada. Selleks peab pidevõppe andmebaasis olema andmekihi, mille puhul omasarnasust soovitakse kasutada, klassikombinatsioonide sarnasusmaatriks, kuhu kantakse klassidevahelised sarnasused väärtusvahemikus 1...100. Null-sarnasusega kombinatsioone ei ole tarvis sarnasusmaatriksisse kanda.

Sarnasusmaatriksid registreeritakse omasarnasuste tabelis (ptk 3.5.1.1). Klassidevahelisi sarnasusi kasutatakse vaid nominaalse andmekihi nominaalsete indeksite (mood, kaugusega kaalutud mood) puhul.

Mullaliikide omavahelise sarnasuse otsustamisel võeti aluseks J. Paali (1997) järgi kasvukohatüüpides esinevad mullad. Sarnasteks (50%) loeti need mullad, mis võivad kaasneda sama kasvukohatüübiga. Arvesse võeti vaid metsakasvukohatüüpe, looduslikke niite ja soid ning neile sobivaid muldi, sest tugeva inim mõjutusega kasvukohatüüpides (näiteks kultuurniidud, aiad, põllud jmt) võib esineda nii troofsuse kui niiskuse poolest väga erinevaid muldi.

3.2.3. Maapinna kõrgusmodel

3.2.3.1. Andmed

Pidevstuudiumis kasutatava maapinna kõrgusandmestiku originaalina säilitatav algvorming on kolmemõõtmelises *Microstationi* failis olevad samakõrgusjooned ja maapinna kõrgusarvud. Tartu Ülikooli geograafia instituudis on varasemate uurimisprojektide käigus loodud maapinna suuremõõtkavaline kõrgusmodel Otepää looduspargi ja Porijõe valgla kohta. Olemasolevaid kõrgusandmeid kontrollitakse ja parandatakse ning tehakse täpsustusi vastavalt vigade avastamisele ja uute andmete laekumisele. Väljaspool Otepää loodusparki ja Porijõe valglat asuvate taimestiku näidisalade piirkonda digitaliseeriti kõrgusarvud ja samakõrgusjooned põhiliselt 1980. aastate NSVL 1: 10 000 topograafilistelt kaartidelt ja orienteerumiskaartidelt (EOL...). Nende kaardilehtede, mille kohta on publitseeritud 1: 20 000 paberkujul põhikaart, puhul oli võimalik kasutada ka maa-ametist tellitud kahemõõtmelist 5 m samakõrgusjoonte vahega reljeefikihti. 1: 50 000 baaskaardi 10 m löikevahega samakõrgusjooni kasutati vaid mõnede tasasel maastikul (Nõo ja Meeri piirkond) paiknevate näidisalade piirkonnas, kus detailsem kõrgusinfo puudus. Baaskaardi kõrgusandmete põhjal loodud kõrgusmodeli vähest informatiivsust on täheldatud ka Saaremaa taimkatte suuremõõtkavalisel prognoosimisel (Palo *et al.*, 2005).

Nõuded erinevatele kaardiliikidele ning nende valmistamise tehnoloogia on erinev. Sellest tulenevalt saab mitme kaardi kõrgusinfo mittevastavuse puhul mingis teatud kohas usaldusväärseks pidada kord üht, kord teist allikat. Suuremõõtkavaliste topokaartide puhul, mille koostamisel on kasutatud stereomõõdistust, on kõrgusarvud ja samakõrgusjooned lagedal usaldusväärsed. Sama ei saa aga öelda metsas asuvate pinnavormide kohta, sest aerofotolt ei ole metsa maapind nähtav. Orienteerumiskaardid seevastu, mille andmed kogutakse jalgsi ringi liikudes ning millele esitatavate nõuete kohaselt on oluline täpselt kujutada reljeefivormi kuju ja paiknemist lähiobjektide suhtes, näitavad metsas pinnavormide kuju täpsemalt (Remm, 2004b).

Kõrgusmudelitest saab automaatselt genereerida mitmesuguseid maapinna kõrguse, kuju ja vormi arvulisi näitajaid ehk parameetreid, näiteks mitmeid variante suhtelisest kõrgusest, nõlva kaldenurki jmt, mida antud uurimuses on käsitletud tunnustena (ptk 3.2.7).

3.2.3.2. Andmekihi ettevalmistus

Pidevstuudium kasutab binaarkujul heederita rasterfaile (*Idrisi32 rst*-vorming). Algseid maapinna kõrgusandmeid hoitakse geograafia instituudis aga *Microstationi* 3D-failides. *Pidevstuudiumi* kasutamisega seotud tööde jaoks on *Microstationi* vormis kõrgusandmete failid Eesti Põhikaardi 10 × 10 km kaardilehtede kaupa. Iga fail sisaldab samakõrgusjooni ja kõrgusarve ka 200 m laiuse puhverala kohta väljaspool kaardilehe serva, et vältida kaardilehe piirile tekkivaid moonutusi kolmnurkpinna (TIN) ja rastervormis maapinna kõrgusmodeli genereerimisel. 3D-faili digitud kõrgusjoonte horisontaalsuse kontrollimiseks kasutati *Microstationi* programminaga *Kõrgusvärv.bas* (lisa 2).

3D *Microstationi* fail avati tarkvarapaketi *Intergraph MGE*. *MGE* mooduliga *Terrain Analyst* genereeriti TIN-mudel, mis konverteeriti *MGE* grid-vormi ja teisendati *Idrisi32* rasterformaati.

Kõrgusmodeli andmekihis (*elev_dm* tabelis 3.2.1) on maapinna kõrgus salvestatud täisdetsimeetritena merepinnast. Kuna detsimeetrites esitatavaid väärtusi on rohkem kui 255, on kiht 2-baidiline.

3.2.4. Ortofotod

3.2.4.1. Andmed ja andmekihid


Kasutati värvilisi ortofotosid. Ortofotode kvaliteet on ebaühtlane. Looduspargi lääne- ja lõunaosa (kaardilehed 5423, 5424, 5433, 5443) ortofotod on aastast 2000 ja varasemad. Nende optiline lahutus on väiksem (0.8...1.2 m), need on töödeldud analoogtehnoloogiaga, värvitoonid on standardiseerimata (varieeruvad nii ühe kaardilehe piires kui ka kaardilehtede vahel), kujutis sisaldab defekte (valgeid kriime). Looduspargi ülejäänud osa kohta (kaardilehed 5434, 5435, 5444, 5445) on olemas uuemad ja parema kvaliteediga ning väiksema piksliga (40 cm maastikul) ortofotod aastast 2002.

Varasemas Otepää looduspargis sarnase metoodikaga läbi viidud uurimuses (Remm, 2004a) kasutati ka hallskaalas ortofotosid. Kuna mainitud uurimuse tulemustest selgus, et hallskaalas ortofotode prognoosivõime on võrreldes värviliste ortofotode ja Landsat TM kujutise lähisinfrapunase ja infrapunase kanaliga väiksem, siis antud uurimuses neid ei kasutatud.

Ortofotode andmekihte (*ortof* ning värvikanalit, värvitooni, küllastust või heledust tähistav suurtäht kihi kataloogi nimes tabelis 3.2.1) on seitse: värvikujutise punase (*R*), roheline (*G*), sinise (*B*) ja kollase (*Y*) värvikanali ning värvitooni (*H*), küllastuse (*S*) ja heleduse (*L*) kihid.

3.2.4.2. Värvilahutus

Riigi Maa-ametist saadud ortofotod on *MrSid*-formaadis. Need teisendati programmiga *IrfanView* *bmp*-formaati, avati seejärel programmiga *Idrisi32* ning salvestati *Idrisi32* *rgb*-vormingusse. Ortofotode värvid lahutati *rgb*-failist programmiga *Lokaalstatistikud*, mis teisendas ka originaalpikslid 1 m küljepikkusega piksliteks ning salvestas 5×5 km *rgb*-failidest värvilahutuse iga andmekihi eraldi 10×10 km kaardilehe rasterfaili (joonis 3.2.3).



Joonis 3.2.3. Programmi *Lokaalstatistikud* värvilahutuse väljundfailide nimede sisestusaken.

3.2.5. Metsakorraldusfotod

3.2.5.1. Andmed ja andmekihid

Uurimuses kasutatud 1990. aastatel tehtud metsakorraldusfotod saadi AS Eesti Metsakorralduskeskusest värviliste paberkoopiatena. Fotod on ühtlustamata, värvitoonidega ning ebaühtlase kvaliteediga. Metsakorraldusfotod ei kata kogu uuritavat ala, nende vahel on katmata ala, mõnes kohas aga ülekatteid (fotod pole põhikaardi kaardilehtede kaupa). Sellisel kujul fotode digitaliseerimine ja puhastamine on töömahukas.

Metsakorraldusfotode kihte (tabelis 3.2.1 *Metsakorraldusfoto* ning värvikanalit või heledust tähistav suurtäht kihi kataloogi nimes) on neli: kujutise punase (*R*), rohelise (*G*) ja sinise (*B*) värvikanali ning heleduse (*L*) kihid.


3.2.5.2. Andmekihtide ettevalmistus

Kõigepealt metsakorraldusfotod skaneeriti. Seejärel need ortorektifitseeriti ning seoti programmis *Microstation* koordinaatidega. Defektsetele kohtadele joonistati programmis *Microstation* peale polügonid ning maskiti need siis programmis *Microstation Descartes* nullväärtusega piksliteks. Üksikud fotod liideti üheks failiks ja teisendati ühtsesse pikslisuurusse (piksli küljepikkuseks sai 2.5 m) programmiga *Lokaalstatistikud*. Seejärel lahutati *rgb*-vormis värvifoto sama programmiga eraldi punase, rohelise, sinise tooni intensiivsuse ning kujutise heleduse kihiks ja salvestati 10×10 km kaardilehtedena.

3.2.6. Landsat 7 ETM+ satelliidipildid

3.2.6.1. Andmed ja andmekihid

Pidevstuudiumi jaoks sobival kujul andmekihtidena on andmekihtide hoidlas viie Landsat 7 ETM+ (*Enhanced Thematic Mapper*) kujutise failid nende kaardilehtede osas, millelt pärinevad taimkatteüksuste näidistebaasis olevad kirjeldused. Need on kujutised kaadriumbritega 186-019 (pildistamiskuupäevad 10. juuli 1999, 30. sept 2000 ja 23. mai 2005), 187-018 (6. juuli 2001) ja 187-019 (16. mai 2000). Otepää loodusparki katavad kaadrid 187-019 ja 186-019. Viimase poolt kaetud alast jääb osa looduspargi lõunaosast välja. Kaadri 187-018 alaosa katab osa põhjarannikust ja Kirde-Eestist (joonis 3.2.4).



Joonis 3.2.4. Landsat 7 kaadrite alad.

Andmekihid valmistati ette olemasolevate satelliidipiltide kõikide (v.a 1999. ja 2001. a pankromaatiline laineala) kanalite kohta. Taimestiku kaardistamisel kasutatavad tunnused arvutati kõigist 2005. a kujutise kanalitest. 2001. a satelliidipilti esialgu ei kasutatud, ülejäänud satelliidipiltide puhul jäeti välja sinise kanali kui atmosfääris hajuva kiirguse kasutus ning 2000. a septembri pildi puhul ka pankromaatiline laineala.

Satelliidipildid on läbinud geomeetrilise ning radiomeetrilise kvaliteedikontrolli. Piltide valiku peamine eeltingimus oli pilvede võimalikult väike katvus.

Kanalite B1 ... B5 ning B7 kihtidel on piksli küljepikkus 25 m, kanali B6.2 kihtidel 50 m ning kanali B8 kihtidel 10 (enamasti) või 25 m, sõltuvalt originaalkujutise detailsusest ja pikslisuurusest.

Satelliidipiltide kihtide kataloogi nimi (tabel 3.2.1) koosneb lühendist *ETM*, millele järgnevad kaadri number (näiteks 186_019), salvestuskuupäev (näiteks 16-05-2000) ning kanali number (näiteks B1; kanalite tähistused tabelis 3.2.2).

Tabel 3.2.2. Landsat TM lainealad ja nende tähistus uurimuses (Meiner, 1999)

Kanali tähistus	Laineala	Spektraalne lahutus (μm)
B1	sinine	0.45 – 0.52
B2	roheline	0.52 – 0.60
B3	punane	0.63 – 0.69
B4	lähisinfrapunane	0.76 – 0.90
B5	keskinfrapunane	1.55 – 1.75
B6.1	soojusinfapunane (madala lahutusvõimega)	10.4 – 12.5
B6.2	soojusinfapunane (kõrge lahutusvõimega)	
B7	keskinfrapunane	2.08 – 2.35
B8	pankromaatiline	0.52 – 0.90

3.2.6.2. Andmekihtide ettevalmistus

Landsati pildid teisendati *Idrisi32* rasterformaati. *Idrisi32s* teisendati need Eesti Põhikaardi projektsiooni ning lõigati Eesti Põhikaardi kaardilehtede suurustesse failidesse (10×10 km kaardilehtedeks).

3.2.7. Andmekihtidest arvutatud seletavad tunnused

3.2.7.1. Tunnustest ja nende valikust

Rasteriseeritud kaartidelt ja pildiandmekihtidest arvutatakse seletavad tunnused ehk argumenttunnused programmiga *Pidevstuudium*. Argumenttunnusteks on satelliidipiltide ja ortofotode lokaalset tekstuuri, kiirgusvahemike intensiivsust ja värvitooni kirjeldavad parameetrid ning üksiknäitajatest tuletatud suhtarvud ja keerukamad indeksid, samuti kaartidel olevad klassifikatsiooniüksused ja kaardimustri indeksid. Otepää looduspargi esialgsete taimkattekaartide genereerimiseks vajalikus tehisõppes kasutati 86 põhitudunust (tabel 3.2.3), kaartide genereerimisel lisandus neile 26 asendustunust. Süsteem on avatud, tunnuseid on suhteliselt lihtne olemasolevatest andmekihtidest vajaduse korral juurde luua või ümber arvutada.

Lokaalset mustrit kirjeldavaid parameetreid võib põhimõtteliselt olla lõpmatult palju. Väga suure hulga seletavate tunnuste kasutamine muudab tunnuste kaalude otsimise aeglaseks ja viib kergesti liigsobitamisele, mille puhul täpsed prognoosid ei kehti väljaspool õpetusandmeid. Seetõttu tuleb sadadest või isegi tuhandetest katseliselt arvutatud lokaalstatistikutest valida paarkümmend kuni sada kandidaati, mis seostuvad funktsioontunnusega tugevamini ja on omavahel vähem korreleerunud. Uurimuses on andmekihtidest arvutatud seletavad tunnused paljudest indeksi arvutamise parameetrite (ptk 3.5.1) võimalikest kombinatsioonidest välja valitud, tuginedes peamiselt eelnevale kogemusele. Näiteks on ortofototunnuste puhul värvikanalitest enim kasutatud punast, sest punane kiirgus hajub atmosfääris kõige vähem. Seetõttu ei saa olla kindel, et mingit teatud nähtust kõige paremini prognoosivad tunnused on süsteemis olemas. Näidistepõhise taimkatte kaardistamise kõige parema indikaatorväärtusega tunnused peab välja selgitama eraldi uurimus.

Kuna metsakorraldusfotod on ebaühtlase kvaliteediga, ortorektifitseerimata ning nende andmekihtide ettevalmistamine töömahukas (ptk 3.2.5), siis püüti tehisõppe käigus välja valitud metsakorraldusfoto tunnuseid asendada analoogiliste parameetritega ortofototunnuste hulgast ja otsiti tunnuste komplekte, mis sisaldaksid teisi tunnuseid. Kui asendamine vähendas tunduvalt prognoosi täpsust, siis metsakorraldusfotode tunnuseid siiski kasutati.

Põhikaardi andmekihtidest arvutatud tunnuste nimes olev *PK* on põhikaardi lühend, sõnad *eelmine* või *uusim* märgivad kihi päritoluaega, *põhiala* näitab, et tegemist on eelklassifikaatorina kasutatava tunnusega. Osad põhikaardi- ja mullakaardikihtidest tuletatud tunnuste nimed sisaldavad nende arvutamisel kasutatud indeksite (lühendatud) nimetusi või tähendusi (ptk 3.5.1.2) ja/või klassikoodide tähendusi (nt *järv*, *madalsoomuld*). Number tunnuse nimes märgib indeksi arvutamise raadiust või klasside arvu. Ortofotokihtidest arvutatud tunnuste nimedes tähistab suurtäht värvikanalit (*R*, *G*, *B* või *Y*), värvitooni (*H*), küllastust (*S*) või heledust (*L*), number märgib kerneli raadiust meetrites ning ülejäänud kasutatud indeksi nime või selle lühendit. Metsakorraldusfotode puhul langeb tunnuse, mille arvutamisel on kasutatud indeksit keskmine, nimi kokku andmekihi nimega, standardhälbe puhul on tunnuse nimesse lisatud lühend *SD*. Satelliidipiltide tunnused on üldjuhul sama nimega nagu andmekihid, millest nad on arvutatud (andmekihtide nimedes kasutatud lühendite tähendused vt ptk 3.2.1...3.2.6).

Tabel 3.2.3. Otepää looduspargi esialgse taimkattekaardi genereerimisel kasutatud seletavad tunnused ja mõned nende arvutamise parameetrid. *Tunnus* — tunnuse nimi andmebaasis; *andmekiht* — kihi, millest tunnus on arvutatud, nimi; *indeks* — tunnuse arvutamisel kasutatud indeks (indeksite seletus ptk 3.5.1.2); *R* — tunnuse arvutamise raadius meetrites õpetuskohtade arvutamisel; *R_k* — tunnuse arvutamise raadius meetrites kaartide genereerimisel.

Tunnus	Andmekiht	Indeks	R	R_k
uusim-PK-põhiala	PK-uusim	mood	0	0
uusim-PK100klasse		klasside arv	200	200
kaugus_PK_järvest		kaugus klassi piirist	500	500
kaugus_PK_teedest		kaugus klassi piirist	200	200
uusim-PK_servalähedus		klassipiiri kaugus	300	300
uusim-PK100klassikülgnevus		klassikülgnevuste osa	100	100
eelmine-PK-põhiala	PK-eelmine	mood	0	0
nõlvakalle	elev_dm	gradiendi tugevus	100	100
suhtkõrgus_100m-keskmisest		erinevus keskmisest	100	100
suhtkõrgus_200m-keskmisest		erinevus keskmisest	200	200
ekspositsioon		gradiendi suund	100	100
kaugusega_kaalutud_mulla_mood	muld_57	kaugusega kaalutud mood	250	250
valdav_muld_10m		mood	10	10
valdav_muld_eelklassis		mood	100	100
mulla_klassikülgnevuste osa		klassikülgnevuste osa	100	100
valdav_lõimis_10m	loim	mood	10	10
valdav_lõimis_eelklassis		mood	100	100
lõimise_klassikülgnevuste osa		klassikülgnevuste osa	100	100
R30keskm	Ortof-1m-R	keskmine	100	30
R30autokorr		kaugusega kaalutud Morani I	100	30
R30gradienditugevus		gradiendi tugevus	100	30
R30naabrierinevus		naaberpikslite erinevus	100	25
R30naabruse_autokorr		Morani I 8st naaberpikslit	100	30
R30sujuvus		üleminekute sujuvus	100	30
R30SD		standardhälve	100	30
R30max		maksimum	100	30
G30keskm		keskmine	100	30
G30SD		standardhälve	100	30
B30keskm	Ortof-1m-B	keskmine	100	30
B30SD		standardhälve	100	30
Y30keskm	Ortof-1m-Y	keskmine	100	25
Y30SD		standardhälve	100	30
H30keskm	Ortof-1m-H	keskmine	100	30
H30SD		standardhälve	100	30
S30keskm	Ortof-1m-S	keskmine	100	30
S30SD		standardhälve	100	30
L30naabrierinevus	Ortof-1m-L	naaberpikslite erinevus	100	30
L30ekstsess		ekstsess	100	30
L30autokorr		kaugusega kaalutud Morani I	100	30

L30gradienditugevus		gradiendi tugevus	100	30
L30keskm		keskmine	100	30
L30SD		standardhälve	100	30
L30naabruse_autokorr		Morani I 8st naaberpikslist	100	30
L30max		maksimum	100	30
L30sujuvus		üleminekute sujuvus	100	30
Metsakorraldusfoto-R	Metsakorraldusfoto-R	keskmine	100	30
Metsakorraldusfoto-R-SD		standardhälve	100	30
Metsakorraldusfoto-G	Metsakorraldusfoto-G	keskmine	100	30
Metsakorraldusfoto-G-SD		standardhälve	100	30
Metsakorraldusfoto-B	Metsakorraldusfoto-B	keskmine	100	30
Metsakorraldusfoto-B-SD		standardhälve	100	30
Metsakorraldusfoto-L	Metsakorraldusfoto-L	keskmine	100	30
Metsakorraldusfoto-L-SD		standardhälve	100	30
Karbonaatmulla_osa		antud klassi sagedus	100	100
Gleimulla_osa	muld_10	antud klassi sagedus	100	100
Madalsoomulla_osa		antud klassi sagedus	100	100
Valdav_muld_10_klassi		mood	100	30
ETM-186_019-10-07-1999-B2	ETM-186_019-10-07-1999-B2	keskmine	100	30
ETM-186_019-10-07-1999-B3	ETM-186_019-10-07-1999-B3	keskmine	100	30
ETM-186_019-10-07-1999-B4	ETM-186_019-10-07-1999-B4	keskmine	100	30
ETM-186_019-10-07-1999-B5	ETM-186_019-10-07-1999-B5	keskmine	100	30
ETM-186_019-10-07-1999-B7	ETM-186_019-10-07-1999-B7	keskmine	100	30
ETM-186_019-10-07-1999-B62	ETM-186_019-10-07-1999-B62	keskmine	100	30
ETM-186_019-30-09-2000-B2	ETM-186_019-30-09-2000-B2	keskmine	100	30
ETM-186_019-30-09-2000-B3	ETM-186_019-30-09-2000-B3	keskmine	100	30
ETM-186_019-30-09-2000-B4	ETM-186_019-30-09-2000-B4	keskmine	100	30
ETM-186_019-30-09-2000-B5	ETM-186_019-30-09-2000-B5	keskmine	100	30
ETM-186_019-30-09-2000-B62	ETM-186_019-30-09-2000-B7	keskmine	100	30
ETM-186_019-30-09-2000-B7	ETM-186_019-30-09-2000-B62	keskmine	100	30
ETM-187_019-16-05-2000-B2	ETM-187_019-16-05-2000-B2	keskmine	100	30
ETM-187_019-16-05-2000-B3	ETM-187_019-16-05-2000-B3	keskmine	100	30
ETM-187_019-16-05-2000-B4	ETM-187_019-16-05-2000-B4	keskmine	100	30
ETM-187_019-16-05-2000-B5	ETM-187_019-16-05-2000-B5	keskmine	100	30
ETM-187_019-16-05-2000-B62	ETM-187_019-16-05-2000-B62	keskmine	100	30
ETM-187_019-16-05-2000-B7	ETM-187_019-16-05-2000-B7	keskmine	100	30
ETM-187_019-16-05-2000-B8	ETM-187_019-16-05-2000-B8	keskmine	100	30
ETM-23-05-2005-B1	ETM-186_019-23-05-2005-B1	keskmine	100	30
ETM-23-05-2005-B2	ETM-186_019-23-05-2005-B2	keskmine	100	30
ETM-23-05-2005-B3	ETM-186_019-23-05-2005-B3	keskmine	100	30
ETM-23-05-2005-B4	ETM-186_019-23-05-2005-B4	keskmine	100	30
ETM-23-05-2005-B4-gradiendi_tugevus	ETM-186_019-23-05-2005-B4	gradiendi tugevus	100	100
ETM-23-05-2005-B5	ETM-186_019-23-05-2005-B5	keskmine	100	30
ETM-23-05-2005-B62	ETM-186_019-23-05-2005-B62	keskmine	100	30
ETM-23-05-2005-B7	ETM-186_019-23-05-2005-B7	keskmine	100	30
ETM-23-05-2005-B8	ETM-186_019-23-05-2005-B8	keskmine	100	30

3.2.7.2. Tunnuste arvutamise raadiused ja eelklassifikaatorite kasutus

Taimkatte õpetusandmete puhul kasutati enamiku mustriindeksite arvutamisel pikslid, mis olid näidisala sees, mitte kaugemal kui 100 m koordinaatidega andmebaasi fikseeritud fokaalkohast ja samas eelklassifikaatori klassis kui fokaalkoht. Eelklassifitseerivate klassidena kasutati põhikaardi põhialasid (Eesti põhikaardi..., 2000; ptk 3.2.1). Kuna valdavalt olid näidisalad alla 100 m raadiusega, siis läksid arvesse kõik näidisalas olevad pikslid. Mingist etteantud üksusetüübist kaugust arvutatavad indeksid arvutati ilma eelklassifikaatorita ja suurema kauguseni (praegusel juhul 200...500 m), kirjelduse fokaalkohas olevat üksust fikseerivad tunnused arvutati 10 m või nullraadiuses. Taimestikukaartide genereerimisel kasutati (enamasti pildiandmete puhul) väiksemaid raadiusi (25 või 30 m), sest hinnatavate kohtade ümber ei ole kirjelduse kehtivuse ulatust määravaid eraldisepiire (tabel 3.2.3).

Käpaliste leiukohad on punktandmed, mitte eraldised, nagu taimkatte kirjeldused. Käpaliste leiukohti ei ümbritse kirjelduse kehtivuse piirid. Sellest tulenevalt arvutati käpaliste esinemise/puudumise kohti iseloomustavad indeksid 30 m ulatuses ja eraldistekihina kasutati põhikaardi põhialasid.

3.2.7.3. Asendustunnused

Kaardi genereerimisel saab protsessi kiirust vähendavate, arvutusmahukate indeksite asemel kasutada neist eelnevalt omaette andmekihtidena valmis arvutatud asendustunnuseid. Praegu on asendustunnused olemas siiani prognoosikaartide genereerimisel kasutatud ortofototunnuste kohta, sest ortofoto-andmekihtide väike pikslisuurus (1×1 m) ja sellest tulenev suur pikslite arv muudab kaardi arvutused aeglaseks. Arvutusi aeglustavad pildiindeksid on enne kaartide genereerimist suuremate pikslitena (pikslid külgsuure 10 m) valmis arvutatud.

3.3. Vaatlusandmete kogumise metoodika

3.3.1. Välivaatlusandmete kogumise metoodika


2005. aasta välivaatlused koguti näidistebaasi 2005. a aprillist oktoobrini. Taimkatte näidisalade kirjeldamisel tehti GPS-vastuvõtja, aerofoto, orienteerumiskaartide ja põhikaardi abil kindlaks vaatluse asukoht ja kirjelduse kehtivuse ruumilised piirid. Märjiti üles vaatleja, kasvukohatüüp, puittaimede katvus, kümnepalline puistu valem, põõsarinde koosseis, alustaimestiku iseloomulikud liigid. Metsakohtades hinnati kasvukoha niiskus ja troofsus arvuliste näitajatenä vahemikus 0...100 kasvukohatüüpide ordinatsiooniskeemil (Lõhmus, 1984; joonis 3.3.1) eesmärgiga katsetada, kui hästi äratuntav on metsa kasvukohatüüp nende näitajate hinnangute põhjal. Viimane moodus peaks kasvukohatüüpide üleminekuid võimaldama paremini käsitleda ja esitada. Kui vaadeldud kohas oli tõenäoliselt viimase viie aasta jooksul toimunud muutusi, mis muudavad taimkatteüksust vastavalt selles töös kasutatud jaotusele, või kui kooslus tõenäoliselt muutub paari aasta jooksul, siis lisati hinnanguliselt kirjelduse kehtivuse ajalised piirid.

Enamikus vaatluskohtades pildistati koosluse ja üldilmet ja alustaimestikku.

Kuna kaugseirepildidel paistab üldvaade, hinnati puistu koosseisu ja katvust üldvaate järgi, mistõttu on ka rohkem lootust puistu koosseisu kaugseireandmetega siduda. Kuna üldvaate järgne katvus vastab ligikaudselt liikidele langeva päiksekiirguse hulgale, siis kajastab sel moel hinnatud katvus ligikaudselt liikide produktiivsust. Üldvaate järgi katvust on kasutatud ka varasemates Otepää looduspargi puistu andmeid kasutavates uuringutes (Remm, 2002, 2004b, 2005a).

Näidisalade valikul ja piiritlemisel lähtuti neljast üldisest kriteeriumist:

- 1) ruumiline stabiilsus (näidisala kirjeldus peaks kehtima võimalikult suures raadiuses, reeglina vähemalt 20 m raadiuses),
- 2) ajaline stabiilsus (hiljuti inimtegevuse tõttu või muul põhjusel tugevasti muutunud kohti välditi),
- 3) tüpoloogiline esinduslikkus (eelistati taimkatteüksuste tüüpilisemaid esinemisvorme),
- 4) esindatus näidistebaasis (näidisaladena eelistati taimkatteüksusi, mille esinemisvormid olid näidistebaasis senini vähe esindatud (vähem kui 10 näidisala).



Joonis 3.3.1. Eesti metsakasvukohatüüpide ordinatsiooniskeem. 1 – kasvukohatüübi piir, 2 – alltüübi piir. Ristikestega on tähistatud koordinaatide lõikepunktid (Lõhmus, 1984).

3.3.2. Näidisalade valimine varasematest andmestikest

Läbi vaadati järgmised varasemad andmestikud: projekti „Otepää looduspargi sürjametsade mitmekesisuse inventuur” aruanne (Paal *et al.*, 2002) (vaatlused aastast 2001), Elle Meieri vaatlusandmed juulist ja augustist 2004 (Paal *et al.*, 2004), Otepää looduspargi kasvukohatüüpide kaardistus kolmel vaatlusalal aastast 2001, 1000 juhupunkti kasvukohatüübi ja metsa koosseisu kaardistus aastast 2002 (kaardistajad Kaupo Kohv, Jaanus Remm, Kalle Remm), Kristiina Sulbi vaatlusandmed augustist ja septembrist 2004 (Sulbi, 2005) ning metsastuva põllumaa kirjelduste andmebaas Tartu Ülikooli geograafia instituudis. Varasematest andmestikest ei liidetud andmebaasi kõiki vaatlusi, kuid liideti ka väljaspool loodusparki olevaid vaatluskohti. Varasemate andmestike sobivusele annab hinnangu kasutatud vaatluste osakaal (tabel 3.3.1).

Vajadusel korrigeeriti kasvukohatüüpide nimetusi vastavalt uurimuses kasutatavatele üksuste määratlustele.

Varasemate andmete valikul lähtuti alltoodud põhimõtetest.

Eraldis ei sobi näidisalaks, kui:

- 1) selles kohas juba on näidis,
- 2) aerofotol on selles kohas defekte,
- 3) ala on valdavalt puude või hoonete varju sees,
- 4) ala on kitsas (reeglina peaks läbimõõt olema vähemalt 20 m, soovitatavalt vähemalt 30 m; alla 20 m võib olla koosluste puhul, mida laiemal alal näidistebaasis ei ole),
- 5) aerofoto järgi tundub, et puude katvus või okas- ja lehtpuude vahekord on välitööl valesti hinnatud või on välitöö ja aerofoto pildistamise vahel muutunud,
- 6) eraldis on seesiselt ebaühtlaselt muutlik ja ei ole selge, millise osa kohta kirjeldus kehtib,
- 7) välitööl määratud kasvukohatüüp on selges vastuolus mullakaardil oleva mullaliigiga, põhikaardil oleva põhialaga või aerofotoga,
- 8) vastuolu reljefiandmetega.

Tabel 3.3.1. Taimkatte kaardistuse näidisalade andmebaasis olevate vaatluste hulk ja päritolu


Andmeallikas	Vaatlusi andmeallikas	Näidiste baasi liidetud vaatlusi	Kasulike vaatluste osa [%]
Välivaatlused 2005	573	573	100
Metsastuva põllumaa kirjelduste andmebaas	361	33	9
Paal <i>et al.</i> , 2004	15	15	100
Sulbi, 2005	12	12	100
1000 juhupunkti 2002. a	1000	179	18
Paal <i>et al.</i> , 2002	49	13 (14)*	27 (29)*
Kaardistus 2001	6420	88 (89)**	1

* Paal *et al.* (2002) andmetest sai kokku 13 näidisala, kuid kasutati 14 vaatlust (kaks vaatlust ühendati üheks näidiseks nende sarnasuse ning lähestikku paiknemise tõttu).

** Üks vaatluskoht on kombineeritud kirjeldusega andmestikust Sulbi (2005).

3.3.3. Näidisalade hulk ja paiknemine

Uurimuses kaardistatakse Otepää looduspargi taimkatet näidiste ning kaugseire- ja kaardiandmete järgi. Kaugseire- ja kaardiandmete järgi kaardistamisel saab õpetusandmetena kasutada ka väljaspool uuritavat ala olevaid näidisalaid, kui need esindavad Otepää looduspargis esinevaid kaardistusüksusi. Taimkatte näidisalad paiknevad Otepää looduspargi erinevates osades (joonis 3.3.2). Näidisalaid on näidistebaasis 2006. a alguse seisuga 913 (metsavaatlusi 529), nendest Otepää looduspargis 647 vaatlusala (metsade kohta 387). Koosluse tasemel taimkatteüksuseid on näidisalade andmebaasis kokku 298 (näidisalaid on neist 162 kohta), neist 184 on metsaüksused (näidisalad on olemas 87 kohta). Otepää looduspargi kaardistamiseks sobivad näidisalad jagunevad 49 kasvukohatüübi ja 150 taimekoosluse tasemel detailse kaardistusüksuse vahel, millest looduspargis paiknevate näidistega on esindatud 133 üksust.



Joonis 3.3.2. Taimkatte kaardistuse näidisalade paiknemine Otepää looduspargis ja selle lähie ümbruses.

3.3.4. Taimkatte näidisalade andmebaas

Taimkatte näidisalade andmebaas on *MS Accessi* vormingus ning sisaldab kõikide olemasolevate näidisalade andmeid.

Andmebaas sisaldab järgmisi tabeleid: *kooslusekoodid*, *KKT*, *PK-alad*, *VAATLUSED*. Tabelis *KKT* on kasvukohatüüpide nimed, lühendid ja koodid ning kasvukohatüübile vastavad mullakoodid mitmes erinevas süsteemis. Tabelis *PK-alad* on Eesti 1: 10 000 Põhikaardi põhi-alade nimed ja võtmeatribuudid. Tabelis *kooslusekoodid* on esialgselt eristatud taimkatteüksuste nimed, koodid, üksusele vastavate kõrgema taseme klassifikatsiooniüksuste koodid ning mõningad seletused üksuste piiritlemise kohta. Kasutajaga suhtlemiseks on näidisalade andmebaasis vorm *vaatlustesisestus* (joonis 3.3.3). Vorm võtab kokku ja kuvab andmeid tabelitest *kooslusekoodid*, *PK-alad*, *VAATLUSED*. Kasvukohatüüp on iga vaatluse puhul üheselt määratletud tabelites *kooslusekoodid* ja *KKT* olevate koodidega ning tabelitevaheliste seostega (joonis 3.3.4). Lisaks sisaldab andmebaasi struktuur linke kaardi- ja pilditunnuste andmebaasi tabelitega (*Akihid*, *Indeksid*, *ATUNNUSED*; vt ptk 3.5).

vaatlustesisestus

VID	kuup	vaatlaja	Alates	Kuni
1054	26-Aug-04	Elle Meier		

kooslus2005	kooslusekoodid_nimi	Niiskus	Karbonaatsus
48	sinilille-männisegamets	40	65

katvus	puistuvalem	teised puud
60	4Mä 3Ku 2Ka 1Sr	Pi Hb Re Ta Le

PK	PK-alad_nimi	☒ Otepää LP
64	mets	

pöösarinne
Sarapuu (15%)


rohurinne
Jänesekapsas (K), metskastik, lillakas, maikelluke, metspipar. Metsakäharik, sarnas-lehiksammal, lame lühikupar

märkmed
Elle Meieri Nm39. Vanus 71a. Esimene rinne 7Mä3Ks+HbKu 0.4; teine rinne 7Ku2Sp1Pi+KsVa 0.3.

vastuolulisus ☐ vastuoluline

Record: 836 of 913

Joonis 3.3.3. Vaatluste sisestuse vorm taimkatte näidisalade andmebaasis.



