

KAUGSEIRE EESTIS

2021

Artiklikogumik



TARTU ÜLIKOO



Eesti Maaülikool
Estonian University of Life Sciences

WWW.ORTU.EE



KESKKONNAAGENTUUR

KAUGSEIRE EESTIS

2021

Artiklikogumik



TARTU ÜLIKOOL

Tartu observatoorium

1632

Toimetaja: Urmas Peterson
Eesti keele toimetaja: Sirje Nilbe
Inglise keele toimetaja: Krista Kallis
Küljendus: Marja-Liisa Plats
Kaane kujundus: Triinu Sarv
Kaanepilt: Viljo Alliku droonifoto Võrtsjärve rannikust Tammel juulis 2018

Väljaandja:
Tartu Ülikooli Tartu observatoorium
Observatooriumi 1, Tõravere
Nõo vald, 61602 Tartumaa
Tel: 737 4510
E-post: kosmos@ut.ee

Autoriõigus: artiklite autorid ja Tartu Ülikool, 2022

ISSN 2382-7653

Kogumiku väljaandmist toetasid:
Tartu Ülikool, Eesti Maaülikool ja Keskkonnaagentuur

Sisukord

- 7 Kaanepildile lisaks**
- 10 Maapealse tugiväärtuse mõõtmine satelliitkaugseire andmete valideerimiseks**
Riho Vendt, Viktor Vabson, Ilmar Ansko, Joel Kuusk
- 22 Sinivetikate põhjustatud veeõitsengud Peipsi järves ja satelliidivõimalused nende märkamiseks**
Kersti Kangro, Anne-Mai Pall, Krista Alikas
- 35 Fütoplanktoni primaarproduktiooni modelleerimine Sentinel-3 andmete põhjal Eesti ja Läti järvede näitel**
Tuuli Soomets, Kristi Uudeberg, Kersti Kangro, Kaire Toming, Tiit Kutser
- 53 Sentineli satelliitide andmetel põhinev operatiivne jääseireteenus**
Sander Rikka, Liis Sipelgas, Martin Simon, Jekaterina Služenikina, Laura Siitam, Rivo Uiboupin
- 65 Sentinel-3 satelliitaltimeetria andmete valideerimine Eesti rannikuvetes ja suuremates järvedes**
Ivar Kapsi, Kadi Õunas, Tarmo Kall, Aive Liibusk
- 75 Kuumasaarte ning neid mõjutavate tegurite tuvastamine Tartu linnaruumis mehitamata õhusõidukite abil**
Kaupo Kokamägi, Miguel Villoslada Peciña, Raul Sampaio De Lima, Kalev Sepp
- 86 Kaamerate kasutamine riiklikus seires ning tehisintellekti loomine tulemuste analüüsimiseks**
Rauno Veeroja, Mart Thalfeldt, Einar Kärgenberg, Timo Kark

- 99 Konvektiivsete tormide klimatoloogia Eestis lähtuvalt radariandmetest ja keskkonnatingimustest**
Tanel Voormansik, Tuule Mürsepp, Piia Post
- 111 Tüüplahendused kaugseire lõimimiseks pideva metsakorralduse süsteemi**
Mait Lang
- 121 Kaugseiremeetoditega metsaressursi hindamise täpsuse analüüs**
Allan Sims
- 130 Metsa statistiline peegeldusmudel**
Andres Kuusk, Joel Kuusk, Mait Lang

Kaanepildile lisaks

Urmas Peterson

Roostikud, üldisemalt kaldaveetaimestiku lapid on objektid, mis Eesti suurjärvede Võrtsjärve ja Peipsi järve ning Läänemere rannikuil kuuluvad riiklikku seireprogrammi. Satelliitide Landsat ja Sentinel-2 keskmise ruumilise lahutusega piltide põhjal koostatud roostike pindalamõõtmiste aegrida ulatub tagasi aastani 1985 (Landsat) ja aastani 2015 (Sentinel-2).


Joonisel 1 on näidatud Võrtsjärve suurtaimestiku lappide kaart. Tähelepanuväärne, et suurtaimestiku lapid vastavad kaardi mõõtkavale, oma suuruse tõttu on nad järve ülevaatekaardil märgatavad. Kõige ulatuslikumad suurtaimestiku lapid paiknevad looderannikul järve suubuva Tănassilma jõe suudmelahel lähikonnas, edelarannikul, Kivilõppe ümbruses ja järve lõunasopis. Viimasel alal on tegemist eeskätt ujulehtedega taimestikuga. Roostiketa on vaid lühike rannikulõik kagurannikul Vehendi ja limnoloogiajaama vahel ning tükati looderannikul Valma küla all. Järvele avanevate vaadete avardamiseks on Valma küla all eluhoonetega rannikulõikudel roostikku tõrjutud.

Võrtsjärve rannikul on lõike, kus satelliidipiltidega kaetud ajavahemiku jooksul on suurtaimestikuga ala silmapaistvalt laienenud. Tähelepanuväärne on see olnud järve looderannikul (vt joonis 2).


Teisal on suurtaimestikuga ala pindala sama ajavahemiku jooksul vähe muutunud, tähelepanuvõrt on muutunud vaid suurtaimestiku lappide kuju. Nii on see olnud järve lõunasopis Väikese Emajõe suudme ümbruses (vt joonis 3).



Joonis 1. Võrtsjärve suurtaimestiku lappide kaart, kujutatud on 2020. a suvine situatsioon. Suurtaimestiku lapid on kaardil mõõtkavalised: lapid on samas mõõtkavas, milles järv ise.

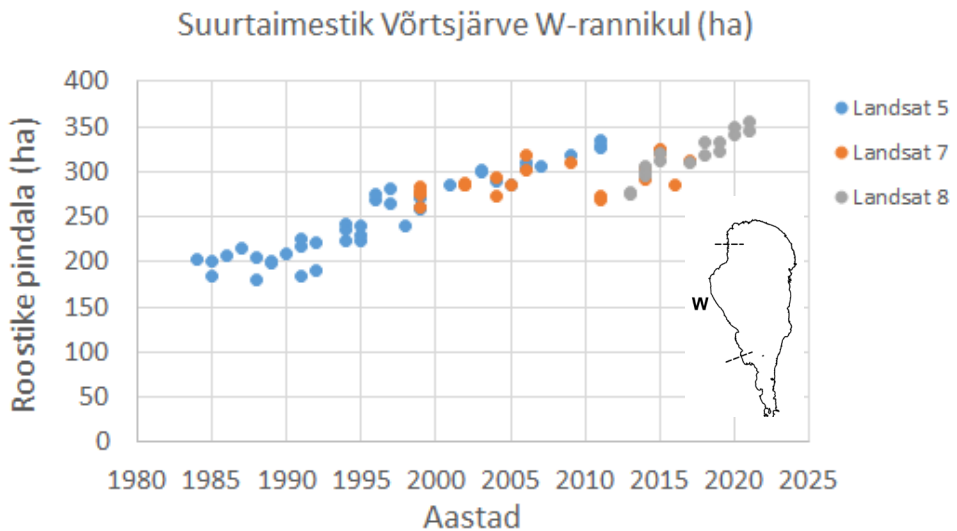


Joonis 2. Järve looderannikul Tänassilma jõe suudmelahel on suurtaimestiku lappidega kolmekümne viie aasta kestel toimunud silmapaistev muutus. Laienenud on pilliroo ja ujulehtedega taimeestikuga kaetud ala järvel.



Joonis 3. On neidki Võrtsjärve osi, kus suurtaimestiku lappide pindala pole kolmekümne viie aasta jooksul oluliselt muutunud, lapid on vaid aastate kestel muutnud oma kuju. Üheks suurtaimestikuga kaetuse osas vähe muutunud alaks on järve lõunasopp Väikese Emajõe suudmeala ümbruses.

Satelliidipiltide põhjal tehtud roostikulappide pindalahinnangute aegreast nähtub valdav trend – suurtaimestiku lappide pindala suurenemine järve rannikul (vt joonis 4). Võrtsjärve suurtaimestiku seire praeguseks kolmekümne viie aasta pikkune aegrida ületab ühe satelliidiskanneri tehnilise „eluea“ pikkust. Aegreas on esindatud mõõtmiste tulemused kolme erineva Landsat-seeria satelliidi skannerite piltidelt. Nende skannerite ruumilise ja spektraalse lahutuse sarnasuse tõttu võiks eeldada, et tulemustes on süstemaatilised erinevused vähemärgatavad. Võrtsjärve roostike pindalahinnangute tulemuste puhul näib see nii ka olevat.



Joonis 4. Suurtaimestiku lappide pindala hektareis Võrtsjärve läänerannikul (W). Pispildil on näidatud lääneranniku (W) kokkuleppeline ulatus järve rannajoonel. Kolme erineva, kuigi sama seeria Landsat-satelliitide piltidelt tekitatud tulemused on näidatud erineva värviga. Mitme aasta suvekuudel on satelliidid pildistanud järve mitmel korral. Eeldatavalt sama tulemuse varieerumine mõnel aastal annab aimu Võrtsjärve roostikulappide pindalahinnangute määramatusest keskmise ruumilise lahutusega satelliidipiltide puhul.

Maapealse tugiväärtuse mõõtmine satelliitkaugseire andmete valideerimiseks

Riho Vendt, Viktor Vabson, Ilmar Ansko, Joel Kuusk

Tartu Ülikool, Tartu observatoorium, Tõravere, Nõo vald, 61602 Tartumaa

Kokkuvõte

Satelliitkaugseire võimaldab hinnata meie planeedi tervist. Iga otsus, mis aitab kaasa keskkonna säästmisele, peab põhinema usaldusväärsetel andmetel. Satelliitide abil kogutud seireandmete usaldusvärsuse kinnitamiseks tuleb kohapealse tegeliku olukorra hindamiseks teha maapealse tugiväärtuse mõõtmisi (inglise keeles tähistatud terminiga *fiducial reference measurements* ehk FRM), mis peavad vastama kindlatele kvaliteedinõuetele. Näiteks peab olema tagatud mõõtmiste jälgitavus rahvusvahelise mõõtühikute süsteemi SI koos sinna juurde kuuluva määramatuse hinnanguga. Selliste usaldusväärsete tugiväärtuse mõõtmiste jaoks satelliitkaugseires on Euroopa Kosmoseagentuur (ESA) ja Euroopa Meteoroloogiasatelliitide Kasutamise Organisatsioon (EUMETSAT) algatanud mitu spetsiaalse suunitlusega FRM projekti. Artiklis on püütud pakkuda ingliskeelses teaduskirjanduses levinud uudsetele mõistetele eestikeelseid vasteid. Samuti on toodud näiteid usaldusväärse tugiväärtuste mõõtmise olulistest nõuetest vee kaugseirele suunatud projekti FRM4SOC abil, mida juhivad Tartu Ülikooli Tartu observatooriumi teadlased.

Võtmesõnad: tugimõõtmised, SI-jälgitavus, mõõtemääramatus, kalibreerimine, karakteriseerimine

Sissejuhatus

Kaasaegne ühiskonnakorraldus toetub meie planeedi loodusvarade kasutamisele. Inimkonna jätkusuutlikkus ja areng sõltuvad nende varade vastutustundlikust kasutamisest, samas kui kasvav rahvastik vajab üha enam elamiseks sobivaid elupaiku, värsket vett, viljakat maad ja puhast õhku. Me seisame silmitsi mitmete ülemaailmsete ohtudega, nagu näiteks kliimamuutused, energia- ja toidunappus, sagenevad ning paisuvad loodus- ja inimtekkelised kataastroofid. Järjest rohkem omab iga tehtud valik elulist tähtsust meie säilimise ja toimetuleku kindlustamisel.

Õigete otsuste tegemiseks vajame aga head arusaamist meie ümber toimuvast. Iga päev kogutakse Maa tehiskaaslaste, lennukite ja maapealsete mõõtevõrgustike abil suurel hulgal mõõteandmeid. Näiteks on globaalse kliimavaatluse süsteemi (GCOS) raames defineeritud 54 olulist kliimamuutujat (*Essential Climate Variable*, ECV), mille kohta kogutavad pika-ajalised aegread aitavad meil jälgida ja mõista meie planeedil toimuvaid muutusi [1]. Üheks selliseks andmete kogumise vahendiks on Euroopa Komisjoni ja Euroopa Kosmoseagentuuri (ESA) koordineeritud Maa kaugseireprogramm Copernicus [2, 3], mis võimaldab saada andmeid korruga suurtelt ja raskesti ligipääsetavalt maa-aladelt. On hinnatud, et üle poolte defineeritud kliimamuutujate kohta on võimalik andmeid koguda ainult satelliitkaugseire meetodeid rakendades ja ülejäänutest poolte puhul on möödapääsematu nende osaline rakendamine [4].

On jõutud ühisele arusaamisele, et kogutavad kaugseireandmed peavad olema usaldusväärsed ja kõrge kvaliteediga [4–6]. Erinevate agentuuride, teadusastutuste ja ettevõtete poolt kogutavate andmete kvaliteedi ühtlustamiseks on kokku lepitud, et järgitakse ühtseid põhimõtteid (*Quality Assurance Framework for Earth Observation*, QA4EO) [4, 7]. Üheks oluliseks põhimõtteks mõõtetulemuste usaldusväärsuse tagamisel on, et kõik kasutatavad mõõtühikud lähtuvad samast lähteallikast ja on sellega kindlalt seotud. Selleks ühtseks allikaks on 1875. a 20. mail sõlmitud meetrikonventsiooni alusel rahvusvaheline mõõtühikute süsteem (SI) [8, 9]. Väärib märkimist, et 19. jaanuaril 2021 allkirjastas Eesti meetrikonventsiooni ja sai selle täisliikmeks. Assotsieerunud liige oli Eesti alates 2007. aastast. Teiseks oluliseks põhimõtteks on, et kõik kaugseire mõõtetulemused peavad sisaldama realistlikku määramatuse hinnangut, mille kehtivust on sõltumatult kontrollitud.

Seireandmete usaldusväärsuse tagamise vajadus

Satelliitkaugseire peamiseks eeliseks on võimalus katta mõõtmistega suuri ning raskesti ligipääsetavaid piirkondi. Samuti on võimalik nende mõõtmiste regulaarne kordamine suhteliselt lühikese ajavahemiku järel, mistõttu saab andmeid koguda ja analüüsida peaaegu reaajas (*Near Real Time*, NRT). Proovikiviks on aga mõõteandmete usaldusväärsuse tagamine. Mõõtetulemuste seostamiseks SI ühikutega koos sinna juurde kuuluva mõõtemääramatuse hinnanguga ehk metroloogilise jälgitavuse (*metrological traceability*) esmaseks tagamiseks kalibreeritakse satelliitidel asuvad mõõteandurid enne kosmosesse lähetamist maapealsetes laborites. Probleeme seireandmete usaldusväärsuse tagamisel on mitmeid.

Näiteks on hinnatud, et ühte vee kaugseire olulist kliimamuutujat – klorofüllil sisaldust vees – oleks kaugseire meetodeid kasutades vaja mõõta umbes 30% määramatusega, mis eeldab veest väljuva kiirguse kirkuse (*radiance*) L_w mõõtmist määramatusega 5% ning atmosfääriparandi suure osakaalu tõttu eeldab see omakorda satelliitsensorite kirkuse mõõtmise määramatust 0,5% tasemel [10–12]. Sellise

mõõtemääramatuse tagamine kosmoses kogu missiooni jooksul on aga tõeline väljakutse. Seetõttu on peale seirevahendite kosmosesse lähetamist vaja hinnata,

- kuidas karmid tingimused (nt vibratsioon, põrutused, äkilised temperatuurimuutused) kosmoseraketi stardi ajal mõjutasid kalibreeritud mõõteseadmete omadusi;
- millisel määral vananevad andurid orbiidil kasutamise käigus;
- kuidas muudab atmosfäär seda läbivaid valgussignaale.

Mõõteseadmete muutusi on vaja püsivalt jälgida, kuid erinevalt tavapära-
stest mõõteseadmetest ei ole võimalik tehiskaaslast kalibreerimiseks laborisse tagasi tuua. Ka valgussignaali mõjureid pikal teel Maalt orbiidile on üsna raske piisavalt täpselt hinnata.

Seireandmete metrooloogilise jälgitavuse tagamise meetodid

Satelliitide mõõteandurite omaduste ja nende ajaliste muutuste hindamiseks on kasutusel järgmised meetodid:

- kalibreerimine maapealsetes laborites enne lähetamist kosmosesse;
- kalibreerimine orbiidil, kasutades
 - satelliidi pardale paigutatud spetsiaalseid tugietalone (nt peegelduspaneelid, musta keha kiirgurid, valgusallikad);
 - stabiilseid looduslikke objekte (Päikese kiirgus, Kuult peegeldunud kiirgus);
- stabiilsuse hindamine, mõõtes perioodiliselt Maal asuvaid stabiilseid looduslikke ja tehislikke objekte (kõrbed, peegelduspaneelid, aktiivkiirgurid);
- satelliitidevaheline võrdlusmõõtmine:
 - tandemina orbiidil liikuvate satelliitide mõõtetulemuste võrdlus;
 - Maal asuvate stabiilsete looduslike ja tehislake objektide (aktiivkiirgurid, peeglid) mõõtmine üksteise järel;
- arendusjärgus on nn kosmose-kalibreerimislaborid, mis pakuvad andurite kalibreerimiseks orbiidil SI-jälgitavusega mõõteallikaid; sellised on näiteks NASA missioon CLARREO [13], Hiina kosmoseagentuuri projekt LIBRA [14] ning NPL ja ESA ühisarendus TRUTHS [15].

Kosmoses kogutud kauge-seireandmete ja maapealset tegelikku olukorda kirjeldavate mõõtmiste süstemaatiliste erinevuste parandamiseks on vajalikud maapealsed tugimõõtmised (nn satelliidiandurite vikaarkalibreerimine) [4, 6, 10].

Maapealse tugiväärtuse mõõtmine

Mõõtes kosmosest spektroskoopia ja radiomeetria meetodite abil maapealsete objektide omadusi on üheks olulisemaks mõjuriks mõõteandurite ja sihtmärgi vahel asuv atmosfäärikiht [6]. Atmosfääri ja vikaarkalibreerimise parandeid rakendades peame veenduma, et parandid ja algoritmid oleksid õiged ning usaldusväärsed. Selleks peame teadma satelliitide poolt mõõdetud ala tegelikku olukorda maapinnal (*ground truth*). Kohaliku „tõe“ väljaselgitamiseks tehakse (*in-situ*) atmosfääri-aluseid kohtmõõtmisi, kuid ka parimate riistade ja mõõtemetodite puhul ei ole mõõdetavate parameetrite tõelise väärtuse määramine põhimõtteliselt võimalik. Suudame parameetreid hinnata vaid mingi kindla mõõtemääramatuse piires. Eesmärgiks on, et pärast kogutud satelliidiandmete parandamist ja nende usaldusväärsuse hindamist – valideerimist – jääks seireandmete mõõtemääramatus defineeritud kliimamuutujate jälgimisele seatud piiridesse.

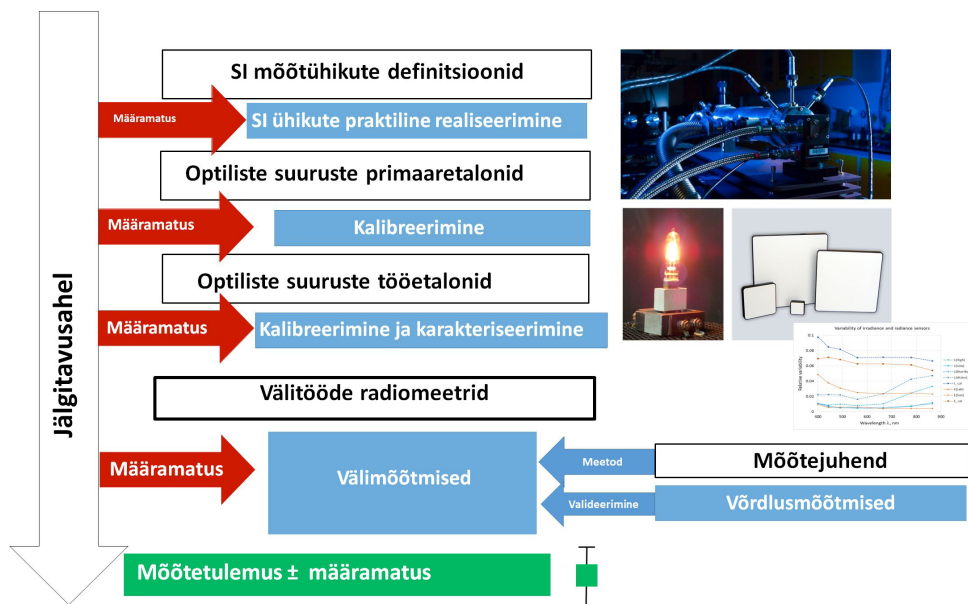
Rangetele kvaliteedinõuetele vastavaid maapealsete tugiväärtuste mõõtmisi on hakatud nimetama ühtse ingliskeelse terminiga *Fiducial Reference Measurements* ja tähistama lühendiga FRM, mis viimasel ajal on laialt levinud kaugseirealases teaduskirjanduses.

Ingliskeelne sõna *fiducial* pärineb ladinakeelsest sõnast *fidus* (usaldusväärne, kindel) ja märgib usaldusväärset tugiväärtust või objekti – näiteks temperatuuri-skaalat defineeriva kinnispunkti (aine sisemistele füüsikalistele omadustele vastava faasisiirde) temperatuuri, kujutisele objekti suuruse hindamiseks lisatud absoluut-skaala mõõtemärke või siis usaldusväärsust üldiselt. Käesoleva artikli autorid on varasemalt mõiste FRM eestikeelseks üldiseks vasteks pakkunud *usaldusväärse tugiskaala määramine* [6]. Konkreetsete kohtmõõtmiste kontekstis võiks seda mõistet nimetada ka *maapealse tugiväärtuse usaldusväärseks mõõtmiseks* või lihtsalt *maapealse tugiväärtuse mõõtmiseks*.

Maapealse tugiväärtuse usaldusväärsed mõõtmised (FRM) on defineeritud kui *maapealsete sõltumatute mõõtmiste kogum, mis aitab saavutada satelliidimissiooni parimat investeringutasuvust, kindlustades tarbijatele satelliitkaugseire andmeproduktide ootuspärase usaldusväärsuse sõltumatute valideerimistulemuste ja mõõtemääramatuse hinnangu abil kogu satelliidimissiooni eluea jooksul* [16].

Tugiväärtuse usaldusväärsel mõõtmisel on järgmised omadused (joonis 1) [16, 17]:

- mõõtetulemustel on **dokumenteeritud metrooloogiline jälgitavus rahvusvahelise mõõtühikute süsteemini (SI)**;
- kõikide kasutatavate mõõtevahendite ja protseduuride jaoks on olemas mõõtemääramatuse hinnangud;
- kasutatakse üksikasjalikult kirjeldatud ja rahvusvaheliselt tunnustatud **mõõtemetodit** (juhendit/eeskirja, ingl k *protocol*; sh mõõteprotseduurid, andmetöötlus, andmehõive ja -säilitus jne);
- mõõtetulemused on kogutud satelliidimõõtmistest sõltumatult;
- mõõtetulemused on kontrollimiseks avalikud ja vabalt kättesaadavad.



Joonis 1. Maapealse tugiväärtuse mõõtmise usaldusväärsuse tagamise põhimõtteskeem vee kaugseires.

Näiteid maapealse tugiväärtuse usaldusväärsest mõõtmisest

Copernicuse missiooni raames kogutavate satelliitkaugseireandmete usaldusväärsuse tagamiseks on Euroopa Kosmoseagentuur algatanud mitu FRM projekti maapealse tugiväärtuse usaldusväärseks mõõtmiseks. Näiteiks on atmosfääri koostise (FRM4AC), altimeetria (FRM4ALT), radarkaugseire (FRM4SAR), kasvuhoonegaaside (FRM4GHG) ja merepinna temperatuuri (FRM4STS) projektid [18].

Nende algatuste seas oli Tartu Ülikooli Tartu observatooriumi teadlastel oluline roll satelliitide abil veekogude pinnalt peegeldunud valguse spektri ehk vee värvuse (SOC – *Satellite Ocean Colour*) maapealse tugiväärtuse mõõtmise meetodite arendamise ja rakendamise projektis FRM4SOC (2016–2019). Projekti juhtis Tartu Ülikooli Tartu observatoorium ja partneriteks olid National Physical Laboratory ja Plymouth Marine Laboratory Ühendkuningriigist, Royal Belgian Institute of Natural Sciences Belgiast ning tunnustatud ettevõtte ACRI-ST Prantsusmaalt [17, 19]. Eelkõige lähtuti tugiväärtuse usaldusväärsete mõõtmiste definitsiooni kohaste omaduste tagamisest vee kaugseires.

Selleks

- töötati läbi ja uuendati seni rakendatud kaugseire peegeldumisspektri mõõtejuhend [20, 21];


- kaardistati põhiliste vee kaugseires kasutatavate radiomeetrite tehnilised parameetrid;
- korraldati kaugseire radiomeetrite kalibreerimiseks kasutatavate kirkuse (*radiance*) ja kiiritustiheduse (*irradiance*) mõõtetalonide võrdlusmõõtmine [22];
- korraldati kirkuse ja kiiritustiheduse võrdlusmõõtmine vee kaugseire radiomeetritega labori- ja välitingimustes [23, 24];
- korraldati veest väljuva valguse spektraalse kirkuse võrdlusmõõtmine spetsiaalsel mere uurimisplatvormil Veneetsia lahes [25];
- korraldati vee peegeldusspektri võrdlusmõõtmine Atlandi ookeanil sõitval uurimislaeval [26];
- koostati mõõtemääramatuse hinnangud kaugseire radiomeetrite kalibreerimisel laboris ja kasutamisel välitingimustes [27].

Projekti FRM4SOC tulemused on kokku võetud teadusajakirja Remote Sensing erinumbris [28]. Peamise järeldusena leidis kinnitust, et mõõtevahendite omaduste uurimine ja kalibreerimine, mõõtemääramatuse hindamine, lähtumine ühtsetest mõõtejuhenditest ja mõõtetulemuste kooskõla/ekvivalentsuse hindamine võrdlusmõõtmiste abil on mõõteandmete usaldusväärsuse tagamise vältimatud eeltingimused.

FRM sensorite radiomeetriline kalibreerimine võimaldab konkreetse sensori väljundsignaali ümber arvutada SI ühikute skaalale vastavaks spektriiks koos sinna juurde kuuluva määramatusega. Sellisel moel on võimalik erinevate sensorite abil kogutud mõõtetulemusi kergesti omavahel võrrelda ja kasutada. Sensorite SI-põhise radiomeetrilise kalibreerimise olulisus on näha joonisel 2.

Võrdlusmõõtmisele laekunud riistad olid kalibreeritud eri aegadel eri laborite ja tootajafirmade poolt. Joonisel 2 tähistavad sümbolid L(enne_kal) ja E(enne_kal) kirkuse ja kiiritustiheduse sensorite mõõtetulemuste suhtelist hajuvust stabiilsetes laboritingimustes vanade kalibratsioonikoefitsientide rakendamisel, L(Lab) ja E(Lab) sama pärast TO optikalaboris teostatud kalibreerimise tulemuste rakendamist ning sümbolid L(Vesi), L(Taevas) ja E(Päike) erinevust looduslike kiirguste mõõtmisel Kääriku järvel tavapärastes välitingimustes.

Kui pärandkalibratsioonide rakendamisel oli paarikümne võrdlusel osalenud kirkuse ja kiiritustiheduse sensori mõõtetulemuste hajuvus laboratoorsetel mõõtmistel (6–9)%, siis Tartu observatooriumi laboris vahetult enne võrdlusmõõtmisi läbi viidud kalibreerimine vähendas tulemuste hajuvuse 1%-ni. Välimõõtmistel ilmnisid ikkagi üsna suured suhtelised erinevused, mis küündisid nii kirkuse kui ka kiiritustiheduse sensorite korral kuni 5%-ni. Seega ainuüksi mõõtevahendite radiomeetrisest kalibreerimisest, mis loob sensori väljundsignaali seose SI ühikutega, ei piisa, kuna keskkonnatingimused kalibreerimislaboris ja mõõtevahendite hilisemal kasutamisel võivad olla üsna erinevad ja keskkonnatingimused mõjuvad erinevaid sensoreid eri viisil. Seetõttu tuleb kasutatavaid mõõtevahendeid täiendavalt iseloomustada (karakteriseerida) ning mõõtetulemuste arvestamiseks rakendada mitut individuaalset parandit, et saavutada kliimamuutujate andmestiku



Joonis 2. Kiiritustiheduse ja kirkuse sensorite mõõtetulemuste suhteline hajuvus laboroorsetes ja välitingimustes enne ja pärast Tartu observatooriumi optikalaboris läbi viidud radiomeetrilise kalibreerimise koefitsientide rakendamist.

kogumisel vajalik mõõtemääramatuse tase. Oluline on ümbritseva keskkonna võimalike temperatuurierinevuste kompenseerimine, mittelineaarsusparandi rakendamine, sisendoptika erinevustest põhjustatud efektide hindamine, hajuvalguse parandi rakendamine jne. FRM instrumentide tähtsamate kalibreerimiste ja karakteriseerimiste nimekiri, mis peaks kindlustama tugimõõtmiste määramatuse jäämise etteantud vastuvõetavatesse piiridesse, ja tugimõõtmiste määramatuse arvutamiseks tarvilik lisainfo on esitatud tabelis 1. FRM mõõtmiste määramatuse arvutamiseks on peale mitmesuguste sensoripõhiste parandustegurite tarvis mõõta või hinnata seotud keskkonnaparameetreid, kuna enamik parandeid sõltub keskkonnatingimuste erinevusest kalibreerimise ja FRM mõõtmise ajal.

Mõõtetulemuste ning -määramatuse hinnangute paikapidavuse kontrolliks tuleb viia läbi spetsiaalseid võrdlusemõõtmisi. Suured sensoritevahelised erinevused ilmnevad ainult siis, kui mõõtmistingimused erinevad oluliselt kalibreerimisaegsetest laboritingimustest ja sensorid reageerivad keskkonnatingimustele erinevalt. Näiteks kui kahel sensoril on sarnased (karakteriseerimata ja kompenseerimata) temperatuurikoefitsiendid, võivad nad anda välimõõtmiste kogu temperatuurivahemikus kooskõlalisi (valesid) mõõtetulemusi. Selliste süstemaatiliste hälvete avastamiseks on tarvis võrdlusemõõtmistel kaasata täpne (st keskkonnatingimuste kogu muutumispiirkonnas täielikult karakteriseeritud) tugiradiomeeter, mis kindlustaks FRM radiomeetrite tulemuste hindamiseks usaldusväärsed SI-põhised tugiväärtused. Siiski avastati FRM4SOCi võrdlusemõõtmiste käigus isegi ilma

tugiradiomeetri kaasamiseta selliseid mõõtevigade allikaid, mis tavapärase mõõtmise puhul ei oleks ilmnenud – näiteks mõnede kiiritustiheduse radiomeetrite teistega võrreldes tugevasti hälbiv sõltuvus mõõdetava kiirguse nurkjaotusest [17].

Tabel 1. FRM instrumentide olulisimate kalibreerimise ja karakteriseerimise nimekiri ja vastavate parandite määramatuse arvutamiseks tarvilik lisainfo [29].

Hinnatav parameeter	Tarvilik lisainfo
Spektraalne radiomeetriline tundlikkus	Etalonlambi SI-põhine spekter ja selle radiomeetriga mõõdetud spekter
Tundlikkuse muutumine	Kalibreerimisandmete ajalugu
Spektraalne hajuvallus ja/või mõõtepiirkonnaväline kiirgus	Radiomeetriga mõõdetud FRM ja kalibreerimisspektrite erinevus
Kiiritustiheduse sensori nurksõltuvus	FRM spekter, kiirguse nurksõltuvus
Kiiritustiheduse sensori sukeldustegur	FRM spekter, kiirguse nurksõltuvus
Mittelineaarsus / säriaja sõltuvus	Radiomeetri kalibreerimise ja FRM spektrite erinevus, pimespektrid
Temperatuuritundlikkus	FRM spekter, temperatuuride erinevus kalibreerimisel ja FRM mõõtmisel
Pimesignaali	FRM spekter, säriajaga ja optilise sensori temperatuur FRM mõõtmisel
Signaalimüra suhe	FRM spekter, säriajaga ja optilise sensori temperatuur FRM mõõtmisel
Polarisatsioonitundlikkus	FRM kiirguse polarisatsioon
Kirkuse sensori sukeldustegur	FRM spekter, kiirguse nurksõltuvus
Kirkuse sensori nurksõltuvus	FRM spekter, kiirguse nurksõltuvus

Kokkuvõte

Satelliitkaugseire andmete usaldusvärsuse tagamiseks on vaja võrrelda orbiidilt kogutud andmeid usaldusväärsete *in-situ* mõõtmistulemustega. Selleks tehakse kindlaksmääratud kvaliteedinõuetele vastavaid *maapealse tugiväärtuse mõõtmisi*, mida tähistatakse inglise keelest tuleneva lühendiga FRM. Kogutud andmete

põhjal on näha, et mõõtesensorite SI-põhine kalibreerimine on vältimatu tingimus. Samas, ainuüksi kalibreerimisest ei piisa mõõtetulemuste usaldusväärsuse saavutamiseks. Mõõtmistel tuleb lähtuda ühtsetest mõõtejuhenditest ning vaja on objektiivselt hinnata kõiki mõõtetulemust mõjutavaid tegureid. Selleks on vajalik mõõtevahendite täiendav iseloomustamine (karakteriseerimine) kõikide oluliste mõjurite osas. FRM mõõtetulemuste määramatuse vähendamiseks, usaldusväärsuse suurendamiseks ning mõõtjate ja andmete lõppkasutajate töö lihtsustamiseks tuleb rakendada mitmesuguseid meetmeid. Näiteks: 1) kindlustada mõõtjad infoga, mis on tarvilik kõigi oluliste süstemaatiliste vigade parandamiseks; 2) seada eri mõjuritest tulenevatele vigadele lubatud piirväärtused ja võimalusel hoida kontrolli all need parameetrid, mille korral nendest põhjustatud vigade efektiivne parandamine ei ole võimalik või on võimalik vaid piiratud juhtudel; 3) arendada uut tüüpi sensoreid, mille omadused võimaldavad vähendada mõjurite arvu ja panust. Nende tegevuste rakendamiseks on Euroopa Komisjon algatanud ESA ja EUMETSATi vahendusel mitu FRM projekti. Tartu Ülikooli Tartu observatooriumi teadlased koordineerivad vee kaugseire projekti FRM4SOC.

Tänuavaldus

Projekti FRM4SOC rahastas Euroopa Kosmoseagentuur (ESA, leping nr 4000117454/16/I-Sbo). Projekti FRM4SOC Phase-2 rahastab Euroopa Komisjon ja koordineerib Euroopa Meteoroloogiasatelliitide Kasutamise Organisatsioon (EUMETSAT, leping nr EUM/CO/21/460002539/JIG).

Viidatud kirjandus

1. „Global Climate Observing System (GCOS)“. <https://gcos.wmo.int/en/home> (vaadatud 9. mai 2022).
2. A. Reinart ja A. Vain, „Copernicus – Euroopa jälgib Maad“, *Kaugseire Eestis 2016. Artiklikogumik*, Tõravere: Tartu Observatoorium, 2016, lk 9–17.
3. „Copernicus programme“. <https://www.copernicus.eu> (vaadatud 9. mai 2022).
4. E. R. Woolliams *et al.*, „European Metrology Network for Climate and Ocean Observation. Stakeholders needs review report 2020.“ EURAMET, 23. dets 2020.
5. BIPM, „Comptes Rendus de la 20e reunion de la Conference Generale des Poids et Measures“. BIPM, 1996. <https://www.bipm.org/en/committees/cg/cgpm/publications> (vaadatud 9. mai 2022).
6. V. Vabson *et al.*, „Mõõtmiste usaldusväärsus kaugseires“, *Kaugseire Eestis 2016. Artiklikogumik*, Tõravere: Tartu Observatoorium, 2016, lk 18–27.
7. QA4EO, „A Quality Assurance Framework for Earth Observation: Principles“. QA4EO, 2010.
8. BIPM, *The international system of units (SI)*, 9. tr. Sèvres: BIPM, 2019.

9. „Metre Convention - BIPM“. <https://www.bipm.org/en/metre-convention> (vaadatud 9. mai 2022).
10. IOCCG, „Report, ‘Atmospheric Correction for Remotely-Sensed Ocean-Colour Products’“, 10, 2010. <https://ioccg.org/what-we-do/ioccg-publications/ioccg-reports/> (vaadatud 9. mai 2022).
11. H. R. Gordon ja M. Wang, „Retrieval of water-leaving radiance and aerosol optical thickness over the oceans with SeaWiFS: a preliminary algorithm“, *Appl. Opt.*, *AO*, kd 33, nr 3, lk 443–452, jaan 1994, doi: 10.1364/AO.33.000443.
12. M. Wang, „Remote sensing of the ocean contributions from ultraviolet to near-infrared using the shortwave infrared bands: simulations“, *Appl. Opt.*, *AO*, kd 46, nr 9, lk 1535–1547, märts 2007, doi: 10.1364/AO.46.001535.
13. „CLARREO Pathfinder“. <https://clarreo-pathfinder.larc.nasa.gov/> (vaadatud 9. mai 2022).
14. P. Zhang *et al.*, „Development of the Chinese Space-Based Radiometric Benchmark Mission LIBRA“, *Remote Sensing*, kd 12, nr 14, Art. nr 14, jaan 2020, doi: 10.3390/rs12142179.
15. „TRUTHS“, *NPLWebsite*. <https://www.npl.co.uk/earth-observation/truths> (vaadatud 9. mai 2022).
16. G. Zibordi ja C. J. Donlon, „Chapter 5 - In Situ Measurement Strategies“, *Experimental Methods in the Physical Sciences*, kd 47, G. Zibordi, C. J. Donlon, ja A. C. Parr, toim, Academic Press, 2014, lk 527–529. doi: 10.1016/B978-0-12-417011-7.00016-7.
17. A. C. Banks *et al.*, „Fiducial Reference Measurements for Satellite Ocean Colour (FRM4SOC)“, *Remote Sensing*, kd 12, nr 8, Art. nr 8, jaan 2020, doi: 10.3390/rs12081322.
18. ESA, “Earth Online” <https://earth.esa.int/eogateway/> (vaadatud 9. mai 2022).
19. „FRM4SOC“, sept 14, 2018. <https://frm4soc.org/> (vaadatud 9. mai 2022).
20. K. G. Ruddick *et al.*, „A Review of Protocols for Fiducial Reference Measurements of Water-Leaving Radiance for Validation of Satellite Remote-Sensing Data over Water“, *Remote Sensing*, kd 11, nr 19, Art. nr 19, jaan 2019, doi: 10.3390/rs11192198.
21. K. G. Ruddick *et al.*, „A Review of Protocols for Fiducial Reference Measurements of Downwelling Irradiance for the Validation of Satellite Remote Sensing Data over Water“, *Remote Sensing*, kd 11, nr 15, Art. nr 15, jaan 2019, doi: 10.3390/rs11151742.
22. A. Białek *et al.*, „Results from Verification of Reference Irradiance and Radiance Sources Laboratory Calibration Experiment Campaign“, *Remote Sensing*, kd 12, nr 14, Art. nr 14, jaan 2020, doi: 10.3390/rs12142220.
23. V. Vabson *et al.*, „Laboratory Intercomparison of Radiometers Used for Satellite Validation in the 400–900 nm Range“, *Remote Sensing*, kd 11, nr 9, Art. nr 9, jaan 2019, doi: 10.3390/rs11091101.
24. V. Vabson *et al.*, „Field Intercomparison of Radiometers Used for Satellite Validation in the 400–900 nm Range“, *Remote Sensing*, kd 11, nr 9, Art. nr 9, jaan 2019, doi: 10.3390/rs11091129.
25. G. Tilstone *et al.*, „Field Intercomparison of Radiometer Measurements for Ocean Colour Validation“, *Remote Sensing*, kd 12, nr 10, Art. nr 10, jaan 2020, doi: 10.3390/rs12101587.
26. K. Alikas *et al.*, „Comparison of Above-Water Seabird and TriOS Radiometers along an Atlantic Meridional Transect“, *Remote Sensing*, kd 12, nr 10, Art. nr 10, jaan 2020, doi: 10.3390/rs12101669.

27. A. Białek *et al.*, „Example of Monte Carlo Method Uncertainty Evaluation for Above-Water Ocean Colour Radiometry“, *Remote Sensing*, kd 12, nr 5, Art. nr 5, jaan 2020, doi: 10.3390/rs12050780.
28. A. C. Banks, R. Vendt, C. Lerebourg, K. Ruddick ja G. Tilstone, toim, *Fiducial Reference Measurements for Satellite Ocean Colour (FRM4SOC)*. MDPI, 2020.
29. IOCCG, G. Zibordi, K. J. Voss, B. C. Johnson ja J. L. Mueller, „Protocols for Satellite Ocean Color Data Validation: In situ Optical Radiometry“. IOCCG, Dartmouth, NS, Canada, 2019. doi: 10.25607/OBP-691.

Summary

Fiducial Reference Measurements to validate satellite remote sensing data

Satellite remote sensing helps us to evaluate the health of our home planet. Every decision to support the saving of the environment must be based on reliable data. To ensure the reliability of remote sensing data collected by using satellites, we need to evaluate the actual conditions on the ground by making fiducial reference measurements (FRM). These measurements must comply with specific quality requirements. For example, they must have metrological traceability to the units of SI with related uncertainty evaluation. The European Space Agency (ESA) and the European Organisation for the Exploitation of Meteorological Satellites (EUMETSAT) have initiated several FRM projects in several scientific fields to support the development and establishment of principles for collecting such fiducial reference measurement data. The authors propose Estonian equivalents for some new terms now being frequently used in the scientific literature of remote sensing. Some examples of essential aspects in fiducial reference measurements are given on the basis of water remote sensing projects FRM4SOC, which are coordinated by the scientists of Tartu Observatory of the University of Tartu.

Sinivetikate põhjustatud veeõitsengud Peipsi järves ja satelliidivõimalused nende märkamiseks

Kersti Kangro^{1,2}, Anne-Mai Pall², Krista Alikas¹

¹ Tartu Ülikool, Tartu observatoorium, Tõravere, Nõo vald, 61602 Tartumaa

² Eesti Maaülikool, põllumajandus- ja keskkonnainstituut, limnoloogiakeskus, Elva vald, 61117 Tartumaa

Kokkuvõte

Sinivetikad on edukad paljudes veekogudes, põhjustades oma massilise arenguga probleeme vee kasutamisel nii joogiveeks kui muuks otstarbeks. Kaugseire annab võimaluse vaadata õitsengute ruumilist paiknemist ja arengut. Copernicuse programmi satelliidid Sentinel-3 A ja B pakuvad kahepeale Peipsist igapäevase pildi võimalust, paraku on reaalsuses pilvkatte tõttu pilte tunduvalt vähem. Uurisime Peipsi järve klorofüllisisaldust, kasutades Sentinel-3 A ja B *Ocean and Land Colour Imager*'i (OLCI) esimese taseme täislahutusega pilte ning maksimaalse klorofüllis indeksit (MCI) aastate 2016–2020 vegetatsiooniperioodil. Peipsi Suurjärves on klorofüllisisaldus püsivalt madalam võrreldes Lämmijärve ja Pihkva järvega, jäädes enamasti alla 40 µg/L. Lämmijärves olid väärtused kõrgemad, aastatel 2019 ja 2020 ulatusid kõrgemad väärtused üle 75 µg/L, ning Pihkva järves üle 100 µg/L. Võttes 2019. aasta näidiseks, uurisime veeõitsengute ruumilist katvust Peipsi järves kahe meetodiga: 1) arvestades pikaajalist klorofüllis mediaanväärtust vahemikus juuni–september + 5% ja 2) sinivetikate protsendi alusel, võttes läviväärtuseks hea ja kesise seisundi järveosaspetsiifilise piiri. Õitseng oli intensiivsem 2019. aastal Pihkva ja Lämmijärves, alates seal juuni keskel (kestus 83 ± 5 päeva), ning Peipsi järves juuni lõpus, kestes oktoobrini (96 ± 5 päeva).

Võtmesõnad: veekogude kaugseire, Sentinel-3/OLCI, klorofüll-a, MCI, sinivetikad, veeõitseng

Sissejuhatus

Sinivetikad on vanimad teadaolevad hapnikku tootvad fotoautotroofid ning nad on tänapäevalgi väga edukad paljudes veekogudes. Põhjuseid, miks sinivetikad

arvukad on, võib välja tuua mitmeid: osa liike võib fikseerida õhulämmastikku, mitte sõltudes sissevoolude kaudu veekokku jõudvast lämmastikust; nad võivad end gaasivakuolide abil veesambas sobivale sügavusele sättida (Ibelings jt, 1991); nad võivad moodustada piisavalt suuri kolooniaid, et end ärasöömisest säästa; nad omastavad ja säilitavad rakus edukalt fosforit ning on võimelised tootma mitmesuguseid mürke (Paerl ja Otten, 2013). Just sinivetikamürkide võimalik olemasolu veekogudes on põhjus, miks inimesed peaksid öitsengutega arvestama ja mürgistuse vältimiseks ennast peale suplust puhtaks pesema. Joomiseks selline vesi ei sobi, kuna mürgid ei lagune isegi vett keetes (Rakko, 2009; Sidelev ja Babanazarova, 2020). Eriti häirivad on öitsengud sellistes veekogudes, millest võetakse joogivett veekogu kaldal asuvalle linnale: nii oli Erie järve ääres asuv 400 000 elanikuga Toledo linn 2014. aasta augustis mitu päeva joogiveeta, kuna mikrotsüstiini tase vees oli liiga kõrge (Steffen jt, 2017).

Erie järve järjest sagedavate sinivetikaöitsengute taga arvatakse olevat põlumajandusest järve jõudev lämmastik, sest seal domineerivad perekonna *Microcystis* liigid vajavad toiteainena lisaks fosforile ka lämmastikku (Steffen jt, 2017; Newell, 2019). Peipsi järves on domineerivamad liigid tavaliselt sellised, millel on heterotsüstid ja mis ise lämmastikku fikseerida saavad – perekonnad *Aphanizomenon*, *Dolichospermum* ja suuremõõtmelisi kolooniaid moodustav *Gloetrichia echinulata*, samas Lämmijärves võib ka perekond *Microcystis* arvukas olla. Igal aastal Peipsi järves öitsenguid ei ole, nende esinemine sõltub eelkõige veetemperatuurist („Öitsengutele meeldib kuum ilm“ – Paerl ja Huisman, 2008). Wynne jt 2013 leidsid, et perekonna *Microcystis* poolt domineeritud öitsengute areng oli seotud temperatuuridega üle 18 °C ja väiksete ilmadega (tuulestress < 0,04 Pa). P. Nõgese (2020) uuringu järgi on Peipsi järves öitsengute tekkeks oluline veetemperatuuri lühiajaline tõus üle 24 kraadi või pikema perioodi (mai–september) keskmine üle 16,5 kraadi, kusjuures lisateguritena soodustavad öitsengu teket ka madal veetase ja madal N/P suhe.

