

Latvijas Universitātes doktora studiju programma "Datorzinātnes"

Promocijas darbs

**Koku vainagu automatizēta kartēšana meža  
inventarizācijai, izmantojot tālzipētes datu kopīgu apstrādi**

Linda Gulbe

Promocijas darba vadītājs: Dr. sc. comp., vadošais pētnieks Ints Mednieks

2019

# Saturs

<b>1. Ievads</b>	<b>9</b>
1. 1. Darba mērķi, uzdevumi un galvenie rezultāti . . . . .	11
1. 2. Autore publikācijas, dalība konferencēs un projektos . . . . .	13
<b>2. Tālīzpētes izmantošana mežu inventarizācijai</b>	<b>16</b>
2. 1. Lidar dati . . . . .	16
2. 1. 1. No Lidar datiem veidotie modeļi . . . . .	19
2. 2. Multispektrālie dati . . . . .	22
2. 3. Datu kopīga apstrāde . . . . .	26
<b>3. Pētītie apgabali un izmantotie dati</b>	<b>30</b>
3. 1. A1: Kārļi, Amatas novads, Latvija . . . . .	30
3. 2. A2: Salaspils, Lielvārdes, Ikšķiles, Stopiņu un Ropažu novadu administratīvā teritorija, Latvija . . . . .	32
3. 3. A3: Ventpils apkārtnē . . . . .	34
<b>4. Metodes koku vainagu noseguma kartēšanai</b>	<b>36</b>
4. 1. Eksistējošie risinājumi . . . . .	36
4. 2. Piedāvātie risinājumi . . . . .	42
4. 3. Precizitātes novērtēšana . . . . .	44
4. 4. Vidējas telpiskās izšķirtspējas datu apstrāde . . . . .	44
4. 4. 1. k - tuvāko kaimiņu metode . . . . .	45
4. 4. 2. Hibrīdās klasifikācijas darbplūsma . . . . .	52
4. 5. Augstas telpiskās izšķirtspējas datu apstrāde . . . . .	62
4. 5. 1. Attēlu sliekšņošanas darbplūsma . . . . .	63
4. 5. 2. Lēmumu balstīta metode TCID . . . . .	65
4. 5. 3. Konvolūcijas neironu tīkla U-Net pielietojums . . . . .	69
4. 6. Rezultāti un diskusija . . . . .	73
<b>5. Metodes atsevišķu koku identifikācijai un vainagu atdalīšanai</b>	<b>76</b>
5. 1. Eksistējošie risinājumi . . . . .	76
5. 2. Piedāvātie risinājumi . . . . .	80
5. 3. Precizitātes novērtēšana . . . . .	81
5. 4. Atsevišķu koku identifikācija . . . . .	84
5. 4. 1. Šablonu salīdzināšanas metode un tās papildinājumi . . . . .	84
5. 4. 2. Šablonu sagatavošana, izmantojot evolucionāro algoritmu EATG . . . . .	90
5. 5. Koku vainagu atdalīšana . . . . .	94
5. 5. 1. Lēmumu balstīta koku vainagu atdalīšanas metode . . . . .	94

5. 5. 2. Mask R-CNN pielietojums koku vainagu atdalīšanai . . . . .	100
5. 6. Rezultāti un diskusija . . . . .	102
<b>6. Secinājumi un priekšlikumi</b>	<b>107</b>
<b>Izmantotās literatūras saraksts</b>	<b>109</b>

## Izmantotie saīsinājumi

**3D:** trīsdimensionāls.

**AI:** precizitātes indekss (angl. *accuracy index*).

**ANN:** mākslīgais neironu tīkls (angl. *artificial neural network*).

**ASCII:** Amerikas informācijas apmaiņas standartkods (angl. *American Standard Code for Information Interchange*).

**B:** zilā starojuma frekvenču joslas attēls (angl. *blue band*).

**CIR:** krāsu infrasarkanā ortofotokarte (angl. *colour infrared*).

**CNN, konvNN:** konvolūcijas neironu tīkls (angl. *convolutional neural network*).

**DSM:** digitālais virsmas modelis (angl. *digital surface model*).

**DTM:** digitālais reljefa modelis (angl. *digital terrain model*).

**EA:** evolucionārais algoritms/ evolucionārie algoritmi (angl. *evolutionary algorithm*).

**EATG:** promocijas darba ietvaros izstrādāta metode šablonu ģenerēšanai.

**FCM:** faziklasifikācijas algoritms (angl. *fuzzy c-means*).

**G:** zaļā starojuma frekvenču joslas attēls (angl. *green band*).

**GPS:** Globālā pozicionēšanas sistēma (angl. *The Global Positioning System*).

**GPU:** grafiskais procesors (angl. *graphic processing unit*).

**ĢIS:** ģeogrāfiskā informācijas sistēma (angl. *geographic information system*).

**kNN:**  $k$  tuvāko kaimiņu metode (angl. *k - nearest neighbours*).

**LGIA:** Latvijas Ģeotelpiskās informācijas aģentūra.

**LIZ:** Lauksaimniecībā izmantojamā zeme.

**MIR:** vidējā infrasarkanā starojuma frekvenču joslas attēls (angl. *midwave infrared*).

**MK:** Ministru Kabinets.

**MLC:** maksimālās ticamības klasifikators (angl. *Gaussian maximum likelihood*).

**nDSM:** normalizēts digitālais virsmas modelis (angl. *normalized digital surface model*).

**NDVI:** normalizētās starpības veģetācijas indekss (angl. *Normalized Difference Vegetation Index*).

**NIR:** infrasarkanā starojuma frekvenču joslas attēls (angl. *infrared*).

**nRMSE:** normalizēta vidējā kvadrātiskā kļūda (angl. *normalized root mean square error*).

**O:** citas zemes pārseguma klases, kas nav koku vainagu nose gums, apzīmējums.

**OA:** kopējā precizitāte (angl. *overall accuracy*).

**PA:** ražotāja precizitāte (angl. *producer's accuracy*).

**R, RED:** sarkanā starojuma frekvenču joslas attēls (angl. *red band*).

**RE:** sarkanā starojuma robežas frekvenču joslas attēls (angl. *red edge band*).

**RGB:** dabisko krāsu attēls (angl. *true colour image*).

**RMSE:** vidējā kvadrātiskā kļūda (angl. *root mean square error*).

**SVM:** atbalsta vektoru mašīna (angl. *support vector machine*).

**SWIR:** īso viļņu infrasarkanā starojuma frekvenču joslas attēls (angl. *shortwave infrared*).

**TC:** koku vainagu nose gums (angl. *tree cover*).

**TCID:** darbā ieviests apzīmējums lēmumu balstītai metodei koku vainagu nose guma noteikšanai.

**TM:** šablonu salīdzināšanas metode (angl. *template matching*).

**UA:** lietotāja precizitāte (angl. *user's accuracy*).

**VeA IZI VSRC:** Ventspils Augstskolas Inženierzinātņu institūts „Ventspils Starptautiskais radioastronomijas centrs”.

**VRI:** Vides Risinājumu Institūts.

## Terminu vārdnīca

1. Zemes lietojuma klasi (angl. *land use class*) definē apraksts kā cilvēki izmanto zemi [29].
2. Zemes pārseguma klasi (angl. *land cover class*) definē fiziskais materiāls uz Zemes virsmas ar līdzīgiem parametriem, kurus izvēlas atbilstoši informācijas pielietojuma vajadzībām [29].
3. Klasifikācijas uzdevums ir piekārtot zemes pārseguma/ izmantojuma klasi vai nu katram attēla pikselim vai attēla reģioniem, kurus vieno kāda kopīga pazīme.
4. Attēlu aritmētika ir attiecināma uz aritmētisko operāciju (saskaitīšana, atņemšana, reizināšana, dalīšana utml.) pielietojumu vienam vai vairākiem attēliem. Aritmētiskās operācijas tiek izpildītas kā masīvu, nevis matricu operācijas, starp atbilstošajiem attēlu pikseliem [35]. Viens no biežākajiem attēlu aritmētikas pielietojumiem tālzpētē ir indeksu attēlu aprēķināšana.
5. Indeksus veido, kombinējot attēlu aritmētiskās operācijas viena attēla dažādām frekvenču joslām tā, lai uzsvētu dažādas zemes pārseguma īpašības [78].
6. Attēlu segmentācija (angl. *image segmentation*) ietver metodes, kas apvieno līdzīgas spektrālās un tekstūras informācijas apgabalus reģionos [35].
7. Deskriptors ir skaitliska vērtība, kas raksturo kādu konkrētu attēla apgabalu vai pikseli [35]. Visbiežāk izmantotie pikseļu deskriptori tālzpētē ir satelītattēla frekvenču joslu spektrālās vērtības un to pārveidojumi [78]. Reģionus bieži apraksta, izmantojot tekstūras deskriptorus, pikseļu intensitāšu vidējās vērtības un citus deskriptorus.
8. Deskriptoru attēls - attēls, kurš var saturēt jebkuras deskriptoru vērtības. Vienkāršākajā gadījumā tas ir attēls ar tā intensitātes vērtībām kādu to piedāvā attēla piegādātājs.  
Deskriptorus var iedalīt [35]:

(a) Spektrālie deskriptori attiecas uz pikseļu intensitāšu vērtībām oriģinālajos attēla datos vai to pārveidojumos. Spektrālie deskriptori var tik tikt definēti atsevišķu pikseļu līmenī vai attēla reģiona vai apgabala līmenī (piemēram, pikseļu intensitāšu vidējā vērtība).

(b) **Telpiskie deskriptori** attiecas uz sakarībām starp pikseliem.

Tekstūras deskriptori - lai arī terminam *tekstūra* nav formālas definīcijas, teksturālie deskriptori attiecas uz tādām attēla apgabala īpašībām kā homogenitāte, regularitāte un izlīdzinātība. Biežāk izmantotie tekstūras deskriptori ir pikseļa apkārtnes vai reģiona pikseļu intensitāšu vērtību standarta novirze, entropija,

pelēko toņu sakritību (angl. *Gray Level Coocurrence Matrix, GLCM*) matricas raksturlielumi.

Formas deskriptori raksturo reģiona formu, novietojumu un citas ģeometriskās īpašības. Formas deskriptora piemērs ir reģiona kompakums un reģiona robežas izlīdzinātība.

(c) Temporālie deskriptori - deskriptori, kuri aprēķināti dažādos laika periodos iegūtiem attēliem.

9. Spektrālo jeb deskriptoru klasi veido pikseļu vai attēla reģionu grupa ar līdzīgiem deskriptoriem, piemēram, līdzīgām intensitātes vērtībām satelītattēla frekvenču joslās [71].
10. Nevadītās klasifikācijas (angl. *unsupervised classification*) ietvaros deskriptoru klases tiek identificētas, meklējot klāsterus jeb grupas, kuras veido pikseļi ar līdzīgu digitālo vērtību. Parauga dati nav nepieciešami, taču pēc klasifikācijas attēla analītiķim tik un tā ir nepieciešams noteikt, kuram zemes pārseguma tipam atbilst katra spektrālā klase.
11. Vadītās klasifikācijas (angl. *supervised classification*) ietvaros objekta klase tiek noteikta, salīdzinot objekta deskriptorus ar parauga datiem, kuru patiesā klase jau ir zināma. Klasificējamais objekts tiek piešķirts tai klasei, kuras parauga datiem tas ir vislīdzīgākais.
12. Hibrīdās klasifikācijas metodes apvieno vadītās un nevadītās klasifikācijas konceptus, lai paaugstinātu klasifikācijas precizitāti salīdzinājumā ar iepriekš minēto konceptu metodēm.
13. Palīgdati (angl. *reference data*) ir datu kopa, kas tiek izmantota tālizpētes datu interpretācijai un datu apstrādes rezultātu validācijai.

## Anotācija

Promocijas darbā izstrādāti risinājumi koku vainagu kartēšanai, izmantojot dažādas telpiskās izšķirtspējas tālzpētes datus. Koku vainagu kartēšanas uzdevums ietver gan datu klasifikāciju divās klasēs (koku vainagu noseģums un cits zemes pārseguma tips), gan atsevišķu koku noteikšanu un to kontūru atrašanu.

Koku vainagu noseģums tika kartēts, izmantojot vidējas telpiskās izšķirtspējas multispektrālos satelītattēlus, augstas telpiskās izšķirtspējas ortofotokartes un Lidar datus. Atsevišķi koku vainagi tika noteikti, izmantojot ortofotokartes un Lidar datus.

Risinājumi ietver 3 jaunas metodes: hibrīdās klasifikācijas darbplūsmu koku vainagu noseģuma noteikšanai, šablonu ģenerēšanas metodi koku vainagu atdalīšanai un lēmumu balstītu koku vainagu atdalīšanas metodi, kas izmanto dažādu datu avotu kopīgu apstrādi. Papildinājumi izstrādāti arī bieži izmantotajai šablonu salīdzināšanas metodei. Tai pievienota atbilžu filtrācija un iespēja kopīgi apstrādāt dažādu sensoru iegūtus attēlus. Ņemot vērā dziļās apmācības popularitāti objektu atpazīšanas uzdevumu realizācijā, veikts arī konvolūcijas neironu tīklu U-Net un Mask R-CNN pielietojuma novērtējums Latvijas mežu kartēšanai.

Papildu metožu izstrādei, tika veiktas arī gadījumu izpētes, lai noskaidrotu atbildes uz pētījuma jautājumiem par metožu parametru efektīvu iestatīšanu un metožu rezultātu interpretāciju un izskaidrošanu. Satelītattēlu gadījumā tika pētīta atmosfēras un apgaismojuma, kā arī meža inventarizācijas parametru ietekme uz klasifikācijas rezultātiem.

Izstrādāto metožu rezultāti tika salīdzināti ar citu literatūrā bieži pieminētu metožu rezultātiem, izmantojot neatkarīgas testa datu kopas. Koku vainagu noseģuma kartēšanas augstākā kopējā precizitāte 94.2% tika sasniegta, izmantojot hibrīdo klasifikāciju un 92.8%, izmantojot sliekšņošanas darbplūsmu. kNN, lēmuma balstītās metodes TCID un U-Net rezultātiem precizitāte bija zemāka.

Augstākā koku vainagu identifikācijas precizitāte bija 63.3% (šablonu salīdzināšanas metode ar pielāgotām parametru vērtībām) un no 277 koku vainagiem 189 bija novērojama vairāk kā 60% atbilstība palīgdatiem (lēmumu balstītā koku vainagu atdalīšanas metode).

*Atslēgas vārdi: koku vainagu noseģums, atsevišķu koku vainagu atdalīšana, multispektrālie satelītattēli, Lidar, aerofotogrāfijas.*



# 1. Ievads

Meži sedz vairāk kā pusi no Latvijas teritorijas un ir viens no nozīmīgākajiem mūsu valsts dabas resursiem. Lai mežu apsaimniekošanas rezultātā efektīvi sasniegtu ekonomiskos, apkārtējās vides aizsardzības un sociālos mērķus ir nepieciešama precīza informācija par mežu kvalitatīvo un kvantitatīvo stāvokli konkrētajā laika momentā, kā arī par izmaiņām laika gaitā.

Šāda informācija tiek ievākta un apkopota meža inventarizācijas laikā, kad ar lauka mērījumu un aprēķinu palīdzību tiek noteikti tādi meža inventarizācijas parametri kā koku sugas, nogabala krājas apjoms, audzes vecums un citi.

**Meža inventarizācija** ir "informācijas iegūšana par mežu un tam piegulošiem purviem, meža infrastruktūras objektiem, mežā ietilpstošiem pārplūstošiem klajumiem, purviem un laucēm konkrētā meža īpašumā vai valdījumā un iegūtās informācijas dokumentēšana" [1]. Pamatojoties uz meža inventarizācijas datiem tiek izstrādāti meža tālākās apsaimniekošanas plāni.

Latvijā tiek veikta nogabalu (regulārā) meža inventarizācija (angl. *standwise forest inventory*) un statistiskā meža inventarizācija (angl. *sampling forest inventory*). Nogabalu meža inventarizācija attiecas uz inventarizācijas parametru noteikšanu mežaudzes ("mežs ar viendabīgiem meža augšanas apstākļiem, koku sugu sastāvu un vecumu" [1].) līmenī, izmantojot instrumentālus mērījumus un acumēru. Lai arī pamatvienība šajā inventarizācijas shēmā ir nogabals, vairāki meža inventarizācijas parametri ir jānosaka, veicot atsevišķu koku mērījumus izlases kārtībā. Saskaņā ar aktuālo likumdošanu, nogabalu inventarizācija ir jāveic vismaz reizi 20 gados, ja netiek veikta saimnieciskā darbība. Meži tiek inventarizēti pakāpeniski un tādējādi nogabalu inventarizācijas dati nesniedz pilnvērtīgu pārskatu par plašām teritorijām vienā laika momentā.

Statistiskā inventarizācija tiek veikta regulāri izvietotos parauglaukumos, kur katrs parauglaukums reprezentē 2500 hektāru lielu platību. Meža statistiskā inventarizācija sniedz augstāku mežu resursu novērtēšanas precizitāti valsts mērogā, bet neattiecas uz konkrētiem meža īpašumiem [37], [50].

Lauka mērījumi ir precīza pieeja meža inventarizācijas parametru noteikšanā, taču tas ir laikietilpīgs un finansiāli dārgs process. Meža inventarizācijas atvieglošanai kā papildu informācijas avots var kalpot Zemes mākslīgo pavadoņu un lidmašīnu ievāktie dati (tālīzpētes dati, angl. *remote sensing*) attēlu un punktu datņu formātos.

Zemes virsmas attēli ar tālīzpētes tehnoloģiju palīdzību tiek iegūti jau vairākus gadu desmitus un ir pieejamas apjomīgas datu bāzes ar potenciālu zemes virsmas fiziskā noseģuma novērošanai (angl. *Land Cover*) un pētīšanai. Landsat programmas [74] dati nodrošina bezmaksas informāciju par vairāk kā 30 gadus ilgu periodu. Bez maksas pieejami arī Copernicus programmas datu produkti un Sentinel satelītattēli. Savukārt, Latvijas Ģeotelpiskās Informācijas Aģentūra (LĢIA) uztur ortofotogrāfiju datu bāzi par 5 gadu periodiem, sākot no 1994. gada. Pieejamais digitālo datu apjoms sniedz nepieciešamos priekšnosacījumus

datorizētai apstrādei un attēlu pārveidošanai tematiskajās kartēs, izmantojot mašīnmācīšanās un citus attēlu apstrādes algoritmus.

Tālizpētes datu galvenā priekšrocība ir regulāra informācija par plašām, t.sk., arī grūti pieejamām teritorijām. Nav cita informācijas avota, kas spētu nodrošināt līdzvērtīgi detalizētu teritoriālo pārklājumu.