Joonis 3.3.4. Tabelitevahelised seosed taimkatte näidisalade andmebaasis.

3.4. Kaardistusüksused

Taimkatet saab kaardistada erineva ruumilise ja taksonoomilise detailsusega. Uurimuses on kaardistusüksusteks metsakasvukohatüübid, tüübirühmad, metsatüübid ning puistutüübid.

3.4.1. Metsatüübid

Metsakooslus on puistu ja alumiste rinnete poolest ühetaoline metsaosa ning *metsatüüp* ühetaoliste metsakoosluste kogum (Masing, 1992). Metsakasvukohatüüpide piires jagatakse metsad enamuspüüliigi järgi metsatüüpideks (Lõhmus, 1984, 2004; Masing, 1992).

Kuigi metsakorraldajad metsatüüpide seas segametsi ei erista ning ka Eesti taimkatte kasvukohatüüpide klassifikatsioonis (Paal, 1997) pole metsakasvukohatüüpide kirjeldustes loetletud sagedasemate koosluste (metsatüüpide) seas segametsi ega nende eristamise kriteeriume mainitud, on selles uurimuses peetud vajalikuks eristada ka segametsi. Enamikus Eesti metsades kasvab lähestikku rohkem kui üks puuliik. Selles mõttes on peaaegu kõik metsad segametsad. Segametsa klassid on okas- ja lehtmetsadest eristatud mitmetes maakatte ja elupaikade klassifikatsioonides (CORINE, EUNIS), kuid ka nende kirjeldustes ei ole segametsarühmade eristamise kriteeriume täpsustatud.

Eesti Põhikaardil on segametsadeks loetud need alad, kus okaspuude või lehtpuude osakaal on alla 80%. Antud uurimuses kohandati seda kriteeriumi peapuuliigi tasemele (segametsad on need, kus peapuuliiki on vähem kui 80%). Metsade vaatlusandmete jagamisel andmebaasis olevatesse metsatüüpidesse olid aluseks järgmised põhimõtted. Kui peapuuliiki on vähemalt 80%, koosneb metsatüübi nimi kasvukohatüübi ning peapuuliigi nimetusest (näiteks *mustikakuusik*). Segametsade puhul on vaatlused jagatud kasvukohatüüpide kaupa *okas-segametsade* (okaspuude osakaal 50...70%) (näiteks *mustika-okas-segamets*) ja *leht-segametsade* (lehtpuude osakaal 50...70%) (näiteks *jänsekapsa-leht-segamets*) vahel. Osades kasvukohatüüpides on enamuspüüliigi järgi eristatud (suurema arvu näidiste olemasolu korral) ka detailsemaid segametsa-üksuseid, näiteks *lillaka-männi-segamets* (sellised üksused hõlmavad enamasti vaatluskohti, milles peapuuliiki on 50...70%). Lisaks on kõikides kasvukohatüüpides nn metsata metsamaa kirjelduste jaoks eristatud üksus nimega *harvik/noorendik/raiesmik*. Nimetatud üksuse kood omistatakse alla 4 m kõrguse esimese rindegale kooslustele või üle 4 m kõrguse, kuid alla 30% puude liitusega kooslustele. Selle aluseks on põhikaardi *metsa* määratlus, mille kohaselt nimetatakse *metsaks* ala, kus esimese rinde puude kõrgus on vähemalt 4 m ning puude katvus vähemalt 30%. Raiesmiku ja noorendiku kasvukohatüübi määramisel kasutati kaudseid meetodeid: jälgiti raiestikega piirnevaid analoogilise reljeefi ja mullatingimustega metsakooslusi, arvestati säilinud alustaimestiku fragmente, samuti raiutud puistu koostist ja kasvukiirust (kändude järgi) ning selgitati mullatingimused (Lõhmus, 1984, 2004). Kaheldava kuuluvusega kohti näidiseks ei võetud.

Andmebaasis olevad metsatüüpide jaotused on esialgsed (võimalikult detailsed, sest detailsemalt üldisemale tasemele saab alati minna). Neid optimeeriti nii, et kaardistatavate üksuste äratuntavus olemasolevate pildi- ja kaardiandmete ning näidiste järgi oleks võimalikult suur – kaardistusüksustena kasutati metsa tüübirühmade ja kooslusekoodidel põhinevate puistutüüpide (vt ptk 3.4.3) kombinatsioone (tekstis nimetatud *metsatüüpideks*). Tehisõppes kasutatud metsatüübid ning neisse kuuluvate näidiste arv on toodud tabelis 3.4.1.


Tabel 3.4.1. Tehisõppel kasutatud metsatüübid ning nendesse kuuluvate näidiste arv andmebaasis.

Nimi	Näidiseid
paluraiesmik	7
palumännik	48
palu-segamets ja -lehtmets	11
laanehaavik	1
laanekaasik	7
laanekuusik	21
laane-segamets	54
sürjaraiesmik	1
sürja-okasmets	16
sürja-segamets ja -lehtmets	14
laane- ja saluraiesmik	20
salukaasik	18
salumännik	6
salukuusik	5
salu-segamets	93
muu salu-lehtmets	20
soostunud pajustik	5
soostunud raiesmik	2
soostunud lehtmets	8
soostunud segamets	12
lodupajustik	4
lodulepik	3
soometsa raiesmik	3
soo-männik	17
sookaasik	38
soo-segamets	49
kõdusoo-segamets	33
kõdusoo-lehtmets	7
kõdusoo-männik	1
kõdusoo-kuusik	4
noor mets söödil	23

3.4.2. Tüübirühmade ja kasvukohatüüpide kirjeldused

Metsakasvukohatüüp on ühesuguste looduslike (kliimaatiliste, mullastikuliste ja hüdroloogiliste) taimestikku mõjutavate kasvutingimuste kompleksiga metsamaade kogum. Metsakasvukohatüüp on taimkatteüksus, mida eristatakse tunnuste kompleksi (peamiselt mullastikutingimuste ja taimkatte) alusel. Arumetsa kasvukohatüüpe tähistatakse mõne iseloomuliku alustaimestiku liigi nimetusega (näiteks *pohla* kasvukohatüüp), soometsade puhul kasutatakse üldtuntud sootüüpide nimetusi (Lõhmus, 1984, 2004; Masing, 1992; Paal, 1997). Enamiku Otepää looduspargis esinevate metsakasvukohatüüpide määratlus lähtub Eesti taimkatte kasvukohatüüpide klassifikatsioonist (Paal, 1997), juurde on lisatud *lillaka*, *metsastuva söödi* ning *allikasoometsa* kasvukohatüübid. Kasvukohatüübid on rühmitatud tüübirühmadeks vastavalt J. Paal (1997) jaotusele.

J. Paali (1997) ning uurimuses kasutatud metsakasvukohatüüpide määratlustele vastavate üksuste ligikaudne paiknemine E. Lõhmuse (1984) ordinatsiooniskeemil on toodud joonisel 3.4.1.



Joonis 3.4.1. Eesti metsakasvukohatüüpide ordinatsiooniskeem (Lõhmus, 1984, järgi). 1 – kasvukohatüübi piir Lõhmuse järgi, 2 – alltüübi piir Lõhmuse järgi, 3 – kasvukohatüübi piir vastavalt uurimuses kasutatavale käsitlesele; musta kirjaga on Lõhmuse kasvukohatüüpide ning uurimuses sama nime alla kasutatavate kasvukohatüüpide nimetused, punases kirjas skeemile lisatud või algsest erinevama asukohaga kasvukohatüüpide nimetused. Ristikestega on tähistatud koordinaatide lõikepunktid.

3.4.2.1. Palumetsade tüübirühm

3.4.2.1.1. Pohla kasvukohatüüp

Pohla kasvukohatüübis on siiani eristatud männikuid, männi-segametsi ning kaks üksusse nimega harvik/noorendik/raiesmik kuuluvat näidist. Puurindes domineerib neis vaatluskohtades mänd (v.a üks näidisala, kus domineerib kuusk). Kuusk esineb teises rindes, ulatudes esimesse. Üksustesse harvik/noorendik/raiesmik ning männi-segamets kuuluvates kooslustes kasvab lisaks arukaske, viimases ka sarapuud ning tamme.

Teises rindes kasvab kuusk ja kask, põõsarindes on kõige sagedamini märgitud kadaka esinemist, samuti kuuske, tamme, kaske ning vaarikat; lisaks mändi, sarapuud, pihlakat, paakspuud, punast leedrit, toomingat.

Puhmarinne on hästi arenenud, kõige rohkem on mainitud pohla, vähem mustika ja kanarbiku esinemist. Rohurinne on suhteliselt hõre, sagedasemad on metskastik, palu-härghein ning lamba-aruhein. Lisaks on mõnes kirjelduses nimetatud karvast piipheina, lillakat, raestikel jäneskastikut jt.

Pohla kasvukohatüüpi kuulub 2006. a alguse seisuga 24 näidisala.

3.4.2.1.2. Lillaka kasvukohatüüp

Uurimuses *lillaka* kasvukohatüübiks nimetatud üksus kattub põhimõtteliselt E. Lõhmuse (1984, 2004) poolt eristatud *jänesekapsa-pohla* osatüübiga. Eesti metsakorralduses on peetud otstarbekaks *pohla* kasvukohatüübi, mis on üks kahest enamvarieeruvast metsakasvukohatüübist, detailsemat jaotust, arvestades mullaviljakuse olulist erinevust, mis kaasneb moreeni sügavuse muutumisega või ka lõimise ja reljeefi muutustega. Metsakorraldajate ettepanekuid arvestades on Lõhmus (1984, 2004) *pohla* kasvukohatüübi viljakamat, huumuslikel ja sekundaarsetel leedemuldadel levivat osa käsitlenud omaette üksusena, *sinilille-pohla* ning *jänesekapsa-pohla* alltüüpe ühendava *jänesekapsa-pohla* kasvukohatüübina. Sarnast üksust on pidanud vajalikuks eristada ka varasemad tüpoloogid – A. Karu ja L. Muiste (1958) metsakasvukohatüüpide klassifikatsioonis on sarnane üksus eristatud *kuuse-pohla variandi* nimetuse all.

Lillaka kasvukohatüübis kirjeldati enim männi-segametsi ning männikuid, lisaks kase-segametsi, okas-segametsi ja harvik/noorendik/raiesmikke. Mänd on esindatud kõigil loetletud üksustesse kuuluvatel vaatlusaladel. Mänd domineerib kõigis kooslustes peale kase- ja okas-segametsa, kus esimeses on enamuspuuliigiks arukask, teises kuusk. Männikus kasvavad lisaks mändidele kuused, harvik/noorendik/raiesmikel arukased, ülejäänud kooslustes on nii kuuski kui arukaski ning männi-segametsades ka sarapuud.

Teises rindes on sagedaseim tamm, palju on ka arukaske, haaba, kadakat, kuuske ning sarapuud, veidi harvem tuleb ette toomingat, pärna, vahtrat, pihlakat. Põõsarindes on kõige rohkem nimetatud sarapuud, pihlakat, tamme ning vaarikat. Kuusk, vaher, mage sõstar ning sarapuu on samuti mitmel näidisalal esindatud. Lisaks kasvab *lillaka* kasvukohatüübi kohtades paakspuud, kadakat, kaske, haaba, punast leedrit jt.

Uurimuses kasutatud määratlustele kohandatud metsakasvukohatüüpide ordinatsiooniskeemil paikneb *lillaka* kasvukohatüüp *jänesekapsa*, *pohla*, *sinilille* ning *maasika* kasvukohatüüpide vahel (joonis 3.4.1). Sellest ning seega ka kattumisest E. Lõhmuse eristatud üleminekulise kasvukohatüübiga *sinilille*, *jänesekapsa* ning *pohla* kasvukohatüüpide vahel (*jänesekapsa-pohla* kasvukohatüüp) annab tunnistust alustaimestiku koosseis, kus esindatud on nii *palu*-, *laane*-, *sürja*- kui *salumetsadele* iseloomulikke taimi. Puhmarindes on kõige rohkem märgitud mustikat

ja pohla, harvem kanarbikku. Puhmarinne on hea indikaator happese keskkonna määramiseks, sest kõik puhmarinde liigid on hapulembesed. Hästiarenenud puhmarinde olemasolu kinnitab lillaka kasvukohatüübi kuulumist *palumetsade* tüübirühma. Rohurinde kirjeldustes esineb kõige sagedamini lillakat, maasikat ning metskastikut. Palju on ka jänesekapsast, maikellukest ning karvast piipheina. Suhteliselt sagedased on ohtene sõnajalg, leseleht, laanelill, kilpjalg, kuutõverohi, koldnõges, palu-härghein. Lisaks on mitmes kirjelduses märgitud sinilille, maarjasõnajalga, ussilakka, külmamailast, jänese салатit, lakklehte, aasosja, lamba-aruheina, kolmissõnajalga, naistesõnajalga, mets-tähtheina, sõrmtarna, longus helmikat, võsaülast jt.

Teooria kohaselt (Lõhmus, 1984, 2004) paikneb *lillaka (jänese kapsa-pohla)* kasvukohatüüp huumuslikel leedemuldadel, mille lõimiseks on sidus peenliiv ning mille profiilis leethorisont kas puudub või esineb katkendliku helehalli triibuna. 1: 10 000 mullakaardil on *lillaka* kasvukohatüüpi paigutatud kohtades mullaliigiks samuti märgitud nõrgalt leetunud või huumuslik leedemuld. *Lillaka* kasvukohatüüpi määratud näidisaladel tehti ka mullakaeveid. Selgus, et mullad neis kasvukohtades sarnanevad Paal *et al.* (2004) poolt Otepää kõrgustikul kirjeldatud nn *küllastumata sidus-liivmuldadega* ning L. Reintami (1996) poolt kirjeldatud *Arenosols*'idega. Need mullad sarnanevad esmapilgul nõrgalt leetunud muldadele: soolhappega kihisemine on sügavamal kui 0,8 m, ülemiste horisontide reaktsioon on tugevasti happeline ning morfoloogilised leetumistunnused mullaprofiilis puuduvad, profiili ülasosas esineb mõnikord raudkiviveerist ja kruusa. Mineraloogiliselt on need liivad aga suhteliselt rikkad (liivafraktsiooni murenemisel on suurenenud sekundaarsete mineraalide arvel tolmufraktsiooni osatähtsus) ning lõimiselt lähedased saviliivadele. Huumushorisondi huumuse- ja lämmastiksisaldus on samuti suhteliselt kõrge ning võrreldav karbonaatsete veerismuldadega. Mulla mineraloogilisele rikkusele viitab sarapuu esinemine põõsarindes ning alustaimestiku liigirikkus, mis on ränirohkel leetunud liivmullal kasvavate metsadega (*pohla, mustika, jänese kapsa* kasvukohatüübi metsad) võrreldes palju suurem.

Lillaka kasvukohatüüpi kuulub 32 näidisala.

3.4.2.1.3. Mustika kasvukohatüüp

Mustika kasvukohatüübis on siiani eristatud kõige rohkem okas-segametsi, aga ka männikuid ning harvik/noorendik/raiesmik. Kõigi vaatlusalade puistutes peale ühe, kus domineerib kuusk, on peapuuliigiks mänd, millele lisandub enamasti kuusk, mõnikord ka aru- või sookask.

Mustika kasvukohatüüpi kuuluvate näidisalade kirjeldustes on teise rinde puudest mainitud pihlakat; põõsarindes pihlakat, haaba, mändi, kaske ning vaarikat. Puhmarindes kasvab peamiselt mustikas, millele lisandub pohl ning harvem kanarbik. Rohurinne on hõre, nimetatud on leselehte, metskastikut, palu-härgheina, kilpjalga, lillakat jt.

Mustika kasvukohatüüpi kuulub 10 näidisala.

3.4.2.2. Laanemetsade tüübirühm

3.4.2.2.1. Jänesekapsa-mustika kasvukohatüüp

Selles kasvukohatüübis eristati kõige enam okas-segametsi, aga ka kuusikuid, kaasik, haavik ning harvik/noorendik/raiesmikke. Segametsas domineerib kuusk või mänd, rohkelt on ka sarapuud ja arukaske. Lisaks kasvab segametsades kohati pihlakat, tamme, haaba, halli leppa, vahtrat. Harvik/noorendik/raiesmikul kasvavad männid ning arukased. Kuusikus kasvab kuuse kõrval sarapuud, kaasikus ning haavikus lisandub peapuuliigile kuusk.

Teises rindes kasvab kõige sagedamini pihlakas, tamm ning arukask, mõnikord mänd ja kuusk, kohati ka sarapuu, haab, vaher, saar ning hall lepp. Põõsarindes domineerivad vaarikas, pihlakas ja vaher, palju on veel magedat sõstart ja sarapuud. Vähem on kirjeldustes mainitud kuuske, paakspuud, arukaske ning kuslapuud. Lisaks kasvab selles kasvukohatüübis kohati mändi, toomingat, saart, tamme, halli leppa.

Domineerivad puhmad (mustikas). Rohurinne on liigivaene. Kõige sagedamini on nimetatud leselehte, jänesekapsast ja lillakat, palju on veel metskastikut, maasikat, maikellukest, koldnõgest, sinilille, mets-härgheina. Lisaks on mitme vaatlusalal kirjelduses märgitud jänasesalatit, kilpjalg, ohtest sõnajalga, karvast piipheina, maarjasõnajalga, sõrmtarna, metspipart, võsaülast, aasosja, põdrakanepit, jäneskastikut jt.

Jänesekapsa-mustika kasvukohatüüpi kuulub 22 näidisala.

3.4.2.2.2. Jänesekapsa kasvukohatüüp

Jänesekapsa kasvukohatüübis eristati kõige enam leht- ja okas-segametsi ning kuusikuid, vähem kaasikuid ja haavikuid ning üksusse harvik/noorendik/raiesmik kuuluvaid kooslusi.

Okas-segametsades domineerib enamasti kuusk, üksikutel juhtudel mänd või arukask, kaaspuuliigina esineb enim kaske, aga ka leppa, haaba ning sarapuud. Leht-segametsades domineerivad arukased või haavad, harvem ka hall lepp, palju on sarapuud. Peaaegu kõigil näidiseladel esineb puistuvalemis kuusk. Lisaks kasvab mõlemat tüüpi segametsas saart, vahtrat, toomingat, remmelgat, lehtpuu-enamusega puistutes ka jalakat ning okaspuu-enamusega puistutes tamme ja pihlakat.

Teises rindes on rohkem märgitud arukase, pihlaka, remmelga, vahtra esinemist, kuid nimetatud on ka sarapuud, kuuske, jalakat, haaba, leppa, tamme. Põõsarindes kasvab kõige rohkem pihlakat, sarapuud ja vahtrat; üsna sageli on märgitud ka saare, kuslapuu, vaarika, mageda sõstra ja paakspuu esinemist. Harvemini, kuid siiski esindatud on tamm, jalakas, toomingas, lodjapuu, lisaks hall lepp, kask, haab, kuusk ning paju.

Puhmarindes on nimetatud mustikat. Rohurinne on suhteliselt liigivaene, selles on kõige enam nimetatud jänesekapsast. Suhteliselt paljude vaatluste puhul on märgitud maasika, koldnõgese, naiste-, maarja- ning ohtese sõnajala esinemist. Mitmel korral on mainitud ka metspipart, sinilille, võsaülast, väikeseõielist lemmaltsa, lillakat, salu-siumarja, aasosja, kõrvenõgest, metskastikut, leselehte, jänasesalatit, naati, maikellukest, salu-tähtheina, maamõõla, ussilakka, kilpjalg, lisaks harilikku härgheina, metsosja, põdrakanepit, kirjut kõrvikut, laanelille, kolmissõnajalga, luht-kastevart, uibulehte, karvast piipheina jt.

Jänesekapsa kasvukohatüüpi kuulub 66 näidisala.

3.4.2.3. Sürjametsade tüübirühm

3.4.2.3.1. Maasika kasvukohatüüp

Sürjametsade tüübirühmas eristati Otepää looduspargis vaid *maasika* kasvukohatüüp (vt ka ptk 3.4.2.4.1).

Kuna Otepää looduspargi *sinilille* kasvukohad on suhteliselt hästi veega varustatud, kuid *maasika* kasvukohatüüp on määratletud *sürjametsade hulka kuuluva* kuivataluva kooslusena, siis nende kasvukohatüüpide eristamine probleeme ei tekita. Küll aga võib kohati olla raske teha vahet *maasika* ja *lillaka* kasvukohatüüpidel. Kuigi mulla poolest on ühel juhul tegemist happelisel ning teisel juhul karbonaatsel lähtekivimil kujunenud mullaga, on mõlemal puhul niiskustingimused sarnased ning ka puistu välisilme võib neil *lillaka* kasvukohtades esineva liivmulla mineraloogilise rikkuse tõttu (vt ka ptk 3.4.2.1.2) ning põhjusel, et üldiselt on Kagu-Eesti sürjametsad võrreldes Lääne-Eestis esinevatega liigiliselt vaesemad ning paluelemente on rohkem (Kalda, 1991), suhteliselt sarnane olla. Seega peaks kasvukohatüübi määramisel arvesse võtma mullareaktsiooni, soolhappega kihisemise sügavust mullaprofiilis. Veidi erinev on ka nende kasvukohatüüpide paiknemine reljeefil – kui *maasika* kasvukohatüüp asub pigem kõrgemate pinnavormide lagedel, siis *lillaka* kasvukohatüüp paikneb laugatel nõlvadel või tasasel alal.

Maasika kasvukohatüübis on andmebaasis kõige rohkem kirjeldusi okas-segametsade ning männikute kohta. Olemas on ka kuusikute, kaasiku, kase-segametsade ning harvik/noorendik/raiesmiku näidisalad. Kuusikus kasvavad peamiselt ainult kuused, lisanduvad üksikud männid. Männikus lisanduvad peapuuliigile kohati kuused, sarapuud, arukased. Okas-segametsades domineerivad kas kuused või männid, lisaks kasvab seal arukaske, sarapuud, haaba. Kaasikus ja kase-segametsas domineerib arukask, mille kõrval kasvab kõige sagedamini kuusk, harvem mänd, pihlakas, sarapuu, hall lepp, haab, remmelgas. Harvik/noorendik/raiesmik on esindatud haava-enamusega puistuga.

Teises rindes on sagedasemad pihlakas, kuusk ja sarapuu, lisaks esineb mändi, toomingat, kaske, vahtrat. Sarnaselt teisele rindele esineb põdsarindes kõige sagedamini pihlakat ja sarapuud, aga ka kuuske, lisaks vahtrat, tamme, magedat sõstart, kuslapuud, toomingat ning vaarikat.

Puhmarinne on *maasika* kasvukohatüübis tunduvalt halvemini välja kujunenud kui *lillaka* kasvukohatüübis; selles kasvab mõnes vaatluskohas mustikat. Rohurinde puhul on kirjeldustes teistest tunduvalt rohkem nimetatud maasikat. Suhteliselt palju on ka lillakat, ristikut, lakklehte, sinilille, jänese kapsast, kõrvenõgest. Lisaks on mõnes kirjelduses mainitud võsalille, metskastikut, longus helmikat, arujumikat, suurt aruheina, punast aruheina, mägimühti, kolmissõnajalga, karvast piipheina, võilille, harilikku näärt, luht-kastevart, äiatari, väikeseõielist lemmaltsa, koldnõgest, kannikest, roomavat tulikat, harilikku nurmikat, karukolda, salu-siumarja, maarjaleppa, sõrmtarna, aasosja, pehmet madarat, maamõõla, leselehte, nurmenukku, kilpjalga, jänese salatit, palu-härgheina.

Maasika kasvukohatüüpi kuulub 31 näidisala.

3.4.2.4. Salumetsade tüübirühm

3.4.2.4.1. Sinilille kasvukohatüüp

Varasemates Otepää looduspargi kasvukohatüüpide kaardistustes (2001 ja 2002) *sinilille* kasvukohatüüpi pole eristatud. Siis paigutati sellised kooslused *sarapuu* kasvukohatüüpi *sürjametsade* tüübirühmas.

Sinilille ja *sarapuu* kasvukohatüüpide puhul on kogu Eesti metsatüpoloogia ajaloo jooksul olnud tegemist üsna raskesti piiritletavate ning üleminekuliste üksustega. Karu ja Muiste (1958) klassifikatsioonis on eristatud osaliselt sürjametsi hõlmavad *maasika-sinilille* ja *sarapuu* kasvukohatüübid. Lõhmus (1974a, 1974b) võttis nimetatud tüpoloogide *maasika-sinilille* asemel kasutusele *sinilille* kasvukohatüübi nimetuse. Algul paigutas ta viimase *sürjametsade* tüübirühma nagu seda olid teinud ka Katus ja Tappo (1965). Lõhmusel kuulus sürjametsade hulka veel *sarapuu*, Katusel ja Tappol *pohla-sinilille* kasvukohatüüp. Hiljem Lõhmus (1984) sürjametsi enam omaette tüübirühmana ei eristanud; siis paigutas ta *sinilille* kasvukohatüübi *laanemetsade* tüübirühma ning jättis *sarapuu* kasvukohatüübi üldse eraldi käsitlemata, jagades selle vastavalt mullatingimustele ära *sinilille* ja *jänesekapsa* kasvukohatüüpide vahel.

Sinilille kasvukohatüüpi on erinevad tüpoloogid paigutanud ka erinevatesse tüübirühmadesse: *sürjametsade* (Lõhmus, 1974a, 1974b; Katus, Tappo, 1965), *laanemetsade* (Lõhmus, 1984) ning *salumetsade* (Ilves, 1953, 1969; Laasimer, 1965; Paal, 1997) hulka. Masing (1970) aga läks kompromissile: *salumetsades* eristas ta *sinilille-ülase* ja *sürjametsade* hulgas *maasika (sinilille)* kasvukohatüübi. Ilmselt tuleneb selline käsitluse erinevus tüpoloogia aluseks olnud andmestiku erinevusest – kuivemapoolsete sinilille-metsade uurijad on eelistanud need paigutada sürja-, niiskemate metsade uurijad salu- või laanemetsade hulka.

Kuna nii *sinilille* kui *sarapuu* kasvukohatüüp esinevad teooria kohaselt (Lõhmus, 1984, 2004; Paal, 1997) samasugustel karbonaadirikastel muldadel (leostunud pruunmuldadel, leetjatel pruunmuldadel või rendsiinadel) ning sarapuud võib ohtralt esineda mõlema kasvukohatüübi metsades (eriti noorendikes ja raiesmikel), tuleb kasvukohatüübi määramisel aluseks võtta veerežiim. *Sarapuu* kasvukohatüüp kuulub *sürjametsade* tüübirühma, mis on defineeritud õhukese peenesekihiga, suvel kergesti läbikuivavate muldadega koosluseid hõlmava üksusena, *sinilille* kasvukohatüüp aga *salumetsade* tüübirühma, mille kasvukohad on kogu aasta jooksul veega hästi varustatud (Paal, 1997). Kuna sarapuuohked kooslused Otepää looduspargis niiskuse puuduse all ei kannata, siis nimetati need vaidlusalused kohad *sinilille* kasvukohatüüpi kuuluvaks ning *sarapuu* kasvukohatüüpi ei eristatud. Leiti, et tüüpilisel kujul viimast Otepää looduspargis ei esine.

Kõige rohkem on *sinilille* kasvukohatüübis leht-segametsi, järgnevad kuuse- ja männi-segametsad. Lisaks on eristatud kase-segametsi, männikuid, kuusikuid, kaasikuid, pärnik, lepik ning noorendik/raiesmik. *Sinilille* kasvukoha puistud on naadimetsade kõrval ühed liigirikkamad, mida on näha ka puistuvalemitest, milles on sageli märgitud kuni seitse erinevat puuliiki. Liigirikkaimad on leht-segametsad, kus erinevatel vaatlusaladel domineerivad erinevad puuliigid: kuusk, saar, hall lepp, tamm, sarapuu, haab, arukask; lisaks kuulub leht-segametsa puistuvalemitesse mändi, vahtrat, remmelgat, pihlakat, pärna, lehist, toomingat, jalakat. Pärnikus esinevad 100% pärnad, kuusikus ainult kuused, hall-lepikus kasvab koos peapuuliigiga kuuske, kaasikus sarapuud, kuuske ja remmelgat. Männikus ja männi-segametsas domineerib mänd, selle kõrval kasvab kõigis vaatluskohtades kuusk, üsna sageli on märgitud ka sarapuu ja arukase ning mõnikord pihlaka, vahtra, tamme, remmelga esinemist. Kuuse-segametsades domineerib kuusk, palju on ka arukaske, mändi, sarapuud, aga ka toomingat, vahtrat, leppa, pihlakat, jalakat. Kase-segametsas domineerib arukask, millele peaaegu alati lisandub kuusk ning tihti ka sarapuu või

haab, mõnikord ka hall lepp, remmelgas või mänd. Koosluses noorendik/raiesmik kasvab enim kuuske ja sarapuud.

Teise rinde puudest on kõige sagedamini nimetatud tamme ja pihlakat, aga ka vahtrat, arukaske, remmelgat, haaba. Lisaks esineb halli leppa, sarapuud, kuuske ning saart ja mändi. Põõsarindes domineerivad kasvukohatüübile iseloomulikest liikidest sarapuu ja kuslapuu, rohkelt esineb ka magedat sõstart, pihlakat ning vahtrat; lisaks kuuske, vaarikat, toomingat, saart, mõnikord tamme, lodjapuud, näsiniint.

Puhmarinne puudub. Rohurindes on kõige sagedamini märgitud sinilille ja jänsekapsast, neile järgnevad maasikas, metskastik ja metspipar, palju on veel koldnõgest, lillakat ja maikellukest. Suhteliselt tihti on kirjeldustes naati ja salu-siumarja ning võsaülast, lisaks kilpjalga, mustikat, jänesesalatit, väikeseõielist lemmaltsa, sõrmtarna, aasosja, ohtest sõnajalga, naistesõnajalga, leselehte, karvast piipheina jt. Võrreldes naadi kasvukohatüübiga on rohurinne mõnevõrra liigivaesem (v.a mõne leht- või leht-segametsa näidise puhul) ning märkimisväärne on kõrvenõgese mainimine vaid ühe näidisala puhul. Kilpjalga kasvab enamasti kase-metsades (ka teistes kasvukohatüüpides). Metskastikut on rohkelt just männimetsades. Jänsekapsas domineerib sinilille kõrval peamiselt okaspuu-enamusega metsades.

Sinilille kasvukohatüüpi kuulub näidistebaasis kõige rohkem näidisalasid – 91.

3.4.2.4.2. Naadi kasvukohatüüp

Naadi kasvukohatüübis on siiani kõige rohkem eristatud leht-segametsi. Viimastest on eraldatud vastavate näidiste suhteliselt rohke esindatuse tõttu lepa-segametsad (halli lepa osakaal 50...70%). Lisaks on kirjeldatud hall-lepikuid, kaasikuid, haavikuid, kuusikuid, harvik/noorendik/raiesmikke, *laialehine naadi-salumets*, männik ning okas-segamets.

Naadi kasvukoha puistud on *sinilille* kasvukohatüübi omade kõrval liigirikkaimad (puistuvalemis kuni 9 puuliiki). Segametsades kasvab kõige rohkem arukaske. Palju on veel kuuske, haaba, sarapuud, halli leppa ja jalakat, aga ka saart ning remmelgat. Lisaks esineb puistuvalemeis pärn, vaher, tamm, pihlakas, paju, mänd. Harvik/noorendik/raiesmikul domineerib haab, mõnikord ka kuusk, kask või remmelgas. Puhtpuistutes on kõige sagedamini kaaspuuliigiks kuusk või arukask, lepikutes ka toomingas, jalakas, sarapuu või remmelgas; kaasikus kasvab pärna. Kuusikus kasvab peapuuliigi kõrval haaba, halli leppa. *Laialehisesse naadi-salumetsa* kuuluvad haruldasemad laialehised puhtpuistud. Näidistebaasist kuulub siia vaatlus, kus peapuuliigiks on vaher (vahtra osakaal 80%).

Alusmetsas kasvab puudest enamasti kuuske, toomingat (seda liiki just lepikus), arukaske, aga ka vahtrat, pihlakat, haaba, paju, remmelgat, leppa, tamme, saart. Põõsarindes on eriti ohtralt vaarikat, toomingat, sarapuud ja kuslapuud ning pihlakat. Sageli esineb kirjeldustes veel vahtrat, kuuske, magedat sõstart, aga ka leppa ja haaba; harvem näsiniint, saart, lodjapuud ning paju. Lisaks on üksikutes kirjeldustes mainitud põõsaid (jalakas, kask, leeder, tamm, pärn, must sõstar), millest mitmed on olulised ära märkida seetõttu, et neid esineb suhteliselt harva ning just laialehistes naadimetsades.

Puhmarinne puudub. Rohurindes domineerib naat, palju on ka metspipart, kõrvenõgest ja jänsekapsast, vähem sinilille, maasikat, koldnõgest ning naistesõnajalga. Mitmetes kirjeldustes on nimetatud luht-kastevart, maarjasõnajalga, heinputke, aasosja, ussilakka, seaohakat, metsosja, angervaksa, salu-tähtheina, väikeseõielist lemmaltsa, metstarna ning mets-nõianõgest. Mõnikord on mainitud salu-siumarja, mets-harakputke, orasheina, keraheina, metskastikut, harilikku luga, soo-koeratubakat, mets- ja harilikku härghina, lillakat, soo-ohakat, maamõõla, kolmissõnajalga,

jänesesalatit, maikellukest, ohtest sõnajalga, kilpjalga, imekannikest, kevadist seahernest, nõgeselehist ja laialehist kellukat, suurt aruheina, püsik-seljarohtu jt.

Naadi kasvukohatüüpi kuulub 66 näidisala.

3.4.2.5. Soostunud metsade tüübirühm

3.4.2.5.1. Sõnajala kasvukohatüüp

Andmebaasis on leht-segametsade ning harvik/noorendik/raiesmiku kirjeldused. Tegemist on väga erinevaimeliste puistutega, kus enamasti on kõige rohkem kuuske, kuid mõnikord domineerib ka haab või hall lepp. Lisaks kasvab neis kohtades arukaske, saart, sookaske, mändi, jalakat, remmelgat, kohati sarapuud ning pihlakat.