Pinnaöitsengute teke on seotud tuulevaikse ilmaga, tõusev tuul lükkab vees hõljuvad sinivetikad randa kokku ja põhjustab suurema ja märgatava sinivetikate biomassi madalas kaldavees (Rakko, 2009). See ja hilisem lagunev mass põhjustabki probleeme suplejatele. Kliimamuutuse tõttu on sinivetikate massiline areng tulevikus pigem sagedasem kui harvem, arvestades kõrgema temperatuuri ning süsihappegaasi hulga ja suurema aurumise kombineeritud mõju (Paerl ja Huisman, 2009; O’Neil jt, 2012). Ökosüsteemi seisundi hindamisel tuleb sinivetikad kui potentsiaalselt mürgiseid veeöitsenguid tekitav rühm kindlasti arvesse võtta (Nõges, 2020), sest mürgised öitsengud mõjutavad nii veekvaliteeti, kalavarusid kui ka loomade ja inimeste tervist (Paerl ja Fulton, 2006). Kalade suremist võivad põhjustada vetikamürkide kõrval ka kuum ilm ja sellest tulenev kõrge veetemperatuur ning vee hapnikusisalduse kõikumine nii vetikate elutegevuse kui lagunemise tulemusena (Kangur jt, 2005; Paerl ja Otten, 2013).

Üldiselt on teada sinivetikate kasvuelistused (pigem üle 20 kraadi (Carey jt, 2012)), lisaks on leitud ka positiivse tagasiside mehhanism – sinivetika öitsenguga

kaetud ala temperatuur on ümbritsevast veest soojem (Ibelings jt, 2003; Paerl ja Otten, 2013). Samas ei tähenda külm aeg iseenesest seda, et õitsenguid pole – mõned sinivetikad (näiteks perekonna *Planktothrix* liigid) võivad eutroofsetes järvedes olla arvukad talveperioodil ning ka jää all (Laugaste, 1991; Toporowska jt, 2010; Wejnerowski jt, 2018). Näiteks sinivetikaõitsengutega kimpus olevas Taihu järves esinevad perekonna *Microcystis* õitsengud aastaringselt, kusjuures rakkude kasv algab alates 12,5-kraadisest veetemperatuurist (Ma jt, 2016).

Uurisime klorofüllisisaldust ja sinivetikate poolt põhjustatud veeõitsenguid Peipsi järves, kasutades Sentinel-3/OLCI pilte ning võttes näidiseks 2019. aasta. Kaugseire annab hea võimaluse vaadata õitsengute ruumilist paiknemist ja arengut: Copernicuse programmi satelliidid Sentinel-3 A ja B pakuvad kahepeale Peipsist igapäevase pildi võimalust, paraku on reaalsuses pilvkatte tõttu pilte tunduvalt vähem.


Materjal ja meetodika

Peipsi järv on Eesti-Vene piiriveekogu pindalaga 3555 km², pikkusega 152 km ja laiussega 48 km. Keskmine sügavus on 7,1 m ja maksimaalne 15,3 m, kusjuures aasta veetase kõigub keskmiselt 1,5 m, olles kõrgeim kevadel peale jää sulamist ning madalaim oktoobris (Mäemets jt, 2018). Eutroofne järv koosneb kolmest osast: Peipsi Suurjärv (Peipsi s.s., pindala 2611 km², keskmine sügavus 8,3 m), Lämmijärv (pindala 236 km², keskmine sügavus 2,5 m) ja Pihkva järv (708 km², keskmine sügavus 3,8 m).

Peipsi järve seiratakse igal aastal vegetatsiooniperioodil aprillist või maist kuni oktoobrini 7 punktist ning ebaregulaarselt 3 punktist (12, 13, 14) (joonis 1). Vene poole kohta saadakse infot üks kord aastas toimuva augustikuise ühisekspeditsiooni raames, aga seda erinevatel põhjustel mitte igal aastal.

Artiklis käsitleme püsiseirepunkte Eesti poolel (2, 4, 11, 38, 92, 16, 17) ning Vene poolel (5, 7, 10, 91, 43, 22, 27, 51, 52) (joonis 1).

Seire käigus koguti proove klorofüll-a analüüsiks, lahustina kasutati etanooli ja proovid mõõdeti spektrofotomeetriliselt ning arvutati Jeffrey-Humphrey (1976) järgi.



Joonis 1. Seirepunktid Eesti ja Venemaa poolel (Tammeorg ja Tuvikene, 2020).

Sentinel-3 A ja B / OLCI esimese taseme täislahutusega pilte töödeldi EstHUBi keskkonnas. Uuritav ajavahemik oli vegetatsiooniperiood (aprill–september) 2016–2020. Kasutati pilvede ja päikselgi märgendeid (quality_flags.bright ja quality_flags.sun_glint_risk).

Seejärel leiti maksimaalse klorofüll-i indeks (Gower jt, 2008):

$$MCI = L_{709} - L_{681} - 0,389(L_{753} - L_{681}), \quad (1)$$

kus L_x tähistab atmosfääri ülemiste kihtide kirkusi lainepikkustel 709, 753 ja 681 nm ning faktor 0,389 on vastavate lainepikkuste suhe $(709 - 681)/(753 - 681)$. MCI valiti seetõttu, et varasemalt on see indeks näidanud häid tulemusi Peipsi järvest klorofüll-i ja teiste näitajate saamisel kaugseireandmetest (Alikas jt, 2010).

MCI kaudu on võimalik leida klorofüll-a kontsentratsiooni, fütoplanktoni kogubiomassi ja tsüanobakterite biomassi, ning kahe viimase näitaja abil on võimalik leida kaugseireandmetest ka sinivetikate protsenti kogubiomassist.

Veeõitsenguid uuriti aastal 2019. Õitsengupindala tulemused saadi järveosa-spetsiifiliselt SNAP 8.0 abil, võttes arvesse kilomeetrise puhvri rannajoonest kõigis järveosades. Kasutati 15 päeva piltide keskmisi väärtusi, sest sageli olid pildid pilvised ja igapäevaseid andmeid poleks olnud võimalik saada. Joonised tehti tarkvara R 4.0.3 abil, kasutades paketti ggplot2.

Õitsengu tuvastamiseks kasutasime kahte meetodit (tabel 1):

1) pikaajalist klorofüllisisalduse mediaani juunist septembrini (1984–2015) + 5%. Need väärtused olid järveosade kaupa erinevad (tabel 1).

2) P. Nõgese (2020) hinnangu alusel soovitatud sinivetikate osakaalu protsendi (CY%) VRD hinnangu kesise ja hea seisundi piiri.


Tabel 1. Kriteeriumid õitsengu määramiseks

Õitsengu piirväärtus	Peipsi Suurjärv	Lämmijärv	Pihkva järv
Chl-a pikaajaline mediaan + 5% ($\mu\text{g/L}$)	18	35,7	46,6
CY% kogubiomassist; kesise ja hea seisundi piir	30%	51%	51%

Tulemused ja arutelu

Klorofüll-a satelliidiandmetelt

Peipsi Suurjärves on klorofüllisisaldus püsivalt madalam võrreldes Lämmijärve ja Pihkva järvega, jäädes enamasti alla 40 $\mu\text{g/L}$ (joonis 2). Lämmijärves olid väärtused




Joonis 2. Klorofüll-a ($\mu\text{g/L}$) Peipsi Suurjärves, *in situ* ja Sentinel-3 andmetel.

kõrgemad, 2019. ja 2020. aastal ulatusid kõrgemad väärtused üle $75 \mu\text{g/L}$ (joonis 3), ning Pihkva järves olid klorofüll-i väärtused veelgi kõrgemad, ulatudes 2019. ja 2020. aastal üle $100 \mu\text{g/L}$ (joonis 3). 2017. aastal olid väärtused madalamad kui teistel aastatel Lämmijärves ja enamikus Pihkva järve punktides (joonis 3).

Sinivetikaõitsengute hinnang


Sinivetikate põhjustatud õitsengute olemasolu võib kasutada ökosüsteemi seisundi indikaatorina, sest sinivetikad reageerivad kiiresti ökosüsteemi muutustele, ja samas võib õitsenguid oskusliku majandamisega leevendada ning neid saab satelliidipiltidelt edukalt kaardistada (Clark jt, 2017). Õitsengute hindamiseks satelliidilt on mitmeid võimalusi: kasutatakse kas esimese taseme pilte (atmosfääri ülapääri kirkust) (Binding jt, 2021) või atmosfäärikorrektsiooniga töödeldud teise taseme pilte (atmosfäärilust peegeldustegurit) (Kahru ja Elmgren, 2014; Mishra jt, 2019). Clark jt (2017) ning Matthews ja Odermatt (2015) kasutasid näiteks esimese taseme pilte, millele on lisatud ainult töötlus Rayleigh' korrektsiooniga. Sinivetikate hulka hinnatakse satelliidilt kas otse biomassi mõõtes või kaudsete



Joonis 3. Klorofüll-a ($\mu\text{g/L}$) Lämmijärves (16, 17) ja Pihkva järves (22, 27, 51, 52), *in situ* ja Sentinel-3 andmetel.

meetoditega, leides klorofüll-a kontsentratsiooni (Binding jt, 2012; Kahru jt, 2014), fükotsüaniini hulga (Simis jt, 2005; Mishra jt, 2013), fluorestsentsi piigid (Matthews ja Odermatt, 2015) ning rakkude hulga (Wynne jt, 2008; Stumpf jt, 2016). Hinnatavateks parameetriteks on näiteks õitsenguga kaetud ala pindala (Urquhart jt, 2017; Binding jt, 2021) ja ajaline sagedus (protsent vaatlustest) (Clark jt, 2017). Samas on globaalses mastaabis valideerimisandmeid sageli keeruline saada, kuna pigmendimõõtmised kipuvad olema haruldased ja taksonoomilise koosseisu määramine ei kuulu sageli standardprogrammi (Clark jt, 2017).

Õitsengu defineerimine polegi nii lihtne, veekogu ääres on see subjektiivne ja visuaalne: kui vees on nähtavad kolooniad ja/või on vesi värvunud, ongi tegu veeõitsenguga (Rakko, 2009). WHO soovitus järgi on õitseng alates klorofüllisisaldusest $10 \mu\text{g/L}$ (WHO, 2003), aga Peipsi järvele selline hinnang õitsengukriteeriumiks ei sobi, kuna siis klassifitseeruks enamik vegetatsiooniperioodil mõõdetud väärtusi (joonised 2 ja 3) õitsenguna. Pikaajalise mediaani + 5% kriteeriumit on varasemalt kasutatud näiteks Läänemeres kevadõitsengute määratlemiseks (Groetch jt, 2016; Brando jt, 2021).




Joonis 4. a) Sentinel-3A/OLCI RGB pilt, b) öitseng Chl-a alusel ja c) öitseng CY% alusel. Pilt on tehtud 18.08.2019, valitud on intensiivseima öitsenguga pilt ning öitsenguala on tähistatud punaselt.

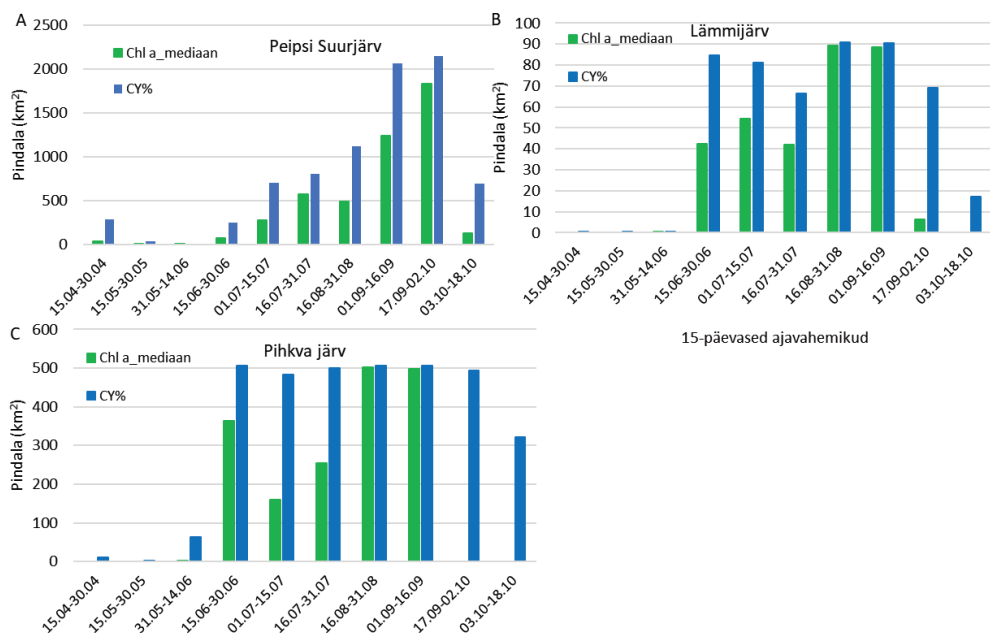
Näidiseks võtsime aasta 2019, mil Peipsi järves olid ulatuslikud sinivetika-öitsengud (Tammeorg jt, 2019). Kilomeetrine puhvertsoon kalda ääres oli vajalik selleks, et vähendada naabrusefekti mõju, mis oli eriti märgatav kaldaala lähedastel pikslitel (joonis 4). Intensiivse öitsengu perioodil olid peaaegu kogu Lämmijärv ja Pihkva järv öitsenguga kaetud, Peipsi Suurjärv aga osaliselt (joonis 4).

Satelliidipiltide alusel võib öelda, et öitsengud algasid Lämmijärves ja Pihkva järves veidi enne 18. juunit ning kestsid kuni oktoobrini (joonis 5). Öitsengupeerioid oli seal võrreldes Peipsi Suurjärvega intensiivsem: vahemikus 16.08–16.09 olid nii Pihkva kui Lämmijärv peaaegu täies ulatuses öitsengutega kaetud. Peipsi Suurjärves algas öitseng hiljem, juuni lõpus, ja kestis oktoobrini. Suurjärve põhja- ja lääneosas ületas klorofüll-a kontsentratsioon piirväärtusi alles juuli lõpus. Öitsengute kogukestuseks oli 96 päeva (± 5 päeva) ning ruumiliselt oli öitseng väga varieeruv. Öitsengud Pihkva ja Lämmijärves kestsid lühemalt, 83 päeva (± 5 päeva).

Joonisel 6 on näidatud kahe meetodiga saadud pindalade erinevus: valides sinivetikaöitsengute hinnangu aluseks sinivetikate protsendi biomassist, saame öitsengute pindala kõikides järveosades kogu aeg märgatavalt suurema ning öitsenguperiood on ka pikem. Põhimõtteliselt on siiski õigem hinnanguks kasutada



Joonis 5. Öitsengu arenemine klorofüll-a ($\mu\text{g/L}$) sisalduse alusel Peipsi järves 2019. aastal 15 päeva keskmistatud piltide alusel.



Joonis 6. Öitsengupindalad kahe erineva meetodiga a) Peipsi Suurjärves, b) Lämmijärves ja c) Pihkva järves.

klorofülliväärtusi, kuna MCI algoritm ei võta aluseks fükotsüaniini piiki ega määra sinivetikasisaldust, vaid arvutab sinivetikate hulga kaudselt, mille tulemusena näidatakse sinivetikaõitsengute olemasolu ka kevadel (joonis 6a).

2019. aasta augustikuise ühisseire ajal olid sinivetikad dominantideks 19 proovipunkti 18-s ning sinivetikaid oli Suurjärves 70%, lõunapoolsetes osades keskmiselt 90% fütoplanktoni biomassist, mis mõjutab ka veepoliitika raamdirektiivi jaoks antavat seisundihinnangut halvemuse suunas: Suurjärves oli seisundihinnang „halb“ ja Läämi- ning Pihkva järves „väga halb“ (Tammeorg jt, 2019). Satelliidipiltide alusel oli Pihkva järv mõlema kriteeriumi järgi õitsenguga kaetud (joonis 6c). Peipsi järve seisundinäitajate halvenemine 2019. aastal võrreldes varasema seireperioodiga tulenes pigem looduslikest teguritest (väga madal veetase ja kõrgem temperatuur) kui inimtegevuse survest (Tammeorg jt, 2019). Pihkva järves oli ka tunduvalt suurem üldfosfori sisaldus kui teistes järveosades (< 0,1 teistes järveosades, näiteks Peipsi Suurjärves keskmiselt 0,04 mg/L, aga Pihkva järves > 0,1–0,16 mg/L, kasutatud on ainult augusti andmeid). Seda on märgatud varemgi, Habermani jt (2013) järgi on Pihkva pigem teiste järveosade reostaja kui Velikaja jõest tulnud reostuse puhastaja.

Edaspidi saab satelliidiandmete alusel võrrelda sinivetikaõitsengute ulatust eri aastatel, arvestades Sentinel-3 missiooni pikaajalist perspektiivi toota vähemalt 20 aasta vältel kvaliteetseid satelliidiandmeid (ESA, 2021). Samuti saab minna ajas tagasi, kasutades ENVISAT/MERISE andmeid, ning täiustada algoritme sinivetikate hulga täpsemaks määramiseks.

Tänuavaldus

Klorofüll-a pikaajaliste väärtuste eest täname Lea Tuvikest EMÜ PKI limnoloogiakeskusest. Samuti täname EMÜ PKI limnoloogiakeskust Peipsi seire raames kogutud klorofüll-a ning fütoplanktoni biomassi andmete eest ning keskkonnainfo seiresüsteemi KESE fosforisisalduste eest. Töös on kasutatud ESA Copernicuse programmi satelliitide Sentinel-3 A ja B andmeid. Täname Maa-ametit töötluskeskkonna ESTHub kasutamise võimaluse eest. Tööd finantseeris Eesti Teadusagentuur (PSG10), Horisont 2020 projekt EOMORES (730066) ning Euroopa Liidu projekt No FPA 275/G/GRO/COPE/17/10042, FPCUP (*Framework Partnership Agreement on Copernicus User Uptake*), tegevus 2019-1-51: *Downstream service/application development for supporting implementation of EU Water Framework Directive in Estonia*).

Viidatud kirjandus ja internetiallikad

Alikas, K., Kangro, K., Reinart, A. 2010. Detecting cyanobacterial blooms in large North European lakes using the Maximum Chlorophyll Index. *Oceanologia* 52, 237–257.

- Binding, C.E., Greenberg, T.A. & Bukata, R.P. 2012. An analysis of MODIS-derived algal and mineral turbidity in Lake Erie. *Journal of Great Lakes Research* 38, 107–116.
- Binding, C.E., Pizzolato, L. & Zeng, C. 2021. EOLakeWatch; delivering a comprehensive suite of remote sensing algal bloom indices for enhanced monitoring of Canadian eutrophic lakes. *Ecological Indicators* 121, 106999, <https://doi.org/10.1016/j.ecolind.2020.106999>.
- Brando, V., Sammartino, M., Colella, S., Bracaglia, M., Di Cicco, A., D'Alimonte, D., Kaijiyama, T., Kaitala, S., Attila, J. 2021. Phytoplankton bloom dynamics in the Baltic Sea using a consistently reprocessed time series of multi-sensor reflectance and novel Chlorophyll -a retrievals. *Remote Sensing*, submitted.
- Carey, C.C., Ibelings, B.W., Hoffmann, E. P., Hamilton, D. P. & Brookes, J.D. 2012. Eco-physiological adaptations that favour freshwater cyanobacteria in a changing climate. *Water Res.* 46, 1394–1407.
- Clark, J.M., Schaeffer, B.A., Darling, J. A., Urquhart, E.A., Johnston, J. M., Ignatius, A.R., Myer, M.H., Loftin, K.A., Werdell, P. J., Stumpf, R.P. 2017. Satellite monitoring of cyanobacterial harmful algal bloom frequency in recreational waters and drinking water sources. *Ecological Indicators*, 80, 84–95. <https://doi.org/10.1016/j.ecolind.2017.04.046>.
- Eesti Maaülikooli põllumajandus- ja keskkonnainstituut. 2019. *Peipsi järve hüdrobioloogiline seis 2019.a*, lõpparuanne, Tartu.
- Gower, J., King, S., Goncalves, P. 2008. Global monitoring of plankton blooms using MERIS MCI. *International Journal of Remote Sensing* 29, 6209–6216.
- Groetch, P.M.M., Simis, S.G.H, Eleveld, M.A., Peters, S.W.M. 2016. Spring blooms in the Baltic Sea have weakened but lengthened from 2000 to 2014. *Biogeosciences* 13, 4959–4973.
- Haberman, J., Haldna, M., Laugaste, R. 2013. The status of the southernmost part (Lake Pihkva) of large Lake Peipsi: A purification pond or polluter? *Journal of Aquatic Ecosystem Health and Management* 16, 198–204. DOI: [10.1080/14634988.2013.787876](https://doi.org/10.1080/14634988.2013.787876).
- Ibelings, B.W., Mur, L.R., Walsby, A.E. 1991. Diurnal changes in buoyancy and vertical distribution in populations of *Microcystis* in two shallow lakes. *J. Plankt. Res.* 13, 419–436.
- Ibelings B.W., Vonk, M., Los, H.F.J. , [van der Molen, D.T.](#), [Mooij, W.M.](#) 2003. Fuzzy modeling of cyanobacterial surface water blooms: validation with NOAA-AVHRR satellite images. *Ecol. Appl.* 13, 1456–1472.
- Jeffrey, S.W., Humphrey, G.F. 1975. New Spectrophotometric Equations for Determining Chlorophylls a, b, C1 and C2 in Higher Plants, Algae and Natural Phytoplankton. *Biochemie und Physiologie der Pflanzen*, 167, 191–194, doi:10.1016/S0015-3796(17)30778-3.
- Kahru, M. & Elmgren, R. 2014. Multidecadal time series of satellite-detected accumulations of cyanobacteria in the Baltic Sea. *Biogeosciences* 11, 3619–3633.
- Kangur, K., Kangur, A., Kangur, P., Laugaste, R. 2005. Fish kill in Lake Peipsi in summer 2002 as a synergistic effect of cyanobacterial bloom, high temperature and low water level. Proceedings of the Estonian Academy of Sciences. *Biology. Ecology* 54 (1), 67–80.
- Laugaste, R. 1991. Fütoplankton. Verevi järve seisund. *Hüdrobioloogilised uurimused XVII*, Tartu. pp. 69–90.
- Ma, J., Qin, B., Paerl, H.W., Brookes, J.D., Hall, N.S., Shi, K., Zhou, Y., Guo, J., Li, Z., Xu, H., Wu, T., Long, S. 2016. The persistence of cyanobacterial (*Microcystis* spp.) blooms throughout winter in lake Taihu, China. *Limnol. Oceanogr.* 61, 711–722. doi: 10.1002/lno.10246

- Matthews, M.W., Odermatt, D. 2015. Improved algorithm for routine monitoring of cyanobacteria and eutrophication in inland and near-coastal waters. *Remote Sensing of Environment* 156, 374–382. <https://doi.org/10.1016/j.rse.2014.10.010>.
- Mishra, S., Mishra, D.R., Lee, Z. & Tucker, C.S. 2013. Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: A quasi-analytical approach. *Remote Sensing of Environment* 133, 141–151.
- Mishra, S., Stumpf, R.P., Schaeffer, B.A., Werdell, P.J., Loftin, K.A., Meredith, A. 2019. Measurement of Cyanobacterial Bloom Magnitude using Satellite Remote Sensing. *Sci Rep* 9, 18310. <https://doi.org/10.1038/s41598-019-54453-y>
- Mäemets, H., Laugaste, R., Palmik, K., Haldna, M. 2018. Response of primary producers to water level fluctuations of Lake Peipsi. *Proc. Est. Acad. Sci.* 67, 231–245, doi:10.3176/proc.2018.3.06.
- Newell, S.E., Davis, T.W., Johengen, T.H., Gossiaux, D., Burtner, A., Palladino, D., McCarthy, M.J. 2019. Reduced forms of nitrogen are a driver of non-nitrogen-fixing harmful cyanobacterial blooms and toxicity in Lake Erie. *Harmful Algae* 81, 86–93. doi: 10.1016/j.hal.2018.11.003. Epub 2019 Jan 2. PMID: 30638502.
- Nõges, P. 2020. *Uuring Peipsi järve füüsikalise-keemilise ja fütoplanktoni kvaliteedinäitajate klassipiiride täpsustamiseks*. Eesti Maaülikool, Põllumajandus- ja keskkonnainstituut. Hüdrobioloogia ja kalanduse õppetool, Tartu, 43 pg. https://www.envir.ee/sites/default/files/Vesi/Uuringudjaaruanded/2021/peipsi_vrd_kriteeriumite_aruanne_2020.pdf
- O'Neil, J.M., Davis, T.W., Burford, M.A., Gobler, C.J. 2012. The rise of harmful cyanobacteria blooms: the potential roles of eutrophication and climate change. *Harmful Algae* 14, 313–334. [10.1016/j.hal.2011.10.027](https://doi.org/10.1016/j.hal.2011.10.027)
- Paerl, H.W., R.S. Fulton III. 2006. Ecology of harmful cyanobacteria. *Ecological Studies*. Ed. E. Granéli, J.T. Turner Vol. 189. 95–110 pp. Springer-Verlag Berlin, Heidelberg.
- Paerl, H., Huisman, J. 2008. Blooms Like It Hot. *Science* 320(5872), 57–8 DOI: [10.1126/science.1155398](https://doi.org/10.1126/science.1155398)
- Paerl, H.W., J. Huisman. 2009. Climate change: a catalyst for global expansion of harmful cyanobacterial blooms. *Environ. Microbiol. Rep.*, 1 (), pp. 27–37, [10.1111/j.1758-2229.2008.00004.x](https://doi.org/10.1111/j.1758-2229.2008.00004.x)
- Paerl, H.W., Otten, T. 2013. Harmful Cyanobacterial Blooms: Causes, Consequences, and Controls. *Microbial Ecology* 65(4), DOI: [10.1007/s00248-012-0159-y](https://doi.org/10.1007/s00248-012-0159-y)
- Rakko, A. 2009. Veeõitsengud Eesti järvedes. *Eesti Loodus*, 7. http://www.eestiloodus.ee/artikkel/2839_2837.html
- Sidelev, S.I., Babanazarova, O.V. 2020. Detection of Cyanobacterial Toxins in Water Supply Sources and Tap Water in Some Russian Cities: Searching Producers and Testing Removal Methods. *Water Resour.* 47, 304–314. <https://doi.org/10.1134/S0097807820020189>
- Simis, S. G. H., Peters, S. W. M. & Gons, H. J. 2005. Optical changes associated with cyanobacterial bloom termination by viral lysis. *Journal of Plankton Research* 27, 937–949.
- Steffen, M.M., Davis, T.W., McKay, R.M.L., Bullerjahn, G.S., Krausfeldt, L.E., Stough, J.M.A., Neitzey, M.L., Gilbert, N.E., Boyer, G.L. Johengen, T.H., Gossiaux, D.C., Burtner, A.M., Palladino, D., Rowe, M.D., Dick, G.J., Meyer, K.A., Levy, S., Boone, B.E., Stumpf, R.P., Wynne, T.T., Zimba, P.V., Gutierrez, D., Wilhelm, S. W. 2017. Ecophysiological Examination of the Lake Erie Microcystis Bloom in 2014: Linkages between Biology

- and the Water Supply Shutdown of Toledo, OH. *Environ. Sci. Technol.* 51, 12, 6745–6755. [10.1021/acs.est.7b00856](https://doi.org/10.1021/acs.est.7b00856)
- Stumpf, R.P., Davis, T.W., Wynne, T.T., Graham, J. L., Loftin, K.A., Johengen, T.H., Gossiaux, D., Palladino, D., Burtner A. 2016. Challenges for mapping cyanotoxin patterns from remote sensing of cyanobacteria. *Harmful Algae* 54, 160-173. <https://doi.org/10.1016/j.hal.2016.01.005>.
- Tammeorg, O., L. Tuvikene, Maileht, K. jt. 2019. *Peipsi järve hüdrobioloogiline seire ja uuringud aastal 2019 (Eesti-Vene suvine ühisekspeitsioon)*. Lõpparuanne. Leping nr. 4-1/19/154. Eesti Maaülikool. Tartu 58 pg.
- Tammeorg, O., Tuvikene L. (koostajad) 2020. *Peipsi järve suvise ühise seire hüdrobioloogiline seire ja uuringud aastal 2020*. Lõpparuanne. Leping nr. 4-1/20/108. Eesti Maaülikool. Tartu 2020., 59 pg.
- Toporowska, M., Pawlik-Skowrońska, B., Krupa, D., Kornijów, R. 2010. Winter versus summer blooming of phytoplankton in a shallow lake: effect of hypertrophic conditions. *Pol. J. Ecol.* 58, 3–12.
- Urquhart, E.A., Schaeffer, B.A., Stumpf, R.P., Loftin, K.A. & Werdell, P.J. 2017. A method for examining temporal changes in cyanobacterial harmful algal bloom spatial extent using satellite remote sensing. *Harmful Algae* 67, 144–152.
- Wejnerowski, Ł., Rzymiski, P., Kokociński, M., Meriluoto, J. 2018. The structure and toxicity of winter cyanobacterial bloom in a eutrophic lake of the temperate zone. *Ecotoxicology* 27, 752-760. doi:10.1007/s10646-018-1957-x
- WHO, 2003. Guidelines for safe recreational water environments. Volume I: *Coastal and fresh waters*. 253 pg.
- Wynne, T.T. Stumpf, R.P., Tomlinson, M.C., Warner, R.A., Tester, P.A., Dyble J. & Fahnenstiel, G.L. 2008. Relating spectral shape to cyanobacterial blooms in the Laurentian Great Lakes. *Int J Remote Sens* 29, 3665–3672.
- Wynne, T.T., Stumpf, R.P., Tomlinson, M.C., Fahnenstiel, G.L., Dyble, J., Schwab, D.J., Joshi, S.J. 2013. Evolution of a cyanobacterial bloom forecast system in western Lake Erie: Development and initial evaluation. *Journal of Great Lakes Research* 39, Supplement 1, 90-99. <https://doi.org/10.1016/j.jglr.2012.10.003>.
- ESA, 2021. <https://earth.esa.int/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-3>, päritud 24.05.2021

Summary

Description of cyanobacterial blooms in Lake Peipsi with remote sensing methods

Cyanobacteria are successfully growing in many waterbodies, causing potentially toxic surface blooms, hampering the recreational activities, impeding the usage of drinking water and causing problems for other lake biota. Remote sensing methods allow to track the development and movement of the bloom on spatial scale. We estimated Chlorophyll a (Chl a) amount in Lake Peipsi from Sentinel 3 A and B/OLCI Level 1 full resolution images and MCI index during the vegetation period of 2016–2020. In Peipsi s.s., the amount of Chl a was generally lower (below 40 $\mu\text{g/L}$) in comparison to Lake Lämmijärv and Lake Pihkva, where higher values were present ($>75 \mu\text{g/L}$ and $>100 \mu\text{g/L}$, respectively) during 2019 and 2020. Taking 2019 as an example year, we studied cyanobacterial blooms with two methods: 1) long-term median value of Chl a from the period of June to September + 5%; 2) cyanobacterial % (Cy%) in total phytoplankton biomass, according to lake-part-specific value between “good” and “moderate” status assessment. During 2019 cyanobacterial bloom was more intensive in L. Pihkva and L. Lämmijärv, starting there in the middle of June and lasting for 83 ± 5 days. In L. Peipsi s.s. cyanobacterial bloom started at the end on June and lasted for 96 ± 5 days.

Fütoplanktoni primaarproduktiooni modelleerimine Sentinel-3 andmete põhjal Eesti ja Läti järvede näitel

Tuuli Soomets¹, Kristi Uudeberg², Kersti Kangro³,
Kaie Toming¹, Tiit Kutser¹

¹ Tartu Ülikool, Eesti mereinstituut, Mäealuse 14, 12618 Tallinn

² Keskkonnaagentuur, Mustamäe tee 33, 10616 Tallinn

³ Tartu Ülikool, Tartu observatoorium, Tõravere, Nõo vald, 61602 Tartumaa

Kokkuvõte

Fütoplanktoni primaarproduktioonil järvedes on oluline roll ülemaailmses süsinikuringes. Kogu maailmas on hinnanguliselt 117 miljonit järve ning traditsiooniliste, keerukate ja ajamahukate *in situ* meetoditega ei ole võimalik kõiki järvi seirata. Käesolevas uuringus on ühendatud bio-optiline modelleerimine ja kaugseiresatelliitide (Sentinel-3A ja -3B multispektraalse sensori *Ocean and Land Colour Instrument*) andmed, et uurida primaarproduktiooni ajalist ja ruumilist varieerumist Baltikumi neljas järves 2018. aastal. Kasutataval bio-optilisel mudelil on kolm sisendparameetrit: klorofüll-*a* kontsentratsioon, valguse difuusne nõrgenemistegur ja pealelangeva kiirguse hulk. Aastane hinnanguline produktioon oli, võrreldes väiksemate järvedega, nagu Lubāns (18 Gg C a^{-1}) ja Rāzna (7 Gg C a^{-1}), suurimas uuritud järves Võrtsjärves (270 km^2) kõrgeim (61 Gg C a^{-1}). Uuritud järvedest kõige produktiivsem oli väikseim järv Burtnieks ($40,2 \text{ km}^2$): aastase koguproduktiivsusega 13 Gg C a^{-1} oli päeva keskmine produktioon pindalaühiku kohta $910 \text{ mg C m}^{-2} \text{ p}^{-1}$. Väikese ja keskmise suurusega järvede suur arvukus tähendab nende olulist panust süsiniku sidumisse. Töös kasutatav primaarproduktiooni ruumilise ja ajalise varieeruvuse jälgimise meetod on rakendatav ka suurematele piirkondadele.

Võtmesõnad: primaarproduktioon, bio-optiline modelleerimine, järved, optiliselt keerukad veed, kaugseire, Sentinel-3, OLCI, optilised veetüübid

Sissejuhatus

Maal on üle 117 miljoni järve ja veehoidla pindalaga üle $0,002 \text{ km}^2$ [1]. Need veekogud moodustavad ainult ~4% Maa maismaapinnast, kuid sisaldavad ~85%

ülemaaailmsest mageveevarust. Ühiskond sõltub siseveekogudest, sest nii joogivesi, põllumajandus, kalandus, energia kui ka osaliselt transport tugineb siseveekogudele. Vaatamata suhteliselt väikesele pindalale annavad järved võrreldes avaookeaniga suure panuse ülemaailmsesse süsinikuringesse, olles äärmiselt olulised maismaa süsiniku transpordil, muundamisel ja säilitamisel [2]. Fütoplanktoni primaarproduktioon on uue orgaanilise aine ja potentsiaalse energia peamine sisend, mis on aluseks kogu järve ökosüsteemile.

Fütoplanktoni primaarproduktioon ehk esmasproduktioon (PP, *primary production*) on autotroofide poolt fotosünteesiprotsessis toodetud orgaaniline aine (ehk seotud energia hulk moodustatud anorgaanilisest süsinikust ja mineraalainetest). Veekogudes on esmasproduktentideks põhiliselt mikroorganismid – vetikad ja tsüanobakterid (sinivetikad). PP-d mõjutavad kõige rohkem valgus, toiteainete hulk ja temperatuur. Muudest mõjuritest on olulised vee segunemine ning heterotroofide (zooplanktoni) valikuline toitumine. Vee liikumisest tingitult võib fütoplankton kanduda sügavale, kus tal pole võimalik kasvada.

PP hindamiseks veekogudes on mitu võimalust. Järvedes kasutatakse neist sagedamini nelja: hapniku- (O_2) meetod, radioaktiivse süsiniku (^{14}C) meetod, hapniku stabiilsete isotoopide (^{16}O , ^{17}O ja ^{18}O) meetod ning fluorestsentsi kineetika meetod. Kaks esimest meetodit põhinevad ainevahetuse otsesel mõõtmisel.

Kõige täpsemaks loetakse ^{14}C meetodit, kuna selle meetodi suur tundlikkus võimaldab kasutada lühikest ekspositsiooniaega ja teha mõõtmisi ka väheproduktiivsetes vetes. Mõõdetud PP ühikuks on kas milligrammi süsinikku kuupmeetris ($mg\ C\ m^{-3}$) või milligrammi süsinikku ruutmeetril ($mg\ C\ m^{-2}$). Viimane näitab, kui palju toodetakse orgaanilist ainet terves veesambas, ja seda on nimetatud integraalseks primaarproduktiooniks PP_{int} . Mõõtmisaeg (pudelite inkubeerimine vees) võib oligotroofsetes vetes olla suhteliselt pikk (nt üks päev). Mesotroofsetes ja eutroofsetes veekogudes on mõõtmisaeg tavaliselt umbes 2,5 tundi ja PP profiili ööpäevase variatsiooni kirjeldamiseks peab kordama mõõtmistsükleid vähemalt 6 korda päevas. Pikemaid inkubeerimisi kasutades võivad tulemused olla moonutatud: hapnikumeetodi puhul võib osa katsepudelites toodetud hapnikust moodustada superküllastumisel gaasimulle. ^{14}C meetodi puhul hakkavad liiga pika inkubeerimisaja tõttu rakud süsiniku isotoopi vabastama (kui tekib küllastus). Lisaks on kõik *in situ* lähenemisviisid aeganõudvad, kallid ja praktiliselt võimatu on saada ülevaadet PP ruumilise varieeruvuse kohta.

PP on ülioluline, sest see on fotosünteesi otsene tulemus ja kujutab endast ökosüsteemi kõigi fotosünteesimäärade summat. Järvede ökoloogilise seisundi hindamiseks on vaja andmeid PP hooajaliste kõikumiste ning igakuiste ja -aastaste summade kohta. PP ruumiliste variatsioonide tundmine on ökosüsteemi dünaamika mõistmisel väga oluline. Nagu öeldud, traditsioonilised *in situ* lähenemisviisid ei sobi usaldusväärseks PP hindamiseks suurtes mastaa-pides. Seetõttu on vaja täiendavat modelleerimist. Bio-optiline modelleerimine püüab parandada PP hindamist sügavusega integreeritud empiiriliste seoste kaudu, kaasates muutujad, mis moodustavad fotosünteesiliselt aktiivse

kiirguse nõrgenemise, fütoplanktonile omased neeldumisomadused ja fotosünteesi parameetreid [3–5].

Tänapäeval kasutatakse Maa looduslike parameetrite ja protsesside uurimiseks laialdaselt kaugseire andmeid [6, 7]. See on võimas vahend, kuna annab andmeid suure ruumilise katvuse ja tiheda ajalise sammuga. Seega on bio-optilise modelleerimise ja kaugseire kombineerimine kogu maailma järvede tootlikkuse hindamiseks suurepärase lahendus [8, 9].

Kuid siseveekogude kaugseire on siiski endiselt väljakutseks nende veekogude optilise keerukuse (vee koostisosade kontsentratsioonid varieeruvad üksteisest sõltumatult ja suurel määral, põhjustades probleemi, mille puhul paljud vee koostisosade kombinatsioonid võivad tekitada identseid kaugseiresignaale), kalda mõjude ja asjakohase atmosfäärikorrektsiooni puudumise tõttu [6]. Erinevatel järvedel hästi toimivate, n-ö „üks-kõigile“ kaugseirealgoritmide väljatöötamine on ilmselt võimatu; seega viimase aja suund on esmalt veespektrid eri optilistesse klassidesse määrata ja seejärel rakendada klassipõhiseid algoritme [10–13].

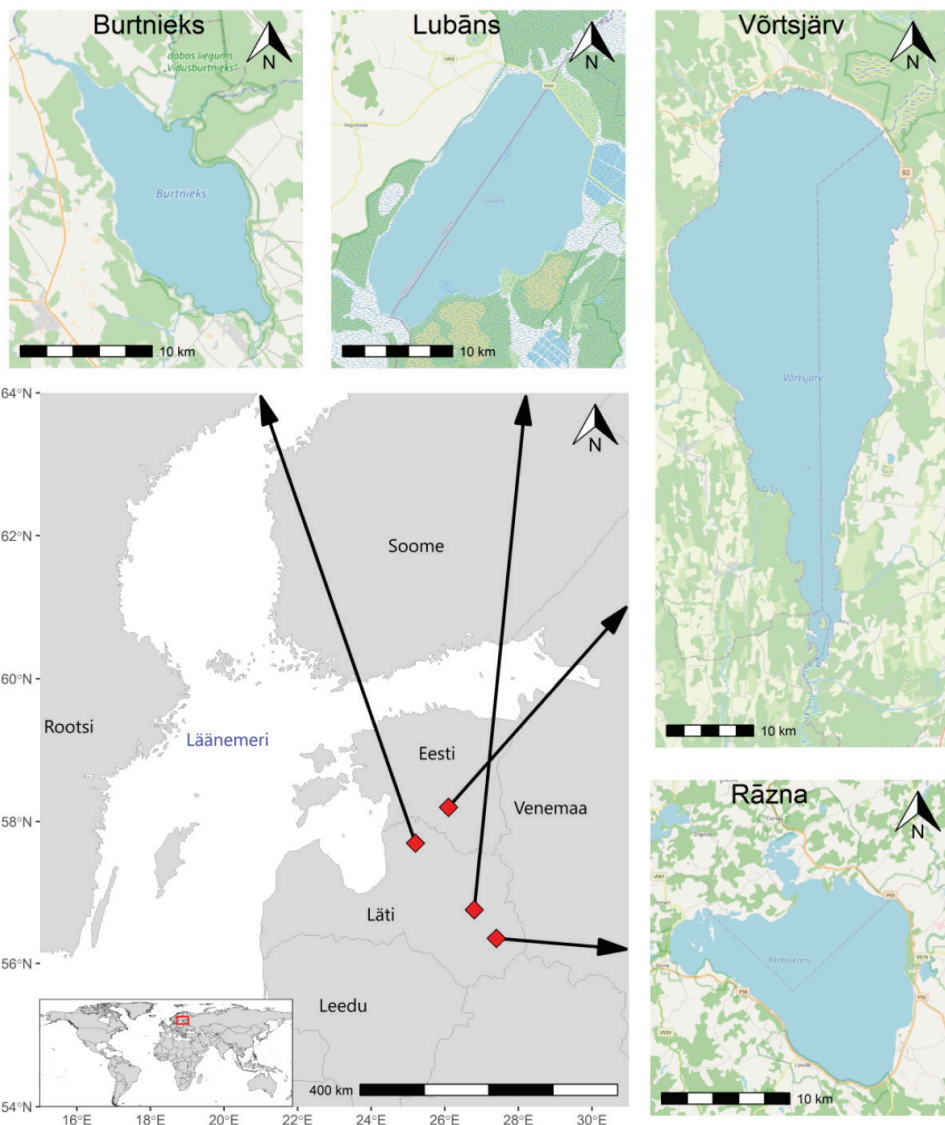
Mudelid PP arvutamiseks satelliidiandmete põhjal on välja kasvanud kõige lihtsamatest produktsioonimudelitest, mis hindasid PP profiile üle aja veepinna klorofüll-*a* funktsioonina [9], kuni keeruliste piirkondlike mudeliteni [4, 14] ja algoritmideni, mis kasutavad kaugseire andmeid globaalsete PP hinnangute jaoks [8]. Käesolevas töös kasutasime PP mudelit, mille töötasid välja Arst jt [15] optiliselt keerukate vete jaoks. Mudel võimaldab arvutada PP profiile (PP(*z*), mg C m⁻³ h⁻¹) kolme sisendparameetri alusel: pealelangev päikesekiirgus fotosünteesiliselt aktiivses piirkonnas (PAR, 400–700 nm; q_{PAR} , mol photons m⁻² h⁻¹), klorofüll-*a* kontsentratsioon vees (Chl-*a*, mg m⁻³) ja valguse difuusne nõrgenemistegur vees PAR-is ($K_{d,PAR}$, m⁻¹).

Meie peamiseks eesmärgiks oli hinnata süsiniku sidumise määra (päevast, kuist ja aastast) erinevates Baltikumi järvedes, ühendades 2018. aasta kaugseire andmed ja bio-optilise modelleerimise, ning uurida PP ajalist ja ruumilist varieeruvust järvedes, kasutades Sentinel-3A ja -3B pardal paiknevate keskmise eraldusvõimega OLCI sensorite andmeid.

Uurimisobjektid

Uuringualasse kuulus kolm Läti ja üks Eesti järv. Järvede asukohad on esitatud joonisel 1 ja nende geograafilised omadused tabelis 1.

Rāzna järv asub Lätis Latgale kõrgustikul ning tema pindala on 57,6 km² ja valgala 229 km². Rāzna on pindala järgi riigi suuruselt teine järv ja veemahu järgi suurim (0,46 km³). Riikliku seireandmebaasi kohaselt liigitatakse Rāzna järv selge veega madalaks järveks [16], kuigi suurim sügavus ulatub 17 meetrini (keskmise sügavus 7,0 m). Järv on mesotroofne; Secchi sügavus (SD) varieerus 3,2–6,6 m (mediaan 5,5 m) ja Chl-*a* 1,4–10,9 mg m⁻³ (mediaan 6,4 mg m⁻³) aprillist oktoobrini 2018 [11].



Joonis 1. Uuritavate järvede asukohad.

Lubānsi järv asub Ida-Läti madaliku keskel. Järve valgala on 2040 km². Kui veetase on 90 m kõrgusel merepinnast, on järve pindala 80,7 km². Kuid inimese poolt reguleeritud veetaseme tõttu võib järve pindala suuresti muutuda, olles 25–100 km² [16]. Lubānsi järv on liigitatud väga madalaks järveks, kus suurim sügavus on vaid 3,5 m ja keskmine sügavus 1,6 m. Järv on eutroofne ja makrofüütide ehk veetaimede poolt domineeritud; SD määrdeti 0,4–1,2 m (mediaan 0,9 m) ja Chl-*a* 8,6–63,1 mg m⁻³ (mediaan 16,8 mg m⁻³) 2018. aasta aprillist oktoobrini [11].

Tabel 1. Uuritavate järvede pindala, kõrgus merepinnast, keskmine sügavus, valgala suurus ja toitelisus.

Järve nimi	Asukoha koordinaadid	Pindala, km ²	Kõrgus, m	Keskmine sügavus, m	Valgala, km ²	Toitelisus
Rāzna	56°19'N 27°28'E	57,6	164	7,0	229	mesotroofne
Lubāns	56°46'N 26°52'E	80,7	90,0	1,6	2040	eutroofne
Võrtsjärv	58°16'N 26°02'E	270	33,7	2,8	3374	eutroofne
Burtnieks	57°44'N 25°14'E	40,2	47,0	2,4	2215	eutroofne

Võrtsjärv (pindala 270 km²) asub Eesti keskosas. See on riigi suuruselt teine järv, mille valgala on 3374 km². Võrtsjärv on samuti madal järv, mille suurim sügavus on 6,0 m (keskmine sügavus 2,8 m). Reguleerimata veetase võib kõikuda aastas kuni 3,2 m (keskmine 1,4 m) [17]. Selles eutroofses järves varieerus SD 0,5–1,0 m (mediaan 0,6 m) ja Chl-*a* vahemikus 22,2–63,8 mg m⁻³ (mediaan 33,1 mg m⁻³) 2018. aasta aprillist oktoobrini [11].

Burtnieksi järv asub Läti põhjaosas. See on suuruselt neljas järv Lätis, pindalaga 40,2 km² ja valgalaga 2215 km². Burtnieksi järv on madal eutroofne järv, mille suurim sügavus on 4,3 m (keskmine sügavus 2,4 m). Järves on pruun vesi, kus SD mõõdeti 0,4–1,2 m (mediaan 1 m) ja Chl-*a* 6,7–117,1 mg m⁻³ (mediaan 19,1 mg m⁻³) 2018. aasta aprillist oktoobrini [11].