Meža inventarizācijas parametru noteikšanu, izmantojot tālizpētes datus un datorizētās metodes, visbiežāk veic divos līmeņos:

1. **Pikseļa līmenī.** Meža inventarizācijas parametru vērtības tiek noteiktas katram attēla pikselim, balstoties uz sakarībām starp pikseļa vērtībām tālizpētes datos un meža inventarizācijas parametru vērtībām.
2. **Atsevišķu koku līmenī.** Vispirms automatizēti tiek veikta atsevišķu koku identifikācija un vainagu atdalīšana, kurai seko atsevišķu koku inventarizācijas rādītāju noteikšana un nogabalu statistisko raksturlielumu novērtējumu aprēķināšana.

Abu līmeņu gadījumā nepieciešamas šādas datu apstrādes operācijas:

1. **Lietotāju interesējošo objektu atrašana** (izmantojot segmentācijas, objektu identifikācijas un atdalīšanas metodes). Mežu inventarizācijas un monitoringa vajadzībām nepieciešamie objekti ir :

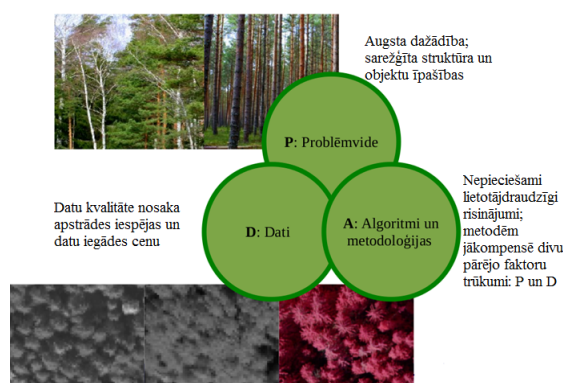
mežu teritorijas saskaņā ar likuma definīciju;

koku vainagu nosegtās teritorijas;

atsevišķi koku vainagi;

meža nogabali saskaņā ar likuma definīciju.

2. Meža inventarizācijas parametru noteikšana atrastajam objektam vai objektu veidojošajiem pikseliem, izmantojot klasifikācijas un regresijas metodes.



Att. 1.1. Tālizpētē problēmas sarežģītību nosaka problēmvide, datu iegūšanas parametri un izmantotās metodes vienlaicīgi.

Semantiskā un instanču segmentācija ir viens no grūtākajiem uzdevumiem attēlu apstrādē, jo lietotāju interesējošos objektus reti veido homogēni, no matemātikas viedokļa vienkārši aprakstāmi un tādēļ viegli atdalāmi attēla reģioni. Tālizpētē papildu izaicinājumus nosaka pētāmā problemātika, attēlveides process un metožu praktiskā pielietojamība. Konkrētas

pētāmās problēmas ir aprakstītas izklāsta nodaļās. Attēlā 1.1. ir uzsvērti vispārīgie izaicinājumi tālīzpētē, kas rada šķēršļus tālīzpētes datu izmantošanai meža novērtēšanas ikdienas praksē.

1. **Problēmvide.** Latvijas mežos nav sastopamas daudz koku sugas, taču mežu telpiskā struktūra ir sarežģīta. Relatīvi nelielas teritorijas ietvaros ir sastopamas dažādu vecumu un biežības mežaudzes. Lapu koku vainagiem raksturīga neregulāra forma, bez skaidri saskatāmas koka virsotnes un augsta biežība audzēs. Šāda daudzveidība ievērojami apgrūtina risinājumu izstrādi, jo datorizētie algoritmi ir vieglāk pielietojami standartizētu scenāriju apstrādei.
2. **Dati.** Tālīzpētes dati potenciāli nodrošina unikāli detalizētu teritoriālo pārklājumu, taču datu kvalitāte nosaka pielietojamības iespējas. Jo augstākas izšķirtspējas dati, jo augstākas to iegādes izmaksas, turklāt ne visus meža inventarizācijas parametrus iespējams noteikt tālīzpētes datu apstrādes rezultātā fizikāli pamatojamu iemeslu dēļ.
3. **Algoritmi un metodoloģijas.** Datorizētajām metodēm nepieciešams sasniegt rezultātus, kompensējot datu un problēmvides trūkumus. Datu apstrādes rezultātos ieinteresētie gala lietotāji visbiežāk nav datorzinātņu speciālisti, tādēļ daudzi algoritmu iekšējie parametri, kurus nepieciešams pielāgot optimāla rezultāta iegūšanai, ir grūti saprotami.

Tā kā problēmvidi meža inventarizācijas uzdevumu veikšanai nav iespējams kontrolēt un kvalitatīvu datu iegādes izmaksas bieži vien ir neadekvāti augstas salīdzinājumā ar datu apstrādes rezultātā iegūtā produkta vērtību, tad risinājumu iespējams meklēt, attīstot apstrādes metodes un kopīgi izmantojot dažādus, bet relatīvi lētākus datus.

Lai nodrošinātu efektīvu tālīzpētes datu izmantošanu meža inventarizācijai, nepieciešamas datorizētas apstrādes metodes koku vainagu noseģuma noteikšanai (semantiskā segmentācija) un koku vainagu segmentācijai (instanču segmentācija), kas

- būtu nejutīgas pret unikāliem apstākļiem attēla ieguves brīdī;
- efektīvi izmantotu paša attēla informāciju;
- spētu darboties ar mazu lietotāja līdzdalību;
- sniegtu stabilus, lietotājam viegli saprotamus rezultātus;
- realizētu modernās pieejas tālīzpētes datu apstrādē: a) datu kopīgu apstrādi, b) vairākpakāpju datu apstrādi.

## 1. 1. Darba mērķi, uzdevumi un galvenie rezultāti

Promocijas darba ietvaros veiktie pētījumi un metožu izstrāde iedalāmi divos tematiskajos virzienos:

1. koku vainagu noseģuma kartēšana un kartēšanas rezultātu interpretācija, izmantojot satelītattēlu, aerofotogrāfiju un Lidar datu apstrādi.

2. atsevišķu koku identifikācija un vainagu kontūru atdalīšana, izmantojot Lidar un multispektrālos datus.

**Darba mērķi ir:**

1. izpētīt vidējas telpiskās izšķirtspējas multispektrālo satelītattēlu klasifikācijas rezultātu uzticamību atkarībā no dažādiem faktoriem un izstrādāt lietotājam draudzīgu hibrīdās klasifikācijas risinājumu;
2. izpētīt Latvijas un citu jaukto mežu apstākļiem piemērotas metodes un algoritmus koku vainagu noseguma noteikšanai, izmantojot ļoti augstas telpiskās izšķirtspējas datus;
3. izpētīt un izstrādāt risinājumus atsevišķu koku vainagu identifikācijai un atdalīšanai, izmantojot Lidar un multispektrālos datus.

**Lai sasniegtu darba mērķus tika izvirzīti sekojoši darba uzdevumi:**

- Veikt literatūras apskatu par koku vainagu noseguma kartēšanu un atsevišķu koku vainagu identifikāciju un atdalīšanu, izmantojot tālīzpētes datus.
- Sagatavot tālīzpētes un palīgdatu kopas tālākam darbam.
- Realizēt risinājumus precizitātes novērtējumu veikšanai.
- Realizēt kNN metodi salīdzinājumu veikšanai.
- Izstrādāt un realizēt hibrīdās klasifikācijas darbplūsmu koku vainagu noseguma kartēšanai vidējas telpiskās izšķirtspējas tālīzpētes datos.
- Veikt gadījumu izpētes koku vainagu noseguma kartēšanas rezultātu interpretācijai un uzticamības novērtēšanai.
- Realizēt metodes koku vainagu noseguma kartēšanai ļoti augstas telpiskās izšķirtspējas tālīzpētes datos.
- Izstrādāt un realizēt papildinājumus šablonu salīdzināšanas metodei, lai tā būtu pielietojama multispektrālo un Lidar datu kopīgai apstrādei.
- Izstrādāt un realizēt risinājumu optimālai šablonu kopas sagatavošanai.
- Izstrādāt un realizēt risinājumu koku vainagu atdalīšanai, izmantojot multispektrālo un Lidar datu kopīgu apstrādi.
- Testēt konvolūcijas neironu tīklu pielietojumu koku vainagu noseguma noteikšanai un atsevišķu koku vainagu atdalīšanai.
- Veikt gadījumu izpētes dažādu parametru ietekmes novērtēšanai uz koku vainagu identifikācijas un atdalīšanas precizitāti.

Darba izklāsta daļa ir iedalīta četrās galvenajās nodaļās. Otrajā un trešajā nodaļā apskatīti izmantoto tālīzpētes datu veidi un pētāmie apgabali. Ceturtajā nodaļā aprakstīts pirmais pētījumu virziens: koku vainagu noseguma klasifikācija un semantiskā segmentācija, izmantojot gan vidējas, gan ļoti augstas telpiskās izšķirtspējas tālīzpētes datus. Piektajā nodaļā aprakstīts otrais pētījumu virziens: atsevišķu koku vainagu identifikācija un atdalīšana (instanču segmentācija).

Tēmas novitāte detaļās aprakstīta ceturtais un piektais nodaļas apakšnodaļās "Piedāvātie risinājumi".

Datu vizualizācijai izmantota brīvi pieejama ģeogrāfiskās informācijas sistēma QGIS un risinājumi realizēti Python valodā, izmantojot *numpy*, *skimage* un *keras* bibliotēku atbalstu.

### **Promocijas darba rezultāti:**

- Izstrādāta hibrīdās klasifikācijas darbplūsma koku vainagu noseguma kartēšanai, izmantojot vidējas telpiskās izšķirtspējas multispektrālos satelītattēlus un zemas kvalitātes apmācības datus. Hibrīdās klasifikācijas darbplūsma un kNN metode tika papildinātas ar pārliecības līmeņa aprēķiniem kartes uzticamības novērtēšanai.
- Veikts pētījums (gadījumu izpētes) par unikālo apstākļu satelītattēlu ieguves brīdī un mežaudžu raksturlielumu ietekmi uz koku vainagu noseguma kartēšanas rezultātu uzticamību un precizitāti.
- Salīdzinātas trīs dažādas metodes koku vainagu noseguma kartēšanai, izmantojot ļoti augstas telpiskās izšķirtspējas tālīzpētes datus: 1) vienkāršota sliekšņošana, 2) lēmumu balstīta metode, 3) konvolūcijas neironu tīkls U-Net.
- Izstrādāti papildinājumi šablonu salīdzināšanas metodei: 1) multispektrālo un Lidar datu kopīgai apstrādei, 2) atbilžu filtrācijai un šablonu izmēra maiņai.
- Izstrādāta jauna metode EATG optimālu šablonu izveidei, kas balstīta uz evolucionāro algoritmu koncepciju.
- Izstrādāta jauna lēmumu balstīta metode koku vainagu atdalīšanai, izmantojot dažādu tipu un avotu tālīzpētes datu kopīgu apstrādi.
- Testēts konvolūcijas neironu tīkls Mask R-CNN atsevišķu koku vainagu instanču segmentācijai un rezultāti salīdzināti ar lēmumu balstītās metodes rezultātiem.

## **1. 2. Autores publikācijas, dalība konferencēs un projektos**

Promocijas darba rezultāti ir iekļauti sekojošos zinātniskajos rakstos:

1. L. Gulbe, A. Kozlovs, J. Donis, A. Traškova "Tree cover mapping using hybrid fuzzy c-means and Landsat satellite images", *Baltic Forestry*, 25(1), 113-123, 2019. Autores aptuvenais ieguldījums procentos: 80%. *Indeksēts SCOPUS*.

2. M. Lang, L. Gulbe, A. Traškova, A. Stepčenko "Assessment of different estimation algorithms and remote sensing data sources for regional level wood volume mapping in hemiboreal mixed forests", *Baltic Forestry*, 22 (2), 283-296, 2016. Autores aptuvenais ieguldījums procentos: 20%. *Indeksēts SCOPUS*.
3. L. Gulbe "Identification and delineation of individual tree crowns using Lidar and multispectral data fusion", *Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE, 2015. Autores aptuvenais ieguldījums procentos: 100%. *Indeksēts SCOPUS*.
4. L. Gulbe "Automatic Template Generation For Individual Tree Identification in Remote Sensing Data Using (1+1) Evolutionary Algorithm". 14th International Multidisciplinary Scientific GeoConference: GEOINFORMATICS AND REMOTE SENSING. Conference Proceedings. VOLUME: 3, p. 63-70. Section: Photogrammetry and Remote Sensing, 2014. Autores aptuvenais ieguldījums procentos: 100%. *Indeksēts SCOPUS*.
5. L. Gulbe, G. Hilkevica "Vegetation Change Detection In Landsat TM Time Series Using Singular Spectrum Analysis and Regular Forest Inventory Data". 14th International Multidisciplinary Scientific GeoConference: GEOINFORMATICS AND REMOTE SENSING. Conference Proceedings. VOLUME: 3, p. 397-404. Section: Photogrammetry and Remote Sensing, 2014. Autores aptuvenais ieguldījums procentos: 80%. *Indeksēts SCOPUS*.
6. L. Gulbe, I. Mednieks "Automatic Identification of Individual Tree Crowns in Mixed Forests Using Fusion of LIDAR and Multispectral Data", *Scientific Journal of Riga Technical University. Technologies of Computer Control*, Volume 14: 93-99, 2013. Autores aptuvenais ieguldījums procentos: 80%.

Promocijas darba rezultāti tika prezentēti sekojošās zinātniskajās konferencēs:

1. 05.11.2015. Scientific conference of the forest sector "Knowledge based forest sector", Riga, Latvija, prezentācija "Mapping of tree crown coverage using satellite and ortho-photo images".
2. 26.07.2015. The International Geoscience and Remote Sensing Symposium 2015 (IGARSS 2015), Milan, Italy, plakāta prezentācija "Identification and Delineation of Individual Tree Crowns Using Lidar and Multispectral Data Fusion".
3. 15.09.2014. 18th International Conference on Information Systems for Agriculture and Forestry, Jelgava, Latvia, prezentācija "Identification of Forest Areas in Kurzeme Planning Region, Latvia Using Fuzzy Classification and Landsat Oli/Tirs Imagery".
4. 20.06.2014. 14th International Multidisciplinary Scientific GeoConferences SGEM2014, Albena, Bulgaria, prezentācijas 1. "Automatic Template Generation For Individual Tree Identification in Remote Sensing Data Using (1+1) Evolutionary Algorithm" un

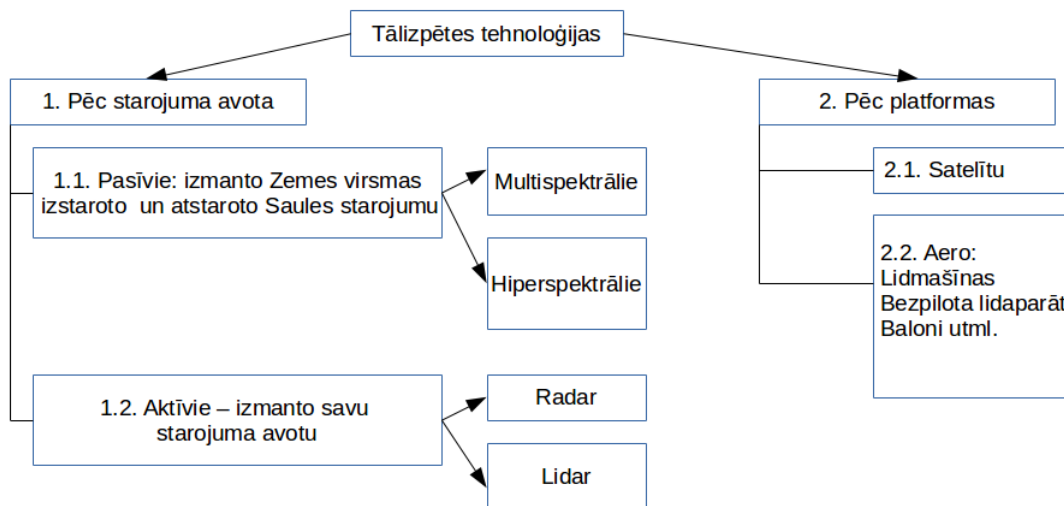
2. "Vegetation Change Detection In Landsat TM Time Series Using Singular Spectrum Analysis and Regular Forest Inventory Data".
5. 15.10.2013. Riga Technical University 52nd International Scientific Conference, Riga, Latvia, prezentācija "Automatic Identification of Individual Tree Crowns in Mixed Forests Using Fusion of LIDAR and Multispectral Data".

Uz promocijas darbu attiecināmi pētījumi tika veikti arī vairāku pētniecisko projektu ietvaros:

1. 2014 - 2017: valsts pētījumu programma "Next generation information and communication technologies", apakšaktivitāte "Pilsētvides tālzipēte".
2. 2015. gada vasara: prakse Freiburgas Universitātes pētījumu centrā "Chair of Remote Sensing and Landscape Information Systems FeLis"
3. 2014 - 2015: ERAF apakšaktivitātes 2.1.2.1.1. "Kompetences centri" projekts "Estimation of forest inventory parameters in non inventoried and overgrowing agricultural lands using remote sensing data processing". Nr. P10 – tālzipēte.
4. 2013: Central Baltic Interreg IV A Programme programmas projekts "Pure Biomass" No. CB56.

## 2. Tālpētes izmantošana mežu inventarizācijai

Vispārīgi tālpētes datus var iedalīt pēc platformas veida, uz kuras atrodas datu ieguves sensori, un pēc sensora veida atkarībā no starojuma avota, skat. att. 2.1.



Att. 2.1. Tālpētes datu vispārīgs iedalījums pēc platformas veida un sensora veida.

**Pasīvie sensori** ieraksta dabisko elektromagnētisko starojumu, kas tiek atstarots (Saules starojums) vai izstarots no Zemes virsmas (termālais starojums). Pasīvo sensoru piemērs ir multispektrālie, hiperspektrālie un termālie sensori. Pamatprincips šo sensoru datu izmantošanai Zemes novērojumos ir balstīts uz faktu, ka dažādi objekti un materiāli uz Zemes un atmosfērā atšķirīgās proporcijās atstaro, absorbē un pārraida atsevišķas elektromagnētiskā starojuma daļas, tādējādi ļaujot identificēt dažādas vielas.


**Aktīvie sensori** apstaro pētāmo objektu, izmantojot savu elektromagnētiskā starojuma avotu un reģistrē dažādus no Zemes virsmas atstarotā mākslīgā starojuma parametrus. Aktīvo sensoru piemēri ir Lidar un Radar tehnoloģijas.