Põõsarinde koosseis on erinevatel näidisaladel erinev: paakspuu, tamm, pihlakas, haab, sookask, mänd, paju, kuusk, kuslapuu, sarapuu, jalakas, saar, toomingas.

Puhmarinne puudub. Rohurindes on kõige enam naistesõnajalga, koeratubakat ning metskastikut, vähem seaohakat ja naati ning lisaks paiselehte, ülast, maasikat, metsosja, harilikku luga, angervaksa, laiuvat sõnajalga, maarjasõnajalga, ohtest sõnajalga, kolmissõnajalga, jänesekapsast, väikeseõielist lemmaltsa, luht-kastevart, salu-siumarja, kõrvenõgest, metspipart, suurt aruheina, heinputke, salu-tähtheina, koldnõgest, sookastikut, aasosja.

Sõnajala kasvukohatüüpi kuulub 5 näidisala.

3.4.2.5.2. Angervaksa kasvukohatüüp

Angervaksa kasvukohatüübis on enim eristatud leht-segametsi ja hall-lepikuid, lisaks okas-segametsi, sanglepikuid, harvik/noorendik/raiesmik ning kaasik.

Segametsades kasvab kõige rohkem kuuske, ohtralt on ka sangleppa, halli leppa, arukaske ning haaba. Lisaks kasvab neis paju, saart, sarapuud, tamme, vahtrat, pärna, jalakat. Hall-lepikutes esineb lisaks hallile lepale sangleppa, paju, toomingat. Harvik/noorendik/raiesmikus domineerib hall lepp, millele lisandub kuuske ja kaske. Kaasikus kasvab kasega koos kuuske.

Teises rindes kasvab kaske ja kuuske. Põõsarindes on kõige rohkem kuuske, halli leppa ja toomingat; esindatud on ka paju, pihlakas, sarapuu, paakspuu, jalakas. Lisaks on märgitud kuslapuu, pärna, tamme, musta sõstra, lodjapuu esinemist.

Puhmarinne puudub. Rohurindes domineerivad angervaks ja seaohakas, palju on ka naati, metspipart, ohtest, maarja- ning naistesõnajalga, kõrvenõgest, harilikku metsvitsa, ojamõõla, jänesekapsast. Lisaks on nimetatud lillakat, metsosja, luht-kastevart, soo-koeratubakat, salu-tähtheina, heinputke, humalat, püsik-seljarohtu, kevadist seahernest, aasosja, ülast, roomavat tulikat, väikeseõielist ja õrna lemmaltsa, sinilille ning koldnõgest.

Angervaksa kasvukohatüüpi kuulub 16 näidisala.

3.4.2.5.3. Sinihelmika kasvukohatüüp

Andmebaasis on üks *sinihelmika* kasvukohatüüpi kuuluv näidis — leht-segamets, kus kasvab aru- ja sookaske, kuuske ning sarapuud ning põõsarindes kuuske, sarapuud, pihlakat, paakspuud. Rohurindes on esindatud ojamõõl, soo-koeratubakas, jänesekapsas, metsosi, maarjasõnajalg.

3.4.2.6. Madalsoometsade tüübirühm

Selles uurimuses on uue, *madalsoometsade* tüübirühma kuuluva kasvukohatüübina eristatud *allikasoometsa* kasvukohatüüp. *Lodumetsa* kasvukohatüübis on peetud vajalikuks eristada *lodupajustike* kooslus.

3.4.2.6.1. Madalsoometsa kasvukohatüüp

Kõige enam eristati madalsoo-segametsi, kus enamasti domineerib sookask või kuusk, millele järgnevad sanglepp ning kask. Madalsoo-segametsadest eraldati madalsoo-männisega- ja madalsoo-sookase-segametsad. Seda põhjusel, et mänd ja sookask domineerivad sageli madalsoometsade puistutes (katvus vastavalt männil või sookasel 50% või rohkem), kuid tihti 80% puistu koosseisust ei moodusta, et kooslust nende liikide järgi nimetada. Puhtpuistutest eristati kaasikuid (soo- või arukase katvus üle 80% või soo- ja arukase katvus kokku 80% või rohkem). Sageli esineb puistuvalemis pajuliike.

Teises rindes kasvab enamasti kuusk või hall lepp, nimetatud on ka saart, remmelgat, mändi, sangleppa, arukaske ning haaba.

Põõsarindes on kõige sagedasemaks liigiks paakspuu, palju on ka kuuske ning pajuliike, lisaks pihlakat, kadakat, madalat kaske, vahtrat, tünnpuud, halli leppa, saart, toomingat, sarapuud, sookaske. Mainitud on veel vaarikat, tamme, lodjapuud, magedat sõstart, sangleppa, vaevakaske ning mändi.

Puhmarinde taimedest esineb kohati mätastel mustikat, üksikutes kohtades ka pohla ning jõhvikat. Rohurindes domineerib angervaks, lisaks sellele on palju ojamõõla, soopihla ja uba-lehte, aga ka varsakapja, soo-koeratubakat, harilikku tarna, tedremaranat. Vähem leidub seaohakat, kannikeseliike, metsvitsa, konnaosja, soo-piimputke, heinputke, pilliroogu, mätastarna, lillakat, luht-kastevart, jänese kapsast, sookastikut, ohtest ja soosõnajalga ning soomadarat. Peale selle on märgitud soo-ohaka, soo-kurereha, maikellukese, naistesõnajala, lodumadara, hirsstarna, kõrvenõgese, soo-osja, naadi, põistarna, sinihelmika, kollase tarna, uibulehe, leselehe, usslille, maasika jt esinemist.

Madalsoometsa kasvukohatüüpi kuulub 59 näidisala.

3.4.2.6.2. Lodumetsa kasvukohatüüp

Lodumetsa kasvukohatüüpi kuuluvate koosluste hulgas on kõige rohkem eristatud leht-segametsi; lisaks sanglepikuid, kaasikuid, *lodupajustikke*, hall-lepik ning harvik/noorendik/raiesmik. *Lodupajustikeks* on nimetatud enamasti künkliku maastiku sulglohkudes hästilagunenud turbakihiga sügaval madalsoomullal või toorhuumusliku horisondiga gleimullal kasvavad kooslused, mille puittaimede katvus on vähemalt 30% ning paju osakaal puittaimestikis vähemalt 80%. Neisse sulglohkudesse valgub lume sulamisel ja vihmaga tekkiv pinnavesi. Põhjavee tase on siin ilmselt suhteliselt kõrge ning põhjavesi liikuv, mis on peamiseks erinevuseks *paju* kasvukohatüüpi paigutatud *määratlemata pajustike* kasvukohatingimustest (vt ptk 3.4.2.10).

Sanglepikuis ning koosluses harvik/noorendik/raiesmik kasvab sanglepp kas üksi või koos sookasega. Ka leht-segametsades on sangleppa palju (esineb peaaegu kõigil vaatlusaladel ning domineerib mitmes neist). Segametsas on sagedased ning mõnikord ka dominantliikideks veel sookask ja hall lepp, vähem esineb puistuvalemis arukaske, kuuske, haaba, paju, mändi. Hall-

lepikus kasvab hall lepp koos kuusega. Kaasikutes kasvab lisaks (enamasti soo-)kaskedele kuuske või paju. Pajustikes esineb lisaks pajudele halli leppa, soo- ning arukaske.

Teises rindes kasvab kuuske, soo- ja arukaske, mändi, sangleppa ning remmelgat. Põõsarindes on kõige sagedasemad pajuliigid, palju on ka toomingat ja paakspuud, lisaks halli leppa, kuuske, pihlakat. Kohati kasvab neis kasvukohatüüpides magedat ja musta sõstart, lodjapuud ning vaarikat.

Rohurindes on kõige tavalisemaks taimeks angervaks. Sageli tuleb ette ka heinputke, varsakapja, soo-koeratubakat, seaohakat, soo- ja konnaosja, maavitsa, metsvitsa, ubalehte, soopihla, pilliroogu, erinevaid tarnasid (ümar-, mätas-, soo-, lodu-, kollane, harilik, eris-, kraav-, pudel-, põistarn), soo- ja lodumadarat, parkheina, soovõhka, soosõnajalga, palderjani, metskõrkjat, naistesõnajalga, soo-kurereha, soo-pajulille, sookastikut, kannikeseliike, lodupajustikus ka ussilille, loduharvikus hundinuia, vesitakjat. Mätastelt ning kuivematest kasvukohtadest (kaasikus, segametsas) võib üsna tihti leida laane- või salumetsadele iseloomulikke liike: jänsekapsast, leselehte, sinilille, lillakat, naati, ussilakka, salu-tähtheina, kõrvenõgest, ojamõõla, püsig-seljarohtu, maikellukest, aga ka harilikku nõiakolda, lakklehte, salu-siumarja, aasosja, koldnõgest, metspipart, kuutõverohtu, kullerkuppu, ülast, puhmarindes mustikat.

Olemasolevate kirjeldustega näidised on taimestiku järgi pigem kuivemapoolsed — lammimetsade (näiteks *pika tarna* kasvukohatüübi), pajustike või *angervaksa* kasvukohatüübi lähedased.

Lodumetsa kasvukohatüüpi kuulub 23 näidisala.

3.4.2.6.3. Allikasoometsa kasvukohatüüp

Allikasoometsade näidisalasid on esialgu andmebaasis vähe (6) ja need on kõik segametsad (leht- ja okas-segametsad). Leht-segametsas domineerib hall lepp, okas-segametsas enamasti kuusk. Peaaegu kõigil vaatlusaladel on esindatud sookask. Lisaks esineb puistu koosseisus mändi ja saart, arukaske, paju ning sangleppa.

Teises rindes kasvab kuuske, halli leppa, toomingat ning pihlakat. Põõsarinne on suhteliselt liigirikas, kõige enam on nimetatud halli leppa, samuti sarapuud, pihlakat ning paakspuud. Lisaks kasvab põõsarindes vaarikat, paju, arukaske, kadakat, tamme, kuuske, saart ning madalat kaske.

Rohurinde liikidest on kõige sagedamini nimetatud seaohakat, soo-koeratubakat ning angervaksa, vähem pilliroogu, ojamõõla, konnaosja, soo-osja, soomadarat, heinputke, lakklehte, uibulehte, naati, naistesõnajalga, jänsekapsast, lillakat. Lisaks on mainitud sinilille, metsosja, ussilille, salu-tähtheina, vööthuul-sõrmkäppa, kannikeseliike, suurt aruheina, niitjat tarna, väikeseõielist lemmaltsa, aasosja, soo-lõosilma, mätastarna, metsvitsa, varsakapja, soo-piinputke, pajulille, ussilakka, metskõrkjat, soosõnajalga, peetrilehte, käbiheina, tedremaranat, leselehte, ubalehte. Puhmarinde liikidest on kohati esindatud mustikas ja pohl.

3.4.2.7. Siirdesoometsade tüübirühm

3.4.2.7.1. Siirdesoometsa kasvukohatüüp

Kõige rohkem on andmebaasis selle kasvukohatüübi okas-segametsade näidisalasid. Kirjeldatud on ka kaasikuid ja männikuid, leht-segamets ning harvik/noorendik/raiesmik.

Segametsade hulgas on tavalisim kooslus männi, kuuse ning (enamasti soo-) kase segamets. Kaasikutes on peapuuliigiks sookask, millega koos kasvab mõnikord paju või mändi. Männikus lisandub peapuuliigile kuusk ja/või sookask. Harvik/noorendik/raiesmikul domineerib kuusk, mille kõrval kasvab sookaske.

Teises rindes kasvab kuuske, sookaske, halli leppa ja sangleppa, haaba ning kadakat. Põõsarindele on kõige iseloomulikum ohtra paakspuu esinemine; palju on ka kuuske, samuti pajuliike, kadakat, tamme, pihlakat. Lisaks on kirjeldustes põõsarindesse märgitud haaba, sarapuud, halli leppa, saart ning madalat kaske.

Puhma-rohurinnet iseloomustab siirdesoometsadele iseloomulik üleminekuline taimeistik. Madalsoo-poolse siirdesoo puhul on mitmes kirjelduses nimetatud ubalehte ja konnaosja, vähem harilikku tarna, pilliroogu ja sinihelmikat; lisaks on mainitud soosõnajalga, sookastikut, soopihla, niitjat tarna, soo-piimputke, lodutarna, varsakapja, peetrilehte. Veel kasvab siirdesoometsades suhteliselt palju õhema turbakihiga (soostunud) metsadele iseloomulikke taimi nagu angervaks, ojamõõl, ohtene sõnajalg, vähem soo-koeratubakat, metsvitsa, tähttarna, lakklehte, jänesekapsast, mustikat, tedremaranat. Siirdesoometsadele omaselt kasvavad neis kasvukohtades madalsootaimedega kõrvuti rabataimed: rohkem jõhvikat, sinikat, tupp-villpead ja pohla, vähem küüvitsat, kanarbikku, sookailu. Mätastel kasvab lillakat ja leselehte. Viimased, laanelill ning ümaralehine uibuleht, aga ka jänesekapsas, mustikas ning lakkleht viitavad võimalikule kuivenduse/kuivenemise mõjule (kõdusoostumisele).

Siirdesoometsa kasvukohatüüpi kuulub 17 vaatluskohta.

3.4.2.8. Rabametsade tüübirühm

3.4.2.8.1. Rabametsa kasvukohatüüp

Enamik vaatlusi kuulub rabamännikute hulka, kuid esineb ka okas-segametsa kirjeldusi. Kõigil näidisaladel domineerib mänd, mille kõrval kasvab sookaske.

Teises rindes esineb selle olemasolu korral kuuske ning kohati halli leppa, põõsarindes lisaks neile soo- ja arukaske. Puhma-rohurindes domineerivad rabataimed: sookail, tupp-villpea, sinikas, samuti jõhvikas ja kanarbik, lisaks kasvab kohati küüvitsat ning rabamurakat. Siirdesoometsa-poolses koosluses (segametsas) kasvab pilliroogu ja ubalehte, kuivemates ning toitainerikkamates kohtades (mätastel) mustikat, pohla, palu-härgheina.

Rabametsa kasvukohatüüpi kuulub 9 vaatluskohta.

3.4.2.9. Kõdusoometsade tüübirühm

3.4.2.9.1. Mustika-kõdusoometsa kasvukohatüüp

Enim on kirjeldatud segametsi (leht- ja okas-segametsad), kuid ka kuusikuid ning männik. Kasvukohatüübi puistutes kasvavad kuusk, mänd ja sookask enamasti koos. Enamupuuliigiks on kõige sagedamini kuusk, harvem sookask või mänd. Andmebaasis olevatest *mustika-kõdusoometsa* kasvukohatüüpi kuuluvatest kooslustest on liigirikkaima puistuga leht-segamets, kus kuuse, sookase ja männi kõrval esineb ka arukaske, pajuliike, haaba, leppa, sangleppa.

Teises rindes kasvab pihlakat, kuuske, tamme, põõsarindes samuti pihlakat ning kuuske, aga ka vahtrat, paakspuud ja vaarikat. Puhma-rohurindes domineerivad palu- ja laanemetsade taimed:

puhmarindes mustikas koos pohlaga ning rohurindes jänesekapsas, leseleht, ohtene sõnajalg. Kõdusoometsadele iseloomulikult esineb kõrvuti arumetsataimedega sootaimi (sookail). Lisaks on ühelt näidisalalt leitud kasvamas käpaliseliik: roomav öövilge.

Mustika-kõdusoometsa kasvukohatüüpi kuulub 17 näidisala.

3.4.2.9.2. Jänesekapsa-kõdusoometsa kasvukohatüüp

Jänesekapsa-kõdusoo kasvukohatüübis on kirjeldatud kõige enam segametsi (leht- ja okas-segametsad). Segametsades domineerib kuusk, mänd, sookask või arukask. Lisaks kasvab seal haaba, sangleppa ja leppa. *Jänesekapsa-kõdusoo-kaasikutes* esineb nii soo- kui arukaske (soo- või arukase või nende katvus kokku on vähemalt 80%). Kaskedega koos kasvab kuusk. Andmebaasis on ka *jänesekapsa-kõdusoo-kuusiku* näidiskoht.

Teises rindes kasvab kohati mändi ja saart. Põõsarindes domineerib pihlakas, rohkelt on ka kuuske ja paakspuud ning tamme. Lisaks esineb kuslapuud, lodjapuud, paju, leppa, sarapuud. Rohurindes domineerivad laanemetsade alustaimestikule iseloomulikud taimed (jänesekapsas, ohtene sõnajalg, ümaralehine uibuleht), lisaks laanemetsades sageli esinevad salutaimed (lillakas, ussilakk) ning muud salutaimed — nii kuivemapoolsete kasvukohtade omad (maasikas, sinilill) kui ka rohkem niiskust ja toitaineid nõudvad (salu-tähthein, salu-siumari, harilik nõiakold, kõrvenõges, naistesõnajalg). Lisaks esineb mustikat ja väikeseõielist lemmaltsa. Madalsoometsade, millest jänesekapsa-kõdusoo metsad on kujunenud, taimi (varsakabi, soosõnajalg, soo-koeratubakas, ojamõõl) on vähem.

Jänesekapsa-kõdusoometsa kasvukohatüüpi kuulub 28 näidisala.

3.4.2.10. Lammipajustike tüübirühm

3.4.2.10.1. Paju kasvukohatüüp

Lammimuldadel kasvavad pajustikud on paigutatud *lammipajustike* tüübirühma *paju* kasvukohatüüpi. Eesti taimkatte kasvukohatüüpide klassifikatsiooni järgi (Paal, 1997) võiksid lammi-madalsoomuldadel kasvavad pajustikud kuuluda ka *lodumetsa* kasvukohatüüpi (*lodupajustike* hulka).

Samuti on *paju* kasvukohatüüpi kuuluvaks nimetatud suhteliselt väikestes sulglohkudes keset haritavat maad või selle ääres kasvavad pajustikud. Mõnes neist kohtadest on tegemist mineraalmullaga, mõnes (madal)soomullaga. Kuna sulglohud, milles pajustikud kasvavad, on suhteliselt väikse läbimõõduga, on mullakaardil neis esinev mullaliik kohati jäänud välja toomata, kuigi see erineb ümbritsevast (põllumullast) (näiteks madalsoomulla laik gleistunud deluviaalmulla eraldises). Esineb ka juhte, kus põhikaardil on pajustiku-koht märgitud sooks, kuid mullakaardil on tegemist sama põllumullaga mis ümbruskonnas.

Pajusid pole liigini määratud, kõik *paju* kasvukohatüüpi paigutatud kooslused (kokku 5 näidisala) on nimetatud *määratlemata pajustikuks*.

Määratlemata pajustiku vaatlusaladel domineerivad pajuliigid, natuke on puistuvalemeis ka arukaske. Lammimuldadel olevates kooslustes kasvab nii lammipajustikele (soo-piimputk) kui ka madalsoometsadele (lodumetsadele) (ubaleht, suur tulikas) ning samuti neile mõlemale iseloomulikke taimi (konnaosi, soosõnajalg, sookastik) ning tarnaliigid. Teistes antud kasvukohatüüpi kuuluvates pajustikes (põldudevahelised või -äärsed sulglohud) on rohurindeliikideks märgitud metskõrkjat, mätastarna, luhttarna, põistarna, angervaksa, ristlemmelt, ahtalehist nurmikat, käokanni, kõrvenõgest jt.

3.4.2.11. Metsastuv sööt

3.4.2.11.1. Metsastuv sööt

Kuna Otepää looduspargis ja selle ümbruses on rohkelt metsa kasvavaid sööte, peeti vajalikuks koondada need omaette kasvukohatüüpi ja tüübirühma. Metsade hulka ei saa neid lugeda põhjusel, et metsale iseloomulikud ökoloogilised tingimused pole veel välja kujunenud (eelkõige mullatingimused, mis on veel tugevasti harimisest mõjutatud). Samas ei saa neid kohti ka põlluks nimetada, sest sinna on peale kasvanud noor puistu, mis on kõrgem kui 4 m ning mille liitus on üle 30% (nii on määratletud põhikaardi *mets*). Eelmisel põhikaardil on neis kohtades põhialaks *põld*, uusimal põhikaardil *mets* või *noor mets*.

Koosluse nimetus koosneb söödil kasvava puistu tüübist ning söödil oleva mullaliigi nimetusest (näiteks *noor segamets deluviaal- või gleimullaga söödil*). Leetunud või näivleetunud mullaga söödil kasvavad vaatluskohtades noored kaasikud, segametsad, männik ja pajustikud; leostunud või rähkse mullaga söödil ning erodeeritud mullaga söödil samuti kaasikud ning pajustikud; deluviaal- või gleimullaga söödil kasvab noor segamets. Noortes kaasikutes esinevad arukased kas ainsa liigina või koos paju, männi, remmelga, vahtra, kuusega. Noores männikus kasvab mänd koos pajuga. Pajustikes domineerivad pajud (enamasti remmelgad), mille kõrval kasvab arukaske. Noortes segametsades valitsevad arukased, millega koos esineb paju, mändi, remmelgat, vahtrat, kuuske.

Metsastuva söödi kasvukohatüüpi kuulub 23 näidisala.

3.4.3. Puistutüüpide kirjeldused

Puistutüübi all on mõeldud puistu koosseisu poolest ühetaoliste metsaosade kogumit. Puistutüüpide puhul prooviti kahe erinevate põhimõtete järgi loodud klassifikatsiooni üksuste äratuntavust kaardi- ja pildandiandmete järgi. Üks klassifikatsioon tugineb koosluste klasteranalüüsile (ptk 3.4.3.1), teine on loodud, ühendades andmebaasis olevaid ühesuguste puistunimetustega üksusi (ptk 3.4.3.2).

3.4.3.1. Klasteranalüüsil põhinev klassifikatsioon

Klasteranalüüs tehti andmebaasis olevate metsatüüpide (koosluste) kohta (lisa 3). Klasteranalüüs teostati koosluste keskmiste puistuvalemitega, muutujateks olid koosluste keskmised puuliikide katvused ning kooslusse kuuluvate näidisalade keskmine puude poolt katmata ala (protsentides). Viimane peaks eeldatavalt kooslused, mis on keskmisest väiksema või suurema katvusega, aitama eraldi klastritesse paigutada.

Ainult klasteranalüüsil põhinevate klassifikatsiooniüksuste pildi- ja kaardiandmete järgi äratuntavus ei pruugi mitmel põhjusel kõige parem olla. Esiteks, kuigi puistuvalemite klasteranalüüsis eristusid mingid teatud üksused selgepiiriliste klastritena, on paljudes neist näidiseid liiga vähe. Teiseks võeti klasteranalüüsil arvesse vaid puistute liigilist koosseisu ning katvust. Need tunnused on küll mingil määral, kuid mitte otseselt määratud faktorite poolt, mille andmekihtide järgi taimkatet ennustatakse (näiteks rohke sookase esinemine soomullal jms).

Esialgsete tehispöppe tulemuste põhjal halvasti eristuvad (väheste näidistega) klastrid ühendati teistega. Klasteranalüüsi ning tehispöppe tulemuste põhjal eristati 11 puistuklastrit. Alljärgnevalt on toodud nende kirjeldused.

3.4.3.1.1. Männik

Klasteranalüüsil põhinevas klassifikatsioonis hõlmab *männiku* puistutüüp kõiki andmebaasis olevaid puhtmänniku-kooslusi (männi osakaal vähemalt 80%): *pohla-*, *lilllaka-*, *mustika-*, *maasika-*, *sinilille-*, *naadi-*, *siirdesoo-*, *raba-*, *mustika-kõdusoo-männikuid* ning üksust *noor männik söödil*. Andmebaasis olevais männiku-näidisaladel kasvavad mändide kõrval kõige sagedamini kuused, harvem sookased või sarapuud, mõnikord ka arukased ning metsastuval söödil ka pajud. Vaatlusi on neis kooslustes kokku 52.

3.4.3.1.2. Kuusik

Kuusiku puistutüüp hõlmab kõiki andmebaasis olevaid kuusiku-kooslusi (kuuske üle 80%): *jänesekapsa-*, *jänesekapsa-mustika-*, *sinilille-*, *naadi-*, *maasika-*, *mustika-kõdusoo-* ning *jänesekapsa-kõdusoo-kuusikuid*. Kuna üksuse *siirdesooharvik/noorendik/raiesmik* puistuvalemis on kuuske üle 80%, on klasteranalüüsis ka see kuusikute hulka paigutatunud.

Näidistebaasi kuusikutes kasvab kuuse kõrval haaba, halli leppa, sarapuud ning mändi ning sookaske; ette tuleb ka arukaske, tamme, remmelgat. Näidisalasid on kuusiku-kooslustes kokku 37.

3.4.3.1.3. Hall-lepik

Antud üksusse kuuluvad *sinilille-*, *naadi-*, *angervaksa-* ning *lodu-hall-lepikud* (halli lepa osakaal vähemalt 80%), *naadi-lepa-segamets* (halli leppa 50...70%) ning üksused *allikasoo-lehtsegamets* (halli leppa 70%) ning *angervaksa-harvik/noorendik/raiesmik* (halli leppa 60%). Näidisalasid on nimetatud kooslustes kokku 34.

Neis hall-lepikutes kasvab suhteliselt palju ka kuuski ning arukaski, suhteliselt sageli tuleb ette pajuliike ning toomingat, harvem remmelgat, sookaske, sangleppa, saart, jalakat, tamme ja sarapuud.

3.4.3.1.4. Arukaasik

Sellesse klastrisse kuuluvad järgmised arukase enamusega kooslused: *jänesekapsa-*, *jänesekapsa-mustika-*, *maasika-*, *sinilille-* ja *naadikaasik* (arukaske vähemalt 80%); *lilllaka-*, *maasika-* ja *sinilille-kasesegamets* (arukaske 50...70%); *sinihelmika-lehtsegamets* (arukaske 40%). Näidiste koguarv loetletud kooslustes on 33.

Klasteranalüüsi ehk puistu koosseisu ning katvuse järgi võiksid siia kuuluda ka noored kaasikud ja noored segametsad (viimastes domineerib samuti arukask) erinevate muldadega söötidel. Neid on siiski mitmel põhjusel eraldi käsitletud (vt ptk 3.4.3.1.10).

Arukase kõrval kasvab kõigis neis kooslustes palju kuuske. Mõnikord esineb puistuvalemis ka suhteliselt palju mändi, lisaks tuleb ette sarapuud, haaba, remmelgat, sookaske ning vähemal määral ka pihlakat ja pärna.

3.4.3.1.5. Sookasega lehtmets ja leht-segamets

Osades siia klastrisse paigutunud kooslustes domineerib sookask kõigil vaatlusaladel (*madalsoo-sookase-segametsas* on kõigis vaatlustes sookaske 50...70%, *siirdesookaasikus* vähemalt 80%). Teistes antud tüüpi kuuluvates kooslustes on sookask samuti dominantpuuliigiks, kuid ta domineerib koosluse keskmises puistuvalemis (mitte kõigis vaatlustes).

Suurem on sookase osakaal ülejäänud siia klastrisse paigutunud kaasikutes (aru- või sookaske või neid kokku puistuvalemis vähemalt 80%): *jänese kapsa-kõdusoo-kaasikus* (sookaske koosluse keskmisena 50%), *lodkaasikus* (sookaske 71%), *madalsookaasik* (sookaske 69%). Vähem on sookaske, kuid ta siiski domineerib koosluse keskmisena, järgmistes leht-segametsades: *jänese kapsa-kõdusoo-lehtsegamets* (sookaske 36%), *mustika-kõdusoo-lehtsegamets* (sookaske 38%), *siirdesoo-lehtsegamets* (sookaske 39%).

Klastrisse on paigutunud üks kooslus (*madalsoo-lehtsegamets*), milles domineerib arukask (29%) ning üks kooslus (*lodu-lehtsegamets*), milles domineerib sanglepp (30%), kuid ka neis on sookaske palju (vastavalt 17 ja 19%).

Sookase kõrval esineb puistuvalemis sageli arukaske ja kuuske, sagedamini tuleb ette veel sangleppa ja pajuliike, harvem mändi ja halli leppa.

Näidisalasid on üksuses *sookasega lehtmets ja leht-segamets* 78.

3.4.3.1.6. Muu lehtmets

Kuigi klasteranalüüsi järgi saaks eristada sellised puistutüübid nagu *haavik* ja *sanglepik*, liideti need koos üksustega *laialehine naadi-salumets* ja *sinilillepärnik* ühte klastrisse nimega *muu lehtmets*. Seda tehti põhjusel, et esialgsete tehisõppe tulemuste kokkulangevus nende üksuste osas oli väga väike, mis tuleneb ilmselt suuresti asjaolust, et nende üksuste kohta on liiga vähe näidiseid. Haavikute puhul võib mitte-eristumise põhjuseks olla lisaks asjaolu, et suure haava osakaaluga näidiseid on tegelikult palju, kuid need pole omaette üksustena eristatud, vaid kuuluvad teiste leht-segametsade koosseisu.

Seega kuuluvad muu lehtmetsa alla järgmised kooslused: *naadi-*, *jänese kapsa-* ja *jänese kapsa-mustika-haavik* (haava osakaal vähemalt 80%), *maasika-harvik/noorendik/raiesmik* (haaba 60%), *lodu-* ja *angervaksa-sanglepik* ning *lodu harvik/noorendik/raiesmik* (sangleppa vähemalt 80%), *laialehine naadi-salumets* (vahtrat 80%), *sinilillepärnik* (pärna 100%).

Loetletud haava ülekaaluga kooslustes kasvab haava kõrval ka kuuske ja arukaske ning sarapuud, sanglepiku esineb sookaske.

Näidisalasid on üksuses *muu lehtmets* 13.

3.4.3.1.7. Leht-segamets

Siia kuuluvad *sinilille-*, *jänese kapsa-*, *naadi-*, *angervaksa-* ja *sõnajala-leht-segamets* ning *jänese kapsa-* ja *naadiharvik/noorendik/raiesmik*. Näidisalasid on neis kooslustes kokku 93. Praeguses andmestikus on koosluste keskmine lehtpuude osakaal kokku üle 80% (v.a *sõnajala-leht-segamets*, kus see on 70%).

Haab domineerib puistutes kõige sagedamini, ainult *jänese kapsa-leht-segametsa* koosluse puhul on ülekaalus arukase enamusega vaatlused. Arukase enamusega puistud on sagedased kõigis kooslustes peale *sinilille-lehtsegametsa*. Viimasesse ning *naadi-lehtsegametsa* kooslusse kuulub vaatlusi, kus dominantpuuliigiks võib olla sarapuu või saar, *sinilille-lehtsegametsas* ka

tamm ning naadi kasvukohatüübis jalakas või remmelgas. Üsna sageli domineerib vaatlusaladel ka hall lepp või kuusk.

Enamik näidisalasid on sellised, kus puistuvalemis on puuliike väga palju ning on raske öelda, milline neist domineerib. Kõigis kooslustes on rohkelt arukaske ja haaba, palju on ka kuuske ja halli leppa (v.a *jänesekapsaharvik/noorendik/raiesmiku* puhul). Kõigis kooslustes kasvab sarapuud ning saart, sage on ka remmelgas, tamm ja jalakas, aga ka pajuliigid, pihlakas, vaher. Harvem tuleb ette pärna, toomingat, mändi, sangleppa (ainult angervaksa kasvukohatüübi leht-segametsas) ning isegi lehist. Iseloomulik on puistu suur liigirikkus ning sookase puudumine kõikidest vaatustest (vrd üksus *sookasega lehtmets ja leht-segamets*, ptk 3.4.3.1.5).

3.4.3.1.8. Okas-segamets

Tegemist on nii koosluste (15) kui näidisalade (150) poolest kõige arvukama puistute üksusega. Siia kuuluvad järgmised kooslused: *maasika-, lillaka-, mustika-, jänesekapsa-, jänesekapsa-mustika-, angervaksa-, jänesekapsa-kõdusoo-, mustika-kõdusoo-, allikasoo-, madal soo- ja siirdesoo-okas-segamets; pohla-, lillaka- ja sinilille-männi-segamets ning sinilille-kuuse-segamets*.

Kõigis loetletud kooslustesse kuuluvatel vaatlusaladel on männi või kuuse või mõlema osakaal kokku 50...70% (v.a paar üksikut vaatlust *jänesekapsa-mustika-okassegametsa* kooslusest, kus okaspuude osakaal on 40%). Männi-segametsades domineerib mänd, kuuse-segametsades kuusk.

Arumetsa kasvukohatüüpide puistuvalemis esineb kuuse ja/või männi kõrval kõige sagedamini arukaske ning sarapuud; mõnel näidisalal kasvab vahtraid, pihlakat, tamme, remmelgat, haaba, toomingat, leppa ning jalakat.

Soometsa kasvukohatüüpide puistutes kasvab kuuse ja männiga koos kõige sagedamini sookask, harvem arukask; mõnikord lisandub sanglepp või hall lepp. *Jänesekapsa-kõdusoo-okassegametsa* vaatlusaladel on palju nii soo- kui arukaske. *Angervaksa-okas-segametsa* puistud sarnanevad koosseisult pigem soometsade puistutele.

3.4.3.1.9. Harvik/metsalage

Klasteranalüüsis eristus üksus, kuhu kuuluvate koosluste keskmine katvus on suhteliselt madal. Siia kuuluvad kooslused, kus katvus on alla 30% kõigil vaatlusaladel (*pohla-, mustika-, sõnajala-, lillaka- ja madal soo-harvik/noorendik/raiesmik*); kooslused, kus esineb nii madala kui kõrge katvusega vaatluskohti, kuid keskmine katvus on suhteliselt madal (30...50%) (*jänesekapsa-mustika-harvik/noorendik/raiesmik* ja *sinilille-noorendik/raiesmik*), ning hõredamad küpse metsa kooslused (*naadi-okas-segamets, madal soo-männi-segamets, raba-okas-segamets*), mille keskmised katvused on vahemikus 30...65%.

Kuigi üksuse *lodu-harvik/noorendik/raiesmik* katvus on samuti väga madal (alla 10%), paigutus see klasteranalüüsis sanglepikute juurde, mis koos teiste halvemini äratuntavate üksustega kuuluvad puistutüüpi *muu lehtmets*. Põhjuseks, miks *lodu-harvik/noorendik/raiesmik* ei sattunud ühte klastrisse teiste väikse katvusega kooslustega, on asjaolu, et selle puistuvalem on teistest täiesti erinev, sisaldades 90% sangleppa. Teistes kooslustes (v.a *sinilillenoorendik/raiesmik*) on keskmiselt kõige rohkem mändi, millega koos kasvab enamasti kuusk ning soo- või arukask. Muudest puudest esineb natuke vaid halli leppa. Üksusse kuuluvatest kooslustest erinevad teistest liigirikkamad *sinilillenoorendik/raiesmiku* puistud, mille

vaatluseladel mändi ei kasva, kuid kuuske ja arukaske on samuti palju. Lisaks kasvab *sinilillenoorendik/raiesmikul* rohkelt sarapuud, vähem haaba ning mõnikord tuleb ette saart, remmelgat, pihlakat, tamme, jalakat.

Näidisalasid on üksuses *harvik/metsalage* 29.