Primaarproduktiooni mudel

Kasutatud PP mudel on välja töötatud optiliselt keerukate siseveekogude jaoks ning on üks väheseid bio-optilisi mudeleid, mis on kohandatud töötama kasutades vaid kaugseire andmeid [18–20]. Mudeli põhimõtteks on, et PP on fotosünteesiliselt neeldunud kiirguse ja süsiniku fikseerimise kvantsaagise funktsioon:

$$PP(z) = \Psi \cdot Q_{PAR}^*(z) \cdot F_{PAR}(z),$$

kus $PP(z)$ on primaarproduktioon (mg C m⁻³ h⁻¹) sügavusel z , Ψ on faktor 12 000, et teisendada süsiniku moolid milligrammideks, $Q_{PAR}^*(z)$ on fotosünteesiliselt neeldunud kiirgus sügavusel z (arvutatakse kvantkiirguse põhjal; mol photons m⁻³ h⁻¹) ja $F_{PAR}(z)$ on süsiniku fikseerimise kvantsaagis (mol C (mol photons⁻¹) PAR-is sügavusel z . Mudelil on vaid kolm sisendparameetrit: 1) klorofüll-*a* (mg m⁻³), 2) valguse difuusne nõrgenemistegur K_d (m⁻¹) PAR-is

ja 3) pealelangev kiirgus q_{inc} (mol photons $m^{-2} h^{-1}$), mis on kõik kättesaadavad kaugseireandmetest.

Selles uuringus järgisime Soometsa jt [19] poolt kaugseireandmete jaoks kohandatud PP mudeli arvutusskeemi ja hinnangutes kasutasime integraalse primaarproduktiooni väärtusi tunni kohta (PP_{int} , $mg\ C\ m^{-2}\ h^{-1}$), integreerides $PP(z)$ iga järve keskmise sügavuse järgi.

Mudeli tulemuste põhjal tehti järgmised täiendavad arvutused:

Kogu järve integraalne primaarproduktioon tunnis ($PP_{j\grave{a}rv}$, $mg\ C\ h^{-1}$) arvutati summeerides kõikide saadaolevate pikslite PP_{int} ning seejärel omistati kõikide järve pindalast puuduvate pikslite väärtuseks saadaolevate pikslite keskmine PP_{int} .

- Keskmine järve integraalne primaarproduktioon pindalaühiku kohta tunnis (PP_{kesk} , $mg\ C\ m^{-2}\ h^{-1}$) saadi jagades $PP_{j\grave{a}rv}$ järve pindalaga. Selle parameetri jaoks arvutasime uuringuperioodil (aprillist oktoobrini) ka standardhälbe (\pm).
- Kogu järve integraalne primaarproduktioon päevas ($PP_{j\grave{a}rv,p\grave{a}ev}$, $mg\ C\ p^{-1}$) arvutati korrutatades $PP_{j\grave{a}rv}$ antud päeva päevavalguse kestusega (h) ja koefitsiendi 0,75-ga, et võtta arvesse päevast valguskõverat.
- Kogu järve keskmine integraalne primaarproduktioon pindalaühiku kohta päevas ($PP_{p\grave{a}ev}$, $mg\ C\ m^{-2}\ p^{-1}$) saadi jagades $PP_{j\grave{a}rv,p\grave{a}ev}$ järve pindalaga.
- 2018. aasta järve koguproduktioon (PP_{aasta} , $Gg\ C\ a^{-1}$) saadi summeerides järve kuuproduktioonide väärtused aprillist oktoobrini. Kogu järve kuuproduktioonid saadi summeerides $PP_{j\grave{a}rv,p\grave{a}ev}$ väärtusi iga kuu jaoks üle kogu uurimisperioodi. Kui $PP_{j\grave{a}rv,p\grave{a}ev}$ väärtus puudus, kas satelliidipildi puudumise või pilvisuse tõttu, siis kasutati $PP_{j\grave{a}rv,p\grave{a}ev}$ väärtuse arvutamiseks inter- või ekstrapoleerimist.
- Aasta keskmine integraalne primaarproduktioon pindalaühiku kohta päevas ($PP_{aasta,kesk}$, $mg\ C\ m^{-2}\ p^{-1}$) arvutati jagades PP_{aasta} aastas olevate päevade arvu ja järve pindalaga.

Kaugseire andmed

Kasutati pilvevabu või osaliselt pilvevabu OLCI esimese taseme täislahutusega pilte (300×300 m), mis laaditi alla *Copernicus Open Access Hub* andmebaasist (koduleht: www.scihub.copernicus.eu). Esimene tase tähendab, et piltidele on tehtud radiomeetriline ja geomeetriline korrigeerimine, kuid tulemus näitab kiirgust sensori kõrgusel ehk atmosfääri kohal. Kuna üle 90% vee kohal satelliidi kõrgusel mõõdetud kiirgusest tuleneb atmosfäärist ega anna infot vee kohta, siis on hädavajalik korrigeerida kiirguseid atmosfääri suhtes. Tuginedes eelnevatele töödele rakendati esimese taseme piltidele atmosfäärikorrigeerimise protsessoriga (Case-2 Regional Coast Colour [21]), et saada PP mudeli sisendid. Lisaks rakendati igale pildile multisensoriline pikslituvastuse protsessor (IdePix) ja edasises analüüsis kasutati vaid pilvevabu veepikslid, jättes välja eelnevalt mainitud protsessorite kvaliteedianalüüsis

tuvastatud pilvepikslid. Primaarproduktiooni modelleerimisel kasutati vaid pilte, millel oli pärast kvaliteedianalüüsi rohkem kui 50% järvepikslitest.

Tulemusena saadi iga piksli kohta mudeli kaks sisendit: klorofüllü kontsentratsiooni hindav produkt (conc_chl) ja vees valguse nõrgenemistegurit hindav produkt (kd_490). Kuna standardsed kaugseire Chl-*a* ja K_d tulemid neis optiliselt keerukates siseveekogudes sageli ebaõnnestuvad, kasutati nende järvede jaoks välja töötatud alternatiivset lahendust (üksikasjalik selgitus on leitav [11]).

Chl-*a* väärtuste arvutamiseks kasutati optilise veetüübi klassifikatsiooni põhist meetodit, mis tähendab, et esiteks määrati optiline veetüüp igale analüüsis kasutatud pikslile, kasutades selleks Uudebergi jt [12] meetodit, ning seejärel rakendati vastavalt piksli optilisele veetübile Soometsa jt [11] väljatöötatud sobivaimat algoritmi. Antud töös kasutatud veetüüpide klassifikatsioon eristab viit optilist veetüüpi: 1) selge veetüüp vastab madala optiliselt aktiivsete ainete (OAA, klorofüll, hõljum ja humiinained) taseme ja suure läbipaistvusega veele; 2) mõõdukas veetüüp vastab veidi kõrgematele OAA kontsentratsioonidele, kuid ükski neist ei domineeri; 3) hägune veetüüp vastab vetele, kus domineerib hõljum; 4) väga hägune veetüüp vastab vetele, kus domineerib Chl-*a*, ja on seotud fütoplanktoni öitsengutega; ja 5) pruun veetüüp vastab vetele, kus domineerivad humiinained ehk värvunud lahustunud orgaanilised ained.

$K_{d,PAR}$ väärtuste leidmine OLCI andmetest koosnes kahest peamisest etapist. Esiteks arvutati veelune valguse difuusne nõrgenemistegur 490 nm juures ($K_{d,490}$) veest väljuva peegeldusspektri põhjal, kasutades Alikase jt [22] algoritme. Teiseks arvutati saadud tulemustest $K_{d,PAR}$ väärtus.

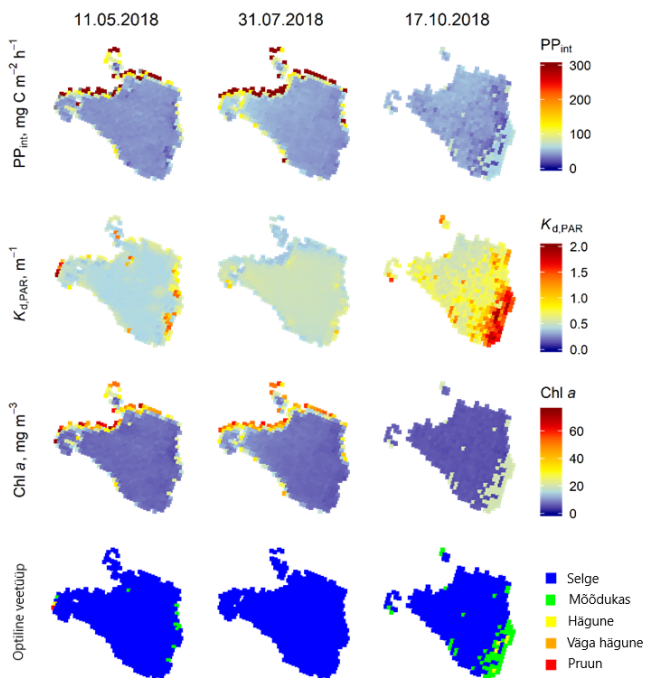
Kolmas vajalik parameeter, pealelangev kiirus ($\mu\text{mol m}^{-2} \text{s}^{-1}$) PAR-is, saadi mõõdetuna tunnikeskmissena SMEAR-Estonia Järvelja uurimisjaamas Eestis (58°16'40.60"N, 27°18'30.84"E) 2018. aastal [23]. PP mudeli q_{PAR} sisendi puhul kasutasime mõõdetud päevaseid maksimumväärtusi, mis teisendati mooli footoniteks ruutmeetri kohta tunnis ($\text{mol photons m}^{-2} \text{h}^{-1}$) iga päeva kohta, mil meil olid OLCI andmed.

Tulemused ja arutelu

PP ruumiline varieeruvus

PP_{int} ruumilist varieeruvust uuriti OLCI pilvevabadest või osaliselt pilvevabadest piltidest tuletatud PP_{int} ruumilise varieeruvuse kaartide abil 2018. aastal; kokku koostasime 161 PP_{int} kaarti (umbes 40 iga uuritud järve kohta). Saadud PP_{int} ($\text{mg C m}^{-2} \text{h}^{-1}$) näited koos PP mudeli tuletatud sisenditega on esitatud joonistel 2–5.

Selge veega Rāzna järv näitas PP_{int} vähest ruumilist varieeruvust. Kevadel ja suvel oli järve põhjakaldal tõenäosus suuremaks PP_{int}-ks (joonis 2). Sügisel oli järve lõunaosas veidi suurem tootlikkus. Selge optiline veetüüp oli Rāzna järves väga domineeriv ja enamikul pikslitest olid siseveekogude jaoks suhteliselt madalad Chl-*a* (keskmise 11,1 ±17,3 mg m^{-3}) ja $K_{d,PAR}$ (keskmise 0,62 ±0,57 m^{-1})




Joonis 2. Kolm näidet Rāzna järve modelleeritud integraalsest primaarproduktioonist (PP_{int} , $\text{mg C m}^{-2} \text{h}^{-1}$) (esimene rida), valguse difuussest nõrgenemistegurist fotosünteesilisel aktiivses piirkonnas ($K_{d,PAR}$, m^{-1}) (teine rida), klorofüll- a kontsentratsioonist ($\text{Chl-}a$, mg m^{-3}) (kolmas rida) ja optilisest veetüübist (neljas rida), mis on saadud satelliidi (Sentinel-3 OLCI) andmetest.

väärtused; seetõttu oli ka järve tootlikkus madal. PP_{kesk} uuringuperioodil oli $51,2 \pm 14,9 \text{ mg C m}^{-2} \text{h}^{-1}$.

Eutroofne Lubānsi järv näitas bio-optiliste omaduste suurt ruumilist varieeruvust; kogu uuringuperioodi jooksul klassifitseeriti veed enamasti hägusesse ja väga hägusesse veetüüpi. Lubānsi järve eripärasus oli avaveelise järveosa märgatav vähenemine veetaimestiku tõttu. Seda oli selgelt näha augusti lõpus ja septembris, kus avavee pindala vähenes oluliselt (joonis 3, 19.09.2018). Keskmine $\text{Chl-}a$ oli $42,4 \pm 40,0 \text{ mg m}^{-3}$, mediaanväärtus oli palju madalam ($29,4 \text{ mg m}^{-3}$), ja keskmine $K_{d,PAR}$ oli $2,52 \pm 1,08 \text{ m}^{-1}$. PP_{kesk} oli uuringuperioodil $90,9 \pm 53,9 \text{ mg C m}^{-2} \text{h}^{-1}$.

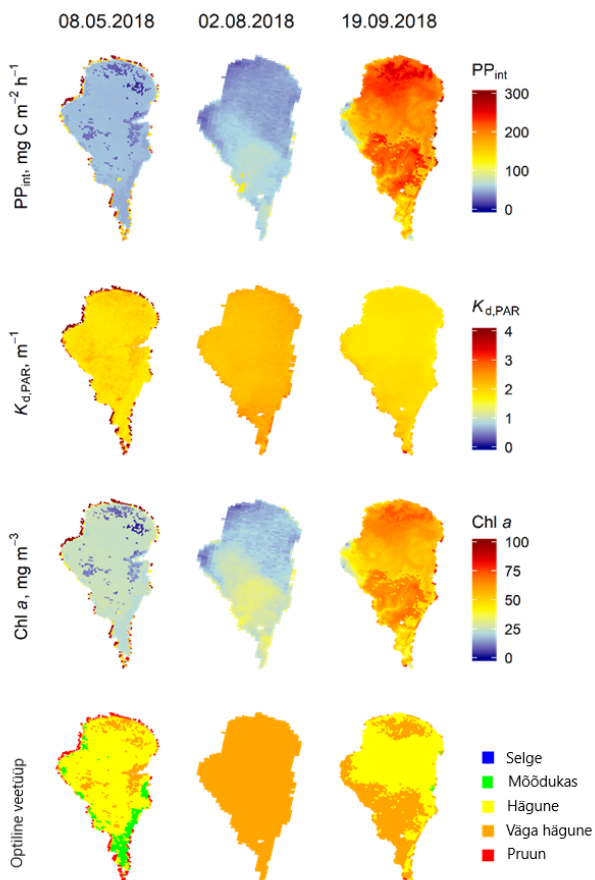
Suurimas uuritud järves Võrtsjärves näitas PP_{int} suhteliselt suurt ruumilist varieeruvust. PP_{int} oli sageli kõrgem järve lõunaosas ja mõnel juhul oli jõe sissevool selgelt nähtav järve edelaosas, kus PP_{int} väärtused olid veidi madalamad kui ümbritsevas vetes (joonis 4, 19.09.2018). Domineerivaks veetüübiks oli kas hägune või väga hägune. Keskmine $\text{Chl-}a$ oli $33,4 \pm 20,4 \text{ mg m}^{-3}$, kuid öitsemise tingimustes palju kõrgem, ja keskmine $K_{d,PAR}$ oli $2,15 \pm 0,55 \text{ m}^{-1}$. PP_{kesk} oli uuringuperioodil sarnane Lubānsi järvega: $100,0 \pm 65,1 \text{ mg C m}^{-2} \text{h}^{-1}$.



Joonis 3. Kolm näidet Lubānsi järve modelleeritud integraalsest primaarproduktioonist (PP_{int} , $\text{mg C m}^{-2} \text{h}^{-1}$) (esimene rida), valguse difussest nõrgenemistegurist fotosünteesiliselt aktiivses piirkonnas ($K_{d,PAR}$, m^{-1}) (teine rida), klorofüll- a kontsentratsioonist ($\text{Chl-}a$, mg m^{-3}) (kolmas rida) ja optilisest veetüübist (neljas rida), mis on saadud satelliidi (Sentinel-3 OLCI) andmetest.

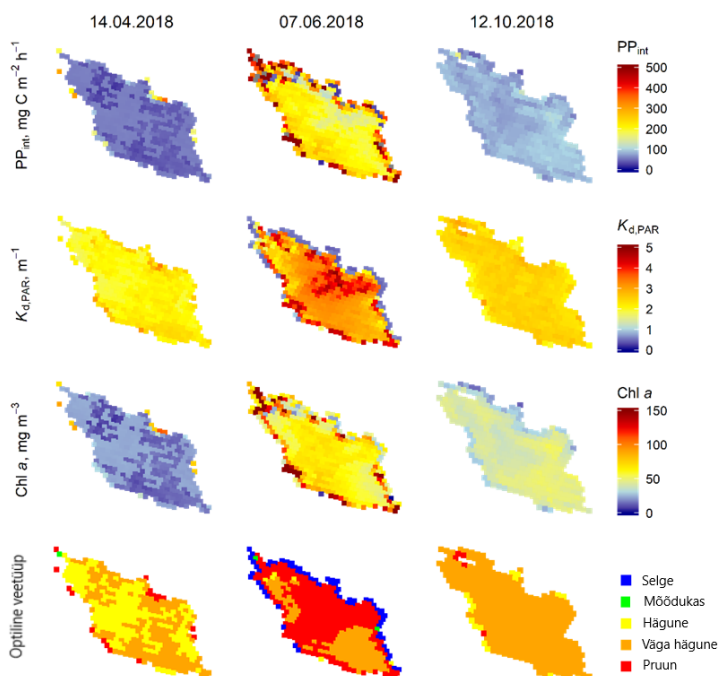
Uuringu väikseim ja kõige pruunima veega järv Burtnieks näitas kõigi bio-optiliste omaduste ja PP_{int} suurimat varieeruvust. Kogu järves oli eriti suur produktioon hilissuvel. Sageli oli järve ümber selge veetüübiga kaldajoon (joonis 5), mis tõenäoliselt on klassifikatsiooni viga ja on seletatud peatüki lõpus. Domineeriv veetüüp oli kas hägune, väga hägune või pruun, kuid ka mõõdukas veetüüp oli sageli esindatud. Keskmise $\text{Chl-}a$ oli $43,5 \pm 37,3 \text{ mg m}^{-3}$, mediaanväärtus oli palju madalam ($27,7 \text{ mg m}^{-3}$), ja keskmine $K_{d,PAR}$ oli $2,58 \pm 1,02 \text{ m}^{-1}$. PP_{kesk} oli uuringuperioodil $139,2 \pm 108,6 \text{ mg C m}^{-2} \text{h}^{-1}$.

Burtnieksi ja Lubānsi järve puhul on järve kaldal sagedasti selget veetüüpi, mis on tõenäoliselt tingitud C2RCC atmosfäärikorrektsiooni probleemidest [12, 24]. Tumeda vee (pruun veetüüp) puhul on suur osa signalist tegelikult veepinnalt peegeldunud kiirgus ja veest tulenev kiirgus on väike, mistõttu atmosfäärikorrektsioon



Joonis 4. Kolm näidet Võrtsjärve modelleeritud integraalsest primaarproduktioonist (PP_{int} , $\text{mg C m}^{-2} \text{h}^{-1}$) (esimene rida), valguse difussest nõrgenemistegurist fotosünteetiliselt aktiivses piirkonnas ($K_{d,PAR}$, m^{-1}) (teine rida), klorofüll-*a* kontsentratsioonist ($\text{Chl-}a$, mg m^{-3}) (kolmas rida) ja optilisest veetüübist (neljas rida), mis on saadud satelliidi (Sentinel-3 OLCI) andmetest.

tugevalt ülehindab spektri sinist [25, 26]. See võib põhjustada selge veetüübi valesti klassifitseerimist. Teine põhjus, mis põhjustab piksli valesti klassifitseerimist, võib olla veesisese taimestiku mõju peegeldusspektrile. IdePixi ja C2RCC protsessori ebapiisav ja/või halb selgete veepikslite markeerimine võib samuti põhjustada olukorra, kus need pikslid liigitatakse ekslikult selgeteks veepiksliteks. Seega on Lubänsi järve puhul piksli tüübi valesti klassifitseerimise põhjuseks veetaimestik ja Burtneiksi järve puhul pruun vesi. Vaatamata eespool käsitletud probleemidele on meie 2018. aasta veetüübi klassifikatsiooni tulemused üldiselt sarnased 2017. aasta uuringuga [24].



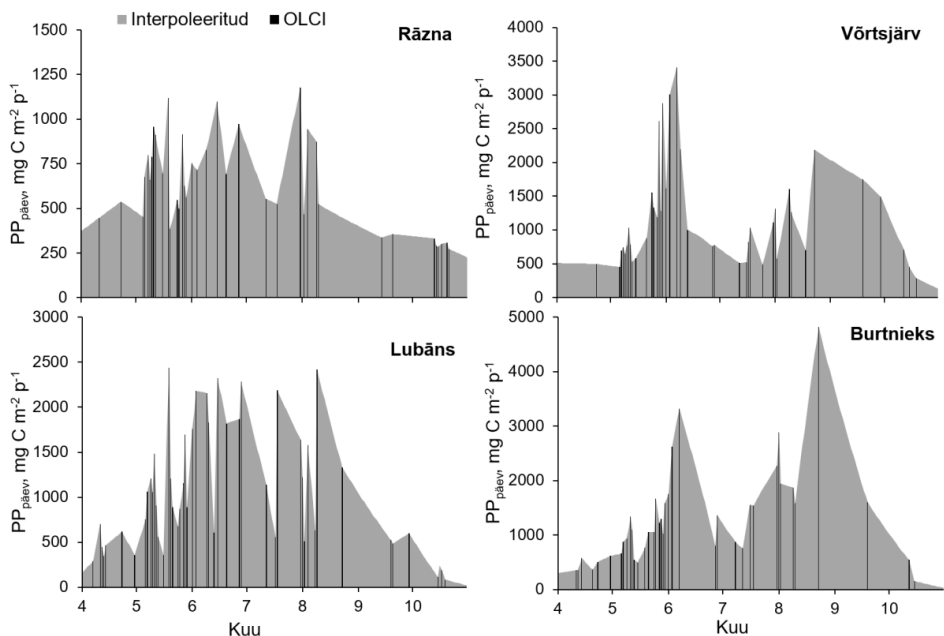
Joonis 5. Kolm näidet Burtnieksi järve modelleeritud integraalsest primaarproduktioonist (PP_{int} , $\text{mg C m}^{-2} \text{h}^{-1}$) (esimene rida), valguse difuussest nõrgenemistegurist fotosünteetiliselt aktiivses piirkonnas ($K_{d,PAR}$, m^{-1}) (teine rida), klorofüll- a kontsentratsioonist ($\text{Chl } a$, mg m^{-3}) (kolmas rida) ja optilisest veetüübist (neljas rida), mis on saadud satelliidi (Sentinel-3 OLCI) andmetest.

PP ajaline varieeruvus

Arvutasime OLCI andmete põhjal välja kogu järve keskmise päevaproduktiooni ($PP_{päev}$). Aprillist oktoobrini oli meil umbes 40 satelliidipilti iga järve jaoks (Rāzna 38, Burtnieks 40, Lubāns 42, Vörtsjārv 41). Kõige rohkem pilvevabu pilte oli mais, kuid septembris-oktoobris oli meil kasutada vaid üksikuid pilte. Novembrist aprillini ei olnud pilvevabu pilte või olid järved jääga kaetud. $PP_{päev}$ ajaline varieeruvus näitab iga järve puhul erinevaid mustreid (joonis 6).

Vörtsjārves ja Burtnieksi järves näitas $PP_{päev}$ uurimisperiodil selget kahetipulist mustrit. Esimene produktiooni haripunkt oli hiliskevadel / suve alguses (juuni esimene pool) ja teine oli hilissuvel (augusti lõpus ja septembris) (joonis 6). Nende järvede sesoonse varieeruvuse peamine erinevus oli teise kõrge PP perioodi kestus. Vörtsjārves kestis hilissuvine kõrge PP kauem (1,5 kuud) ja ei olnud nii intensiivne kui kevadine. Burtnieksi järves kestsid mõlemad kõrge PP-ga perioodid umbes 3 nädalat ja teine periood oli intensiivsem (joonis 6).

$PP_{päev}$ ajaline varieeruvus oli Rāzna järves ja Lubānsis üsna sarnane: mõlemas järves puudub suvine „selge“ periood kahe kõrge tootlikkuse perioodi vahel.




Joonis 6. Kogu järve keskmine integraalne primaarproduksioon pindalaühiku kohta päevas ($PP_{\text{päev}}$, $\text{mg C m}^{-2} \text{p}^{-1}$) neljas uuritud järves ajavahemikul 01.04.2018–31.10.2018. Sentinel-3 OLCI andmete modelleeritud väärtused on mustade joontena ja interpoleeritud väärtused nende vahel halli alana.

Rāzna järves toimus maksimaalne PP suve alguses, samas kui Lubānsi järves oli see hilissuvel (joonis 6).

Burtnieksi järve teine väga iseloomulik tunnus oli $PP_{\text{päev}}$ väärtuste suur varieeruvus. Näiteks $PP_{\text{päev}}$ vahemik oli uuringuperioodil üle $4600 \text{ mg C m}^{-2} \text{p}^{-1}$, olles $4817 \text{ mg C m}^{-2} \text{p}^{-1}$ 23.08.2018 ja $156 \text{ mg C m}^{-2} \text{p}^{-1}$ 15.10.2018. Teised järved näitasid palju väiksemaid $PP_{\text{päev}}$ vahemikke, Rāzna järves oli varieeruvus väiksem: $950 \text{ mg C m}^{-2} \text{p}^{-1}$. Rāzna järves oli ka madalaim maksimaalne PP päevaväärtus ($1177 \text{ mg C m}^{-2} \text{p}^{-1}$), Burtnieksi järves oli see aga 4 korda kõrgem.

Üldiselt olid $PP_{\text{päev}}$ tulemused Lubānsi järve puhul kogu suve jooksul üsna kõrged, ilma et oleks selgeid PP puhanguid nagu Burtnieksi järves (joonis 6). Burtnieksi järve väga kõrgete $PP_{\text{päev}}$ maksimumide tõttu oli PP_{kesk} samuti umbes 30% kõrgem kui Võrtsjärves ja Lubānsi järves. Kõrgemad PP_{int} väärtused kaldaaladel on kõigis järvedes üsna tavalised, kuid kõige silmapaistvam on Burtnieksi järv, kus seda põhjustavad aeglasem veevahetusrežiim ja toitaineterikkad veed. Teine võimalik põhjus kõrgematele väärtustele kaldaalal on „kalda efekt“ — spektraalsignaali on mõjutatud maa poolt peegeldunud kiirgusest, mida atmosfäär levitab satelliidi andurisse [27].

Järve suurus mängib järve iga-aastases produktsioonis olulist rolli. Aasta-produktsiooni saime summeerides kogu järve produktsiooni igakuised summad aprillist oktoobrini. Eeldasime, et produktsioon novembrist märtsini ei olnud



Joonis 7. 2018. aasta järve koguproduksioon (PP_{aasta} , Gg C a⁻¹) neljas uuritud järves.

Tabel 2. Järvede võrdlus: nende pindala (P , km²), keskmine sügavus (S , m), aastane järve koguproduksioon (PP_{aasta} , Gg C a⁻¹) ja aasta keskmine produktsioon pindalaühiku kohta päevas ($PP_{aasta,kesk}$, mg C m⁻² p⁻¹).

Järv	P (km ²)	S (m)	PP_{aasta} (Gg C a ⁻¹)	$PP_{aasta,kesk}$ (mg C m ⁻² p ⁻¹)	Viide
Superior	82103	149	8100	274	
Huron	59590	59	5300	247	[29]
Michigan	58030	85	6300	301	[30]
Tanganyika	32900	570	7651	646	[14]
Taihu	2338	1,9	890	1094	[5]
Genfi	580	155	180	828	[19]
Vörtsjārv	270	2,8	61	622	Käesolev uurimus
Lubāns	80,7	1,6	18	610	Käesolev uurimus
Burtnieks	40,2	2,4	13	887	Käesolev uurimus
Rāzna	57,6	7	7	333	Käesolev uurimus

märkimisväärne [28]. Kogu järve 2018. aasta produktsioon varieerus 7 Gg C a^{-1} (Räzna) kuni 61 Gg C a^{-1} (Vörtsjärv) (joonis 7).

Kui uurida tervet järve kui süsinikutootjat, siis on järve suurus ilmselgelt oluline tegur. Näiteks on kogu Suur Järvistu Ameerikas (sealhulgas Erie, Huroni, Michigani, Ontario ja Superiori järv; kõik on maailma 15 suurima järve hulgas) 300 korda suurem kui näiteks Genfi järv ja aastatoodang on seal üle 120 korra suurem, kuid keskmise päevase produktsiooni väärtused on seal madalamad (tabel 2). Lisaks järve suurusele peab silmas pidama ka kliimatingimusi ja järve morfoloogiat. Näiteks madalas (keskmise sügavus ligi 3 m) eutroofses Vörtsjärves, mis on üle 4 kuu aastast kaetud jääga ja tootlikkus sel ajal nullilähedane [28], on süsinikutoodang ligi 3 korda väiksem kui väga sügavas (keskmise sügavus 155 m, millest produktsioon võib ulatuda ligi 30 m sügavusele) selge veega Genfi järves, kus produktsioon toimub aastaringselt. Seetõttu on eri järvi võrreldes korrektsem kirjeldada järve produktsiooni pindalaühiku kohta teatud perioodil (nt üks suvekuu), mitte kogu järve PP aastas.

Kuigi esialgu võib tabelit 2 vaadates tunduda, et väiksemad järved ei panusta märkimisväärselt süsinikuringesse, katavad $1\text{--}1000 \text{ km}^2$ pindalaga järved umbes 36% ($\sim 1,9$ miljonit km^2) kõigi maailma järvede kogupindalast ja ainult umbes 29% sellest alast moodustavad 225 maailma suurimat järve (pindala $>1000 \text{ km}^2$) [1]. Tabelist 2 on ka näha, et tavaliselt on väiksemad järved pindalaühiku kohta produktiivsemad. Kuid sellest hoolimata on vaid väga väike osa väiksematest järvedest regulaarselt seiratud, mistõttu ei võeta arvesse suurt osa ülemaailmsest magevee tootlikkusest. Seetõttu on kaugseire äärmiselt oluline vahend ülemaailmse süsinikuringe ja PP uurimiseks järvedes.

Kokkuvõte

Kogu veekogu ökosüsteemi ja toiduahela aluseks on fütoplanktoni primaarproduktsioon. Kuigi see on äärmiselt oluline parameeter, on seda väga keeruline ning kallis mõõta. Tihti on mudelarvutused ainus viis, kuidas saada kogu veekogu kohta ruumilist või ajalist infot. Siinkohal annab kaugseireandmete ja mudelarvutuste kombineerimine lihtsa lahenduse hindamiseks PP-d ajas ja ruumis. Koostatud PP kaardid näitavad selgelt, et üks mõõtepunkt ei esinda kogu järve ning PP hindamiseks kogu järve ulatuses on vaja rohkem kohapeal asuvaid proovivõtupaiku või kaugseiret, sest järvede PP ruumiline muutlikkus on suur. Selles uuringus kasutasime Sentinel-3 OLCI andmetel põhinevat PP bio-optilist mudelit. 2018. aasta keskmine päevane tootlikkus $PP_{\text{aasta,kesk}}$ Räzna järves oli $333 \text{ mg C m}^{-2} \text{ p}^{-1}$, Lubänsi järves $610,2 \text{ mg C m}^{-2} \text{ p}^{-1}$, Vörtsjärves $622,4 \text{ mg C m}^{-2} \text{ p}^{-1}$ ja Burtnieksi järves $887,3 \text{ mg C m}^{-2} \text{ p}^{-1}$. See näitab, et kõige produktiivsem järv oli väikseim uuritud järvedest. 2018. aasta kogutoodang kogu järve kohta oli 7 Gg C a^{-1} (Räzna järv), 13 Gg C a^{-1} (Burtnieksi järv), 18 Gg C a^{-1} (Lubänsi järv) ja 61 Gg C a^{-1} (Vörtsjärv). Isegi kui järve suurus on kogu järve aastases PP-s oluline, siis väikesed ja

keskmise suurusega järved omavad märkimisväärset tähtsust süsinikuringes oma suure arvukuse tõttu.

Viidatud kirjandus

1. Verpoorter, C.; Kutser, T.; Seekell, D.A.; Tranvik, L.J. A global inventory of lakes based on high-resolution satellite imagery. *Geophys. Res. Lett.* 2014, 41, 6396–6402, doi:10.1002/2014GL060641.
2. Tranvik, L.J.; Downing, J.A.; Cotner, J.B.; Loiselle, S.A.; Striegl, R.G.; Ballatore, T.J.; Dillon, P.; Finlay, K.; Fortino, K.; Knoll, L.B.; et al. Lakes and reservoirs as regulators of carbon cycling and climate. *Limnol. Oceanogr.* 2009, 54, 2298–2314, doi:10.4319/lo.2009.54.6_part_2.2298.
3. Platt, T.; Sathyendranath, S. Oceanic Primary Production: Estimation by Remote Sensing at Local and Regional Scales. *Science* (80-). 1988, 241, 1613–1620, doi:10.1126/science.241.4873.1613.
4. Behrenfeld, M.J.; Falkowski, P.G. Photosynthetic rates derived from satellite-based chlorophyll concentration. *Limnol. Oceanogr.* 1997, 42, 1–20, doi:10.4319/lo.1997.42.1.0001.
5. Deng, Y.; Zhang, Y.; Li, D.; Shi, K.; Zhang, Y. Temporal and Spatial Dynamics of Phytoplankton Primary Production in Lake Taihu Derived from MODIS Data. *Remote Sens.* 2017, 9, 195, doi:10.3390/rs9030195.
6. Palmer, S.C.J.; Kutser, T.; Hunter, P.D. Remote sensing of inland waters: Challenges, progress and future directions. *Remote Sens. Environ.* 2015, 157, 1–8, doi:10.1016/j.rse.2014.09.021.
7. Tyler, A.N.; Hunter, P.D.; Spyarakos, E.; Groom, S.; Constantinescu, A.M.; Kitchen, J. Developments in Earth observation for the assessment and monitoring of inland, transitional, coastal and shelf-sea waters. *Sci. Total Environ.* 2016, 572, 1307–1321, doi:10.1016/j.scitotenv.2016.01.020.
8. Kulk, G.; Platt, T.; Dingle, J.; Jackson, T.; Jönsson, B.F.; Bouman, H.A.; Babin, M.; Brewin, R.J.W.; Doblin, M.; Estrada, M.; et al. Primary Production, an Index of Climate Change in the Ocean: Satellite-Based Estimates over Two Decades. *Remote Sens.* 2020, 12, 826, doi:10.3390/rs12050826.
9. Eppley, R.; Stewart, E.; Abbott, M.; Owen, R. Estimating ocean production from satellite-derived chlorophyll: Insights from the Eastropac data set. *Oceanol. Acta, Spec. issue* 1987, 109–113.
10. Spyarakos, E.; O'Donnell, R.; Hunter, P.D.; Miller, C.; Scott, M.; Simis, S.G.H.; Neil, C.; Barbosa, C.C.F.; Binding, C.E.; Bradt, S.; et al. Optical types of inland and coastal waters. *Limnol. Oceanogr.* 2018, 63, 846–870, doi:10.1002/lno.10674.
11. Soomets, T.; Uudeberg, K.; Jakovels, D.; Brauns, A.; Zagars, M.; Kutser, T. Validation and Comparison of Water Quality Products in Baltic Lakes Using Sentinel-2 MSI and Sentinel-3 OLCI Data. *Sensors* 2020, 20, 742, doi:10.3390/s20030742.
12. Uudeberg, K.; Ansko, I.; Põru, G.; Ansper, A.; Reinart, A. Using Optical Water Types to Monitor Changes in Optically Complex Inland and Coastal Waters. *Remote Sens.* 2019, 11, 2297, doi:10.3390/rs11192297.

13. Eleveld, M.; Ruescas, A.; Hommersom, A.; Moore, T.; Peters, S.; Brockmann, C. An Optical Classification Tool for Global Lake Waters. *Remote Sens.* 2017, 9, 420, doi:10.3390/rs9050420.
14. Bergamino, N.; Horion, S.; Stenuite, S.; Cornet, Y.; Loisel, S.; Plisnier, P.D.; Descy, J.P. Spatio-temporal dynamics of phytoplankton and primary production in Lake Tanganyika using a MODIS based bio-optical time series. *Remote Sens. Environ.* 2010, 114, 772–780, doi:10.1016/j.rse.2009.11.013.
15. Arst, H.; Nõges, T.; Nõges, P.; Paavel, B. In situ measurements and model calculations of primary production in turbid waters. *Aquat. Biol.* 2008, 3, 19–30, doi:10.3354/ab00059.
16. LEGMC (State Limited Liability Company “Latvian Environment, Geology and Meteorology Centre”) National Monitoring Database. Available online: www.meteo.lv/fs/CKFinderJava/userfiles/files/Par_centru/ES_projekti/Projekts_Udens_kvalitate/Assessment_on_data_availability_and_quality.do (accessed on May 1, 2020).
17. Nõges, T.; Nõges, P.; Laugaste, R. Water level as the mediator between climate change and phytoplankton composition in a large shallow temperate lake. *Hydrobiologia* 2003, 506–509, 257–263, doi:10.1023/B:HYDR.0000008540.06592.48.
18. Kauer, T.; Kutser, T.; Arst, H.; Danckaert, T.; Nõges, T. Modelling primary production in shallow well mixed lakes based on MERIS satellite data. *Remote Sens. Environ.* 2015, 163, 253–261, doi:10.1016/j.rse.2015.03.023.
19. Soomets, T.; Kutser, T.; Wüest, A.; Bouffard, D. Spatial and temporal changes of primary production in a deep peri-alpine lake. *Inl. Waters* 2019, 9, 49–60, doi:10.1080/20442041.2018.1530529.
20. Soomets, T.; Uudeberg, K.; Kangro, K.; Jakovels, D.; Brauns, A.; Toming, K.; Zagars, M.; Kutser, T. Spatio-Temporal Variability of Phytoplankton Primary Production in Baltic Lakes Using Sentinel-3 OLCI Data. *Remote Sens.* 2020, 12, 2415, doi:10.3390/rs12152415.
21. Brockmann, C.; Doerffer, R.; Peters, M.; Stelzer, K.; Embacher, S.; Ruescas, A. Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters.; ESA Living Planet Symposium: Prague, 2016.
22. Alikas, K.; Kratzer, S.; Reinart, A.; Kauer, T.; Paavel, B. Robust remote sensing algorithms to derive the diffuse attenuation coefficient for lakes and coastal waters. *Limnol. Oceanogr. Methods* 2015, 13, 402–415, doi:10.1002/lom3.10033.
23. Kuusk, J.; Kuusk, A. Hyperspectral radiometer for automated measurement of global and diffuse sky irradiance. *J. Quant. Spectrosc. Radiat. Transf.* 2018, 204, 272–280, doi:10.1016/j.jqsrt.2017.09.028.
24. Soomets, T.; Uudeberg, K.; Jakovels, D.; Zagars, M.; Reinart, A.; Brauns, A.; Kutser, T. Comparison of Lake Optical Water Types Derived from Sentinel-2 and Sentinel-3. *Remote Sens.* 2019, 11, 2883, doi:10.3390/rs11232883.
25. Kutser, T.; Paavel, B.; Verpoorter, C.; Ligi, M.; Soomets, T.; Toming, K.; Casal, G. Remote Sensing of Black Lakes and Using 810 nm Reflectance Peak for Retrieving Water Quality Parameters of Optically Complex Waters. *Remote Sens.* 2016, 8, 497, doi:10.3390/rs8060497.
26. Matthews, M.W.; Bernard, S.; Lain, L.R.; Griffith, D.; Odermatt, D.; Kutser, T. Understanding the Satellite Signal from Inland and Coastal Waters. In *Earth Observations*

- in Support of Global Water Quality Monitoring; Greb, S., Dekker, A., Binding, C.E., Eds.; International Ocean Color Coordinating Group, 2018; pp. 55–68.
27. Bulgarelli, B.; Kiselev, V.; Zibordi, G. Adjacency effects in satellite radiometric products from coastal waters: a theoretical analysis for the northern Adriatic Sea. *Appl. Opt.* 2017, 56, 854, doi:10.1364/AO.56.000854.
 28. Nöges, T.; Arst, H.; Laas, A.; Kauer, T.; Nöges, P.; Töming, K. Reconstructed long-term time series of phytoplankton primary production of a large shallow temperate lake: the basis to assess the carbon balance and its climate sensitivity. *Hydrobiologia* 2011, 667, 205–222, doi:10.1007/s10750-011-0647-y.
 29. Sanches, L.F.; Guenet, B.; Marinho, C.C.; Barros, N.; de Assis Esteves, F. Global regulation of methane emission from natural lakes. *Sci. Rep.* 2019, 9, 255, doi:10.1038/s41598-018-36519-5.
 30. Yousef, F.; Charles Kerfoot, W.; Shuchman, R.; Fahnenstiel, G. Bio-optical properties and primary production of Lake Michigan: Insights from 13-years of SeaWiFS imagery. *J. Great Lakes Res.* 2014, 40, 317–324, doi:10.1016/j.jglr.2014.02.018.

Summary

Modelling phytoplankton primary production in Estonian and Latvian lakes using Sentinel-3 data

Phytoplankton primary production (PP) in lakes plays an important role in the global carbon cycle. However, monitoring PP in lakes with traditional complicated and costly in situ sampling methods is impossible due to the large number of lakes worldwide (according to estimations 117 million lakes). In this study, bio-optical modelling and remote sensing data (Sentinel-3 Ocean and Land Colour Instrument) were combined to investigate the spatial and temporal variation of PP in four Baltic lakes during 2018. The model used has three input parameters: concentration of chlorophyll-*a*, the diffuse attenuation coefficient, and incident downwelling irradiance. The largest of our studied lakes, Lake Võrtsjärv (270 km²), had the highest total yearly estimated production (61 Gg C y⁻¹) compared to the smaller lakes Lubans (18 Gg C y⁻¹) and Razna (7 Gg C y⁻¹). However, the most productive was the smallest lake studied, Lake Burtnieks (40.2 km²); although the total yearly production was 13 Gg C y⁻¹, the daily average areal production was 910 mg C m⁻² d⁻¹ in 2018. Even if lake size plays a significant role in the total PP of the lake, the abundance of small and medium-sized lakes would sum up to a significant contribution of carbon fixation. Our method is applicable to larger regions for monitoring the spatial and temporal variability of lake PP.

Sentinel-i satelliitide andmetel põhinev operatiivne jääseireteenus

Sander Rikka^{1*}, Liis Sipelgas¹, Martin Simon², Jekaterina Služenikina³, Laura Siitam¹, Rivo Uiboupin¹

¹Tallinna Tehnikaülikool, meresüsteemide instituut, Akadeemia tee 15a, 12618 Tallinn

²Tallinna Tehnikaülikool, tarkvarateaduse instituut, Akadeemia tee 15a, 12618 Tallinn

³Keskonnaagenteer, Riigi Ilmateenistus, Mustamäe tee 33, 10616 Tallinn

Kokkuvõte

Artikkel annab ülevaate projekti „Jääkaardi koostamise infosüsteemi loomine“ raames satelliitide Sentinel-1, -2 ja -3 andmetest loodud produktidest, mida kasutatakse jääkaardi koostamisel ning jagatakse avalikkusele veebirakenduse kaudu. Produktide arendamisel kasutati masinõppe metoodikaid, väljatöötatud vee ja jää eristamise produkti usaldusväärsus oli tree-ninguandmetega võrreldes >90%. Kõik arendatud produktid töötavad operatiivselt ESTHub-i Calvaluse andmetöötluskeskkonnas. Automaatproduktide kasutuselevõtt jääkaardi koostamise protsessis võimaldab tulevikus üle minna poolautomaatsele jääkaardi koostamise metoodikale.

Võtmesõnad: operatiivteenused, Sentinel-1, Sentinel-2, Sentinel-3, jääseire

Sissejuhatus

Merejää tekkimine, arenemine ja liikumine on keeruline ja nende protsesside modelleerimine Läänemeres on endiselt probleem. Läänemerd kirjeldavates hüdrodünaamilistes mudelites on püütud merejää olemasolu võimalikult täpselt kirjeldada erinevate parametriseringute kaudu (Rogers ja Zieger, 2004; Pemperton jt, 2017; Tuomi jt, 2019). Lisaks numbrilistele mudelitele on tänapäeval peamiseks jääinfo allikaks radarsatelliitide andmed (Radarsat-2, Sentinel-1 jt). Just Sentinel-1 SAR andmete olemasolu on Läänemere piirkonna jääseirevõimekust oluliselt parandanud. Näiteks on Copernicuse mereseireteenuse (CMEMS) raames loodud merejää dünaamikat jälgiv produkt, mis töötab Sentinel-1 EW ja AMSR2 andmete põhjal (Karvonen, 2012).

Ülevaade radarandmete põhjal jääpiiri, -tüüpide ja -nähtuste tuvastamiseks loodud produktidest on toodud artiklis Zakhvatkina jt, 2019. Jää- ja veepinna tuvastamiseks on testitud mitmeid masinõppe põhinevaid meetodeid: lineaarne

regressioonanalüüs, tugivektorklassifitseerijad (*Support Vector Machines*), gradiendi võimendamine (*Gradient Boosting*), närvivõrgud (NN) (Zakhvatkina jt, 2019). Algselt kasutatud tugivektormeedod (Zakhvatkina jt, 2017; Hong ja Yang, 2018) on hiljem asendatud gradiendi võimendamise meetodiga ning mitmekihiliste närvivõrkude (Boulze jt, 2020) metoodikaga. Viimase kahe meetodi usaldusväärsus on kõrgem, mida näitab ka tõusev trend süvanärvivõrkude kasutamises radarsatelliidandmete alusel pinnavormide ja objektide tuvastamisel (Zakhvatkina jt, 2019). Tüüpiliselt saadakse sellistes ülesannetes mudelite hindamiskriteeriumitele väga kõrged väärtused, ka üle 95% (Ochilov jt, 2012; Laanemäe jt, 2017). Lisades ülesandepüstitusse eri jääklasside eristamise, jäävad tulemused märgatavalt kesisemaks (Kaleschke ja Kern, 2002; Bogdanov jt, 2005).

Eelnenud lõigus kirjeldati rahvusvahelisi arenguid jää hindamiseks radarsatelliitide andmestiku põhjal viimase 10–20 aasta jooksul, kuid Eesti merealadele on Keskkonnaagentuur väljastanud jääkaarte alates 1944. aasta novembrist. Kuni esimeste arvutite tulekuni joonistati jääkaarte paberile. Alates 1970ndate lõpust on jääkaarte koostatud digitaalselt mitmesugustes programmides. Praegu tehakse seda vabavaralise programmiga QGIS, mille jaoks on arendatud jääkaardi koostamise tööriist (plugin), mis on kättesaadav e-riigi koodivaramust (<https://koodivaramu.eesti.ee/kemit/j-kaart>).

Jääkaardi koostamise andmeallikad on viimaste kümnendite jooksul oluliselt muutunud. Eelmise sajandi üheksakümnendateni koostati jääkaart enamasti visuaalsete vaatluste põhjal (ilmavaatlejad rannikujaamades). Tänapäeval toetutakse kõikvõimalikele kättesaadavatele satelliitmõõtmistele ja mudelarvutustele, mille põhjal kogunud sünoptik tuvastab merejää tüübid Eesti rannikumere piirkonnas. Jää tüüpide ja piiri eristamine ning nende väljatoomine ametlikul jääkaardil käib satelliitinfo alusel QGIS programmis endiselt käsitsi joonistades.