### 2. 1. Lidar dati

Tehnoloģijas Lidar (arī saukta par aerolāzerskenēšanu) nosaukums ir saīsinājums no angļu valodas (angl. *Light Detection And Ranging*), kas nozīmē gaismas stara veiktā attāluma mērīšanu. Lidar ir aktīvais sensors, kas raida lāzera pulsus pret pētāmo objektu un mēra laiku, kas nepieciešams, lai pulss atstarotos pret objekta virsmu un tiktu uztverts atpakaļ sensorā, skat. att. 2.2. Pulsa atgriešanās laiks tiek izmantots, lai aprēķinātu attālumu starp sensoru un pētāmo objektu.

Attāluma mērījumi ļauj aprakstīt pētāmā objekta trīsdimensionālo (3D) struktūru. Rezultātā tiek iegūta informācija par objektu telpisko izvietojumu pētāmajā teritorijā. Lidar dati ir efektīvs informācijas avots par meža struktūru, koku augstumu, krāju, biomasu un citiem parametriem, kas saistīti ar mežaudzes vertikālo dimensiju [17]. Spektrālā informācija Lidar datu gadījumā ir ierobežota, taču dažos pētījumos secināts, ka tā ir noderīga koku sugu klasifikācijai [9].





Att. 2.2. Lidar tehnoloģijas pamatideja. Attēls: Marek9134 [CC BY-SA 3.0, Wikimedia Commons.

Atkarībā no lāzera darbības principiem iedala:


- Diskrētā pulsa Lidar, kura datu formāti un kvalitātes rādītāji tiks apskatīti šajā nodaļā sīkāk. Lāzera pulsu frekvence ir apmēram 20 000 līdz 75 000 pulsu sekundē. Topogrāfisko Lidar gadījumā tiek lietots infrasarkanā starojuma diapazons, kas ļauj iegūt atstarojumus no dažādām virsmām.
- Pilnas viļņformas Lidar spēj ierakstīt visu katra lāzera pulsa izstaroto un atstaroto signālu. Punktu mākoņa vietā lietotājiem tiek piedāvāti 3D ainas viendimensionāli profili.

Diskrētā pulsa Lidar dati satur punktu  $X$ ,  $Y$ ,  $Z$  koordinātu mērījumus, kā arī Lidar atbalss intensitātes un citu parametru mērījumus. Lidar dati bieži tiek uzglabāti kā punktu faili ASCII XYZ formātā vai arī kādā no binārajiem formātiem, piemēram, .LAS [106].  $X$  un  $Y$  koordinātes vērtība tiek norādīta saskaņā ar lokālo kartes projekciju, bet  $Z$  koordināti bieži izsaka kā punkta augstumu metros virs jūras līmeņa. Attēlā 2.3.  $X$  un  $Y$  vērtības ir norādītas saskaņā ar Latvijas kartes projekciju LKS-92.

Atkarībā no virsmas īpašībām pulss var atstaroties no virsmas tikai vienu reizi vai arī vairākas reizes. Piemēram, skenējot mežu teritorijas, pirmais atstarojums var būt no augstākajiem koka zariem, nākamie no zemākām koka vainaga struktūrām, bet pēdējais no zemes zem koku vainagiem.

Savukārt, punkta intensitāte raksturo starojuma intensitāti, kas tika atstarota no materiāla uz zemes. Katrs materiāls uz zemes virsmas atšķirīgi atstaro un absorbē noteiktas

elektromagnētiskā spektra daļas. Lidar datu gadījumā intensitāte raksturo infrasarkanā starojuma atstaroto daļu no pētāmā materiāla uz zemes.




Att. 2.3. Punktu faila piemērs un punktu vizualizācija. Punkti iekrāsoti atkarībā no augstuma ( $Z$ ) vērtības.

Galvenais Lidar datu kvalitātes rādītājs ir punktu skaits uz kvadrātmetru. Jo lielāks ir punktu blīvums, jo plašākas interpretācijas un datu produktu izstrādes iespējas. Punktu blīvumu lidojuma laikā parasti nosaka, regulējot lidojuma ātrumu, lidojuma augstumu, skenēšanas leņķi un skenēšanas ātrumu. Latvijas Ģeotelpiskās Informācijas Aģentūra kopš 2014. gada organizē Latvijas teritorijas Lidar datu ievākšanu, norādot, ka kopējais punktu blīvums nedrīkst būt mazāks par 4 punktiem/ $m^2$  un vidējam zemes virsmu raksturojošo punktu blīvumam jābūt ne mazākam par 1.5 punktiem/ $m^2$ .

Analizējot punktu blīvumu, jāpievērš uzmanība tam kā punktus uzskaita. Piemēram, vai tiek uzskaitīti visi viena pulsa atstarojumi, vai tiek ņemts vērā tikai pēdējais atstarojums. Tāpat arī jāņem vērā, ka skenēšanas procesā atsevišķas teritorijas tiek noskenētas blīvāk nekā citas. Līdz ar to Lidar punktu blīvums atšķirīgās teritorijās var atšķirties. Dažādu punktu blīvumu vizualizāciju skatīt att. 2.4.

Pielietojumu iespējas atkarībā no punktu blīvuma [96]:

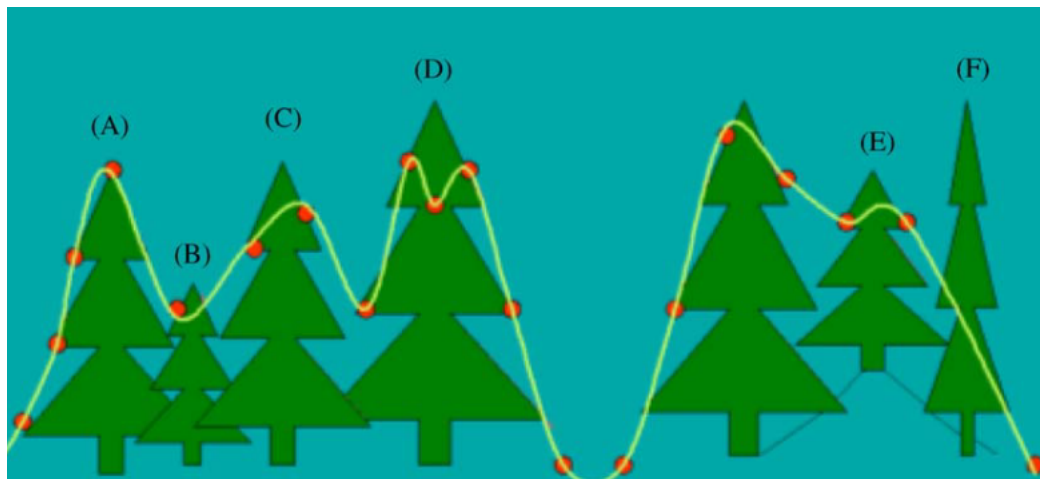
- $<2$  punkti/ $m^2$  tiek lietoti liela mēroga digitālo virsmas un reljefa modeļu sagatavošanā.
- $2 - 5 m^2$  ir biežāk sastopamais kompromiss starp punktu blīvumu un datu ieguves izmaksām. Šāda blīvuma dati tiek izmantoti gan virsmas un reljefa modeļu sagatavošanai, gan dažādās tautsaimniecības nozarēs, piemēram, mežsaimniecībā.
- $5 - 10 m^2$  blīvuma dati jau ir piemēroti vienkāršotai ēku analīzei pilsētvidē.
- $>10 m^2$  jau sniedz iespēju iegūt precīzākus ēku modeļus pilsētvidē un, protams, sniedz augstāku precizitāti iepriekš minētajiem produktiem.



Att. 2.4. Punktu blīvuma vizualizācija  $100\text{ m}^2$  lielam laukumam. a)  $1\text{ punkts/m}^2$ , b)  $5\text{ punkti/m}^2$ , c)  $10\text{ punkti/m}^2$ . Vizualizācijas mērķiem punkti izvietoti pēc gadījuma un nesimulē Lidar punktu rakstu.

Atsevišķu koku analīzes gadījumā ir iespējami dažādi scenāriji, kuros Lidar dati nereprezentē patieso situāciju [72], skat. att. 2.5.

Lidar datiem nav nepieciešama ortorektifikācija (ģeometriskā korekcija), jo katrs mērījums atsevišķi tiek ģeoreferencēts, izmantojot globālās pozicionēšanas un inerciālās mērījumu ierīces mērījumus. Taču trūkums ir neregulārais punktu izvietojums, kas apgrūtina vienmērīga teritorijas pārklājuma sagatavošanu kā tas notiek multispektrālo datu gadījumā.



Att. 2.5. Iespējamie scenāriji meža resursu izpētē, izmantojot Lidar, attēls no [106]. (A) Lāzera pulss trāpa koka virsotnei, (B) mazi koki, kas atrodas blakus lieliem netiek reģistrēti, (C) lāzera pulss netrāpa koka virsotnei, (D) viens no pulsiem trāpa zemākā augstumā un modelis rada divas virsotnes, (E) zemākiem kokiem var tikt piešķirts lielāks augstums, ja nav kvalitatīva reljefa modeļa, (F) maza punktu blīvumā daži koki var netikt reģistrēti.

Koku vainagu identificēšanai un atdalīšanai rekomendējamais punktu blīvums ir vismaz  $7\text{ punkti/m}^2$  [106].


### 2. 1. 1. No Lidar datiem veidotie modeļi

Lidar datus izmanto, lai sagatavotu virsmas un reljefa modeļus, kurus iespējams apstrādāt un analizēt vai nu attēla, vai trīsdimensiju modeļa formā:

- **Digitālais virsmas modelis (DSM, angl. *digital surface model*)** ir Zemes virsmas trīsdimensiju reprezentācija, iekļaujot arī objektus uz tās, piemēram, kokus, ēkas utml.

- **Digitālais reljefa modelis (DTM, angl. *digital terrain model*)** raksturo Zemes virsmas reljefu, neiekļaujot objektus uz tās.
- **Normalizētais virsmas modelis (nDSM)** raksturo tikai objektu telpisko struktūru, bez Zemes virsmas reljefa ietekmes.

Ja modelis tiek reprezentēts attēla formā, tad punktu mērījumi tiek projicēti uz rastra attēla režģa un pikseļa vērtība raksturo augstumu virs jūras līmeņa pikselim atbilstošajā laukumā uz zemes. Modeļu telpisko izšķirtspēju norāda tādā pašā veidā, kā multispektrālo attēlu gadījumā - pikselim atbilstošā laukuma izmēru uz zemes metros. Modeļu piemēri parādīti attēlā 2.6.




Att. 2.6. a) DSM, b) DTM, c) nDSM.

**Digitālais virsmas modelis** šīm pētījumam tika izveidots saskaņā ar vienkāršu algoritmu:


1. Tiek izveidota matrica, kuru sākotnēji aizpilda ar nulles vērtībām. Matricas izmērus aprēķina, ņemot vērā Lidar punktu failā ierakstīto  $x, y$  koordināšu diapazonu un lietotāja norādītu pikseļa izmēru metros.
2. Katram punktam Lidar punktu failā tiek aprēķināta tuvākā režģa punkta koordināte. To iespējams aprēķināt, meklējot vismazāko parasto Eiklīda vai Manhatana attālumu starp Lidar punkta koordinātēm un visām iespējamām pikseļu koordinātēm.
3. Ievietojam atrastajā režģa pikselī Lidar punkta  $z$  koordināti, ja tā ir lielāka par jau esošo pikseļa vērtību.
4. Ja režģa telpiskā izšķirtspēja ir smalkāka nekā punktu mākoņa telpiskā izšķirtspēja, tad atsevišķas režģa šūnas paliks neaizpildītas. Neregulārā Lidar punktu blīvuma dēļ šādi gadījumi iespējami arī tad, ja DSM telpiskā izšķirtspēja ir izvēlēta pareizi. Tādēļ DSM pēc aprēķināšanas tika filtrēts, izmantojot mediānas telpisko attēla filtrāciju ar loga izmēru  $4 \times 4$ , ja telpiskā izšķirtspēja ir  $0.4 \text{ m/piksels}$ .

Attēlā 2.7. parādīts DSM fragments un rezultāts pēc papildu filtrācijas.

Vienu no populāriem algoritmiem **digitālā reljefa modeļa** izveidei ieviesa Krauss un Feifers 1998. gadā. Šis algoritms arī tika izmantots šajā pētījumā, pielietojot brīvi pieejamo FUSION programmatūru. Filtrācijas algoritms ir balstīts uz iteratīvu mazāko kvadrātu interpolāciju. DTM izveidošana ietver 2 vispārīgus soļus: zemes punktu filtrāciju un vērtību



(a) Pirms.



(b) Pēc.

Att. 2.7. DSM piemērs pirms un pēc papildu filtrācijas.

interpolāciju. Ja zemes punktu filtrāciju veic tikai analizējot punktu  $Z$  koordinātes vērtību, atlasot zemākos punktus kā zemes punktus, tad reljefā, kuram raksturīgas straujas izmaiņas, piemēram, nogāzes, filtrācijas rezultātos var rasties kļūdas. Šī iemesla dēļ filtrācija ir jāveic kopā ar vērtību interpolāciju, lai izvairītos no netipisku, reljefam nepiederošu punktu iekļaušanas DTM.

Pirmajā algoritma solī reljefu raksturojošā virsma tiek aprēķināta ļoti aptuveni, ņemot vērā tikai punktu  $Z$  koordināti. Rezultātā virsma atrodas starp objektu virsmu un patieso reljefu, tā kā reljefa punkti visticamāk ir zem šīs virsmas, bet veģetācijas punkti virs virsmas. Pēc tam katram Lidar punktam  $v_i$  tiek aprēķināts svāra koeficients  $p_i$ , ņemot vērā šī punkta attālumu no virsmas un novietojumu attiecībā pret to:

$$p_i = \begin{cases} 1 & v_i \leq g \\ \frac{1}{1+(a(v_i-g)^b)} & g < v_i \leq g + w \\ 0 & g + w < v_i \end{cases} \quad (2. 1.)$$

$g$  koeficients nosaka, kuriem punktiem tiks piešķirts svāra koeficients 1. Ja punkta  $v_i$   $Z$  vērtība ir zemāka par vērtību  $g$ , tad punkts noteikti pieder reljefa patiesajai virsmai un tam tiek piešķirts augstākais svāra koeficients.

$w$  koeficients nosaka augstāko robežu, pie kuras punkti vēl ietekmē virsmas aprēķinus. Ja punkta  $Z$  vērtība ir augstāka par  $g + w$ , tad punktam tiek piešķirts svāra koeficients 0, respektīvi, tas netiek iekļauts virsmas aprēķinos nākamajā iterācijā.

Parametri  $a$  un  $b$  nosaka svāra funkcijas stāvumu.


Nākamajā iterācijā virsma tiek atkārtoti aprēķināta, ņemot vērā svāra koeficientus. Punkti ar augstu svāra koeficienta vērtību "pievelk virsmu sev tuvāk". Savukārt, punkti ar zemu svāra koeficientu "attālinās" no virsmas. Pēc virsmas pārrēķināšanas atkal tiek pārrēķināti svāra koeficienti un process atkārtojas tik ilgi līdz aprēķinātajā virsmā nozīmīgas izmaiņas vairs nenotiek. Izmantojot šo virsmu iespējams veikt klasifikāciju, ka visi punkti, kas atrodas zem virsmas vai uz virsmas tiek klasificēti kā zemes punkti.

Pēc punktu klasifikācijas tiek veikta zemes punktu  $Z$  vērtību interpolācija, lai izveidotu DTM ar vienmērīgu pārklājumu (piemēram, rastra attēla veidā).


DTM kvalitāte mežu teritorijās ir apmierinoša, taču metode nespēj efektīvi atfiltrēt ēkas.

Šī iemesla dēļ, tika sagatavota DTM filtrācija:


1. DTM attēlam tiek aprēķināts attēla morfoloģiskais gradients un veikta morfoloģiskā gradienta sliekšņošana, izmantojot sliekšņa vērtību  $T_{grad}$ .
2. Sliekšņotajam attēlam tiek izpildīta morfoloģiskā caurumu aizpildīšana. Rezultātā binārā attēla priekšplānā tiek saglabāti visi tie objekti, kuru telpiskās struktūras straujas izmaiņas veido malas (angl. *edges*) DTM. Atkarībā no DTM telpiskās izšķirtspējas, var būt nepieciešamas papildu morfoloģiskās operācijas bināro malu paplašināšanai.
3. Binārā attēla priekšplānam tiek atrastas savienotās komponentes. Katras savienotās komponentes vidējā apgrieztā (pirms vidējās vērtības aprēķināšanas tiek atņemti 10% augstāko un zemāko vērtību) DTM vērtība tiek salīdzināta ar tās ārējās robežas vidējo apgriezto vērtību. Ja to starpība ir lielāka par vienu metru, tad savienotās komponentes vērtības tiek aizstātas ar ārējās robežas apgriezto vidējo vērtību.



(a) Pirms.




(b) Gradients attēls.



(c) Gradients binārais attēls.



(d) Aizpildīts binārais attēls.



(e) Gala rezultāts.

Att. 2.8. DTM parauga apstrāde soli pa solim.

**Normalizēto virsmas modeli** aprēķina ļoti vienkārši, veicot matricu atņemšanu:

$$nDSM = DSM - DTM. \quad (2. 2.)$$

## 2. 2. Multispektrālie dati

Multispektrālie sensori ieraksta saņemto elektromagnētisko atstarojumu un izstarojumu no Zemes virsmas vairākās frekvenču joslās (angl. *bands*). Par frekvenču joslu sauc atstarojumu atsevišķā elektromagnētiskā starojuma diapazonā, kas kodēts pelēktonu attēla veidā. Meža inventarizācijas vajadzībām multispektrālie dati piedāvā unikālu informāciju

par veģetācijas raksturlielumiem, t.i., par koku sugām, koku veselības stāvokli un veģetācijas fizikāli ķīmiskajām īpašībām.

Attēlu pikseļu vērtība raksturo diskretizētu (angl. *sampled*) un digitalizētu (angl. *digitalized*) atstarojuma vai izstarojuma vērtību, kuru saņem sensors [26]. Dati tiek piedāvāti vai nu kā vairāku slāņu attēls ( $M \times N \times F$  izmēru matrica) vai kā atsevišķi pelēko toņu attēli ( $M \times N$  izmēru matrica).

Biežāk lietotie multispektrālo datu produkti ir satelītattēli, aerofotogrāfijas, ortofoto un ortofotokartes.

**Satelītattēli** tiek iegūti no Zemes mākslīgo pavadoņu platformām. Satelītattēli piedāvā regulāru un telpiski detalizētu informāciju par plašām teritorijām, taču pikseļu spektrālās vērtības spēcīgi ietekmē apgaismojuma un atmosfēras apstākļi attēla ieguves brīdī [33]. Latvijas klimatiskajos apstākļos bieži nav iespējams atrast vēlamā laika perioda attēlu mākoņu noseguma dēļ.