Andmebaasis on üksus *harvik/noorendik/raiesmik* olemas kõikide metsakasvukohatüüpide kohta. Klasteranalüüsis ühe muutujana kasutatud koosluse puistute keskmine katvus pidanuks need üksused väikese katvusega kooslusi ühendava klastrina välja tooma. Praegusel juhul aga nii ei juhtunud, sest üksuse *harvik/noorendik/raiesmik* praegune määratlus on väga lai. Nimelt võib nii vanas metsas, noorendikus kui ka raiesmikul puude katvus väike olla. Samas aga võib noorendikus puistu katvus ka väga suur olla. Seetõttu kuulub neisse kooslustesse väga erineva katvusega näidisalasid.

Andmebaasis olevasse üksusse *harvik/noorendik/raiesmik* paigutatud kooslused, millesse kuuluvate kõikide vaatluste katvus on kõrge (vahemikus 50...90%, koosluste keskmised katvused vahemikus 60...90%), klasterdusid peamiselt keskmise puistu koosseisu alusel (*angervaksa-harvik/noorendik/raiesmik hall-lepikute* juurde, *siirdesoo-harvik/noorendik/raiesmik kuusikute* juurde, *maasika-harvik/noorendik/raiesmik haavikute* ning *jänese kapsa- ja naadi-harvik/noorendik/raiesmik leht-segametsade* juurde).

3.4.3.1.10. Noor kaasik ja kase-segamets söödil

Eristati klass, kuhu kuuluvad järgmised kooslused: *noor segamets leostunud või rähkse mullaga söödil*, *noor segamets leetunud ja näivleetunud mullaga söödil*, *noor segamets deluviaal- või gleimullaga söödil*, *noor kaasik leostunud või rähkse mullaga söödil*, *noor kaasik leetunud või näivleetunud mullaga söödil* ning *noor kaasik erodeeritud mullaga söödil*. Näidisalasid on loetletud kooslustes kokku 16.

Kuna loetletud kooslustes domineerib arukask (kaasikutes arukaske vähemalt 80%, segametsades 40...70%), siis klasteranalüüsi järgi nad teistest arukase ülekaaluga metsadest ei eristu. Ilmselt on lisaks puistu koosseisu sarnasusele nende eristatavus teistest kaasikutest ka kaugseire seisukohalt halb. Siiski saab välja tuua mitu põhjust, miks neid oleks mõistlik omaette üksusena käsitleda. Sellise üksuse eristamine on vajalik, kuna Otepää piirkonnas on selliseid, nn metsastuvaid sööte rohkelt. Metsade hulka pole neid loetud põhjusel, et metsale iseloomulikud ökoloogilised tingimused pole veel välja kujunenud (eelkõige mullatingimused, mis on veel tugevasti harimisest mõjutatud). Samas ei saa neid kohti ka enam põlluks nimetada, sest sinna on peale kasvanud puud, mis on kõrgemad kui 4 m ning liitusega üle 30% (nii on määratletud põhikaardi *mets*). Eelmisel põhikaardil ongi neil aladel põhjalaks *põld*, uusimal põhikaardil *mets* või *noor mets*.

Arukaskede kõrval kasvavad metsastuvatel söötidel pajuliigid, remmelgad, männid, esineb ka kuuski ja vahtraid.

3.4.3.1.11. Pajustik

Puistutüüpi *pajustik* kuuluvad järgmised kooslused: *pajustik leetunud või näivleetunud mullaga söödil*, *pajustik leostunud või rähkse mullaga söödil*, *pajustik erodeeritud mullaga söödil*, *lodupajustik* ning *määratlemata pajustik*. Erinevalt noortest kase-enamusega söödil kasvavatest metsadest (vt ptk 3.4.3.1.10), söödil kasvavaid pajustikke omaette üksusena ei

käsitletud, mille põhjuseks on eelkõige näidiste vähesus kõigis loetletud üksustes (kokku on näidisalasid siia üksusse kuuluvates kooslustes 15).

Klasteranalüüsis eristus küll klaster, kuhu kuulusid kooslused nimega *pajustik leetunud või näivleetunud mullaga söödil* ning *pajustik leostunud või rähkse mullaga söödil*. Klaster eristus seetõttu, et nimetatud kooslustesse kuuluvate vaatluskohtade puistuvalemites oli 70-100% remmelgat ning nii palju seda liiki ühegi teise andmebaasis oleva koosluse puhul pole. Samas pole pajusid näidistebaasis olevate vaatluste puhul siiani liigini määratud, vahetevahel on märgitud vaid remmelgat, täpsustamata ka selle liigi nime. Lisaks, kuna tegemist on noorte remmelgatega, näevad need kooslused aerofotol ning satelliidipildil tõenäoliselt välja samasugused nagu muude pajuliikidega kooslused.

Söödil kasvavates ning *määratlemata pajustikes* esineb pajuliikide kõrval arukaske, *lodupajustikes* halli leppa ja sookaske.

3.4.3.2. Koosluste nimedel põhinev klassifikatsioon

3.4.3.2.1. Männik

Kooslusekoodidel põhineva klassifikatsiooni *männik* hõlmab kõiki klasteranalüüsil põhineva klassifikatsiooni *männiku* üksusse kuuluvaid kooslusi; lisanduvad *pohla-männi-segametsa* (mändi 60...70%) ja *lillaka-männi-segametsa* (mändi 50...70%) kooslused. Näidisalasid on siin mõnevõrra rohkem kui klasteranalüüsi põhjal eristatud *männiku* üksuses – 74.

3.4.3.2.2. Kuusik

Kooslusekoodide põhjal loodud *kuusiku* üksusse kuuluvad samad kooslused, mis klasteranalüüsi põhjal eristatud *kuusiku* klastrisse, v.a üksus *siirdesoo-harvik/noorendik/raiesmik*. Näidisalasid kuulub siia 36.

3.4.3.2.3. Hall-lepik

Sarnaselt klasteranalüüsil eristatud *hall-lepikutele* kuuluvad antud üksusse *sinilille-, naadi-, angervaksa-* ning *lodu-hall-lepikud* (halli lepa osakaal vähemalt 80%). Väiksema kui 80% halli lepa osakaaluga kooslused on välja jäetud, mistõttu ka näidisalade arv on väiksem – 22.

3.4.3.2.4. Kaasik

Sellesse üksusse on ühendatud kõik andmebaasis olevad kaasikud ning aru- ja sookase-segametsad. Üksus hõlmab kõiki klasteranalüüsi alusel eristatud klastrisse *arukaasik* kuuluvaid koosluseid (vt ptk 3.4.3.1.4) (v.a *sinihelmika-leht-segamets*) ning klastrisse *sookasega lehtmets ja leht-segamets* kuuluvaid kaasikuid ja sookase-segametsa kooslust (vt ptk 3.4.3.1.5). Näidisalasid on neis kaasikutes kokku 78.

Sookase- ja arukase enamusega metsade käsitlemine ühes ja samas klastris on põhjendatud järgmiste asjaoludega. Esiteks pole varasemates uurimustes, mille vaatlusandmeid on

integreeritud ka praeguses uurimuses kasutatavasse andmebaasi, sookaske arukasest sageli eristatud ning teiseks põhjusel, et ka pildiandmete alusel (üldtvaates) ei pruugi need kaks puuliiki väga hästi eristuda. Vastuväitena kõnealuste puistute koos käsitlemisele võiks aga tuua eelduse, et kuna aru- ja sookaasikud kasvavad enamasti siiski suhteliselt erinevates kasvukohtades, võiks nende eristamisel kasu olla mõnest kaardi-andmekihist (näiteks põhikaardist, mullakaardist).

3.4.3.2.5. Muu lehtmets

Kattub klasteranalüüsi põhjal tehtud klassifikatsiooni üksusega *muu lehtmets*, v.a *maasika-harvik/noorendik/raiesmik* ning *lodu-harvik/noorendik/raiesmik*, mis on siit üksusest välja jäetud. Näidisalasid on siin kokku 11.

3.4.3.2.6. Leht-segamets

Klasteranalüüsi põhjal loodud klassifikatsiooni *leht-segametsa* kattub see üksus *sinilille-, jänsekapsa-, naadi-, angervaksa- ja sõnajala-leht-segametsa* osas. Lisaks kuuluvad siia kõik ülejäänud andmebaasis leht-segametsadeks nimetatud kooslused, mis klasteranalüüsil põhinevas klassifikatsioonis kuuluvad *hall-lepiku (allikasoo-leht-segamets)*, *arukaasiku (sinihelmika-leht-segamets)* ning *sookasega leht- ja leht-segametsa (madal-soo-, lodu-, siirdesoo-, mustika-kõdusoo-, jänsekapsa-kõdusoo-leht-segamets)* üksustesse; ning *naadi-lepa-segamets* (klasteranalüüsil põhinevas klassifikatsioonis hall-lepikute hulgas). Näidisalasid on neis kooslustes kokku 127.

Naadi-lepa-segametsa käsitlemist *leht-segametsa*, mitte *hall-lepiku* puistutüübis saab põhjendada järgmiselt. Kooslus eristub küll teistest segametsadest suure halli lepa lepa osakaalu poolest (kõigis vaatluskohtades halli leppa 50...70%), kuid suure halli lepa osakaaluga vaatlusi leidub hulganisti ka teiste kasvukohatüüpide leht-segametsade kooslustes, millest neid aga erinevalt *naadi* kasvukohatüübi leparohketest segametsadest omaette üksusena välja pole toodud. Seetõttu muudab *naadi-lepa-segametsade* käsitlemine hall-lepikute hulgas ülemineku hall-lepikute ja teiste rohke lepaga koosluste vahel sujuvaks ning kooslused omavahel halvasti eristatavaks. Tulevikus, kui näidiseid laekub rohkem, oleks ilmselt siiski mõttekas kõik lepa-, aga näiteks ka haava-rikkamad segapuistud omaette üksustesse eraldada, mis peaks nende üksuste äratuntavust parandama. Kase puhul on seda juba tehtud.

3.4.3.2.7. Okas-segamets

Üksus kattub klasteranalüüsi alusel loodud klassifikatsiooni *okas-segametsa* *lillaka-, mustika-, maasika-, jänsekapsa-, jänsekapsa-mustika-, angervaksa-, allikasoo-, madal-soo-, siirdesoo-, mustika-kõdusoo-, jänsekapsa-kõdusoo-okas-segametsa* ning *sinilille-kuuse-sega- ja sinilille-männi-segametsa* osas. Välja on jäetud *pohla-männi-sega- ja lillaka-männi-segamets* ning juurde võetud klasteranalüüsil põhinevas klassifikatsioonis klassi *harvik/metsalage* kuuluvad *raba-okas-sega-, madal-soo-männi-sega- ning naadi-okas-segamets*.

Näidisalasid on selles üksuses 139.

3.4.3.2.8. Harvik/metsalage

Kõikide metsakasvukohatüüpide *harvik/noorendik/raiesmiku*-kooslused (vt ka ptk 3.4.3.1.9). Näidisalasid on kokku 33.

3.4.3.2.9. Metsastuv sööt

Kattub klasteranalüüsi põhjal loodud üksusega *noor kaasik ja kase-segamets söödil*.

3.4.3.2.10. Pajustik

Kattub klasteranalüüsi põhjal loodud *pajustikuga*.

3.5. Pidevstuudiumi andmebaasid

Kõik *Pidevstuudiumi* tabelandmed peavad olema relatsioonilistes andmebaasides, mis võimaldavad päringuid SQL-keeles. Senini on kasutatud *MS Access 2000* ja *MS Access 2003* vormingus andmebaase. Tunnuste järjekord ei ole oluline üheski *Pidevstuudiumiga* seonduvas andmebaasiobjektis. Suur- ja väiketähtedel ei ole andmebaasiobjektide nimede puhul vahet.

3.5.1. Vaatlusandmete andmebaas

Vaatlusandmete andmebaas sisaldab õpetusandmete vaatlusvektoreid (tunnuste väärtusi iga vaatluse puhul) ja tabeleid, milles on vaatluste kirjeldustes kasutatud koodide (näiteks mullaliikide ja põhikaardi põhialade koodide) tähendused. Pideva muutujana prognoositava tunnuse väärtused võivad olla nii täisarvud kui ka murdarvud, bi- ja multinominaalsete tunnuste klassikoodideks võivad olla vaid täisarvud vahemikus 0...255.

Vaatlusandmete andmebaase on praegu kaks: põhikaardi põhialade ja taimkatteüksuste andmebaas ning käpaliste leiuandmete andmebaas. Vaatlusandmete tabeli struktuuris on lisaks prognoositavate tunnuste väärtustele vajalikud väljad *VID*, *alates*, *kuni* (tabel 3.5.1). *Pidevstuudium* vaatluste tabeliga otse ei suhtle, vaatlusvektoreid, vaatlusandmeid ja muid vajalikke tunnuseid loetakse siduvast päringust ning vaatluste tabeli nimi ei ole fikseeritud kuskil mujal peale päringu. Vaatluse kehtivuse alguskuupäev ja lõpukuupäev tähistavad vaatlusandmete ajalise kehtivuse piire. Näiteks raiesmiku kirjeldus ei kehti enne ja vana metsa kirjeldus pärastageraiaet.

Tabel 3.5.1. Vajalikud väljad vaatlusandmete tabelis

Välja nimi	Vorming	Kommentaar
VID	4-baidine täisarv	vaatluse tunnusnumber
alates	kuupäev, kirjutamise ja kuvamise vorm sõltub opsüsteemi suvanditest	vaatluse kehtivuse algus, väli võib ka tühi olla
kuni	kuupäev, kirjutamise ja kuvamise vorm sõltub opsüsteemi suvanditest	vaatluse kehtivuse lõpp, väli võib ka tühi olla
<seletava tunnuse nr>	bait	

3.5.2. Andmekihtide andmebaas

Andmekihtide andmebaasis on tabelid *Akihid*, *INDEKSID*, *PK20t*, nominaalsete tunnuste klasside koodide tähenduste tabelid ja klasside omavahelise sarnasuse tabelid. Nominaalsete koodide omasarnasustabelid koosnevad sarnasushinnangutest täisarvulistest protsentides väljal *s*. Klassikoodid on omasarnasustabelite väljadel 1 ja 2. Ühe või teise tunnuse puhul kasutatavad omasarnasustabelid registreeritakse tehisõppe või seletavate tunnuste andmebaasi tabelis *OMASARNASUSTABELID*. Viimane paikneb nimetatud andmebaasides, kuna omasarnasustabeli kasutus ei ole andmekihi, vaid tunnuse atribuut. Andmekihtide andmebaasi tabelite kohustuslikud väljad ja nende vormingud on alljärgnevad (tabelid 3.5.2...3.5.4).

Tabel 3.5.2. Vajalikud väljad tabelis *Akihiid*

Välja nimi	Vorming	Kommentaar
KID	bait	kihi tunnusnumber
pkylg	4-baidine murdarv	piksli küljepikkus meetrites
kataloog	tekst	andmekihi failide kataloog
nominal	jah/ei	= jah, kui kihti tuleb töödelda nominaalse tunnusena
eira	bait	andmete puudumist tähistav väärtus, mis võrdsustatakse kaardivälise alaga
alates	kuupäev, kirjutamise ja kuvamise vorm sõltub op-süsteemi suvanditest	andmekihi kasutatavuse algus
kuni	kuupäev, kirjutamise ja kuvamise vorm sõltub op-süsteemi suvanditest	andmekihi kasutatavuse lõpp
baite	bait	= 1 Idrisi32 byte vormingu ja = 2 Idrisi32 integer vormingu puhul. Nominaalne andmekiht võib olla vaid ühebaidine.

Tabel 3.5.3. Vajalikud väljad tabelis *INDEKSID*

Välja nimi	Vorming	Kommentaar
IndeksID	bait	indeksi tunnusnumber
nimi	tekst	indeksi nimi
nomkiht	jah/ei	= jah, kui indeks arvutatakse nominaalsest andmekihist
nomind	jah/ei	= jah, kui indeksi väärtust tuleb kasutada nominaalse tunnusena

Tabel 3.5.4. Vajalikud väljad tabelis *PK20t*

Välja nimi	Vorming	Kommentaar
NR	4-baidine täisarv	Eesti Põhikaardi 10 × 10 km kaardilehe number
min-x	8-baidine murdarv	kaardilehe lääneserva x-koordinaat L-EST 92 süsteemis
min-y	8-baidine murdarv	kaardilehe lõunaserva y-koordinaat L-EST 92 süsteemis
<andmekihi nr>	jah/ei	= jah, kui andmekihtide hoidlas on andmekihi fail selle kaardilehe kohta olemas

Andmekihtide hoidla täienemist saab tabelisse *PK20t* üle kanda *Accessi* programmimooduliga *Kaardilehtede_andmed* (lisa 4). See programminaga eemaldab andmekihtide kataloogides olevate *rst*- ja *rdc*-laiendiga failidelt neljale esimesele täheruumile järgneva nime osa. Eeldatakse, et neli esimest täheruumi on 100 km² kaardilehe number.

Seni *Pidevstuudiumi* jaoks ette valmistatud andmekihtide loetelu, iseloomustus ja ettevalmistamise kirjeldus on esitatud peatükis 3.2, *Pidevstuudiumis* kasutatavate indeksite loetelu ja kirjeldus on peatükis 3.6.1.1.

3.5.3. Tehisõppe andmebaas

Tehisõppe andmebaas on keskne üksus, mis sisaldab alltoodud andmebaasiobjekte või otseteed ehk linki nende objektide juurde. Tehisõppe andmebaasi nimi ei ole fikseeritud, see sisestatakse koos kataloogi, milles andmebaas asub, nimega *Pidevstuudiumi* algmenüü andmebaasi nime lahtrisse. Alltoodud andmebaasiobjektide nimedest on *Pidevstuudiumi* jaoks fikseeritud järgmised: **AKIHID**, **ATUNNUSED**, **FTUNNUSED**, **INDEKSID**, **logitabelid** ja **OMASARNASUSTABELID**. Ülejäänud tabelite nimed on muudetavad ja esitatakse siinkohal vaid kui näited senikasutatud nimedest.

AKIHID — andmekihtide tabel (struktuuri kirjeldus on eelmises peatükis).

FTUNNUSED — prognoositavate tunnuste tabel.

ATUNNUSED — seletavate tunnuste tabel.

INDEKSID — andmekihtidest arvutatavate tunnuste (indeksite) tabel (struktuuri kirjeldus on eelmises peatükis).

STUNNUSED — seletavate tunnuste väärtused õpetuskohtades.

LOGI_F1, *LOGI_F2* jt logitabelid — tabelid, millesse salvestatakse iga õppevooru tulemusena leitud tunnusekaalud, otsitava sarnasuse hulga optimeeritud väärtus, jäta-üks-välja ristkontrolli vastavus nii valimis kui ka kõigi vaatlustega.

TULEMUSED — seni parimate komplektide näidiste kaalud ja aktuaalsused ning õpetusandmetele teiste õpetusandmete järgi prognoositud väärtused.

Vaatlusvektorite tabelid või päringud, millele viidatakse tabeli *FTUNNUSED* väljal *andmepäring*.

OMASARNASUSTABELID — tabel, milles on loetletud nominaalsete argumenttunnuste koodide vahelisi sarnasusi kirjeldavad tabelid. Selles on väljad *AID* — argumenttunnuse tunnusnumber, *sarnasustabel* — andmebaasiobjekti nimi, mis sisaldab nominaalse tunnuse kategooriate omavahelisi sarnasusi. Selles tabelis loetletud omasarnasustabelite struktuur on esitatud andmekihtide andmebaasi peatükis (ptk 3.5.2)

3.5.3.1. Funktsioontunnused

Kasutatavate funktsioontunnuste loetelu ja parameetrid peavad olema tabelis *FTUNNUSED* kindlal etteantud kujul (tabel 3.5.5). Tabeli *FTUNNUSED* kaudu toimub ka õppeprotsessi juhtimine, sest tehisõppe programm loeb sellest tehisõppe iga iteratsiooni lähteülesandeid.

Tabel 3.5.5. Vajalikud väljad tabelis *FTUNNUSED*. Selgitused on tabelile järgnevas tekstis


Välja nimi	Vorming	Kommentaar
arvutada	jah/ei	esmane väli, mille kaudu suunatakse Pidevstuudiumi
FID	bait	prognoositava tunnuse tunnusnumber
antudkood	bait	klassikood multinominaalse tunnuse klasside ükshaaval käsitlemisel
LogID	4-baidine täisarv	seni parima tunnuste ja näidiste komplekti tunnusnumber logitabelis
eelklass	bait	eelklassifikaatorina kasutatava tunnuse number
nimi	tekst	prognoositava tunnuse nimi
ftyyp	bait	prognoositava tunnuse tüüp
osatunnuseid	bait	mitmemõõtmelise hinnatava tunnuse osatunnuste arv
sumsimmax	4-baidine murdarv	otsitava kogusarnasuse algväärtus (vajalik vaid tehisõppes)
andmepäring	tekst	andmebaasi objekt (tabel või päring) millest loetakse õpetusandmed või näidised (prognoosiülesande puhul)
vmaht	4-baidine täisarv	õpetusvaatluste ligikaudne arv vaatluste juhuvalimis (vajalik vaid tehisõppes)
tmaht	4-baidine täisarv	tunnuste piirarv tunnuste juhuvalimis (vajalik vaid tehisõppes)
nullkaugus	4-baidine murdarv	sarnasuse nullkaugus (vajalik vaid tehisõppes)

Antudkoodi ja *FID* kombinatsioon peab olema unikaalne ridade hulgas, kus *arvutada* = jah. Tühi eelklassi lahter ja väärtus 255 tähistavad eelklassifikaatorita arvutusi. Prognoositava tunnuse tüüpide (väli *ftyyp*) tähistus: 0 — multinominaalne tunnus, 1 — mitmemõõtmeline tunnus, 2 — pidev tunnus, 3 — binominaalne tunnus, 4 — multinominaalse tunnuse antud klass, mida vastandatakse kõigile ülejäänud klassidele. Mitmemõõtmeline tunnus on näiteks puistuvalem, milles osatunnusteks on üksikute puuliikide osakaalud. Mitmemõõtmelise tunnuse hindamise funktsionaalsus on 2006. a märtsi seisuga programmist *MLNN* programmi *Pidevstuudium* üle toomata. Kui funktsioontunnuse tüüp = 4, siis peab tabelis *FTUNNUSED* olema iga uuritava klassi kohta eraldi rida.

Otsitav kogusarnasus on prognoositava vaatluse ja näidiste vahelise summaarse sarnasuse väärtus, mille järel lõpetatakse sarnasuselt järgmiste näidiste otsimine. Mingile vaatlusele prognoosi arvutamisel otsitakse sellele kõige sarnasemaid näidiseid. Alustatakse kõige sarnasemast ja kui sellest ei piisa, siis lisatakse sarnasuselt järgmine jne. Sarnasuse taset

alandatakse 1% haaval. Otsitava kogusarnasuse väärtus määrab, millal näidiste otsimine lõpetada. Kui välja valitud kõige sarnasemate näidiste summaarne sarnasus on suurem või võrdne kui otsitav kogusarnasus, siis näidiste lisamine prognoosi aluseks olevasse komplekti lõpetatakse ja hakatakse hinnangut arvutama. Otsitava kogusarnasuse optimaalne suurus sõltub andmetest, optimaalse väärtuse otsimise algväärtuse määrab kasutaja. Otsitava kogusarnasuse väiksema väärtuse puhul on prognoosiv süsteem tundlikum, suurema väärtuse juures üldistavam. Seniste kogemuste kohaselt on enamiku andmestike puhul sobivaim otsitava kogusarnasuse algväärtus vahemikus 2...3.

Sarnasuse nullkaugus reguleerib, mil määral saavad üksteisest mingil kaugusel paiknevad vaatlused üksteise prognoosimisel näidiseks olla. Enamiku prognoositavate nähtuste ruumilise autokorrelatsiooni tõttu on lähestikku tehtud vaatlused sarnased. Näiteks on 30 m raadiuses arvutatud pildimustriindeksid kahes üksteisest 5 m kaugusel paiknevas vaatluskohas peaaegu identsed. Kui õpetustäpsuse hindamisel kasutatakse lähestikuseid õpetusvaatlusi, siis võidakse saada petlikult kõrged hinnangu tõesuse näitajad, sest lähestikku paiknevad vaatlused prognoosivad üksteist vastastikku väga edukalt. Kaugemate vaatluste hindamisel ei pruugi leitud näidised ja tunnused sugugi nii usaldusväärseid hinnanguid anda. Seetõttu vähendatakse *Pidevstuudiumi* tehisõppe osas vaatlustevahelist sarnasust proportsionaalselt vaatlustevahelise vahemaa pöördväärtusega. Sarnasuse nullkaugus reguleerib kauguskorrektuuri vahemaast sõltuvat muutumist. Kui vaatluste vahemaa ei ületa nullkaugust, siis nendevaheline sarnasus nullitakse, kui vaatluste vahemaa võrdub kahekordse nullkaugusega, siis vähendatakse sarnasust 50% võrra. Tänu nullkauguse kasutamisele eelistab *Pidevstuudium* sellist näidiste komplekti, milles näidised ei paikne lähestikku (joonis 3.5.1). Selle uurimuse raames kasutati vaid nullkaugust 100 m. See tähendab, et kui kahe õpetusandmetes oleva vaatluskoha sarnasus kaardi- ja kaugseireandmete järgi on 90%, siis nende vaatluskohtade 100 m vahemaa puhul korrigeeritakse sarnasus nulliks, 200 m vahemaa puhul 40%ks, 500 m vahemaa puhul 70%ks, 1000 m vahemaa puhul 80%ks.



Joonis 3.5.1. Soo-neiuvaiba (*Epipactis palustris*) leiukohad (sinised), õpetusandmetena kasutatud kohad (ruuged) ja näidisteks valitud kohad (punased) Otepää looduspargi Kortina sihtkaitsevööndi piirkonnas.

3.5.3.2. Argumenttunnused


Argumenttunnuste loetelu ja parameetrid peavad olema *Pidevstuumiumi* andmebaasi tabelis *ATUNNUSED* kindlal kujul (tabel 3.5.6).

Tabel 3.5.6. Vajalikud väljad tabelis *ATUNNUSED*. Osa selgitusi on tabelile järgnevas tekstis

Välja nimi	Vorming	Kommentaar
AID	bait	tunnuse number
nimi	tekst	tunnuse nimi
KID	bait	kasutatava andmekihi tunnusnumber tabelis Akihid
indeksID	bait	arvutatava indeksi tunnusnumber tabelis INDEKSID
radius	4-baidine murdarv	tunnuse arvutamise raadius meetrites õpetuskohtade arvutamisel (vajalik vaid indeksite arvutamisel)
radius_k	4-baidine murdarv	tunnuse arvutamise raadius meetrites binaarkaardi arvutamisel (vajalik vaid kaartide genereerimisel)
valim	4-baidine murdarv	pikslite juhuvalimi maht vahemikus 0...1 tunnuse arvutamisel (tehisõppes ei ole vajalik)
blokkvalim	jah/ei	blokkvalimi kasutus (tehisõppes ei ole vajalik)
antudkood	bait	piksliväärtus, millest kaugust või mille sagedust arvutatakse (väärtus on vajalik vaid kaugust või sagedust arvutavate indeksite korral)
eelklassikasutus	jah/ei	kas arvutada tunnuse indeksid vaid eelklassi piires (vajalik vaid prognoosikaartide arvutamisel ja indeksite arvutamisel binaarfaili)
eelklassikiht	bait	kaartidel eelklassifikaatorina kasutatav andmekiht tabelis Akihid (vajalik vaid kaartide arvutamisel)
eraldistekasutus	jah/ei	kas arvutada õpetusandmete indeksid vaid eraldiste piires (vajalik vaid õpetusvaatluste seletavate tunnuste arvutamisel)
eraldistekiht	bait	õpetusandmete ruumiliste piiride kiht
BV_kataloog	tekst	binaarväljundi salvestamise kataloog (vajalik vaid indeksite arvutamisel binaarfaili)
asendab	bait	asendustunnuste puhul on sellel väljal asendatava tunnuse number. Kui tunnus ei ole asendustunnus, siis peab väli olema tühi või = 0.
F1	jah/ei	argumenttunnuse kasutamine funktsioontunnuse FID = 1 arvutamisel ja tehisõppel. Kasutatakse juhul, kui ftyyp ≠ 4.
AF1	bait	argumenttunnuse aktuaalsus vahemikus 1...250 funktsioontunnuse FID = 1 tehisõppel. Kasutatakse juhul, kui ftyyp ≠ 4.
F1_66	jah/ei	kas kasutada argumenttunnust funktsioontunnuse FID = 1, antudkood = 66 tehisõppel. Kasutatakse juhul, kui ftyyp = 4.
AF1_66	bait	argumenttunnuse aktuaalsus vahemikus 1...250 funktsioontunnuse FID = 1, antudkood = 66 tehisõppel. Kasutatakse juhul, kui ftyyp = 4.

Pidevstuudium arvutab mustriindekseid vaid ümarast kernelist.

Blokkvalim võimaldab kasutada rohkem külgnevaid piksleid kui lihtne juhuvalim. Blokkvalimi puhul valitakse 3×3 piksli suurusi ruute (joonis 3.5.2). Blokkvaliku puhul määratakse piksliruutude vahemaa nii, et kasutaja määratud valimisse sattuvate pikslite osa oleks võimalikult täpselt järgitud. Blokkvalim on vajalik külgnevaid piksleid võrdlevate tunnuste puhul, kui juhuvalimi maht on väike.



Joonis 3.5.2. Blokkvalim rasterfailist valimi osaga 9/49 (mustad ja viirutatud ruudud), ringikujuline kernel raadiusega 7 pikslit ja kernelis olevad valimi ruudud (mustad).

Õpetusandmete ruumiliste piiride kiht on seni olnud taimkatte ja põhikaardi üksustel vaatlusalade eraldiste kiht ning käpaliste leiukohtadel põhikaardi põhialad.

Binaarväljund arvutatakse kõigist *rst*-laiendiga failidest, mis on valitud tunnuse andmekihis.

F-väli kujul *F*<*FID*> (näiteks *F2*) või *F*<*FID*>_<*antudkood*> (näiteks *F2_12*) peab olema igal tehisõppes või seletavate tunnuste arvutamisel kasutataval real tabelis *ATUNNUSED*, väli *AF* kujul *AF*<*FID*> (näiteks *AF2*) või *AF*<*FID*>_<*antudkood*> (näiteks *AF2_12*) igal tehisõppes kasutataval real.

Tunnuste asendamist kasutatakse vaid kaardi genereerimisel, mitte tehisõppes. Asendustunnused peaksid olema *F*-väljadelt alati välja lülitatud. Asendustunnus peab kindlasti olema suurema tunnusunumbriga kui asendatav tunnus. Seni andmekihtidest arvutatud põhitudunnuste loetelu on tabelis 3.2.3 (ptk 3.2.7).

Tunnuste kaale ja aktuaalsusi salvestab *Pidevstuudium*.

3.5.3.3. Vaatlusvektorid

Andmeliiasuse vältimiseks ja väljade nimede sobitamiseks on vaatlusvektorid soovitatav moodustada päringutena, mis loevad andmeid tabelitest *TULEMUSED*, *STUNNUSED* ja tabelist, kus on vaatlusandmed. Kui algsel kujul õpetusandmed asuvad tabelis, mis sisaldab rohkem kui ühte prognoositavat tunnust, siis tuleb iga prognoositava tunnuse nimi andmeid tarkvarale edastavas päringus ümber defineerida nii, et iga prognoositava tunnuse kohta oleks funktsioontunnuse väärtuste väli *F* ning õppetulemuste salvestamiseks väljad *progn*, *prob*, *aktuaalsus*, *w* (tabel 3.5.7).

Vaatlustele prognoositud väärtusi, vaatluste kaale ja aktuaalsusi salvestab *Pidevstuudium*. Puuduvat seletava tunnuse väärtust ja määramatust tähistab vaatlusvektoris kas tühi lahter või väärtus 255.

Multinominaalse tunnuse klasside ükshaaval hindamisel (ftyyp = 4) kasutatakse kõigi klasside puhul sama vaatlusvektorit. Seega vastavad vaatlusvektorid *FID*-koodidele, mitte tabeli *FTUNNUSED* ridadele.

Andmekihi ajapiirangu väli ei tohi, kuid vaatluste ajapiirangute väljad võivad tühjad olla. Tehisõppes ja prognoosis kasutatakse vaid neid tunnuse ja vaatluse kombinatsioone, mille puhul tunnuse kasutatavuse ja vaatluse kasutatavuse ajavahemik on vähemalt osaliselt ülekattes. Näiteks ei kasuta *Pidevstuudium* raiesmikuvaatluse puhul kaugseire andmekihi, mille kehtivus lõpeb enne vaatluse juurde märgitud (arvatavat) lageraie aega. Samas on mullatunnuste kehtivuse ajaline piirang kauges minevikus või tulevikus ja need on kõigi vaatluste puhul kasutatavad. Kui vaatluse ajapiirangu väli on tühi, siis selle vaatluse kasutamist ajaliselt ei piirata.

Tabel 3.5.7. Vajalikud väljad vaatlusvektorites

Välja nimi	Vorming	Kommentaar
VID	8-baidine täisarv	vaatluse tunnusnumber
F	4-baidine murdarv ftyyp = 2 korral, jah/ei ftyyp = 3 korral, bait muudel juhtudel	funktsioontunnuse väärtus
progn	sama, mis väljal F	ülejäänud õpetusandmete järgi prognoositud väärtus (vajalik vaid tehisõppel ja tabelisse prognoosimisel)
prob	bait	sarnasus ülejäänud õpetusandmete hulgast valitud näidistega vahemikus 0...100 (vajalik vaid tehisõppel ja tabelisse prognoosimisel)
aktuaalsus	bait	vaatluse aktuaalsus (vajalik vaid tehisõppel)
w	4-baidine murdarv	vaatluse kaal näidisena
x	8-baidine murdarv	vaatluskoha L-EST süsteemi x-koordinaat meetrites
y	8-baidine murdarv	vaatluskoha L-EST süsteemi y-koordinaat meetrites
alates	kuupäev, kirjutamise ja kuvamise vorm sõltub op-süsteemi suvanditest	vaatluse kasutatavuse algus
kuni	kuupäev, kirjutamise ja kuvamise vorm sõltub op-süsteemi suvanditest	vaatluse kasutatavuse lõpp
<seletava tunnuse nr>	bait	seletavate tunnuste väärtused

3.5.3.4. Logitabelid

Logitabelitesse salvestatakse tehisõppe vahetulemused. Logitabeli nimi peab algama tähe-kombinatsiooniga *LOGI_F*, millele järgneb funktsioontunnuse number (näiteks *LOGI_F18*). Iga funktsioontunnuse jaoks peab olema omaette logitabel. Multinominaalse tunnuse klasside ükshaaval hindamisel (ftyyp = 4) salvestatakse iga klassi õppe tulemused samasse logifaili. Seega vastavad logifailid *FID*-koodidele, mitte tabeli *FTUNNUSED* ridadele. Logitabelite kohustuslikud väljad ja nende vormingud on tabelis 3.5.8.