2019. aastal algatas Keskkonnaagentuur jääseire infosüsteemi arendamise projekti „Jääkaardi koostamise infosüsteemi loomine“ (JAAK). Projekti sisuks oli sünoptiku töö üleviimine poolautomaatselt lahendusele jääkaardi koostamisel koos selleks vajalike satelliidiproduktide ning spetsialisti töölaua tarkvarade arendamisega. Lisaks hõlmas projekt ka uue veebiväljundi loomise jääkaardi jagamiseks laiemale avalikkusele ning läbi riikliku nutirakenduse ILM+ lisatud vabatahtlike ning koostööpartnerite jäävaatluste kuvamiseks. Projekti teostasid TalTech MSI ja CGI Eesti koostöös GIS-eksperti Rain Elkeniga.

Käesolevas artiklis antakse ülevaade projekti JAAK raames loodud radarsatelliidandmetel põhinevatest produktidest: 1) merejää-vee piiri automaatne tuvastamine ja jäätüüpide eelklassifitseerimine masinõppe meetoditega; 2) järvede jää tuvastamine ja jää paksuse hinnang masinõppe meetoditega ning jäänähtuste tuvastamine.

Lisaks annab artikkel ülevaate teistest jääkaardiprojekti käigus välja töötatud produktidest: värvikomposiidid Sentinel-2 ja Sentinel-3 andmetest ning visualiseeringud CMEMS ja C2RCC produktidest.

Andmed ja meetodid

Projekti eesmärkide täitmiseks kasutati ESA Copernicuse programmi raames orbiidile viidud Sentinel-seeria satelliitide andmeid. Kõik andmed pärinevad riiklikust satelliidiandmete keskusest ESTHub.

Komposiidid/visualiseeringud

Satelliidiinfo visuaalseks kuvamiseks on kasutatud multispektraalseid andmeid Sentinel-2/MSI ja Sentinel-3/OLCI instrumentidelt. Sentinel-2/MSI andmetest on koostatud kaks värvikomposiiti: a) RGB kanalite B04, B03, B01 põhjal ja b) valv värvi RGB kanalite B12, B8A, B04 põhjal. Sentinel-3/OLCI instrumendi andmetest on joonistatud merevee värvi komposiit (*ocean colour* RGB), kasutades Pythoni kooditeeki Pytroll SatPy mooduliga (<https://pytroll.github.io/>).

Sentinel-1 tehisavara-dari (SAR) andmetele on üles ehitatud mitu jää parameetreid arvatavat töövoogu. Sentinel-1 andmetest on kasutuses nii kitsa (*Interferometric Wide*, IW) kui laia (*Extra Wide*, EW) skaneeringuga tehtud pildid, mille polarisatsioonirežiimid on vastavalt VV+VH ja HH+HV. Sentinel-1 tehisavara-dari andmetele on rakendatud kalibreerimise ja müra eemaldamise funktsioonid, pärast mida on antud pildile L-EST97 projektsioon ja vähendatud piksli lahtust IW puhul 50 m ja EW puhul 100 m peale (joonis 1).

Klassifitseeritud jää produktide arendamise meetodika kirjeldus

Klassifitseerimiseks vajalike mudelite loomisel oli esimeseks sammuks eeltöödel-dud SAR pildi segmenteerimine väiksemateks aladeks vastavalt pildi tekstuurile (piksli kontrastsus eri polarisatsioonides jms; joonis 1). Selle protsessi jaoks kasutati superpiksli meetodit (Achanti jt, 2012). Iga segmendi alla jäävate piksli kohta arvutati statistilised väärtused, mille hulka kuuluvad aritmeetiline keskmine, standardhälve ning 15 ja 85 protsentiili väärtused. Need väärtused leiti mõlema polarisatsiooni jaoks (IW puhul VV ja VH, EW puhul HH ja HV) ning radarikiire langemisnurga väärtustele. Lisaks arvutati halltasemete tekstuuri parameetrid (*Gray Level Co-occurrence Matrix*, GLCM) polarisatsioonide väljadele: kontrast-sus, korrelatsioon, erinevused (*dissimilarity*), homogeensus (*homogeneity*), energia ja ASM (Haralick ja Shanmugam, 1973; Van der Walt jt, 2014). Pärast GLCM arvutusi leiti iga segmendi alla jäävatele GLCM parameetrite väärtustele lisaks ka nende statistika (keskmine, standardhälve ja protsentiilid).

SAR andmete annoteerimiseks merejää klassifitseerimise tarbeks kasutati Keskkonnaagentuuri ametlikke varasemate talvede jääkaarte. Digitaalsel kujul jääkaardid (vektorandmed) olid Keskkonnaagentuurist kättesaadavad alates 8. märtsist 2018 ja neile annotatsioon ka loodi. Igale SAR pildile tehti samade dimensioonidega annotatsioon (geotiff-fail, kus igal piksilil on vastava jäätüübi indikaator numbritega 1–9). Kokkuvõttes lõpetati kahe andmehulgaga IW ja EW andmete jaoks, kus igale mere kohal olevale segmendile vastab kindel jääklassi number (avavesi kaasa arvatud).

Järvede jää tuvastamisel kasutati annotatsiooni loomiseks sama loogikat. Küll aga polnud järvede puhul kasutada varasemaid jääkaarte. Järvede jää mudeli treenimiseks koguti SAR andmeid 2018/2019, 2019/2020 ja 2020/2021 talvede kohta alates novembri keskpaigast aprilli lõpuni. Andmeid koguti ainult Peipsi järve pealt, aga operatiivses rakenduses antakse jäähinnang kõikidele järvedele, mis on suuremad kui 0,25 km². Jää paksuse andmehulk koostati 2018/2019 ja 2020/2021 talvedel Politsei- ja Piirivalveameti poolt kogutud mõõtmiste järgi IW ja EW SAR andmete jaoks eraldi. Mõõtmispunkti koordinaati ümbritsevale alale (~1000 piksli) arvutati sama statistika, mis muude rakenduste puhul. Merejää, järvejää ja jää paksuse andmehulgad nii IW kui ka EW andmete jaoks on erineva suurusega ja sellest on ülevaade antud tabelis 1.

Statistikute valimiseks mudeli treeningu jaoks kasutati Fischeri skoori meetodit (Longford, 1987). Koguhulgast valiti välja paarkümmend prominentsemat, mis mudeli treenimisel ette anti. Valitud statistikud varieeruvad olenevalt rakendusest, aga valdav osa GLCM parameetritest on igas rakenduses kasutusel.


Mudeli konfiguratsioon loodi manuaalselt, kasutades Pythoni programmeerimiskeelt ja selle kooditeeki Keras (Chollet, 2015; kasutati versiooni 2.3.1). Parima tulemuse saamiseks optimeeriti süvanärvivõrgu arhitektuur. Efektivseimaks osutus viie peidetud kihiga mudel, kus aktivatsiooni funktsioon varieerus mittene-gatiivse lineaarfunktsiooni ehk ReLU (*Rectified Linear Unit*; Yang, 2018) ja sigmoidfunktsiooni vahel. Neuronite arv eri kihtides varieerus 512 ja 32 vahel ja iga kihi vahel asus väljajätukiht (*dropout*) väärtusega 0,3. Treenimisel kasutati Adami optimeerimise algoritmi, mille õpisamm oli 0,0005. Kaalude (*weight*) ja vabaliikmete (*bias*) optimeerimise kriteeriumiks kasutati mudeli täpsust.

Tabel 1. Eri mudelite/produktide loomiseks kogutud andmeridade arv.

		Meri							
		IW				EW			
		Vesi	Jää			Vesi	Jää		
Andmehulk		174901	30203			78581	9430		
Andmehulk			Kinnisjää	Tugev jää	Nõrk jää		Kinnisjää	Tugev jää	Nõrk jää
			10399	14555	12235		3102	4638	3610

		Järv			
		IW		EW	
		Vesi	Jää	Vesi	Jää
Andmehulk		143180	184975	129723	132479

		Jää paksus							
		IW				EW			
		0 - 15	15 - 20	20 - 25	25 +	0 - 15	15 - 20	20 - 25	25 +
Paksuse vahemik (cm)									
Andmehulk		33	57	34	56	51	61	91	65




Joonis 1. Sentinel-1 IW ja EW andmete töövoo skeem.

Tulemused ja väljundid

Selles osas on toodud näited projekti raames loodud produktidest, mis arvutatakse operatiivselt SENTINEL-1, -2 ja -3 andmetest ESTHub-i töötluskeskkonnas Calvalus. Väljundid hõlmavad nii visualiseeringuid/komposiite eri spektrikanalitest kui ka masinõppe abil loodud eelklassifitseeritud jäätüüpide ja -nähtuste produkte.

Visualiseeringud/komposiidid andmetest

Avalikkusele jagamiseks mõeldud veebikaardile loodi satelliidiandmetest värvikomposiidid jaotise 2.1 meetodikate järgi. Joonisel 2 on näidatud Sentinel-3 OLCI merevärvi (*ocean color*) komposiit (joonis 2a), Sentinel-1 EW andmed (joonis 2b), Sentinel-2 vaevärvi komposiit (joonis 2c) ning Sentinel-1 IW andmed (joonis 2d). Joonisel 2 näidatud visualiseeringud kuvatakse peale töötlemisprotsessi ESTHub-is




Joonis 2. Väljundid veebis: a) Sentinel-3 OLCI merevärvi (*ocean color*) komposiit, b) Sentinel-1 EW andmed, c) Sentinel-2 vaevärvi komposiit, d) Sentinel-1 IW andmed.

operatiivselt avalikule veebikaardile (<https://jaakaart.envir.ee>). Lisaks on võimalik visualiseeringuid küsida ka WMS-teenusena KEMIT-i (Keskkonnaministeeriumi Infotehnoloogiakeskuse) geoserverilt.


Joonistel 3, 4 ja 5 on näidatud värvikomposiidid ja väljundid C2RCC (Case 2 Regional Coast Colour) protsessorist (Brockmann ja Doerffer, 2016) ning CMEMS produktist (<https://marine.copernicus.eu/>; Karvonen, 2012), mis kuvatakse operatiivselt sünoptiku QGIS tööluarakendusele ja on kasutusel jääkaardi koostamisel. Joonisel 3a on näidatud vaevärvides komposiit SWI (Shortwave Infrared) ja joonisel 3b C2RCC protsessori pilvemask, mis aitavad sünoptikul talvistes oludes paremini eristada optilistelt satelliidipiltidelt lund, jääd ja pilvi. Joonisel 5 on näidatud CMEMS produkti visualiseeringud – jäätriivi kiirus (joonis 5b) ja jäätriivi suunad (joonis 5c) – aitavad sünoptikul eristada kinnisjääd triivjääd. Joonisel 6 on näidatud koherentsuse produkt, kus kõrgemad väärtused ühtivad väikese või puuduliku triiviga ja aitavad seega tuvastada stabiilseid jääalasid, st kinnisjääd.

Eelklassifitseeritud jää produktid


Kokku käivitati projekti jooksul 8 masinõppel põhinevat mudelit erinevate produktide loomiseks: IW ja EW andmete jaoks eraldi jää ja vee tuvastamine mere kohal, IW ja EW andmete jaoks eraldi jää klassifitseerimine kolme klassi (kinnis-, tugev ja nõrk jää) mere kohal, IW ja EW andmete jaoks eraldi jää ja vee tuvastamine järvedel ja tuvastatud järvejää aladele jää paksuse hinnangu andmine. Jää ja vee eristamine SAR andmetest on 90% ulatuses vastavuses nende andmetega, mida



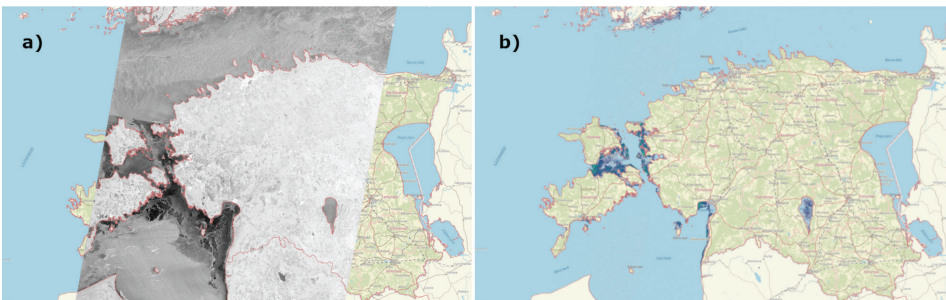
Joonis 3. Sentinel-2 värvikomposiidid 18. veebruaril 2021.



Joonis 4. a) Sentinel-3 RGB pilt 17. veebruaril 2021, b) C2RCC protsessori väljundi pilvemask (IDEPIX), c) C2RCC protsessori väljundi lume- ja jäämask (IDEPIX).



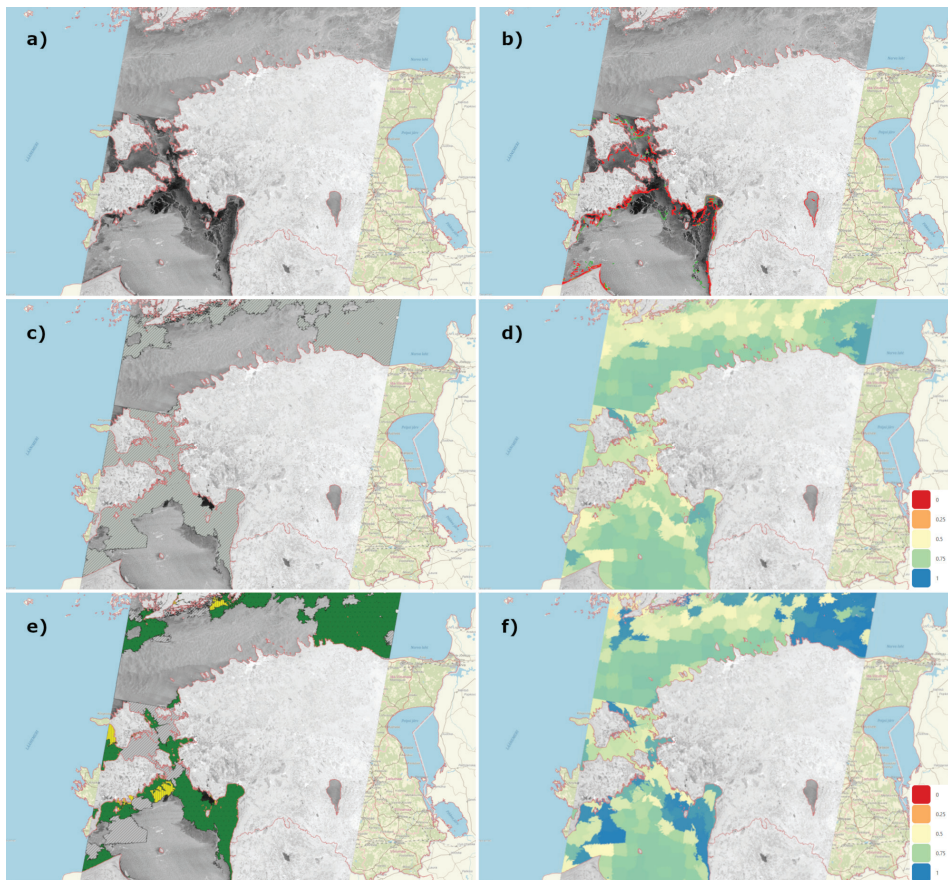
Joonis 5. CMEMS produkti visualiseering: a) referents SAR EW 16. veebruaril 2021, b) jäätriivi kiiruse moodul, c) jäätriivi suunad.



Joonis 6. a) SAR IW 17. veebruaril 2021 ja b) sellele arvutatud (12 päeva) koherentsus.

treenimise käigus kasutati valideerimiseks. Järvede puhul on täpsus mõnevõrra kõrgemgi. Küll aga polnud (andmete vähesusest tulenevalt) võimalik jää paksuse hinnangut anda suurema täpsusega kui umbes 40%. Masinõppe mudelite treenimise täpsuste ülevaade on toodud tabelis 2.


Joonisel 7 ja 8 on näidatud jaotises 2.2 kirjeldatud meetodikat kasutades eelklassifitseeritud jää produkte IW ja EW andmete põhjal. Produktid arvutatakse ESTHub-i töötluskeskkonnas operatiivselt paari tunni jooksul peale algandmete laekumist.



Joonis 7. SAR IW merejää produktid: a) SAR IW ülelend 17. veebruaril 2021 kell 04:44 UTC; b) pildilt tuvastatud jäänähtused – punasega lahvandused ja rohelisega rüsid; c) jää ja vee klassifikatsioon, kus hall tähistab jääd; d) jää ja vee klassifitseerimise usaldusväärsus (skaalal 0–1); e) eelnevas etapis leitud jääalade edasine jaotus kolme klassi: kinnisjää (hall), tugev jää (kollane) ja nõrk jää (roheline); f) kolme jääklassi hinnangu usaldusväärsus.

Tabel 2. Mudelite treenimise täpsused

Produkt	Treenimise täpsus
Jää ja vee eristamine merel	90%
Jää jagamine kolme klassi (kinnisjää, tugev ja nõrk jää)	70%
Jää ja vee eristamine järvedel	95%
Jää paksuse klassifitseerimine järvedel	40%



Joonis 8. SAR EW merejää produktid: a) SAR EW ülelend 16. veebruaril 2021 kell 04:49 UTC; b) pildilt tuvastatud jäänähtused – punasega lahvandused ja rohelisega rüsid; c) jää ja vee klassifikatsioon, kus hall tähistab jääd; d) jää ja vee klassifitseerimise usaldusväärsus (skaalal 0–1); e) eelnevas etapis leitud jääalade edasine jaotus kolme klassi: kinnisjää (hall), tugev jää (kollane) ja nõrk jää (roheline); f) kolme jääklassi hinnangu usaldusväärsus.

Arutelu ja kokkuvõte

Kuigi Läänemere kohta on rahvusvaheliselt arendatud täisautomaatseid jää ulatuse ja kontsentratsiooni produkte (CMEMS), ei ole Läänemere riikide jääteenistused siiski loobunud „käsitsi“ jääkaardi koostamisest, kuna automaatsete produktide usaldusväärsus ja detailsus ei ole siiani olnud piisavad. Projekti „Jääkaardi koostamise infosüsteemi loomine“ raames TalTech MSI poolt arendatud automaatsete produktide usaldusväärsus võrreldes treenimise andmetega jäi testimisel vahemikku 40–95%. Kõige suurema usaldusväärsusega oli vee ja jää eristamise produkt, mille usaldusväärsus oli >90%. Madalaima usaldusväärsusega oli jää paksuse hindamise produkt (40%).

Projekti eesmärk oli muuta jääkaardi koostamise töövoog poolautomaatseks. Projekti raames väljatöötatud töövoos on sünoptikul (jääkaardi koostajal) jääkaardi koostamise töölaual (QGIS tööriista abil) võimalus valida jääkaardile automaatselt eeldefineeritud polügonid, kuid samal ajal säilib võimalus teha vajadusel muudatusi ja täiendusi „käsitsi“. Arendust testitakse 2021/2022. aasta talvel ja seejärel saab selgeks, kas ja kuidas selline lahendus lihtsustab jääkaardi koostamist.

Projekti käigus avalikkusele jagamiseks loodud veebirakendus oli 2020/2021. aasta talvel testkeskkonnana kasutusel ja leidis kasutajate seas positiivset vastukaja. Veebirakendusele saab edaspidi lisada täiendavaid või uusi produkte, mis võimaldavad suvisel perioodil veebikaarti kasutada nii ohtlike vetikaõitsengute kui ka veetemperatuuri seireks.

Tänuavaldus

Artikli koostamine on rahastatud Keskkonnaministeeriumi Infotehnoloogia-keskuse projekti „Kaugseire meetoditega jääkaardi koostamine“ (nr 209818) vahenditest.

Viidatud kirjandus

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. and Süsstrunk, S., 2012. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 34(11), pp.2274-2282.
- Bogdanov, A.V., Sandven, S., Johannessen, O.M., Alexandrov, V.Y. and Bobylev, L.P., 2005. Multisensor approach to automated classification of sea ice image data. *IEEE Transactions on geoscience and remote sensing*, 43(7), pp.1648-1664.
- Boulze, H., Korosov, A. and Brajard, J., 2020. Classification of sea ice types in Sentinel-1 SAR data using convolutional neural networks. *Remote Sensing*, 12(13), p.2165.
- Brockmann, C., Doerffer, R., Peters, M., Kerstin, S., Embacher, S. and Ruescas, A., 2016, August. Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of

- ocean colour products in normal and extreme optically complex waters. In *Living Planet Symposium* (Vol. 740, p. 54).
- Chollet, F., 2015. Keras. Available at: <https://github.com/fchollet/keras>.
- Haralick, R.M., Shanmugam, K. and Dinstein, I.H., 1973. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), pp.610-621.
- Hong, D.B. and Yang, C.S., 2018. Automatic discrimination approach of sea ice in the Arctic Ocean using Sentinel-1 Extra Wide Swath dual-polarized SAR data. *International journal of remote sensing*, 39(13), pp.4469-4483.
- Kaleschke, L. and Kern, S., 2002, June. ERS-2 SAR image analysis for sea ice classification in the marginal ice zone. In *IEEE International Geoscience and Remote Sensing Symposium* (Vol. 5, pp. 3038-3040). IEEE.
- Karvonen, J., 2012. Operational SAR-based sea ice drift monitoring over the Baltic Sea. *Ocean Science*, 8(4), pp.473-483.
- Longford, N.T., 1987. A fast scoring algorithm for maximum likelihood estimation in unbalanced mixed models with nested random effects. *Biometrika*, 74(4), pp.817-827.
- Ochilov, S. and Clausi, D.A., 2012. Operational SAR sea-ice image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11), pp.4397-4408.
- Pemberton, P., Löptien, U., Hordoir, R., Höglund, A., Schimanke, S., Axell, L. and Haapala, J., 2017. Sea-ice evaluation of NEMO-Nordic 1.0: a NEMO-LIM3. 6-based ocean-sea-ice model setup for the North Sea and Baltic Sea. *Geoscientific Model Development*, 10(8), pp.3105-3123.
- Rogers, W.E. and Zieger, S., 2014. New wave-ice interaction physics in WAVEWATCH III®, in *Proceedings of 22nd IAHR International Symposium on Ice* (Singapore: International Association for Hydro-environment Engineering and Research (IAHR)).
- Tuomi, L., Kanarik, H., Björkqvist, J.V., Marjamaa, R., Vainio, J., Hordoir, R., Höglund, A. and Kahma, K.K., 2019. Impact of ice data quality and treatment on wave hindcast statistics in seasonally ice-covered seas. *Frontiers in Earth Science*, 7, p.166.
- Van der Walt, S., Schönberger, J.L., Nunez-Iglesias, J., Boulogne, F., Warner, J.D., Yager, N., Gouillart, E. and Yu, T., 2014. scikit-image: image processing in Python. *PeerJ*, 2, p.e453.
- Yang, J., 2017. ReLU and softmax activation functions.
- Zakhvatkina, N., Korosov, A., Muckenhuber, S., Sandven, S. and Babiker, M., 2017. Operational algorithm for ice-water classification on dual-polarized RADARSAT-2 images. *The Cryosphere*, 11(1), pp.33-46.
- Zakhvatkina, N., Smirnov, V. and Bychkova, I., 2019. Satellite sar data-based sea ice classification: An overview. *Geosciences*, 9(4), p.152.

Summary

Operational sea ice monitoring on the basis of Sentinel satellite data

The paper gives an overview of the project “Ice charting using remote sensing”, which aim was to set up Sentinel-1, -2, and -3 data processing for ice charting experts in the Estonian Weather Service as well as for the public web service. Color composites of Sentinel-2 and Sentinel-3 data are processed for public web service. For detecting ice edges and classifying ice types machine learning-based methods were developed for Sentinel-1 radar data. The reliability of separating ice from water exceeds 90%. Operational processing of satellite data-based ice products is performed on the national satellite data center’s (ESTHub) processing platform. Automated ice products from satellites enable moving towards semi-automatically generated ice charts.

Sentinel-3 satelliitaltimeetria andmete valideerimine Eesti rannikuvetes ja suuremates järvedes

Ivar Kapsi, Kadi Õunas, Tarmo Kall, Aive Liibusk

Eesti Maaülikool, geomaatika õppetool, Kreutzwaldi 1, 51006 Tartu

Kokkuvõte

Artikkel keskendub Sentinel-3 satelliitaltimeetria valideerimisele Eesti rannikuvetes ning Peipsi järves ja Võrtsjärves. Sentinel-3 missioon kasutab satelliitide pardal SAR-sensoreid, mis võimaldavad täpselt mõõta veetaseme kõrgust rannikualadel. Töö käigus korraldati viis ekspeditsiooni Eesti veekogudel, et GNSS-mõõtmiste abil valideerida Sentinel-3 andmete täpsust. Lisaks kaasati valideerimisse rannikule paigaldatud veemõõdujäämade andmed ning see võimaldas teha ka alternatiivse valideerimise. Kahel meetodil valideerimise tulemusel saab öelda, et rannikumeres on Sentinel-3 altimeetriga võimalik veetaseme kõrgust määrata täpsusega $0,08 \pm 0,07$ m. Peipsi järvel ja Võrtsjärvel tuleks arvestada aga täpsusega vastavalt $0,15 \pm 0,14$ m ja $0,22 \pm 0,33$ m.

Võtmesõnad: Sentinel-3, Copernicus, satelliitaltimeetria, valideerimine, geoidi mudel, veetase

Sissejuhatus

Satelliitaltimeetria (SA – *Satellite Altimetry*) andmeid on kasutatud veetaseme ja selle muutuste jälgimiseks enam kui 40 aastat. Esimeseks satelliitaltimeetria missiooniks oli Seasat 1978. aastal. Läbi aastakümnete on orbiidile saadetud mitmeid satelliite (nt TOPEX/Poseidon, Jason, ERS-1, SARAL AltiKa).

Satelliitaltimeetria on end tõestanud ennekõike avaookeanil, kus veetaseme on määratud $0,035$ – $0,050$ m täpsusega (Shum jt, 1995; Ollivier jt, 2012; Prandi jt, 2015). Rannikualadel on aga satelliitaltimeetria kasutamine olnud komplitseeritud. Viimase viieteistkümnede aasta jooksul on altimeetrite sensorid teinud läbi suure arengu ning varasemate impulss-sensorite asemel on kasutusele võetud tehisava-radar-sensorid (*synthetic-aperture radar* – SAR). Lisaks on täiustatud andmetötlusalgoritme ning eri mudeleid (kuiva ja märja troposfääri, ionosfääri, loodete parandid), mida rakendatakse altimeetriliselt mõõdetud kauguse parandamiseks

(Vignudelli, 2019). Viimase kümnendi jooksul on orbiidile saadetud ka uusi satelliite: CryoSat-2 (2010) (Wingham, 2006) ja Euroopa Kosmoseagentuuri (*European Space Agency* – ESA) Copernicuse programmi raames satelliidid Sentinel-3A (2016) ning Sentinel-3B (2018). Need uued satelliidid võimaldavad suuremat ruumilist eraldusvõimet ja väiksemat andmemüra, mis sageli tekib ranniku lähedal mõõtmisel. Nii CryoSat-2 kui Sentinel-3 kasutavad SAR-altimeetrit, mille signaal veega kokkupuutel tekitab 5 km² suuruse „jalajälje“, mis võrreldes vanemate satelliitide (SARAL AltiKa, Jason) impulss-altimeetri jäljega (20–30 km²) on 4–6 korda väiksem. Piki lennusuunda on SAR-altimeetri eraldusvõime 300 m. Tänu nimetatud lahutusvõimele võimaldab SAR-altimeeter saada täpsemaid veetaseme kõrguse mõõtmistulemusi ka ranniku lähedal (Santos-Ferreira, 2018).

Kõigi kaugseire missioonide andmed on enne kasutusele võtmist vaja valideerida, et oleks teada nende eeldatav täpsushinnang. Kaugseireandmeid, mille täpsus pole teada, ei tohiks kasutada, eriti uute missioonide puhul, mille kohta on veel vähe *in situ* võrdlusmaterjali. Olgugi et satelliitaltimeetria andmete kogumine on lihtne ning kiire, on nende andmete õigsuse kontrollimine märksa aeganõudvam ning keerulisem protsess. Käesolevas artiklis antakse ülevaade satelliitaltimeetria andmete valideerimise võimalustest geodeetiliste meetoditega ning Sentinel-3 andmete valideerimisest Eesti rannikuvetes ja suuremates järvedes (Peipsi ja Võrtsjärv).

Metoodika ja andmed

Satelliitaltimeetria tööpõhimõte

Satelliitaltimeetria põhineb signaali levimisaja mõõtmisel. Mõõdetakse aega, mis kulub satelliidilt edastatud ning veepinnalt tagasi peegeldunud signaalil satelliidi ja veepinna vahelise maa kahekordseks läbimiseks. Mõõdetud aja järgi on võimalik arvutada satelliidi kõrgus veepinnast (R):

$$R = c \frac{\Delta t}{2} \quad , \quad (1)$$

kus c on valguse levimise kiirus ning Δt on aeg, mis kulub signaalil vahemaa kahekordseks läbimiseks. Kuna signaal peab läbima atmosfääri eri kihte kaks korda, siis mõjutab see signaali levimist ja sellest tulenevalt valemis (1) mõõdetud kaugus on nn pseudokaugus. Selle parandamiseks lisatakse mõõdetud kaugusele mitmed parandid, nagu näiteks: ionosfääri parand (Δh_{iono}); troposfääri kuiva ja märja komponendi parandid (Δh_{dry} ja Δh_{wet}); mere seisundi parand (Δh_{ssb}); erinevate loodete (mere, Maa, pooluste) parandite summa (Σh_i); pööratud baromeetri efekti korrigeerimine (h_a) ja merepinna topograafia parand (h_f). Parandatud kauguse satelliidi ja veepinna vahel saab arvutada järgmiselt:

$$R_{cor} = R + \Delta h_{iono} + \Delta h_{dry} + \Delta h_{wet} + \Delta h_{ssb} + \Sigma h_i + h_a + h_f \quad . \quad (2)$$


Veetaseme kõrgus, mis on tegelik otsitav suurus, leitakse ellipsoidi suhtes valemist:

$$SSH_{SA} = h_{SA} - R_{cor} , \quad (3)$$

kus h_{SA} on satelliidi kõrgus ellipsoidist, mis saadakse satelliidi orbiidi elementide kaudu. Valemist (3) ja jooniselt 1 on näha, et satelliitaltimeetria abil mõõdetud veetaseme saadakse ellipsoidi suhtes, mida on sageli tülikas võrrelda muude meetodite, nt veemõõdujaamade abil mõõdetud veetaseme kõrgusega, sest viimased kasutavad referentspinnana hoopis Amsterdami nulli, mis on ametlikult Eesti kõrgussüsteemi EH2000 referentspunktiks (Kollo, 2019). Kahe referentspinna vaheline erinevus on siiski lihtsasti leitav, kui kasutada selleks geoidi mudelit. Eestis on ametlikuks geoidi mudeliks EST-GEOID2017, mis on ühildatud keskmise merepinnaga, vt ka joonis 1. Geoidi mudelit EST-GEOID2017 võib pidada üheks kõige täpsemaks riiklikuks geoidi mudeliks maailmas. Tema täpsuseks on GNSS-nivellemistega hinnatud $\pm 0,005$ m (Ellmann, 2020). Tingituna masside ebahütlasest jaotumisest Maa sees pole geoidi ja ellipsoidi pindade erinevus konstantne suurus, vaid varieerub Eesti alal 16–20 meetri vahel. Täpse erinevuse leidmiseks igas konkreetses punktis ongi vaja kasutada geoidi mudelit, mille abil on võimalik kõrgused ellipsoidist ümber arvutada kõrgusteks geoidist. Ehk saada veetaseme kõrgused, mis on võrreldavad veemõõdujaamas mõõdetud veetaseme kõrgustega, vt ka joonis 1:

$$SLA_{TG} = SSH_{SA} + N , \quad (4)$$

kus N on geoidi kõrgus ellipsoidist ehk nn undulatsioon, mis saadakse geoidi mudelist.



Joonis 1. Satelliitaltimeetri (SA), veemõõdujaama (TG) ja GNSS-vastuvõtjaga (GNSS) mõõdetud veetasemete omavaheline suhe. SSH – hetkeline veetaseme kõrgus, SLA – hetkeline veetaseme anomaalia, h – kõrgus ellipsoidist, N – geoidi undulatsioon, R – kaugus satelliidi ja veetaseme vahel, H – GNSS-antenni kõrgus veetasemest.

Sentinel-3 missioon

Sentinel-3 satelliidimissioon on üks osa Euroopa Kosmoseagentuuri programmist Copernicus. Copernicus on Euroopa Liidu programm, mille eesmärk on orbiidile saata kuus satelliiti, millel kõigil on oma osa Maa seiramisel ning andmete kogumisel, et saada parem ja täpsem ülevaade muutustest Maal. Kogutud andmed võimaldavad täpsemalt prognoosida muutusi tulevikus.

2021. aasta alguseks on Copernicuse programmi raames orbiidile saadetud seitse satelliiti: Sentinel-1A, Sentinel-1B, Sentinel-2A, Sentinel-2B, Sentinel-3A, Sentinel-3B ja Sentinel-6. Sentinel-3 missioon on mõeldud meretaseme muutuste mõõtmiseks, kasutades selleks SAR-altimeetrit, mis töötab Ku-sagedusel (13,575 GHz). SAR-altimeetri andmete resolutsioon on piki ja risti lennutrajektoori vastavalt 300 m ning 1640 meetrit, mistõttu on võimalik neid andmeid kasutada rannikule lähemal, võrreldes tavalise impulss-altimeetri andmetega. Sentinel-3 satelliitide orbiit on Päikese-sünkroonne ülelennu kordusega 27 päeva. Kombiinerides Sentinel-3A ja Sentinel-3B andmeid, saab satelliidi ülelennu sageduseks 13,5 päeva ning maapinnale moodustuvate „jälgede“ omavaheliseks kauguseks on 27 kilomeetrit, mis võrreldes varasemate missioonidega on tihedam ning tänu sellele on Sentinel-3 andmeid võimalik edukamalt kasutada ka väiksematel veekogudel (nt Peipsi ja Võrtsjärv).

Valideerimine

Satelliitaltimeetria andmete valideerimiseks on kõige mugavam kasutada GNSS-mõõtmisi, sest nii nagu altimeetria satelliidid, määrab ka GNSS enda kõrguse ellipsoidi suhtes. GNSS-iga valideerimiseks paigaldatakse GNSS-vasutuvõtja veesõidukile ning satelliidi ülelennu hetkel teostatakse GNSS-mõõtmised satelliidi ülelennuga samal transektil. Selle tulemusena saadakse veetaseme kõrgused SSH_{SA} ja SSH_{GNSS} ja nende vahe:

$$\Delta SSH_{GNSS} = SSH_{SA} - SSH_{GNSS} , \quad (5)$$

mis iseloomustabki altimeetriga saadud veetaseme kõrguse täpsust.

Projektis kasutati GNSS-mõõtmisteks kaheageduslikke vastuvõtjaid Trimble R8s ja Trimble R4-3, mis paigaldati veesõiduki kabiini laele. Enne valideerimismõõtmisi seoti laevalael olevad GNSS-antennid veepinnaga (vt H joonisel 1), kasutades selleks tahhümeetrit. GNSS-antenni veetasemega sidumise hinnanguline täpsus on $ca \pm 0,010$ m. Selline täpsus on tingitud veesõiduki kõikumisest ning väiksemagi veevirvenduse korral on mõõtmiste teostamine raskendatud.

Merel, aga ka suurematel järvedel tuleks GNSS-mõõtmisteks kasutada pidevkinemaatilist mõõtmisviisi andmete salvestamise intervalliga 1–2 sekundit.

Pidevkinemaatilise mõõtmise eeliseks on see, et andmeid on hiljem võimalik järeltöödelda ning põhjalikumalt analüüsida. Lisaks, rannikust kaugemal merel on sageli mobiilileviga probleeme ning seetõttu on RTK GNSS-mõõtmine seal piiratud. Pidevkinemaatilise GNSS-mõõtmise täpsus sõltub kasutatavatest vastuvõtjatest, kaugusest baasjaamast, mille suhtes andmed töödeldakse, ning andmetöötlusest. Kõiki neid komponente arvestades on pidevkinemaatilise meetodiga võimalik veetaseme kõrgus määrata $\pm 0,015$ kuni $0,025 \text{ m} + 1 \text{ ppm}$ täpsusega, kus ppm sõltub kaugusest baasjaamast.

Teise satelliitaltimeetria andmete valideerimise võimalusena saab kasutada valideerimist veemõõdujaamade andmetega. Satelliidi ülelennule neljast lähimast veemõõdujaamast interpoleeritakse ülelennu hetkele vastav veetase ülelennu trajektoorige ning koos geoidi mudeliga leitakse veemõõdujaamade andmetel põhinev veetaseme kõrgus (SSH_{TG}):

$$SSH_{TG} = SLA_{TG} + N, \quad (6)$$

kus SLA_{TG} on veemõõdujaama andmetel põhinev ja lennutrajektoorige interpolateeritud veetaseme kõrgus.


Satelliitaltimeetria ja veemõõdujaama andmete erinevus on leitav:

$$\Delta SSH_{TG} = SSH_{SA} - SSH_{TG}. \quad (7)$$

Mõõtmised

Projekti raames viidi kahe aasta jooksul läbi viis ekspeditsiooni Eesti veekogudele (Läänemeri, Peipsi ja Võrtsjärv) (Liibus jt, 2020). Joonisel 2 on lilla värvusega märgitud transektid, kus teostati laevaga GNSS-mõõtmised. Kuna selliste mõõtmiste tegemine on kulukas, pidi transektide valik olema optimaalne, hõlmates 1) nii Sentinel-3A kui Sentinel-3B trajektoore; 2) transekti lähedale jäävaid veemõõdujaamu; ning 3) erinevaid veekogusid (Soome ja Riia laht, rannikulähedane madalik (Vormsi-Osmussaar), Peipsi ja Võrtsjärv). Nende kriteeriumite tulemusena jäid valikusse Sentinel-3A ülelennud 186 (Riia laht), 072 (Vormsi-Osmussaar), Sentinel-3B ülelennud 625 (Soome laht), 642 (Peipsi järv) ja 528 (Võrtsjärv).

Tabelisse 1 on koondatud kõigi viie ekspeditsiooni andmed. Mõõtmisteks püüti valida võimalikult tuulevaikne ilm, et lainetusest tingitud kõikumise mõju mõõtmistele oleks minimaalne. Kõikideks mõõtmisteks oli kasutada erinev veesõiduk. Kõige suurem ja stabiilsem oli Tallinna Tehnikaülikooli uurimislaev Salme, millega tehti mõõtmised Soome lahel, kus ka ilmaolud olid kõige ebasoodsamad. Kõigil ülejäänud neljal mõõtmisel oli tuulevaikne ilm.



Joonis 2. Sentinel-3 andmete valideerimiseks kasutatud GNSS-mõõtmiste transektid ning veemõõdujaamade asukohad.

Tabel 1. Sentinel-3 satelliitlõimeetri andmete valideerimiseks läbi viidud ekspeditsioonid

	Vormsi-Osmussaar	Soome laht	Riia laht	Peipsi järv	Võrtsjärv
Kuupäev	16.08.2018	25.04.2019	20.06.2019	19.06.2019	13.07.2019
Ilm	Vaikne	Nõrk tuul, laine kuni 1m	Vaikne	Vaikne	Vaikne
Transekti pikkus (km)	20	25	54	33	10
Veisõiduk					

Tulemused

Tabelitesse 2 ja 3 on koondatud GNSS-mõõtmiste (SSH_{GNSS}) ja veemõõdujaamade andmetega (SSH_{TG}) tehtud valideerimiste tulemused. Tulemustest on näha, et järvedel ja madala veega rannikualal (Vormsi-Osmussaar) (Õunas, 2019) teostatud võrdlused on andnud keskmisest suuremad erinevused ja suuremad standardhälbed kui mõõtmised Soome ja Riia lahel. GNSS-mõõtmiste keskmine erinevus on samuti suurem, võrrelduna veemõõdujaama andmete võrdlusega (nt Soome lahel vastavalt 0,11 m ja 0,01 m), samas standardhälve on mõlema valideerimismeetodi korral üsna sarnane (nt Soome lahel vastavalt 0,08 m ja 0,06 m või ka Riia lahel vastavalt 0,05 m ja 0,07 m). GNSS-mõõtmiste keskmine suurem erinevus satelliit-altimeetria mõõtmistest võib olla tingitud GNSS-mõõtmiste täpsusest, mis koos GNSS-antenni kõrguse veepinnaga sidumisega ning kaugusega GNSS-baasjaamast võib kokku anda veaks kuni $\pm 0,05$ m. Teisalt on GNSS-mõõtmistega tehtud valideerimise eeliseks see, et *in situ* mõõtmised on teostatud täpselt satelliidi ülelennu ajal satelliidi transektil. Samas tuleks välja tuua, et GNSS-mõõtmistega valideerimisel on kasutatud ainult ühe satelliidi ülelennu andmeid GNSS-mõõtmiste ajal. Tabelisse 3 koondatud andmed baseeruvad ühe aasta jooksul (kaksteist ülelendu) tehtud valideerimiste tulemustel.

Saadud tulemused on siiski väga head, arvestades, et valideerimised teostati just rannikulähedastel aladel ning järvedel. Oodatult on järvedel tehtud valideerimiste tulemused halvemad kui merel saadud tulemused. Eriti tuleb esile Võrtsjärve keskmine veetaseme erinevus ($0,31 \pm 0,39$ m GNSS-mõõtmistest ja $0,13 \pm 0,27$ m veemõõdujaamade andmetest), mis on tingitud rannikulähedasest Sentinel-3B ülelennust. Nimelt jääb ülelennu kaugeim punkt rannikust ainult 2 km kaugusele ning Võrtsjärve kallastel kasvab laialdaselt kõrkjaid. Vaatamata sellele on võimalik Sentinel-3 andmete põhjal määrata veetaset ja veetaseme muutuseid ka Peipsi järves ja Võrtsjärves täpsusega vähemalt $0,13 \pm 0,27$ m.

Tabel 2. Sentinel-3 satelliitaltimeetria andmete (SSHSA) valideerimine (üks ülelend) GNSS-mõõtmiste tulemusega (SSHGNSS) vastavalt valemile (5). Ühikud meetrites.

Statistik	Vormsi-Osmussaar	Soome laht	Riia laht	Peipsi järv	Võrtsjärv
Keskmine	0,14	0,11	0,14	0,16	0,31
Standardhälve	0,06	0,08	0,05	0,13	0,39
RMSE	0,15	0,13	0,15	0,21	0,49
Min	0,02	-0,11	0,00	-0,33	-0,45
Max	0,27	0,29	0,27	0,38	0,74

Tabel 3. Sentinel-3 satelliitaltimeetria andmete (SSH_{SA}) valideerimine (kaksteist ülelendu ühe aasta jooksul) veemõõdujaama andmetega (SSH_{TG}) vastavalt valemile (7). Ühikud meetrites.

Statistik	Vormsi-Osmussaar	Soome laht	Riia laht	Peipsi järv	Võrtsjärv
Keskmine	0,09	0,01	0,00	0,14	0,13
Standardhälve	0,11	0,06	0,07	0,16	0,27
RMSE	0,19	0,07	0,10	0,23	0,27
Min	-0,22	-0,32	-0,98	-0,56	-1,13
Max	0,35	0,33	0,58	0,98	0,78

Kokkuvõtvalt võib öelda, et kahel erineval meetodil läbi viidud valideerimise tulemusena on Sentinel-3 altimeetriga võimalik rannikualadel (kuni 25 km rannikust) määrata veetaseme kõrgust täpsusega $0,08 \pm 0,07$ m. Peipsi järvel ja Võrtsjärvel tuleks Sentinel-3 veetaseme kõrguse määramise täpsuseks arvestada vastavalt $0,15 \pm 0,14$ m ja $0,22 \pm 0,33$ m. Saadud täpsused on piisavad, et kaasata Sentinel-3 altimeetria andmeid veekogude seisundi määramise uuringutesse, mis sõltuvad veetaseme muutustest, või kasutada Sentinel-3 andmeid veetaseme mudelprognooside täpsustamiseks.

Tänuavaldus

Töö on teostatud projektide PUT1553: „Läänemere viimase 70 aasta geotsentrilise meretaseme- ja maatõusu määramine kasutades satelliitaltimeetriat“ ja L180284MIGX (RITA1/02-52-08) „Kaugseire andmete kasutuselevõtt avalike teenuste väljatöötamisel ja arendamisel (01.01.2019–31.12.2020)“ raames.

Viidatud kirjandus

- Ellmann, A.; Märdla, S.; Oja, T. The 5 mm geoid model for Estonia computed by the least squares modified Stokes's formula. *Surv. Rev.* 2020, *52*, 352–371, doi:10.1080/00396265.2019.1583848.
- Kollo, K.; Ellmann, A. Geodetic Reconciliation of Tide Gauge Network in Estonia. *Geophysica* 2019, *54*, 27–38.
- Liibus, A.; Kall, T.; Rikka, S.; Uiboupin, R.; Suursaar, Ü.; Tseng, K.-H. Validation of Copernicus Sea Level Altimetry Products in the Baltic Sea and Estonian Lakes. *Remote Sensing* 2020, *12* (24), doi: 10.3390/rs12244062.

- Ollivier, A.; Faugere, Y.; Picot, N.; Ablain, M.; Femenias, P.; Benveniste, J. Envisat Ocean altimeter becoming relevant for mean sea level trend studies. *Mar. Geod.* 2012, *35*, 118–136, doi:10.1080/01490419.2012.721632.
- Prandi, P.; Philipps, S.; Pignot, V.; Picot, N. SARAL/AltiKa global statistical assessment and cross-calibration with Jason-2. *Mar. Geod.* 2015, *38*, 297–312, doi:10.1080/01490419.2014.995840.
- Santos-Ferreira, A. M.; Silva, J. C. B.; Magalhães, J. M. SAR Mode Altimetry Observations of Internal Solitary Waves in the Tropical Ocean Part 1: Case Studies. *Remote Sens.* 2018, *10*, 644, doi:10.3390/rs10040644.
- Shum, C. K., Ries, J. C. & Tapley, B. D., 1995. The accuracy and applications of satellite altimetry. *Geophysical Journal International*, 121(2), pp. 321-336.
- Vignudelli, S.; Birol, F.; Benveniste, J.; Fu, L.-L.; Picot, N.; Raynal, M.; Roinard, H. Satellite Altimetry Measurements of Sea Level in the Coastal Zone. *Surv. Geophys.* 2019, *40*, 1319–1349, doi:10.1007/s10712-019-09569-1.
- Wingham, D. J.; Francis, C. R.; Baker, S.; Bouzinac, C.; Cullen, R.; de Chateau-Thierry, P.; Laxon, S. W.; Mallow, U.; Mavrocordatos, C.; Phalippou, L.; et al. CryoSat: A mission to determine the fluctuations in earth's land and marine ice fields. *Adv. Space Res.* 2006, *37*, 841–871, doi:10.1016/j.asr.2005.07.027.
- Õunas, K. Satelliidi Sentinel-3 altimeetria andmete valideerimine Lääne-Eesti rannikulähedastel aladel. Magistritöö 2019, Eesti Maaülikool.