**Aerofotogrāfijas** lielākoties tiek uzņemtas no lidmašīnām un bezpilota lidaparātiem. Attēlu ieguvei iespējams izvēlēties piemērotus laika apstākļus, taču objektu ģeometriskās īpašības ietekmē skata leņķis no nadīra un pēcapstrādes operācijas [33].

**Ortofoto** ir zemes virsmas attēls (aerofotogrāfija vai satelītattēls), kam novērsti visi sagrozījumi, kas rodas ainā fotografēšanas brīdī ainas slīpuma un reljefa ietekmes rezultātā [23].

**Ortofotokarte** ir ortofoto mozaīka, ko izgatavo atbilstoši noteiktai karšu lapu nomenklatūrai. Latvijā ortofotokartes tiek sagatavotas Latvijas koordinātu sistēmā LKS-92 TM atbilstoši TKS-93 karšu lapu dalījuma (mēroga 1:10 000 karšu lapa atbilst 5 x 5 kilometriem dabā) [23].

Ortofotokaršu nozīmīgākā priekšrocība ir augstā ģeometriskā precizitāte, taču mozaīkas izveidē izmantotās aerofotogrāfijas nereti iegūtas pie atšķirīgiem apgaismojuma un atmosfēras apstākļiem. Šis aspekts ievērojami apgrūtina automatizētu metožu pielietojumu, jo iegādājoties ortofotokartes saskaņā ar karšu lapu nomenklatūru, lielākoties, nav pieejama informācija par aerofotogrāfiju metadatiem un nav zināmas oriģinālo aerofotogrāfiju, kas veido ortofotokarti, robežas.

Multispektrālo datu izmantošanas iespējas, neatkarīgi no to ieguves platformas, nosaka četras multispektrālo attēlu izšķirtspējas:


- Laika izšķirtspēja: cik bieži tiek atkārtoti iegūti viena un tā paša apgabala attēli?
- Radiometriskā izšķirtspēja: cik daudz pelēkā toņu vērtības tiek izmantotas, lai kodētu saņemto starojumu?
- Telpiskā izšķirtspēja: cik liels ir mazākais objekts, kuru attēlā varam saskatīt? Šo izšķirtspēju izsaka kā pikselim atbilstošā laukuma izmērus metros.
- Spektrālā izšķirtspēja: kādās un cik daudz elektromagnētiskā starojuma frekvenču joslās notiek datu ieguve? Multispektrālie sensori datus ievāc aptuveni 4 - 15 frekvenču joslās, bet hiperspektrālie sensori spēj nodrošināt pat vairāk kā 100 frekvenču joslu.

**Telpiskā izšķirtspēja** nosaka mazākā objekta izmērus, kurš ir saskatāms tālzipētes attēlā. Telpisko izšķirtspēju raksturo zemes laukuma izmēri metros [m], kas atbilst vienam attēla pikselim pilnas izšķirtspējas attēlā [71].

Piemēram, Landsat OLI multispektrālo frekvenču joslu attēlu telpiskā izšķirtspēja ir 30 m, kas nozīmē, ka vienam attēla pikselim "uz zemes atbilst"  $30\text{m} \times 30\text{m}$  liels laukums. Šādi definēta telpiskā izšķirtspēja ir intuitīvi viegli uztverama, taču, detalizētā pikseļu analīzē jāņem vērā vairāki papildu faktori kā tehniska rakstura mijiedarbība starp pikseļiem.

Atkarībā no telpiskās izšķirtspējas attēlus grupē: ārkārtīgi augstas (0.1-0.5m), ļoti augstas (>0.5-1m), augstas (>1-4m), vidējas (>4-12m), zemas (>12-50), ļoti zemas (>50-250m) un ārkārtīgi zemas (>250m) izšķirtspējas attēlos [7]. Ja telpiskā izšķirtspēja ir zema, tad pārskatāmā teritorija ir plaša un attēlā redzami relatīvi lieli objekti. Augstas telpiskās izšķirtspējas gadījumā iespējams novērot relatīvi sīkus objektus, taču telpiskais nosejums ir mazs.

Attēlā 2.9. redzami divi apgabali Ventspils teritorijā trīs dažādu izšķirtspēju sarkanā starojuma frekvenču joslas attēlos.



Att. 2.9. a) Sentinel-2A satelītattēla sarkanā starojuma diapazonā fragments, b) Sentinel-2A satelītattēla sarkanā starojuma diapazonā fragments, c) ortofotokarte sarkanā starojuma diapazonā mērogā 1 : 10000 LĢIA.

Pētījumā [46] tika analizētas empīriskās un analītiskās likumsakarības kā izvēlēties pareizu telpisko izšķirtspēju dažādu tālzipētes uzdevumu veikšanai. Rezultātā tika secināts, ka lai atpazītu aplūveida objektus (piemēram, koku vainagus) attēlā, šos objektus jāreprezentē vismaz četriem pikseļiem. Tas nozīmē, ka koka vainaga izmēra diametra un pikseļa izmēra attiecībai, ja nepieciešams atrast vainagus ar 5 m diametru, būtu jābūt vismaz 2.5:1 jeb attēla telpiskajai izšķirtspējai būtu jābūt vismaz 2 metriem. Taču pārskata rakstā [56] autori apkopoja pētījumus par sakarībām starp vainaga izmēru un telpisko izšķirtspēju un secināja, ka, lielākoties, vainagu atdalīšanas pētījumi tiek veikti, izmantojot datus ar 0.5 - 0.7 m izšķirtspēju (5:1 un 10:1). Savukārt jaunaudžu pētījumos rekomendējamā attiecība ir 15:1.

Ja telpiskā izšķirtspēja ir pārāk augsta, tad attēlā saskatāmas jau pārāk sīkas detaļas, kas palielina pelēko toņu variācijas koka vainaga iekšienē un apgrūtina identifikāciju un vainagu atdalīšanu [55]. Taču telpisko izšķirtspēju vienmēr iespējams samazināt datu apstrādes procesā.

Ortofotokartes ieteicams ģenerēt, izmantojot Lidar mērījumus. Pretējā gadījumā iespējamas ģeometriskas nobīdes starp Lidar un multispektrālo datu kopām, kas apgrūtina vai pat padara neiespējamu datu kopīgu apstrādi (angl. *data fusion*).



Koku vainagu naseguma un pikseļa līmeņa meža inventarizācijas parametru noteikšanu ierobežo mijiedarbība starp pikseļiem.

Mijiedarbība starp pikseļiem nozīmē, ka sakarības starp pikseļa spektrālo vērtību un patieso atstarojuma vērtību pikselim atbilstošajam zemes apgabalam nav neatkarīga no blakus esošajiem pikseļiem un blakus esošajiem zemes apgabaliem.

Pikselim atbilstošo laukumu uz zemes nosaka skata lauks (angl. *Instantaneous field of view, IFOV*), kuru var mērīt kā attālumu metros no nadīra punkta, līdz ar to mērījumu ziņā pikselim atbilst aplūveida mērījums uz zemes [15]. Projicējot šādus mērījumus uz kvadrātveida pikseļu režģa, notiek tehnoloģiska mijiedarbība starp blakus esošo pikseļu vērtībām. Rezultātā meža inventarizācijas parametru noteikšanu pikseļa līmenī ietekmē arī blakus esošo pikseļu meža inventarizācijas parametri.

Klasifikācijas uzdevumu veikšanu ierobežo arī jaukto pikseļu klātbūtne.

**Jauktais pikselis** (angl. *mixed pixel*) ir pikselis, kura atstarojumu veido vairāk nekā viens zemes pārseguma tips [108]. Nehomogēnas ainavas gadījumā jaukto pikseļu problēma var būtiski ierobežot klasifikācijas uzdevuma sarežģītību.

Pikseļa atstarojums mežu teritorijām pēc būtības ir funkcija no dažādiem faktoriem: meža inventarizācijas skaitliskajiem un diskrētajiem parametriem, atmosfēras apstākļiem, Saules apgaismojuma leņķa, leņķa no nadīra un citiem. Ņemot vērā, ka pikseļa atstarojumu ietekmē vairāki faktori, tad iespēja noteikt viena faktora ietekmi vai vērtību ir ierobežota vai atsevišķos gadījumos pat neiespējama [33]. Tāpat koku vainagu blīvums ietekmē mašīnmācīšanās algoritmu rezultātus, jo pie maza koku vainaga blīvuma pikseļa vērtības frekvenču joslās vairāk līdzinās tādiem zemes pārseguma tipiem kā zāliens vai lauksaimniecības zeme.

**Spektrālās izšķirtspējas** (angl. *spectral resolution*) jēdziens iekļauj elektromagnētiskā starojuma frekvenču joslu skaitu, platumu un novietojumu [111].

Multispektrālajiem datiem raksturīgas 4 - 15 frekvenču joslas, savukārt, hiperspektrālie dati satur daudz vairāk joslu, pat vairākus simtus.

Dažādi materiāli uz Zemes virsmas atšķirīgās proporcijās absorbē un atstaro specifiskas elektromagnētiskā spektra daļas.

**Spektrālā signatūra** ir novērotajam objektam specifiska atstarotās, izstarotās un absorbētās enerģijas kombinācija atkarībā no viļņa garuma. Jo vairāk frekvenču joslas instruments spēj detektēt, jo detalizētāka informācija par materiāla spektrālo signatūru.

Mežaudzes gadījumā meža inventarizācijas parametru noteikšanas iespējamību nosaka sakarību eksistence un kvalitāte starp meža inventarizācijas parametriem un spektrālajām vērtībām [106]. Koku sugu klasifikācijas uzdevumā var uzskatīt, ka sakarībām ir jābūt izteiktām, jo katrai koku sugai ir raksturīga īpaša spektrālā signatūra (atstarotā un absorbētā starojuma proporcijas dažādās frekvenču joslās) atkarībā no veģetācijas fizioloģiskā sastāva. Taču koku vecums neietekmē lapu ķīmisko sastāvu un tādējādi neatstāj tiešu iespaidu uz spektrālajam signatūrām [33]. Koku vecumu iespējams netieši noteikt, izmantojot multispektrālos datus, taču sakarības var būt vājas.

Jo vairāk frekvenču joslu, jo pilnvērtīgāka informācija par koku sugām. Koku sugu spektrālās signatūras ir relatīvi līdzīgas, tādēļ pie maza frekvenču joslu skaita var nebūt iespējama koku sugu klasifikācija. Savukārt, pieaugot frekvenču joslu skaitam līdz hiperspektrālo sensoru līmenim pieaug datu dimensionalitātes problēma un nepieciešamo datora atmiņas un skaitļošanas resursu apjoms.

Saskaņā ar pārskata rakstu [56] atsevišķu koku identifikācijas uzdevumam visbiežāk tiek lietotas multispektrālo datu panhromatiskā josla (plata redzamās gaismas frekvenču josla), zaļā starojumam atbilstošās frekvenču joslas un tuvā infrasarkanā attēli (NIR), jo NIR frekvenču josla ir īpaši jutīga attiecībā uz veģetācijas izmaiņām.

Skata leņķis no nadīra atsevišķu koku gadījumā ietekmē koku vainagu ģeometriju attēlā. Vairums autoru rekomendē izmantot nadīra attēlus atsevišķu koku identifikācijai, jo pie citas ģeometrijas ir limitētas algoritmu izmantošanas iespējas [65].

Apgaismojuma leņķis ietekmē atsevišķu koku identifikāciju un visaugstāko identifikācijas un vainagu atdalīšanas precizitāti iespējams sasniegt, ja Saules augstuma leņķis virs horizonta ir pēc iespējas tuvāks maksimālam iespējamam [16].

## 2. 3. Datu kopīga apstrāde

**Datu kopīga apstrāde** (angl. *data fusion*) ir lietotāja prasībām atbilstoša sistēma, kurā pielietoti līdzekļi un rīki dažādas izcelsmes datu apvienošanai. Datu kopīgas apstrādes mērķis ir iegūt augstākas kvalitātes informāciju, kur "augstākās kvalitātes" definīcija ir atkarīga no pielietojuma sfēras [110].

Vienkāršoti skaidrojot, datu kopīga apstrāde ir process, kas apstrādā datus un informāciju no dažādiem avotiem, lai sasniegtu uzlabotu rezultātu lēmumu pieņemšanai. Atšķirīgi datu avoti var saturēt atšķirīgu informāciju par pētāmo objektu, tādējādi kopīgi apstrādājot vairāku avotu datus iespējams iegūt vairāk informācijas un veikt kvalitatīvāku analīzi nekā viena datu avota gadījumā.

Tālīzpētes datu kopīgā apstrādē var iedalīt dažādus scenārijus atkarībā no datu avota un parametriem [7]:

1. **Dažādu sensoru dati** (angl. *multisensor*) ļauj iegūt savstarpēji papildinošu informāciju.

Piemērs. Meža inventarizācijas vajadzībām bieži kombinē multispektrālos un Lidar datus. Multispektrālie dati satur spektrālo informāciju, kas ir ļauj noteikt koku sugas un koku veselības stāvokli. Savukārt Lidar dati sniedz datus par virsmas telpiskajiem raksturlielumiem un ļauj noteikt koku augstumu.

2. **Dažādos laika periodos** iegūtu datu kopīga apstrāde (angl. *multitemporal*) iekļauj dažādu sezonu datu apstrādi, lai iegūtu pilnvērtīgu informāciju par zemes pārsegumu vai dažādu laika periodu datu apstrādi ar mērķi identificēt izmaiņas.

Piemērs. Ziemāju un vasarāju sējumu klasifikācija, izmantojot satelītdatus, kas iegūti aprīlī (ziemāji ir uzdīguši, bet vasarāji vēl ne) un augustā (ziemāji un vasarāji ir ga-

tavības stadijā un atšķirami no zālieniem). Gadā nocirsto mežu platību noteikšana, izmantojot vienas un tās pašas sezonas satelītattēlus divos secīgos gados.

3. **Dažādu līmeņu dati** (angl. *multistage*) ir zemes pārseguma raksturošanas stratēģija, kas ietver informācijas apkopošanu un analīzi dažādos ģeogrāfiskos mērogos, piemēram, nacionālā mērogā un tad lokālā mērogā.

Piemērs. Aizaugušo lauksaimniecības zemju identifikācija, izmantojot vidējas izšķirtspējas satelītattēlus un šo teritoriju meža inventarizācijas datu novērtējumi, izmantojot ortofoto apstrādi.

4. **Dažādu mērogu dati** (angl. *multiscale*) ietver dažādu telpisko izšķirtspēju datu kopīgu apstrādi.

Piemērs. Dažādu izmēru koku vainagu identifikācija, izmantojot aerofotogrāfijas ar atšķirīgām izšķirtspējām.

5. **Dažādu avotu dati** (angl. *multisource*) ietver tālīzpētes datu apstrādi kopā ar citu avotu datiem, piemēram, palīgdatiem, digitālā augstuma modeļiem un citu informāciju.

Piemērs. Digitālā augstuma modeļa un augsnes tipu karšu pievienošana meža klasifikācijas uzdevumam.

Attēlu kopīgu apstrādi var realizēt trīs dažādos apstrādes līmeņos [87], [118]:

1. **Pikseļa jeb mērījumu līmenī** (angl. *pixel, measurement level*) tiek apvienoti dažādu datu avotu nomērītie fizikālie parametri.

Piemērs. Redzamās gaismas attēlu izšķirtspējas paaugstināšana, izmantojot panhromatisko joslu (angl. *pansharpening*). Redzamās gaismas mērījumi tiek apvienoti ar panhromatiskās joslas mērījumiem, lai paaugstinātu redzamās gaismas attēlu asumu. Metožu ietvaros tiek apvienotas tieši pikseļu vērtības.

2. **Pazīmju līmenī** (angl. *feature level*) dažādiem datu avotiem tiek aprēķinātas pazīmes kā malas vai tekstūras parametri un tālākā procesā tiek izmantotas šīs pazīmes.

Piemērs. Dažādu datu avotu pazīmes, piemēram, multispektrālo datu veģetācijas indekss un entropijas attēls un Lidar datu augstuma modelis, var tikt apvienotas vektorā un šo vektoru pēc tam apstrādā ar mašīnmācīšanās algoritmu palīdzību, lai klasificētu zemes izmantojumu.

3. **Lēmumu līmenī** (angl. *decision level*) tiek apvienoti vairāku algoritmu rezultāti, lai iegūtu gala rezultātu.

Piemērs. Koku vainagi tiek segmentēti, izmantojot Lidar datus, bet segmentācijas rezultāts tiek koriģēts, izmantojot multispektrālo datu koku sugu klasifikācijas rezultātus.

Šajā darbā, algoritmos izmantoti elementi, kas raksturīgi visiem trim apstrādes līmeņiem.

Meža inventarizācijas parametri nosakāmi vairākos līmeņos:

- $A$  - parametrs nosakāms atsevišķa koka līmenī,
- $VS$  - parametrs nosakāms valdošajai sugai pēc atsevišķu koku identifikācijas un sugu noteikšanas,
- $M$  - parametrs nosakāms meža audzes līmenī.

Parametru noteikšanas veids var būt veicot lauka mērījumus vai aprēķinot parametra vērtību, izmantojot nomērītos lielumus.

Meža inventarizācijas parametrs	Līmenis	Noteikšanas veids	Lidar	MS <1m izšķirtspēja	MS >12 m un < 50 m izšķirtspēja
Koku skaits $N_t$	A	Lauka mērījums	T	T	-
Koku suga $M_{inv}$	A	Lauka mērījums	T	T	T, I
Bonitāte $B_{inv}$	VS	$f(M_{inv}, A_{inv}, H_{inv})$	NT, I	NT, I	NT, I
Vidējais augstums $H_{inv}$	VS	Lauka mērījums	T	NT	NT, I
Vidējais caurmērs $D_{inv}$	VS	Lauka mērījums	NT	NT, I	NT, I
Vecums $A_{inv}$	VS	Lauka mērījums	NT, I	NT, I	NT, I
Biezība $Z_{inv}$	M	$f(G_{inv}, coef.)$	NT, I	NT, I	NT, I
Šķērslaukums $G_{inv}$	M	$f(D_{inv})$	NT, I	NT, I	NT, I
Krāja $V_{inv}$	M	$f(G_{inv}, coef.)$	NT	NT, I	NT, I

Tabula 2. 1. Meža inventarizācijas parametru noteikšana, izmantojot tālziņas datus.

Tabulā 2. 1. apkopta informācija no literatūras apskata par meža inventarizācijas parametru noteikšanas iespējām, izmantojot Lidar un dažādas izšķirtspējas multispektrālos datus. Tabulā izmantotie apzīmējumi raksturo meža inventarizācijas parametru noteikšanas metodes tipu un efektivitāti:

- $T$  - parametra vērtība tiešā veidā ir saistīta ar sensoru nomērītajiem lielumiem;
- $NT$  - parametra vērtība tiešā veidā nav saistīta ar sensoru nomērītajiem lielumiem, taču parametrs tiek novērtēts, izmantojot eksperimentālas sakarības starp konkrēto parametru un sensoru datu vērtībām;
- $I$  - parametra noteikšanas precizitāte neatbilst meža inventarizācijas prasībām.