Tabel 3.5.8. Vajalikud väljad logitabelites

Välja nimi	Vorming	Kommentaar
ID	8-baidine täisarv	kirje tunnusnumber
antudkood	bait	klassikood multinominaalse tunnuse klasside ükshaaval käsitlemisel
kuupäev	kuupäev	tulemuse salvestamise aeg
tvastavus	4-baidine murdarv	õpetusvaatluste valimis saavutatud hinnangute vastavus
kvastavus	4-baidine murdarv	hinnangute vastavus kõigi õpetusandmete suhtes
sumsimmax	4-baidine murdarv	tehisõppes optimeeritud otsitav kogusarnasus
etn	4-baidine täisarv	näidiseks valitud vaatluste arv
valim	4-baidine täisarv	valimi maht
<seletava tunnuse nr>	4-baidine murdarv	seletavate tunnuste tehisõppel leitud kaalud

Logitabel ei tohi täiesti tühi olla. Logitabeli esmasel kasutamisel võib sinna lisada ühe rea, millel *ID* = 0. Argumenttunnuste väljade nimeks on tunnuse number. Asendustunnuste numbreid ei pea logifailis olema juhul, kui ühegi kasutatava põhitunnuse number ei ole asendustunnuse numbrist suurem. Kasutatavate tunnuste väljad ei tohi logifailis tühjad olla. Kui tunnust ei kasutata, olgu väljal 0. Tunnused, mille kasutamine on tabelis *ATUNNUSED* välja lülitatud, võivad logitabelist puududa.

3.5.3.5. Seletavate tunnuste tabel

Vaatluskohti kirjeldavad pildi- ja kaarditunnused tuleb välja arvutada enne tehisõpet ja näidiste prognoosides kasutamist. Seletavate tunnuste väärtusi võib hoida vaatlusandmetega ühes tabelis või eraldi tabelis. Seni kasutatud andmebaasisüsteemis on välivaatluste andmebaas omaette fail ja seletavaid tunnuseid seal ei hoita. Seletavate tunnuste väärtusi hoitakse praegustes tehisõppe andmebaasides tabelis *STUNNUSED*. Vajalikud väljad selles on vaatluse tunnusnumbrit sisaldav *VID* (vorminguks 8-baidine täisarv) ja väljad seletavate tunnuste tunnusnumbritega (vorminguks bait). Kuna *Pidevstuumdium* suhtleb tabeliga vaatlusvektori päringu kaudu, siis on oluline, et päringu vorm vastaks programmi nõuetele; seletavate tunnuste tabeli nimi ja vorm ei ole rangelt fikseeritud.

3.5.3.6. Tulemuste tabel

Praegu kasutuses olevas andmebaasisüsteemis loevad funktsioontunnuste vaatlusvektorite päringud tulemuste salvestamise välju tabelist *TULEMUSED*. Lisaks vaatluse identifikaatori väljale nimega *VID* on selles iga omaette *FID*-koodiga funktsioontunnuse jaoks väljad, et salvestada: 1) iga kasutatud vaatluse prognoositud väärtus, 2) sarnasus prognoosis kasutatud näidistega, 3) vaatluse aktuaalsus ning 4) vaatluse kaal näidisena. Sarnasuse väljale salvestatakse kaheväärtuselise funktsioontunnuse puhul keskmine sarnasus hinnangu andmisel kasutatud suurema koodiga (esinemiskohtade) näidistega. Multinominaalse tunnuse klasside ükshaaval tehisoõppel salvestatakse sarnasuse väljale keskmine sarnasus parajasti õpitava klassi näidistega. Multinominaalse tunnuse klasside korraka õppes ning pideva tunnuse õppes salvestatakse keskmine sarnasus hinnangu andmisel kasutatud näidistega. Kuna *Pidevstuudium* suhtleb tabeliga vaatlusvektori päringu kaudu, siis on oluline, et päringu vorm vastaks programmi nõuetele; tulemuste tabeli nimi ja vorm ei ole rangelt fikseeritud.

3.6. Kaartide genereerimise metoodika ja tarkvara

Metsade prognoosikaartide tegemisel kasutati kolme erinevat metoodikat:

- 1) metsakasvukohatüüpide, tüübirühmade, puistutüüpide, metsatüüpide, metsa kasvukoha troofsuse ja niiskuse tehisõpe ning prognoos,
- 2) kasvukohatüüpidest tuletatud tüübirühmad,
- 3) metsa kasvukoha troofsuse ja niiskuse järgi prognoositud tüübirühmad.

Tunnuste ja näidiste tehisõppel ning vaatlusandmetest ja andmekihtidest kaardi genereerimisel kasutati tarkvara *Pidevstuudium*, kaardi kujundamisel ja vajalikku vormi viimisel muud tarkvara (ptk 3.6.2).


3.6.1. Tarkvara Pidevstuudium

3.6.1.1. Tehnilised eeldused

Pidevstuudium on MS Windows keskkonnas töötav rakendusprogramm, mis ei nõua kasutamiseelset installeerimist. Varasemate Windowsi versioonide puhul tuleb enne *Pidevstuudiumi* käivitamist installeerida MS Windows .NET. Programmi käivitumiseks peavad ühes kataloogis olema failid *^PIDEVSTUUDIUM-2006.exe*, *^PIDEVSTUUDIUM-2006.exe.config* ja *PK20t.txt*. Exe-faili saab käivitada ka otsetee (*shortcut*) abil.

3.6.1.2. Algmenüü

Programmi *Pidevstuudium* käivitamisel avaneva algmenüü päises on programmi versiooni kuupäev. Värvidega on tähistatud neli osa: roheline — uued andmed (tunnuste väärtuste arvutamine vaatlustele või binaar-rastrisse), kollane — õppimine (tunnustele ja vaatlustele optimaalseimate kaalude otsimine), roosa — teadmiste kontroll (hinnangute ja vaatluste vastavuse kontrollarvutus), sinine — teadmiste rakendus (hinnangute arvutamine andmebaasi tabelitesse või binaar-rastritesse (joonis 3.6.1).



Joonis 3.6.1. Programmi *Pidevstuudium* algmenüü.

3.6.1.3. Ruumimustrit kirjeldavate tunnuste arvutamine

See osa algmenüüst on rohelise taustaga. Kui sisse on lülitatud kaardi- või pildimustri indeksite arvutamine vaatlustetabelisse, siis loetakse vaatlustetabeli või -päringu nimi kasutatava andmebaasi tabelist *FTUNNUSED*. Kui indeksid väljastatakse prognoosi- või sarnasuste tabelisse, siis peab väljundtabeli või -päringu nimi olema kirjas algmenüü sinises osas olevas tekstisestuslahtris.

Kui indeksite väljastamine tellitakse binaarfaili, siis loeb *Pidevstuudium* tulemuste väljastamise kataloogi kasutatava andmebaasi tabeli *ATUNNUSED* väljalt *BV_kataloog*. Indeksite arvutamisel binaarfailidesse arvutab *Pidevstuudium* indeksid failidesse kõigist väljal *arvutada* tabelis *FTUNNUSED* valitud funktsioontunnustele vastavatel väljadel *F<FID>* tabelis *ATUNNUSED* valitud indeksite andmekihtide kataloogides olevatest *rst*-failidest. Kui soovitakse arvutada indeksid vaid andmekihi mõnest failist, tuleks teisendatavad failid tõsta omaette kataloogi ja kas defineerida uus andmekiht teisendatavate failide kataloogi nimega või muuta ajutiselt teisendatavate failide andmekihi kataloogi nime.

Enne indeksite arvutamist tabelkujul andmetele peab andmebaasis olema igal arvutataval vaatlusel järjekorranumber ning x- ja y-koordinaat LAMBERT-EST97 süsteemis meetrites. x tähistab siinkohal lääne-ida suunda, y — lõuna-põhja suunda.

3.6.1.3.1. Indeksi arvutamise parameetrid

Indeksite arvutamiseks peab kasutaja määrama indeksi, andmekihi, millest indeks arvutatakse, raadiuse, mille ulatuses piksleid kasutatakse, valimi osa (arvestades seejuures, et vaatluspaare eeldavate geostatistiliste indeksite puhul suureneb arvutusteks kuluv aeg pikslite arvu suurenedes järsult), blokkvalimi kasutuse (vajalik külgnevaid piksleid kasutavate indeksite ja pikslite valimi kasutamise puhul), etteantud koodi, ruumilise eelklassifikaatori ehk eraldiste kasutuse ja eraldistekihi. Loetletud indeksite parameetrid tuleb kanda *Pidevstuudiumiga* seotud andmebaasi peatükis *Pidevstuudiumi* andmebaasid (ptk 3.5) kirjeldatud väljadele samas peatükis esitatud vormis. Indeksid arvutatakse nendele vaatlustele, mida vaatluse kohas eelklassi järgi ei eirata.

3.6.1.3.2. Eelklassifikaator ja eraldised

Pidevstuudium võimaldab kasutada kolme liiki eelklassifikaatoreid: 1) funktsioontunnuse eelklassifikaator, mis määrab, millisesse eelklassi kuuluvaid näidiseid ühe või teise koha puhul kasutada, 2) kaardi- ja pildimustri indeksite arvutamist ruumiliselt piiravad eraldised, 3) interpoleerimiseraldised, mis piiravad kaartide genereerimisel tulemuste interpoleerimist arvutatud pikslite vahele. Esimene ja viimane määravad ka kaardi arvutatava osa.

Funktsioontunnuse eelklassifikaatori kasutamisel otsitakse iga vaatluse puhul sarnaseimaid näidiseid vaid samasse eelklassi kuuluvate näidiste hulgast. Funktsioontunnuse eelklassifikaatorit saab kasutada tehisõppes ja hinnangute arvutamisel. Funktsioontunnuse eelklassifikaator on üks argumenttunnustest, mille number on tabelis *FTUNNUSED*, eelklassifikaatorit ei pea muul moel teistest tunnustest eristama.

Kaardi- või pildimustri indeksite arvutamisel kasutatavad eraldised on määratletud andmekihiga, mille number on tabelis *ATUNNUSED*. Eraldistekihti tunnuseks ei teisendata. Eraldiste kasutamisel arvutatakse mustriindeksid vaid pikslitest, mis on eraldistekihi sama numbriga ning indeksi arvutamise raadiuse ulatuses. Mustriindekseid ei pea õpetusandmetele ja

hinnanguliste kaartide genereerimisel tingimata sama raadiuse ja sama eraldistekihiga arvutama. Näiteks arvutati Otepää looduspargi taimkatte kaardistamise projekti jaoks kirjeldatud kohtade pildimustri indeksid iga kirjelduse puhul selle kehtivuse ulatust tähistava eraldise piires, kaardi genereerimisel kasutati eraldistekihina aga uusima põhikaardi põhialasid.

3.6.1.3.3. *Pildi- või kaardimustrit kirjeldavad indeksid Pidevstuudiumis*

Pidevstuudium suudab seisuga veebruar 2006 arvutada 30 erinevat indeksit (tabel 7.1). Kõik indeksid arvutatakse ümarast kernelist, mille raadius meetrites loetakse tabelist *ATUNNUSED*. Indeksid kaugus etteantud klassist ja kaugus klassipiirist väljastatakse arvutuse aluseks oleva andmekihi pikslites. Indeksite loetelu ja arvutamise viis on alljärgnev.

Antud klassi sagedus — kasutaja poolt valitud koodi protsentuaalne osa kernelis.

Mood — kõige sagedasem piksliklass kernelis.

Shannoni mitmekesisus — klasside mitmekesisus valemi $H = -10 \cdot \sum p_i \log_2 p_i$ järgi, kus p_i — klassi i osakaal kernelis.

Lloydi ühetaolisus — arvutatud: $10 \cdot H / \lg(s)$, kus H — Shannoni mitmekesisus, s — klasside arv kernelis.

Dominants — arvutatud: $100 \cdot \sum p_i^2$.

Klasside arv — erinevate klasside arv kernelis.

Klassikülgnnevuste osa — sama klassi pikslite külgnnevuste protsent kõigist pikslikülgnnevustest. Võrdub 100%, kui kõik pikslid kernelis kuuluvad samasse klassi.

Laikude suund — 0 tähistab vertikaalseid ühe piksli laiuseid ribasid, 90 tähistab horisontaalseid ühe piksli laiuseid ribasid. Laigupiiride puudumisel kirjutatakse faili kood 255.

Klassivastavuste lähedus — sama klassi pikslite keskohtade vahemaade pöördväärtuste summa suhe kõigi pikslipaaride vahemaade pöördväärtuste summasse protsentides.

Erinevat klassi vaatluspaaride osa — erinevat klassi pikslipaaride osa protsentides kõigi kernelis olevate pikslite kõigi paaride suhtes.

Kaugusega kaalutud mood — kauguse pöördväärtusega kaalutud mood. See piksliväärtus, mille puhul seda klassi pikslite kerneli keskmest kauguste pöördväärtuste summa on suurim. Kerneli keskmis olev piksel arvesse ei lähe.

Klassipiiri kaugus — lähima klassipiiri kaugus kerneli keskmest sisendfaili pikslites.

Kaugus etteantud klassi piirist — lähima etteantud klassi kuuluva piksli kaugus kerneli keskmest sisendfaili pikslites.

Üle keskmise väärtuste osa — üle keskmise väärtusega pikslite osakaal protsentides. Näitab piksliväärtuste jaotuse asümmeetriat.

Keskmine — aritmeetiline keskmine kernelis või valimis olevatest piksliväärtustest.

Standardhälve — ruutjuur piksliväärtuste dispersioonist lokaalse keskmise suhtes.

Mediaan — piksliväärtus, millest mõlemal pool on võrdne arv pikseleid.

Morani I 8st naaberpikslid — 8 naaberpiksli Morani I väljendatuna protsentides. 0 tähistab maksimaalset võimalikku negatiivset ruumilist autokorrelatsiooni, 100 tähendab ruumilise autokorrelatsiooni puudumist ja 200 — maksimaalset võimalikku positiivset ruumilist autokorrelatsiooni (sarnased piksliväärtused külgnnevad).

Kaugusega kaalutud Morani I — kauguse pöördväärtustega kaalutud Morani I . Skaala sama, mis eelmisel statistikul.

Naaberpikslite erinevus — keskmine erinevus esimese astme naaberpikslite vahel.

Variatsioonikoefitsient — standardhälbe ja keskmise suhe protsentides.

Gradiendi suund — lineaarse trendpinna kalde suund kernelis. 255 tähistab gradiendi puudumist, 50 tähistab suurenevaid väärtusi y-telje suunas, 150 — kahanevaid väärtusi y-telje suunas, 100 — suurenevaid väärtusi x-telje suunas, 0 ja 200 — kahanevaid väärtusi x-telje suunas.

Serva ja keskosa erinevus — poolraadiuse sees olevate pikslite keskvaartuse ja poolraadiuse ja täisraadiuse vahel olevate pikslite keskvaartuse vahe. Salvestamisel liidetakse erinevusele konstant 100 ja väärtused alla 0 ja üle 255 kärbitakse mainitud piirväärtusteks. Seega on indeks vahemikus 0...255 ning väärtus 100 tähistab keskkoha ja serva erinevuse puudumist.

Miimum — väikseim väärtus etteantud raadiuses ja valimis.

Maksimum — suurim väärtus etteantud raadiuses ja valimis.

Ekstsessitegur — järgmise valemi järgi: $E = 10 \cdot \left(\frac{1}{n} \sum \left(\frac{x_i - \bar{x}}{\sigma} \right)^4 - 1 \right)$, kus x_i – piksli väärtus,

$\bar{x}$ – piksliväärtuste keskmine, n – pikslite arv kernelis ja σ – piksliväärtuste standardhälve. Annab suuremad väärtused erineva heledusega alade kokkupuutekohtadesse.

Üleminekute sujuvus — naabruse homogeensus järgmise valemi järgi:

$$S = 100 \cdot \frac{\sum_i \sum_j \frac{1}{1 + (x_i - x_j)^2}}{n}$$
, kus x_i ja x_j – nii horisontaal-, vertikaal- kui ka diagonaalsuunas külgnevate pikslite väärtused ja n – pikslite arv kernelis.

Erinevus keskmisest — kerneli keskmis oleva piksli väärtuse ja kõigi kernelis olevate pikslite väärtuste aritmeetilise keskmise erinevus.

Gradiendi tugevus — lineaarse trendpinna kaldenurk kernelis. Arvutamisel korrutatakse piksliväärtuste erinevus kernelis olevate pikslite keskvaartusest ja pikslite kaugus gradiendi suunal. Gradiendi tugevus esitatakse arvude vahemikus 0...200. 0 tähistab gradiendi puudumist, et väärtustega kaalutud pikslikauguste summa gradiendil võrdub kaalumata pikslikauguste summaga gradiendil. Väärtus 100 tähendab, et piksliväärtuste lineaarse gradiendi tõus ühe piksli kaugusel võrdub ühega.

Kauguse pöördväärtusega kaalutud keskmine — kaugust arvestatakse kerneli keskmest, keskmine võetakse piksliväärtustest.

Tabel 3.6.1. Pildi- või kaardimustrit kirjeldavad indeksid programmis *Pidevstuudium*. Kui nomkiht = *jah*, siis töödeldakse andmekihis olevaid arve nominaalse tunnuse klassikoodidena, kui nomkiht = *ei*, siis töödeldakse andmekihti arvudena, kui nomind = *jah*, siis on arvutatud indeks nominaalne, kui nomind = *ei*, siis on arvutatud indeks arvuline.

Nr	Nimi	nomkiht	nomind
1	antud klassi sagedus	<i>jah</i>	<i>ei</i>
2	mood	<i>jah</i>	<i>jah</i>
3	Shannon	<i>jah</i>	<i>ei</i>
4	Lloyd	<i>jah</i>	<i>ei</i>
5	dominants	<i>jah</i>	<i>ei</i>
6	klasside arv	<i>jah</i>	<i>ei</i>
7	klassikülgnvuste osa	<i>jah</i>	<i>ei</i>
8	laikude suund	<i>jah</i>	<i>ei</i>
9	klassivastavuste lähedus	<i>jah</i>	<i>ei</i>
10	eri klassi vaatluspaaride osa	<i>jah</i>	<i>ei</i>
11	kaugusega kaalutud mood	<i>jah</i>	<i>jah</i>
12	klassipiiri kaugus	<i>jah</i>	<i>ei</i>
13	kaugus etteantud klassi piirist	<i>jah</i>	<i>ei</i>
101	üle keskmise väärtuste osa	<i>ei</i>	<i>ei</i>
102	keskmine	<i>ei</i>	<i>ei</i>
103	standardhälve	<i>ei</i>	<i>ei</i>
104	mediaan	<i>ei</i>	<i>ei</i>
105	Morani I 8st naaberpikslist	<i>ei</i>	<i>ei</i>
106	kaugusega kaalutud Morani I	<i>ei</i>	<i>ei</i>
107	naaberpikslite erinevus	<i>ei</i>	<i>ei</i>
108	variatsioonikoefitsient	<i>ei</i>	<i>ei</i>
109	gradiendi suund	<i>ei</i>	<i>ei</i>
110	serva ja keskosa erinevus	<i>ei</i>	<i>ei</i>
111	miinimum	<i>ei</i>	<i>ei</i>
112	maksimum	<i>ei</i>	<i>ei</i>
113	ekstsessitegur	<i>ei</i>	<i>ei</i>
114	üleminekute sujuvus	<i>ei</i>	<i>ei</i>
115	erinevus keskmisest	<i>ei</i>	<i>ei</i>
116	gradiendi tugevus	<i>ei</i>	<i>ei</i>
117	kauguse pöördväärtusega kaalutud keskmine	<i>ei</i>	<i>ei</i>

3.6.1.4. Tehisõppe

Tehisõppe osa on *Pidevstuudiumi* algmenüüs tähistatud kollasega (joonis 3.6.1). Tehisõppe programmiga *Pidevstuudium* on võimalikult hästi vaatlusandmetele vastavaid hinnanguid andvate näidiste ja tunnuste kaalude iteratiivne otsimine.

3.6.1.4.1. Tehisõppe ettevalmistused

Enne tehisõpet peab olema otsustatud, milliseid funktsioontunnuseid üritatakse hinnata, milliseid seletavaid tunnuseid kaalumiseks pakutakse, millised on õpetusvaatlused. Õpetusvaatluste seletavad tunnused peavad olema enne tehisõpet õpetusandmete tabelisse valmis arvutatud. Seletavate tunnuste indikaatorväärtusi võib enne tehisõpet mingil muul viisil hinnata ja lülitada tehisõppesse vaid kõrgema indikaatorväärtusega tunnused.

Uue funktsioontunnuse tehisõppeks tuleb teha järgmised ettevalmistused: lisada unikaalse *FID*-koodiga rida tabelisse *FTUNNUSED*, veerud *F<FID>* ja *AF<FID>* tabelisse *ATUNNUSED*, logitabel nimega *LOGI_F<FID>*; tulemuste tabelisse tuleb lisada neli veergu: prognoositud väärtuste, näidistega sarnasuse, vaatluste kaalu ja aktuaalsuse salvestamiseks; tekitada päring, mis esitab tulemuste tabeli eelmainitud veerud tunnustena nimedega *progn*, *prob*, *w*, *aktuaalsus*, funktsioontunnuse väärtuse tunnuseks *F* ning argumenttunnuste väärtused. Tabelisse *FTUNNUSED* tuleb kasutatava funktsioontunnuse reale kanda vaatlusvektorite tabeli või päringu nimi, funktsioontunnuse tüüp, otsitava sarnasuse kriitilise hulga algväärtus, vaatluste valimite soovitatav maht, tunnuste valimi soovitatav maht, lähestikku paiknevate vaatluste sarnasuse vähendamise nullkaugus ja eelklassifikaatori kasutamisel eelklassi andmekihi number.

Tabeli *ATUNNUSED* väli *AF* võib enne tehisõpet tühi olla. Logitabel ei tohi täiesti tühi olla, seal peab olema vähemalt üks kirje ID-numbriga 0. Tulemuste tabeli veerud *progn*, *prob*, *w* ja *aktuaalsus* võivad enne tehisõpet tühjad olla. Tühja aktuaalsusvälja puhul loetakse aktuaalsuse algväärtuseks 100 ühikut. Logifailis ei pruugi olla nende argumenttunnuste välju, mida selle funktsioontunnuse puhul ei kasutata.

3.6.1.4.2. Tehisõppe protseduur

Kui tehisõppeks vajalikud andmebaasiobjektid on loodud ja parameetrid sisestatud, saab *Pidevstuudiumi* algmenüüst tehisõppe käivitada. Põhilised *Pidevstuudiumis* võimalikud tehisõppe variandid on alltoodud. See, millist varianti programm kasutab, oleneb tehisõppeks tehtud ettevalmistustest ning tehisõppe käigus parameetrites läbi viidud muudatustest.

Ühekordne tehisõpe. Kõiki tunnuseid ja vaatluseid kasutatakse korraga. Sobib, kui vaatluseid on alla 1000 ja tunnuseid alla 30. Kui vaatlusi on üle paari tuhande ja tunnuseid üle paarikümne, siis võib arvutusaega kuluda üle nädala.

Ühe- või mitmekordne tehisõpe etteantud tunnustega. Kasutatavad tunnused peavad olema valitud tabelis *ATUNNUSED* ja tunnuste arv valimis tabeli *FTUNNUSED* järgi peab olema vähemalt sama suur kui valitud tunnuste arv.

Pidevõpe korduvate juhuvalimitega tunnustest ja vaatlustest. Iga tunnuse ja vaatluse puhul säilitatakse aktuaalsuskood, mis muutub vastavalt tunnuse/vaatluse kasu-

likkusele/mittevajalikkusele valimises. Tunnuse/vaatluse edasise juhuvalimisse sattumise tõenäosus on proportsionaalne aktuaalsuskoodiga. Sobib, kui vaatluseid on üle paarisaja ja tunnuseid üle paarikümne.

Pidevõpe juhuvalimitega tunnustest. Mingist kriitilisest piirist allapoole langenud aktuaalsusega tunnused saab kasutaja eemaldada ja käivitada seejärel ühekordse tehisõppe kõigi allesjäänud tunnustega ja kõigi vaatlustega. Sobib, kui vaatluseid on alla 1000 ja tunnuseid üle paarikümne.

Pidevõpe juhuvalimitega vaatlustest. Kasutaja nullib mingist kriitilisest piirist allapoole langenud aktuaalsusega vaatluste aktuaalsuskoodid ja käivitab seejärel tehisõppe kõigi tunnuste ja vaatlustega. Sobib, kui vaatluseid on üle paarisaja ja tunnuseid alla paarikümne.

Pidevõpe paarisaja vaatluseliste juhuvalimitega ja ilma vaatluste kaalumiset, mille käigus selguvad suhteliselt kiiresti suurema aktuaalsusega tunnused. Seejärel lülitab kasutaja ülejäänud tunnused välja, välja arvatud 10...20 kõrgema aktuaalsusega tunnust, misjärel toimub parima lahenduse otsimine kõigi valitud tunnustega ja suure vaatluste hulgaga.

Multinomiinalse prognoositava tunnuse puhul on täiendavalt võimalik kõigi prognoositavate klasside õpetamine korraga (ftyyp = 0) või iga prognoositava klassi pidevõpe eraldi (ftyyp = 4). Esimesel juhul kasutatakse kõigi klasside äratundmiseks samu tunnuseid, teisel juhul võidakse iga klassi puhul valida erinev komplekt seletavaid tunnuseid.

Kui pidevõppe esialgsed tulemused ei rahulda, võib hinnangute täpsust tõsta tunnuste muutmise, näiteks halvastieristuvate klasside ühendamise ja seejärel ühendatud klassi uus õpe, või siis uute seletavate tunnuste kasutuselevõtt. Ka õpetusandmed tasub kriitiliselt üle vaadata. Juhuslikud vead vaatlustes, defektid andmekihtides ning õpetusandmetesse sattunud ebatüüpilised vaatlused võivad muuta nähtused raskestituvastavateks.

3.6.1.4.3. Tehisõppe osad

3.6.1.4.3.1. Tunnuste valik ja kaalumine

Pidevstuudiumi tehisõpe valib kõigepealt tunnuseid. Esmalt proovitakse igat tunnust ükshaaval kasutatavate tunnuste hulka lisada. Üksiktunnustest valitakse see, mille kasutamisel saadakse parim vastavus hinnangute ja õpetusandmetes oleva tulemuse vahel. Järgmises korduses proovitakse esimesena valitud tunnusele ükshaaval ülejäänud tunnuseid lisada. Tunnuste ükshaaval lisamine lõpeb, kui kõik tunnused on lisatud. Iga iteratsiooni lõpus arvutatakse hinnangute vastavus õpetusandmetele.

Iga järgmine tunnus lisatakse väiksema kaaluga, lisatava tunnuse kaal arvutatakse järgmise valemi järgi:

$$\text{tunnusekaal}(p) = 1 - (\text{tunnuse astak} - 1) / (\text{kasutatavate tunnuste arv} + 1),$$

kus tunnuse astak on tunnuse kasutuselevõtu järjekorranumber, kasutatavate tunnuste arv on tunnuste valimi maht, p on tunnuse indeks.

Varem tunnuste komplekti liidetud tunnuste kaale jagatakse iga tunnuse lisamise järel tunnuste keskmise kaaluga, mille tulemusel võrdub prognoosivas komplektis olevate tunnuste kaalude keskväärtus alati ühega. Kaalumisele läheb see tunnuste komplekt, mis tunnuste valiku staadiumis andis kõige täpsemaid hinnanguid. Enamasti ei ole parimas tunnuste komplektis kõiki

tunnustevalimi tunnuseid, sest mõned tunnused ei seostu prognoositava nähtusega ning mõned tunnused on omavahel niivõrd kovarieeruvad, et mitmest lähedasest tunnusest valib tehisõpe vaid ühe.

Tunnuste lisamise etapile järgneb uus tunnuste kaalumine, mille jooksul proovitakse korduvalt ükshaaval iga tunnuse kaalu muutmise mõju hinnangutäpsusele, mis arvutatakse valemi

$$\text{tunnusemuudetudkaal}(p) = \text{tunnusekaal}(p) - 0.5 + \text{Rnd}()$$

järgi, kus $\text{Rnd}()$ on juhuarv vahemikus $0 \dots 1$.

Lisaks tunnuste kaalude muutmisele kontrollitakse ka otsitava sarnasusehulga muutmise mõju hinnangutäpsusele. Sarnasusehulka muudetakse valemi

$$\text{muudetudsarnasusehulk} = \text{sarnasusehulk} - 1 + 2 \cdot \text{Rnd}()$$

järgi.

Järgmises korduses jätkatakse selle muudetud kaalude ja sarnasusehulga komplektiga, mis andis parima hinnangute vastavuse. Korduste arvu saab kasutaja sisestada avamenüü aknast *Tunnuste kaalumisi*. Tunnuste kaalumise järel jääb kasutusse see kaalude komplekt, mis andis parima vastavuse.

3.6.1.4.3.2. Näidiste valik ja kaalumine

Näidiste valiku eel arvutatakse vastavus kõikide vaatluste kasutamisel näidistena. Seejärel eemaldatakse näidiste hulgast viimane vaatlus ja arvutatakse vastavus uuesti. Kui vastavus ei halvenenud, siis jääbki see vaatlus eemaldatuks, kui hinnangud muutusid vähemtäpseks, jääb vaatlus näidiseks. Näidiste valikul siirdatakse suurema ID-koodiga vaatluse juurest väiksema koodiga näidise poole. Näidiste eemaldamine tagantpoolt ettepoole tulevas järgnevuses toetab näidistekomplekti konservatiivsust — ühesuguste vaatluste puhul jääb näidiseks väiksema ID-koodiga vaatlus. Vaatlust ei eemaldata, kui see on viimane oma eelklassi esindaja või kui nominaalse prognoositava klassi esindajaid on näidiste hulka jäänud vähem kui $2 + \text{sarnasusehulga täisarvuline osa}$.

Vaatluste kaalumist ja selle põhjalikkust saab täisarvuna määrata algmenüü lahtrist *Vaatluste kaalumisi*. Kui vaatluste kaalumiseks kirjutada 0, siis piirdub programm vaid näidiste valimisega — kõik valitud näidised on võrdse ühikulise kaaluga. Nullist suurema arvu kaalumiste korral järgneb näidiste valiku etapile vaatluste kaalumine. Kaalumine toimub samuti ID-numbrite alanevas suunas. Kaalumises osalevad kõik valimisse sattunud vaatlused, ka need, mis said eelmises voorus nullkaalu. Näidiste kaalumisel võrreldakse vaatluse eemaldamise või mitte-eemaldamise otsuse asemel kolme varianti: näidise kaalu suurendamine kaalumutuse võrra, kaalu samaks jätmine, kaalu vähendamine kaalumutuse võrra. Kaalumutuse on esimeses kaalumiste voorus 0.5, igas järgmises voorus kaks korda väiksem. Seega kontrollitakse kolmandas voorus, kuidas mõjub hinnangute täpsusele näidiste kaalude muutmine 0.125 võrra. Üle kolme kaalumistevooru ei ole reeglina mõtet kasutada.

3.6.1.4.3.3. Aktuaalsused ehk unustamine

Iga tehisõppes kasutatava tunnuse puhul on kohustuslik aktuaalsuste väli tabelis *ATUNNUSED* ja vaatluste puhul aktuaalsuste väli vaatlusvektori päringus, mille nimi on tabelis *FTUNNUSED* (vt ptk 3.5). Tunnuste ja vaatluste aktuaalsuste algväärtuseks loetakse 100. Valimisse sattunud ja prognoosivas komplektis vajalikuks osutunud tunnuste ja vaatluste

aktuaalsus suureneb tehisõppe voorudes vastavalt nende kaalule. Valimisse sattunud, aga prognoosiks mittevajalike vaatluste ja tunnuste aktuaalsus väheneb. Aeg-ajalt, keskmiselt kümne õppevooruga järel, normeeritakse tunnuste ja vaatluste aktuaalsusi nii, et parajasti kasutuses olevate tunnuste ja vaatluste keskmine aktuaalsus võrduks 100 ühikuga. Aktuaalsuse maksimaalväärtus on 200, minimaalväärtus = 1, mis tähendab, et ükski tunnus ega vaatlus ei vaju aktuaalsuste muutumisega täielikult unustusse – tema valimisse sattumine ning kasutuselevõttu tehisõppe käigus ei välistata. Tunnuseid saab kasutusest eemaldada vastava valikuvälja väljalülitamisega tabelis *ATUNNUSED*, vaatluste eemaldamiseks tuleb vaatluste päringut muuta.

Aktuaalsuskoodi kasutatakse tunnuste ja vaatluste valimite moodustamisel. Aktuaalsuskoodide muutumise kiirus sõltub nn kergeusklikkuse kordajast, mille väärtust saab seada *Pidevstuumiumi* algmenüü kergeusklikkuse-umbusklikkuse taseme reguleerimise nuppudest (joonis 3.6.1). Kergeusklikkuse kordaja on täisarv vahemikus 1...6. Nihuti jaotused vastavad kordaja väärtustele. Kui tehisõppe on reguleeritud kergeusklikuks, siis muutuvad aktuaalsuskoodid igas õppevoorus suuremate väärtuste võrra — aktuaalseimate vaatluste ja tunnuste komplekt ning unustuse äärele vajunud tunnused ja vaatlused eristatakse vähema arvu õppevoorude alusel.

Kui vaatlus on tehisõppe vooru lõpuks näidiseks valitud, siis selle aktuaalsus suureneb vaatluse kaalu ja kergeusklikkuse korrutise võrra. Kui vaatlus on õpetusvalimis, aga osutus näidiseks mittevajalikuks, siis selle kaalu vähendatakse näidiste kaalude summa ja mittenäidiste arvu suhte võrra. See tähendab, et mida suurem on kergeusklikkus, seda suuremad on aktuaalsuste muutused iga õpetusvooru järel. Tänu sellele on vaatluste kaalude suurenemine ja vähenemine ligikaudu tasakaalus. Muudetud aktuaalsuskoodid kirjutatakse andmebaasi.

Tunnuste aktuaalsuse muutmine toimub analoogiliselt vaatluste aktuaalsuste muutmisega. Arvutuslikult on protsess veidi lihtsam tänu sellele, et kasutatavate tunnuste kaalude keskmine hoitakse kogu aeg võrdne ühega ehk kaalude summa võrdub tunnuste arvuga.

3.6.1.4.3.4. Valimite moodustamine

Kui kaheväärtuselise tunnuse esinemisjuhte on kogu õpetusandmestikus alla poole valimi mahust, siis võetakse kõik need valimisse. Kui puudumisjuhte on alla poole, siis liidetakse valimisse kõik puudumisjuhud. Ülejäänud vaatlused valitakse valimisse juhul, kui nende aktuaalsuskood on suurem kui

$\text{vaatluste aktuaalsuse summa} / \text{soovitud valimimaht} \cdot \text{Rnd}()$,

kus *Rnd()* on juhuarv vahemikus 0...1. Kui tabelisse *FTUNNUSED* märgitud valimi maht on suurem või võrdne vaatluste arvuga, siis lähevad kõik vaatlused valimisse.

Tunnuste valik valimisse toimub samuti juhuslike arvude abil ja valimisse sattumise tõenäosus on proportsionaalne tunnuse aktuaalsusega.

3.6.1.4.3.5. Sarnasuse arvutus

Vaatlustevahelise sarnasuse arvutamise eel kontrollitakse esmalt, kas vaatluste ajalise kehtivuse piirid kattuvad (vt ka ptk 3.5.3). Seejärel hakatakse arvutama vaatlustevahelist sarnasust iga tunnuse osas ehk osasarnasust ehk partsiaalsarnasust. Kõigepealt kontrollitakse, kas kasutatava tunnuse ajalise kehtivuse piirid kattuvad mõlema vaatlustega vähemalt osaliselt. Kui kehtivuse piirid ei kattu, siis järeldatakse, et mittekatuvate kehtivuspiiridega vaatluste vahel või tunnuse, mille kehtivusaeg ei kattu vaatluste omaga, osas ei ole võimalik sarnasust leida.