Summary

Validation of Sentinel-3 satellite altimetry data in Estonian coastal waters and larger lakes

The article describes the validation of Sentinel-3 satellite altimetry in Estonian coastal waters, in Lake Peipsi and Lake Võrtsjärv. Remote sensing mission data must be validated before deployment in order to be aware of expected accuracy estimate. SAR sensors are used on board of Sentinel-3; compared to their predecessors, this provides more accurate measurements of the sea level in the coastal areas and lakes. In the course of the study, five expeditions took place on different Estonian water bodies in order to validate the accuracy of Sentinel-3 data using GNSS measurements. In addition, data from coastal tide gauges were included, which allowed for alternative validation. The validation results were very good. Based on the results of validation, the height of the sea level in the coastal sea can be determined with an accuracy of 0.08 ± 0.07 m by using the Sentinel-3 altimeter. The accuracy of water level heights determination was 0.15 ± 0.14 m and 0.22 ± 0.33 m in lakes Peipsi and Võrtsjärv, respectively.

Kuumasaarte ning neid mõjutavate tegurite tuvastamine Tartu linnaruumis mehitamata õhusõidukite abil

**Kaupo Kokamägi, Miguel Villoslada Peciña,
Raul Sampaio De Lima, Kalev Sepp**

Eesti Maaülikool, põllumajandus- ja keskkonnainstituut, keskkonnakaitse ja maastikukorralduse õppetool, Kreuzwaldi 5, 51014 Tartu

Kokkuvõte

Artiklis antakse ülevaade linna kuumasaarte ja rohe- ning sinitaristu vaheliste seoste hindamisest. Lisaks sellele kirjeldatakse ehitustiheduse linna soojussaari võimendava mõju hindamist. Seost linna maakatte ja soojussaarte vahel hinnati RGB-, multispektraal- ja soojuskaameraid kandvate mehitamata õhusõidukite abil. Uuritavaks alaks olid Tartu linna eri piirkonnad. Uurimistöök vajalikud andmed koguti kolmes erinevate omadustega Tartu piirkonnas kahe kuumalaine ajal 2020. aasta juulis ja augustis. Andmete kogumiseks kasutati mehitamata õhusõidukeid SenseFly eBee Plus, eBee X ja DJI Matrice 210, mille pardal olid kaamerad SenseFly S.O.D.A, Sequoia, ThermoMap ja DJI Zenmuse XT2. Soojuskaamera abil tuvastati potentsiaalsed linna kuumasaared ning nende mõju leevendavad objektid väga suure resolutsiooniga. Multispektraalkaamera abil tuvastati taimestikule olemasolu ja elujõud. RGB-piltidest loodi fotogramm-meetrilise töötamise käigus kolmemõõtmeline mudel, mille abil hinnatakse ehitustiheduse ja ehitiste paigutuse ning kuju mõju linna kuumasaartele. Kasutades seda lähenemist erineva iseloomuga piirkondades, saime analüüsida infrastruktuuri eri elementide soojussaari leevendavaid ja võimendavaid mõjusid. Tänu suurele resolutsioonile on töö tulemuste abil võimalik anda edaspidiseks linnaplaneerimiseks täpseid soovitusi. Tegemist on ülevaatliku artikliga ja analüüsi tulemusi siin ei avaldata.

Võtmesõnad: linna kuumasaar, soojuskaamera, multispektraalkaamera, fotogramm-meetria, linnaplaneerimine

Sissejuhatus

Kuigi juba sõlmitakse ülemaailmseid kokkuleppeid kliimamuutusega võitlemiseks, on meil siiski vaja ka plaane muutustega kohanemiseks. Linnade keskkonna uurimine ja arendamine on eriti tähtis, kuna enamik Eesti elanikke elab linnades. Samuti on linnad kliima suhtes haavatavad, kuna suure ehitustihedusega piirkonnad võivad mitmeid ilmastikunähtusi, näiteks kuumalaineid, võimendada, mis omakorda võib suurendada tervisele kahjulikke mõjusid ning põhjustada surmasid (Basagaña, 2011). Arvutustechnika, mehitamata õhusõidukite ja tarkvara areng lubab koguda varasemast tunduvalt kiiremini ja lihtsamalt andmeid huvipakkuva ala kohta ning neid ka võrdlemisi kiirelt töödelda.

Töö eesmärk on hinnata kuumalainete ning erinevate tegurite, nagu ehitustiheduse, rohe- ja sinitaristu olukorra, kasutatavate materjalide jmt mõju Tartu linna kuumasaartele. Seost nende tegurite ja soojusaarte vahel uuritakse kasutades mehitamata õhusõidukeid, mille pardal on RGB-, multispektraal- ja soojuskaamerad. Töö tulemusena on võimalik anda omavalitsustele soovitusi linnade, sealhulgas ka rohe- ja sinitaristu planeerimiseks. Mujal maailmas tehtud uurimistöodes on leitud, et rohe- ja sinitaristu arendamise abil on võimalik linna kuumasaarte mõju leevendada (Emmanuel ja Loconsole, 2015; Herath jt, 2018). Töö hüpoteesiks on, et nimetatud eesmärgil rohe- ja sinitaristu paremaks planeerimiseks on võimalik kasutada kaugseire meetodeid, sealhulgas ka mehitamata õhusõidukeid. Artiklis antakse ülevaade tehtud tööst, kuid analüüsi tulemusi siin ei avaldata.

Objekt

Uurimistöö jaoks valiti välja kolm erinevate omadustega piirkonda Tartus. Valitud objektid asuvad Ihastes, Ränilinnas ja Annelinnas (joonis 1). Valisime need piirkonnad sellepärast, et tegemist on taristu, eriti just rohe- ja sinitaristu poolest väga erinevate piirkondadega.

Ihastes on palju kõrghaljastust ning aedadega eramaju. Mõõdetud ala keskele jääb parkmets ning läheduses on ka Emajõgi. Suuri parklaid ega hooneid selles piirkonnas ei ole. Eelduste kohaselt on tegemist kuumasaare-efekti leevendavate omadustega. Ränilinnas valitud alasse jääb Lõunakeskuse kaubanduskeskus koos ümbrusega. Tegemist on suurte bituumenkatustega hoonetega, mida ümbritsevad suured parklad. Alasse jääb osaliselt ka Tartu ringtee, mis on Eesti ühe suurema liikluskoormusega Tallinna–Tartu–Võru–Luhamaa maantee osa. Alast lääne poole jäävad peamiselt põllud ning madala haljastusega alad ja ida poole Tartu linn. Ala on ka varasemates satelliidiandmetele toetuvates uuringutes jäänud silma ühe kõige kõrgema temperatuuriga piirkonnana Tartus (KATI lõpparuanne, 2015; Märtnens jt, 2020).

Annelinnas valitud alasse jäävad osaliselt Anne kanalid ning Eedeni keskus ning neist põhja poole elumajade kvartal koos lasteaedade ja koolidega. Piirkonnas



Joonis 1. Valitud alade asukohad Tartus: Ränilinn vasakul, Annelinn üleval keskel ja Ihaste all paremal.

on rohkem suuri hooneid ja parklaid kui Ihastes, samas on kortermajade vahel ka kõrghaljastust ning läheduses Anne kanalid ja Emajõgi, samuti elumajade vahel üks tiik. Annelinnas on kõige suurem üle 64- ja alla 4-aastaste elanike osakaal Tartus. Nende vanuserühmade esindajad on kuumalainete suhtes kõige tundlikumad (Vene, 2017).

Riistvara ja tarkvara

Andmete kogumiseks kasutati kolme erinevat mehitamata õhusõidukit mitmesuguste sensoritega. Maapealsete andmete kogumiseks kasutati kõigil objektidel Trimble R10 GNSS (*Global Navigation Satellite System* – globaalne satelliitnavigatsioonisüsteem) vastuvõtjat ning infrapuna-termomeetrit. Ihastes kasutati soojus- ja multispektraalandmete kogumiseks eBee Plus UAV-d (*Unmanned Aerial Vehicle* – mehitamata õhusõiduk) SenseFly ThermoMap ja Sequoia kaameratega ning RGB (*Red Green Blue* – punane roheline sinine) andmete kogumiseks eBee X UAV-d Sensefly S.O.D.A. kaameraga (joonis 2).

Ränilinnas kasutati soojusandmete kogumiseks eBee Plus mehitamata õhusõidukit ThermoMap kaameraga ning multispektraal- ja RGB-andmete kogumiseks eBee X mehitamata õhusõidukit Sequoia ja S.O.D.A. kaameratega.



SenseFly eBee Plus



SenseFly eBee X



SenseFly thermoMAP



SenseFly Sequoia



SenseFly S.O.D.A.

Joonis 2. Töös kasutatud SenseFly UAV-d ja sensorid. (SenseFly)



DJI Matrice
210 V2



DJI Zenmuse XT2

Joonis 3. Töös kasutatud DJI Matrice 210 V2 ja DJI Zenmuse XT2. (Droon.ee, DJI)

Annelinnas koguti multispektraal- ja RGB-andmeid eBee X UAV-ga ning Sequoia ja S.O.D.A. kaameratega. Soojusandmeid koguti DJI Matrice 210 V2 UAV-ga, millel oli Zenmuse XT2 kaamera (joonis 3).

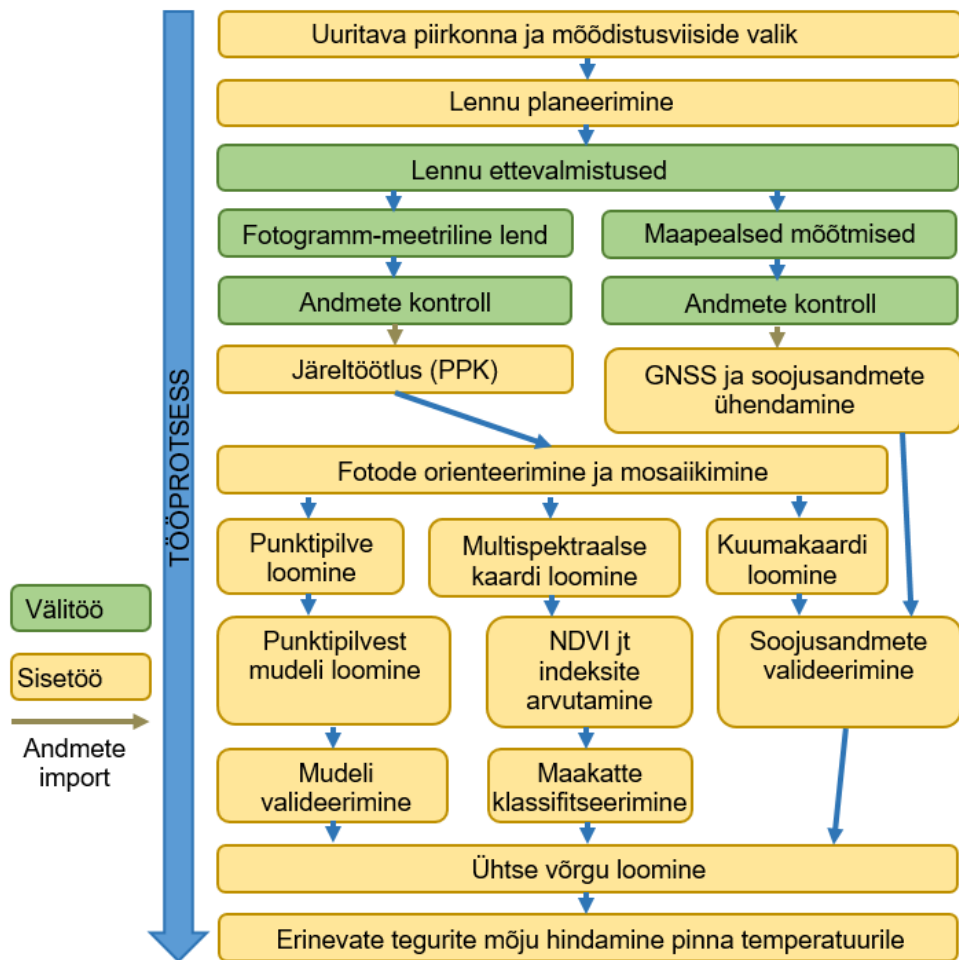
eBee Plus ja eBee X lendude planeerimiseks ning trajektoori järeltöötamiseks kasutati tarkvara eMotion. eBee UAV-dega kogutud piltidest loodi ortofotod Pix4D tarkvara abil. DJI Zenmuse abil kogutud andmetest loodi termokaardid Python Spyderi skripti ja Drone2Mapi tarkvara abil. Andmete töötamiseks ja analüüsiks kasutati tarkvarasid ArcMap, QGIS ja R.

Välitööd

Arvestades eesmärgiga hinnata linnakeskkonda kuumalainete ajal, valisime mõõtmispäevad nii, et pärastlõunane temperatuur oleks vähemalt 27 kraadi, mis on võetud kuumalainet tähistavaks piiriks Eestis ka varasemates linna soojussaari uurivates töödes (Sepp jt, 2015; Märtnens jt, 2020). Peale selle kogusime soojusandmeid päeval, millele oli eelnenud vähemalt kaks päikesepaistelise ja sooja päeva, et soojus jõuaks ehitusmaterjalidesse akumulieruda. Sellised kriteeriumid koos tavapäraste UAV-mõõtmisi piiravate sademete- ja tuulepiirangutega tegid sobivate päevade valiku väga kitsaks. Kokku oligi 2020. aasta suve jooksul kaks perioodi, mis vastasid meie tingimustele: üks juuni lõpus pärast jaanipäeva ja teine augusti esimeses pooles. Kuna kõik valitud alad asuvad Tartu lähiala kontrollitavas õhuruumis, pidime Tartu Torni lahtioleku aegadel lendamiseks loa taotlema umbes nädal aega varem. Seetõttu tuli ilmaprognoosidel pidevalt silma peal hoida ja soojema prognoosi puhul alati luba taotleda. Lisaks sellele tuleb linnakeskkonnas olla väga tähelepanelik lennuki tüüpi UAV-de jaoks piisavalt suurte õhkutõusmis- ja maandumisalade valikul. Jälgida tuleb ka võimalikke ohuallikaid, nagu mastid, liinid, kõrged hooned jne.

Kogu tööprotsessi skeem on näha joonisel 4. Pärast lennu-, õhkutõusmis- ja maandumisaladega kohapeal tutvumist loodi esialgsed lennuplaanid. eBee UAV-de puhul tehti see eMotioni tarkvaras.

Välitöödel seati kõigepealt UAV töökorda ja korrigeeriti lennuplaani vastavalt olukorrale. Enne ja pärast iga lendu tuli võtta ühendust Tartu Torniga ja neid olukorradest teavitada. Ihastes teostati kõik mõõtmised 27. juunil 2020. aastal, vahetult pärast lõunat. Ränilinnas koguti multispektraal- ja soojusandmed samuti 27. juuni pärastlõunal, RGB-andmed aga 27. juulil. Annelinnas koguti multispektraal- ja RGB-andmed 8. augustil 2020. aastal ning soojusandmed 9. augusti pärastlõunal. Nii 27. juuni kui ka 9. august olid päikesepaistelised ja kuumad päevad. Õhutemperatuur pärast lõunat oli vastavalt 29 °C ja 27 °C. Siiski, kui juunis oli kuumalaine kestnud juba peaaegu terve nädala, siis augustis oli tegemist alles kolmanda kuuma päevaga. Maapealsed mõõtmised teostati soojuskaameraga varustatud UAV lennuga samal ajal ning 5–6 asukohas, mis olid hajutatud kogu uuritava ala peale (joonised 5, 6 ja 7). Igas asukohas mõõdeti erinevate maakattetüüpide pinnatemperatuure,



Joonis 4. Tööprotsessi skeem

iga tüüpi kohta 5 temperatuurimõõtmist. Kõigi mõõtmiste asukohad mõõdistati GNSS vastuvõtja abil RTK (*Real Time Kinematic*) meetodil. Ihastes, Ränilinnas ja Annelinnas mõõdeti vastavalt 26, 21 ja 23 maapealset kontrollpunkti soojuskaardi valideerimiseks. Iga sensoriga mõõtmiseks tuli eBee UAV-de puhul sooritada eraldi lend, kuna vahepeal tuli sensorit vahetada. Kuna 9. augustil ei saanud tehniliste probleemide tõttu kummagi eBee õhusõidukiga lennata, mõõdeti Annelinnas Päästeametile kuuluva DJI multirootori tüüpi õhusõidukiga. Võrreldes eBee UAV-dega on sellel lühem lennuaeg ning seetõttu tuli valitud alal teostada kolm lendu, vahetades iga lennu järel akusid. Kui kõik andmed olid kogutud, teavitati Tartu Torn ja kontrolliti kogutud andmed kiirelt üle.

Andmete töötlus ja analüüs

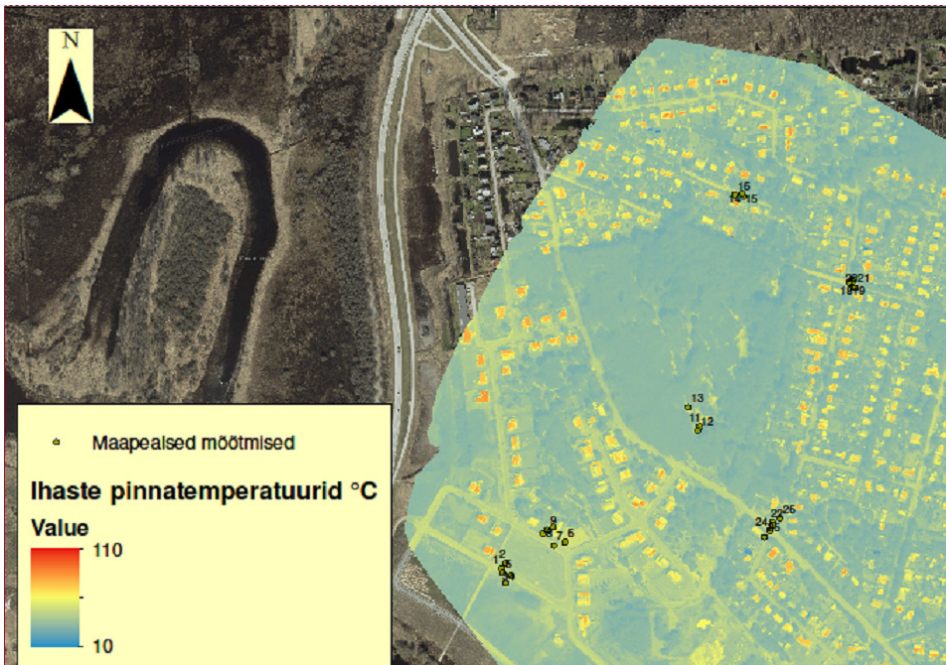
Pärast andmete kogumist korrigeeriti eBee UAV-dega kogutud andmete kordinaate järeltöötuse käigus PPK (*Post Processing Kinematic*) meetodil eMotioni tarkvaras. Selle jaoks laaditi alla Tartu lähedal asuva Tõravere GNSS püsijaama (TOR2) kohta käivad parandid (Maa-amet) sama aja kohta, mil lennud toimusid. Seejärel kasutati trajektooride korrigeerimiseks eMotioni tarkvaras PPK meetodit. Pärast seda teostati esialgne fotode orienteerimine samuti eMotioni tarkvaras ning loodi Pix4D tarkvarale sobiv projektifail. Pix4D tarkvaras fotod orienteeriti ning loodi iga ala ja sensori kohta ortofotomosaiik. Termokaart ja eri lainepikkustele (roheline, punane, lähiinfrapuna ja *red edge*) vastavad multispektraalkaardid salvestati eraldi tif-failidena. RGB-andmetest loodi punktipildid. DJI Matrice abil kogutud andmete puhul anti igale pikslile Python Spyderi skripti abil temperatuuri väärtus ning termokaardid koostati Drone2Mapi tarkvara abil. Kolme eri lennu termokaardid liideti ühtseks ArcMapi tarkvaras. Maapealsete mõõtmiste temperatuuriandmetele lisati koordinaadid ning need imporditi koos termokaartidega ArcMapi tarkvarasse. Termokaardid georeferentseeriti täiendavalt, kasutades Maa-ameti ortofotot. Seejärel loodi ühine tabel, kus samale reale tulid sama asukoha temperatuurid maapealsetest mõõtmistest ja UAV abil kogutud andmetest. Termokaarte koos maapealsete mõõtmiste asukohtadega on näha joonistel 5, 6 ja 7. Maapealsete mõõtmiste ühes punktis teostatud viiest temperatuurimõõtmisest leiti keskmine ning selle keskmise erinevus samas punktis olevast UAV andmete temperatuuriväärtusest. Seejärel arutati keskmine ruutviga (KRV) ja R-ruut (R^2) iga ala kohta. KRV jäi samaaegselt teostatud mõõtmiste puhul mõne kraadi ($^{\circ}\text{C}$) piiresse. Annelinnas arutati mõlemad väärtused nii iga lennu kohta kui ka kogu ala kohta. Annelinnas oli KRV teise ja kolmanda lennu puhul suurem kui esimesel, aga hea R^2 väärtus lubab järeldada, et korrelatsioon on tugev. Autorite hinnangul tuleb erinevus sellest, et maapealsed mõõtmised toimusid samal ajal esimese lennuga ning teine ja kolmas lend toimusid 30 kuni 90 minutit hiljem. Tegemist oli hilise pärastlõunaga ning päike oli iga järgmise lennu ajal madalamal ja temperatuur langes.

Multispektraalandmetest arutati välja mitmesugused indeksid. Sarnaselt varasematele linna kuumasaari uurivatele töödele valiti indeksiteks NDVI (*Normalized Difference Vegetation Index* – normaliseeritud vegetatsiooniindeks), GNDVI (*Green Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*) ja MSAVI2 (*Modified Soil-Adjusted Vegetation Index*) (Adeyeri jt, 2017; Equere jt, 2020). Eri tegurite mõju hindamiseks loodi ühtne võrgustik, kuhu lisati soojusandmed ja indeksite andmed. Kogutud andmetest tuvastatakse, kuidas mõjuvad pinnatemperatuurile erinevad maakattetüübid ja ehitusmaterjalid ning kaugus veekogudest ja rohetaristust. RGB-piltidest loodud mudeli abil hinnatakse tänavate laiuse, majadevaheliste kauguste ja nende kõrguste mõju temperatuurile.


Multispektraalandmete abil hinnatakse taimeestiku elujõudu ja selle mõju ümbuskonna pinnatemperatuurile. Kuna tegemist on ülevaatliku artikliga ning andmete analüüs pole veel täielikult lõpule viidud, siis siinkohal analüüsi tulemusi ei avaldata.

Tänuavaldus


Autorid soovivad tänada Mart Suursut Päästeametist, kes kriitilisel hetkel reageeris väga kiiresti ning aitas Annelinna soojusandmete kogumisel.



Joonis 5. Ihaste pinnatemperatuurid ja maapealsete kontrollmõõtmiste asukohad.



Joonis 6. Ränlinna pinnatemperatuurid ja maapealsete kontrollmõõtmiste asukohad.



Joonis 7. Annelinna pinnatemperatuurid ja maapealsete kontrollmõõtmiste asukohad.

Viidatud kirjandus

- Adeyeri, O.E., Akinsanola, A.A., Ishola, K.A. (2017). Investigating surface urban heat island characteristics over Abuja, Nigeria: Relationship between land surface temperature and multiple vegetation indices, *Remote Sensing Applications: Society and Environment*, Volume 7, 57-68, ISSN 2352-9385, <https://doi.org/10.1016/j.rsase.2017.06.005>.
- Basagaña, X., Sartini, C., Barrera-Gómez, J., Davvand, P., Cunillera, J., Ostro, B., Sunyer, J., Medina-Ramón M. (2011). Heat Waves and Cause-specific Mortality at all Ages. *Epidemiology*, vol. 22, no. 6, 2011, 765-772. www.jstor.org/stable/23048065.
- DJI kodulehekül. <https://www.dji.com/ee/zenmuse-xt2>
- Droon.ee kodulehekül. <https://droon.ee/toode/dji-matrice-210-rtk-v2-enterprise/>
- Emmanuel, R., Loconsole, A., (2015). Green infrastructure as an adaptation approach to tackling urban overheating in the Glasgow Clyde Valley Region, UK. *Landscape and Urban Planning*. 138. 71-86,ISSN 0169-2046, <https://doi.org/10.1016/j.landurbplan.2015.02.012>.
- Equere, V., Mirzaei, P. A., Riffat, S. (2020). Definition of a new morphological parameter to improve prediction of urban heat island, *Sustainable Cities and Society*, Volume 56, 102021, ISSN 2210-6707, <https://doi.org/10.1016/j.scs.2020.102021>.
- Herath, H.M.P.I.K., Halwatura, R.U., Jayasinghe, G.Y. (2018). Evaluation of green infrastructure effects on tropical Sri Lankan urban context as an urban heat island adaptation strategy, *Urban Forestry & Urban Greening*, Volume 29, 212-222, ISSN 1618-8667, <https://doi.org/10.1016/j.ufug.2017.11.013>.
- Kliimamuutuste mõjude hindamine ja kohanemismeetmete väljatöötamine planeeringute, maakasutuse, inimtervise ja päästevõimekuse teemas (KATI). Lõpparuanne. (2015) Keskkonnaministeerium. Tartu. 321 lk. https://www.envir.ee/sites/default/files/kati_lopparuanne.pdf
- Maa-ameti kodulehekül. <https://geoportaal.maaamet.ee/est/Ruumiandmed/Geodeetilised-andmed/Geodeetilised-vorgud/GNSS-pusijaamade-vork-p571.html>
- Märtens, O., Pärj, R ja Služenikina, J. (2020). Soojusaarte hindamine Eesti linnades 2014-2019. Lõpparuanne. Keskkonnaagentuur. Tallinn. 63 lk.
- SenseFly kodulehekül. <https://www.sensefly.com/>
- Sepp, M., Sagris, V., Tamm, T. (2015). Eesti asub kliimamuutuste tulipunktis. *Eesti Loodus*, 66 (8), 8-13.
- Vene, K. (2017). Kiirabikutsete jaotuvus elanikkonna riskirühmade alusel Tartu linnas kuumalainete ja kuumapäevade ajal. Magistritöö. Eesti Maaülikool. Tartu. 78 lk.

Summary

Identification of urban heat islands and affecting factors in Tartu, Estonia by means of unmanned aerial vehicles

This article provides an overview of the assessment of the relationship between urban heat islands (UHI) and green- and blue infrastructure. In addition, an assessment of the amplifying effect of building density on the urban heat island effect is described. The relation between the city's land cover and urban heat islands was assessed, using unmanned aircraft carrying RGB, multispectral and thermal cameras. The study was carried out in Tartu, Estonia.

The data required for the research was collected in three city regions of different character during two heat waves in July and August 2020. The data was collected using SenseFly eBee Plus, eBee X, and DJI Matrix 210 unmanned aircraft carrying SenseFly S.O.D.A, Sequoia, ThermoMap and DJI Zenmus XT2 cameras. The thermal camera was used to identify potential urban heat islands and objects that mitigate their effect with very high resolution. The presence of vegetation and its vital impact was detected using a multispectral camera. A three-dimensional model was created from the RGB images during photogrammetric processing, which is used to assess the effect of building density and geometry on urban heat islands. Using this approach in areas of different nature, we were able to analyze the mitigating and amplifying effects of different infrastructure elements on urban heat islands. Very good resolution allows for making more precise recommendations for future urban planning.

The article provides an overview of the work done, the results of the analysis have not been included.

Kaamerate kasutamine riiklikus seires ning tehisintellekti loomine tulemuste analüüsimiseks

Rauno Veeroja, Mart Thalfeldt, Einar Kärgerberg, Timo Kark

Keskonnaagentuur, Mustamäe tee 33, 10616 Tallinn

Kokkuvõte

Eluslooduse seiret on pikka aega tehtud ühelaadsete meetodikate alusel, kuid tänu tehnoloogia arengule ning seadmete paremale kättesaadavusele katsetatakse vastavalt võimalustele uusi alternatiivseid lahendusi. Eestis on eluslooduse seires kaameraid kasutatud juba mõnda aega, kuid terviklahendust seni ei ole, sest kaameravõrgu ülesehitamine ja andmete analüüsimine eeldab täiendavaid vahendeid – nii raha kui inimesi. Samas on kaamerad võimelised tootma paljude liikide kohta tohutus koguses andmeid, samaväärne andmekogumine üksnes inimeste abil on praktikas töömahu tõttu ebamõistlik ja sisuliselt võimatu. Kaamerate rakendamist toetab ka asjaolu, et paljude ulukiliikide arvukusdünaamikas toimuva uurimiseks on seni kasutatud lumele jäetud jäljeradade vaatlustel ja loendusel põhinevaid meetodeid, mis on soojeneva kliima tingimustes muutunud aina problemaatilisemaks. Kaameraülesvõtetel põhinevad meetodid võiks olla sobivaks alternatiiviks.

2018. ja 2019. aasta kevadel katsetati ELME projektis Eestis esmakordselt mitme ulukiliigi asustustiheduse hindamiseks juhusliku kohtamise mudelit (*random encounter model*, REM: Rowcliffe jt, 2008), mis põhineb loodusesse juhuslikesse asukohtadesse paigutatud kaameratega kogutud pildimaterjali põhjal tehtud arvutustel. Katse viidi läbi Põlvamaal Karilatsi-Ihamaru seirealal ja Tartumaal Järvselja seirealal. Kahelt seirealalt kogunes kokku 46 040 fotot, millest 15 749 pildil (34,2%) võis täheldada loomi ja linde. Kokku õnnestus fotodelt eristada 15 erineva imetaja ja vähemalt 8 erineva linnuliigi esindajaid. Asustustiheduse ja selle määramiseks vajalike parameetrite hindamine tehti täielikult läbi põdra ja metskitse puhul.

Kui koguda samasuguses mahus rajakaamerate salvestisi kõigilt 47 seirealalt, mida kasutatakse Eestis hirvlaste seireks, kuluks koguneva fotomaterjali analüüsiks ühel inimesel ligi 500 tööpäeva, mis muudab selle töö ebamõistlikult aeganõudvaks ja kulukaks. Siia lisanduvad veel kaamerate soetuskulud, paigaldamisele ja kaamerate asukohtade vahetamisele kuluv aeg ja transpordikulu. Selleks et kaameraid laialdasemalt kasutusele võtta, on Keskonnaagentuur välja töötamas tehisintellekti, mis suudaks automaatselt

tuvastada fotodel olevaid loomi ja linde. Esimeses etapis õpetatakse masinale selgeks metskits (*Capreolus capreolus*) ja nugis (*Martes*).

Kaameraid on võimalik kasutada ka kalastiku seires ning kalapääsude efektiivsuse hindamiseks. Esimese kaameraga varustatud kalaloenduri kalapääsu toimimise hindamiseks paigaldas Keskkonnaagentuur 2020. aastal Purtse jõe le rajatud Sillaoru kalapääsule. Kui varasemad loendurid on olnud ilma kaamerata, siis kaameraga täiustatud loendur annab täiendavat infot ja kindlust kalapääsu sobivuse kohta eri liikidele. Sillaoru paisu juurde rajatud kalapääsu ja loendurit on kuue kuu jooksul (sept–dets 2020; aprill–mai 2021) läbinud 10 eri liiki, kellest arvukaim on olnud meriforell (*Salmo trutta*). Loenduri tulemused on selgelt näidanud, et kalapääs toimib. Kalastiku seire Purtse jõel jätkub.

Võtmesõnad: ELME, LIFE IP CleanEST, ulukiseire, kalastiku seire, VAKI Riverwatcher, tehisintellekt

Sissejuhatus

Rajakaamerate ehk fotolõksude kasutamine eluslooduse seires ei ole enam ammu midagi uut. Tänu tehnoloogia arengule ning kaamerate hinna ja kvaliteedi suhte märgatavale paranemisele on need eri liikide seires leidnud aina rohkem kasutust. Kui kõrvale jätta algsed soetamiskulud, saab kaameralõksudega oluliselt madalamate kuludega väärtuslikku informatsiooni loomade igapäevatoimetuste kohta, võrreldes klassikaliste loendusmeetoditega.

Keskkonnaagentuur on rajakaameraid abivahendina eri looma- ja linnuliikide kohta info kogumisel kasutanud juba üle kümne aasta. Selle aja jooksul on kaamerateid paigaldatud näiteks kiskluse mõjude hindamiseks maaspesitsevate linnuliikide tehis- ja ka päris pesade juurde. Kaamerate abil kogutakse infot kaitsealuste linnuliikide must-toonekure ja kassikaku asurkondades toimuva kohta. Kaameraid kasutatakse lendorava pesapuude jälgimisel ja ka hundikarjade juurdekasvu kohta teabe kogumisel. Ka märkimisväärne osa jahimeeste kogutud ja Keskkonnaagentuurile esitatud suurulukite vaatlusinfost on kogutud soolakutele ja ulukite peibutusöödaplatsidele paigaldatud rajakaamerate abil. Kui Keskkonnaagentuuril on praegu kasutuses sadakond rajakaamerat, siis jahimeestel on neid aktiivses kasutuses juba tõenäoliselt üle tuhande. Näiteks sama-aastaste poegade emakarude eristamisel tuginetakse paljuski just jahimeeste rajakaamerate fikseeritud vaatlustele.

Kui isendid oleksid üksteisest selgelt väliste tunnuste põhjal eristatavad ja piirkonda oleks paigaldatud piisavalt palju kaameraid, võiks kaamera ette jäänud isendite ja nende kordusvaatluste alusel üsna lihtsalt tuletada vaatlusaluses piirkonnas elavate isendite koguarvu. Paraku enamik meil elutsevatest ulukiliikidest

ei kanna selliseid väliseid tunnuseid, mis võimaldaks isendeid üksteisest väga lihtsalt eristada. Õnneks on välja arendatud ka sellised meetodid, mis võimaldavad fotolõksude abil kogutud info põhjal hinnata meid huvitava liigi arvukust ilma vajaduseta isendeid üksteisest eristada. Ühte sellist loendusmetoodikat – juhusliku kohtamise mudelit (REM – *random encounter model*, Rowcliffe jt, 2008) on viimasel kolmel aastal Keskkonnaagentuuris ka katsetatud ning 2018. ja 2019. aasta katse tulemuste põhjal on koostatud aruanne (Veeroja ja Linder, 2019), milles on detailselt kirjeldatud nii REM-metoodikat, saadud tulemusi kui ka hinnatud selle loendusmetoodika rakendamise kaasnivat tööjõukulu.


Loomade arvukuse määramise metoodikast

2018. ja 2019. aasta kevadel katsetati ELME projektis („Elurikkuse sotsiaal-majanduslikult ja kliimamuutustega seostatud keskkonnaseisundi hindamiseks, prognoosiks ja andmete kättesaadavuse tagamiseks vajalikud töövahendid“)¹ Eestis esmakordselt mitme ulukiliigi asustustiheduse hindamiseks juhusliku kohtamise mudelit, mis põhineb loodusesse juhuslikesse asukohtadesse paigutatud kaamerate kogutud pildimaterjali põhjal tehtud arvutustel. 2018. aasta kevadel viidi katse läbi Põlvamaal Karilatsi-Ihamaru seirealal ja 2019. aasta kevadel Tartumaal Järvselja seirealal. Mõlemal aastal oli seitsme nädala pikkuse jälgimisperioodi jooksul töös korraga 20 rajakaamerat, mille asukohti muudeti iga seitsme päeva tagant. Nii saadi lõpuks kummaltki seirealalt 140 asukohapunkti nädalajagu vaatlusmaterjali. Kaamerate paigaldamise asukohad valiti välja juhuslikult, vältides vaid kaamerate sattumist üksteisele lähemale kui 200 m.

Kaamerad paigaldati puude külge 2018. aastal 1 meetri ja 2019. aastal 0,8 meetri kõrgusele maapinnast nii, et kaamera vaateväljas ei oleks vähemalt 10 m ulatuses liikumisanduri tööd oluliselt piiravaid takistusi.

Liigi asustustiheduse määramiseks REM-meetodiga tuleb kogutud fotomaterjali põhjal lisaks liikide ja vaatluskordade eristamisele määrata terve rida muid näitajaid: 1) vaatluspingutus – kaamerapäevade arv; 2) looma kaugus kaamerast ja esmase kohtamise nurk, mille mõõtmisest annab aimu joonis 1; 3) keskmine päevateekonna pikkus, mille leidmiseks kasutatakse meid huvitava liigi isendite poolt kaamerate vaateväljas oldud aja vältel läbitud vahemaad ja liigi ööpäevase aktiivsuse taset. Looma kauguse ja läbitud vahemaa hindamiseks paigaldati kaamera vaatevälja keskele kaamerast 5, 10 ja 15 meetri kaugusele väikesed ja hiljem fotodelt tuvastatavad märgised (joonis 1). Olgu siinkohal öeldud, et adekvaatse asustustiheduse määramiseks ei tohi loomi kaamera ette peibutada, vaid nende kaamera vaatevälja sattumise tõenäosus ja liikumine kaamera ees peaks jääma võimalikult sarnaseks sellele, kuidas nad maastikul suvaliselt valitud asukohtades tavatsevad liikuda.

1 Euroopa Liidu Ühtekuuluvusfondi projekt number 2014-2020.8.01.16-0112




Joonis 1. Looma kauguse (r) ja esmase kohtamise nurga (α) määramine fotode põhjal. Mõlemad näitajad arvutatakse fotodelt trigonomeetriliselt vertikaalse (y) ja horisontaalse kauguse (x) kaudu, kus $r^2 = x^2 + y^2$ ja $\arctan(\alpha) = y/x$. Maksimaalne horisontaalne kaugus (x_{max}) arvutatakse vertikaalse kauguse (y) ja kaamera lääitse maksimaalse nurga põhjal. Looma horisontaalne kaugus x leitakse x/x_{max} suhte kaudu.

Ööpäevase aktiivsuse taseme hindamiseks kasutatakse ära kõikide uuritava alal kaamera ette sattunud sama liigi isendite vaatluste kellaegade põhjal tekkivat ööpäevast aktiivsusmustrit (sagedusjaotus) (Rowcliffe, 2016). Näitena on siinkohal esitatud Karilatsi-Ihamaru seirealal 2018. aasta mais ja juunis rajakaameralega kogutud info põhjal välja joonistunud metskitsede aktiivsusmuster (joonis 2).

Mõistliku usaldusväärsusega tulemuse saavutamiseks on soovitatav seire piirkonnas jäädvustada uuritava liigi isendeid vähemalt viiekümnel korral (Rovero jt, 2013).

Kahelt seirealalt kogunes kokku 46 040 fotot, millest 15 749 pildil võis täheldada loomi ja linde. Viimaste põhjal eristati 946 eri vaatlusjuhtumit, neist 525 Karilatsi-Ihamaru seirealal ja 421 Järveljal. Ülekaalukalt kõige rohkem jäädvustasid rajakaamerad mõlemal seirealal metskitsi, kellele vaatluste arvult järgnesid põdrad ja nugised, kuigi keskel läbi sattus neid kaamera ette metskitsedega võrreldes umbes kümme korda harvemini. Kokku õnnestus fotodelt eristada 15 erineva imetaja ja vähemalt 8 erineva linnuliigi esindajaid.

Asustustiheduse ja selle määramiseks vajalike parameetrite hindamine tehti läbi põdra ja metskitse puhul. Kuigi põtru sattus kaameralöksudesse mõlemal



Joonis 2. Metskitsede ööpäevane aktiivsusmuster Põlvamaal Karilatsi-Ihamaru seirealal ajavahemikus 11. mai – 23. juuni 2018.

seirealal kirjanduses soovitatud 50 korra asemel märksa vähem, 17 korda Karilatsi-Ihamaru ja 40 korda Järvelja seirealal, olid tulemused üllatavalt realistlikud ja saadud asustustiheduse määrangud väga sarnased samadel seirealadel tehtud pabulaloenduse tulemustega. Karilatsi-Ihamaru seirealal hinnati põdra asustustiheduseks pabulaloenduse põhjal 3,3 ja REM-lähenedisega 4,1 \pm 1,5 põtra 1000 ha kohta, Järvelja seirealal pabulaloenduse põhjal 8,9 ja REM-meetodiga 9,2 \pm 1,6 isendit 1000 ha kohta.

Erinevalt põdrast oli metskitse vaatluste hulk mõlemal seirealal vägagi soliidne ja kui eesmärgiks oleks olnud ainult metskitse asustustiheduse määramine, siis oleks piisanud ka mitu korda väiksemast kaamerapäevade arvust. Karilatsi-Ihamaru seirealal saadi metskitse asustustiheduseks 65,0 \pm 3,2 isendit / 1000 ha ja Järveljal 59,6 \pm 3,9, mis on samuti teiste meetodite põhjal tuletatuga üsna hästi haakuv.

Kui eksperimenti võib saadud tulemuste mõttes pidada edukaks ja kasutatud meetodi potentsiaali levinumate jahiulukite arvukuse hindamisel kõrgeks, siis tuleb paraku tõdeda, et fotomaterjali analüüsile kuluv tööaeg 80–90 tundi, millele lisaks veel kaamerate paigaldamisele ja asukohtade vahetamisele kuluv aeg ühe seireala kohta, on pelgalt inimtööjõudu kasutades väga suur. Näiteks kui koguda samasuguses mahus rajakaamerate salvestisi kõigilt 47 seirealalt, mida kasutatakse Eestis hirvlaste seireks, kuluks koguneva fotomaterjali analüüsiks ühel inimesel ligi 500 täispikkusega tööpäeva (á 8 tundi). Seega on selge, et meetoodika laialdane rakendamine seires eeldab kas väga suure hulga vabatahtlike abi või tuleb fotode analüüsi võimalikult suures ulatuses automatiseerida.

Tehisintellekt kui oluline abivahend fotode läbitöötamisel ja loomade asustustiheduse hindamisel

Selleks et vähendada tuhandete fotofailide läbivaatamise ja analüüsiga kaasnevat suurt aja- ja tööjõukulu ning luua eeldused rajakaamerate kasutamiseks senisest suuremas mahus, on Keskkonnaagentuur Majandus- ja Kommunikatsiooniministeeriumi rahastuse toel² koostöös tarkvaraarendajaga OÜ Solita välja töötamas tehisintellekti prototüüpi, mis suudaks automaatselt tuvastada fotol olevaid looma- või linnuliike. Esimeses etapis õpetatakse masinale eristama loomaga ja loomata fotosid ning teises etapis loomaga piltidelt eristama nugist ja metskitse. Sealt edasi tuleb masinale järk-järgult selgeks õpetada ülejäänud loomad ja linnud, keda seirata soovitakse. Lisaks liikide tuvastamisele peab loodav lahendus määrama fotode põhjal looma asukohta, eristama kaamerate ees liikuvatest loomadest tekkivad pildiseeriad eri vaatlusjuhtumiteks ja määrama pildiseeria põhjal looma poolt kaamera vaateväljas läbitud vahemaa. Loomade asukohta ja kaamera ees läbitud vahemaa hindamisel kasutatakse kaamerast 5, 10 ja 15 meetri kaugusele paigaldatavaid märgiseid, mille põhjal koostatakse lähtuvalt kaamera objektiiviga ja sensori parameetritest kauguste maatriks. Märgiste tuvastamiseks rakendatakse sama objektituvastuse algoritmi. Salvestatud fotode töötlemisel rakendatakse lisaks masinnägemisele juhusliku kohtamise mudelit, mille tulemusel on võimalik hinnata eri loomaliikide arvukust seirealal. Põhimõtteliselt peab loodav lahendus olema võimeline fotodel oleva ja fotofailide metaandmetes peituva info (kellaajad, kasutatud kaameramudeli objektiiviga fookuskaugus ja muud parameetrid) põhjal arvutama kõik REM-metoodikaga asustustiheduse hindamiseks vajalikud näitajad ja süsteemi kasutaja poolt eelnevalt määratud projektiala kaamerate põhjal ka eri liikide asustustiheduse piirkonnas. Sealjuures saavad süsteemi kasutavad seirespetsialistid kontrollida ja vajadusel täpsustada nii tehisintellekti tehtud liigimääranguid kui ka isendite ja märgiste asukohti ning lisanduva fotomaterjaliga mudelit vajadusel edasi treenida.

Lahenduse arendamiseks on kasutuses ligikaudu 30 000 sildistatud pilti süvaõppe raamistiku treenimiseks.

Lisaks rajakaameratele kasutab Keskkonnaagentuur kaameraga kalaloendurit VAKI Riverwatcher, mis on projekti LIFE IP CleanEST³ raames paigaldatud Purtse jõe Sillaoru kalapääsule, et anda hinnang kalapääsu efektiivsusele. Nii nagu rajakaamerad, ei ole uudne ka kaameraga kalaloendur, ent erilisemaks teeb selle siinkohal asjaolu, et teadaolevalt pole Eestis kaameraga kalaloendurit varem kasutatud kalapääsu efektiivsuse hindamiseks. Kalaloenduri abil on võimalik

2 Integrating RENewable energy and Ecosystem Services in environmental and energy policies, <https://www.interregeurope.eu/irenes/>

3 Projekti rahastusleping LIFE17 IPE/EE/00007 sõlmiti Keskkonnaministeeriumi ja Euroopa Komisjoni vahel 14.12.2018.

hinnata ka Purtse ja Kohtla jõel nende seisundit parandavate tegevuste tulemuslikkust. Purtse jõest ja Kohtla jõest likvideeriti keemiatööstuse jääkreostust ja rajati parema kvaliteediga elupaiku. Projekti raames on plaanis rajada karestiku tüüpi kalapääs ka Sillaorust ülesvoolu jääva Püssi paisu asemele. Käimasoleva uuringu tulemused annavad hea võrdlusmaterjali tegevuste tulemuslikkuse hindamiseks tulevikus.

Kaameraga kalaloendur Sillaoru kalapääsul

Möödaviik-kalapääs rajati Sillaoru paisu juurde juba 2008. aastal, kuid see ei vastanud kalapääsu nõuetele ega täitnud oma eesmärki. Vajalikud rekonstrueerimistööd kalapääsu efektiivsuse parandamiseks teostati 2014. aastal (foto 1).

Sillaoru hüdroelektrijaama paisu juurde rajatud kalapääs on väikese languga looduslähedane tehiskarestik. Kalapääsu pikkus on ligikaudu 160 m ja keskmine lang 2,1%. Esimene kalapääsu efektiivsuse hindamine tehti 2015. aastal, see andis kinnitust, et Sillaoru kalapääs on kõikidele sellele jõetüübile omastele kalaliikidele üles- ja allarändeks füüsiliselt läbitav.