Tabulā 2. 2. apkopotas koku vainagu un koku vainagu noseģuma noteikšanas iespējas konkrētu sensoru datu gadījumā.

Dati	Telpiskā izšķirtspēja (m)	Frekvenču joslas	Koku vainagu noseģuma noteikšana	Koku vainagu atdalīšana	Aptuvena cena arhīvu datiem (EUR/km <sup>2</sup> )

LĢIA orto-fotokartes	0.2 vai 0.5 atkarībā no reģiona	R, G, B, NIR	Iespējama	Iespējama	0.37 aktuālie dati, 0.29 neaktuālie dati
WorldView 3 satelītattēli	1.24 - 1.38 multispektrālie dati, 0.31-0.34 panhromatiskā josla	Coastal, R, G, B, Y, RE, NIR1, NIR2	Iespējama	Daļēji iespējama	34.91
RapidEye satelītattēli	5	R, G, B, RE, NIR	Iespējama	Nav iespējama	1.12
Landsat OLI	30 multispektrālie dati, 15 panhromatiskā josla	R, G, B, NIR, MIR, SWIR	Daļēji iespējama	Nav iespējama	Bezmaksas
Sentinel 2A	10	R, G, B, NIR	Iespējama	Nav iespējama	Bezmaksas
Lidar (vispārīga informācija)	4 punkti/ $m^2$	-	Iespējama	Iespējama atkarībā no punktu blīvuma	3272 <sup>1</sup>

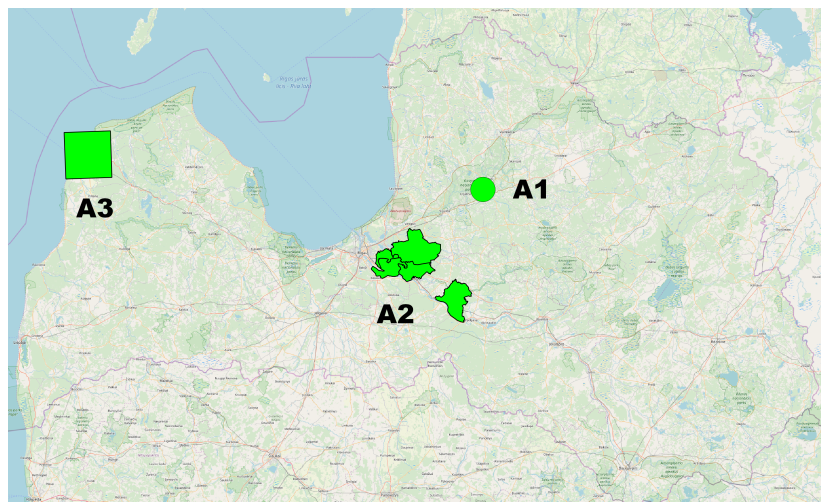
Tabula 2. 2. Objektu atdalīšanas iespējas, izmantojot dažādu sensoru datus. Cenas no datu piegādātāju mājas lapām.

Rezultātā iespējams secināt, ka tālizpētes dati nespēj sniegt lauka mērījumiem ekvivalentu meža inventarizācijas parametru noteikšanas precizitāti, taču var kalpot kā papildu informācijas avots apstākļos, kad lauka mērījumus nav iespējams veikt pietiekami bieži vai ar pietiekami blīvu telpisko noseģumu. Vispārējiem mežu teritoriju novērtējumiem labs risinājums ir brīvi pieejamie Landsat un Sentinel satelītu dati, taču meža inventarizācijas parametru pietiekami ticamiem novērtējumiem nepieciešami Lidar un multispektrālie dati ar augstu telpisko izšķirtspēju.

<sup>1</sup><http://sofew.cfr.msstate.edu/papers/0504tilley.pdf>

### 3. Pētītie apgabali un izmantotie dati

Darbā aprakstītās metodes ir testētas trim pētāmajiem apgabaliem Latvijā, skat. att. 3.1. Pētāmajiem apgabaliem ir atšķirīgas pieejamo references un tālzpētes datu kopas. Pētāmajos apgabalos testētie uzdevumi apkopoti tabulā 3. 1.



Att. 3.1. Pētāmie apgabali iekrāsoti zaļā krāsā. Pamatslānis: OpenStreetMap karte.

Uzdevums	A1: Amata	A2: Ropaži	A3: Ventspils
T1: koku vainagu noseģuma kartēšana, izmantojot vidējas telpiskās izšķirtspējas satelītattēlus	×	✓	✓
T2: koku vainagu noseģuma kartēšana, izmantojot krāsu infrasarkanās ortofotokartes (CIR)	×	✓	✓
T3: koku vainagu noseģuma kartēšana, izmantojot CIR ortofotokaršu un Lidar datu kopīgu apstrādi	×	×	✓
T4: atsevišķu koku vainagu identifikācija, izmantojot ortofotokaršu un Lidar datu kopīgu apstrādi	✓	×	×

Tabula 3. 1. Realizētie uzdevumi, izmantojot pētāmo apgabalu datus.


Klimatu pētāmajos apgabalos nosaka mērenās joslas klimats ar vidējo temperatūru janvārī  $-4.6^{\circ}$ , jūlijā  $+17.0^{\circ}$  un vidējo nokrišņu daudzumu gadā 667 mm [109]. Latvija atrodas saskares joslā starp diviem nozīmīgiem ekosistēmu tipiem: ziemeļu skujkoku mežiem un mērenās joslas platlapju mežiem, tādēļ mežaudzēs novērojamas abiem tipiem raksturīgas koku sugas [121].

#### 3. 1. A1: Kārli, Amatas novads, Latvija

Pētāmais apgabals ietver  $0.25 \text{ km}^2$  plašu teritoriju netālu no Cēsīm ( $57^{\circ}14'N$ ,  $25^{\circ}13'E$ ). Pētāmajā apgabalā atrodas apmēram 20 hektāri jaukta tipa meža. Reljefs ir līdzens ar nelie-

liem pakalņiem. Visas mežaudzes ir dabiski izveidojušies meži, kuros ir veikta saimnieciskā darbība. Dominējošās koku sugas ir parastā priele (latīniski *Pinus sylvestris L.*), parastā egle (latīniski *Picea Abies*), bērzs (latīniski *Betula pendula Roth*), apse (latīniski *Populus tremula L.*), baltalksnis (latīniski *Alnus incana*), ozols (latīniski *Quercus robur L.*). Vidējie meža inventarizācijas rādītāji: koku vecums 60 līdz 85 gadi, koku augstums 25 – 28 metri un diametrs krūšu augstumā 28 – 36 centimetri. Pamežs sastopams tikai 10% no mežaudzēm.

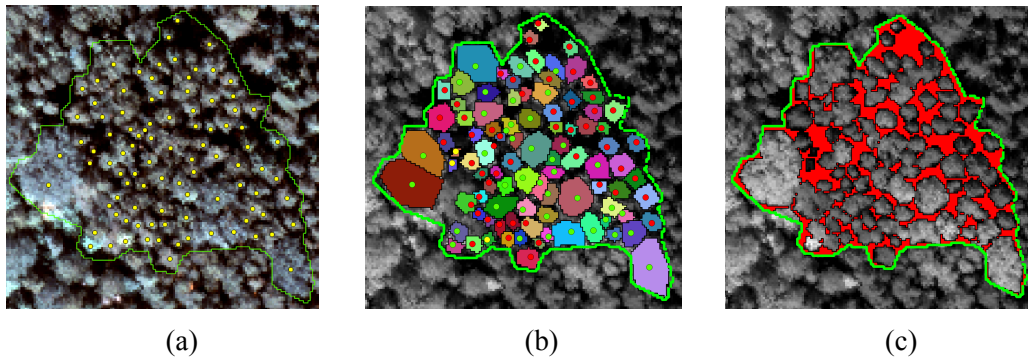
Palīgdati iekļauj lauka mērījumu rezultātus, kuru ieguvu organizēja Vides Risinājumu Institūts (turpmāk tekstā VRI). Lauka mērījumi tika veikti 270 kokiem 6 testa apgabalos (skat. att. 3.2., izvēloties aerofotogrāfijā skaidri redzamus koku vainagus. Koku novietojums tika nomērīts, izmantojot augstas precizitātes GPS un katram kokam tika reģistrēta koka suga.



Att. 3.2. Testa apgabali dabisko krāsu aerofotogrāfijā (©Vides Risinājumu Institūts). Lauka mērījumos noteiktie koku novietojumi iezīmēti ar dzelteniem punktiem, zaļā līnija parāda testa apgabala robežas.

Tā kā koku vainagu identifikācijas un atdalīšanas metožu testēšanai nepieciešami dati specifiskā formā, tad, vadoties pēc lauka mērījumiem un aerofotogrāfijām, autore manuāli iezīmēja nomērīto koku vainagu kontūras, testa apgabala robežas un koku vainagu nenosegtās teritorijas. Piemēru palīgdatiem skatīt attēlā 3.3.

Arī tālizpētes datus šim pētāmajam apgabalam nodrošināja VRI. Dati tika ievākti 2008. gada 13. jūnijā no plkst. 10:34 līdz 10:46. Saules azimuta leņķis bija no 185° līdz 191° un Saules augstuma leņķis no 55.95° līdz 55.65°. Multispektrālie dati tika ievākti, izmantojot ITRES Research hiperspektrālo sensoru CASI-1500, bet Lidar dati ar Optech Lidar kartēšanas sistēmu ALTM Gemini. Multispektrālo datu telpiskā izšķirtspēja ir 0.5 m/pikseli, bet Lidar punktu blīvums ir apmēram 4 punkti/ $m^2$ . Multispektrālo datu spektrālā izšķirtspēja ietver 13 frekvenču joslas:  $427.3 \pm 28.6$  nm,  $479.8 \pm 23.9$  nm,  $518.0 \pm 14.3$  nm,



Att. 3.3. Palīgdatu kopas piemērs vienam testa apgabalam. a) Testa apgabals 1 un lauka mērījumos noteiktās koku atrašanās vietas; b) manuāli iezīmētas atsevišķu koku vainagu kontūras; c) koku vainagu nenosegtā teritorija iekrāsota sarkana.

551.4 ± 19.1 nm, 597.9 ± 27.5 nm, 633.7 ± 8.4 nm, 671.9 ± 29.8 nm, 710.1 ± 8.4 nm, 728.0 ± 9.5 nm, 742.3 ± 4.8 nm, 761.4 ± 14.3 nm, 836.6 ± 60.8 nm un 934.3 ± 37.0 nm.

Datu pirmsapstrādi nodrošināja datu piegādātājs. Detalizētāku informāciju par datu ieguvu un pirmsapstrādi skatīt [20].

### 3. 2. A2: Salaspils, Lielvārdes, Ikšķiles, Stopiņu un Ropažu novadu administratīvā teritorija, Latvija

Kopējā pētāmā apgabala platība ir 864.7 km<sup>2</sup>, no kuriem apmēram 44.3 % aizņem mežs, bet 32.2 % lauksaimniecībā izmantojamā zeme (turpmāk saīsinājumā LIZ). No kopējās mežu platības 350.2 km<sup>2</sup> aizņem valsts īpašumā esošie meži. Vidzemes reģionam raksturīgs klimats ar agru sala iestāšanos rudenos, salīdzinoši garām ziemām, lielu nokrišņu daudzumu, salīdzinoši īsu veģetācijas periodu [93].

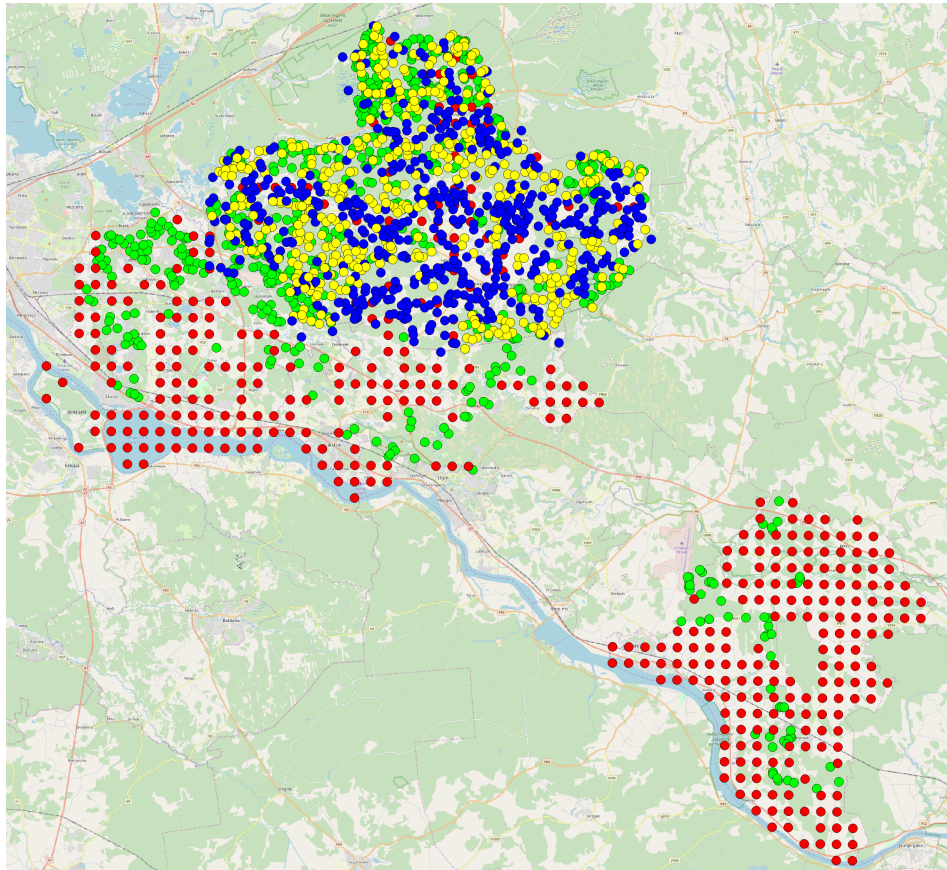
Dominējošās koku sugas ir parastā priedē (latīniski *Pinus sylvestris*, valdošā koku suga 61 % no kopējās valsts mežu teritorijas šajā apgabalā), parastā egļu (latīniski *Picea abies*, valdošā koku suga 13%) un bērzs (latīniski *Betula pendula*, valdošā koku suga 13%). Visbiežāk visas koku sugas ir sastopamas jaukto koku audzēs. Meži neaizņem lielus meža masīvus, bet gan veido mozaīku ar lauksaimniecības zemēm, purviem, apbūvētajām teritorijām un ūdens laukumiem.

Pētāmajam apgabalam bija pieejama nogabalu meža inventarizācijas datu bāze par valsts īpašumā esošajiem mežiem 20801 nogabalos. Datu bāze satur meža inventarizācijas ierakstus nogabala līmenī no 2002. līdz 2014. gadam. Šī datu bāze tika izmantota, lai manuāli sagatavotu zemes pārseguma klašu apmācības un testa datu kopas punktu formātā skatīt att. 3.4..

Apmācības datu kopa tika sagatavota sekojoši:

1. Koku vainagu noseģuma klases punktus veido Valsts mežu nogabalu poligonu centroīdas, kur kopējā krāja ir lielāka par nulli, inventarizācijas gads ne vecāks par 2012 un nogabala platība lielāka par 5 ha. Kopā 691 punkts.
2. Pārējie zemes pārseguma tipi tika apvienoti vienā klasē "Cits". Pārējo zemes pārseguma tipu iekļaušanai parauga datos tika ģenerēts regulārs punktu režģis, kur atstarpes





Att. 3.4. Apmācības un testa punktu izvietojums. Krāsu kodējums: sarkans - apmācības dati tipam "cits", zaļš - apmācības dati koku vainagu noseģuma klasei, zils - testa dati tipam "cits", dzeltens - testa dati koku vainagu noseģuma klasei. Pamatslānis: OpenStreetMap karte.

starp punktiem ir 1 km. No punktu reģģa tiek izņemti visi punkti, kas pārklģjas ar valsts meģu nogabalu poligoniem. Punkti, kuri bija novietoti tuvģk par 60 metriem robeģai ar citu zemes pģrseģuma tipu, tika nobģdģti vismaz 60 metru attģlumģ no šģs robeģas, padarot datu kopu īpaģi piemģrotu vidģjas izģķirtspģjas satelģtattģlu analģzei. Kopģ 433 punkti.

Neatkarģgs testa datu komplekts tika sagatavots Ropaģu novadam. Ropaģu novada teritorijģ pģc gadģjuma tika izvietoti 1000 punkti, kuru zemes pģrseģuma tips tika noteikts, izmantoģot ortofotokarģu vizuģlu analģzi. Ja pģc gadģjuma novietotais punkts atradģs tuvģk par 60 metriem robeģai starp daģģdiem zemes pģrseģuma tipiem, tad tas tika pģrvietots vismaz 60 metru attģlumģ no šģs robeģas. Rezultģtģ tģkai iegģti 465 koku vainagu noseģumam atbilstoģi testa punkti un 535 citam zemes pģrseģuma tipam atbilstoģi punkti.

Uzdevuma T1 veikģšanai tika izmantoti Landsat TM, ETM+, OLI, Sentinel-2A un Sentinel-2B satelģtattģli, bet uzdevuma T2 realizģcijai Latvģjas Geotelpiskģs informģcijas aģģntģras (turpmģk tekstģ LģģIA) ortofotokartes.

Telpiskģ izģķirtspģģa ir 30 m/pikseli Landsat un 10 m/pikseli - 20 m/pikseli Sentinel-2A, Sentinel-2B multispektrģlajģm joslģm.

Landsat OLI koku vainagu noseģuma kartģģšanai iespģjams lietot 8 frekvenģu joslas: 0.43 - 0.45  $\mu m$  (krasta, aerosolu josla), 0.45 - 0.51  $\mu m$  (zils, B), 0.53 - 0.59  $\mu m$  (zaļģ, G),

0.64 - 0.67  $\mu\text{m}$  (sarkans, R), 0.85 - 0.88  $\mu\text{m}$  (tuvais infrasarkanais, NIR), 1.57 - 1.65  $\mu\text{m}$  (īso viļņu infrasarkanais, SWIR1), 2.11 - 2.29  $\mu\text{m}$  (īso viļņu infrasarkanais, SWIR2), 1.36 - 1.38  $\mu\text{m}$  (dūmakas josla).