Vaatlustevahelise osasarnasuse arvutamise reegel sõltub sellest, kas argumenttunnus on nominaalne või arvuline. Nominaalse tunnuse klasside kokkulangevuse puhul võrdub osasarnasus ühega. Kui kategooriad on erinevad ja tunnuse puhul klassidevahelisi sarnasusi ei arvestata, siis võrdub osasarnasus nulliga. Kui tunnuse puhul kasutatakse omasarnasusi ehk kategooriate omavahelisi sarnasusi, siis võrdub osasarnasus omasarnasuste tabelist loetava kategooriatevahelise sarnasusega.

Vaatluse ja näidise vahelise sarnasuse arvutus toimub erinevuse arvutuse kaudu. Erinevus arvmuutujate osas arvutatakse järgmise valemi järgi:

$$D(T_p, E_p) = \frac{|T_p - E_p|}{V_{p,precl} \cdot w_E \cdot w_p},$$

kus:

p — tunnuse indeks,

$D(T_p, E_p)$ — standardiseeritud erinevus väärtuste T_p ja E_p vahel,

E — näidis,

T — vaatlus,

$V_{p,precl}$ — tunnuse p väärtuste normaliseerija eelklassis *precl*,

w_E — näidise E kaal,

w_p — tunnuse p kaal.

Normaliseeriv faktor V võrdub tunnuse p kahekordse standardhälbega üle kõigi eelklassis *precl* olevate õpetusvaatluste. Kui eelklassifikaatorit ei kasutata, siis arvutatakse standardhälve kõigist õpetusvaatlustest. Nimetajas olevad kaalud reguleerivad siinkohal samaväärse erinevuse ulatust piki tunnuse väärtustelge. Suurema kaaluga tunnuse ja näidise puhul saadud suuremad erinevused on samaväärsed vähem kaaluka tunnuse ja näidise puhul saadud väiksema erinevusega. Vaatluse eelklassi 255 puhul kasutatakse kõigi eelklasside näidiseid.

Kui saadud erinevus on suurem kui üks, loetakse osasarnasuseks 0, muul juhul saadakse osasarnasus erinevuse lahutamisel ühest. Osasarnasustest arvutatakse kaalutud keskmine kogusarnasus, kusjuures kaaludeks on näidise ja tunnuse kaalu korrutis, nagu eeltoodud valemiski. Nullkaaluga tunnuseid, ajaliste kasutuspiiride sobimatuse tõttu või muul põhjusel puuduvaid või määramatuskoodiga tunnuseid osasarnasuste kaalutud keskmise arvutamisel ei arvestata. Kui näiteks ühe võrreldava vaatluse kohas mullakaart puudub, siis mullatunnused vaatlustevahelist kogusarnasust ei mõjuta.

3.6.1.4.3.6. Otsuste langetamine

Pidevstuudium langetab otsuseid sarnasuse alusel. Kui hinnangu andmiseks kasutatakse vaid ühte kõige sarnasemat näidist, saab hinnanguks selle näidise funktsioontunnuse väärtus. Enamasti on otsuse aluseks aga suurem arv näidiseid. Kasutatavate näidiste arvu piirab otsuseks vajalik summaarse sarnasuse hulk, mille algväärtus loetakse tehisõppe alguses tabelist *FTUNNUSED* ja mida *Pidevstuudium* seejärel sobitab andmetele koos tunnusekaalude õppega. Programm otsib kõige sarnasemaid näidiseid senikaua, kuni otsuseks vajalik sarnasuse hulk on saavutatud või kuni leidub üle nulli sarnasusega näidiseid.

Pideva funktsioontunnuse väärtus leitakse otsuse aluseks olnud näidiste funktsioontunnuste väärtuste sarnasusega kaalutud keskmisena, nominaalse funktsioontunnuse prognoositud klassiks saab kategooria, mille puhul kasutatud näidiste sarnasuste summa on suurim. Multinominaalse tunnuse klasside eraldi õppes käsitletakse tunnust kaheväärtuselisena: kas vaatlus kuulub antud

klassi või kuulub mõnda teise klassi. Eelklassifikaatori kasutamisel otsitakse näidiseid vaid vaatluse eelklassi piirest.

Pidevstuudiumi tehisõppe osa salvestab koos hinnangutega ka sarnasustaseme otsuse langetamisel. See arvutatakse numbrilise funktsioontunnuse puhul nende näidiste, mida hinnangu andmisel kasutati, sarnasuste aritmeetilise keskmisena, kaheväärtuselise funktsioontunnuse puhul keskmise sarnasusena suurema koodi näidistega, multinominaalse funktsioontunnuse kategooriate eraldi õpetamisel keskmise sarnasusena antud koodi näidistega. Multinominaalse tunnuse puhul näitab sarnasustase prognoositud kategooria näidiste summaarse sarnasuse suhet kõigi hinnangu arvutamisel kasutatud näidiste summaarsesse sarnasusse. Kaheväärtuselise tunnuse puhul eeldatakse, et nähtuse esinemine on tähistatud suurema numbrilise koodiga kui nähtuse puudumine; soovitatav on kodeerida esinemisjuhud number ühega ja puudumisjuhud nulliga.

3.6.1.4.3.7. Hinnangute vastavus

Pidevstuudium hindab hinnangute ja vaatluste vastavust tehisõppel (vastavus õpetusandmetes ehk õpetusvastavus ehk treeningvastavus) jäta-üks-välja ristkontrolli meetodil (*LOOC — leave-one-out cross validation*). Selle puhul hinnatakse iga õpetusvaatluse puhul funktsioontunnuse väärtus kõigi teiste valimis olevate vaatluste järgi. Parima kaaludekomplekti, mille logitabeli kood on tabelis *FTUNNUSED*, abil kõigile näidistebaasis olevatele vaatlustele arvutatud hinnangute vastavust nimetatakse kontrollvastavuseks.

Vaatluste ja hinnangute vahelist vastavust mõõdab *Pidevstuudium* multinominaalse tunnuse puhul kapa kordajaga.

Binominaalse ehk kaheväärtuselise tunnuse hinnangute vastavuse aluseks, erinevalt multinominaalsest tunnusest, ei ole kategooriate kokkulangevuste sagedused, vaid sarnasuste hulgad. Kaheväärtuselise tunnuse puhul võrdub täpsushinnang: õigestihinnatud sarnasus ühe kategooriaga pluss õigestihinnatud sarnasus teise kategooriaga miinus üks. Saadav koondhinne (k) on muutumisvahemikult korrelatsioonikordaja ja kapa kordaja taoline muutuja, mis $= -1$, kui kõik vaatlused hinnatakse valesti; $k = 0$, kui pooled ühe kategooria vaatlustest (näiteks liigi esinemiskohad) ja pooled teise kategooria vaatlustest (näiteks liigi puudumiskohad) on ära tuntud või kui kõik hinnangud on ühte ja samasse väärtusklassi pakutud; $k = 1$, kui kõik vaatlused on õigesti prognoositud.

Mitmemõõtmelise numbrilise funktsioontunnuse puhul mõõdetakse hinnangute vastavust osatunnuste kokkulangeva osa kaudu. Ühemõõtmelist numbrilist funktsioontunnust käsitletakse *Pidevstuudiumis* pideva reaalarvulise muutujana. Selle hinnangute täpsust iseloomustatakse valimi ruutkeskmise hälbe kaudu, kus vaatluste arvust on lahutatud prognoosis kasutatud tunnuste arv.

3.6.1.4.3.8. Tehisõppe tulemuste salvestumine

Tehisõppe voorudes leitud tunnuste kaalud ja otsuse langetamiseks otsitava sarnasuse hulgad salvestuvad andmebaasi logitabelitesse. Ftyyp = 4 korral salvestub logitabeli väljale *etn* uuritava klassi näidiste arv, mitte kõigi näidiste arv nagu ülejäänud tunnusetüüpide puhul. Logitabeli väljale *kuup* salvestub tulemuste salvestamise aeg ja väljale *tvastavus* õppevoorus saavutatud vastavus õpetusvaatluste valimis (treeningvastavus). Väljale *kvastavus* salvestatakse leitud kaaludekomplektiga arvutatud kontrollvastavus. Kontrollvastavust arvutab *Pidevstuudium* vaid

nende tehisõppe voorude järel, milles leitud treeningvastavus oli parem kui seni parimana tähistatud kontrollvastavus.

Tunnuste aktuaalsused salvestuvad andmebaasi tabelisse *ATUNNUSED*. Vaatluste aktuaalsused, seni parima kaalude komplekti abil prognoositud väärtused, vaatluste kaalud näidistena seni parimas komplektis ja sarnasustase otsuse langetamisel salvestuvad tabelis *FTUNNUSED* näidatud andmebaasiobjekti (tabelisse või päringusse).

Tabeli *FTUNNUSED* väljale *LogiID* salvestab *Pidevstuudium* seni parima vastavuse andnud tunnusekaalude komplekti kirje numbri logitabelis. Seda välja ning samuti vaatluste kaale, prognoositud väärtusi ja sarnasustaset otsuse langetamisel muudetakse vaid siis, kui õppevoorus leiti paremat vastavust andev kaalude komplekt, kui see komplekt, mille number oli enne õppevooru algust väljal *LogiID*. Oluline on aga tähele panna, et nii tunnuste kui ka vaatluste aktuaalsusi muudetakse iga õppevooru lõpus ning logitabelisse kirjutatakse õppevooru lõpus tunnuste kaalud ka siis, kui prognoos ei olnud parim.

3.6.1.5. Teadmiste kontroll

Teadmiste kontrolli osa on *Pidevstuudiumi* algmenüüs tähistatud roosaga (joonis 3.6.1). Selles osas on kaks valikunuppu: kontrolltäpsuse arvutus ja näidiste uuestivalimine. Kontrollvastavuse arvutamisel ja uute näidiste valikul ei tohi logifaili parima komplekti real tunnuste kaalude väärtusteks tühikud olla.

3.6.1.5.1. Kontrolltäpsuse arvutus

Pidevstuudiumi algmenüüs olevat kontrolltäpsuse arvutuse valikut on mõtet kasutada juhul, kui õpetusandmestik või näidiste ja tunnuste komplekt on tehisõppe käigus muutunud või on kasutaja ise neid muutnud (vaatlusi on lisatud või eemaldatud, muudetud on tunnuste komplekti või kaale). Kui tehisõppel kasutatakse arvuti mälus olevaid ja õppe käigus optimeeritavaid näidiste kaale, siis kontrolltäpsuse arvutamisel loetakse näidiste kaalud tehisõppe andmebaasist.

Multinomiinalse tunnuse kategooriate eraldi õpetamisel (ftyyp = 4) tehisõppe voorudes saadud kontrollvastavus erineb kontrolltäpsuse eraldiarvutuse tulemusest. Iga klassi eraldi tehisõppe puhul valitakse selle klassi optimaalseks eristamiseks vajalikud sama klassi näidised ja kõiki ülejäänud klasse esindav ühtne näidiste komplekt. Nii iga klassi puhul. Seni parimaid tulemusi andnud tehisõppevoorude järel salvestatakse vaid parajasti õpitava klassi näidiste kaalud, teiste klasside näidiste kaale ei salvestata. Teisi klasse jäävad esindama nende teiste klasside eraldiõpetamisel leitud parimad näidised, mis sobisid nende teiste klasside jaoks valitud eristamistunnustega kasutamiseks. Kontrollvastavus arvutatakse ftyyp = 4 puhul nominaalse funktsioontunnuse igale kategooriale eraldi. Selle juures kasutatakse kõiki vaatlusi aga vaid antud kategooria jaoks optimeeritud tunnustega. Ülejäänud klasse esindavad vaid nende klasside seni parimast õppevoorst pärinevad näidised, mis ei pruugi sobida antud klassi äratundmiseks valitud tunnustega. Üldjuhul on sarnasusele tuginevates hinnangutes näidiste komplekt ja tunnuste komplekt omavahel seotud. Tunnuste ja näidiste ümberkombineerimine mõjub täpsushinnangutele ettearvamatult. Multinomiinalse tunnuse klasside õpe iga klassi puhul erinevate tunnustega vajab täiendavat uurimist ja katsetamist.

3.6.1.5.2. Näidiste uuestivalik

Näidiste uuestivalimine ja kaalumine võib aidata leida paremat prognoosikomplekti juhul, kui seni parim hinnangute vastavus on saadud mitte kõigist andmebaasis olevaist vaatlustest, vaid vaatluste valimist (s.t treeningvastavus on suurem kui kontrollvastavus). Näidiste uuestivaliku puhul eelistatakse suurema aktuaalsuskoodiga vaatlusi. Näidiste valiku ajal jälgitakse, et eelklasse jääks esindama vähemalt üks näidis ja et nominaalse tunnuse kategooriaid jääks võimaluse korral esindama otsuseks otsitavast summaarsest sarnasusest suurem arv näidiseid.

Lisaks sellele, et näidiste uuestivalik ei pruugi anda sama head näidiste komplekti, kui on tehisõppel leitud seni parim näidiste komplekt, võib protsess osutuda liigselt ajakulukaks. Näidiste uuestivalik toimub kümnekonna minuti jooksul, kui vaatluste hulk on tuhatkond, kuid suurema vaatluste arvu korral suureneb näidiste uuestivaliku aeg tunduvalt. Suure õpetusandmestiku korral (kui vaatlusi on üle 3000) ja aeg piiratud, siis on näidiste uuestivalimise asemel mõistlikum eelistada ühekordset tehisõpet umbes tuhatkonna juhusliku vaatlusega.

Ükshaaval õpetatavate multinominaalse tunnuse kategooriate (ftyyp = 4) näidiste uuesti-kaalumise korral valitakse ja kaalutakse uuesti vaid antud klassi näidised, teiste klasside näidiseid kasutatakse selliste kaaludega, nagu need tehisõppe andmebaasis on.

3.6.1.6. Hinnangute ehk prognooside arvutamine

Hinnang võib olla prognoositud klassikood või pideva muutuja väärtus, sarnasus prognoositud klassi või väärtuse näidistega või etteantud klassi näidistega. *Pidevstuudium* suudab prognoositud väärtusi ja sarnasusi väljastada kas andmebaasi tabelisse või *Idrisi32* binaarfaili kujul rasterkaardile. Hinnangute osa on *Pidevstuudiumi* avamenüüs teadmiste rakenduse nime all ja tähistatud sinise taustaga (joonis 3.6.1).

Prognoosi arvutamine teadmiste rakenduse osas toimub üldjuhul nii nagu tehisõppe puhulgi (ptk 3.6.1.4.3.6). Erandiks on multinominaalse tunnuse eraldi õpetatud klasside järgi prognoosimine, mille puhul arvutatakse vaatluse või koha sarnasus iga üksiku klassiga selle klassi tunnuste järgi ning prognoositud väärtuseks saab kõige sarnasema klassi kood. Kui ükshaaval õpetatud klasse soovitakse hinnata ükshaaval, siis tuleb hinnangud iga klassi osas eraldi arvutada ja eraldi faili salvestada (valik ühekaupa prognoos rasterfaili *Pidevstuudiumi* algmenüüs). Sel juhul käsitletakse multinominaalse tunnuse klasse binominaalse muutujana ja salvestub otsus, kas koht on sarnasem valitud klassiga või muude klassidega.

Hinnangute arvutamisel, nagu kontrolltäpsuse arvutuseski, ei tohi logifaili parima komplekti real tunnuste kaaludeks tühikud olla. Kui pideva tunnuse hindamisel tekib määramatus (näiteks sarnased näidised puuduvad täiesti), väljastatakse hinnanguks muutuja keskvärtus õpetusandmetes. Nominaalsete tunnuste määramatuse korral väljastatakse klassiks 255.

3.6.1.6.1. Sarnasushinnangud

Sarnasuse hinnang näitab otsuse langetamisel kasutatud näidiste protsentuaalset sarnasust hinnatava vaatlusega või vaatluskohaga. Enamasti on sarnasus kõige sarnasemate näidistega üsna kõrge, mis aga ei tähenda, et sama koha sarnasus teiste otsitavate klasside näidistega või pideva muutuja teistsuguste väärtustega peaks tingimata palju väiksem olema. Halvastieristuvate tunnuste puhul võib kohaga sarnaneda korraga mitmeid erineva funktsioontunnuse väärtusega näidiseid.

Arvtunnuse puhul väljastatakse otsuse langetamisel kasutatud näidiste keskmine sarnasus. Multinomiinalse ja binomiinalse tunnuse puhul väljastatakse prognoositud klassi näidiste sarnasuse summa ja kõigi otsuse langetamisel kasutatud näidiste sarnasuste summa suhe. Binomiinalse tunnuse puhul näitab sarnasuskaart seega nähtuse prognoositud esinemiskohtades sarnasust esinemiskoha näidistega, prognoositud puudumiskohtades sarnasust puudumiskoha näidistega. Kui sarnasus on 50%, siis on koht samavõrd sarnane nii esinemiskohtade kui ka puudumiskohtade kõige sarnasemate näidistega. Multinomiinalse tunnuse klasside puhul näitab sarnasuskaart sarnasust kõige sarnasema klassiga.

Korruga saab arvutada vaid sarnasust ühe multinomiinalse tunnuse klassidega. Seetõttu peavad sarnasuse arvutuse eel tabelis *FTUNNUSED* olema sisse lülitatud vaid ühe funktsioontunnuse need klassid, millega sarnasust hinnatakse.

3.6.1.6.2. Hinnangud andmebaasi tabelisse

Andmebaasi tabelisse saab arvutada nii prognoositavat väärtust kui ka sarnasust etteantud klassi näidistega. Hinnangute väljundtabeli nimi tuleb kirjutada *Pidevstuudiumi* algmenüü vastavasse lahtrisse. Selles tabelis peavad olema väljad *F*, *prob* ja *VID*. Prognoositavate väärtuste tabelis peab esimene neist olema funktsioontunnuse vormingus ja sinna salvestatakse prognoositud väärtus, teine peab olema baidivormis ja sinna salvestatakse sarnasus näidistega täisprotsentides, kolmandal väljal on vaatluse number täisarvu kujul. Lisaks mainitud kolmele väljale peavad prognoositavate väärtuste tabelis olema seletavate tunnuste väljad, kus välja nimeks on seletava tunnuse number tabelis *ATUNNUSED*.

Sarnasushinnangu puhul peab väljal *F* olema etteantud klassi baidi vormis kood, muus osas on etteantuga sarnasuste arvutamise tabeli struktuur nagu eelkirjeldatud prognooside tabeli puhulgi. Väljale *prob* salvestatakse kõige sarnasemate antud klassi näidiste keskmine sarnasus vaatlusega. Kõige sarnasemate näidiste arvu piirab otsustuseks otsitava summaarse sarnasuse hulk, mis loetakse logitabelist seal olevate parimate tunnusekaalude realt.

Nii sarnasushinnangu kui ka prognoosi arvutamisel kasutatakse tabelisse *FTUNNUSED* märgitud andmepäringut. Selles olevatest andmetest arvutatakse sarnasuse mõõtmisel kasutatavad seletavate tunnuste standardhälbed ning näidiste omadused.

Erinevalt salvestusest binaarfaili, peavad hinnangute ja sarnasuste tabelisse arvutamisel seletavad tunnused olema eelnevalt andmebaasi tabelisse valmis arvutatud ning asendustunnuseid ei kasutata.

3.6.1.6.3. Hinnangud rasterkaardile

Kõik *Pidevstuudiumi* väljundiks olevad binaar-rastrid on ilma heederita ridupidi ülalt alla loetavad baidiread (*Idrisi32 rst*-vorming). Sarnasuskaardi arvutamise kiirus sõltub tunnuste arvust, näidiste arvust ja kui funktsioontunnuse tüüp nelja korral arvutatakse lisaks sarnasuskaardile ka hinnangukaart, siis funktsioontunnuse tabelis *FTUNNUSED* sisse lülitatud klasside arvust.

Hinnangukaartide genereerimisel kasutatavaid andmekihte ei tohi olla rohkem kui 15. Tunnuseid võib olla kuni 255. Nii hinnangu- kui ka sarnasuskaardi genereerimisel saab kasutada varem kogu kaardi ulatuses välja arvutatud asendustunnuseid. Need võivad kaardi genereerimisele kuluvat aega vähendada kordades.

Kõigi sisend- ja väljund-binaarfailide servad peavad vastama Eesti Põhikaardi 10×10 km kaardilehtedele.

Proгноositava tunnuse parameetreid saab sisestada progноosiparameetrite dialoogiaknast (joonis 3.6.2). Progноosiparameetrid on alljärgnevad.

1. Kaardilehe number, mis määrab kasutatavad seletavate tunnuste andmekihtide failid.
2. Piksli küljepikkus dialoogiaknas loetletud failides.
3. Interpoleerimisparameetrid: sammu algpikkus pikslites, näidistega sarnasuse lubatud erinevus interpoleeritavate pikslite vahel, pideva muutuja puhul — interpoleeritavate pikslite hinnangute erinevus progноositava muutuja skaalas. Viimane sisestusaken on nähtav vaid siis, kui andmebaasi tabelis *FTUNNUSED* on väljal *ftyyp* progноositava tunnuse tüübiks 2. Interpoleerimise algoritmi kirjeldatakse peatükis 3.6.1.6.3.1.
4. Hinnangute salvestamise (progноosikaardi) fail. Kui hinnatakse vaid sarnasust etteantud klassiga, siis seda sisestusakent ei näidata.
5. Näidistega sarnasuse salvestamise fail. Sellesse faili salvestatakse etteantuga sarnasuse hindamisel keskmine sarnasus antud klassi näidistega, muudel juhtudel keskmine sarnasus progноositud klassi näidistega.
6. Interpoleerimiseraldiste fail.
7. Progноositava tunnuse eelklassi fail. Faili nime sisestusaken on vaikimisi nähtav vaid siis, kui andmebaasi tabelis *FTUNNUSED* väljal eelklass on kirjas progноositava tunnuse eelklassifikaatortunnuse kood.
8. Eraldistefailis ja eelklassifailis eiratavate väärtuste (eiramiskoodide) sisestamise väljad. Mõlemad failid määratlevad eiramiskoodi abil selle osa kaardilehest, mille kohta hinnangud ei arvutata. Eiramiskoodid võimaldavad arvutada progноose vaid põhikaardi mingite põhialade (näiteks metsaala) või kaardilehe interpoleerimiseraldiste failiga määratletud piirkonnas.
9. Kaardistatud klasside fail. See sisestusväli on nähtav vaid juhul, kui alghinvalist on valitud väljundiks sarnasus etteantud väärtusega. Sellel väljal näidatakse binaarfail, milles on etteantud klassikoodid, millega sarnasust tuleb hinnata. Sarnasuse mõõtmisel saab valida, kas hinnatakse sarnasust progноositava klassiga või etteantud klassiga ning kas koos sarnasushinnanguga arvutatakse ka progноositav klass või mitte.
10. Vaheproduktide salvestamise valikunupp, mille sisselülitatud seisul korral salvestatakse omaette failidesse interpoleerimise vahestadiumid. Iga salvestatava faili nimele lisatakse interpoleerimissammu määratlus.
11. Kihipuudumise hoiatuste valikunupp. Kui see on linnukesega märgitud, siis ilmub iga kord, kui mõne andmekihi faili ei leitud, ekraanile hoiatusteade andmekihi numbriga. Programmi töö jätkamiseks ilma puuduva andmekihita tuleb vajutada hoiatusteate OK-nuppu.

Prognosisiparameetrid

Hinnatav tunnus:

5423 Kaardileht

10 Piksli külg

16 Interpoleerimis-sammu algpikkus pikslites

Suurim lubatud erinevus interpolateerimisel

10 sarnasuse erinevus %

5 pideva tunnuse erinevus

Interpoleerimiskardi fail

vali

Näidistega sarnasuse kaardi fail

vali

☒ Interpoleerimiseraldiste kasutus

Interpoleerimiseraldiste fail

vali

Prognosi ei arvutata seal, kus eraldis = 255

☒ Prognositava tunnuse eelklassi kasutus

Prognositava tunnuse eelklasside fail

vali

Prognosi ei arvutata seal, kus eelklass = 0

☐ Sarnasus kaardistatuga

☒ prognosisiga

Kaardistatud klasside fail

vali

Tagasi

☒ vaheproduktide salvestus

☒ kihipuudumise hoiatused


Arvuta

Joonis 3.6.2. Hinnangukaartide nimede ja hinnangute parameetrite valimise dialoogiaken.

3.6.1.6.3.1. Kaardi interpolateerimine

Kaartide genereerimise kiirendamiseks ei arvutata hinnanguid igas pikslis. Uuritaval pinnal (maastikul) on tavaliselt ühetaolisi piirkondi, kus kõigis samade omadustega pikslites ei ole sarnasust näidistega mõtet hinnata. Seetõttu hinnatakse piksleid teatud sammuga ning vahepealne ala interpolateeritakse. *Pidevstuudiumis* saab kasutaja määrata kaardi genereerimise esimese etapi pikslisammu. Interpoleerimissammuks on soovitatav võtta arv, mis on kahe aste: 2, 4, 8, 16, 32 või 64. Esimeses etapis arvutatakse hinnang pikslites, mille rida ja veerg on etteantud pikslisammu vahega. Igas järgmises etapis tiheneb arvutuse samm kahekordselt, juba arvutatud piksleid uuesti ei arvutata. Iga etapi järel interpolateeritakse arvutatud pikslite vaheliste pikslite väärtused. Nominaalse tunnuse puhul interpolateeritakse piksliväärtused siis, kui kõiki nelja nurkmisse pikslisse hinnatud klass on sama. Pideva tunnuse puhul interpolateeritakse piksliväärtused juhul, kui nurkmiste pikslite sarnasus näidistega ei erine rohkem kui hinnangukaartide parameetrite sisestusaknas määratletud arvu võrra. Kui kasutatakse interpolateerimiseraldisi, siis interpolateeritakse vahepealsed piksliväärtused vaid juhul, kui kõigil neljal nurkmisel pikslil on sama interpolateerimiseraldise väärtus.

Hinnangulise kaardi järk-järgulise ilmumise näitena on esitatud soo-neiuvaiba esinemiskohtadega sarnasuse kaart (joonis 3.6.3, 3.6.4). Hinnangute arvutamist veekogudesse, hoonestusalale ja hoonestusalale tõkestas eelklassifikaatori andmekiht.



Joonis 3.6.3. Soo-neiuvaiba (*Epipactis palustris*) esinemise hinnangukaardi genereerimise astmed sammuga A — 16 pikslit ja B — 4 pikslit. Hall — määratlemata ala, valge — liigi tõenäoline puudumine, roheline — liigi tõenäoline esinemine, roosa — nii esinemise kui ka puudumise kohtadega sarnased alad. Eesti põhikaardi leht 5434, kaardilehe külg 10 km, piksli külg 10 m.

3.6.2. Muu tarkvara

Ruumiandmete originaalide digimisel ja kaartide kujundamisel kasutati programmi *Microstation 95*. Maapinna kõrgusmudel genereeriti samakõrgusjoontest ja kõrgusarvudest *Intergraph MGE* tarkvara abil. *dgn*-vormis andmed rasteriseeriti programmiga *ArcView 3.1*. Manipulatsioonid andmekihtidega, kaardi rasterkihtide kujundus ja rasterkihtide konverteerimine vektorvormis eraldisteks teostati programmiga *Idrisi32*. Lihtsamad kokkuvõtted tehti programmi *MS Office* abil. Klasteranalüüs viidi läbi programmiga *Statistica*. Originaaltarkvara ning programminagade programmeerimiskeskond on *Microsoft Visual Studio.NET*.

4. Tulemused ja arutelu

4.1. Tehisõppe tulemused

Selles peatükis esitatud tabelites on kasutatud järgmist tähistust: N — näidiste arv; T — tunnuste arv; S — otsuse langetamiseks otsitava sarnasuse hulk; V — hinnangute ja õpetusvaatluste vastavus, mille mõõduks on multinominaalse tunnuse (metsakasvukohatüübid, tüübirühmad, metsatüübid, puistutüübid) puhul kapa (κ), arvtunnuse (metsa troofsus ja niiskus) puhul ruutkeskmise hälve.

Uuritavast alast on põhikaardi põhialade järgi eraldatud vaid mets, mis hõlmab kahte eelklassifikaatori klassi: *mets* ja *noor mets*; viimane tähendab tavamõistes valdavalt raiesmikku.

4.1.1. Metsakasvukohatüübid

Tabel 4.1.1. Metsakasvukohatüüpide koos äratundmise seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetus- vaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
16 kasvukohatüüpi koos	451	214	10	3	0.54	198	12	2.92	0.53

Tabel 4.1.2. Metsakasvukohatüüpide kokkulangevus nende koos hindamisel. Tähistuse selgitused ptk 4.1 alguses.

Nimi	Vaatlusi	Kokkulangevus [%] (eelklassita)	Kokkulangevus [%] (eelklass põhikaart)
16 metsakasvukohatüüpi:	451	58	50
pohla	22	64	41
mustika	9	44	0
jänesekapsa-mustika	21	38	38
jänesekapsa	65	66	60
maasika	31	35	29
sinilille	90	68	63
naadi	64	64	63
sõnajala	5	0	0
angervaksa	16	63	56
sinihelmika	1	0	0
madalsoometsa	48	81	77
lodumetsa	17	29	12
siirdesoometsa	13	23	23
rabametsa	5	80	80
mustika-kõdusoometsa	17	35	24
jänesekapsa-kõdusoometsa	27	48	22

Metsakasvukohatüüpide koosõppe tulemusena on seni parim vastavus saavutatud ilma eelklassifikaatori kasutusega ($\kappa = 0.54$), eelklassifikaatori kasutamisel saavutatud vastavus oli veidi nõrgem ($\kappa = 0.53$). Otsuse langetamiseks vajalik otsitava sarnasuse hulk oli eelklassita õppe puhul kõrge – 3 (tabel 4.1.1), mis tähendab, et otsuse langetamiseks kasutati vähemalt 4 näidist.

Üldiselt oli kokkulangevus keskmiselt kõrgem *raba-* ja *madalsoometsa*, kuid samuti *naadi*, *sinilille*, *jänesekapsa*, *angervaksa* ning *pohla* kasvukohatüüpides (tabel 4.1.2). Kõikide metsakasvukohatüüpide puhul oli kokkulangevus põhikaardi kasutamisel eelklassifikaatorina kas sama või väiksem kui ilma selle kasutusega. Seda võib interpreteerida järgmiselt. Kui kasutada eelklassifikaatorit, siis peavad iga eelklassi (metsa puhul põhikaardi *mets* ja *noor mets*) puhul olema eraldi näidised. Kui neid mõnes eelklassis ei piisa, siis pole abi ka sama prognoositava kategooria näidistest teistes eelklassides.

4.1.2. Metsade tüübirühmad

Metsa tüübirühmade koos hindamisel on saavutatud kõrgem vastavus kui kasvukohatüüpide puhul (tabel 4.1.3), kuid otsuse langetamiseks vajalik otsitava sarnasuse hulk on ka siin kõrge – üle 3. Parema tulemus ($\kappa = 0.64$) on saavutatud ilma eelklassi kasutusega. Üldiselt on kokkulangevus kõikides tüübirühmades suur, keskmiselt halvem on see *sürja-*, *soostunud*, *siirdesoo-* ning *kõdusoometsade* puhul. Põhikaardi kasutamine eelklassifikaatorina suurendas kahekordselt *siirdesoo-* ja *rabametsade*, vähemal määral ka *salu-* ning *sürjametsade* hinnangute kokkulangevust; teiste tüübirühmade puhul eelklassifikaatori kasutamine vähendas kokkulangevust (tabel 4.1.4).

Tüübirühmade eraldi õppimise tulemusena saavutati seni parim vastavus söödil kasvava noore metsa ja *nõmmemetsade* puhul (tabel 4.1.5). Eelklassifikaatori kasutamine mõnede tüübirühmade puhul halvendas, mõne puhul parandas vastavust, kuid erinevused ei olnud kuigi suured.

Tabel 4.1.3. Metsade tüübirühmade koos äratundmise seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetus-vaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
10 tüübirühma koos	512	236	16	3.29	0.64	260	11	3.71	0.62

Tabel 4.1.4. Metsade tüübirühmade kokkulangevus nende koos hindamisel. Tähistuse selgitused ptk 4.1 alguses.

Nimi	Vaatlusi	Kokkulangevus [%] (eelklassita)	Kokkulangevus [%] (eelklass põhikaart)
10 tüübirühma:	512	72	70
palumets	63	79	73
laanemets	86	71	59
sürjamets	31	26	39
salumets	154	81	84
soostunud mets	22	50	50
madalsoomets	71	90	85
siirdesoomets	13	31	62
rabamets	5	40	80
kõdusoomets	44	52	41
metsastuv sööt	23	91	74

Tabel 4.1.5. Metsade tüübirühmade eraldi äratundmise seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetus- vaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
11 tüübirühma:	512								
nõmmemets	2	2	10	0.5	1	2	5	0.45	0.99
palumets	61	16	11	0.83	0.79	14	8	0.72	0.82
laanemets	86	43	6	0.53	0.77	35	4	0.56	0.69
sürjamets	31	14	9	0.83	0.69	15	9	0.80	0.72
salumets	154	75	13	1.36	0.68	38	8	0.34	0.62
soovikumets	22	8	4	0.53	0.79	8	5	0.97	0.79
madalsoomets	71	31	3	0.13	0.82	39	3	0.68	0.83
siirdesoomets	13	12	10	2.24	0.79	9	5	0.72	0.85
rabamets	5	3	7	1.84	0.80	3	8	0.91	0.83
kõdusoomets	44	24	12	0.91	0.84	35	6	3	0.80
noor mets söödil	23	9	5	3.24	1	12	3	3.11	0.99

4.1.3. Puistutüübid

Puistutüüpide koos õppes saavutati veidi parem vastavus klasteranalüüsil põhineva (11 üksusega) klassifikatsiooni puhul (tabel 4.1.6). Kooslusekoodidel põhineva klassifikatsiooni (10 üksust) kategooriaid õpetati ka eraldi (tabel 4.1.7). Enamasti tõstis eelklassifikaatori kasutamine siin tunduvalt hinnangute täpsust, hall-lepiku puhul koguni 0.55lt 0.82ni.