Kuna Purtse jõgi on üks suurema potentsiaaliga siirdekalade koelmu- ja elupaigajõgesid Virumaal ning kogu Eestis, siis otsustati projekti LIFE IP Clean-EST raames, et jõe seisundi parandamiseks tehtud tööde tulemuslikkus vajab võimalikult põhjalikku uurimist. Lisaks traditsioonilistele kalastiku seisundi hindamise meetoditele peeti otstarbekaks kasutada kaameraga varustatud kalaloendurit, mis võimaldaks loendada üles- ja allavoolu liikuvaid kalu ning tuvastada ka nende liiki. Loendur paigaldati 23. septembril 2020. aastal Sillaoru kalatee sissevoolule esmase eesmärgiga registreerida kuderändel lõhelisi. Et maksimaalselt ära kasutada loenduri võimalusi ja suurendada seiratavate liikide ning vanuserühmade arvu ning ka hõlbustada loenduri hooldust, valmistas paisu omanik loenduri kinnitamiseks uue konstruktsiooni (foto 2). Uus konstruktsioon, suunaja võre silmasuurusega 16 mm, paigaldati 30.03.2021. Täiustatud süsteem suunab loendurisse ka väiksemaid ning saledamaid liike, nagu jõesilm. Arvatavasti ei suuda süsteem registreerida kõiki isendeid, kuna seadistustes on isendi selja kõrguse alampiiriks 25 mm. Õnnestunud on registreerida ka väiksemate kalaliikide ülesvoolurännet, juhul kui väikeste kalade parv käivitab loenduri salvestusseadmed. Kuna nähtavus Purtse jões on praegu puhastustööde ja muutuvate vooluhulkade tõttu halb, siis on liigiti määramine siiski keeruline. Kontrollimist ja arendamist vajab allavoolurändel merre laskuvate lõheliste nn smoltide registreerimine loenduriga. Keskmiselt on üksiku isendi pikkus 10–20 cm, mis ei pruugi olla piisav loenduri käivitamiseks.



Foto 1. Mõdaviik-kalapääs Sillaoru paisu juures 10.09.2019.



Foto 2. Kalaloenduri paigaldamine 23.09.2020.




Foto 3. Kalaloenduri paiknemine kalapääsul 2020. aasta sügisel.



Foto 4. Uue konstruktsiooniga kalaloendur 30.03.2021.



Foto 5. Kalaloendur 30.03.2021.




Foto 6. Kaamera vaade

Kalaloenduri kasutamisel saadud tulemused

VAKI Riverwatcheri kasutamine Sillaoru kalapääsul on ennast õigustanud. Kalaloendur ei raskenda kalatee ülesvoolu läbimist ega takista kalade rännet. On näiteid, kus suuremad isendid on kasutanud loendurit ka varjumiseks ja jäänud loenduri kambrisse pikemaks ajaks pidama. Loendur fikseerib mõlemas suunas toimuvad ränded, kalad läbivad loenduri vigastusteta. Kaamera abil on olnud võimalik tuvastada kalaliike, samuti läbivad loendurit imetajad, näiteks saarmas ja kobras. Peale konstruktsiooni täiustamist hakkas loendur fikseerima ka raskesti tuvastatavaid liike, nagu jõesilm, ja väiksemamõdulisi parvena rändavaid kalu. Maksimaalse kasutamise huvides oleks vaja katsetada loenduri võimalusi laskuvate lõheliste smoltide loendamiseks. Väiksemate isendite ja kalaliikide registreerimise soovi korral on vaja loendur kombineerida traditsiooniliste püügimeetoditega, nagu püük väikesesilmalise mõrraga.

Kogunenud andmete põhjal on võimalik juba väita, et Sillaoru kalatee funktsioneerib ja seda on võimelised läbima ka väiksemad kalad ja kehvema ujumisvõimega liigid, nagu jõesilmud. Kokku on kalapääsu ja loenduri läbinud 10 eri liiki, kellest arvukaim on olnud meriforell (tabel 1). Lisaks teadmisele, et kalapääs toimib, annab kalaloendur kindlust, et pikalt sisuliselt surnud veekogu elustik on hakanud taastuma. Kui meriforelli ja lõhe asurkondade taastamiseks on veekogusse lastud suurel hulgal tehistingimustes üleskasvanud noorkalu, siis ülejäänud liigid on jões uuesti levima hakanud looduslikult.

Sillaoru kalateel on loenduri kasutamine võimalik, kuna kalateed ei läbi kogu jõe vesi ja kalateele suunatav vooluhulk on küllaltki stabiilne ning veetaseme kõikumine ei ole suur. Ka on kalatee rajamisel ette nähtud loenduri paigaldamise võimalus ja rajatud vastavad konstruktsioonid loenduri stabiilseks paigaldamiseks ja hoolduse hõlbustamiseks. Raskendav asjaolu on aeg-ajalt vee halb läbipaistvus, mis paljuski on tingitud ülesvoolu Purtse jõel ja Kohtla jõel tehtud jõesängi puhastustöödest. Senikaua kui ümberkujundatud jõesäng ja kaldavöönd ei ole veel taimestunud ja setted stabiliseerunud, halveneb suuremate sadude ja suurvete ajal nähtavus endiselt ja kaamera vajab tihedamat hooldust. VAKI kalaloendurit arendatakse pidevalt edasi. Loendurit on võimalik täiendada andurite ja logeritega, mis salvestavad olulisemaid veekeskonna parameetreid.

Nii nagu rajakaamerad metsas, toodavad ka kalastiku seireks mõeldud kaamerad suurel hulgal pildi/videomaterjali, mida tuleb analüüsida. Seni, kuni kaameraid on kasutuses vähe, saab salvestatud materjali lihtsa vaevaga analüüsida, kuid suuremate mahtude korral on ka siin abiks tehisintellekt. Kalade automaatselt tuvastamiseks ja liikide määramiseks on juba välja töötatud abivahendeid, mida siiski tuleb pidevalt edasi arendada ja kohandada konkreetse seirepiirkonna vajadustele ja seal elavate liikide tuvastamiseks.

Tabel 1. Kalaloenduri läbinud liikide ja isendite arv perioodil 09.2020 – 05.2021.

Aasta ja kuu	2020	9	10	11	12	2021	4	5	Kokku
Ahven	1			1					2
Forell	79	1	66	11	1	4	2	2	83
Haug	4	3	1			12	10	2	16
Jõesilm									17
Löhe	15		5	10					15
Ogalik						5		5	5
Särg						8	1	7	8
Vikerforell						2	2		2
Löheline	4		2	2					4
Karplane						2	2		2
Kobras	1		1			5	2	3	6
Saarmas						1		1	1
Takson tuvastamata	34		19	12	3				34
Kokku	138	4	94	36	4	57	27	30	195

Viidatud kirjandus

- Norouzzadeh, M. S., Morris, D., Beery, S., Joshi, N., Jojic, N., & Clune, J. (2019). A deep active learning system for species identification and counting in camera trap images. arXiv preprint arXiv:1910.09716.
- Rowcliffe, J. M., Field, J., Turvey, S. T., Carbone, C. 2008. Estimating animal density using camera traps without the need for individual recognition. *J. Appl. Ecol.* 45, 1228–1236.
- Rowcliffe, J. M. 2016. Package ‘activity’: animal activity statistics. R package version 1, 1.
- Rowcliffe, J. M., Jansen, P. A., Kays, R., Kranstauber, B., Carbone, C., Pettorelli, N. 2016. Wildlife speed cameras: measuring animal travel speed and day range using camera traps. *Remote Sens. Ecol. Conserv.* 2, 84.
- Rovero, F., Zimmermann, F., Berzid, D., Meek, P. 2013. ‘Which camera trap type and how many do I need?’ A review of camera features and study designs for a range of wildlife research applications. *Hystrix* 24, 148–156.
- Veeroja, R., Linder, M. (2019). Rajakaamerate kasutamine ulukite arvukuse hindamiseks juhusliku kohtamise mudeli abil. Keskkonnaagentuur.

Summary

Use of cameras for environmental monitoring and development of AI for result analysis

For considerable time wildlife monitoring has been performed by using cameras. However, due to the development of technology and its affordability, new possibilities have emerged. When possible, they have been implemented, but the problem remains in Estonia: the establishment of camera network and analysis of data needs additional resources – both financial and human. Yet cameras are capable of producing enormous amounts of data about different animal and bird species; collection of equivalent volume of data using only human resources is unreasonable, even impossible in practice. Cameras are useful also due to the fact that monitoring of different game species, which is largely based on counting of snow tracks, has become increasingly problematic because of warming climate. Therefore camera-based methods could be a suitable alternative.

In 2018 and 2019, within the ELME project framework, random encounter model was tested in Estonia for the first time; the model is based on calculations of images collected by cameras placed in random locations in the wild. The test was carried out in Põlva County Karilatsi-Ihamaru monitoring area and in Tartu County Järvselja monitoring area. A total of 46,040 photographs were collected from the two monitoring areas, of which 15,749 (34.2%) reveal animals and birds. In total, fifteen different mammals and at least eight different bird species were distinguished from the photos. The assessment of population density was carried out in case of moose and roe deer.

If a similar amount of track camera recordings were collected from all 47 monitoring areas used for deer monitoring in Estonia, it would take almost 500 working days for one person to analyze the accumulated photographic material, which is unreasonably time-consuming and costly. In addition, there are camera acquisition costs, time spent on their installation and relocation, as well as transportation costs. In order to use cameras more widely, the Environment Agency is developing artificial intelligence that could automatically detect animals and birds in photographs. In the first stage, the machine is „taught“ to identify roe deer (*Capreolus capreolus*) and marten (*Martes*).

Cameras could also be used in fish monitoring and in assessment of efficiency of fish passes. First fish counter equipped with a camera was installed at the Sillaoru by-pass fishpass which is located in the Purtse River. Previously used counters in fish pass assessments in Estonia have not included a camera; the counter upgraded with a camera, however, provides additional information and certainty about the suitability of the fish pass for different species. In six months (Sept-Dec 2020; Apr-May 2021), ten different species have used the fish pass at the Sillaoru dam and have been recorded by the counter, most abundantly sea trout (*Salmo trutta*). The results of the counter provide clear proof of the effectiveness of the Sillaoru dam fish pass. Fish monitoring in the Purtse River continues.

Konvektiivsete tormide klimatoloogia Eestis lähtuvalt radariandmetest ja keskkonnatingimustest

Tanel Voormansik^{1,2}, Tuule Mürsepp¹, Piia Post¹

¹ Tartu Ülikool, füüsika instituut, W. Ostwaldi 1, 50411 Tartu

² Keskkonnaagentuur, Mustamäe tee 33, 10616 Tallinn

Kokkuvõte

Artiklis antakse ülevaade konvektiivsete tormide klimatoloogiast Eestis lähtuvalt radariandmetest ja keskkonnatingimustest. Uuritav ajavahemik hõlmas 9 aasta sooja perioodi (mai–september) aastatel 2010–2019 (v.a 2017). Esmalt defineeriti konvektiivne torm, kasutades radari peegelduvuse piirväärtust 51 dBZ ja atmosfääri järelanalüüsi mudelandmete konvektiivse kättesaadava energia (CAPE) piirväärtust 80 J/kg. Leitud konvektiivsete tormide võrdlus välgudetektorite andmestikust saadud pilv-maa-välgulöökidega näitas head kooskõla. Enim konvektiivseid torme esines pärastlõunasel ajal kella 15–16 paiku kohaliku aja järgi. Kuude löikes oli enim konvektiivseid torme juulikuus, välgulöökidete maksimum oli augustis. Suveperioodil on konvektiivse tormipäeva esinemise tõenäosus Eestis 45% päevadest, välgupäeva esinemise tõenäosus 54%. Enim on konvektiivse tormi päevi Mandri-Eesti lääne- ja edelaosas. Välgudetektori andmetest nähtub lisaks ka Kagu-Eesti maksimum, mis jääb radari parimast mõõteulatusest välja.

Märksõnad: konvektiivne torm, meteoradar, järelanalüüs, äike, klimatoloogia

Sissejuhatus

Konvektiivsed tormid on soojal poolaastal laialdaselt esinevad meteoroloogilised nähtused. Tugeva konvektiivse tormiga kaasnevad mitmed ohud, nagu rahe, tugev puhanguiline tuul, intensiivsete sademete põhjustatud tulvaveed ja tornaadod. Sellistel tormidel on ka ulatuslik majanduslik mõju, näiteks Euroopas põhjustavad need aastas hinnanguliselt 5–7 miljardi euro ulatuses kahjusid (Hoeppe, 2016).

Kuna konvektiivsete tormide tekkega on seotud keerukad protsessid erinevatel ruumi- ja ajaskaaladel, on nende tekke ja arengu ennustamine senimaani probleemne (Pulkinen jt, 2020). Hoolimata numbriliste ilmaennustusmudelite

märkimisväärsest arengust viimastel aastakümnetel, ei suuda need ennustada konvektiivseid torme piisava täpsusega, et rahuldada lõppkasutajate vajadusi. Konvektiivsete tormide kohta täpsema teabe saamiseks on maailmas tehtud mitmeid juhtumianalüüse (Leon jt, 2016; Lompar jt, 2017; Romero jt, 2015). Siiski on lisaks vaja ka pikaajalistel andmetel põhinevaid uuringuid, et tõsta seeläbi konvektiivsete tormide ennustuste täpsust (Nisi jt, 2014).

Konvektiivsete tormide alane uurimistöö on viimase 50 aasta jooksul oluliselt arenenud seoses kaugseire andmete ja numbriliste ilmaennustusmudelite kasutuselevõtu ja arenguga (Brooks jt, 2019). Varasemate tööde tulemused, mis põhinesid vaatlusjaamade andmetel, olid tugevalt mõjutatud jaamade hõredast paiknemisest ja andmete suurest intervallist. Välgudetektorite võrgustike andmetel tuginevad analüüsid pakuvad võimalust saada ülemaailmseid äikesetormide klimatoloogiaid, kuid nendest jäävad välja konvektiivsed tormid, mis ei sisalda välgulööke (Enno jt, 2020; Mäkelä jt, 2014; Pohjola ja Mäkelä, 2013). Satelliidiandmed pakuvad infot küll suurte alade kohta, kuid on suuremate laiuskraadide kohta väga piiratud või puuduvad sootuks (Huffman jt, 2010). Kõige uuemad atmosfääri järelanalüüsi mudelid, nagu näiteks Euroopa Keskpika Ilmaennustuse Keskuse (ECMWF) ERA5, pakuvad ülemaailmselt kuni 30-kilomeetrise lahutusvõimega konvektiivsete keskkonnatingimuste klimatoloogiaid (Taszarek jt, 2020).

Võrreldes eeltoodud allikatega on meteoradaril mitmeid eeliseid. Meteoradari abil saab avastada tormi juba selle tekkefaasis, jälgida tormi arengut, suurust, paiknemist ja liikumist kõrge ajalise ja ruumilise lahutusvõimega. Radarmõõtmiste andmete kvaliteeti mõjutavad siiski mitmed tegurid, nagu näiteks radarikiire blokeerimine, peegeldused mittemeteoroloogilistelt objektidelt, radarikiire pilvest üleminek ja sumbumine (Saltikoff jt, 2010). Nende kõikidega peab ka tormide andmeid töödeldes ja tulemusi interpreteerides arvestama.

Eestis on konvektiivseid torme süstemaatiliselt uuritud vähestes töodes ja valdavalt äikesevaatlustest või välguandmetest lähtudes. Varasemad uurimused baseerusid jaamade vaatlusandmetel (Enno jt, 2013). Uuemates töodes on äikeseklimatoloogiat analüüsitud välgudetektorite andmete põhjal (Enno jt, 2020; Mäkelä jt, 2014)

Radariandmeid, mille arhiiv on täielikult olemas alates aastast 2010, on kasutatud rahe ja pilv-maa-välkude ning kvantitatiivse sajuhinnangu uurimiseks (Voor-mansik jt, 2021a, 2017).

Käesoleva artikli eesmärk on uurida konvektiivsete tormide ajalisi ja ruumilisi jaotusi Eestis lähtuvalt radari-, välgudetektorite ja järelanalüüsi andmetest. Antakse ka ülevaade tormide olenevusest õhuvoolu suundadest.

Materjal ja meetodika

Üldise meetodilise lähenemise konvektiivsete tormide määramiseks võib kokku võtta järgnevalt. Kõigepealt määrati tugeva sajuga alad kõrgete peegelduvusnäitajate

järgi ilmaradari andmetes. Siin kasutati eeldust, et tugevad sademed on suure tõenäosusega konvektiivse tekkega. Analüüsides neid esialgseid sajualasid, on Voormansik jt (2021b) leidnud peegelduvuse ning konvektiivselt kättesaadava energia (CAPE) lävendite kombinatsiooni, mille ületamine tagab, et valitud sajuala on tõesti tugev konvektiivne torm. Metoodika sobivuse tõendamiseks on konvektiivsete tormide klimatoloogiat võrreldud välgudetektori andmetest saadud tormide jaotusega.

Uuritav periood hõlmas 9 aastat ajavahemikust 2010–2019, radariandmete puuduliku kvaliteedi tõttu jäi välja aasta 2017. Kasutati andmeid mai algusest kuni septembri lõpuni, kuna sellel perioodil esineb Eestis üle 99% konvektiivsetest tormidest (Enno jt, 2014).

Meteoradari andmed

Töös kasutati Kesk-Eestis Sürgavere külas asuva C-laineala kaksikpolarimeetrilise Doppleri ilmaradari andmeid. Radari maksimaalne tööraadius on 250 km, lahutusvõime 300 m radiaalsuunas ja 1° asimuudi suunas. Kasutati madalaima kõrgusnurga (0,5°) skaneeringuid 15-minutilise intervalliga. Et eemaldada mittemeteoroloogilist päritolu peegeldused, rakendati radariandmetel Doppleri, *spec-kle* ja *clutter to signal ratio* filtreid. Polarimeetrilist sademeliikide klassifikatsiooni kasutati ülejäänud mittemeteoroloogiliste peegelduste eemaldamiseks (Chandrasekar jt, 2013).

Radariandmete tehniliste probleemide tõttu kehvena kvaliteediga 2017. aasta andmeid töös ei kasutatud, ülejäänud aastate andmete kättesaadavus oli 95,44%. Täielike andmete puudumise põhjuseks olid radari plaanipärased hooldused, andmeedastuse probleemid ja väiksemad tehnilised tõrked.

Radariandmetest tormialade määramiseks kasutatakse tavaliselt arvutinägemise algoritme, mis kasutavad alade piiritlemiseks mingit valitud horisontaaltasandi peegelduvuse piirmäära (Dixon ja Wiener, 1993; Johnson jt, 1998). Sageli jääb see piirmäär vahemikku 30–45 dBZ (del Moral jt, 2018; Hu jt, 2019; Kober ja Tafferner, 2009; Kyznarová ja Novák, 2009). Madalamad väärtused võimaldavad leida konvektiivseid torme nende varastes staadiumites, samas kui kõrgemad väärtused on sobivamad üksikute konvektiivsete rakkude leidmiseks. Käesolevas töös kasutati 35 dBZ piirmäära, et leida tugeva saju alad, millest omakorda eraldati konvektiivsed tormid hilisema filtreerimise põhjal. Iga sajuala kohta salvestati selle keskpunkti koordinaadid, maksimaalne ja keskmine peegelduvus ning pindala.

Välgudetektorite andmed

Välgulöövide andmestik pärineb Põhjamaade välgudetektorite võrgustikust NORDLIS (Nordic Lightning Information System), kuhu kuulub 39 Vaisala pikalaineala välgudetektorit, mis paiknevad Eestis, Leedus, Lätis, Norras, Rootsis ja Soomes. Andmebaasist kasutati ainult pilv-maa-välgulööke nende parema detekteeritavuse tõttu. Soome kohta on leitud, et NORDLIS-i võrgustiku pilv-maa-välgulöövide detekteerimise efektiivsus on 95% (Tuomi ja Mäkelä, 2007), sarnast tõhusust võib eeldada ka Eesti kohta.

Välgudetektorite andmeid kasutati leitud metoodika kontrolliks. Torm loeti välku sisaldavaks, kui lähim pilv-maa-välk asus tormi keskmest 25 km raadiuses, sest sellesse raadiusse jääb 90% pilv-maa-välkudest.

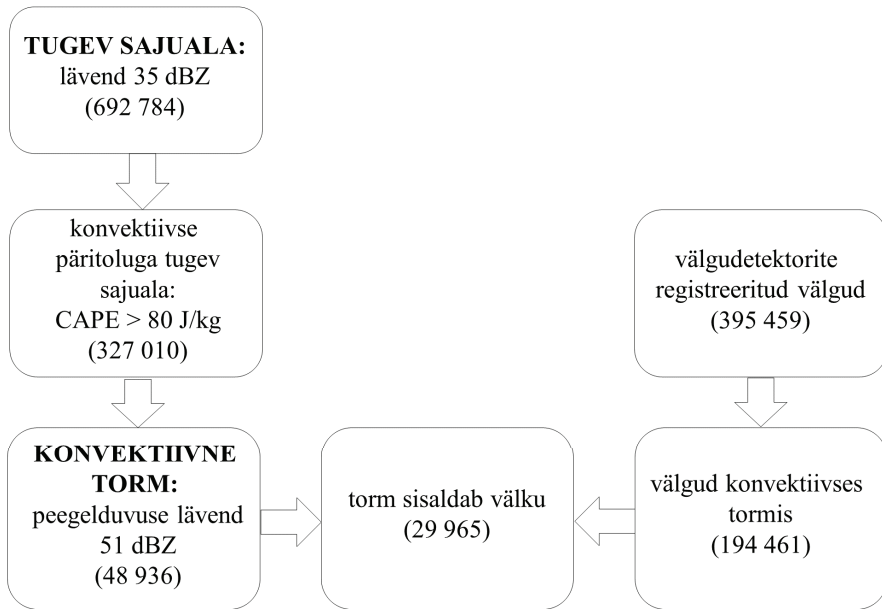
Järelanalüüsi mudelanded

Töös kasutati ECMWF-i värskemaid ERA5 järelanalüüsi mudelanded. Konvektiivse kättesaadava potentsiaalse energia (CAPE) andmeid kasutati konvektiivsete keskkonnatingimuste tuvastamiseks. 500 hPa geopotentsiaalse kõrguse väljadest arvutati Jenkinsoni ja Collisoni metoodikat kasutades atmosfääri tsirkulatsioonitüübid – JCT-d (Jenkinson ja Collison, 1977). Esialgses klassifikatsioonis on 26 tsirkulatsioonitüüpi, kuid käesolevas töös jagati õhuvoolud kaheksasse põhisuunda: lääs – W, loe – NW, põhi – N, kirre – NE, ida – E, kagu – SE, lõuna – S, edel – SW. JCT-d arvutati iga päeva jaoks vahemikus 1979–2019, kasutades 12:00 UTC 500 hPa geopotentsiaalse kõrguse välju. Pikem aeg valiti selleks, et võrrelda valitud 9-aastase perioodi esinduslikkust pikema perioodiga.

Tormialade määramine

Tormialade määramiseks kasutati radariandmeid ja järelanalüüsi mudelanded. Tormialade määramise plokk skeem on toodud joonisel 1. Esmalt leiti radariandmetest tugevad sajualad, kasutades lävendina 35 dBZ horisontaaltasandi peegelduvust, mis vastab sajuintensivsusele umbes 4,8 mm/h. Selle tulemusel saadi 692 784 sajuala. Kuna kasutatud lävend on üsna madal, mis ei taga sajuala konvektiivset päritolu, filtreeriti sajualasid mudelandedmetest pärineva CAPE piirväärtusega 80 J/kg. Saadi 327 010 konvektiivse päritoluga tugevat sajuala. Seejärel tõsteti ka peegelduvuse lävendit, et välja oleksid valitud vaid potentsiaalselt ohtlikud alad. 51 dBZ peegelduvus vastab 55 mm/h sajule, mis Eesti kliimas on väga ekstreemne. Käesolevas töös on konvektiivne torm seega defineeritud kui vähemalt 51 dBZ peegelduvusega ja vähemalt 80 J/kg CAPE-ga ala. Neid saadi kogu perioodi peale kokku 48 936.

Võrreldes detekteeritud välkude arve käesolevas töös leitud tormide arvudega, peab arvestama teatud eripäradega. Esiteks sellega, et kuigi välgudetektorite pilv-maa-välkude tuvastamise efektiivsus on kõrge, jäävad sellest andmestikust kõrvale konvektiivsed tormid, mis ei põhjusta välgulööke. Samuti peab arvestama võimalusega, et väga suur hulk välgulööke langeb ühe tugeva tormi tõttu lühikelele perioodile. Nõnda saadi (joonis 1), et ühelt poolt enam kui pooled ehk 29 965 konvektiivset tormi sisaldasid vähemalt üht välku. Teiselt poolt olid vaid umbes pooled välkudest (194 461) seotud mõne konvektiivse tormiga. Seetõttu on töös võrreldud lisaks tormialadele ja välgulöökidest ka tormi- ja välgupäevi, et tuua suurusjärgu poolest erinevad tormide ja välkude arvud samasse skaalasse.




Joonis 1. Tormialade määramise plokk skeem.

Tulemused ja arutelu


Konvektiivsed tormid võrrelduna pilv-maa-välgulöökidega

Sobiva ajalise ja ruumilise lahususvõimega vaatlusandmed konvektiivsetest tormidest või nendega seotud ohtlikest nähtustest Eesti ala jaoks valitud perioodi kohta puuduvad. Seepärast valiti võrdlusandmestikuks välgudetektorite mõõtmised. Me eeldame, et välgudetektorite andmestik on sõltumatu allikas konvektiivsete tormide määramise meetodi verifitseerimiseks.

Konvektiivsete tormide jaotused olid sarnased pilv-maa-välgude jaotustega erinevatel ajaskaaladel tunnist kuni aastani. Ööpäevaste käikude võrdlusest joonisel 2 on selgelt näha konvektiivse aktiivsuse pärastlõunane maksimum kella 12–13 UTC (15–16 kohaliku aja järgi) paiku. Tugeva saju alad, mis on leitud 35 dBZ peegelduvuse läve kasutades, sisaldavad ka frontaalseid mittekonvektiivseid sadusid ja seetõttu on nende ööpäevane jaotus oluliselt ühtlasem. Peegelduvuse läve tõstmine 51 dBZ-ni ja 80 J/kg CAPE lävendi lisamine eemaldab efektiivselt mittekonvektiivsed alad ja jooniselt 2 võib näha, et konvektiivsete tormide jaotus ühtib hästi pilv-maa-välgude omaga. Pilv-maa-välgude jaotus ja suhtelise sageduse maksimum on võrreldes konvektiivsete tormidega paar tundi nihkes. Selle põhjuseks on välgulahenduse tekke hilinemine võrreldes tugevate sademete tekkega ja tormialade arenemise käigus nende omavahelised ühinemised. Tormide pindalade maksimum on võrreldes tormide arvuga samuti paari tunni võrra nihkes (Voormansik jt, 2017).




Joonis 2. Tugeva saju alad, konvektiivsete tormide ja pilv-maa-välgude ööpäevased käigud.



Joonis 3. Tugeva saju alade, konvektiivsete tormide ja pilv-maa-välgude kuised keskmised (joon), maksimumid ja miinimumid (punktid).

Tugeva saju alade, konvektiivsete tormide ja pilv-maa-välgulöökide kuise skaala võrdlusest on näha selge sesoonsus, aga ka kõigi kolme parameetri suur maksimumide ja miinimumide varieeruvus (joonis 3). Konvektiivne aktiivsus on madal mais ja septembris, kõige aktiivsem periood on juunist augustini. Konvektiivseid torme on keskmiselt kõige enam juulis, pilv-maa-välgulööke aga augustis.

Tugeva saju päevad, konvektiivsed tormipäevad ja välgupäevad leiti selle järgi, kas Eesti territooriumil oli sel päeval vähemalt üks tugeva saju ala, konvektiivne torm või pilv-maa-välk. Nende päevade suur aastatevaheline muutlikkus on kokku võetud joonisel 4. Tugeva saju päevade arv ulatus 86st aastal 2016 kuni 133ni aastal 2019. Konvektiivseid tormipäevi oli kõige vähem samuti aastal 2016 (48 päeva) ja kõige rohkem aastal 2013 (87 päeva). Välgupäevi oli 70st aastal 2015 kuni 97ni aastal 2013. Kusjuures keskmisena oli aastal 14 välgupäeva enam kui konvektiivse tormi päevi, mis viitab küllalt kõrgetele tugeva tormi lävenditele. Kogu uuritud ajaperioodi keskmisena võib välja tuua, et soojal hooajal esineb 76% päevadest kusagil Eestis tugevaid sademeid, 45% päevadest konvektiivseid torme ja 54% päevadest pilv-maa-välke. See näitab, et sellised nähtused ei ole Eestis suvehooajal haruldased.



Joonis 4. Tugeva saju päevade, konvektiivsete tormipäevade ja välgupäevade aastased suhtelised sagedused.

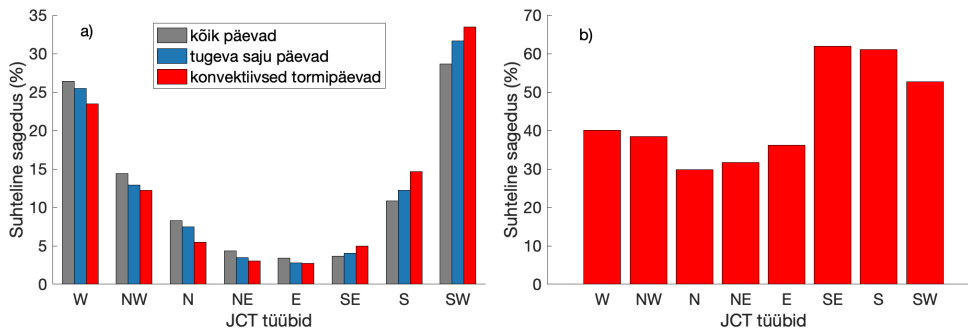
Konvektiivsete tormide jaotus Eesti alal

Eelnevast selgus, et peaaegu pooltel sooja hooaja päevadel esines Eesti alal vähemalt üks konvektiivne torm. Selles osas vaadeldakse konvektiivsete tormide jaotust Eesti alal kahest eri vaatepunktist. Esmalt uuritakse tormide sõltuvust õhuvoolu suundadest ja teiseks tormide jaotust Eesti alal 10 × 10 km ruudustikul.

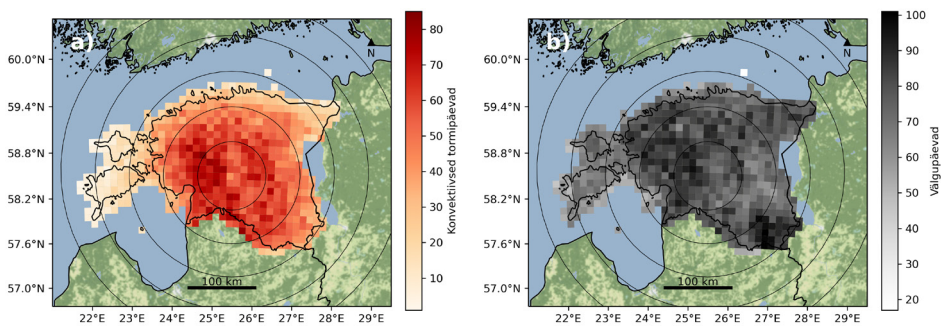
Klimatoloogias on teada, et Eesti laiustel on valdavaks läänekaarte tuuled. Jooniselt 5a on näha, et ka meie uuritud ajaperioodi kõiki päevi arvesse võttes olid sagedaimad õhuvoolu suunad SW ja W. Üldiselt kehtib reegel, et tugeva saju päevade ja konvektiivsete tormide päevade jaotus ühtib valdavate õhuvoolu suundade jaotusega. Mida rohkem aga tõsta radari peegelduvuse lävendit, seda enam tõuseb esile lõunakaare õhuvoolude (SE, S, SW) osatähtsus. Seda kinnitab joonis 5b, millelt ilmneb, et kõige suurem tõenäosus konvektiivse tormi esinemiseks on

lõunakaare õhuvoolude valitsemise korral. Kõige väiksem on konvektiivse tormi esinemise tõenäosus N, NE ja E õhuvoolu korral. Neist suundadest tuleva õhuvoolu korral on esinenud ka arvuliselt kõige vähem tormipäevi.

Kõige rohkem tormipäevi uuritud 9-aastase perioodi põhjal esineb Eesti lääne- ja edelaosas (joonis 6a). Samas tuleb tormide ruumilist jaotust analüüsides arvestada radariandmete eripäradega ja seetõttu väheneb radarist kaugtel aladel tormide detekteerimise efektiivsus. Võib eeldada, et umbes kauguseni 100 km radarist on andmed usaldusväärsed, kaugematel aladel aga usaldusväärsus väheneb. Ka välgudetektorite andmetest (joonis 6b) on näha Mandri-Eesti lääne- ja edelaosa välgupäevade maksimum, aga lisaks ka Kagu-Eesti maksimum, mis suure kauguse tõttu radariandmetest ei ilmne.



Joonis 5. Suhtelised sagedusjaotused kõikide päevade, tugeva saju päevade ja konvektiivsete tormipäevade esinemise kohta sõltuvalt valdavast õhusuunast (a); konvektiivse tormipäeva esinemise tõenäosus vastava JCT tüübi esinemise korral (b).



Joonis 6. Konvektiivsete tormipäevade (a) ja välgupäevade (b) jaotus 10 × 10 km ruudustikul. Näitamaks eri piirkondade kaugust radarist, on joonistatud 50 km sammuga ringid.

Kokkuvõtteks võib öelda, et kombinatsioon kahest lävendist – suhteliselt kõrgest radari peegelduvusele ning madalast konvektiivselt kättesaadava energia jaoks – annab Eesti tormide tuvastamisel pilv-maa-välkudega võrrelduna kokkulangevad tulemused. Neid lävendeid saaks kasutada ka operatiivtöös konvektiivsete tormide lühiennustuses.

Tänuavaldus

Seda tööd on toetanud Eesti Teadusagentuuri uurimisgrant PSG202 ja Euroopa Regionaalarengu Fondist valdkondliku teadus- ja arendustegevuse toetamise programm RITA KAUGSEIRE (RITA1/02-52-07).

Viidatud kirjandus

- Brooks, H.E., Iii, C.A.D., Zhang, X., Chernokulsky, A.M.A., Tochimoto, E., Hanstrum, B., Nascimento, E. de L., Sills, D.M.L., Antonescu, B., Barrett, B., 2019. A Century of Progress in Severe Convective Storm Research and Forecasting. *Meteorological Monographs* 59, 18.1-18.41. <https://doi.org/10.1175/AMSMONOGRAPHS-D-18-0026.1>
- Chandrasekar, V., Keränen, R., Lim, S., Moisseev, D., 2013. Recent advances in classification of observations from dual polarization weather radars. *Atmospheric Research, ADVANCES IN PRECIPITATION SCIENCE* 119, 97–111. <https://doi.org/10.1016/j.atmosres.2011.08.014>
- del Moral, A., Rigo, T., Llasat, M.C., 2018. A radar-based centroid tracking algorithm for severe weather surveillance: identifying split/merge processes in convective systems. *Atmospheric Research* 213, 110–120. <https://doi.org/10.1016/j.atmosres.2018.05.030>
- Dixon, M., Wiener, G., 1993. TITAN: Thunderstorm Identification, Tracking, Analysis, and Nowcasting—A Radar-based Methodology. *Journal of Atmospheric and Oceanic Technology* 10, 785–797. [https://doi.org/10.1175/1520-0426\(1993\)010<0785:TTITAA>2.0.CO;2](https://doi.org/10.1175/1520-0426(1993)010<0785:TTITAA>2.0.CO;2)
- Enno, S.E., Briede, A., Valiukas, D., 2013. Climatology of thunderstorms in the Baltic countries, 1951–2000. *Theor Appl Climatol* 111, 309–325. <https://doi.org/10.1007/s00704-012-0666-2>
- Enno, S.-E., Post, P., Briede, A., Stankunaite, I., 2014. Long-term changes in the frequency of thunder days in the Baltic countries. *Boreal Environment Research* 19, 452–466.
- Enno, S.-E., Sugier, J., Alber, R., Seltzer, M., 2020. Lightning flash density in Europe based on 10 years of ATDnet data. *Atmospheric Research* 235, 104769. <https://doi.org/10.1016/j.atmosres.2019.104769>
- Hoeppe, P., 2016. Trends in weather related disasters – Consequences for insurers and society. *Weather and Climate Extremes, Observed and Projected (Longer-term) Changes in Weather and Climate Extremes* 11, 70–79. <https://doi.org/10.1016/j.wace.2015.10.002>
- Hu, J., Rosenfeld, D., Zrnica, D., Williams, E., Zhang, P., Snyder, J.C., Ryzhkov, A., Hashimshoni, E., Zhang, R., Weitz, R., 2019. Tracking and characterization of convective cells through their maturation into stratiform storm elements using polarimetric radar and lightning detection. *Atmospheric Research* 226, 192–207. <https://doi.org/10.1016/j.atmosres.2019.04.015>

- Huffman, G.J., Adler, R.F., Bolvin, D.T., Nelkin, E.J., 2010. The TRMM Multi-Satellite Precipitation Analysis (TMPA), in: Gebremichael, M., Hossain, F. (Eds.), *Satellite Rainfall Applications for Surface Hydrology*. Springer Netherlands, Dordrecht, pp. 3–22. https://doi.org/10.1007/978-90-481-2915-7_1
- Jenkinson, A.F., Collison, F.P., 1977. An initial climatology of gales over the North Sea. *Synoptic climatology branch memorandum* 62, 18.
- Johnson, J.T., MacKeen, P.L., Witt, A., Mitchell, E.D.W., Stumpf, G.J., Eilts, M.D., Thomas, K.W., 1998. The Storm Cell Identification and Tracking Algorithm: An Enhanced WSR-88D Algorithm. *Weather and Forecasting* 13, 263–276. [https://doi.org/10.1175/1520-0434\(1998\)013<0263:TSCIAT>2.0.CO;2](https://doi.org/10.1175/1520-0434(1998)013<0263:TSCIAT>2.0.CO;2)
- Kober, K., Tafferner, A., 2009. Tracking and Nowcasting of Convective Cells Using Remote Sensing Data from Radar and Satellite. *Meteorologische Zeitschrift* 1, 75–84.
- Kyznarová, H., Novák, P., 2009. CELLTRACK — Convective cell tracking algorithm and its use for deriving life cycle characteristics. *Atmospheric Research*, 4th European Conference on Severe Storms 93, 317–327. <https://doi.org/10.1016/j.atmosres.2008.09.019>
- Leon, D.C., French, J.R., Lasher-Trapp, S., Blyth, A.M., Abel, S.J., Ballard, S., Barrett, A., Bennett, L.J., Bower, K., Brooks, B., Brown, P., Charlton-Perez, C., Choullarton, T., Clark, P., Collier, C., Crosier, J., Cui, Z., Dey, S., Dufton, D., Eagle, C., Flynn, M.J., Gallagher, M., Halliwell, C., Hanley, K., Hawkness-Smith, L., Huang, Y., Kelly, G., Kitchen, M., Korolev, A., Lean, H., Liu, Z., Marsham, J., Moser, D., Nicol, J., Norton, E.G., Plummer, D., Price, J., Ricketts, H., Roberts, N., Rosenberg, P.D., Simonin, D., Taylor, J.W., Warren, R., Williams, P.I., Young, G., 2016. The Convective Precipitation Experiment (COPE): Investigating the Origins of Heavy Precipitation in the Southwestern United Kingdom. *Bulletin of the American Meteorological Society* 97, 1003–1020. <https://doi.org/10.1175/BAMS-D-14-00157.1>
- Lompar, M., Čurić, M., Romanic, D., 2017. Simulation of a severe convective storm using a numerical model with explicitly incorporated aerosols. *Atmospheric Research* 194, 164–177. <https://doi.org/10.1016/j.atmosres.2017.04.037>
- Mäkelä, A., Enno, S.-E., Haapalainen, J., 2014. Nordic Lightning Information System: Thunderstorm climate of Northern Europe for the period 2002–2011. *Atmospheric Research* 139, 46–61. <https://doi.org/10.1016/j.atmosres.2014.01.008>
- Nisi, L., Ambrosetti, P., Clementi, L., 2014. Nowcasting severe convection in the Alpine region: the COALITION approach. *Quarterly Journal of the Royal Meteorological Society* 140, 1684–1699. <https://doi.org/10.1002/qj.2249>
- Pohjola, H., Mäkelä, A., 2013. The comparison of GLD360 and EUCLID lightning location systems in Europe. *Atmospheric Research*, 6th European Conference on Severe Storms 2011. Palma de Mallorca, Spain 123, 117–128. <https://doi.org/10.1016/j.atmosres.2012.10.019>
- Pulkkinen, S., Chandrasekar, V., von Lerber, A., Harri, A.-M., 2020. Nowcasting of Convective Rainfall Using Volumetric Radar Observations. *IEEE Transactions on Geoscience and Remote Sensing* 58, 7845–7859. <https://doi.org/10.1109/TGRS.2020.2984594>
- Romero, R., Ramis, C., Homar, V., 2015. On the severe convective storm of 29 October 2013 in the Balearic Islands: observational and numerical study. *Quarterly Journal of the Royal Meteorological Society* 141, 1208–1222. <https://doi.org/10.1002/qj.2429>

- Saltikoff, E., Huuskonen, A., Hohti, H., Koistinen, J., Järvinen, H., 2010. Quality assurance in the FMI Doppler Weather Radar Network. *Boreal environ. res.* 15, 579–594.
- Taszarek, M., Allen, J.T., Púčik, T., Hoogewind, K.A., Brooks, H.E., 2020. Severe Convective Storms across Europe and the United States. Part II: ERA5 Environments Associated with Lightning, Large Hail, Severe Wind, and Tornadoes. *Journal of Climate* 33, 10263–10286. <https://doi.org/10.1175/JCLI-D-20-0346.1>
- Tuomi, T.J., Mäkelä, A., 2007. Salamahavainnot 2007-Lightning observations in Finland, 2007.
- Voormansik, T., Cremonini, R., Post, P., Moisseev, D., 2021a. Evaluation of the dual-polarization weather radar quantitative precipitation estimation using long-term datasets. *Hydrology and Earth System Sciences* 25, 1245–1258. <https://doi.org/10.5194/hess-25-1245-2021>
- Voormansik, T., Mürsepp, T., Post, P., 2021b. Climatology of convective storms in Estonia from radar data and severe convective environments. *Remote Sensing* [avaldamiseks vastu võetud].
- Voormansik, T., Rossi, P.J., Moisseev, D., Tanilsoo, T., Post, P., 2017. Thunderstorm hail and lightning detection parameters based on dual-polarization Doppler weather radar data. *Meteorological Applications* 24, 521–530. <https://doi.org/10.1002/met.1652>

Summary

Radar-based climatology of convective storms in Estonia

Convective storms are common in Estonia in the warm season. However, they have not been previously systematically studied in Estonia on the basis of remote sensing data. We analyse convective storm climatology in Estonia, using nine years of data from weather radar and atmospheric reanalysis. The investigated period covers the warm season (May-September) of the years 2010-2019. Data from 2017 was not used because of radar technical problems. The results are verified by lightning detector network cloud-to-ground lightning flash data. First, heavy precipitation areas are extracted from the radar reflectivity data based on a 35 dBZ threshold. Reflectivity threshold is increased and CAPE threshold introduced to eliminate non-convective cases. Convective storm is finally determined as an area with at least 51 dBZ reflectivity and 80 J/kg CAPE. Convective storm and lightning data correlate well on various temporal scales. Convective storms are most frequent in the afternoon around 3 - 4 p.m. local time. On a monthly scale the highest probability for a convective storm is in July whereas the probability for a cloud-to-ground lightning flash is highest in August. The number of storm days and thunderstorm days fluctuates greatly from year to year. On average the probability for a convective storm day during the warm season is 45% and for a thunderstorm day 54%. The prevailing airflow direction during convective storms was SW, while the highest probability for a convective storm occurs during SE airflow.

Tüüplahendused kaugseire lõimimiseks pideva metsakorralduse süsteemi

Mait Lang^{1,2}

¹ Eesti Maaülikool, metsandus- ja maaehitusinstituut, Kreutzwaldi 5, 51014 Tartu

² Tartu Ülikool, Tartu observatoorium, Tõravere, Nõo vald, 61602 Tartumaa

Kokkuvõte

Eestis on juba peaaegu kümme aastat avaandmetena kõigile tasuta kättesaadavad nii multispektraalsed satelliidipildid, ortofotod kui ka aerolidari mõõdistusandmed. Neis andmestikes sisalduv info metsaökosüsteeme kirjeldavate tunnuste kohta on üsna lihtsal viisil kasutatav pideva metsakorralduse süsteemis metsataksaatorite töö optimeerimiseks ning andmete ajakohasuse kontrollimiseks. Kirjeldatakse Eesti metsaomanike ning metsakorraldusfirmade jaoks sobivaid kaugseireandmete töötluse tüüplahendusi.

Võtmesõnad: kaugseire, pidev metsakorraldus, välitööde optimeerimine

Sissejuhatus

Metsamaa ja sellel paiknevate ökosüsteemide majandamine on keeruline valdkond, kus tuleb arvestada väga erinevate huvide ja eesmärkidega. Metsakorralduse eesmärk on leida optimaalseid lahendusi, et tagada maa omanikule püsiv ja pikaajaline tulu. Sõltuvalt omandi suuruselt, omaniku soovidest ja riigi poolt kehtestatud omandi kasutamise piirangutest koostatakse metsakorralduse käigus strateegiline ja taktikaline tegevuskava. Kõige lihtsamal juhul võivad need sisaldada ainult üht majandusotsust, mis on mitte midagi tegemine ehk maatüki või selle osa jätmine reservaadiks. Majanduskava koostamiseks ja uuendamiseks vajalikud andmed saadakse metsatakseerimise käigus, mille aluseks on Eestis alates 1960. aastate algusest olnud aerofotod. Aerofotode põhjal kontrolliti või tuvastati metsaeraldiste piirid (metsaeraldis on takseertunnuste poolt homogeenne metsaosa, mida kirjeldatakse väikseima majandusüksusena) ja hinnati enne välitöid ka puistu liigilist koosseisu, kõrgust ja kahjustusi. Välitöödel takseeriti neid tunnuseid, mida kaugseire abil metsa pealtvaates ei ole võimalik piisava täpsusega mõõta (Krigul, 1972; Vaus, 2005).

Metsatakseerimiseks tehtud kulutused ja töö peavad tagama andmed, millele tuginedes saab metsakorralduse tulemusena koostada omaniku jaoks kõige

optimaalsema majanduskava. Metsaökosüsteemides toimuvad pidevad muutused: mets kasvab, konkurentsitingimustes osa puid sureb, kohati tekib uuendus, aegajalt mõjutavad metsi mitmesuguse iseloomuga häiringud. Seetõttu on majanduskava alusandmeid vaja uuendada, et teha metsa majandamiseks taktikalisel ja operatiivsel tasemel parimad otsused. Hoolimata sensortehnika kiirest arengust ei suuda kaugseire paljude oluliste takseertunnuste hindamisel metsataksaatorit välitöödel täpsuses esialgu veel ületada. Aga nagu aerofotode kasutuselevõtt võimaldas metsataksaatoritel välitöödel keskenduda puistute eraldamise asemel takseertunnuste täpsemale mõõtmisele ja puistu struktuuri detailsemale kirjeldamisele, nii on ka tänased kaugseireandmed – multispektraalsed pildid, radarülesvõtted ja laserskaneerimisest tekkivad kolmemõõtmelised punktiparved – potentsiaalseks sisendiks pideva metsakorralduse süsteemile, milles metsataksaatorit kui kõige täpsemat „mõõtevahendit“ kasutatakse just nendes puistutes, mille jaoks andmebaasi kirje loomine või uuendamine majandusotsuste kavandamiseks vajalike tunnuste osas ei ole metsa kasvumudeli ja kaugseirest saadava info abil piisava täpsusega võimalik. Kaugseirele tuginevate optimeeritud lahenduste loomisele aitab kaasa maailmas üha enam juurduv avaandmete ideoloogia, mille tulemusena on keskmise ruumilahutusega (10–30 m) satelliidipilte võimalik vabalt alla laadida Euroopa Kosmoseagentuuri (ESA) kosmoseprogrammi Copernicus pildiarhiivist *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/>) ja USA Geoloogiateenistuse (USGS) pildiarhiivist GloVis (<https://glovis.usgs.gov>). Näiteks on radar-satelliidi Sentinel-1 SAR-andmete aegridade põhjal koostatud Euroopa metsade ning okaspuude osakaalu hinnangud (Dostálová jt, 2021). Ka Eestis on ortofotod ning aerolaserskaneerimise andmed kõigile soovijatele vabalt kasutamiseks antud (Maa-amet, 2021).