Landsat ETM+: 0.45 - 0.52  $\mu\text{m}$  (zils, B), 0.52 - 0.6  $\mu\text{m}$  (zaļš, G), 0.63 - 0.69  $\mu\text{m}$  (sarkans, R), 0.77 - 0.90  $\mu\text{m}$  (tuvais infrasarkanais, NIR), 1.55 - 1.75  $\mu\text{m}$  (vidējais infrasarkanais, MIR), 2.09 - 2.35  $\mu\text{m}$  (īso viļņu infrasarkanais, SWIR).

Landsat TM: 0.45 - 0.52  $\mu\text{m}$  (zils, B), 0.52 - 0.6  $\mu\text{m}$  (zaļš, G), 0.63 - 0.69  $\mu\text{m}$  (sarkans, R), 0.76 - 0.90  $\mu\text{m}$  (tuvais infrasarkanais, NIR), 1.55 - 1.75  $\mu\text{m}$  (vidējais infrasarkanais, MIR), 2.08 - 2.35  $\mu\text{m}$  (īso viļņu infrasarkanais, SWIR).

Sentinel-2: 490  $\pm$  65 nm (zils, B), 560  $\pm$  35 nm (zaļš, G), 665  $\pm$  30 nm (sarkans, R), 705  $\pm$  15 nm (sarkanā robeža, RE), 740  $\pm$  15 nm (RE), 783  $\pm$  20 nm (RE), 842  $\pm$  115 nm (NIR), 865  $\pm$  20 nm (NIR), 1610  $\pm$  90 nm (SWIR), 2190  $\pm$  180 nm (SWIR).

Laika izšķirtspēja Landsat viena sensora attēlu gadījumā ir 16 dienas, bet Sentinel-2 10 dienas viena sensora gadījumā un 5 dienas, apvienojot abu Sentinel-2 platformu datus. Laika izšķirtspēju iespējams palielināt vēl vairāk, kombinējot Landsat un Sentinel datus.

Konkrētu satelītattēlu identifikācijas numuri un ieguves datumi parādīti konkrēto metožu apakšnodaļās.

Aerofotogrāfēšanas darbus LĢIA kartogrāfiskās datu bāzes atjaunināšanai piektajā ciklā (2013. - 2015. gads) veica Polijas uzņēmums MGGPAero, izmantojot divus multispektrālos sensorus. Latvijas centrālajai daļai dati tika iegūti, izmantojot UltraCam Eagle sensoru. Pārējiem apgabaliem mērījumiem tika izmantots DMCI sensors. Datu ieguve notika 2013. gada 1., 2., 21., 23., 26. un 30. jūnijā zaļās veģetācijas sezonā. Telpiskā izšķirtspēja LĢIA ortofotkartēm ir 0.25 m pilsētu apkārtņē, 0.4 m pārējie apgabali. Spektrālā izšķirtspēja LĢIA ortofotkartēm ietver trīs redzamās gaismas frekvenču joslas un tuvā infrasarkanā joslu.

### 3. 3. A3: Ventspils apkārtnē


Ventspils pētāmais apgabals aizņem aptuveni 681.2  $\text{km}^2$  no 21.4108° N - 21.8413° N un no 57.3116° E līdz 57.5438° E. Reljefs ir ļoti līdzens, salīdzinot ar pārējo Latvijas teritoriju un pētāmajā apgabalā atrodas vairākas purvu teritorijas. Mežu teritorijās dominē priežu audzes.

Apmācības datu kopa tika izveidota, regulāri izvietojot 2601 punktu. Testa dati ietver mazāku apgabalu, taču punktu regulārais noseģums ir blīvāks. Testa dati satur 1549 punktus. Punktu izvietojumu skatīt att. 3.5.

Klases punktiem tika noteiktas vizuāli, analizējot ortofotokartes un punkti tika sagrupēti 5 klasēs: 1) ūdens, 2) koku vainagu noseģums, 3) lauksaimniecības zeme, 4) purvs un 5) apbūve.

Uzdevuma T1 veikšanai tika izmantoti Sentinel-2A un Sentinel-2B satelītattēli, bet uzdevuma T2 realizācijai Latvijas Geotelpiskās Informācijas Aģentūras (turpmāk tekstā LĢIA) ortofotokartes un Lidar dati.

Konkrētu satelītattēlu identifikācijas numuri un ieguves datumi parādīti konkrēto metožu apakšnodaļās.



Att. 3.5. Apmācības un testa punktu izvietojums. Krāsu kodējums: sarkans - apmācības dati, zils - testa dati. Pamatslānis: OpenStreetMap karte.

Krāsu infrasarkanās ortofotokartes iegūtas 07.05.2016. sezonā, kad daļai koku lapas jau ir izplaukušas, bet daļai vēl nav. Ortofotokaršu parametri ir tieši tādi paši kā apgabala A2 gadījumā.

LĢIA Lidar dati iegūti 29.05.2016 un to vidējais punktu blīvums ir apmēram  $7 \text{ punkti}/m^2$ . Detalizēts datu apraksts parādīts LĢIA specifikācijās [24, 25].

**Gan VRI, gan LĢIA datu kopu gadījumā jāpiebilst, ka ortofotokaršu ģeometriskās korekcijas ir veiktas, izmantojot fotogrametrijas metodi, tādēļ ir novērojamas nesistemātiskas ģeometriskas nobīdes starp ortofotokartēm un Lidar datiem.**

## 4. Metodes koku vainagu naseguma kartēšanai

### 4. 1. Eksistējošie risinājumi

#### Praktiskais uzdevums

Veikt koku vainagu naseguma semantisko segmentāciju dažādas telpiskās izšķirtspējas tāluzpētes datos.

Vairumā studiju mežu vai koku vainagu naseguma teritoriju atdalīšana tiek iekļauta vispārīgā zemes pārseguma/lietojuma klasifikācijas shēmā, kur meži ir tikai viena no klasēm līdzās lauksaimniecības zemei, apbūvētām teritorijām, ūdens teritorijām un citām zemes pārseguma/lietojuma klasēm. Zemes lietojuma sadalījums klasēs, kas atkarīgs no konkrētā ģeogrāfiskā reģiona [99, 4], būtiski ietekmē klasifikācijas uzdevuma sarežģītību un sagaidāmo precizitāti. Plānošanas un menedžmenta mērķiem apmierinoša precizitāte ir virs 85% [4], taču specifisku uzdevumu veikšanai var būt nepieciešama augstāka precizitāte.

Saskaņā ar Latvijas likumdošanu (MK Noteikumi Nr. 562) zemes lietojums tiek iedalīts 8 vispārīgās klasēs: 01 - lauksaimniecībā izmantojamās zemes, 02 - mežs, 03 - krūmājs, 04 - purvs, 05 - ūdens objektu zeme, 06 - zeme zem ēkām, 07 - zeme zem ceļiem un 08 - pārējās zemes, bet zemes pārseguma klases netiek atsevišķi definētas.

Termins ”**mežs**” tiek definēts Meža likumā [1]: ”mežs ir ekosistēma visās tās attīstības stadijās, kur galvenais organiskās masas ražotājs ir koki, kuru augstums konkrētajā vietā var sasniegt vismaz piecus metrus un kuru pašreizējā vai potenciālā vainaga projekcija ir vismaz 20 procentu no mežaudzes aizņemtās platības”.

Veicot datu apstrādi mežu monitoringa vajadzībām, ir būtiski atšķirt terminus ”mežu teritoriju identifikācija” un ”koku vainagu naseguma identifikācija”. Mežu teritoriju identifikācijas mērķis ir atrast tās koku vainagu nasegtās teritorijas, kas atbilst likumos definētajam terminam ”mežs”. Koku vainaga projekcija ir viens no kritiskākajiem definīcijas parametriem, jo tā aprēķināšanai trūkst skaidri definētas ģeometriskās metodes [27], kā arī vainagu projekcijas lauka mērījumu veikšana prasa laikietilpīgu procedūru.

Meža teritoriju identifikāciju atvieglo vispirms veikta koku vainagu naseguma identifikācija. Tas nozīmē, ka vispirms tiek identificētas koku vainagu nasegtās teritorijas un pēc tam tiek veikta pārbaude, vai šie apgabali atbilst meža definīcijai.

**Šajā pētījumā koku vainagu naseguma klase tiek definēta kā koku vainagu projekciju nasegtās teritorijas neatkarīgi no tā, vai audze atbilst meža definīcijai saskaņā ar likumdošanu vai neatbilst.**

Visai Latvijas teritorijai ir pieejamas vairākas zemes pārseguma un koku vainagu naseguma globālās kartes, kas ir balstītas uz tāluzpētes datu apstrādi:

- **CORINE zemes pārseguma karte.** Latvijā sastopamās CORINE zemes pārseguma klases iedalāmas 5 lielās grupās: mākslīgās platības, lauksaimniecības platības, meži

un dabiskās platības, mitrzemes un ūdenstilpnes. Mežu teritorijas CORINE shēmā sīkāk tiek iedalītas platlapju mežā, skujkoku mežā, jauktā mežā, pārejošos mežu apgabalos un reti apaugušās teritorijās. CORINE programma ir 1985. gadā aizsākta Eiropas Savienības iniciatīva apkārtējās vides informācijas apkopošanai un koordinēšanai [12]. CORINE programma piedāvā bezmaksas zemes pārseguma kartes rastra formātā ar telpisko izšķirtspēju 100 m vai 200 m.

- **Maryland University** sagatavotās koku vainagu noseguma kartes [42].
- **Austrumeiropas teritorijai** sagatavotās koku vainagu noseguma kartes [91].
- Eiropas Komisijas Apvienotā Pētījumu centra (angl. *European Commission's Joint Research Centre*) **Eiropas mežu karte 2000** [2].

Zemes pārseguma/ lietojuma tipa noteikšanu, izmantojot multispektrālos tālizpētes datus, ierobežo fakts, ka multispektrālie sensori tiešā veidā novēro atstarojuma vērtības no Zemes virsmas, kuras veido spektrālās klases. Spektrālās klases ne vienmēr tiešā veidā ir saistītas ar zemes pārseguma un lietojuma klasēm, kas ir cilvēka definēti jēdzieni.

Koku vainagu noseguma noteikšanai multispektrālo un Lidar datu gadījumā populāras pieejas ir attēlu indeksu sliekšņošana, pikseļa līmeņa klasifikācija vai attēla segmentācija, kam seko klasifikācija.

Koku vainagu noseguma atdalīšanai tiek konstruēti īpaši veģetācijas indeksi un koku vainagu nosegtās teritorijas tiek atrastas, veicot indeksa sliekšņošana [11, 116]. Indeksa vērtības, kas atrodas noteiktā diapazonā, kuru nosaka sliekšņa vērtības, raksturo koku vainagus, bet pārējais diapazons atbilst citam zemes pārseguma tipam. Pētījumā [3] veģetācijas indekss NDVI tika pielietots, lai pētītu ne tikai koku vainagu nosegumu, bet arī lai raksturotu mežu teritoriju fragmentāciju. Pētījuma [27] autori izveidoja meža pēc likumā noteiktās definīcijas kartēšanas algoritmu, kas, izmantojot Lidar datus, ļauj atfiltrēt uz mežu neattiecināmus objektus un aprēķināt meža definīcijai nepieciešamos parametrus. Rezultātā tikai iegūta 96% kopējā precizitāte.

Pētījumā [81] tika pielietota inovatīva tehnoloģija: multispektrālais Lidar, un no datiem tika aprēķināti trīs spektrālie indeksi. Ar šo indeksu palīdzību izdevās sasniegt 96.8% precizitāti 3 zemes pārseguma tipu gadījumā (zeme-ūdens, veģetācija, apbūve).

Indeksu izmantošana ir relatīvi vienkārša pieeja, kas ne vienmēr spēj efektīvi aprakstīt meža teritoriju dažādību, tādēļ biežāk zemes pārseguma noteikšana tiek veikta, izmantojot mašīnmācīšanās algoritmus.

Zemes pārseguma klasifikācijā populārākie vadītās klasifikācijas algoritmi:

1. **Maksimālās ticamības klasifikators (MLC)** (angl. *Gaussian maximum likelihood*) [105, 98, 83, 101] - parametrisks, stingrais, pikseļa līmeņa, spektrālais klasifikators. Šo algoritmu iespējams pielietot gadījumos, kad klašu deskriptoru datu sadalījums atbilst normālajam jeb Gausa sadalījumam. Ja šis nosacījums izpildās, tad klašu parauga datu deskriptori tiek reprezentēti ar to vidējo vērtību vektoru un kovariāciju matricu.

Deskriptoru vidējo vērtību vektors un kovariāciju matrica tiek lietoti, lai nodefinētu klases deskriptoru datu sadalījuma funkciju un katram klasificējamam pikselim tiek aprēķināta ticamība, ar kādu tas pieder katrai klasei. Pikselis tiek piešķirts klasei ar augstāko ticamību.

2.  **$k$  Tuvāko kaimiņu klasifikators** (angl. *k nearest neighbors*, kNN) [40] - neparametrisks, stingrais klasifikators. No parauga datiem netiek veidots modelis. Tā vietā klasificējamais pikselis tiek salīdzināts ar visiem parauga datu pikseliem un piešķirts tai klasei, kurai pieder vairākums tā  $k$  skaita tuvāko kaimiņu. kNN šajā darbā detalizētāk apskatīts nodaļā "k-tuvāko kaimiņu metode".
3. **Support vector machine (SVM)** [82, 84, 49] - spektrālās klases deskriptoru telpā tiek atdalītas ar lēmuma virsmām.
4. **Mākslīgo neironu tīkli (ANN)** (angl. *Artificial Neural Networks*) [54, 14] - vispārīga tēlu atpazīšanas metode, kurā ar skaitļošanas elementiem tiek imitēta smadzeņu darbības vispārīga koncepcija.
5. **Jaukto pikseļu analīze** (angl. *Spectral Mixture analysis*) [104] - jaukto pikseļu analīzes metode. Jauktā pikseļa atstarojums tiek uzskatīts par zemes pārseguma tipu atstarojuma lineāru kombināciju, kura svērta, atkarībā no katra zemes pārseguma tipa telpiskā noseģuma pikselim atbilstošajā apgabalā. Risinot pārdefinētu lineāru vienādojumu sistēmu ar optimizācijas kritēriju, rezultātā tiek iegūts novērtējums, cik % no pikselim atbilstošās teritorijas aizņem katrs zemes pārseguma tips. Uzdevuma risināšanai nepieciešama tīro zemes pārseguma tipu spektru datu bāze. Papildu spektru reprezentativitātes nodrošināšanai, problēmas sagādā grūti atšķiramie jauktie pikseļi pēc būtības un fakts, ka pikseļa atstarojumu ietekmē arī tā blakus esošie pikseļi [108].
6. **Lēmumu balstītās sistēmas (klasifikācijas koki, *random forests*)** izmanto nosacījumu virknes, kas pārbauda deskriptoru un citu ievades datu vērtības un izvada lēmumu par objekta piederību klasei. Par vienkāršāko lēmumu balstīto sistēmu var uzskatīt attēlu sliekšņošanu (angl. *image thresholding*), kuras ietvaros pikseļu atstarojumu vērtības frekvenču joslās vai citi multispektrālo datu pārveidojumi tiek salīdzināti ar divām sliekšņa vērtībām [113]. Ja pikseļa vērtība ir lielāka par apakšējo sliekšni, bet mazāka par augšējo sliekšni, tad pikselis atbilst mežu teritorijām. Sarežģītākas klasifikācijas metodes izmanto klasifikācijas kokus un *random forest* algoritmus.

Zemes pārseguma klasifikācijā biežāk lietotie nevadītie klasifikācijas algoritmi:

1. **k-means** [79] algoritma gadījumā lietotājam ir jānorāda sagaidāmais spektrālo klašu skaits  $k$  un iterāciju ceļā tiek atrastas  $k$  spektrālās klases. ISODATA gadījumā spektrālo klašu skaits tiek atrasts algoritma izpildes laikā. Spektrālās klases pēc tam ir jāpiešķir zemes pārseguma klasēm, izmantojot vadītās klasifikācijas algoritmu vai analizējot datus vizuāli.

2. **Fuzzy c-means** [28] ir nevadītās klasifikācijas algoritms, kas realizē nestingro klasifikāciju, t.i. pikselis var daļēji piederēt vairāk kā vienai zemes pārseguma klasei.

Tipiskas pieejas hibrīdajai klasifikācijai ir [78]:

1. izmantot nevadīto klasifikāciju, lai atrastu deskriptoru klases un pielietot vadīto klasifikāciju, lai piešķirtu deskriptoru klasēm zemes pārseguma klasi,
2. pielietot klāsterizāciju apmācības datiem, lai atrastu unimodālas klases un pielietot vadītās klasifikācijas algoritmus, izmantojot atlasītos apmācības datus.

Piemērota zemes pārseguma klasifikācijas algoritma izvēle ir atkarīga no algoritma spējas apstrādāt trokšņainus ieejas datus, sarežģītas deskriptoru telpas un izmantot nelielu apmācības datu apjomu klasifikācijas uzdevumu veikšanā [95].

Pētījumā [105] tika salīdzinātas MLC, SVM un ANN metodes un rezultātā tika secināts, ka ANN precizitāte ir augstāka, bet tikai par 2 %. Tas nozīmē, ka klasifikācijas precizitāti vislielākajā mērā nosaka klašu atšķiramība ieejas datos, bet algoritma izvēle to ietekmē mazāk. Apskatā [57], savukārt, uzsvērts, ka SVM ir efektīvākais algoritms, taču arī kNN daudzās studijās ir sasniedzis augstu precizitāti un pateicoties savai vienkāršībai ir viegli izmantojams. Pētījumā [80] vienam un tam pašam attēlam tika pielietots viens vadītās klasifikācijas (maksimālās ticamības) un viens nevadītās klasifikācijas (ISODATA) algoritms. Rezultātā tika secināts, ka vadītā klasifikācija sniedz par apmēram 10 % augstāku precizitāti un rezultāti ir mazāk trokšņaini.

Ideālai klasifikācijas metodei ir jābūt precīzai, atkārtojamai, robustai, spējīgai izmantot attēlu informāciju pilnvērtīgi, vienmērīgi pielietojamai un objektīvai.

Papildu algoritmu izvēlei, jāizlemj arī kādi deskriptori tiks iekļauti klasifikācijas procesā. Kādas frekvenču joslas vai attēlu transformācijas būtu noderīgākās? Vai papildus spektrālajiem deskriptoriem izmantot arī telpiskos un temporālos deskriptorus? Avotā [57] veikts literatūras apskats par vadītā klasifikatora un deskriptoru izvēli. Apskatot vairāk kā 200 pētījumus autori secināja, ka kopējo precizitāti būtiski paaugstina tekstūras deskriptoru pievienošana, bet mazākā mērā papildu informācija, dažādos laika periodos un no dažādiem leņķiem iegūti attēli.