Tabel 4.1.6. Kahe erineva puistutüüpi klassifikatsiooni üksuste koos äratundmise seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetusvaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
10 puistutüüpi	512	209	16	1.5	0.58	212	18	2.76	0.57
11 puistutüüpi	512	241	9	3	0.60	242	13	3	0.61

Tabel 4.1.7. Puistutüüpi eraldi äratundmise seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetusvaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
10 puistutüüpi	512								
harvik/metsalage	30	15	8	2.94	0.73	6	3	0.83	0.74
pajustik	7	5	14	0.77	0.75	5	2	0.14	0.82
kaasik	71	26	12	0.59	0.55	39	4	0.24	0.58
okas-segamets	132	82	9	0.24	0.63	44	12	0.82	0.67
leht-segamets	121	46	8	0.69	0.54	44	10	0.41	0.63
hall-lepik	21	13	8	1.96	0.55	9	7	0.69	0.82
männik	67	43	9	1.56	0.75	18	7	0.86	0.80
kuusik	36	20	8	0.93	0.80	26	4	1.82	0.83
noor mets söödil	16	6	6	0.29	1.0	16	4	4.44	0.99
muu lehtmets	11	5	11	0.87	0.60	4	8	0.07	0.67

4.1.4. Metsatüübid

Metsatüüpide koos hindamisel saadud vastavus pole kuigi kõrge ($\kappa = 0.48$) (tabel 4.1.8). Ka kokkulangevused üksuste kaupa on enamasti väikesed ning enamasti madalamad just väheste õpetusvaatlustega üksuste puhul (tabel 4.1.9). Märgatav on, et metsatüübi äratuntavus suureneb klassi kohta olemasolevate õpetusandmete hulga suurenedes ($R^2 = 0.52$) (joonis 4.1.1). Logaritmilise trendjoone järgi peaks iga eristatava klassi kohta olema vähemalt kolmkümmend kuni nelikümmend õpetusvaatlust. Praegu on andmebaasis üle kahekümne näidisala vaid *palu-männikute*, *laanekuusikute*, *laane-segametsade*, *salu-segametsade*, *sookaasikute*, *soo-segametsade*, *kõdusoo-segametsade* ja metsastuvate põllumaade kohta (tabel 4.1.9).

Tabel 4.1.8. Metsatüüpide koosõppe seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.


Prognoositav tunnus (mets ja noor mets eraldi)	Õpetusvaatlusi	Eelklassita				Eelklass põhikaart			
		N	T	S	V	N	T	S	V
30 metsatüüpi	512	296	12	4.6	0.48	277	12	3.42	0.48

Tabel 4.1.9. Metsatüüpide kokkulangevus nende koos hindamisel. Tähistuse selgitused ptk 4.1 alguses.

Nimi	Vaatlusi	Kokku-langevus [%]
30 metsatüüpi:	512	51
paluraiesmik	7	86
palumännik	45	67
palu-segamets ja -lehtmets	11	0
laanehaavik	1	0
laanekuusik	21	29
laane-segamets	52	79
laanekaasik	7	0
sürjaraiesmik	1	0
sürja-okasmets	16	6
sürja-segamets ja -lehtmets	14	7
laane- ja saluraiesmik	18	56
salukaasik	18	6
salumännik	6	0
salu-segamets	92	74
salukuusik	5	0
muu salu-lehtmets	20	15
soostunud raiesmik	2	0
soostunud lehtmets	8	38
soostunud segamets	12	50
soometsa raiesmik	2	0
lodupajustik	1	0
sookaasik	32	53
lodulepik	2	0
soo-segamets	40	45
soo-männik	12	83
kõdusoo-segamets	33	70
kõdusoo-lehtmets	6	17
kõdusoo-männik	1	0
kõdusoo-kuusik	4	0
noor mets söödil	23	78

Metsatüüpide eraldi õppest jäeti välja vähem kui 5 näidisega üksused (tabel 4.1.10). Söödil kasvava noore metsa puhul on otsuse langetamiseks otsitav sarnasuse hulk sageli (tabelid 4.1.5, 4.1.7, 4.1.10) teiste üksuste vastavatest näitajatest palju suurem. Selle põhjuseks on ilmselt asjaolu, et söödil kasvava noore metsa klass varieerub rohkem ja on üksiknäidiste järgi raskemini eristatav.

Metsade tüübirühmade kombineerimine puistutüübiga on üks võimalik viis metsatüüpide kaardistamiseks. Paraku aga mõjutab iga klassi näidiste muutmine teiste klasside äratuntavust ja seetõttu on ükshaaval õpetatud klasside alusel koostatud hinnangulised kaardid esialgu ebastabiilsed ja vähemusutavad kui klasside koosõppe tulemused. Kui neid kombineerida puistutüüpide hinnangutega, mis on ka suhteliselt ebakindlad (tabel 4.1.7), siis ei ole eriti usaldusväärset tulemust loota.



Joonis 4.1.1. Metsatüüpide äratuntavus õpetusandmetes ja õpetusvaatluste arv metsaklasside korraga hindamisel. Joon — logaritmilise seose graafik ($R^2 = 0.52$).

Tabel 4.1.10. Metsatüüpide eraldi õppe seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus (mets ja noor mets eraldi)	Õpetus- vaatlusi	Eelklass põhikaart			
		N	T	S	V
22 metsatüüpi	512				
paluraiesmik	7	6	3	2.97	0.99
palumännik	45	34	4	4	0.75
palu-sega- ja -lehtmets	11	8	9	2.69	0.71
laanekuusik	21	15	3	2.16	0.76
laane-segamets	52	22	8	0.87	0.78
laanekaasik	7	5	8	2.57	0.78
sürjaokasmets	16	14	10	3.18	0.73
sürjasega- ja lehtmets	14	13	7	3.37	0.65
laane- ja saluraiesmik	18	8	5	4	0.76
salukaasik	18	8	11	0.67	0.77
salumännik	6	4	2	2.45	0.75
salu-segamets	92	72	12	3.7	0.66
salukuusik	5	5	4	2.39	0.77
muu salulehtmets	20	15	7	1.71	0.76
soostunud lehtmets	8	4	9	0.66	0.82
soostunud segamets	12	10	10	3.3	0.79
sookaasik	32	25	2	2.53	0.78
soo-segamets	40	38	7	4.38	0.75
soo-männik	12	8	12	1.81	0.84
kõdusoo-segamets	33	26	6	2.43	0.81
kõdusoo-lehtmets	6	5	7	1.74	0.87
noor mets söödil	23	13	2	5.75	1

4.1.5. Metsa kasvukoha karbonaatsus ja niiskus

Õpetusandmete jäta-üks-välja ristkontrolli järgi on metsa kasvukoha niiskuse hinnangute ruutkeskmise viga E. Lõhmuse (1984) metsakasvukohatüüpide ordinatsiooni sajaühikuliseks teisendatud skaalal 8.86 (tabel 4.1.11). Vigade jaotusest on aga näha, et täiesti ebaõnnestunud on vaid väike hulk hinnanguid. Kui 512 vaatlusest jätta välja 14 kõige ebaõnnestunud, on hinnangute keskmine viga 5.27 ühikut.

Metsa karbonaatsuse näidiste järgi hindamisel jõudis tehisõpe ruutkeskmise veani 8.8 ühikut sajaühikulises skaalas (tabel 4.1.11). Üle 20 ühiku vaatlusest erinevaid hinnanguid on seejuures vaid 3%, nende mitteamistamisega on ruutkeskmise viga 6.2 ühikut.

Nii niiskuse kui karbonaatsuse puhul saavutati paremad tulemused eelklassi kasutusega.


Tabel 4.1.11. Metsa kasvukoha karbonaatsuse ja niiskuse hinnangute seni parimate prognoosikomplektide omadused. Tähistuse selgitused ptk 4.1 alguses.

Prognoositav tunnus	Õpetus-vaatlusi	Eelklassita				Eelklass põhikaart (mets ja noor mets eraldi)			
		N	T	S	V	N	T	S	V
Metsa karbonaatsus	512	295	7	3.38	8.80	301	15	2.99	8.91
Metsa niiskus	512	307	10	3	8.86	306	11	3.04	9.00

4.2. Kaardid

4.2.1. Metsa kasvukohatüübid


Esialgse kaardi järgi on Otepää looduspargis sagedasemad järgmised metsakasvukohatüübid: *jänese kapsa* (34 km²), *sinilille* (25 km²), *naadi* (19 km²), *madal soo* (14 km²) ja *jänese kapsa-kõdusoo* (13 km²) (joonis 4.2.1).



Joonis 4.2.1. Metsa kasvukohatüübid Otepää looduspargis hinnatuna multinominaalse tunnusena. Säbrulisus viitab kasvukoha üleminekulisusele.

4.2.2. Metsade tüübirühmad


Tüübirühmade hinnangulise kaardi järgi domineerivad Otepää looduspargis *salumetsad* (45 km²), *laanemetsad* (31 km²) ja *madalsoometsad* (25 km²); järgnevad *kõdusoometsad* (9 km²) ja *palumetsad* (8 km²) (joonis 4.2.2).



Joonis 4.2.2. Metsa kasvukoha tüübirühmad Otepää looduspargis hinnatuna multinominaalse tunnuseks. Säbrulisus viitab kasvukoha üleminekulisusele.


4.2.3. Metsa kasvukoha niiskus ja karbenaatsus

Taimkatteüksuste andmebaasis olevate vaatluste, mille kohta niiskus ja karbenaatsuse väärtus on üles märgitud, paiknemine niiskuse ja karbenaatsuse telgedel on toodud joonisel 4.2.3.




Joonis 4.2.3. Metsavaatluste paiknemine niiskuse ja karbenaatsuse telgedel.


Hinnangulise kaardi kohaselt kasvab enamik Otepää looduspargi metsi kas keskmisel ja keskmisest veidi kuivemal kasvukohal küngaste lagedel (49% niiskusvahemikus 40...55%) või keskmisest niiskemates kohtades – küngastevahelistes nõgudes soopinnasel (23% niiskusvahemikus 75...95%). Künklikul maastikul on tasastele aladele iseloomulikke soostunud metsi vähe (joonis 4.2.4, 4.2.6). Kuna väiksema sarnasustaseme juures langetatud otsuste viga ei ole õpetusandmete järgi suurem kui hästi sarnaste näidiste järgi langetatud otsus (joonis 4.2.5), siis näidistega sarnasust metsa kasvukoha niiskuse kaardi kujundamisel ei arvestatud.



Joonis 4.2.4. Metsa kasvukoha niiskuse jaotumine Otepää looduspargis.




Joonis 4.2.5. Metsa kasvukoha niiskuse hinnangute hälbed õpetusandmetes E. Lõhmuse metsa-
kasvukohatüüpide ordinatsiooni 100-ühikulisel skaalal ja keskmise hälbe polünoomtrend.




Joonis 4.2.6. Sajaühikulises skaalas hinnatud metsa kasvukoha niiskus Otepää looduspargis. Valge värv tähistab mittemetsa ala.

Hinnangulise kaardi kohaselt kasvab enamik Otepää looduspargi metsi keskmise ja keskmisest kõrgema troofsusega kasvukohal (joonis 4.2.7). 79% metsa-alast on troofsusvahemikus 50...70 ühikut sajaühikulises skaalas.


Nagu metsa kasvukoha niiskuse puhul, ei ole väiksema sarnasustaseme juures langetatud otsused vähemtäpsed, õpetusandmetest võib leida pigem vastupidise tendentsi (joonis 4.2.8). Seetõttu metsa kasvukoha niiskuse kaardi kujundamisel näidistega vähesarnaseid alasid esile ei tõstetud (joonis 4.2.9).



Joonis 4.2.7. Metsa kasvukoha troofsuse hinnangute jaotumine Otepää looduspargis




Joonis 4.2.8. Metsa kasvukoha troofsuse hinnangute hälbed õpetusandmetes Lõhmuse metsa-kasvukohatüüpide ordinatsiooni 100 ühikulisel skaalal ja keskmise hälbe lineaartrend.



Joonis 4.2.9. Sajauhikulises skaalas hinnatud metsa kasvukoha troofsus Otepää looduspargis. Valge värv tähistab mittemetsa ala.

4.2.4. Metsa kasvukoha troofsuse ja niiskuse järgi prognoositud tüübirühmad

Metsa kasvukoha karbonaatsuse ja niiskuse järgi prognoositud tüübirühmadest on kõige sagedamini esindatud *salumetsad* (46 km²), millele järgnevad *laanemetsad* (39 km²), *madalsoometsad* (21 km²) ja *soostunud metsad* (15 km²) (joonis 4.2.10).



Joonis 4.2.10. Metsa kasvukoha niiskuse ja karbonaatsuse järgi prognoositud metsade tüübirühmad Otepää looduspargis.

4.2.5. Tüübirühmade kaartide võrdlus

Kõigi kolme erineva meetodika abil saadud tüübirühmade kaartide järgi on Otepää looduspargis protsentuaalselt kõige rohkem *salumetsi* (35...37%), millele järgnevad *laanemetsad* (24...31%) (tabel 4.2.1). Suhteliselt palju on ka *kõdusoometsi* ja *madalsoometsi*. Kõigil kaartidel paiknevad suuremad *salumetsa*-laamad looduspargi lõunaosas (Harimäe ümbrus) ning ida- ja loodeosas. *Salumetsa*-alad tulevad parema troofsusega kasvukohtadena hästi esile metsa kasvukoha troofsuse kaardil (joonis 4.2.9). *Palumetsi* on rohkem loodeosas, Paluveski kandis reljeefi kõrgematel osadel, ümbritsetuna *laanemetsade* ning madalamatel aladel – Elva jõe ning Palu kanali ja oja ümbruses – *madalsoometsade* poolt. Nimetatud piirkonnas paiknevad suuremad *madalsoometsade* alad, üldiselt aga esinevad need metsad suhteliselt väikeste laikudena koos *soostunud metsadega* üle kogu looduspargi madalamatel aladel ning nõgudes. Ühtlasemad *laanemetsa*-massiivid paiknevad looduspargi edela- ja keskosas. *Sürjametsade* puhul on tegemist üleminekulise tüübirühmaga *salumetsadele*, mida on näha ka kaartidelt, kus *sürjametsad* paiknevad väiksemate eraldistena *salumetsade* vahel. Kaardipildis kajastub see üleminekulisus säbrulisusena (eriti märgatav otse tüübirühmadena hinnatud üksuste kaardil, joonis 4.2.2). *Siirdesoo*- ja *rabametsi* on Otepää looduspargis hinnangulise kaardi järgi vähe ning need esinevad väikeste laikudena.

Erineva meetodika järgi tehtud kaartidel on suured erinevused märgatavad *soostunud metsade* ja *kõdusoometsade* osakaaludes (tabel 4.2.1). E. Lõhmuse (1984) 100-ühikulisel niiskuse ja karbonaatsuse ordinatsiooniskaalal *kõdusoometsade* niiskus- ja troofsusväärtusi *soostunud* ja *madalsoometsade* omadest eristada ei saa – kuivemate *kõdusoometsade* vastavad väärtused kattuvad *soostunud metsade*, niiskemate omad *madalsoometsade* omadega. Kuna *madalsoometsade* erinevate meetodikate abil saadud osakaalud väga ei erine, siis võib järeldada, et troofsuse ja niiskuse järgi prognoositud *soostunud metsad* hõlmavad suurt osa *kõdusoometsadest*, mis omakorda viitab, et *kõdusoometsad* on Otepää looduspargis kuivemapoolsed. Kasvukohatüüpidest tuletatud tüübirühmade hinnangute järgi on *kõdusoometsi* ligi kaks korda rohkem kui otse tüübirühmadena prognoosituna, mis tuleneb ilmselt asjaolust, et viimatinimetatud meetodikat kasutades on osa metsi klassifitseerunud *madalsoometsadeks* (selle tüübirühma protsentuaalne osakaal on otse prognoosituna tunduvalt suurem kui kasvukohatüüpidest tuletatuna).

Osa *palu*- ja *sürjametsadest* on troofsuse ja niiskuse järgi genereeritud kaardil paigutatunud *laanemetsa* ning osalt ka *salumetsa* tüübirühma, kuna esimesena nimetatute osakaal on selle meetodika järgi hinnatuna tunduvalt madalam kui teiste kaartide järgi, samas kui *salu*- ja *laanemetsade* osakaalud on kolmest variandist suurimad (eriti *laanemetsade* puhul). *Palumetsade* pindala vähenemine on eriti märgatav Paluveski ümbruse metsades, kus niiskuse ja troofsuse järgi on sinna prognoositud rohkem *laanemetsi*. Järelikult on selle kandi *palumetsad* niiskemat sorti. *Sürjametsade* väiksem osakaal troofsuse ja niiskuse järgi hinnatuna tuleneb *salu*- ja *sürjametsade* sarnasest troofsus- ja niiskustasemest Otepää looduspargis.


Salumetsade osakaal on erinevate meetodikate järgi hinnatuna tüübirühmadest kõige ühtlasem.

Tabel 4.2.1. Erineva metoodika abil tuletatud metsa tüübirühmade osakaal protsentides metsa kogupindalast. 1 – kasvukohatüüpidest tuletatud tüübirühmad; 2 – otse prognoositud tüübirühmad; 3 – niiskuse ja karbonaatsuse järgi prognoositud tüübirühmad.

Nimi	1	2	3
nõmmemets		0,01	0,00
palumets	2,83	6,35	1,55
laanemets	29,25	24,38	31,13
sürjamets	3,47	1,77	0,71
salumets	34,99	35,36	36,95
soostunud mets	3,53	3,40	11,92
madalsoomets	12,46	19,31	17,21
siirdesoomets	0,45	0,67	0,35
rabamets	0,51	0,36	0,17
kõdusoomets	12,51	6,98	

4.2.6. Puistutüübid

Klasteranalüüsile tuginevate puistutüüpide hinnangulise kaardi (joonis 4.2.11) järgi on Otepää looduspargis kõige enam *leht-segametsi* (37 km² ehk 31%), millele järgnevad *okas-segametsad* (28 km² ehk 23%) ning *sookasega leht- ja leht-segametsad* (23 km² ehk 19%). Vähem on *hall-lepikuid* (13 km² ehk 11%), *männikuid* (8 km² ehk 7%) ja *kuusikuid* (5 km² ehk 4%) ning veelgi harvem *arukaasikuid* (3 km² ehk 3%) ja üksusse *harvik/metsalage* kuuluvaid kohti (2 km² ehk 2%). Ülejäänud puistutüüpe (*pajustik, muu lehtmets, noor kaasik ja kase-segamets söödil*) on hinnangulise kaardi järgi alla 1 km² ja 1%.



Joonis 4.2.11. Metsade klasteranalüüsile tuginevad puistutüübid Otepää looduspargis hinnatuna multinominaalse tunnuseks.

4.2.7. Tunnustest seni parimates prognoosikomplektides

Ühe või teise metsaüksuse äratundmiseks parima pildi- ja kaarditunnuste komplekti leidmiseks tuleb seletavate pildi- ja kaarditunnuste indikaatorväärtusi plaanipäraselt võrrelda. See nõuab omaette uurimust. Alljärgnevalt on räägitud siiani tehisõppel leitud parimates prognoosikomplektides esinevatest tunnustest.

Kaartide genereerimisel kasutati eelklassifikaatorina põhikaardi põhialasid.

Kasvukohatüüpide eraldi õppel ning kaardi genereerimisel olid kaalukamateks tunnusteks maikuu satelliidipildi pankromaatilise ja keskinfrapunase ning juuli lähis- ja keskinfrapunase kanali kiirguse intensiivsus, kaugus põhikaardi järvedest, valdav muld 10 m raadiuses.

Tüübirühmade eraldi õppel ja kaardi genereerimisel olid kaalukamateks tunnusteks valdav muld 10 m raadiuses, maikuu satelliidipildi pankromaatilise ja lähisinfapunase ning septembri keskinfrapunase laineala kiirgusintensiivsus, eelmine põhikaardi põhiala.

Puistutüüpide kaardi genereerimisel kasutatud tehisõppel leitud seni parimas prognoosikomplektis olid suurema kaaluga järgmised tunnused: maikuu satelliidipildi keskinfrapunane ja pankromaatiline laineala, ortofoto punase tooni ekstsess 30 m raadiuses, kaugusega kaalutud mulla-mood, valdav lõimis 10 m raadiuses.

Metsa kasvukoha niiskuse kaardi genereerimisel kasutatud tehisõppel leitud parimas prognoosikomplektis olid suurema kaaluga järgmised tunnused: valdav muld 10 m raadiuses, metsakorraldusfoto punase ja roheline tooni standardhälve, valdav muld 10-klassilises süsteemis.

Karbonaatsuse hindamise parimas prognoosikomplektis olid suurema kaaluga valdav muld 10 m raadiuses, valdav muld eraldises, juuli satelliidipildi punase ning septembri keskinfrapunase kanali intensiivsus, metsakorraldusfoto punase ja roheline tooni intensiivsus ning heleduse naabruse autokorrelatsioon 30 m raadiuses.

Kokkuvõtlikult, võttes arvesse ka neid tehisõppe läbinud funktsioontunnuseid, mille kohta hinnangukaarte ei genereeritud (metsatüübid, puistutüübid kooslusekoodidele tugineva klassifikatsiooni järgi, eelklassifikaatorita ülejäänud funktsioontunnuste õpe), esines seni parimas prognoosikomplektis tunnustest kõige sagedamini domineeriv muld 10 m raadiuses. See on loogiline, sest muld on kasvukohatüübi kujunemisel ja määratlemisel väga oluline faktor.

Sageli esines prognoosikomplektis kesksuvisel (juuli) satelliidipildi lähisinfapunane kanal, mille kiirgusintensiivsus iseloomustab taimede lopsakust, lehepinnaindeksit, fotosünteesivat võimet. Üsna tihti oli parimas prognoosikomplektis esindatud ka maikuu satelliidipildi soojuskiirguse intensiivsus ning erinevate aastate maikuu satelliidipiltide pankromaatilised ja keskinfrapunased lainealad, aga ka roheline kanali kiirgusintensiivsus. Pankromaatilise laineala kiirgusintensiivsus on informatiivne seetõttu, et selle abil eristuvad okas- ja lehtmetsad – esimesed on tumedamad, teised heledamad. Üldiselt esinesid parima prognoosikomplektides satelliidipiltide tunnused sagedamini kui ortofotodelt arvatud tunnused ning esimestest olid omakorda paremad prognoosijad uusima satelliidipildi (2005. a) tunnused.

Tihti kuulus parimasse prognoosikomplekti ortofoto värvitooni standardhälve 30 m raadiuses. Värvitooni standardhälve on väike, kui piirkonna kõik pikslid on rohelised. Standardhälve pildiantmetest on maksimaalne, kui keskmist tooni – rohelist –, on vähe ning vaheldumisi on punakad ja sinakad pikslid. Väikse standardhålbega on lehtmetsad, mis on õlalt vaadates suhteliselt õhtlaselt rohelised. Suur standardhälve on iseloomulik männimetsadele, kus pildilt välja paistvad puude varjud on sinakamates toonides, valguse-poolsed küljed aga punakamad. Sinakad tunduvad ka männikus alusmetsas kasvavad kuused. Ka kuusikus või värvitooni standardhälve suur olla, kui tegemist on teravatipuliste võradega ning pildil paisatavad ka puude varjud. Oluline on siinkohal värvitooni arvuline väärtus, mitte selle heledus või tumedus.

Lisaks on suhteliselt sageli parimas prognoosikomplektis tunnustest eelmine põhikaardi põhiala ja valdav lõimis eraldises.

4.3. Sarnasushinnangud ja kaartide usaldatavus

Mõõtmisvead kaasnevad igasuguse mõõtmisega ning vigu või erandlikke tulemusi on enamasti kõigis andmetes. Praegu on näidistele tugineva pidevõppe metoodika abil taimkatte hinnangukaartide loomisel suurimaks ebatäpsuste põhjustajaks ilmselt vaatlusandmete väike esinduslikkus ehk näidiste väike hulk teatud üksuste osas. Kui õpetusandmeid on palju, siis toimib suurte arvude seadus ning erandlikud ja vigased vaatlused ei pääse tüüpiliste üle domineerima. Kui üksuse kohta on vaid mõnikümmend või vähem vaatlust, siis võib kergesti juhtuda, et mingit erandlikku või vääralt määratud tunnuste kombinatsiooni esineb õpetusandmetes pea sama palju kui tüüpilist. Tehisintellektil on sel juhul raske otsustada, mis on tõene ja tüüpiline või mis erandlik või väär.

Kaardi usaldatavuse tõstmiseks oleks näidistebaasi tarvis täiendada enamiku kaardistatavate üksuste osas. Tüübirühmade puhul on näidistebaasis väheesindatud üksusi (alla 20 näidise) 4, metsakasvukohatüüpide puhul 9, metsatüüpide puhul 23; puistutüüpidest on vähe näidiseid *muu lehtmetsa*, *metsastuva söödi* ning *pajustiku* kohta (vt ka ptk 3.4).

Väheesindatud kaardistusüksuste hulgas on mitu üksust, mis peaksid ka Otepää looduspargis esinema, kuid on näidiste baasis esindatud vaid näidistega väljastpoolt loodusparki. Üksuste äratuntavus oleks arvatavasti suurem, kui näidised pärineksid kaardistatava ala piirkonnast või vähemalt samast maastikurajoonist. Metsastunud põllumaade kohta on näidistebaasis küll 23 näidisala, kuid valdav osa neist paikneb Elva lähistel kahel sarnase mullastikuga põllumassiivil. Otepää looduspargi taimkatte kaardistamiseks oleks tarvis lisada metsastunud põllumaade näidiseid Otepää kõrgustikult.

Seni kuni pole sõltumatuid kontrollandmeid, saab näidistele tuginevate kaartide paikapidavust hinnata tehisõppes saavutatud kokkulangevuste järgi. Erineva detailsustasemega üksuste koosõppe hinnangutest (tabelid 4.1.1...4.1.4, 4.1.6, 4.1.8...4.1.9) võib järeldada, et lisaks üksuseid esindavate näidiste hulgale ning sarnasusele sõltub taimkatteüksuste äratuntavus suures osas eristatavate kategooriate arvust. Mida rohkem klasse üritatakse ära tunda, seda väiksem on äratundmise täpsus. Tüübirühmade koos hindamisel oli kokkulangevus tunduvalt suurem kui kasvukohatüüpide ja metsatüüpide puhul (eelklassifikaatori kasutamisel vastavalt 72%, 58% ja 51%).

Metsa kasvukohatüübi karbonaatsust ja niiskust õnnestub kaardi- ja pildiandmete järgi ära tunda ruutkeskmise veaga 8...9% (tabel 4.1.11), võttes E. Lõhmuse (1984) metsa-kasvukohatüüpide ordinatsioonitelgede väärtusvahemikuks 0...100%. Kuna kasvukoha karbonaatsuse ja niiskuse välihinnangute täpsus on umbes 10%, siis ei ole põhjust palju paremat tulemust loota.

Hinnangute ekslikkuse tõenäosust saab iseloomustada ka iga klassifitseeritava koha sarnasuse alusel selle näidistega. Vähene sarnasus olemasolevate näidistega viitab unikaalsele või näidistebaasis väheesindatud alale, mille kirjeldamine ja näidistebaasi lisamine aitaks parandada näidistebaasi esinduslikkust. Näidistega sarnasust otsuse langetamisel saab hinnangu paikapidavuse määramisel kasutada mitmel viisil. Üheks viisiks oleks lugeda ebakindlateks kõik teatud sarnasustasemest allpool langetatud otsused. Sarnasustaseme all mõistetakse siinkohal keskmist sarnasust nende näidistega, mida kasutati otsuse langetamisel. Otsuse langetamisel kasutatud näidised ei pruugi seejuures funktsioontunnuse ühele ja samale üksusele või väärtusele viidata. Hinnangute õigsuse ja otsuse langetamisel nõutava sarnasustaseme seost saab analüüsida

õpetusandmete tehiseõppe tulemuste järgi. Metsaüksuste puhul otsuse langetamisel kasutatud näidiste ja vaadeldava koha vahelise sarnasuse taseme ning hinnangu täpsuse vahel selget seost ei leitud. Õigete hinnangute osakaal erinevate sarnasustasemete juures oluliselt ei erine, jäädes vahemikku 54...66%. Erinevate metsaüksuste prognoosimisel on otsus langetatud enamasti keskmiste sarnasuse tasemete juures (60% otsustest 40...70% sarnasustaseme juures). Seose puudumist selgitab asjaolu, et hinnangus kasutatakse paljudest võimalikest näidistest kõige sarnasemaid ka siis, kui need kõige sarnasemad ei ole kaardistatava kohaga just eriti sarnased.

Sarnasuse keskmine tase otsustamisel sõltub üsna palju tehiseõppel valitud otsustamiseks vajalikust sarnasuse hulgast (vt ptk 3.6.1). Kui vajalik summaarse sarnasuse hulk on suur, siis on näidiste hulgast raskem leida selle summeerumiseks vajalikku arvu vaadeldava kohaga väga sarnaseid näidiseid ning otsuse langetamiseks kasutatavate näidiste hulka langeb ka kohaga vähem sarnaseid näidiseid. Vähemsarnased näidised mõjutavad otsustust siiski vähem, sest otsus langetatakse sarnasusega kaalutud sagedusena (nominaalse tunnuse puhul) või sarnasusega kaalutud keskmisena (arvtunnuse puhul). Teisisõnu, kui kasutatakse mõnda hästi sarnast ja mõnda vähesarnast näidist, siis sarnasemad näidised omavad otsuse langetamisel suuremat kaalu. Siinkohal on paraku mõningane eelis kategooriatel, mille esindajaid on näidiste hulgas rohkem. Väheesindatud klassidel on alati raske otsuse langetamiseks vajalikku sarnasuse koguhulka vaid oma klassi esindajatest kokku saada.

Selles uurimuses valis tehiseõppe enamasti üsna suure metsade eristamiseks vajaliku summaarse sarnasuse hulga, mis oli erinevate metsaüksuste koosõppel 3 või enam ning ületades metsatüüpide puhul 4. Üldiselt on kategooriate eraldi õppimisel sarnasuse hulk väiksem (enamasti alla 1), v.a üksikud erandid, näiteks tüübirühmade puhul *noor mets söödil*, *kõdusoomets*, *siirdesoomets*, puistutüüpide puhul *harvik/metsalage* ja *noor mets söödil*. Metsatüüpide puhul on ka kategooriate eraldi õppimisel summaarse sarnasuse hulk väga suur, eriti *soo-segametsa*, *palumänniku* ja *laane- ja saluraiesmiku* puhul (üle 4) ning küündides üksuse *noor mets söödil* puhul 6 lähedale (tabelid 4.1.1, 4.1.3, 4.1.5...4.1.8, 4.1.10...4.1.11).

Teiseks on hinnangute usaldusväarsust võimalik hinnata, võrreldes erinevate, kuid enam-vähem sama heade tunnusekomplektide abil genereeritud kaarte ja lugeda ebakindlateks ja kontrollimist vajavateks kohad, mis on alternatiivsetel kaartidel erinevad. Meetod peaks esile tooma kaardistatavate üksuste sujuvate üleminekute kohad, kus ka maastikul on raske üksuse piiri tõmmata. Selleks, et lahendite ebastabiilsuse hinnang ei sõltuks liiga palju juhusest, peaks võrreldavaid kaarte olema palju. See muudab meetodi kasutamise töömahukaks. Antud uurimuses on kolmel erineval moel genereeritud metsade tüübirühmade kaardid, mille võrdluse alusel saab öelda, et Otepää looduspargis on sagedasemad üleminekulised kasvukohatüübid *sürja-* ja *salumetsade*, *laane-* ja *palumetsade* ning *soostunud*, *madalsoo-* ja *kõdusoometsade* vahel.

Kolmandaks hinnangute usaldusväarsuse hindamise võimaluseks on sarnasus mitte otsuse langetamisel kasutatud näidistega, vaid hinnatavasse kohta prognoositud klassi näidistega. *Pidevstuudiumis* on etteantuga sarnasuse arvutamise võimalus olemas; etteantud klassiks on sel juhul prognoositud klass.

Neljandaks saab hinnangute usaldusväarsust hinnata, fikseerides iga klassifitseeritava piksli puhul, mitme klassi näidiseid otsuse langetamiseks valitud kõige sarnasemate näidiste hulgas on. Selle võimaluse kasutamiseks aga peaks esmalt tarkvara täiendama.

Näidiste järgi tehtavaid otsuseid mõjutavad juhuslikud vead õpetusandmetes, näidiste vastuolulisus mingi näidiseks sobivuse kriteeriumi osas ning süstemaatilised erinevused sama andmekihi omadustes (näiteks erineva tehnoloogiaga valmistatud aerofotod). Vastuolulisi metsavaatlusi on Otepää looduspargi alal seni tuvastatud 33, mille puhul on enamasti kasvukohatüüp vastuolus mullaliigiga, sest näidiste baasi lisatavate vaatluste puhul kontrolliti

senini enamasti välivaatluse vastavust põhikaardiga, aga mitte mullakaardiga. Ebatäpsusi hinnangutes põhjustab ka pildi- ja kaardiandmete kohati ebarahuldav kvaliteet. Mitmel kaardil on näha erineva kvaliteediga ortofotode piir. Fotode kvaliteedierinevus vähendab erinevatel kaardilehtedel olevate kohtade võrreldavust ja ka hinnangute täpsust. Prognooside usaldusväärsust aitab tulevikus loodetavasti tõsta digitaaltehnoogiaga töödeldud ortofotode laekumine seni nendega katmata ala (looduspargi lõuna- ja lääneosa) kohta. Looduspargi lõunaosa (kaardilehed 5423, 5424) kohta on võrreldes teiste uurimisala piirkondadega andmekihte vähem. Uusimad seni kasutada olevad kaugseireandmed looduspargi lõunaservas paiknevate kaardilehtede kohta on aerofotod aastast 2001 ja satelliidipilt aastast 2000.

Praegu on andmekihtidest genereeritud tunnused välja valitud subjektiivselt, toetudes varasemale kogemusele ja ühele uurimusele (Remm, 2005a). Erinevate kaugseire- ja kaarditunnuste arvutamiseks sobivaimad raadiused ning tunnuste indikaatorväärtused erinevate prognoositavate üksuste puhul tuleks välja selgitada eraldi kindla kava järgi läbi viidava uuringu käigus.

Kokkuvõte

Uurimuse käigus genereeriti Tartu Ülikooli geograafia instituudis loodud näidistele tugineva järeldamise tehise õppe originaaltarkvara *Pidevstuudium* abil Otepää looduspargi metsakasvukohatüüpide, metsade tüübirühmade, metsatüüpide ja puistutüüpide ning metsa kasvukohtade niiskuse ja karbonaatsuse esialgsed prognoosikaardid. Uurimuse eesmärgiks ei olnud lõplike, kõiki võimalikke tunnuseid kasutavate ja absoluutselt tõeste kaartide genereerimine, vaid tehnoloogilise protsessi läbimängimine tegelike andmetega suhteliselt suurel alal.

Katsetati ja võrreldi metsade tüübirühmade kaartide genereerimise kolme erinevat võimalust. Kõigil kaartidel olid tüübirühmade osakaalud üldiselt samad, kuid niiskuse ja karbonaatsuse alusel loodud kaardi puhul olid salu- ja laanemetsade osakaalud palu- ja sürjametsade arvelt tõusnud. Ilmselt on nende üksused Otepää looduspargis üleminekulised ning karbonaatsuse ja niiskuse tasemelt lähedased. Niiskuse ja troofsuse järgi tüübirühmade prognoosimine ei võimalda eraldi käsitleda kõdusoometsi, kuid soostunud metsade suur osakaalu tõus selle metoodika järgi loodud kaartidel näitab, et enamuse Otepää looduspargi kõdusoometsadest on kuivemapoolsed, sarnased soostunud metsadele ning ilmselt neist ka raskesti eristatavad.