Avaandmete põhjal on Eestis suurte projektide raames tehtud metsaressurssi kirjeldav 10 m ruumilahutusega bioatlas (ForBio, 2021). Lang jt (2018) töötasid välja lahenduse puistute liigilise koosseisu hindamiseks multispektraalsete satelliidipiltide ja masinõppe abil. Keskkonnaagentuuri jaoks, kes viib Eestis läbi statistilist metsainventuuri, on loodud meetodika proovitükkidelt saadud välimõõtmisandmete kasutamiseks koos metsade kaugseireinfoga üle-eestiliste takseertunnuste kaartide loomiseks (Lang jt, 2020). Põhjalikult on uuritud aerolidarite andmete kasutamise võimalusi Eesti tüüpiliste metsade takseertunnuste hindamiseks (Arumäe, 2020). Käesolevas artiklis kirjeldatakse põhimõttelisi lahendusi metsade kaugseire avaandmete integreerimiseks metsainventuuri ja -korralduse süsteemi. Näited tuginevad põhimõtetele, mille järgi: 1) rakendus oleks realiseeritav üsna tavalisel lauaaalil, 2) algoritmi komponentides kasutatakse vabavara, 3) andmetöötlus on automatiseeritav kuni piirini, kus operaatori sekkumine annab oluliselt täpsema tulemuse, 4) konkreetsete lahendused sobivad ka väikestele ja keskmise suurusega ettevõtetele ja 5) süsteemi kuuluvate mudelite jaoks vajalike empiiriliste andmete kogumine toimub nagunii tavalise metsatakseerimise käigus.

Andmed ja tüüplahendused


Aerolidari andmete töötlemise tüüplahendus

Aerolaserskanerimist (ALS) on Eestis teinud Maa-amet alates 2008. aastast (Maa-amet, 2021). Lennukil oleva lidari ehk laserskanneri väljasaadatud laserimpulsside peegeldumiskohtade registreerimisel tekkiv punktipilv kajastab maapinna kuju ning maatükil kasvava taimestiku ruumilisi omadusi. Väljakujunenud rutiini kohaselt tehakse mõõdistustöid igal aastal kahes etapis – kevadel enne puude lehtimist madalamalt ning suvel metsakorralduse tarbeks aerofotografeerimise käigus kõrgemalt. Laserkiir on metsa võrastiku ülapiirile jõudes u 0,4–0,5 m läbimõõduga. Punktihedus on vanematel andmetel 0,15 m² kuni 0,5 m² ja praegu 0,8 m² kuni 2,0 m² ning asulate kohal madallennul isegi kuni 30 m². Tavalise 10 m raadiusega proovitüki kohta on seega praegu suvistes ALS-andmetes keskmiselt 314×0,8≅250 peegeldust, millest puistu struktuuri kirjeldamiseks näiteks 70%-lise liituse korral leidub võrastikus eeldatavalt 170 peegeldust. ALS-andmeid võib analüüsida nii puistute kaupa, lõigates ruumiandmetest eraldiste piiride järgi välja vastavad peegeldused, või siis puistupiiride puudumisel saab kasutada kunstlikke 10–30 m vaatlusühikuid ehk piksleid (pindala 100–900 m²), mille kokkuliitmisel saadakse pidev kogu ala kattev rasterkaart.

Taimkatte struktuuritunnuste hindamiseks on tarvis peegelduskohtade kõrgused esmalt maapinna suhtes normeerida. Selleks kasutatakse maapinna digitaalset kõrgusmudelit (DEM), mida on Eesti kohta võimalik Maa-ameti kodulehelt alla laadida (joonis 1). Maapinna kõrgusmudel ajas oluliselt ei muutu, välja arvatud kaevanduste alal ning mujal, kus pinnast teisaldetakse. Järgmise sammuna (joonis 1) tehakse ALS-andmetest päringud ning arvutatakse piksletele, eraldistele ning proovitükkidele nende alalt välja lõigatud punktipilvi kirjeldavad meetrikud. Meetrikud kirjeldavad punktipilve struktuuri, andes infot peegelduste kõrgusjaotuse ning ruumis paiknemise kohta.

Punktipilvede meetrikute hulgast valitakse välja sellised, mis on seotud näiteks metsa kõrguse, võrastiku tiheduse ja rindelisusega. Meetrikud võib kohe kanda takseerandmete baasis olevasse lisatabelisse puistute kirjelduste juurde. Oluliseks sõlmpunktiks metsakorralduses tavapäraselt kasutatavate tunnuste ning ALS-meetrikute vahel on mudelid. Näiteks punktipilve kõrgusjaotuse 80-protsentiil H_{p80} on väga tugevasti korreleeritud metsatakseerimisel saadava puistu kõrgusega (H). Aga tulenevalt punktipilvede lokaalsetest omapäradest ja konkreetse mõõtmisandmestiku kogumisel kasutatud seadistusest ei ole H ja H_{p80} seos täpselt 1 : 1, vaid lähendatav lineaarse mudeliga $H = a + b \cdot H_{p80}$, kus a ja b on mudeli parameetrid, mille väärtuseid võib leida kirjandusest. Kuid ideaalsel juhul tuleks need lähendada olemasoleva empiirilise andmestiku põhjal (takseerikirjeldused, proovitükkidel tehtud mõõtmised). Puistu tüvemahu hindamiseks on vaja mudeleid, kus on ka puistu tihedust kirjeldavad argumendid.

Maa-ameti rutiinse mõõdistamise kava järgi saadakse suvised ALS-andmed sama koha kohta iga nelja aasta järel. Aegrea tihendamiseks võib kasutada ka

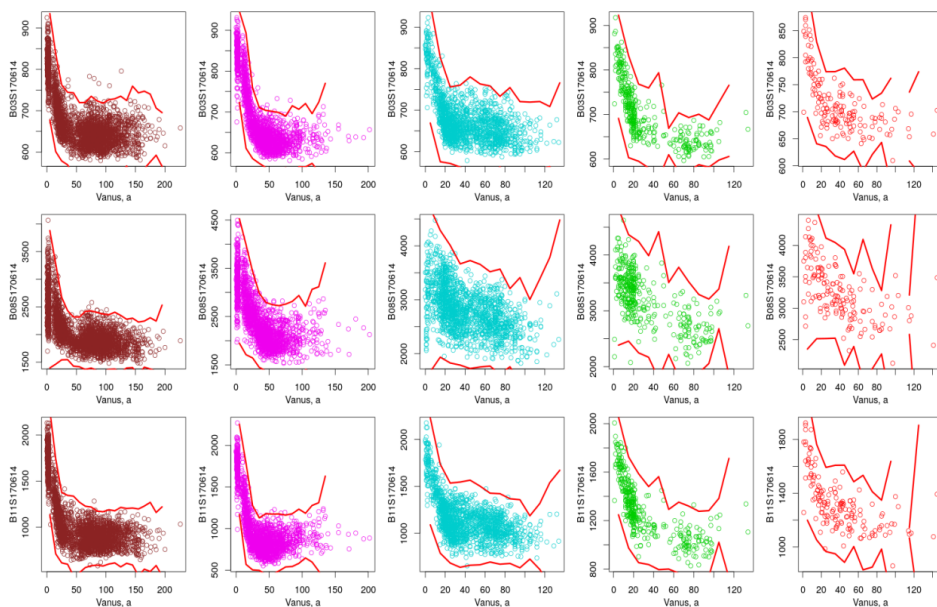


Joonis 1. Aerolidari andmete töötlemise tüüpskeem. Tulemuseks on vastavalt vajadusele info puistute takseerikirjeldustes või rasterkaartidena. Viirutatud plokid ja kursiivkirjas esitatud toimingud on soovituslikud.

kevadiste mõõdistuslendude andmeid, kuid sel puhul tuleb arvestada, et lehtede hulk (lehepinnaindeks) mõjutab oluliselt laserimpulsi läbimineku võrastikust ning kevadel lehtedeta ajal tehtud ALS-mõõdistuse andmetes asuvad peegelduskohad võrastikus süstemaatiliselt mingil määral madalamal. See nihe sõltub puistu liigilisest koosseisust ning võrastiku struktuurist. Teades varasematest mõõtmistest juba puistu liigilise koosseisu andmeid ning kevadist lehtede pindala kasvufunktsiooni või hinnangut, on teatud piirini võimalik rakendada korrektsioone, kuid kevadiste ALS-andmete põhjal saadavad takseertunnuste hinnangud on ikkagi suurema määramatusega. Kindlasti tuleb arvestada, et ALS-punktipilvede andmestik on juhusliku protsessi tulemus ja seega jääb meetrikutesse alati mingi hajuvus. See kandub edasi ka takseertunnuste hinnangutesse ning vanemate väheviljakatel muldadel kasvavate metsade puhul, kus nelja aastaga muutub kõrgus vähe, võib hõredate ALS-punktipilvede meetrikute määramatus ületada puistu paarikümnesentimeetrise tegeliku kõrguskasvu. Heade mudelite korral õnnestub hõredatest ALS-avaandmetest puistute kõrgust prognoosida 1–2 m jääkveega.

Multispektraalsete keskmise ruumilahutusega andmete töötlemise tüüplahendus

Taimkatte seireks sobivate keskmise ruumilahutusega multispektraalsete satelliidipiltide aegrida algab 1980. aastate esimesest poolest, kui saadeti orbiidile Landsat-4 pardal skanner Thematic Mapper (TM). Sellele järgnes Landsat-5 TM ning SPOT-seeria satelliitidel olevad skannerid HRV. Praegu saadakse Eesti alalt avaandmetena allalaaditavaid ülevõtteid iga kolme kuni nelja päeva järel, sest Landsat-8 ning Sentinel-2A/B satelliitide orbiidid poolusele lähenedes koonduvad ning pildid on suure külgmise ülekattega. Spektri optilises osas (400–2500 nm) töötavate skannerite (sh Landsat-8 OLI ja Sentinel-2 MSI) ülevõtetele avaldavad mõju pilved ja pilvevarjud ning nendega kaetud ala on üldiselt kasutuskõlbmatu. Siiski on kogemused näidanud, et tervet Eestit katva pilvevaba pildimosaiki saab tavaliselt iga kahe või kolme kuuga. Võrreldes ALS-andmete kaheaastase uuendusintervalliga on seega multispektraalsete piltide uuenemise sagedus märksa suurem. Multispektraalsete satelliidipiltide sisuks on sensori suunas peegeldunud päikesekiirus. Erinevalt ALS-punktipilvedest ei sisalda Landsat-8 OLI või Sentinel-2 MSI pildid otseselt metsa kõrguse ega võrastiku tiheduse infot. Kui arvutame mõnel ülevõttel olevate metsaeraldiste pikslite keskvärtused pildi spektraalsete kanalite kaupa ja vaatame saadud spektraalsete heleduste sõltuvust puistute vanusest, siis kõige heledamad on noored puistud ja lagedad alad (joonis 2). Puistu spektraalne heledus tavaliselt




Joonis 2. Puistute vanuse ja spektraalse heleduse tüüpilised seosed. Ridades ülalt alates on Sentinel-2 MSI 2014. aasta 17. juuni ülevõtte roheline, NIR- ja SWIR-kanal, veergudes on männikud, kuusikud, kaasikud, haavikud ja teised puistud. Joontega on tähistatud kriitiline piir seosest hälbivate erindite tuvastamiseks.

kahaneb kuni kolmekümne aasta vanuseni ja jääb siis häiringute puudumisel üsna vähemuutuvaks (Nilson ja Peterson, 1994).

Multispektraalsete satelliidipiltide kasutamiseelse töötamise eesmärkide hulka kuuluvad visuaalne kontroll, kaardiprojektsiooni teisendamine, pilvemaskide loomine ning tihti ka atmosfäärikorrektsiooni tegemine, et saada metsa heleduse mudeli simulatsiooni tulemusega otseselt võrreldavad väärtused (joonis 3). Puistute spektraalsed signatuurid ja nende muutused ajas on seotud võrastiku ning metsaökosüsteemi alumiste rinate struktuuriga ning neis toimivate protsessidega. Seosed tavapärase metsa takseertunnustega on korrelatiivsed ja tihti mittelineaarsed. Esimene meetod sellise info kasutamiseks metsade takseerimisel on analüüsida näiteks puistute vanuse või tüvemahu seoseid spektraalsete heledustega (joonis 2). Eristades puistud enamuspuuliigi järgi, saame sellise lihtsa analüüsi põhjal kiiresti ja isegi automatiseeritult leida need eraldised, mis üldisest seosest oluliselt hälbivad.

Siiski muutuvad puistute teiste takseertunnuste väärtused ka sama vanuse või tüvemahu juures Eesti puistute suurt liigilist ja struktuurset varieerumist arvestades üsna laiaades vahemikes. Mitme tunnuse koosarvestamiseks sobib hästi statistiline metsa heleduse mudel SFRM (Kuusk ja Lang, 2020). SFRM sisendiks



Joonis 3. Multispektraalsete keskmise ruumilahutusega satelliidipiltide töötlemise tüüpskeem. Tulemuseks on nimekiri välitöödel kontrollimist vajavatest puistustest ning puistute takseertunnuste prognoosid rasterkaartidena.

on tavaline metsa takseerikirjeldus, mudeli rakendamine ei vaja praktiliselt üldse inimese sekkumist, vajab arvutusteks vähem ressursi kui kontoritarkvara ja selle kasutamine on peaaegu täies ulatuses automatiseeritav. Samuti on automatiseeritav mudeliga saadud ja satelliidipildidelt mõõdetud metsa spektraalsete signatuuride võrdlus ja selle tulemusena kontrollimist vajavate puistute nimekirja koostamine. Kui puistu takseertunnused looduses vastavad takseerandmete baasis salvestatutele ning puistus ei ole suurt sisemist grupilisust või variatsiooni, siis on SFRM-mudeliga saadud spektraalsed signatuurid sarnased satelliidipildilt mõõdetutega. Suured erinevused viitavad takseerikirjelduste andmebaasi info ja reaalse situatsiooni erinevusele ja on aluseks välitööde eelisinimekirja koostamisel. Lisaks takseertunnuste ja spektraalsete heleduste analüüsile on tihti palju kasu ka satelliidipiltide aegridades (näiteks viie viimase aasta kesksuvised ülesvõtted) olevast heleduste muutuste signaalist. Muutuste kaardi koostamiseks on olemas elementaarsed ruumianalüüsi vahendid ja satelliidipiltide puhul sobib väga hästi (järjestikuste) piltide aritmeetiline lahutamine.

Juhul kui majandusüksusel üldse puuduvad varasemad takseerikirjeldused (mahajäetud põllumaadele ja looduslikele rohumaadele tekkinud puistud) või pole need enam üldse ajakohased, siis on võimalik esialgsete takseerikirjelduste koostamiseks kasutada masinõppemeetodeid koos lisainfoga (näiteks mullakaart) (joonis 3). Ka see protsess on automatiseeritav, kuid parimad tulemused saadakse nii-öelda targa kasutaja osalusel. Kasutaja ülesandeks on masinõppe treeningandmete kvaliteedi hindamine, informatiivsete tunnuste valiku kinnitamine ning mudeli seadistuse optimeerimine. Masinõppemudeliga plokk sobib neile kasutajatele, kelle andmebaasis on piisaval hulgal värske takseerikirjeldusega puistute näidiseid (mitmed tuhanded eraldised). Masinõppemudelite kasutamine annab aga teisalt ka võimaluse prognoosida metsaökosüsteemi kõiki tunnuseid, millel on eeldatavalt mingi seos kaugseireinfo või muude olemasolevate andmetega ja mida on hinnatud või mõõdetud näidiste valimis olevatel eraldistel.

Arutelu ja edasivaade

Käesolevas ülevaates kirjeldatud lahendused põhinevad avaandmetel ning vaba-
varal. See tähendab, et kasutaja ei pea tegema kulutusi kaugseireinfo ostmisele ega analüüsitarkvara põhikomponentide soetamisele. Loomulikult on iga juba olemasolev infosüsteem erinevate võimalustega ning metsade kaugseirel põhineva inventeerimise toe loimimine konkreetse andmeohjesüsteemiga nõuab veidi tarkvaraarendust, mille keerukus sõltub soovitud automatiseerituse astmest. Eestis tehtud pikaajalised uuringud metsade kaugseire alal tagavad samas piisava oskusteabe, et avaandmeid tõhusalt metsade seireks saaks kasutada.

Omamoodi lisandväärtust metsatakseerimisel pakub kaugseireandmes-
tik metsaeraldise sisemise varieerumise kirjeldamiseks. Tüüpiliselt piiritletakse
metsaeraldised selliselt, et eraldisele jääva puistu keskmine takseerikirjeldus oleks

kasutatav majandusotsuste tegemiseks. Varieeruva struktuuriga puistute kohta tehakse andmebaasi mäрге, kuid variatsiooni üldiselt metsatakseerimisel kvantitatiivselt ei kirjeldata. Ruumiandmete töötlemise vahendid geoinfosüsteemides võimaldavad liita sarnased naaberpikslid segmentideks ning seejärel on näiteks võimalik hinnata eraldise piiresse jäävate segmentide arvu ning võrrelda segmentide takseertunnuste hinnanguid. Kui näiteks puistu kõrgus või tihedus eraldise sees oluliselt varieerub, siis tekib eraldise sisse ka mitu segmenti. Teisalt võib segmenteerimise tulemusi kasutada ka eraldiste automaatse moodustamise ühe etapina.

Esitatud tüüplahendused põhinevad prototüüpidel, mille edasiarendatud versioonid on Tartu observatooriumi kaasabil kasutusele võtnud Riigimetsa Majandamise Keskus (RMK) ja Keskkonnaagentuuri metsaosakond. Tüüplahenduste puhul saab alustada kaugseireandmete esmase töötluste plokkidest ning hiljem vastavalt soovidele ja võimalustele lõimida juurde keerulisemaid lisaprotseduure. Kõige olulisem on aga esmalt üle vaadata praegu kasutusel olev metsakorralduse ja metsade andmete haldamise infosüsteem ja analüüsida võimalusi metsataksaatorite rutiinse töö optimeerimiseks kaugseire avaandmetele tuginedes.

Tänuavaldus

Metsade kaugseirel põhinevate inventeerimislahenduste arendamist on toetanud Riigimetsa Majandamise Keskus ja Euroopa Regionaalarengu Fond riikliku programmi „Olemasolevate ja uute infosüsteemide nutikas arendamine (sh analüüs)“ raames. Eesti Maa-amet on teinud kõigile kättesaadavaks lidarmõõdistuste andmed. Landsat-8 OLI ja Sentinel-2 MSI pildid on avalikuks kasutamiseks andnud USA Geoloogiateenistus ja EL Copernicuse programm.

Viidatud kirjandus

- Arumäe, T., 2020. Puistute takseertunnuste hindamine aerolidari mõõtmisandmete põhjal hemiboreaalsetes metsades. Väitekirj. Eesti Maaülikool. 63 lk.
- Dostálová, A., Lang, M., Ivanovs, J., Waser, L.T., Wagner, W. 2021. European Wide Forest Classification Based on Sentinel-1 Data. *Remote Sensing*, 13, 337. <https://doi.org/10.3390/rs13030337>.
- ForBio. 2021. Interreg Baltic Sea Region project: Baltic ForBio. (<https://projects.interreg-baltic.eu/projects/baltic-forbio-127.html>).
- Krigul, T. 1972. Metsatakseerimine. Tallinn, Valgus. 359 lk.
- Kuusk, A., Lang, M. 2020. Integration of statistical forest reflectance model and Sentinel-2 MSI images into a continuous forest inventory system. *Baltic Forestry*, 26(2), article id467. <https://doi.org/10.46490/BF467>.

- Lang, M., Kaha, M., Laarmann, D., Sims, A. 2018. Construction of tree species composition map of Estonia using multispectral satellite images, soil map and a random forest algorithm. – *Forestry Studies | Metsanduslikud Uurimused* 68, 5–24.
- Lang, M., Sims, A., Pärna, K., Kangro, R., Möls, M., Möistus, M., Kiviste, A., Tee, M., Vajakas, T., Rennel, M. 2020. Remote-sensing support for the Estonian National Forest Inventory, facilitating the construction of maps for forest height, standing-wood volume, and tree species composition. – *Forestry Studies | Metsanduslikud Uurimused* 73, 77–97.
- Maa-amet. 2021. Ortofotod aastate ja objektide kaupa. [<https://geoportaal.maaamet.ee/est/Andmed-ja-kaardid/Ortofotod/Ortofotod-aastate-ja-objektide-kaupa-p27.html>].
- Nilson, T., Peterson, U. 1994. Age dependence of forest reflectance – analysis of main driving factors. *Remote Sensing of Environment*, 48, 319–331.
- Vaus, M. 2005. Metsatakseerimine. Tartu, OÜ Halo kirjastus. 178 lk.

Summary

Generalized solutions for integrating remote sensing data into continuous forest inventory systems

Remote sensing data from medium spatial resolution multispectral satellite sensors like Landsat-8 OLI and Sentinel-2 MSI, and airborne laser scanning data from the Estonian Land Board have been available for general public use already for about 10 years. Here are introduced two typical schemas to integrate remote sensing data into continuous forest inventory systems. The solutions are based on open data and free software components, meaning that initial investments from the user side are small. The overall aim for using remote sensing data for forest ecosystem monitoring is to optimize fieldwork of forest inventory staff and update forest inventory database records.

Kaugseiremeetoditega metsaressursi hindamise täpsuse analüüs

Allan Sims

Eesti Maaülikool, metsandus- ja maaehitusinstituut, Kreutzwaldi 5, 51014 Tartu

Kokkuvõte

Kaugseire andmed on erineva resolutsiooniga ning seetõttu nende mõõtemääramatus varieerub. Käesolevas töös on analüüsitud 10-meetrise pikslite jagunemisega seotud mõju metsaressursi hinnangute täpsusele. Testimiseks kasutati 100 km² suurust ala Järvelja Öppe- ja Katsemetskonnas ning selle ümbruses (Eesti põhikaardi 1 : 20 000 ruut number 54.69), millest metsaeraldistega oli kaetud 67,2 km².

Pikslitest oli täielikult eraldiste sees 76,6% ja mitme eraldise vahel oli jagunenud 23,4%. Pikslipõhiselt arvatud laserskaneerimise punktandmestiku meetrikutest prognoositud keskmine hektaritagavara oli täielikult eraldiste sees olevatel pikslitel 319,9 tm ning eraldiste piiridel olevate pikslite keskmine hektaritagavara oli 280,4 tm ehk 12,3% erinev. Eraldise keskmise hektaritagavaraga kaalutud keskmiseks hektaritagavaraks tuli samadel pikslitel 321,4 ehk ainult 0,4% erinev. Seega, samade andmete põhjal, kuid erinevate meetoditega arvatud kogutagavara võib erineda ca 3%. Võrdluseks, statistilise metsainventuuri tagavarahinnangu suhteliseks veaks on arvatud 1,1%.

Eraldisesisestel pikslitel oli multispektraalse Sentinel-2 satelliidipildi alusel Random Foresti klassifitseerimismeetodiga leitud enamuspoolsi kapa-kordaja õpetus- ja testandmete puhul ligilähedane, vastavalt 0,484 ja 0,499, ning mudeli üldine täpsus vastavalt 0,726 ja 0,736, aga eraldise piiril olevatel pikslitel olid need statistikud ainult 0,282 ja 0,602.

Võtmesõnad: kaugseire, mõõtemääramatus

Sissejuhatus

Metsaressursi pikaajalise kasutamise optimeerimine eeldab selle kohta täpse info olemasolu. Lisaks ajamahukatele maapealsetele mõõtmistele on andmete kogumiseks võetud kasutusele ka kaugseire meetodid. Traditsioonilise metsakorralduse käigus takseeritakse metsad üle iga 10 aasta järel ning metsa kasutamise otsused tehakse

järgneva 10 aasta kohta. Infoajastule kohaselt on praeguseks metsade inventeerimise praktika muutunud ning infot muutunud metsaosade kohta uuendatakse jooksvalt, mis võimaldab jooksvalt teha ka täiendavaid analüüse metsade kasutamise kohta.

Metsaressursi kohta kogutud infot kasutatakse eri tasanditel – metsaomaniku oma metsaosade majandamisest kuni üleriigilise metsanduspoliitika koostamiseni. Info kasutamine eri tasemetel eeldab ka erineva täpsusega infot, mistõttu on vaja valida sobivad meetodid, kuidas andmeid kogutakse. Metsaomanik, kelle metsaomand on väike, teab parimal juhul peast iga oma puud ning lähtub oma otsustes sellest. Alla kahe hektari suuruste alade kohta ei nõuta isegi metsa inventeerimise andmeid (Metsaseadus, 2006). Samas riiklikul tasemel ei ole üksiku puu infoga midagi teha ning isegi eraldise tasemel info on liiga detailne.

Tavametsakorralduses esitatakse andmed eraldisepõhiselt, kusjuures vektorkaartina on eraldatud metsaosa, millele on takseeritud seda ala kirjeldavad üldistatud (keskmised) tunnused. Kaugseirel põhinevad andmed esitatakse valdavalt rasterkaartidena (pikslipõhised puuliigi, tagavara ja metsa kõrguse kaardid). Nende kahe meetodi peamiseks erinevuseks on ala, mille kohta kirjeldus antakse.

Vektorkaardil on ala piiritletud arvestades looduslikke piire. Rasterkaardil on kindla suurusega piksel. Esimesel juhul on üldiselt iga puu kindlas eraldises. Looduses ei paikne puud korrapäraselt ning on erineva suurusega, mistõttu rasterkaardi puhul võib üks puu ulatuda mitme piksli alla. Väiksemate pikslite ja suuremate häilude puhul ei pruugi iga piksli all isegi puid olla. Nii tavametsakorralduse kui ka rasterkaartide puhul kirjeldatakse ala keskmisi tunnused.

Andmete täpsuse puhul on oluline, milleks neid kasutatakse. Kui metsaomanikul on vaja teha oma otsused ühe eraldise põhjal, siis eraldise piiritlemise täpsusel ei ole nii suurt mõju võrreldes sellega, kui mingi piirkonna kohta on vaja anda ülepinnaalne ülevaade. Sellisel juhul hakkab mõju avaldama piiritlemine.

Nii vektor- kui ka rasterkaartide puhul avaldab tulemustele mõju piiritlemise mõõtemääramatus. Selle teeb keerukamaks ka metsade mitmekesisus ning looduslikult ebakorrapärased piirid. Mõõtemääramatuse muudab suuremaks ka metsa piiri defineerimise raskus, kuna see ei ole looduslikult selge piir, vaid ülemineku-ala ühelt maakasutuse kategoorialt teisele.

Käesoleva töö eesmärk on analüüsida Järvelja Õppe- ja Katsemetskonna ning selle ümbruse alalt valitud testala alusel metsa ja eraldise piiritlemise mõju metsaressursi hinnangute täpsusele.

Materjal ja meetodika

Töös on kasutatud Järvelja Õppe- ja Katsemetskonnast ning selle ümbrusest valitud 100 km² suurust testala (Eesti põhikaardi 1 : 20 000 ruut nr 54.69) (joonis 1). Võrdluseks on kasutatud selle ala kohta metsaregistris (Metsaressursi, 2017) olevat metsakorralduse vektorkaarti.




Joonis 1. Testala (roheline taust, tumedus sõltub 80-protsentiilist) ja sellel paiknevate metsaeraldiste piirid.

Tabel 1. Eri aastatel inventeeritud alade pindala

Inventeerimise aasta	Pindala (ha)
2011	1303,6
2012	6,1
2013	197,8
2014	701,6
2015	1027,9
2016	748,7
2017	895,6
2018	835,2
2019	392,3
2020	379,3
2021	231,4

Metsade inventeerimine on testalal tehtud aastatel 2011–2021. Aastati on see varieerunud, kuna inventeeritud on eraldisepõhiselt (tabel 1). Selle perioodi jooksul on üle mõõdetud neid alasid, kus on toimunud majandamine. Seetõttu on inventeerimisandmed üldiselt ajakohased ning peamiselt on erinevused reaalistest tingimustest tingitud ainult metsade kasvust. Kokku on testalal 4607 metsaeraldist.



Joonis 2. Eraldise piirid (sinine joon) koos pikslite piiridega (punased jooned). Taustal Maa-ameti metsanduslik ortofoto (Maa-amet, 2018).

Testalale moodustati 10×10 m pikslite alusel vektorkaart, mille polügoonid lõigati täiendavalt metsaeraldiste piiride järgi. Selle põhjal on edaspidi andmestik jaotatud kaheks – pikslid, mis on täielikult eraldise sees, ja pikslid, mis on jaotatud mitme eraldise vahel (joonis 2).

Kaugeire andmetest on töös kasutatud aerolaserskaneerimise ja multispektraalseid satelliidipiltide andmeid.

Töös kasutatud laserskaneerimise punktandmestik on Maa-ameti 2017. aasta suvise laserskaneerimise punktandmestik (Maa-amet, 2018). Keskmiselt oli selles punktandmestikus esimesi peegeldusi $0,66$ punkti / m^2 ning kõiki peegeldusi $1,10$ punkti / m^2 .

Laserskaneerimise punktandmete töötlemiseks kasutati vabavaralist tarkvara FUSION (McGaughey, 2014). Punktandmestik normeeriti maapinna mudeli

alusel ning 10 × 10 m pikslite kaupa arvutati katvushinnang ja kõrgusjaotuse 80-protsentiil.

Hektaritagavara tulemuste testimiseks kasutati ühesugust mudelit kõikidele pikslitele:

$$V = \left(1,6494 * (H_{p80})^{1,7239}\right) * CC^{0,1026} ,$$

kus V on hektaritagavara (tm/ha), H_{p80} on kõrgusjaotuse 80-protsentiil ja CC on katvushinnang.

Satelliidipiltide andmetest kasutati Sentinel-2 *MultiSpectral Instrument*'i (MSI) pilte, mille pildistamise aeg oli 31.05.2020.

Satelliidipiltide analüüsimiseks kasutati Random Foresti (Breiman, 2001) klassifitseerimise meetodit statistikaprogrammiga R (R Core Team, 2021). Sisendi kasutati ainult satelliidipiltide andmeid (kanalid B02, B03, B04 ja B08), et testida antud andmestiku erinevust.

Selleks jaotati andmestik kolmeks:

- täielikult eraldise sees olevatest pikslitest
 - õpetusandmed (50%),
 - testandmed (50%),
- mitme eraldise vahel jagunenud pikslite andmed.


Kõikide andmestike puhul kasutati ainult nende eraldiste andmeid, millel metsaregistri järgi oli enamuspuuliik kas mänd, kuusk, kask või haab. Teisi eraldisi oli liialt vähe ning klassifitseerimise täpsuse analüüsi võis mõjutada pigem andmete vähesus kui sisendandmete varieeruvus. Iga grupi puhul arvutati välja kaks statistikut: kapa-kordaja ja mudeli üldine täpsus.

Tulemused

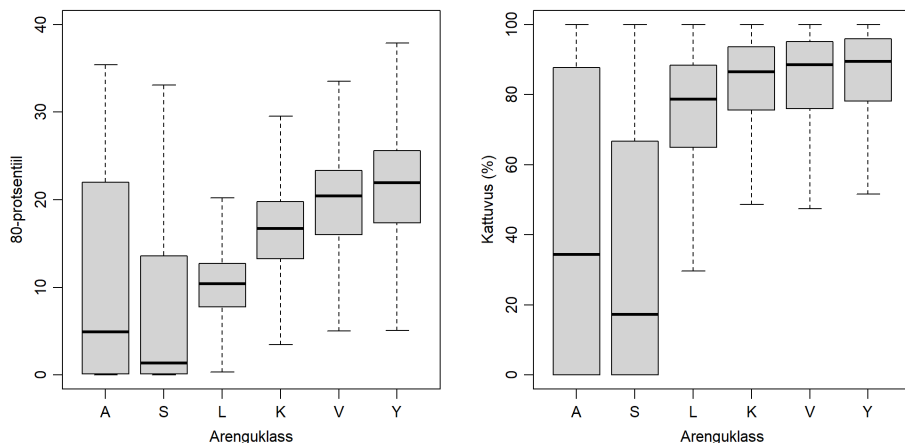
Testalal olevate eraldiste kogupindala on 67,2 ruutkilomeetrit, mis moodustab eraldistega täielikult või osaliselt kattuvate pikslitega alast 96,4%. Pikslid, mis on täielikult eraldise sees, moodustavad 76,6% alast ning 23,4% pikslitest on jaotunud mitme eraldise vahel või on osa pikslist, mis on osaliselt metsast väljaspool.

Eraldise sees varieeruvad pikslitele arvatud punktandmestiku meetrikud ja satelliidipiltide väärtused. Igale eraldisele arvutati (kasutades ainult neid piksleid, mis olid täielikult eraldise sees) punktandmestiku meetrikute standardhälbed (joonis 3). Esineb üksikuid eraldisi, millel on standardhälve väga suur, mis on tingitud kahest peamisest põhjusest:

- 1) lagedatel ja selgusetu aladel esinevatest üksikutest seemnepuudest, mille kõrgus on oluliselt kõrgem kui eraldise keskmine kõrgus (joonis 4);
- 2) eraldise piiritlemise täpsusest, mistõttu on eraldise sisse arvestatud ka pikslid, mis asuvad naabereraldises ning mille kõrgus ja liitus on oluliselt erinevad.



Joonis 3. 80-protsentiilide ja katvushinnangute standardhälvete histogramm.



Joonis 4. Lidari meetrikute jagunemine arenguklasside kaupa.

Kõrgusjaotuse 80-protsentiili standardhälbe mood on 1,86 m ja katvushinnangu mood on 9,17%.

Punktandmestiku meetrikud sõltuvad metsa arenguklassidest (joonis 4). Vanemates arenguklassides (L – latimets, K – keskealine mets, V – valmis mets, Y – küps mets) on kõrgusjaotuse 80-protsentiil suurem, aga nooremates (A – lage ala, S – selgusetu ala) on see varieeruvam. Lagedad ja selgusetu alad on lageraiejärgsed alad, kuhu on jäetud seemnepuid, mis mõjutavad oluliselt varieeruvust.

Täispikslite alusel saadud keskmine hektaritagavara on testalal 319,9 tm/ha. Võrreldes kahte erinevat meetodit:

- 1) iga eraldise piiril olevat pikslit käsitletakse kui tervikut ning punktandmestiku meetrikuid kasutatakse nii, nagu need arvutati;

- 2) igale eraldisele arvutati keskmine hektaritagavara arvestades täielikult eraldises olevaid piksleid ning piiril olevaid pikslid kaaluti vastavalt pindalale, mis paiknes eraldises.

Osaliste pikslite alusel on keskmine hektaritagavara 280,7 tm/ha ehk 12,3% väiksem täispikslite alusel arvutatud keskmisest. Arvutades igale jaotatud pikslile selle kaalutud keskmise tagavara arvestades pindala, mis jääb konkreetseesse eraldisse sisse, ning antud eraldise keskmist hektaritagavara, siis on arvutatud pikslite keskmine hektaritagavara 321,5 tm/ha ehk tulemus erineb ainult 0,4% täielikult eraldises olevatest pikslitest. Arvutades tulemuse kogu pindalale, siis on esimese meetodiga arvutatud kogutagavara 2,088 miljonit tihumeetrit ja teise meetodiga 2,152 miljonit tihumeetrit ehk tulemus erineb 3%.

Võrdluseks: statistilise metsainventuuri puhul, mis on üleriigiline proovitükidel põhinev meetod, on hinnatud tagavara suhteliseks veaks 1,1% (Valgepea jt, 2020). Kuna metsaressursist soovitakse saada ülevaateid igal aastal, siis aastatevaheliste muutuste hindamiseks on oluline saada hinnang võimalikult väikese määramatusega.

Satelliidipilti andmete alusel koostatud mudeli kapa-kordaja on 0,484 ja üldine täpsus on 0,726 ning testandmetest saadud kapa-kordaja on 0,499 ja üldine täpsus on 0,736. Piiril asuvate pikslite puhul on kapa-kordaja 0,282 ja üldine täpsus on 0,602.

Arutelu

Üldistatud tulemuste saamisel on oluline erinevus, kas andmetes on sees ainult juhuslik viga või ka süstemaatiline viga. Juhusliku vea korral vead tasanduvad ning üldistatud tulemus on objektiivne. Kui andmetes on sees süstemaatiline viga, siis ei ole üldistatud tulemus enam objektiivne.

Rasterkaartide puhul tuleb arvestada fragmenteeritud maastikuga, mille puhul pikslite järgi olev piir ei kattu looduses oleva piiriga. Sellest lähtuvalt ei pruugi sõltumatult kogutud kaugeireandmed omavahel kooskõlas olla, mistõttu võivad sisse tulla süstemaatilised vead. Edasine sõltub juba sellest, kuidas neid andmeid kasutatakse ning kas tekkiv süstemaatiline viga jõuab ka üldistamisse.

Üheks võimalikuks süstemaatilise vea tekke kohaks on laserskaneerimise punktandmestikust sõltumatult arvutatud katvushinnangu ja kõrgusjaotuse protsentiil. Esimese puhul kasutatakse kõiki peegeldusi ja teise puhul ainult etteantud nivoost kõrgemal olevate objektide peegeldusi. Nii tekib olukord, kus vähesed kõrged puud mõjutavad piksli ulatuses kõrguse protsentiili arvutamist ning tihe madalam rinne mõjutab katvust. Mudeli sisendid on sellisel juhul sarnased tiheda ja kõrge metsa punktandmestiku meetrikutega. Sellised olukorrad võivad tekkida hiljutistel lageraielankidel, kuhu on jäetud seemnepuud ning nende alla on tekkinud juba mitme meetri kõrgune uus metsapõlv. Samuti on see pikslitel, mis on

jagunenud mitme eraldise vahel – kui pikslist jääb *ca* 20% kõrge metsa sisse, siis 80-protsentiil on antud eraldise järgi ning ülejäänud piksel on madalas ja tihedas eraldises, mis annab tiheda katvushinnangu.

Satelliidiandmete kasutamisel puuliikide tuvastamiseks tekib eraldise piiridel samuti küsimus, millise eraldise järgi puuliik on tegelikult prognoositud. Üksiku eraldise majandamisele see olulist mõju ei avalda, kuna eraldiste piiri kaardistamise täpsuseks on metsa korraldamise juhendi (MKJ, 2009) alusel 10 meetrit, aga kui koostada piirkondlikku ülevaadet pikslite grupeerimise alusel, siis on oluline, kas konkreetse piksli all on sama koha puuliik, tagavara, kõrgus vms. Kui need on omavahel nihkes, siis on ka tulemus veaga. Kuna piiripealsete pikslite osakaal on maastikul väga suur (*ca* 25%), siis avaldab see olulist mõju piirkondlikule metsastatistikale.

Piirkondliku statistika kokkupanemiseks on oluline täpsemalt hinnata eraldiste piiridel paiknevate pikslite väärtusi, kuna nende osakaal on maastikul küllalt suur ning tulemused varieeruvad kui eraldisesisestel pikslitel.

Viidatud kirjandus

- Breiman, L. 2001. Random Forests, *Machine Learning* 45(1), 5-32.
- Maa-amet 2018. Maa-ameti ruumiaandmed seisuga 01.03.2018. [<https://geoportaal.maaamet.ee/est/Ruumiaandmed/Korgusandmed/Laadi-korgusandmed-alla-p614.html>]
- McGaughey, R. J. 2014. FUSION/LDV: Software for LIDAR Data Analysis and visualization. March 2014 – FUSION, Version 3.42. United States Department of Agriculture Forest Service Pacific Northwest Research Station.
- Metsaressursi 2017. Metsaressursi arvestuse riikliku registri põhimäärus. Riigi Teataja, RT I, 29.08.2017, 2.
- Metsaseadus 2006. RT I 2006, 30, 232.
- MKJ 2009. Metsa korraldamise juhend. RTL 2009, 9, 104.
- R Core Team 2021. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Valgepea, M., Raudsaar, M., Sims, A., Timmusk, T., Pärt, E., Suursild, E., Matson, T. 2020. Aastaraamat Mets 2019. Metsavarud. Keskkonnaagentuur.

Summary

Accuracy of forest resources assessment using remote sensing

Remote sensing data have different resolutions, and therefore their measurement uncertainty varies. This study analysed the accuracy of estimates of forest resources based influenced by pixels divided between forest compartments. A total area of 100 km² around the Järvelja Study and Experimental Forest has been used for experiment.

An area of 67.2 km² is covered with forest compartments. 76.6% of the pixels were completely within forest compartments, and 23.4% were divided between several forest compartments.

Based on laser scanning data metrics were calculated for 10-meter pixels. Amount of growing stock were predicted with a model for every pixel based on metrics. The average growing stock was 319.9 m³ per hectare for pixel fully in compartment. Two different methods were used to calculate growing stock summary for partially intersecting pixels: 1) directly from metrics calculated growing stock and 2) compartments average weighted with share of intersection. The first method gave average growing stock of 280.4 m³ per hectare and the second method gave 321.4 m³ per hectare. Thus, the total data calculated growing stock for experiment area using the same data, but different methods may differ about 3%. For comparison, the relative error of total growing stock estimation in the national forest inventory has been analysed to be 1.1%.

Multispectral Sentinel 2 satellite imagery were used to predict tree species. Using only pixels fully within the forest compartments, the kappa coefficient with the Random Forest classification method were close to 0.484 and 0.499 for both teaching and test data; however, with partially intersecting pixels the kappa coefficient was 0.282.

Metsa statistiline peegeldusmudel

Andres Kuusk¹, Joel Kuusk¹, Mait Lang^{1,2}

¹Tartu Ülikool, Tartu observatoorium, Tõravere, Nõo vald, 61602 Tartumaa

²Eesti Maaülikool, metsandus- ja maaehitusinstituut, Kreutzwaldi 5, 51014 Tartu

Kokkuvõte

Hemiboreaalsete metsade peegeldumisspektrite varieeruvust saab kirjeldada väikese arvu baasfunktsioonide abil. Viis baasfunktsiooni kirjeldavad peaaegu 98% vertikaalsuunas spektraalse heleduskordaja muutlikkusest spektraalvahemikus 400–1700 nm (nähtav kuni lühilaineline infrapunane). Välja on töötatud statistiline metsa peegeldusmudel, mille sisendandmeteks on regulaarse metsakorralduse käigus kogutavad takseerandmed. Puistu spektraalne heleduskordaja nadiiris on esitatud baasfunktsioonide lineaarkombinatsioonina, kus baasfunktsioonide kaalud on omakorda esitatud mitmese regressioonina puistu takseerparameetritest. Mitmese korrelatsioonimudeli koefitsiendid baasfunktsioonide kaalude leidmiseks on leitud eraldi kuusikute, männikute ja lehtpuumetsade jaoks. Baasfunktsioonid on leitud Järvelja metsade kohal helikopterilt tehtud spektraalmõõtmiste andmetest. Mudelit on testitud kümnel Eesti metskonnal, võrreldes mudeliga arvatud puistute spektraalsignatuure kaugseiresatelliidil Sentinel-2 oleva skanneri MSI spektraalsetelt piltidelt B2–B11 mõõdetud spektraalsignatuuridega. Mudelarvutuste ja mõõdetud spektraalsete signatuuride lahknevuse mõõdnuna on kasutatud suhteliste erinevuste summat üle kõigi spektraalkanalite. Summaarse vea jaotus on tugevalt asümmeetriline nii kuusikute, männikute kui lehtmetsade korral. Summaarse vea suured väärtused jaotuse kaugel paremal tiival on vihje sellele, et niisuguste puistute takseerandmed ei vasta puistu tegelikule seisukorrale. Mudel SFRM on lihtne ja usaldusväärne vahend takseerandmete kontrolliks.

Võtmesõnad: metsa spektraalne peegeldustegur, hemiboreaalne mets, statistiline mudel, Sentinel-2 MSI spektraalpildid

Sissejuhatus

Päikesekiirguse ja taimestiku vastasmõjust sõltub taimestikuga kaetud maapinna energiabilanss, fotosüntees ja transpiratsioon. Maakatte optiline kaugseire põhineb maapinna (ja taimkatte) poolt hajutatud ja peegeldunud päikesekiirguse

mõõtmistel. Pääkesekiirguse ja taimestiku vastasmõju kirjeldavad kiirguslevi mudelid. Füüsikalisi taimkatte kiirguslevi mudeleid on arendatud juba aastakümneid (Goel, 1988; Pinty jt, 2001; Widlowski jt, 2015; Kuusk, 2018). Metsa peegeldusmudelid kirjeldavad kiirguse vastasmõju ülimalt heterogeense ja ruumis ning ajas muutliku puistu võrastikuga. Niisugustel mudelitel on arvukalt sisendparameetreid (Liang, 2004; Widlowski jt, 2015; Kuusk, 2018). Kõigi vajalike sisendparameetrite väärtuste mõõtmine kas välitöödel või laboris on peaaegu võimatu. Metsade takseerkirjeldused sisaldavad puistu olulisi tunnuseid, mida metsakorraldaja on pidanud puistu kirjeldamiseks vajalikuks. Parameetrite hulk on välja kujunenud metsade majandamise praktika käigus (Burkhart ja Tomé, 2012; Ferretti ja Fisher, 2013). Andmebaasides on metsade olulised takseertunnused, nagu liigiline koosseis, vanus, puistu tihedus, kõrgus, rinnaspindala, tagavara, kasvukoha tüüp. Samas on puudu mitmed kiirguslevi mudelitele vajalikud puistu struktuuri ja optilisi omadusi kirjeldavad sisendparameetrid ning neid on takseerandmete põhjal raske või üsna võimatu hinnata (Nilson jt, 2000). Seetõttu tuleb niisuguste mudeli sisendparameetrite jaoks kasutada kirjanduse andmeid või mõnda eksperthinnangut.

Kaugseiremõõtmiste hulk on aja jooksul suurenenud. Kõige tavalisem optilises kaugseires kasutatav taimestiku iseloomustaja, normaliseeritud vegetatsiooniindeks NDVI, kasutab taimkatte peegeldustegurit kahes spektraalribas ning viimase paarikümne aasta kõige olulisem maismaa seire satelliidisensor Landsat-5 Thematic Mapper mõõdab aluspinna peegeldusomadusi kuues spektraalkanalis. Viimastel aastatel on satelliidisensorite spektraalkanalite arv, spektraalne ja ruumiline lahutusvõime ning mõõtmiskordsus oluliselt kasvanud. Nüüdsetel satelliidisensoritel näeme spektraalset lahutusvõimet alla 10 nm ja spektraalkanalite arv ulatub kümnekonnast mõnesajani (White jt, 2010; Coppo jt, 2017; Kuusk ja Kuusk, 2010). Tulemuseks on kaugseire andmemahutude tohutu kasv. Spektraalanalüüsi arvutusmeetodid ja pöördülesannete lahendamine – taimkatte parameetrite hindamine spektraalmõõtmistest – satuvad raskustesse, kui andmete dimensionaalsus kasvab suureks. Väga suurte maatriksite inversioon on arvutusmahukas ja tekivad ümardusvead. Probleeme lisab mõõtmisandmetes alati olemasolev müra ehk mõõtmis- ja andmevead.