Daudzus klasifikācijas algoritmus ietekmē dimensionalitātes problēma: izmantojot vairāk deskriptoru klasifikācijas precizitāte krītas, ko tikai daļēji var kompensēt palielinot apmācības datu daudzumu [21].

Vidējas izšķirtspējas datus parasti klasificē pikseļa līmenī, taču augstas telpiskās izšķirtspējas attēliem pirms klasifikācijas ir rekomendējams veikt attēla segmentāciju reģionos. Augstas izšķirtspējas attēlos ir novērojamas sīkas detaļas, kas dažādiem zemes pārseguma tipiem var būt līdzīgas. Ja vidējas telpiskās izšķirtspējas gadījumā gandrīz visus zemes pārseguma tipus var atšķirt, izmantojot spektrālās vērtības, tad augstā izšķirtspējā zemes pārseguma klasi var definēt arī specifiska tekstūra.

Pētījumā [60] mežu teritorijas tika noteiktas, izmantojot segmentācijas algoritmu, kas realizēts *eCognition* programmatūrā un reģioni tika klasificēti, izmantojot maksimālās

ticamības algoritmu. Landsat datu gadījumā tika sasniegta kopējā precizitāte no 93 līdz 96 %. Analīzes rezultāti vienas pētāmās teritorijas dažādiem attēliem parādīja, ka 6.8% atpazīto klašu nesakrīt.

*eCognition* segmentācijas algoritms tika izmantots arī pētījumā [77], lai apstrādātu QuickBird satelītattēlus. Reģionu klasifikācija tika veikta, izmantojot klasifikācijas kokus un k-tuvāko kaimiņu metodi. Kopējā precizitāte labākajā gadījumā sasniedza 80% un autori secināja, ka klasifikācijas koks sniedz labākus rezultātus nekā kNN.

Apskata rakstā [112] apkopoti vairāk kā 500 zemes pārseguma un zemes lietojuma klasifikācijas eksperimenti laika periodā 15 gadus pirms 2005. gada, izmantojot tālzipētes datus. Apskatā tika secināts, ka 15 gadu laikā klasifikācijas precizitāte nav nozīmīgi paaugstinājusies un vidējie rādītāji kopējai precizitātei ir 76.2 % ar standarta novirzi 15.59%, kappā koeficientam 0.656 ar standarta novirzi 0.198. Vidējais klasificētais klašu skaits ir 8 ar standarta novirzi 4.6 un izmantoto pazīmju skaits 7.85 ar standarta novirzi 11.54. Satelītdatu telpiskā izšķirtspēja relatīvi maz ietekmē klasifikācijas precizitāti, ņemot vērā, ka augtas telpiskās izšķirtspējas sensoriem parasti ir mazāka spektrālā izšķirtspēja. Apskata rakstā [47] kopējā klasifikācijas precizitāte dažādām meža klasēm, sākot no jaunaudzēm un beidzot ar cērtamgatavības audzēm, bija robežās no 65 - 85%, bet iekļaujot analīzē vēl citas zemes pārseguma klases precizitāte paaugstinājās virs 90 %.

Attēlā 4.1. apkopota mežu teritoriju klasifikācijas precizitāte vairākiem doktora darba ietvaros apskatītajiem zinātniskajiem rakstiem, atkarībā no pētāmā apgabala ģeogrāfiskā novietojuma.



Att. 4.1. Dažādos pētījumos sasniegtā mežu teritoriju klasifikācijas precizitāte.

Kopš 2015. gada īpaša interese attēlu klasifikācijas un objektu atpazīšanas uzdevuma veikšanai tiek pievērsta dziļajai apmācībai un konvolūcijas neironu tīkliem (konvNN). Konvolūcijas neironu tīklu darbības principi sīkāk aprakstīti nodaļā "Konvolūcijas neironu tīkla U-Net pielietojums".



Efektīvai konvNN pielietošanai nepieciešams liels apmācības datu apjoms. Kritiskākais jautājums šajā kontekstā ir saistīts nevis ar tālzpētes datu trūkumu, bet ar augstas kvalitātes palīgdatu trūkumu. Datu trūkumu risina, izmantojot jau uz cita tipa attēliem, piemēram, ImageNet datu bāzes, apmācītus modeļus un mākslīgi palielinot datu kopu, attēlus rotējot un pieskaitot troksni [102]. Iepriekšapmācīto modeļu izvilktais pazīmes ir iespējams veiksmīgi pārnest uz tālzpētes attēlu kontekstu [48]. Castelluccio et. al. [13] testēja iepriekšapmācītus CaffeNet un GoogLeNet arhitektūras modeļus un secināja, ka iepriekšapmācīto modeļu augstāko slāņu pielāgošana apmācības procesā sniedz augstāku precizitāti nekā tikai beidzamo slāņu koriģēšana. Langkvist et. al. [63] veica pikseļa līmeņa pilsētvides attēlu klasifikāciju 5 zemes pārseguma tipos, datu kopā apvienojot gan multispektrālos datus, gan virsmas modeli, un rezultātā sasniedza 94.49% kopējo precizitāti. Mahdianpari et. al. [75] salīdzināja vairākas konvolūcijas tīklu arhitektūras ar citiem populāriem algoritmiem RapidEye satelītattēlu klasifikācijai un rezultātā ieguva ievērojamu precizitātes uzlabojumu: InceptionResNetV2 96.17%, ResNet50 94.81%, Xception 93.57%, Support Vector Machine (SVM) 74.89% un Random Forest(RF) 76.08%.

#### **Problēmas un izaicinājumi uzdevuma realizācijā:**

1. **Zemes pārseguma klašu definēšana un sakarības ar spektrālajām klasēm.** Zemes pārseguma klases ir cilvēka ieviests jēdziens un nav tieši saistīts ar saņemto signālu no satelītu sensoriem. Lauka dati šādā ziņā ir subjektīvi [112]. Ideālā gadījumā zemes pārseguma klasēm atbilst deskriptoru klases, kas savstarpēji nepārklājas un kurām ir zemas klases iekšējās variācijas [95].
2. **Jaukto pikseļu problēma.** Mežu teritoriju kontekstā jauktie pikseļi sastopami uz meža nogabalu robežām ar citu zemes pārseguma klasi un audzēs ar zemu koku vainagu nosejumu. Jaukto pikseļu problēma eksistē jebkuras telpiskās izšķirtspējas datus, taču īpaši tie ietekmē stingrās klasifikācijas rezultātus vidējas telpiskās izšķirtspējas satelīt-datos, jo, atkarībā no klasifikācijas algoritma apmācības, jauktie pikseļi tiek piešķirti vienai vai otrai zemes pārseguma klasei, lai gan patiesībā pikselim atbilstošā teritorija uz zemes ietver abas zemes pārseguma klases. Jaukto pikseļu klasifikācijai visbiežāk tiek lietota faziklasifikācija un jaukto pikseļu spektrālā analīze.
3. **Objektivitāte precizitātes novērtējumos** ir viena no lielākajām problēmām tālzpētes gala produktu uzticamības un pielietojamības analīze. Pētījumā [30] apskatīti 8 faktori, kas ietekmē precizitātes novērtējumu objektivitāti: precizitātes raksturlielumu izvēle, paraugu ņemšanas metodoloģija, kļūdas raksturlielumu tips, lauka mērījumu un citu palīgdatu precizitāte, kļūdu telpiskais sadalījums, kļūdu relatīvais nozīmīgums, kļūdu matricas pareizs pielietojums, zemes pārseguma izmaiņu gala produktu precizitātes novērtējumi. Apstrādājot atsevišķi dažādos datumos uzņemtus attēlus, ir svarīga klasifikācijas rezultātu saderība. Izmaiņu noteikšanā saderība ir pat būtiskāka nekā kopējā precizitāte [34]. Tāpat arī klasifikācijas rezultātu praktiskai izmantošanai svarīgāk ir

saprast kādos gadījumos rezultāti ir uzticami, bet kādos gadījumos informācija jālieto piesardzīgi.

4. **Parauga un testa datu sagatavošana**, nodrošinot to kvalitāti un reprezentativitāti. Ideālā gadījumā parauga datu komplektam būtu jāietver visas būtiskākās deskriptoru variācijas klases iekšienē un jābūt telpiski vienmērīgi sadalītiem pētāmajā reģionā.
5. **Klasifikācijas mērogi** - lielākā daļa satelītattēlu klasifikācijas algoritmu strādā pikseļa līmenī, taču atsevišķu zemes pārseguma klašu gadījumā šāds mērogs nav jēgpilns, tādēļ nepieciešami pētījumi, kuru mērķis vairāk tiek koncentrēts uz mēroga jautājumiem [95]. Pētījumā [103] dažādas pieejas neironu tīklu apmācībā tika testētas 8 zemes pārseguma klasēm un rezultātā nelielu attēla apakšapgabalā klasifikācija, izmantojot gan spektrālos, gan temporālos, gan telpiskos deskriptorus sasniedza 97.21 % precizitāti, bet viena attēla uz pikseļa balstīta sistēma tikai 64.74%.
6. **Lietotājam draudzīga, robusta programmatūra**. Klasifikācijas metodes, kuru realizācijai nepieciešama intensīva lietotāja līdzdalība un specifiskas zināšanas, praktisko problēmu risināšanai nav piemērotas, tādēļ tālizpētē aktuāla ir lietotājam draudzīgu un robustu metožu izstrāde, uzsvāru liekot uz liela datu apjoma apstrādi ar minimālu cilvēka līdzdalību [41].
7. **Konvolūcijas neironu tīklu apmācības stratēģija**. Konkrētā uzdevuma veikšanai ir būtiski noteikt optimālu tīkla arhitektūru, parametrus un apmācības stratēģiju.

Lai arī ir pieejamas globālās koku vainagu noseģuma kartes, lokāli pielāgotiem risinājumiem ir sagaidāma augstāka precizitāte. Taču lokālu risinājumu sagatavošanu apgrūtina sarežģītā mašīnmācīšanās algoritmu pielietošana. Metodēm vajadzētu būt nejutīgām pret unikālajiem apstākļiem attēla ieguves brīdī un pēc iespējas mazāk atkarīgām no lietotāja ievadītajiem parametriem vai lietotāja sagatavotajiem parauga datiem.

Ortofotokaršu gadījumā ir nepieciešamas metodes, kas spēj apstrādāt attēlu mozaikas, bez metadatiem un veikt mežu teritoriju atpazīšanu ātri.

Tā kā Latvijā izteikti ir novērojami visi četri gadalaiki, ir nepieciešams pētījums par sezonālās un unikālo apstākļu ietekmi (atmosfēra, apgaismojums) uz mežu teritoriju atpazīšanu. Šāda pētījuma praktiskais rezultāts ir papildināta zināšanu bāze par to vai un cik efektīvi iespējams apvienot dažādu sezonu klasifikācijas rezultātus vienā datu produktā.

Papildu nepieciešami arī salīdzinošie pētījumi ortofoto klasifikācijas rezultātiem un vidējas telpiskās izšķirtspējas satelītattēlu klasifikācijas rezultātiem, lai noteiktu satelītattēlu iespējas un ierobežojumus Latvijas apstākļu gadījumā.

## 4. 2. Piedāvātie risinājumi

Šajā apakšnodaļā uzskaitīti promocijas darbā sasniegtie rezultāti un pamatota to no- vitāte.

**Promocijas darba rezultāti koku vainagu noseģuma kartēšanā:**

1. Izstrādāta hibrīdās klasifikācijas darbplūsma koku vainagu noseģuma kartēšanai, izmantojot vidējas telpiskās izšķirtspējas multispektrālos satelītattēlus un zemas kvalitātes apmācības datus.

Darbplūsma ietver jau labi pazīstamas metodes kā kNN un FCM. Tā atšķiras ar stabilitātes testa iekļaušanu un iespēju pievienot t.s. "pārliecības līmeni" gala rezultātiem, kas lietotājam ļauj novērtēt, kuras spektrālās klases ir atpazītas pārliecinoši no datu apstrādes viedokļa. Pārliecības līmenis ļauj novērtēt rezultātu uzticamību.

Nevadītās klasifikācijas algoritmiem, kuros ir iestrādāta automatizēta spektrālo klašu skaita noteikšana, ir tendence detektēt mazāku klašu skaitu, kas var apgrūtināt zemes pārseguma klašu robežgadījumu pilnvertīgu reprezentāciju. Šī iemesla dēļ, hibrīdās klasifikācijas darbplūsmā FCM algoritmam tiek iestatīts augsts sākotnējais spektrālo klašu skaits un, stabilitātes testu rezultātā, tas tiek samazināts līdz pirmajam stabilajam gadījumam.

Hibrīdā darbplūsma ļauj izmantot zemākas kvalitātes apmācības datus nekā nepieciešami vadītās klasifikācijas algoritmiem un apmācības datu apjoma nodrošināšana bieži vien ir problēmātiska pieejamo laika un finanšu resursu dēļ.

2. Veikts pētījums (gadījumu izpētes) par unikālo apstākļu satelītattēlu ieguves brīdī un mežaudžu raksturlielumu ietekmi uz koku vainagu noseģuma kartēšanas rezultātu uzticamību un precizitāti.

Zemes pārseguma klasifikācijas uzdevuma sarežģītību ietekmē gan datu kvalitāte, gan zemes pārseguma klašu spektrālās un telpiskās īpašības, tādēļ metožu veikspēja var atšķirties dažādu ģeogrāfisko apgabalu gadījumā. Doktora darba ietvaros veikts detalizēts pētījums par klasifikācijas metožu rezultātiem Latvijas mežu kartēšanā, meklējot atbildes uz zemāk uzskaitītajiem pētījuma jautājumiem.

3. Salīdzinātas trīs dažādas metodes koku vainagu noseģuma kartēšanai, izmantojot ļoti augstas telpiskās izšķirtspējas tālizpētes datus: 1) vienkāršota sliekšņošana, 2) lēmumu balstīta metode, 3) konvolūcijas neironu tīkls U-Net.

Salīdzinājums ir unikāls no tāda aspekta, ka tas veikts, izmantojot valsts mēroga ortofotokartes un Lidar datus. Līdz ar to, tika novērtēta metožu pielietojamība plašās teritorijās un to piemērotība vispārīga izmantojuma datu apstrādē. Salīdzinājumā iekļauts arī konvolūcijas neironu tīkla pielietojums, sekojot mūsdienu tendencēm datorredzes uzdevumu risināšanā.

#### **Galvenie pētāmie jautājumi:**

1. Kā koku vainagu noseģuma klasifikācijas rezultātus ietekmē unikālie apstākļi attēla ieguves brīdī (atmosfēras ietekme, apgaismojums, gadalaiks)?
2. Kādas ir sakarības starp nevadītās klasifikācijas identificētajām spektrālajām klasēm un meža inventarizācijas parametriem?



draudzīga hibrīdās klasifikācijas darbplūsma. Dažādu algoritma un citu parametru gadījuma izpētes sniegtas algoritma apraksta apakšnodaļās, bet apkopotie rezultāti un diskusija nodaļas beigās.

#### 4. 4. 1. $k$ - tuvāko kaimiņu metode

**Ievades dati:** apstrādājamais attēls vai tā pārveidojumi, precīzi parauga dati.

**Algoritma iekšējie parametri:**  $k$  - const.

Viena no vienkāršākajām, bet tajā pašā laikā efektīvākajām attēlu klasifikācijas metodēm ir  $k$  tuvāko kaimiņu metode (turpmāk tekstā kNN). kNN ir spektrālās, vadītās, neparametriskās klasifikācijas metode, kas katram atsevišķam pikselim piešķir vienu zemes pārseguma tipu. Termins "spektrālā" nozīmē to, ka kNN vienkāršākajā realizācijā lieto tikai viena pikseļa deskriptorus, neizmantojot telpiskās sakarības starp vairākiem pikseliem. Savukārt, termins "neparametriskā" nozīmē, ka kNN neizmanto kādu konkrētu parauga datu deskriptoru aprakstošo modeli. Metodes pamatprincips ir salīdzināt klasificējamo pikseli ar visiem parauga pikseliem un piešķirt nezināmajam pikselim tādu zemes pārseguma klasi, kāda ir tā  $k$  skaita tuvākajiem kaimiņu pikseliem parauga datos. Pirmo reizi kNN literatūrā ir minēts 1951. gadā [86], savukārt tālīzpētes datu klasifikācijā meža inventarizācijas atvieglošanai tas tiek testēts un lietots kopš 1990. gada [32].


Vispirms apskatīsim viena pikseļa  $p_n$  klasifikāciju divu deskriptoru gadījumā - katru parauga pikseli apraksta divas satelītattēla frekvenču joslu vērtības  $f_1$  un  $f_2$ , piemēram, tā varētu būt parauga pikseļa vērtība zilā un tuvā infrasarkanā starojuma attēlā. Katru parauga pikseli  $p_i$  raksturo vektors  $p_i = [f_{1,i}, f_{2,i}]$  un katram parauga pikselim  $p_i$  ir piesaistīts zemes pārseguma klases numurs  $\omega_i$ . Mēs apskatīsim divu klašu gadījumu: Klase 1 ir koku vainagu nosegums, Klase 2 - cits zemes pārseguma tips. Šādus divdimensionālus piemērus ir ērti analizēt izkliedes diagrammu veidā. Pirmā deskriptora vērtību variācijas ir parādītas uz  $x$  ass, bet otrā deskriptora vērtību variācijas uz  $y$  ass. Atsevišķas spektrālās klases izkliedes diagrammā var atpazīt kā punktu mākoņus jeb reģionus ar relatīvi augstu punktu blīvumu un atstarpēm starp tiem [79].

Attēlā 4.2. a) ar atšķirīgiem simboliem iezīmēti parauga dati, kuru zemes pārseguma klase jau ir zināma (to nosaka no palīgdatiem). Diagrammai pievienots arī pikselis  $p_n$  (apzīmēts ar "\*\*"), kura klase nav zināma un kuru nepieciešams klasificēt, izmantojot kNN metodi.

No klasificējamā pikseļa  $p_n$  deskriptoru telpā tiek aprēķināts parastais Eiklīda attālums līdz visiem parauga pikseliem  $p_i$ :

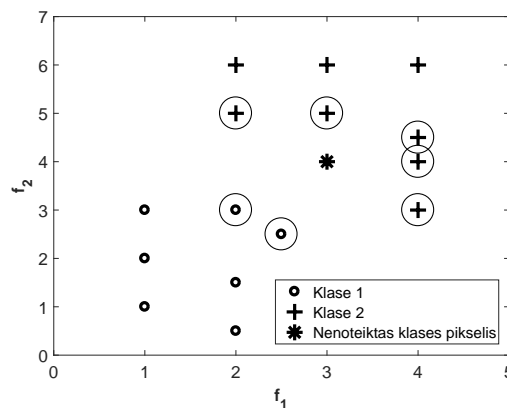
$$d(p_n, p_i) = \sqrt{(f_{1,n} - f_{1,i})^2 + (f_{2,n} - f_{2,i})^2} \quad (4. 1.)$$

Attēlā 4.2. b) attālums iezīmēts ar melnām, raustītām līnijām. Rezultātā aprēķinātais attālums ir vektors  $d$  ar izmēru  $N \times 1$ , kur  $N$  ir kopējais parauga pikseļu skaits.