Metsade kategooriaid õpetati nii koos kui ka eraldi. *Pidevstuudium* võimaldab eraldi õpetatud kategooriatest genereerida suurima tõepära kaarte, aga esialgsete katsetuste kohaselt on näidistele tuginevad suurima tõepära hinnangud veel liiga ebastabiilsed. Kategooriate ükshaaval õpetamise ja seejärel suurima tõepära hinnangutega ülepinnalise kaardistamise tehnoloogiat on tarvis täiendavalt testida. Klasside ükshaaval äratuntavuse keskmiselt tunduvalt kõrgemad hinnangud, võrreldes klasside koos õpetamisega näitavad, et hinnanguliste kaartide genereerimise tehnoloogiat on mõtet selles suunas arendada.

Uurimuse käigus selgusid mitmed lähteandmete ja metoodika puudujäägid. Taimkatteüksuste prognoosikaartide usaldusväärsuse tõstmiseks oleks esmajoonel tarvis parandada vaatlusandmete esinduslikkust. Läbi tuleks käia suuremad esialgsetel kaartidel olevad alad, mille sarnasus kaardil oleva üksusega on väike ja kohad, mis pildi- ja kaardiandmete järgi klassifitseerusid välivaatlusest erinevalt. Üle tuleks kontrollida ka näidisalad, mis esialgsel kaardil on erinevate kaardistusüksuste piiril. Tuleks selgitada, kas erineva klassifitseerumise põhjus võib olla varasema välivaatluse ebatäpsus; kui jah, siis peaks koha uuesti kirjeldama. Näidiste baasi tuleks edaspidi valida kõikide näidiste valiku kriteeriumide suhtes mittevastuolulisi näidiseid, sest praegu on valesti klassifitseerunud sageli just need kohad, kus esines mingi vastuolu. Kontrollimist vajaks hinnangutäpsuste muutus juhul, kui õpetusandmete hulgast eemaldada vaatlused, kus mullakaardil olev mullaklass või põhikaardi põhiala on vastuolus välivaatlusel märgitud kasvukohaga. Kuna harvaesinevate üksuste kohta ei ole lootust koguda sagedaste üksustega samaväärsel hulgal näidiseid, siis on tõenäoline, et nende väheesindatud, kuid suurt looduskaitselist väärtust omavate (näiteks laialehised salumetsad, allikasoometsad) üksuste äratundmisega on kaardi- ja kaugseire andmete järgi ka edaspidi raskusi. Seetõttu tuleks kaardi järgmises versioonis välikaardistusel leitud haruldased ja väärtuslikud alad kaardile lisada välivaatlusel kirjeldatud ulatuses. Täpsustada tuleks kaugseireandmete järgi raskesti eristuvate ja looduses sarnaste üksuste ühendamise mõju hinnangute täpsusele.

Kasutatud tunnuste komplekt on mõnevõrra subjektiivne. Edaspidi tuleks omaette uurimuse käigus välja selgitada tunnuste indikaatorväärtused erinevate funktsioontunnuste puhul ning nende arvutamise optimaalsed raadiused. Indikaatorväärtuste hindamise probleem ei ole triviaalne, sest funktsioontunnusega üksikult võttes hästi korreleeruv argumenttunnus ei pruugi olla vajalik komplektis teiste seletavate tunnustega.

Viited

- Aaviksoo, K. 1995.** Vegetation of Endla Nature Reserve classified on the basis of Landsat TM data. – Aaviksoo, K., Kull, K., Paal, J., Trass, H. (toim.). *Consortium Masingii*. Tartu Ülikool, Tartu, 27-36.
- Aaviksoo, K., Kadarik, H., Möllits, K. 1997.** Endla looduskaitseala taimkatte kaart. *Eesti Loodus* 10, 400-402.
- Aaviksoo, K., Paal, J., Dišlis, T. 2000.** Mapping of wetland habitat diversity using satellite data and GIS: an example from the Alam-Pedja Nature Reserve, Estonia. *Proceedings of the Estonian Academy of Sciences Biology Ecology* 49(2), 177-193.
- Aha, D. W. 1998.** The omnipresence of case-based reasoning in science and application. *Knowledge-Based Systems* 11, 261-273.
- Arold, I., Järvet, A., Remm, K. 1999.** Keskmismõõtkavaline Eesti maastikutüüpide kaart. – Loodusliku mitmekesisuse kaitse viisid ja vahendid. Eesti ökoloogiakogu, EV keskkonnaministeerium, Eesti Põllumajandusülikool, 31-34.
- Arold, I. 2005.** Eesti maastikud. Tartu Ülikooli kirjastus, Tartu.
- Austin, M. P. 2002.** Spatial prediction of species distribution: an interface between ecological theory and statistical modelling. *Ecological Modelling* 157 (2-3), 101-118.
- Birks, H. J. B. 1993.** Quaternary palaeoecology and vegetation science - Current contributions and possible future developments. *Review of Paleobotany and Palynology* 79 (1-2), 153-177.
- Bock, M., Rossner, G., Wissen, M., Remm, K., Langanke, T., Lang, S., Klug, H., Blaschke, T., Vrscaj, B. 2005.** Spatial Indicators for Nature Conservation from European to Local Scale. *Ecological Indicators* 5(4), 322-338.
- Bolstad, P.V., Swank, W., Vose, J. 1998.** Predicting Southern Appalachian overstory vegetation with digital terrain data. *Landscape Ecology* 13 (5), 271-283.
- Brito, J. C., Crespo, E. G., Paulo, O. S. 1999.** Modelling wildlife distributions: logistic multiple regression vs overlap analysis. *Ecography* 22, 251-260.
- Burrough, P. A., Wilson, J. P., van Gaans, P. F. M., Hansen, A. J. 2001.** Fuzzy k-means classification of topo-climatic data as an aid to forest mapping in the Greater Yellowstone Area, USA. *Landscape Ecology* 16 (6), 523-546.
- De'ath, G. 2002.** Multivariate regression trees: a new technique for modeling species-environment relationships. *Ecology* 83, 4, 1105-1115.
- De'ath, G., Fabricius, K. 2000.** Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology* 81, 11, 3178-3192.
- Debeljak, M., Džeroski, S., Adamič, M. 1999.** Interactions among the red deer (*Cervus elaphus*, L.) population, meteorological parameters and new growth of the natural regenerated forest in Snežnik, Slovenia. *Ecological Modelling* 121, 51-61.

- Debeljak, M., Dzeroski, S., Jerina, K., Kobler, A., Adamic, M. 2001.** Habitat suitability modelling for red deer (*Cervus elaphus* L.) in South-central Slovenia with classification trees. *Ecological Modelling* 138, 321-330.
- Eilart, J., Masing, V. 1961.** Taimkatte detailse suuremõõtkavalise kaardistamise juhendid. *Eesti Loodus* 6, 365-370.
- Ek, T., Külvik, M., Palo, A., Tau, R. 1999.** Metsa vääriselupaikade inventeerimine. Metoodika. Eesti Metsaamet ja Östra Götalandi lääni metsaamet. Linköping-Tallinn-Tartu.
- Fitzgerald, R.W., Lees, B.G. 1992.** The application of neural networks to the floristic classification of remote sensing and GIS data in complex terrain. – American Society of Photogrammetry and Remote Sensing (Eds.), Proceedings of the XVII Congress ASPRS, Bethesda, MD, 570–573.
- Flower, R.J., Juggins, S., Battarbee, R.W. 1997.** Matching diatom assemblages in lake sediment cores and modern surface sediment samples: The implications for lake conservation and restoration with special reference to acidified systems. *Hydrobiologia* 344, 27-40.
- Foody, G.M. 1999.** Applications of the self-organizing feature map neural network in community data analysis. *Ecological Modelling* 120, 97-107.
- Franklin, J. 1995.** Predictive vegetation mapping: geographic modelling of biospatial patterns in relation to environmental gradients. *Progress in Physical Geography* 19, 474-499.
- Frey, T. 1969.** Kvantitatiivne taimeökoloogia. Tartu Riiklik Ülikool, Tartu.
- Guisan, A., Zimmermann, N. E. 2000.** Predictive habitat distribution models in ecology. *Ecological Modelling* 135, 2-3, 147-186.
- Hall, O., Arnberg, W. 2002.** A method for landscape regionalization based on fuzzy membership signatures. *Landscape and Urban Planning* 59 (4), 227-240.
- Hang, E. 1976.** Surface relief and geological structure as causes of the landscape peculiarities of the Otepää upland. *Tartu Riikliku Ülikooli Toimetised* 393, 3-20.
- Hang, E., Karukäpp. 1979.** Otepää kõrgustiku pinnavormistik. – Eesti NSV saarkõrgustike ja järvenõgude kujunemine. Tallinn, 42-65.
- Hansen, M. J., Franklin, S. E., Woudsma, C. G., Peterson, M. 2001.** Caribou habitat mapping and fragmentation analysis using Landsat MSS, TM, and GIS data in the North Columbia Mountains, British Columbia, Canada. *Remote Sensing of Environment* 77, 50-65.
- Heikkilä, J., Nevalainen, S., Tokola, T. 2002.** Estimating defoliation in boreal coniferous forests by combining Landsat TM, aerial photographs and field data. *Forest Ecology and Management* 158, 9-23.
- Hilbert, D. W., Ostendorf, B. 2001.** The utility of artificial neural networks for modelling the distribution of vegetation in past, present and future climates. *Ecological Modelling* 146, 311-327.
- Ilves, A. 1953.** Eesti NSV arumetsatüübid. – LUS-i juubelikoguteos 1853-1953. Tallinn, 11-49.
- Ilves, A. 1969.** Metsade tüpoloogilisest liigestamisest ja klassifitseerimisest. – *Metsamajandus* 2, 24-34.

- Kalda, A. 1970.** Välibotaanika. TRÜ, Tartu.
- Kalda, A. 1991.** Taimkatte suuremõõtkavuline kaardistamine looduskaitse planeerimise teenistuses.
- Karu, A., Muiste, L. 1958.** Eesti metsakasvukohatüübid. ERK, Tallinn.
- Katus, A., Tappo, E. 1965.** Eesti metsa-kasvukohatüübid. Metsanduse ja Looduskaitse Peavalitsus, Tallinn.
- Keskkonnaministri 5. veebruari 2004. a määrus nr 4.** Geodeetilise süsteemi kehtestamine. Riigi Teataja Lisa, 18.02.2004, 17, 267.
- Kimes, D. S., Nelson, R. F., Salas, W. A., Skole, D. L. 1999.** Mapping secondary tropical forest and forest age from SPOT HRV data. *Journal of Remote Sensing* 20, 3625-3640.
- Kilpeläinen, P., Tokola, T. 1999.** Gain to be achieved from stand delineation in LANDSAT TM image-based estimates of stand volume. *Forest Ecology and Management* 124, 105-111.
- Klijn, F., Groen, C.L.G., Witte, J. P. M. 1996.** Ecoseries for potential site mapping, an example from the Netherlands. *Landscape and Urban Planning* 35, 53-70.
- Kobler, A., Adamic, M. 2000.** Identifying brown bear habitat by combined GIS and machine learning method. *Ecological Modelling*, 135, 291-300.
- Kont, 1986.** Mähe ümbruse mõhnad. *Eesti Loodus* 11, 697-699.
- Kuusk, A., Lang, M., and Nilson, T. 2004.** Simulation of the reflectance of ground vegetation in sub-boreal forests. *Agricultural and Forest Meteorology* 126 (1-2), 33-46.
- Laasimer, L. 1965.** Eesti NSV taimkate. Valgus, Tallinn.
- Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauga, J., Aulagnier, S. 1996.** Application of neural networks to modelling non linear relationships in ecology. *Ecological Modelling* 90, 39-52.
- Lek, S., Guégan, J. F. 1999.** Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological Modelling* 120, 65-73.
- Lõhmus, E. 1974a.** Eesti metsade ordineerimisest ja klassifitseerimisest. *Metsanduslikud uurimused* 11, 162-194.
- Lõhmus, E. 1974b.** Metsad rabadest nõmmede ja loopealseteni. – Valk, U., Eilart, J. (koostajad). Eesti metsad. Valgus, Tallinn, 60-98.
- Lõhmus, E. 1984.** Eesti metsakasvukohatüübid. ENSV Agrotööstuskoondise Info- ja Juurutusvalitsus, Tallinn.
- Lõhmus, E. 2004.** Eesti metsakasvukohatüübid. Eesti Loodusfoto, Tartu.
- Marvet, A. 1970.** Eesti taimekoosluste määraja. Eesti NSV Teaduste Akadeemia Loodusuurijate Selts, Tartu.
- Mas, J. F., Puig, H., Palacio, J. L., Sosa-Lopez, A. 2004.** Modelling deforestation using GIS and artificial neural networks. *Environmental Modelling & Software* 19, 461-471.
- Masing, V. 1966.** Metsatüüpide rühmad Eestis. *Eesti Loodus* 1.

- Masing, V. 1970.** Rakendusliku tüpoloogია ja taimkatte kaardistamise tähtsamad ühikud. – Kalda, A. (koostaja). Välibotaanika. TRÜ, Tartu, 138-155.
- Masing, V. 1979.** Botaanika 3. Valgus, Tallinn.
- Masing, V. 1991.** Eesti taimkatte suuremõõtkavaline kaardistamine 1960-ndail ja 1970-ndail aastail. – Leht, M. (toimetaja). Botaanilised uurimused VI. Eesti Teaduste Akadeemia zooloogia ja botaanika instituut, Tallinn, 85-91.
- Masing, V. 1992.** Ökoloogialeksikon. Eesti Entsüklopeediakirjastus, Tallinn.
- Meiner, A. 1999.** Eesti maakate. CORINE Land Cover projekti täitmine Eestis. Tallinn.
- Mitchell, T. 1997.** Machine Learning. McGraw-Hill, Boston, MA.
- Moore, D. M., Lees, B. G., Davey, S. M. 1991.** A new method for predicting vegetation distributions using decision tree analysis in a geographic information system. *Environ. Manage.* 15 (1), 59–71.
- Muinen, E., Maltamo, M., Hyppänen, H., Vainikainen, V. 2001.** Forest stand characteristics estimation using a most similar neighbor approach and image spatial structure information. *Remote Sensing of Environment* 78, 223-228.
- Mäkelä, H., Pekkarinen, A. 2001.** Estimation of timber volume at the sample plot level by means of image segmentation and Landsat TM imagery. *Remote Sensing of the Environment* 77, 66-75.
- Nilson, T., Kuusk, A., Lang, M., Lökk, T., Anniste, J., Peterson, U. 1999.** Satelliidipiltidel baseeruva metsakorralduse alused. – Pidev metsakorraldus. EPMÜ Metsandusteaduskonna Toimetised 32. Tartu, 81-87.
- Nilson, T., Lang, M., Kuusk, A., Anniste, J., and Lökk, T. 2000.** Forest reflectance model as an interface between satellite images and forestry databases, In: Zawila-Niedzwiecki, T. and Brach, M., Eds, EUR 19530 - Remote Sensing and Forest Monitoring, Luxembourg: Office for Official Publications of the European Communities, 462-476.
- Osborne, J. M., Brearley, D. R. 2000.** Completion criteria case studies considering bond relinquishment and mine decommissioning: Western Australia. *Int. J. Surface Mining, Reclam. Environ.* 14 (3), 193–204.
- Paal, J. 1997.** Eesti taimkatte kasvukohatüüpide klassifikatsioon. Tallinn.
- Paal, J., Ilomets, M., Fremstad, E., Moen, A., Børset, E. Kuusemets, V., Truus, L., Leibak, E. 1999.** Eesti märgalade inventeerimine 1997. a. Projekti “Eesti märgalade kaitse ja majandamise strateegia” aruanne. Eesti Loodusfoto, Tartu.
- Paal, J., Rooma, I., Turb, M. 2004.** Sürjametsadest Otepää kõrgustikul. *Metsanduslikud Uurimused* 40, 124-149.
- Palo, A., Aunap, R., Mander, Ü. 2005.** Predictive vegetation mapping based on soil and topographical data: A case study from Saare County, Estonia. *Journal for Nature Conservation* 13, 197-211.
- Pekkarinen, A. 2002.** Image segment-based spectral features in the estimation of timber volume. *Remote Sensing of Environment* 82, 349-359.

- Reintam, L. 1996.** On genesis and taxonomy of brown-colored sandy forest soils. *Eurasian Soil Science* 29, 395-401.
- Remm, K. 2002.** Otepää looduspargi taimkatte kasvukohatüüpide kaart. – T. Frey (toim.), Eesti süsinikubilansi ökoloogiast ja ökonoomikast. Tartu, 62-76.
- Remm, K. 2004a.** Case-based prediction for species and habitat mapping. *Ecological Modelling* 177 (3-4), 259-281.
- Remm, K. 2004b.** Nähtuste paiknemissuhteid Eesti põhikaardi lehel 5434. *Publicationes Instituti Geographici Universitatis Tartuensis* 89, 209-236.
- Remm, K. 2005a.** Correlations between forest stand diversity and landscape pattern in Otepää NP, Estonia. *Journal for Nature Conservation* 13 (2-3), 137-145.
- Schank, R. C. 1982.** Dynamic Memory: A Theory of Learning in Computers and People. Cambridge University Press, Cambridge, New York, Melbourne.
- Schank, R., Abelson, R. 1977.** Scripts, Plans, Goals and Understanding: an Inquiry into Human Knowledge Structures. Erlbaum, Hillsdale, NJ.
- Stankovski, V., Debeljak, M., Bratko, I., Adamič, M. 1998.** Modelling the population dynamics of red deer (*Cervus elaphus* L.) with regard to forest development. *Ecological Modelling* 108, 145-153.
- Tokola, T. 2000.** The Influence of Field Sample Data Location on Growing Stock Volume Estimation in Landsat TM-Based Forest Inventory in Eastern Finland. *Remote Sensing of the Environment* 74 (3), 422-431.
- Wettschereck, D., Aha, D. W., Mohri, T. 1997.** A review and empirical evaluation of feature weighting methods for a class of lazy learning algorithms. *Artif. Intell. Rev.* 11 (1-5), 273-314.
- Wilds, S., Boetsch, J., Manen, F. T.van., Clark, J. D., White, P. S. 2000.** Modeling the distributions of species and communities in Great Smoky Mountains National Park. *Computers and Electronics in Agriculture* 27, 389-392.
- Wilson, D. R., Martinez, T. R. 2000.** Reduction techniques for instance-based learning algorithms. *Machine Learning* 38, 257-286.

Viited käsikirjadele

- Paal, J., Turb, M., Rooma, I. 2002.** Riikliku looduskaitseprogrammi projekti „Otepää looduspargi sürjametsade mitmekesisuse inventuur” aruanne. [Käsikiri TÜ botaanika ja ökoloogia instituudis.]
- Palo, A. 1999.** Aerofotopõhine biotoopide kaardistamise meetod ja selle rakendamine looduskaitsealustes planeeringutes. Magistritöö maastikuökoloogia ja keskkonnakaitse erialal. 99 lk + lisad. [Käsikiri TÜ geograafia instituudis.]
- Remm, K. 2005b.** Ruumiliste loodusandmete statistiline analüüs. Versioon 20. detsember 2005. [Käsikiri Tartu Ülikooli geograafia instituudis.]

Sulbi, K. 2005. Salumetsade suktsessioon Otepää looduspargis. Juhendaja J. Paal. Harjutustöö. 49 lk + lisad. [Käsikiri TÜ botaanika ja ökoloogia instituudis.]

Internetiviited

Eesti põhikaardi 1: 10 000 digitaalkaardistuse juhend. 2000. Maa-amet.
http://www.maaamet.ee/index.php?lang_id=1&page_id=64&menu_id=7. 20.02.2006.

EOL kaartide andmebaas. <http://www.orienteerumine.ee/kaart/kaart/index.php>. 11.11.2005.

Meiner, A., Aaviksoo, K. 2001. Satellite landscape diversity monitoring of Alam-Pedja, Soomaa, Lahemaa and Saarejärve in 1988-1995.
http://www.seiremonitor.ee/alam/06/06_2_aruanne2001/. 20.03.2005.

Otepää looduspark. 2003. <http://www.otepaaloodus.ee/failid/LP.pdf>. 15.01.2006.

Mapping of forest site types of the Otepää Nature Park using case-based reasoning and machine learning

Summary

Case-based methods are promising for processing images and other spatial data and could be among the best methods for predictive mapping of vegetation. Case-based ecological mapping relies on the assumption that a phenomenon can be found in locations similar to those where this phenomenon has already been registered. The specific feature of case-based predictions is the presence of empirical data within a predicting system. Lazy learning is a machine learning approach for fitting case-based prediction systems, that prefers general data to generalizations (Remm, 2004a).

High topographical variability of the terrain, continuous variability of soil types and forest composition, mosaic land use pattern, forestation of abandoned agricultural lands are characteristic to the study area.

The main goals of this study were:

- 1) creating predictive maps of forest site types, site groups, stand types, combined categories of type groups and stand types (named forest community types); also maps of forest soil moisture and trophics rate in a scale from 0 to 100 points;
- 2) comparing tentative large-scale maps of forest site type groups created using three different approaches;
- 3) bringing out disadvantages in the methodology and source data.

A machine learning software, designed by Kalle Remm at the Institute of Geography, Tartu University, was used.

Explanatory variables were derived from Landsat TM images, colour ortophotos, forest management photos, digital elevation model, 1: 10 000 digital base map and 1: 10 000 digital soil map. 913 field observations were used as training data.

Goodness-of-fit of predictions was estimated using leave-one-out cross-validation. The predicted and field-estimated values were compared using the index of classification agreement (kappa, κ) if the variable was multinomial (forest site type, type group, community types, stand types). One-dimensional numerical variables were treated as continuous, and the accuracy of predictions was characterized by root mean standard error (*RMSE*). The best fits for variables were: forest site type — $\kappa = 0.54$, type groups — $\kappa = 0.64$, forest community types — $\kappa = 0.58$, stand types — $\kappa = 0.61$, moisture rate — *RMSE* = 8.91, trophics rate — *RMSE* = 8.8.

Based on the initial map of the forest site types, the most common units in Otepää Nature Park are fresh boreo-nemoral forests, but also fresh boreal forests and minerotrophic swamp forests. According to the initial predictive map of forest soil moisture and trophics, forests mostly grow on drier or moister places than average and those places are usually well provided by nutrients.

LISAD

LISA 1. Microstationi programminaga cellidevärvid.bas

Private COL as integer

Sub SELEC

```
MbeSendCommand "SELECTBY MODE INCLUSIVE"
MbeSendCommand "SELECTBY OPTIONS SELECTION"
MbeSendCommand "SELECTBY ON"
MbeSendCommand "SELECTBY LEVEL ALL"
MbeSendCommand "SELECTBY TYPE ALL"
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[0]", -3&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[1]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[2]", -17&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[3]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[4]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[5]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[6]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.typemask[7]", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.colorButton", -1&
MbeSetAppVariable "SELECTBY", "selectorGlobals.color", COL
MbeSendCommand "SELECTBY CLASS ALL"
MbeSendCommand "SELECTBY EXECUTE"
MbeSendCommand "SELECTBY TYPE CELL"
MbeSendCommand "SELECTBY EXECUTE"
```

End Sub

Sub main

```
Dim saveGGLk as Integer
Dim saveMsgs as Integer
Dim elem As New MbeElement
Dim filePos As Long
Dim setMember As MbeSetMember
Dim elemSet as New MbeElementSet
```

```
saveGGLk = MbeSettings.graphGroupLock
MbeSettings.graphGroupLock = 0
MbeSendCommand "MDL LOAD SELECTBY"
For COL=0 to 255
    SELEC
    MbeSendCommand "ACTIVE COLOR "& Str$(COL)
    Mbesendcommand "Change color"
    lopp:
Next
MbeSendCommand "MDL UNLOAD SELECTBY"
MbeSettings.graphGroupLock = saveGGLk
MbeSendReset
```

End Sub

LISA 2. Microstationi programminaga kõrgusvärv.bas

'muudab horisontaalide värvikoodi nende täisarvulisele kõrgusele vastavaks
'elemendid, mis ei ole horisontaalsed saavad värvikoodi 0

Sub main

Dim pp() As MbePoint

dim p As MbePoint

Dim saveGGLk as Integer

Dim elem As New MbeElement

Dim filePos As Long

Dim setMember As MbeSetMember

Dim elemSet as New MbeElementSet

Dim col%,i%,z#

MbeSendCommand "MARK" võimaldab hiljem kasutada käsku Undo to Mark
saveGGLk = MbeSettings.graphGroupLock'salvestatakse graafiliste gruppide luku seis

MbeSettings.graphGroupLock = 0'graafiliste gruppide lukk seatakse lahtasendisse

If elemSet.fromSelectionSet(1)=MBE_Success Then 'kui failis üldse midagi on

status=elemSet.getFirst (setMember)

Do While status=MBE_Success

filePos=elem.fromFile (setMember.filePos,setMember.fileNum)

If elem.getEndPoints(p) = MBE_Success Then

z=p.z'joone alguse kõrgus

col=Fix(z)'kõrguse täisosa

If elem.getPoints(pp) = MBE_Success Then

'alguses loetakse alguspunkt, siis lõpppunkt muutujaks pp

For i=LBound(pp) To UBound(pp)'kõik joone verteksid

If z<>pp(i).z Then col=0

'kui mõni verteks on teisel kõrgusel, siis värv nullitakse

Next i

elem.color=col'joonele omistatakse uus värv

status=elem.rewrite()'element uuendatakse failis

End If

End If

status=elemSet.getNext (setMember)'järgmise joone juurde

Loop

elemSet.clear

End if

MbeSettings.graphGroupLock = saveGGLk'graafilise grupi luku algne seis taastatakse


End Sub

LISA 3. Näidisalade andmebaasis olevate üksuste klastripuu.

lühend	metsatüübi nimetus andmebaasis
an_harv	angervaksa-harvik/noorendik/raiesmik
nd_le-sega	naadi-lepa-segamets
all_lh-sega	allikasoo-leht-segamets
ld_le	lodu-hall-lepik
an_le	angervaksa-hall-lepik
sl_le	sinilille-hall-lepik
nd_le	naadi-hall-lepik
ld_sl	lodu-sanglepik
an_sl	angervaksa-sanglepik
ld_harv	lodu-harvik/noorendik/raiesmik
ss_ka	siirdesookaasik
ld_ka	lodukaasik
mds_ka	madalsookaasik
mds_sk-sega	madalsoo-sookase-segamets
jk-kds_ka	jänesekapsa-kõdusoo-kaasik
mk-kds_lh-sega	mustika-kõdusoo-lehtsegamets
ss_lh-sega	siirdesoo-leht-segamets
jk-kds_lh-sega	jänesekapsa-kõdusoo-lehtsegamets
ld_lh-sega	lodu-leht-segamets
mds_lh-sega	madalsoo-leht-segamets
ms_harv	maasika-harvik/noorendik/raiesmik
jk_ha	jänesekapsahaavik
jk-mk_ha	jänesekapsa-mustika-haavik
nd_ha	naadihaavik
ld_pj	lodupajustik
maar_pj	määratlemata pajustik
pj_Lk_LP_s	pajustik leetunud või näivleetunud mullaga söödil
pj_Ko_K_s	pajustik leostunud või rähkse mullaga söödil
sl_pa	sinilillepärnik
nd-salu	laialehine naadi-salumets
jk_lh-sega	jänesekapsa-leht-segamets
an_lh-sega	angervaksa-leht-segamets
sj_lh-sega	sõnajala-leht-segamets
jk_harv	jänesekapsa-harvik/noorendik/raiesmik
nd_harv	naadi-harvik/noorendik/raiesmik
sl_lh-sega	sinilille-leht-segamets
nd_lh-sega	naadi-leht-segamets
ka_Ko_K_s	noor kaasik leostunud või rähkse mullaga söödil
ka_E_s	noor kaasik erodeeritud mullaga söödil
jk_ka	jänesekapsakaasik
jk-mk_ka	jänesekapsa-mustika-kaasik
ms_ka	maasikakaasik
nd_ka	naadikaasik
ka_Lk_LP_s	noor kaasik leetunud või näivleetunud mullaga söödil
sl_ka	sinilillekaasik
lill_ka-sega	lillaka-kase-segamets
sega_Lk_LP_s	noor segamets leetunud või näivleetunud mullaga söödil

sega_D_G_s	noor segamets deluviaal- või gleimullaga söödil
sh_lh-sega	sinihelmika-leht-segamets
sl_ka-sega	sinilille-kase-segamets
ms_ka-sega	maasika-kase-segamets
nd_ku	naadikuusik
sl_ku	sinilillekuusik
ms_ku	maasikakuusik
mk-kds_ku	mustika-kõdusoo-kuusik
jk_ku	jänesekapsakuusik
jk-kds_ku	jänesekapsa-kõdusoo-kuusik
ss_harv	siirdesoo-harvik/noorendik/raiesmik
jk-mk_ku	jänesekapsa-mustika-kuusik
sl_harv	sinilille-noorendik/raiesmik
ph_harv	pohla-harvik/noorendik/raiesmik
nd_ok-sega	naadi-okas-segamets
lill_harv	lillaka-harvik/noorendik/raiesmik
jk-mk_harv	jänesekapsa-mustika-harvik/noorendik/raiesmik
mk_harv	mustika-harvik/noorendik/raiesmik
sj_harv	sõnajala-harvik/noorendik/raiesmik
mds_harv	madal soo-harvik/noorendik/raiesmik
mds_ma-sega	madal soo-männi-segamets
rb_ok-sega	raba-okas-segamets
all_ok-sega	allikasoo-okas-segamets
mds_ok-sega	madal soo-okas-segamets
mk-kds_ok-sega	mustika-kõdusoo-okassegamets
ss_ok-sega	siirdesoo-okas-segamets
jk-kds_ok-sega	jänesekapsa-kõdusoo-okassegamets
jk-mk_ok-sega	jänesekapsa-mustika-okassegamets
ms_ok-sega	maasika-okas-segamets
jk_ok-sega	jänesekapsa-okas-segamets
sl_ku-sega	sinilille-kuuse-segamets
lill_ok-sega	lillaka-okas-segamets
an_ok-sega	angervaksa-okas-segamets
ph_ma-sega	pohla-männi-segamets
lill_ma-sega	lillaka-männi-segamets
mk_ok-sega	mustika-okas-segamets
sl_ma-sega	sinilille-männi-segamets
ma_Lk_LP_s	noor männik leetunud või näivleetunud mullaga söödil
mk-kds_ma	mustika-kõdusoo-männik
nd_ma	naadimännik
ms_ma	maasikamännik
mk_ma	mustikamännik
rb_ma	rabamännik
ss_ma	siirdesoomännik
sl_ma	sinilillemännik
lill_ma	lillakamännik
ph_ma	pohlamännik

Euclidean distances



LISA 4. Access VBA programmimoodul Kaardilehtede_andmed

```
Option Explicit
Option Compare Database
Sub Andmekihtide_olemasolu()
'Märgib tabelisse olemasolevad andmekihid ja kärbib failide nimed neljätäheliseks
Dim dbs As Database
Dim SQLT, SQLT1, f, fs, fc, fl ' kõik on variandi tüüpi
Dim i As Integer, n As Integer
Dim laiend As String, failinimi, päring As String
Dim KID As String, väli As String, directory As String, loba As String
Set dbs = CurrentDb 'loetakse samast andmebaasist
DoCmd.SetWarnings False 'lüitab välja hoiatused, et kas soovid ikka faili nime muuta
Set SQLT = dbs.OpenRecordset("Akihid") 'avab andmekihtide tabeli
SQLT.MoveLast
n = SQLT.RecordCount 'loendab kihtide arvu
SQLT.MoveFirst
For i = 1 To n
    KID = SQLT.Fields("KID") 'kihi identifikaator
    directory = SQLT.Fields("kataloog") 'kihi kataloog
    SQLT.MoveNext
    Set fs = CreateObject("Scripting.FileSystemObject")
    If fs.FolderExists(directory) = False Then GoTo Line10 'kui kataloogi ei ole
    Set f = fs.GetFolder(directory)
    Set fc = f.files
    For Each fl In fc ' kõik selles kataloogis olevad failid
        failinimi = fl.Name
        laiend = Right(failinimi, 4) 'loeb faili laiendi
        If laiend = ".rst" Then
            väli = Left(failinimi, 4) 'kirjuta andmetabelisse, et kaardileht on olemas
            päring = "Update PK20t set [" + KID + "]=true where NR=" + väli + ";"
            On Error Resume Next
            DoCmd.RunSQL päring
            On Error GoTo Line9
        End If
        If laiend = ".rst" Or laiend = ".rdc" Then 'Eemalda_nimest_liigne_osa
            failinimi = Left(failinimi, 4) + laiend
            fl.Name = failinimi + "_"
            fl.Name = Left(failinimi, 8)
        End If
    Next
Line9:
    Next
Line10:
    Next i
    SQLT.Close
End Sub
```

LISA 5. Näidisalade fotod

Fotod: Kalle Remm, Madli Linder



Joonis 1. Pohlamänniku näidis.



Joonis 2. Alustaimestik pohlamänniku näidiskohas.



Joonis 3. Lillakamänniku näidis.



Joonis 4. Alustaimestik lillakamänniku näidiskohas.



Joonis 5. Mullaprofiil põhlamänniku näidiskohas.



Joonis 6. Mullaprofiil lillaka-männi-segametsa näidiskohas.



Joonis 7. Mustikamänniku näidis.



Joonis 8. Jänesekapsa-mustika-kaasiku näidis.



Joonis 9. Alustaimestik jänesekapsa-mustika-okas-segametsa näidiskohas.



Joonis 10. Jänesekapsakaasiku näidis.



Joonis 11. Alustaimestik jänesekapsakaasiku näidiskohas.



Joonis12. Maasika-okas-segametsa näidis.



Joonis13. Alustaimestik maasika-kase-segametsa näidiskohas.



Joonis 14. Mullaprofiil maasikakaasiku näidiskohas.



Joonis 15. Maasika-okas-segametsa näidiskohas teeservas paljanduv mullaprofiil.



Joonis 16. Sinilille-leht-segametsa näidis.



Joonis 17. Alustaimestik sinilille-kase-segametsa näidiskohas.



Joonis 18. Mullaprofiil sinilille-leht-segametsa näidiskohas.



Joonis 19. Naadi-leht-segametsa näidis.



Joonis 20. Alustaimestik naadi-leht-segametsa nädiskohas.



Joonis 21. Sõnajala-leht-segametsa näidis.



Joonis 22. Angervaksa-hall-lepiku näidis.



Joonis 23. Alustaimestik angervaksa-hall-lepiku näidiskohas.



Joonis 24. Lodu-leht-segametsa näidis.



Joonis 25. Alustaimestik lodu-leht-segametsa näidiskohas.



Joonis 26. Madalsookaasiku näidis.



Joonis 27. Alustaimestik madalsoo-männi-segametsa näidiskohas.



Joonis 28. Siirdesookaasiku näidis.



Joonis 29. Rabamänniku näidis.



Joonis 30. Alustaimeestik rabamänniku nädiskohas.



Joonis 31. Mustika-kõdusoo-kuusiku näidis.



Joonis 32. Alustaimestik mustika-kõdusoo-männiku näidiskohas.



Joonis 33. Jänesekapsa-kõdusoo-kaasiku näidis.



Joonis 34. Karjamaade vahelises sulglohus kasvava pajustiku näidis.



Joonis 35. Lodupajustiku näidis.



Joonis 36. Alustaimestik lodupajustiku näidiskohas.