Vaatlusandmeid saab tihendada, sobitades andmed mudelisse, mis sõltub mitte väga suurest hulgast parameetritest. Mudel võib olla lihtsalt sobiv funktsioonide klass koos asjakohaste kaaludega. Niisuguseid funktsioone nimetatakse baasfunktsioonideks (Press jt, 1992). Baasfunktsioonide kaalud leitakse mõõtmisandmete ja mudelist leitavate spektraalheleduste lahknevust minimeerides. Niisugust meetodit kasutas Price (1990) mullaproovide peegeldusspektrite analüüsil. 564 mullaproovi spektrid lainepikkuste vahemikus 0,55–2,32 μm esitatuna 178 spektraalse heledusega lähendati nelja ortogonaalse baasfunktsiooniga. Baasfunktsioonide kaalud leiti vähimruutude meetodiga.

Samasugust lähenemist saab kasutada ka metsade peegeldusspektrite kirjeldamisel. Tuleb leida baasfunktsioonide hulk, mis kirjeldab peegeldusspektrite

varieeruvust, ning leida iga puistu jaoks selle baasfunktsioonide kaalud. Kui need kaalud väljendada mitmese regressioonina puistu takseertunnustest, saame metsa statistilise peegeldusmudeli, mille abil saab metsa peegeldusspektri leida metsakorralduse andmebaasis oleva tavalise takseerkirjelduse abil.

Baasfunktsioonid on saadud metsade peegeldusspektrite helikopterimõõtmistest Järvelja metsade kohal. Neile baasfunktsioonidele tuginevat statistilist metsa peegeldusmudelit rakendati kümnel Eesti metskonnal ja tulemusi võrreldi Sentinel-2 MSI mõõtmistega 2019. aasta suvel.


Helikopterimõõtmised Järveljal

Metsade peegeldusspektreid lainepikkuste vahemikus 355–1640 nm mõõtsime helikopterilt Järveljal aastail 2010–2015. Järvelja metsades on puht- ja segapuistud, puuliikidest on peamised arukask (*Betula pendula* Roth), harilik mänd (*Pinus sylvestris* L.), harilik kuusk (*Picea abies* (L.) Karst.), sanglepp (*Alnus glutinosa* (L.) Gaertn.), haab (*Populus tremula* L.), hall lepp (*Alnus incana* (L.) Moench) ja harilik pärn (*Tilia cordata* Mill.). Kasvukohad varieeruvad väheviljakatest (H_{100} vähem kui 10 m) väga viljakani (H_{100} rohkem kui 35 m), kus kasvukoha indeks H_{100} on saja-aastase puistu kõrgus. Järvelja metsade eraldiste kontuurid ja takseerkirjeldused on riiklikus metsamajandamise andmebaasis. Andmestikku uuendatakse regulaarselt. Eraldiste primaarsed takseertunnused on loetletud tabelis 1. Lisaks neile on andmebaasis ka mitme primaartunnuse kombinatsioonina tuletatud parameetreid. Tabelis 1 loetlemata puuliikide osakaal on vaadeldavates puistutes väga väike. Eraldiste kontuuride leidmiseks kasutatakse aerofotosid, eelmise inventuuri andmeid ja kohapealseid vaatlusi. Välitöödel mõõdetakse peamised puistu takseertunnused (puistu liigiline koostis, kõrgus, tihedus ja kasvukoha tüüp, tüve diameeter rinna kõrgusel), arvutatakse rinnaspindala ja tagavara. Puuliigi osakaal kummaski rindes leitakse tagavarast lähtuvalt. Puistu kummagi rinde suhteline tihedus on rinnaspindala suhe niinimetatud normaalpuistu standardväärtusse vastava puistu kõrguse korral.

Helikopterimõõtmiste ala on tähistatud joonisel 1. Peegeldusspektrid nadiiris on mõõdetud spektromeetritega UAVSpec3 (VNIR, 306–1140 nm) ja UAVSpec4 (SWIR, 949–1701 nm) (Kuusk, 2011). Spektromeetrite spektraalne lahutus on 10 nm, kummaski spektraalpiirkonnas 256 spektraalkanalit. Registreeritud spektrid interpoleeriti spektromeetrite lainepikkustelt 5 nm sammuga spektriteks, kasutamata jäid halva signaali ja müra suhtega piirkonnad lainealade otstes ja vee neeldumisribades 1,13 μm ja 1,4 μm juures. Nii on igas mõõdetud spektris 217 spektraallugemit. Lennukõrgus oli 50–80 m puulatvadest, nii et mõõtmisandmetele atmosfäärikorrektiooni ei rakendatud. Lennukiirusel 60 km/h on spektrite registreerimissamm maapinnal 2,1 m nähtavas ja NIR-spektriosas (355–1110 nm) ning 1,4 m lühilainelises infrapunapiirkonnas (SWIR, 1160–1640 nm). Spektromeetrite vaateväli maapinnal oli läbimõõduga umbes 2,5–3 m.

Tabel 1. Puistute primaarsed takseerparameetrid


Parameeter	Väärtuste vahemik
Puistu vanus	6–246 aastat
Peapuu osakaal	30–100%
Puistu kõrgus	1–36 m
Ülemise rinde suhteline tihedus	0–145%
Alumise rinde suhteline tihedus	0–62%
Ülemise rinde rinnaspindala	0–45 m ² /ha
Alumise rinde rinnaspindala	0–17 m ² /ha
Ülemise rinde tagavara	0–623 m ³ /ha
Alumise rinde tagavara	0–162 m ³ /ha
Kase osakaal	1–100%
Haava osakaal	1–100%
Musta lepa osakaal	1–100%
Halli lepa osakaal	1–100%
Männi osakaal	1–100%
Kuuse osakaal	1–100%



Joonis 1. Järvselja uuringuala kaart. Proba/CHRIS lähi-infrapuna satelliidipildile, kaader DD40 27. juulil 2011, on kantud lennutrass 5. juulil 2010 ja kollasega analüüsi kaasatud eraldiste piirid.

Kõik mõõtmised on tehtud pilvitu või vähese pilvisusega ilmaga, nii et metsade kohal ei olnud pilvede varjusid. Päikese seniitnurk oli ligikaudu 40°.

Mõõtmisandmetest kaasati analüüsi need puistud, kus puistu kohal oli kogutud vähemalt 10 VNIR-spektrit, nii oli puistu kohta kogutud spektrite arv 10–130. Analüüsi ei kaasatud lageraiealasad ega noorendikke vanusega alla 5 aasta. Üldse oli analüüsitavaid mõõtmisi kuue aasta jooksul kokku 558 puistu kohal. Joonisel 2 on ühel mõõtmispäeval kogutud puistute keskmised peegeldusspektrid.



Joonis 2. Puistute keskmised peegeldusspektrid 5. juulil 2010. Lüngad graafikuil on veeauru neeldumisribade kohad.

Statistiline metsa peegeldusmudel

Mõõdetud metsa peegeldumisspektreid funktsioonina lainepikkusest λ saab esitada lainepikkuse λ mingite fikseeritud funktsioonide lineaarkombinatsioonina (Press jt, 1992),


$$\rho(\lambda) = \sum_{k=1}^n a_k X_k(\lambda), \quad (1)$$

kus $\rho(\lambda)$ on peegeldustegur vaatesuunas, funktsioonid $X_k(\lambda)$ on baasfunktsioonid ja a_k on baasfunktsioonide kaalud. Kõige kiiremini koondub rittaarendus (1), kui kasutada ortogonaalseid baasfunktsioone, mis leitakse vähimruutude meetodiga mõõdetud ja valemiga (1) lähendatud spektrite lahknevuse mõõtu minimeerides

(Press jt, 1992). Metsade spektraalne peegeldustegur varieerub suurtes piirides mõnest protsendist sinises ja punases spektriosas kuni 50%-ni lähi-infrapunases. Et vähimruutude meetodiga leitud baasfunktsioonid lähendaksid peegeldumisspektreid kõigil lainepikkustel ühevõrra hästi, on lahknemise mõõduks kasutatud spektraalse peegeldusteguri variatsiooniga skaleeritud väärtusi,


$$\chi^2 = \sum_j \left(\frac{\rho(\lambda_j) - \sum_k a_k X_k(\lambda_j)}{\sigma_j} \right)^2, \quad (2)$$

kus σ_j on peegeldusteguri standardhälve lainepikkusel λ_j .



Joonis 3. Metsade spektraalse heleduskordaja baasfunktsioonid. Lüngad graafikuil on veeauru neeldumisribades.

Esimesed viis baasfunktsiooni joonisel 3 kirjeldavad ligi 98% peegeldusspektrite variatsioonist, kusjuures ainult esimene baasfunktsioon üksinda kirjeldab ligi 90% variatsioonist (joonis 4a). Esimene baasfunktsioon kirjeldab peegeldumisspektri keskmist kaju. Selle baasfunktsiooni kaalu valikuga saab kirjeldada peegeldumise üldist taset. Järgmised baasfunktsioonid kirjeldavad konkreetse peegeldusspektri hälvimist keskmisest. Kui leida baasfunktsioonid igal aastal ainult selle aasta mõõtmisandmeid kasutades, siis baasfunktsioonide väärtused aastast aastasse kuigivõrd varieeruvad, aga kaju muutub vähe (joonis 3). Erandiks on 2015. aasta mõõtmised, kui tekkivad rümpilved katkestasid mõõtmislennu. Mõõta õnnestus ainult 42% puistuid ning tekkivate rümpilvede tõttu võis spektraalne valgustatus maapealsete tugimõõtmiste kohal ja mõõdetava puistu kohal olla erinev.



Joonis 4. Baasfunktsioonidega kirjeldatud variatsiooni osa (a) ja baasfunktsioonide kaalud (b).

Tabel 2. Takseertunnuste ja baasfunktsioonide kaalude mitmese regressioonimudeli koefitsiendid.

Kaal	Männikud	Kuusikud	Lehtmetsad
a_1	0,870	0,720	0,679
a_2	0,921	0,653	0,451
a_3	0,885	0,447	0,478
a_4	0,764	0,710	0,579
a_5	0,712	0,656	0,443

Selleks et siduda baasfunktsioonide kaalud valemis (1) puistute takseertunnustega, on puistud jagatud enamuspoolsi põhjal kolme gruppi: männikud, kuusikud ja lehtpuumetsad, ning on leitud mitmene korrelatsioon esimese viie baasfunktsiooni kaalude ja tabelis 1 esitatud 15 takseertunnuse vahel. Tabelis 2 on esitatud mitmese korrelatsiooni koefitsiendid kolme puistute rühma jaoks.

Avaldades valemi (1) kordajad a_k regressioonvalemitega funktsioonina takseerparameetreist, saame statistilise metsa peegeldumise mudeli

$$\mathcal{R} = \mathcal{A} \times \mathcal{X}, \quad (3)$$

mis on diskreetsel kujul esitatud baasfunktsioonide maatriksi X ja kaalude vektori A korrutis. Vektori A elemendid a_k on esitatavad puistu takseertunnuste mitmese regressioonina

$$a_k = \sum_{j=1}^{15} r_{jk} \gamma_j + b_{j1}. \quad (4)$$

Siin on r_{jk} mitmese regressiooni koefitsient, γ_j takseertunne ja b_{j1} esimese baasfunktsiooni kaalu regressioonisirge nihe. Seega on statistiline metsa peegeldusmudel SFRM, valem (1), defineeritud viie baasfunktsiooni väärtusega 217 laine-pikkusel, 75 tabuleeritud regressiooniparameetriga r_{jk} ja 15 nihkeparameetriga b_{j1} .

Mudeli rakendamine

Mudeli kasutatavuse kontrolliks on mudelit rakendatud kolmes etapis: helikopterimõõtmistele Järveljal juulis 2010, Järvelja Öppe- ja Katsemetskonna puistutele Sentinel-2 MSI spektraalpiltidel 18. augustil 2019 ning kümne Eesti metskonna puistuile Sentinel-2 MSI spektraalpiltidel 2019. aasta suvel.

Helikopterimõõtmised

Spektromeetritega UAVSpec3 ja UAVSpec4 5. juulil 2010 helikopterilt mõõdetud puistute keskmisi spektraalseid heleduskoefitsiente nadiiris on võrreldud mudeliga SFRM arvatutega, kasutades 2011. aasta takseerandmeid riiklikust metsakorralduse andmebaasist. Mõõtmisandmete $\rho_m(\lambda)$ ja mudelarvutuste $\rho_s(\lambda)$ lahknevuse mõõduks on kasutatud iga puistu jaoks arvatud suhtelist erinevust


$$d\rho(\lambda) = \frac{\rho_s(\lambda) - \langle \rho_m(\lambda) \rangle}{\langle \rho_m(\lambda) \rangle}, \quad (5)$$

kus nurksulud märgivad üle puistu keskmistamist. Mõõtmisandmeid oli 45 männiku, 59 kuusiku ja 231 lehtpuumetsa jaoks. Suhtelise vea jaotus kolme puistute rühma jaoks on esitatud joonistel 5–7.


Võrdlus helikopterimõõtmiste andmetega kinnitas, et mudeliga simuleeritud andmetel ei ole süstemaatilist viga. Simuleeritud ja mõõdetud tulemused erinesid rohkem kui 30% ainult kuuel puistul 335-st. Selle põhjuseks võib olla mõõdetud puistute ebahütlus, kui lennutrass läbis puistu vähetüüpilist osa.

Järvelja Öppe- ja Katsemetskond Sentinel-2 MSI spektraalpiltidel


Sentinel-2B MSI 18. augusti 2019 spektraalpiltidelt on mõõdetud Järvelja Öppe- ja Katsemetskonna puistute keskmised spektraalsed heleduskordajad Sentinel-2 spektraalkanalites B2–B8, B8A ja B11. Öppe- ja katsemetskond on Sentinel-2B MSI 18. augusti 2019 spektraalpildil B7 (780 nm) joonisel 8. Pruunide joontega on märgitud metskonna piir ja puistute kontuurid. Sentinel-2 MSI taseme 1C spektraalpiltide B2–B11 atmosfäärikorrektsioon on tehtud Kuusk jt (2010) soovitatud *look-up*-tabeli meetodil, kasutades atmosfääri optiliste parameetrite hindamiseks satelliidimõõtmistega samaaegseid SkySpec spektraalse valgustatuse mõõtmisandmeid (Kuusk ja Kuusk, 2018b, 2018a). Sentinel-2 MSI 20-meetrise lahutusega spektraalpildid B5, B6, B7, B8A ja B11 teisendati 10-meetrise pikslitega piltideks Sentinel-2 andmetötluspaketi Sentinel-2 Toolbox abil (ESA, 2019a). Spektraalpiltidelt on mõõdetud 514 kuusiku, 601 männiku ja 2121 lehtmetsa spektraalsed heleduskoeffitsiendid.



Joonis 5. Männikute simuleeritud peegeldumisspektrite suhteline viga.



Joonis 6. Kuusikute simuleeritud peegeldumisspektrite suhteline viga.



Joonis 7. Lehtpuumetsade simuleeritud peegeldumisspektrite suhteline viga.


Puistute analüüsi kaasamise tingimused olid, et puistu on vanem kui 5 aastat ja et puistu suurus spektraalpildidel oleks vähemalt kümme 10-meetrist pikslit. Ka ei tohtinud ühegi kaasatud piksli keskkohht olla puistu kontuurile lähemal kui 8 m. Neile tingimustele vastavate puistute keskmine pindala oli 1,72 ha, pindalade vahemik 0,2–42 ha.

Mudeliga simuleeritud keskmiste spektraalsete heleduskoeffitsientide suhtelise vea jaotus kolme puistute rühma jaoks kõigis vaadeldavais spektraalkanaleis on esitatud joonistel 9–11 ja tabelis 3.


Mudelandmete vigade jaotus on üsna ühtviisi standardhällbega 0,12 kuni 0,28 kuusikutel ja lehtmetsadel. Männikute korral on suuremal hajumisel kaks

võimalikku põhjust. Baasfunktsioonide leidmiseks kasutatud helikopterimõõtmiste andmestikus on männikuid vähem kui teisi puistuid ning nende vanusevahemik on väike. Ka on männikute hulgas 15 puistut, kus peapuuliik on mänd, aga lehtpuuliikide osakaal kokku on isegi suurem. Need puistud oleks tulnud klasifitseerida lehtpuumetsadeks. Aga samas on antud näitel võimalik simuleeritud heledust võrdluses satelliidipildilt mõõdetuga kasutada puistu liigilise koosseisu analüüsimiseks.


Süsteematilised vead on kõige suuremad tumedais spektraalkanaleis B2 ja B4 (sinine ja punane), kus atmosfääri osa satelliidisignaalis on suur ja atmosfäärikorrektiooni väikesed vead mõjutavad oluliselt mõõtmistulemust. Neis spektraalkanaleis võivad suhtelised vead olla kuni 40–50%, aga joonisel 12 näeme, et absoluutsed vead on väikesed. Ainult lehtpuumetsade lähi-infrapuna peegeldustegurid on 0,02–0,05 võrra ülehinnatud.




Joonis 8. Järvselja metskonna Sentinel-2 MSI spektraalpilt B7 (780 nm) 18. augustil 2019. Pruunide joontega on märgitud metskonna piir ja puistute kontuurid. Sinises riskülikus on joonisel 1 kujutatud piirkond, kus tehti mõõtmisi.



Joonis 9. Simuleeritud spektrite suhteline erinevus, kuusikud.




Joonis 10. Simuleeritud spektrite suhteline erinevus, männikud.




Joonis 11. Simuleeritud spektrite suhteline erinevus, lehtmetsad.

Tabel 3. Simuleeritud peegeldusteguri keskmine suhteline erinevus ja selle standardhälve (STD).

Spektraalkanal	Kuusikud		Männikud		Lehtmetsad	
	Keskväärtus	STD	Keskväärtus	STD	Keskväärtus	STD
B2 (492 nm)	-0,196	0,163	-0,247	0,147	-0,153	0,143
B3 (559 nm)	-0,028	0,182	-0,082	0,221	0,033	0,153
B4 (665 nm)	-0,206	0,200	-0,204	0,246	-0,211	0,180
B5 (704 nm)	0,073	0,212	0,040	0,290	0,132	0,169
B6 (739 nm)	0,049	0,230	0,017	0,543	0,166	0,127
B7 (780 nm)	0,023	0,234	0,006	0,577	0,154	0,130
B8 (833 nm)	0,096	0,247	0,069	0,614	0,191	0,134
B8a (864 nm)	-0,033	0,220	-0,041	0,548	0,085	0,119
B11 (1610 nm)	0,008	0,277	0,045	0,387	0,098	0,146
B2-B11	-0,024	0,243	-0,044	0,444	0,055	0,199



Joonis 12. Puistute keskmine spektraalne heleduskordaja Sentinel-2 spektraalpiltidelt ja mudelarvutustest SFRM-ga.



Joonis 13. Katsealade kaart. Katsealad on kujutatud Sentinel-2 spektraalkanali B7 (780 nm) piltidega, fooniks on Maa-ameti metsanduslik ortofoto. (a) – Aegviidu, (b) – Alutaguse, (c) – Häädemeeste, (d) – Järvselja, (e) – Käru, (f) – Laeva, (g) – Nõva, (h) – Saaremaa, (i) – Tõstamaa, (j) – Võru.

Sentinel-2 MSI spektraalpildid kümnel metskonnal

Puistute spektraalsignatuurid kümnel metskonnal on kogutud Sentinel-2 2019. aasta suvistelt spektraalpiltidelt. Metsade takseerandmed on 2018. aasta seisuga. Analüüsi on kaasatud puistud, mis on vanemad kui 5 aastat ning eraldise 8 m sissepoole puhverdatud kontuuri sisse jääb vähemalt kümme Sentinel-2 10-meetrist pikslit. Tabelis 4 on loetletud katsealad, nende koordinaadid, kasutatud satelliidipiltide kuupäevad, päikese seniitnurk satelliidipildi tegemise ajal, atmosfääri aerosooli optiline paksus ja veeauru hulk, rakendatud atmosfäärikorrektsooni meetod ja analüüsi kaasatud puistute arv metskonnas. Joonisel 13 on mõõtmisalad tähistatud Maa-ameti metsanduslikul ortofotol Sentinel-2 spektraalsete piltidega B7 (NIR, 780 nm). Sentinel-2 28. augusti 2019 kaadri Häädemeeste piirkonnas on osa katsealast kaetud kiudpilvedega. See piirkond jäi analüüsist välja ning on joonisel 13 jäetud mustaks.

Tabel 4. Katsealad ja Sentinel-2 MSI spektraalpildid.

Metskond	Tsentri koordinaadid	Kuupäev	SZA	AOD	H ₂ O, cm	Meetod	N
Aegviidu	59°17'N 25°33'E	02.09.2019	51,4°	0,07	1,5	Sen2Cor	11272
Alutaguse	59°6'N 27°22'E	28.08.2019	49,5°	0,17	2,2	LUT	8864
Häädemeeste	58°5'N 24°41'E	28.08.2019	48,9°	0,15	2,2	LUT	6461
Järvelja	58°19'N 27°16'E	18.08.2019	45,3°	0,07	1,9	SkySpec	3027
Käru	58°45'N 25°7'E	28.08.2019	49,8°	0,15	2,2	LUT	9168
Laeva	58°32'N 26°26'E	18.08.2019	45,3°	0,07	1,9	SkySpec	5374
Nõva	59°1'N 23°52'E	29.07.2019	41,0°	0,06	1,4	LUT	7835
Saaremaa	58°21'N 22°10'E	25.07.2019	39,0°	0,14	2,8	LUT	8919
Tõstamaa	58°27'N 23°51'E	28.08.2019	48,9°	0,10	1,8	LUT	9662
Võru	57°49'N 26°49'E	29.07.2019	40,0°	0,06	1,4	LUT	7524

SZA – päikese seniitnurk

AOD – aerosooli optiline paksus, 550 nm

H₂O – õhusamba veeauru hulk

N – puistute arv

LUT – atmosfäärikorrektsoon *look-up*-tabeli meetodiga (Kuusk, 1998)

SkySpec – atmosfääri optilised parameetrid on hinnatud SkySpec andmetest Järveljal (Kuusk ja Kuusk, 2018a).

Satelliidi mõõdetud spektraalsete heleduste teisendamiseks puistute atmosfäärialuseks peegeldusteguriks on kasutatud kolme erinevat meetodit. Järvselja ja Laeva metskondade satelliidipiltide atmosfäärikorreksioon on tehtud Järvselja SkySpec mõõtmiste toel. Aegviidu metskonna satelliidipiltide atmosfäärikorreksiooniks on kasutatud Sen2Cor protseduuri (ESA, 2019b). Teiste metskondade satelliidipiltidel ülehindas Sen2Cor protseduur aerosooli optilist paksust ja seetõttu olid spektraalpildid B2 (sinine), B3 (roheline) ja B4 (punane) ülekorrigeeritud. Tulemuseks olid süstemaatiliselt allahinnatud spektraalsed heleduskoeffitsiendid spektraalkanaleis B2–B4 ja seetõttu väga suured suhtelised erinevused simuleeritud ja mõõdetud spektraalheledustes. Nende spektraalpiltide atmosfäärikorreksiooniks sobitasime atmosfääri optilise paksuse niisuguseks, et lehtpuumetsade simuleeritud ja Sentinel-2 andmetest saadud spektraalsed heledused B2 ja B4 keskmiselt ühtisid.

Mudeliga SFRM arvatud ja Sentinel-2 MSI spektraalpiltidelt mõõdetud 78 100 puistu spektraalsete heleduskoeffitsientide suhteline erinevus, valem (5), on eraldi kõigi metskondade jaoks esitatud joonistel 14–15.

Valdav osa kõigist jaotustest jääb vahemikku $-0,5$ kuni $+0,5$. Enamik jaotusi on ühemodaalsed ja keskvärtus erineb vähe nullist. Süstemaatilised erinevused on spektraalkanaliti erinevad. Lühilainelistes spektraalkanalites on satelliidipiltide ülekorrigeerimise tulemuseks positiivsed suhtelised vead $d\rho(\lambda)$. Lehtpuumetsade lähi-infrapuna peegeldusteguri SFRM poolt ülehindamise tulemuseks on positiivne suhteline viga $d\rho(\lambda)$.

Männikus on spektraalkanalite erinevate süstemaatiliste vigade tulemuseks kahemodaalne jaotus, kui kõigi spektraalkanalite suhtelised vead on koondatud ühte massiivi.

Mudeliga SFRM modelleeritud ja mõõdetud spektraalsete heleduskoeffitsientide lahknevuse koondmõõduna võib kasutada spektraalsete suhteliste vigade summat

$$S = \sum_{j=B2}^{B11} \frac{|\rho_s(\lambda_j) - \langle \rho_m(\lambda_j) \rangle|}{\langle \rho_m(\lambda_j) \rangle}. \quad (6)$$

Summaarse vea S jaotus on eraldi iga metskonna jaoks esitatud joonistel 16 ja 17. Kõik need jaotused on tugevalt asümmeetrilised, keskvärtusest suuremate väärtuste poole jääv jaotuse tiib on madal.

Suure summaarse veaga S puistutel võib olla eksitavaid vigu takseerandmetes või on takseerandmed lihtsalt liialt vanad. See on otsene vihje metsade majandajale, et niisuguste puistute takseerandmeid tuleks kontrollida või uuendada esmajärjekorras. Selle väite kontrolliks analüüsime suure summaarse vea S põhjusi Kärü metskonnas, kus suurim summaarne viga on $S = 32,4$. Kärü metskonna primaarsete takseerparameetrite väärtuste vahemikud on esitatud tabelis 5.

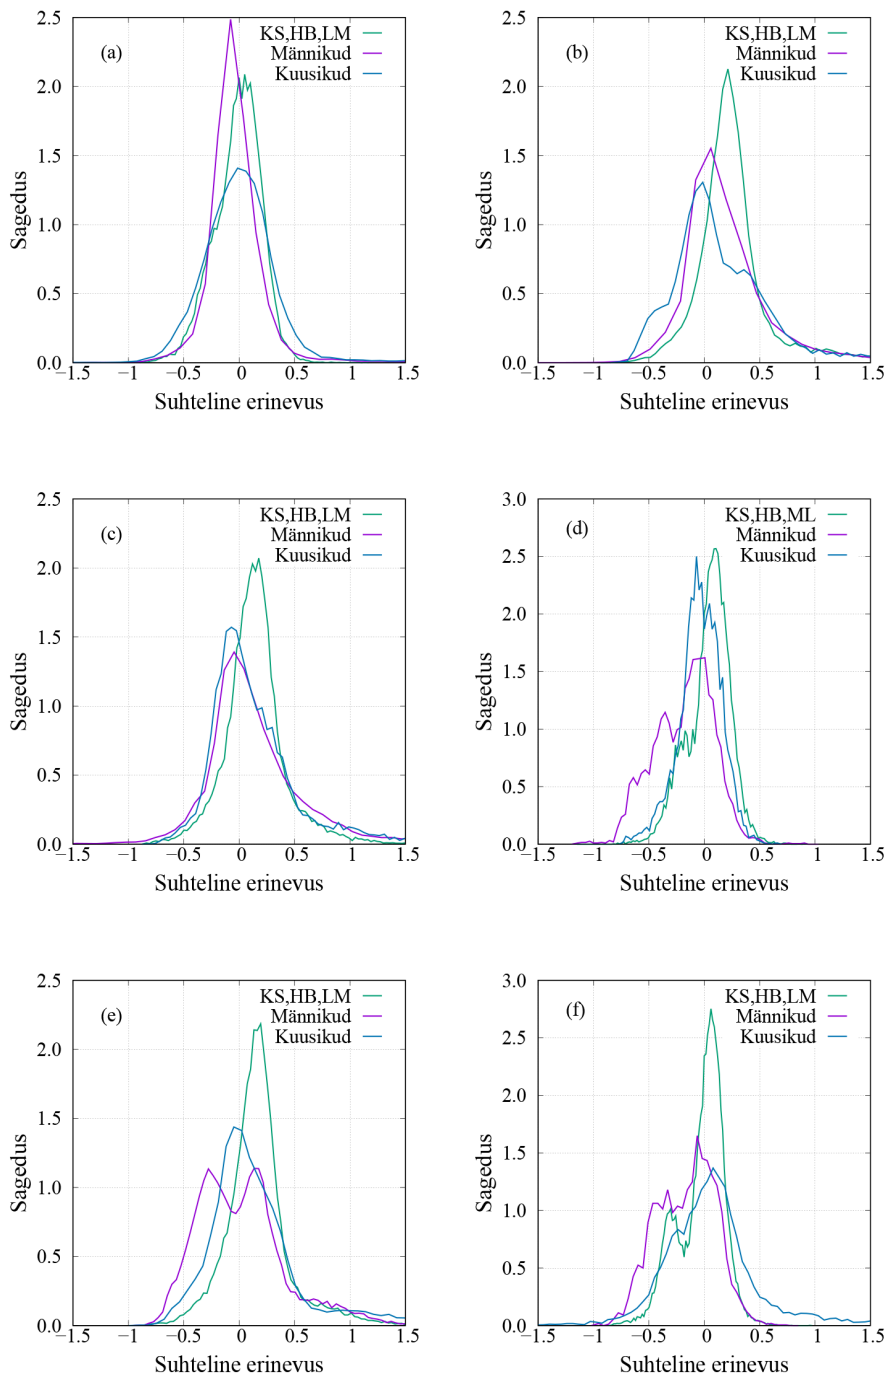
Tabel 5. Käru metskonna puistute takseertunnuste väärtuste vahemikud.

Parameeter	Väärtuste vahemik
Puistu vanus	6–217 a
Peapuuliigi osakaal	30–100%
Puistu kõrgus	1–36 m
Ülemise rinde suhteline tihedus	2–328%
Alumise rinde suhteline tihedus	0–86%
Ülemise rinde rinnaspindala	0,2–47 m ² /ha
Alumise rinde rinnaspindala	0–16 m ² /ha
Ülemise rinde tagavara	0–587 m ³ /ha
Alumise rinde tagavara	0–158 m ³ /ha





Takseerparameetrite ekstreemsete väärtustega puistute summaarne viga S ei ole sugugi kõige suurem. Valime detailseks analüüsiks 200 kõige suurema S-väärtusega puistut. Nende puistute summaarne viga S on vahemikus 4,93 kuni 32,4. Kaheksa puistu takseerandmed on vanemad kui 15 aastat, aga nende puistute S-väärtus ei ole sugugi erakordselt suur. Sentinel-2 28.08.2019 kaadris on neli tekkivat rünpilve, mis katavad osaliselt või tervenisti 14 puistut. Nende puistute korral $S > 7,0$ ja suurim on S-väärtus puistuil, mis on tervenisti pilve varjus. Eemaldasime need 14 puistut edasisest analüüsist. Uuendatud takseerandmete andmebaasis on 2020. aasta seisuga uuendatud 46 puistu takseerandmeid. Muutunud olid 6 puistu kontuurid – need puistud eemaldasime samuti edasisest analüüsist.

Uuendatud takseerandmetega arvatud spektraalsignatuuridega puistute S-väärtuseid on võrreldud 2018. aasta S-väärtustega joonisel 18. Näeme nii kasvanud kui kahanenud S-väärtusi, aga ilmselgelt domineerivad S-väärtuste kahanemised nii arvult kui suuruselt.


S-väärtuse suurim kasv on mahasaetud haavapuistul. S-väärtuse kasv ületab 0,3 vanematel kui 100-aastastel männikutel, kus ainuke muutunud takseerparameeter on puistu vanus. See viitab sellele, et mudelis SFRM on männikutel vanuse mõju ülehinnatud. Rohkem kui pooltel uuendatud takseerandmetega puistutel vähenes simuleeritud spektraalsete signatuuride suhteline viga oluliselt – rohkem kui 0,3 ja suurim vähenemine oli 2,7. See kinnitab, et suured S-väärtused on vihje sellele, et puistu parameetrid on pärast takseerimist muutunud ning neid on vaja uuesti kontrollida.



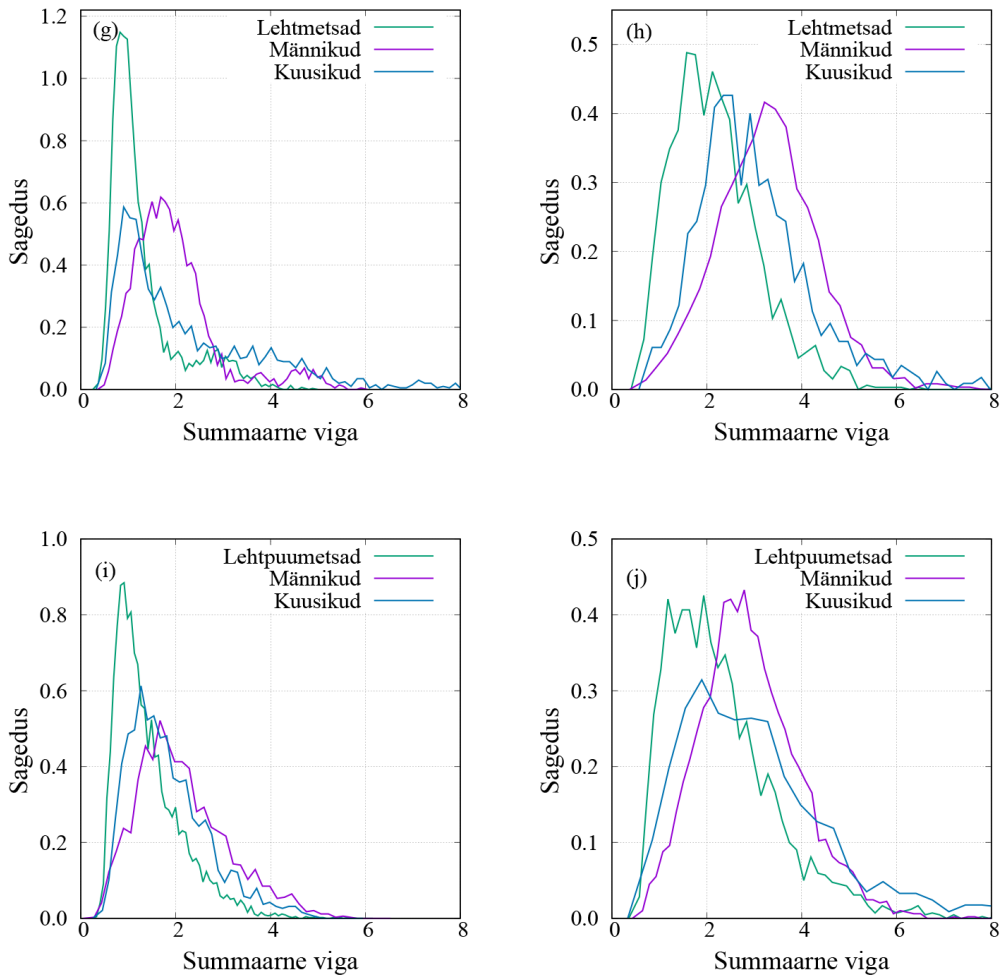
Joonis 14. Suhtelise erinevuse (valem (5)) jaotus katsealadel: (a) – Aegviidu, (b) – Alutaguse, (c) – Häädemeeste, (d) – Järvelja, (e) – Kärü, (f) – Laeva; KS, HB, LM – lehtpuumetsad.



Joonis 15. Suhtelise erinevuse (valem (5)) jaotus katsealadel, joonise 14 järg: (g) – Nõva, (h) – Saaremaa, (i) – Tõstamaa, (j) – Võru; KS, HB, LM – lehtpuumetsad.




Joonis 16. Summaarse erinevuse (valem (6)) jaotus katsealadel: (a) – Aegviidu, (b) – Alutaguse, (c) – Häädemeeste, (d) – Järvelja, (e) – Kärü, (f) – Laeva.



Joonis 17. Summaarse erinevuse (valem (6)) jaotus katsealadel, joonise 16 järg: (g) – Nõva, (h) – Saaremaa, (i) – Tõstamaa, (j) – Võru.

Kommentaariid

Lihtne statistiline metsa peegeldusmudel lubab arvutada puistu spektraalset heleduskordajat vertikaalsuunas, kasutades sisendparameetritena regulaarsel metsade takseerimisel kogutavaid andmeid. Mudeliga simuleeritud puistute spektraalsignatuurid on heas kooskõlas nii helikopterimõõtmistel kui seiresatelliidi Sentinel-2 poolt mõõdetutega. Mudelit on rakendatud kümnel metskonnal Eesti eri piirkondades Saaremaast Ida-Virumaa ja Kagu-Eestini. Hoolimata suurtest erinevustest kasvukohtades ja ilmatingimustes ei esinenud suuri süstemaatilisi lahknevusi



Joonis 18. Simuleeritud spektraalsete signatuuride summaarse erinevuse võrdlus, kui on kasutatud aegunud (2018) ja uuendatud (2020) takseerandmeid.

mudeliga simuleeritud ja Sentinel-2 spektraalpiltidelt mõõdetud puistute spektraalsignatuurides. Suured lahknevused väheste puistute spektraalsignatuurides on otsene vihje, et niisuguste puistute takseerandmed ei vasta tegelikule olukorrale ja neid tuleb uuendada esmajärjekorras.

Mudel on arvutuslikult väga lihtne ja kiire. Mudeli sisendandmete koostamine on lihtne päring metsanduslikus andmebaasis. Veidi problemaatilisem on võrdlusandmete kogumine satelliidimõõtmiste spektraalpiltidelt – sobiva satelliidipildi valik ja sisendandmete leidmine satelliidipildi atmosfäärikorrektsiooniks. Siiski on kosmoseprogrammides (Landsat, Copernicus) võetud suund keskkonnaseireks mõeldud satelliitide arvu suurendamisele. Praegu on Eesti kohta võimalik saada multispektraalseid keskmise ruumilahutusega satelliidipilte iga kahe kuni nelja päeva järel. Optilise spektriosa piltidel on küll oluliseks takistuseks pilved ja pilvevarjud, kuid üldiselt õnnestub pilvevaba kogu ala kattev mosaiik kokku saada mitu korda vegetatsiooniperioodi jooksul. Satelliidipiltide atmosfäärikorrektsiooni toeks tuleks üle Eesti paigaldada automaatsed SkySpec-tüüpi (Kuusk ja Kuusk, 2018b, 2018a) spektraalse valgustatuse mõõtmisjaamad. SkySpec-tüüpi spektrometrite võrgu lisamine Eesti keskkonnaseire programmi looks oluliselt

rohkem võimalusi kasutada multispektraalsete satelliidipiltide mõõtmisandmeid keskkonnaseires, põllu- ja metsamajanduses.

Mudeli aluseks olevad puistu peegeldusspektri baasfunktsioonid on leitud Järvelja metsade kohal helikopterilt tehtud spektraalmõõtmiste andmetest ja mitmese korrelatsiooni koefitsiendid on leitud Järvelja Öppe- ja Katsemetskonna takseerandmeid kasutades. Eestist oluliselt erinevates kliima- ja kasvukohatingimustes või teistsuguse liigilise koosseisuga metsade jaoks saab konstrueerida samasuguse statistilise mudeli, kui on kasutada piirkonnale vastav samaväärse esindatusega spektraalmõõtmiste ja takseerandmestik.

Metsade pideva seire tulemusena saadud andmed võimaldavad aegsasti märgata häiringuid ning teisalt hinnata olemasoleva info kvaliteeti. Avaandmetena kõigile tasuta kättesaadavate keskmise ruumilahutusega (10–30 m) Landsat-8 OLI ning Sentinel-2 MSI piltide info on Eesti puistute suurust (u 1,2 ha) arvestades igati sobilik kas osaliselt või täielikult automatiseeritud seiresüsteemi loomiseks. Lõimides metsa statistilise peegeldusmudeli andmehalduse infosüsteemiga tekib võimalus paari tunni jooksul peale satelliidiülesvõtte ilmumist EstHUB-i saada nimekiri puistutest, mille takseerikirjeldustele tuginev spektraalne heledus on oluliselt erinev pildilt mõõdetust. Selle alusel on võimalik koostada kontrollimist vajavate puistute nimekirjad ning optimeerida metsataksaatorite tööd, mis tähendab otseselt rahalist kokkuhoidu ja paremaid otsuseid metsade majandamiseks.

Tänuavaldus

Käesolevat tööd on toetanud Eesti Teadusagentuur, uurimistoetused SF0180009Bs11, grandid 7725, PUT232, PUT1355, Mobilitas Pluss MOBERC-11, ERMAS, AR12052, IUT24-1, Eesti keskkonnatehnoloogia programm KESTA. Sentinel-2 pildid on saadud riiklikust satelliidiandmete keskusest ESTHub. Täname!

Viidatud kirjandus

- H.E. Burkhardt and M. Tomé. *Modeling Forest Trees and Stands*. Springer, Dordrecht, 2012.
- P. Coppo, A Taiti, L. Pettinato, M. Francois, M. Taccola, and M. Drusch. Fluorescence imaging spectrometer (FLORIS) for ESA FLEX mission. *Remote Sens.*, 9(649), 2017. doi: 10.3390/rs9070649.
- ESA. The Sentinel-2 Toolbox. <https://sentinel.esa.int/web/sentinel/toolboxes/sentinel-2> (accessed on 15 October 2019), 2019a.
- ESA. Sen2cor v2.8. http://step.esa.int/main/third-party-plugins-2/sen2cor/sen2cor_v2-8 (accessed on 15 October 2019), 2019b.

- M. Ferretti and R. Fisher, editors. *Forest Monitoring. Methods for terrestrial investigations in Europe with an overview of North America and Asia*. Elsevier, Oxford, UK, 2013.
- N.S. Goel. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. *Remote Sens. Rev.*, 4:1–212, 1988.
- A. Kuusk. Monitoring of vegetation parameters on large areas by the inversion of a canopy reflectance model. *Int. J. Remote Sens.*, 19(15):2893–2905, 1998.
- A. Kuusk. Canopy radiative transfer modeling. In S. Liang, editor, *Comprehensive Remote Sensing. V. 3, Terrestrial Ecosystems*, pages 9–22. Elsevier, Oxford, 2018.
- A. Kuusk and J. Kuusk. Estimation of variable atmospheric parameters for the atmospheric correction of satellite images. *Int. J. Remote Sens.*, 39(2):565–576, 2018a. doi: 10.1080/01431161.2017.1388937.
- A. Kuusk, J. Kuusk, M. Lang, and T. Lökk. Vicarious calibration of the PROBA/CHRIS imaging spectrometer. *Photogramm. J. Finland*, 22(1):46–59, 2010.
- J. Kuusk. *Measurement of Forest Reflectance. Top-of-canopy Spectral Reflectance of Forests for Developing Vegetation Radiative Transfer Models*. Lambert Academic Publishing, Saarbrücken, Germany, 2011.
- J. Kuusk and A. Kuusk. Autonomous lightweight airborne spectrometers for ground reflectance measurements. In *Proceedings of the 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS 2010)*. IEEE, 14–16 June 2010.
- J. Kuusk and A. Kuusk. Hyperspectral radiometer for automated measurement of global and diffuse sky irradiance. *J. Quant. Spectrosc. Radiat. Transfer*, 204:272–280, 2018b. doi: 10.1016/j.jqsrt.2017.09.028.
- S. Liang. *Quantitative Remote Sensing of Land Surfaces*. Wiley-Interscience, Hoboken, New Jersey, 2004.
- T. Nilson, M. Lang, A. Kuusk, J. Anniste, and T. Lökk. Forest reflectance model as an interface between satellite images and forestry databases. In T. Żawila-Niedzwiecki and M. Brach, editors, *Remote Sensing and Forest Monitoring*, pages 462–476. Office for Official Publications of the European Communities, Luxembourg, 2000.
- B. Pinty, N. Gobron, J. L. Widlowski, S.A.W. Gerstl, M.M. Verstraete, M. Antunes, C. Bacour, F. Gaston, J. P. Gastellu, N. Goel, S. Jacquemoud, P. North, W. Qin, and R. Thompson. Radiation transfer model intercomparison (RAMI) exercise. *J. Geophys. Res. D: Atmos.*, 106(D11):11,937–11,956, 2001.
- W.H. Press, S.A. Teukolsky, W.T. Vetterling, and B.P. Flannery. *Numerical Recipes in FORTRAN. The Art of Scientific Computing*. Cambridge University Press, Cambridge, 1992.
- J.C. Price. On the information content of soil reflectance spectra. *Remote Sens. Environ.*, 33(2):113–121, 1990.
- J.C. White, C. Gómez, M.A. Wulder, and N.C. Coops. Characterizing temperate forest structural and spectral diversity with Hyperion EO-1 data. *Remote Sens. Environ.*, 114: 1576–1589, 2010. doi: 10.1016/j.rse.2010.02.012.

J.-L. Widlowski, C. Mio, M. Disney, J. Adams, I. Andreadakis, C. Atzberger, J. Brennan, L. Busetto, M. Chelle, G. Ceccherini, R. Colombo, J.-F. Côté, A. Eenmäe, R. Essery, J.-P. Gastellu-Etchegorry, N. Gobron, E. Grau, V. Haverd, L. Homolová, H. Huang, L. Hunt, H. Kobayashi, B. Koetz, A. Kuusk, J. Kuusk, M. Lang, P.E. Lewis, J.L. Lovell, Z. Malenovský, M. Meroni, F. Morsdorf, M. Möttus, W. Ni-Meister, B. Pinty, M. Rautiainen, M. Ščlerf, B. Šomers, J. Štuckens, M.M. Verstraete, W. Yang, F. Zhao, and T. Ženone. The fourth phase of the radiative transfer model intercomparison (RAMI) exercise: Actual canopy scenarios and conformity testing. *Remote Sens. Environ.*, 169:418–437, 2015. doi: 10.1016/j.rse.2015.08.016.

Summary

A statistical forest reflectance model

The variability of forest reflectance of hemiboreal forests can be described with a few basis functions. Five basis functions describe almost 98% of variability of directional reflectance spectra in the optical spectral domain (400–1700 nm) in forest stands at the top of a canopy in nadir. A statistical forest reflectance model (SFRM) is developed, the input parameters of which are the forest parameters measured in the course of regular forest inventory. Nadir spectral reflectance of a forest stand is expressed in the SFRM as a linear combination of basis functions. Spectral signatures of forest stands in Sentinel-2 MSI spectral bands are simulated with the statistical forest reflectance model SFRM, and compared to the spectral signatures measured in spectral images at ten study sites in Estonia. This paper is a compilation of two published papers in Estonian, available in open access journals:

Kuusk, A., Kuusk, J., and Lang, M. (2019) A statistical forest reflectance model. *Remote Sensing*, 11(23), 2749. <https://www.mdpi.com/2072-4292/11/23/2749>.

Kuusk, A. and Lang, M. (2020) Integration of statistical forest reflectance model and Sentinel-2 MSI images into a continuous forest inventory system. *Baltic Forestry*, 26(2), article id467. <https://doi.org/10.46490/BF467>.