Att. 4.2. a) Izklīdes diagrammā iezīmēti parauga pikseļi un pikselis, kura zemes pārseguma klasi vēlami noskaidrot. b) Izklīdes diagrammā iezīmēts parastais Eiklīda attālums no klasificējamā pikseļa līdz visiem parauga pikseļiem.

Vadoties pēc attālumu vektora  $d$ , tiek atlasīti  $k$  skaita pikseļi, līdz kuriem ir vismazākais attālums, respektīvi klasificējamā pikseļa  $p_n$   $k$  tuvākie kaimiņi. Nezināmais pikselis tiek piešķirts tai zemes pārseguma klasei, kāda ir visbiežāk sastopama ( $k$  tuvāko kaimiņu zemes pārseguma klašu birku moda) starp  $k$  tuvāko kaimiņu zemes pārseguma klasēm. Attēlā 4.3. atlasīti 7 tuvākie kaimiņi un nenoteiktās klases pikselim  $p_n$  tiek piešķirta Klase 2, jo pieci tuvākie kaimiņi pieder Klasei 2, bet tikai divi kaimiņi pieder Klasei 1.



Att. 4.3. Izklīdes diagrammā ar apli ir apvilkti  $k$  (šajā gadījumā  $k = 7$ ) tuvākie klasificējamā pikseļa kaimiņi.

Vispārīgā gadījumā parasti iespējams aprēķināt vai nolasīt vairāk par divām deskriptoru vērtībām. Ja divu deskriptoru vietā mums ir pieejami  $g$  skaita deskriptori ( $p_i = [f_1, f_2, \dots, f_g]$ ), tad Eiklīda attālums vispārīgā formā izsakāms ar formulu:

$$d(p_n, p_i) = \sqrt{\sum_{j=1}^g (f_{j,n} - f_{j,i})^2}. \quad (4.2.)$$

Skaitļošanas laiku iespējams ietaupīt parastā Eiklīda attāluma vietā, rēķinot Manhatana attālumu:

$$d(p_n, p_i) = \sum_{j=1}^g |(f_{j,n} - f_{j,i})|. \quad (4. 3.)$$

Ja visu deskriptoru vērtības ir no viena vērtību intervāla, tad papildu operācijas nav obligātas. Piemēram, pikseļu intensitātes vērtības Landsat OLI satelītattēliem ir kodētas, izmantojot pelēko toņu skalu  $[0, 2^{16}]$ . Ja tiek izmantoti deskriptoru attēli, kuru vērtības var būt no dažādiem vērtību intervāliem, piemēram,  $[0, 2^{16}]$  vienam attēla slānim un  $[-1, 1]$  citam, tad ir jāveic vērtību standartizācija.

Viens no standartizācijas risinājumiem ir  $z$  - vērtības (angl. *z-scores*). Risinājuma galvenā priekšrocība ir iespēja to pielietot deskriptoriem, kuru vērtību teorētiskais intervāls nav zināms.

Deskriptoru vērtības saskaņā ar  $z$ -vērtību metodi pārrēķina sekojoši:

$$f_{i,n} = (f_{i,n} - m_{f_i})/\sigma_{f_i}, \quad (4. 4.)$$

kur  $f_{i,old}$  - sākotnējā  $i$ -tā deskriptora vērtība pikselim  $n$ ;

$m_{f_i}$  -  $i$ -tā deskriptora vidējā vērtība, kas aprēķināta, lietojot apmācības datus;

$\sigma_{f_i}$  -  $i$ -tā deskriptora standarta novirze, kas aprēķināta, lietojot apmācības datus.

Pēc atbalsta datu standartizācijas ir jā saglabā  $m_{f_i}$  un  $\sigma_{f_i}$ , jo katra klasificējamā pikseļa deskriptoriem pirms kNN procedūras pielietošanas ir jāveic standartizācija tieši tādā pašā veidā kā apmācības datiem.

Tuvāko kaimiņu skaitu izvēlas, veicot precizitātes izmaiņu pētījumus. Ja kopējā precizitāte, palielinot  $k$  skaitu par 1, nepalielinās vairāk kā par 5 %, tad uzskata, ka  $k$  palielināt vairs nav nepieciešams.

Papildu noteiktajai zemes pārseguma klasei iespējams aprēķināt arī, t.s. "pārliecības" līmeni:

$$C_o = n_{mode(\omega_k)}/k, \quad (4. 5.)$$

kur  $n_{mode(\omega_k)}$  - biežākās klases kaimiņu skaits;

$k$  - kopējais kaimiņu skaits.

Ja  $C_o = 1$ , tad visi kaimiņi pieder vienai zemes pārseguma klasei. Ja  $C_o < 1$ , tad daļa no kaimiņiem pieder citām klasēm, nevis izvēlētajai zemes pārseguma klasei. Jo pārliecības līmenis ir zemāks, jo dažādākām klasēm pieder pikseļa tuvākie kaimiņi. Tas nozīmē, ka šādu pikseļu klasifikācijas rezultātiem var uzticēties mazāk, nekā rezultātiem ar augstu pārliecības līmeni. Pārliecības līmeņa attēlu var izmantot papildus klasifikācijas rezultāta attēlam.

kNN testos kā deskriptori tika automatizēti ielasītas rastra attēlu vērtības no visām tālzipētes datu frekvenču joslām (izņemot aerosolu un termālā starojuma joslas), kas saskaņā ar kartes projekcijas koordinātēm atbilst parauga datu kopas punktiem. Apmācības datu piemēru skatīt att. 4.4. Pētījumā [76] tika secināts, ka parauglaukumu vidējā vērtība sniedz augstāku precizitāti nekā tikai punktu ielasīšana, taču VeA IZI VSRC pētījumos [38]

gadījumu izpētes parādīja, ka ne ļoti augstas precizitātes palīgdatu gadījumā punkta ielasīšana sniedz līdzīgu precizitāti kā parauglaukumu vidējo vērtību ielasīšana.

SHAPE_AREA	SHAPE_LEN	lu	B4	B5	B6	B7	B2	B3
32192.98310000...	2174.931822690...	1	6161.00000	8453.00000	6553.00000	5756.00000	7573.00000	6709.00000
58272.27335000...	1572.196033550...	1	6275.00000	8300.00000	6842.00000	5985.00000	7584.00000	6725.00000
57371.31645000...	1101.297023310...	1	6401.00000	8087.00000	6637.00000	6048.00000	7703.00000	6841.00000
37159.58985000...	1562.469344620...	1	6219.00000	8901.00000	6751.00000	5835.00000	7596.00000	6767.00000
33616.57975000...	1670.852103180...	1	6403.00000	8213.00000	6884.00000	6182.00000	7678.00000	6854.00000

Att. 4.4. Apmācības datu atribūtu tabulas piemērs.

### Pētāmais jautājums: kādi kNN parametri ir piemērotākie koku vainagu nose-guma kartēšanai?

kNN metodes iekšējie parametri tika novērtēti, veicot kNN *leave-one-out* precizitātes novērtējumus un izmantojot kopējo precizitāti *OA* kā rādītāju labākajai parametru izvēlei. *Leave-one-out* ietvaros katru parauga datu pikseli klasificē, lietojot visus pārējos parauga pikselus, izņemot no apmācības datiem pašu klasificējamo pikseli. kNN metodes galvenie iekšējie parametri ir *k* tuvāko kaimiņu skaits, attāluma aprēķināšanas metodika (M - Manhatana attālums, E - parastais Eiklīda attālums) un deskriptoru standartizācijas metodes pielietošana (*z-scores* metode, Z). Tabulā 4. 1. redzama kopējā precizitāte Ventspils pētāmajam apgabalam A3, klasificējot tikai 2 klases (koku vainagu nosegums un cits) ar dažādiem kNN parametriem. Ar burtiem S apzīmēts Sentinel 2A vai 2B satelītattēls, bet ar L - Landsat satelītattēls.

Attēla Nr.	k=1	k=3	k=5	k=7	k=9	k=11	k=13	k=15	k=17	k=19
S 01.05.17 M	0.902	0.917	0.921	0.922	0.923	0.924	0.922	0.921	0.919	0.919
S 01.05.17 M Z	0.907	0.921	0.925	0.923	0.923	0.923	0.923	0.919	0.918	0.920
S 01.05.17 E	0.901	0.924	0.925	0.924	0.924	0.922	0.923	0.924	0.923	0.920
S 01.05.17 E Z	0.909	0.926	0.927	0.925	0.924	0.923	0.922	0.923	0.923	0.923
S 07.02.17 M	0.895	0.916	0.918	0.918	0.920	0.918	0.919	0.914	0.913	0.913
S 07.02.17 M Z	0.896	0.912	0.918	0.918	0.919	0.920	0.918	0.916	0.916	0.914
S 07.02.17 E	0.902	0.916	0.921	0.920	0.919	0.918	0.918	0.916	0.917	0.917
S 07.02.17 E Z	0.9	0.915	0.921	0.920	0.922	0.919	0.919	0.917	0.917	0.916
S 29.11.16. M	0.835	0.873	0.877	0.872	0.872	0.866	0.868	0.908	0.91	0.867
S 10.02.17. M	0.899	0.917	0.917	0.921	0.920	0.918	0.917	0.917	0.914	0.915
S 28.05.17. M	0.907	0.931	0.936	0.938	0.936	0.935	0.934	0.933	0.933	0.932
L 12.12.16.	0.86	0.88	0.88	0.88	0.88	0.876	0.876	0.876	0.876	0.877
L 05.05.17 M	0.889	0.905	0.908	0.908	0.907	0.904	0.906	0.905	0.904	0.902
L 09.08.17. M	0.848	0.857	0.865	0.865	0.863	0.863	0.863	0.86	0.859	0.859
L 26.09.17. M	0.876	0.899	0.901	0.9	0.9	0.904	0.903	0.901	0.9	0.897

Tabula 4. 1. Kopējā precizitāte, pielietojot atšķirīgu tuvāko kaimiņu skaitu *k* un atšķirīgu distances aprēķināšanas metodiku (E - Eiklīda attālums, M - Manhatana attālums, Z - standartizācija).

Tālākos kNN pētījumos tiek lietoti sekojoši parametri:  $k = 5$ , Manhatana distance bez deskriptoru standartizācijas.



**Pētāmais jautājums: kā unikālie apstākļi attēla ieguves brīdī ietekmē klasifikācijas precizitāti?**

kNN metode tika pielietota atsevišķi Ventspils pētāmajam apgabalam A3 un precizitāte aprēķināta, izmantojot *leave-one-out* stratēģiju. Rezultāti parādīti tabulā 4. 2. Precizitātes raksturlielumi nedaudz svārstās pat vadītās klasifikācijas gadījumā. Daļa no atšķirībām ir saistīta ar ģeometriskajām nobīdēm starp attēliem. Tomēr lielāko daļu rada klašu atšķiramība dažādos gadalaikos. Piemēram, ziemā, kad novērojams sals un sniega sega, tad purvu teritoriju un lauksaimniecības zemju spektrālās vērtības ir praktiski vienādas.

Attēla Nr.	Parauga pikseļu skaits	OA (%)	PA (%)	UA (%)	Nepareizi klasificēto pikseļu skaits
S 01.05.17.	1549	92	99/94/91/33/44	99/92/84/50/88	577
S 28.05.17	1549	94	99/95/92/70/48	99/93/87/72/91	165
S 10.02.17	1549	92	99/95/89/37/44	99/92/84/54/75	217
S 07.02.17	1549	92	99/95/90/36/41	99/93/83/56/81	255
S 29.11.16	1549	92	99/95/90/30/33	99/92/82/51/85	222
L 12.12.16	1549	88	99/92/81/37/29	97/86/80/66/58	303
L 05.05.17	1549	91	99/92/87/37/59	99/89/94/56/81	238
L 09.08.17	1549	86	99/89/79/22/26	98/83/75/55/65	352
L 26.09.17	1549	90	99/89/85/51/62	99/89/82/61/77	256

Tabula 4. 2. kNN *leave-one-out* klasifikācijas precizitātes novērtējumi 5 zemes pārseguma klasēm. PA un UA parādīti secībā: ūdens, koku vainagu noseģums, lauksaimniecības zeme, purvs un apbūve. Šajā testā nav atsevišķi iedalīta zemā zaļā veģetācija un atklāta augsne.

**Pētāmais jautājums: kāda ir klasifikācijas rezultātu saderība, apstrādājot dažādās sezonās iegūtus datus?**

Rezultātu saderība šajā kontekstā nozīmē, cik telpiski līdzīgus rezultātus klasifikators sniedz laikā pietiekami tuviem attēliem. Ideālā gadījumā klasifikācijas rezultāti starp dažādos datumos iegūtiem attēliem atšķiras tikai reālu izmaiņu dēļ. Šajā eksperimentā saderība tika pētīta Ventspils pētāmajam apgabalam salīdzinot gan Landsat, gan Sentinel datus.

Landsat datu gadījumā tika salīdzināti 05.05.17. un 26.09.17. attēlu klasifikācijas rezultāti, jo šo attēlu gadījumā tika sasniegtas augstākās precizitātes. Kopumā 10% teritoriju atšķiras klasifikācijas rezultāti abiem attēliem, t.i. atšķirības novērojamas 69.7 km<sup>2</sup> no 681.2 km<sup>2</sup>.

Varam uzkonstruēt pārpratumu matricai līdzīgu tabulu (skat. 4. 3.), kas parāda, kā konkrētās klases pikseli 05.05.17. attēlā ir klasificēti 26.09.17. datuma attēlā. Rindīnās ir parādīti maija attēla pikseļu klasifikācijas rezultāti, bet kolonnās septembra klasifikācijas rezultāti. Vislielākā rezultātu nesaderība novērojama purva klasei. Koku vainagu noseģuma klase bieži tiek sajaukta ar lauksaimniecības zemju un purvu klasi.

	1	2	3	4	5
1	296107	465	115	234	260
2	164	218280	13943	4494	1110
3	106	28963	149175	5641	5038
4	185	5051	3335	4946	331
5	794	1512	4408	1249	10994

Tabula 4. 3. Landsat saderības rezultāti. Klašu numuri: 1 - ūdens, 2 - koku vainagu nosešums, 3 - lauksaimniecības zemes, 4 - purvs, 5 - apbūve.

Analizējot pārliecības līmeni pikseļiem, kas klasifikācijas rezultātos atšķiras (skat. tab. 4. 4.), iespējams novērot, ka nesakrītošajiem pikseļiem novērojamas zemākas pārliecības vērtības nekā pikseļiem, kuru klasifikācijas rezultāti ir vienādi.

Klases Nr.	Pārliecība sakrītošajiem pikseļiem 05.05./26.09.	Pārliecība nesakrītošajiem 05.05	Pārliecība nesakrītošajiem 26.09
1	0.9985/0.9991	0.5644	0.7492
2	0.9401/0.9383	0.6737	0.7142
3	0.9166/0.8954	0.7228	0.7006
4	0.7227/ 0.7551	0.6460	0.6968
5	0.8256/0.8503	0.7266	0.7260

Tabula 4. 4. kNN pārliecības līmenis pikseļiem, kuru klasifikācijas rezultāti sakrīt un pikseļiem, kuru klasifikācijas rezultāti nesakrīt.

Sentinel datu gadījumā tika analizēti februāra attēli ar 3 dienu starpību (skat. tab. 4. 5.). Atšķirības novērojamas 29 km<sup>2</sup>, kas ir apmēram 4.3 % no visa attēla.

	1	2	3	4	5
1	2679554	3028	11847	814	3328
2	2823	2183029	53682	8137	9621
3	2063	50453	1489787	27585	29429
4	569	8884	35042	62224	5692
5	4079	7713	26087	4116	92078


Tabula 4. 5. Sentinel 2 saderības rezultāti. Klašu numuri: 1 - ūdens, 2 - koku vainagu nosešums, 3 - lauksaimniecības zemes, 4 - purvs, 5 - apbūve.

Sentinel datu gadījumā sakrītošo pikseļu vidējais pārliecības līmenis bija 0.96, nesakrītošo pikseļu 0.6. Sentinel datu gadījumā atšķirības gan ir novērojamas nelielās teritorijās. Pielietojot mediānas filtru ar izmēru 5 x 5 un veicot morfoloģisko rekonstrukciju koku vainagu nosešuma klases binārajam attēlam, nesakrītošo pikseļu skaits samazinājās aptuveni par 97 %. Tas nozīmē, ka nesakrītības vairumā gadījumu ir saistītas ar ģeometriskām nobīdēm un ar to saistītajām apgaismojuma izmaiņām. Teritorijas, kurās izmaiņas ir novērojamas plašākā reģionā ir saistītas ar straujām sezonālajām izmaiņām purvu un lauksaimniecības zemju teritorijās. Ziemas attēlos mežaudžu ēnas puse bieži tiek klasificēta kā apbūve vai

ūdens. Novembra attēlā ar izteikti zemu precizitāti bija klasificēta pilsētvide, iespējams apgaismojuma un sniega segas dēļ. Rekomendējams izmantot tikai augsta pārlicības līmeņa pikselus, bet pārējos pārbaudīt vizuāli. Attēlā 4.5. redzams pārlicības līmeņa attēls, bet attēlā 4.6. parādīti daži gadījumi, kad pārlicības līmenis ir zemāks par 0.7. Zems pārlicības līmenis ir raksturīgs pilsētu teritorijām, purviem un lauksaimniecības zemēm un retākos gadījumos arī netipiskas telpiskās struktūras mežaudzēm.



Att. 4.5. Pārlicības līmeņa attēla piemērs.



Att. 4.6. Apgabali ar augstu pārlicības līmeni (virs 0.7) iekrāsoti violetā, bet apgabali ar zemu atstāti oriģinālajās krāsās. Apakšējā slānī parādīta LĢIA ortofotokarte.

#### **Pētāmais jautājums: kādi ir tipiskākie kļūdu avoti, klasificējot datus ar kNN?**

Attēlā 4.7. parādīti tipiskākie kļūdu avoti Landsat satelītattēlu klasifikācijā labākajam rezultātam. Apmēram 59 % no punktiem, kuri testa datos atzīmēti kā koku vainagu nosegums, bet atpazīti kā cits zemes pārsegums, meža inventarizācijas datu bāzē ir reģistrēti kā "ciršana", "meža atjaunošana" un "jaunaudžu kopšana". Atlikušos 41% veido punkti, kas atrodas purvu teritorijā, nesenās kailcirtēs, kas nav reģistrētas pieejamos palīgdatos, uz robežas ar citu zemes pārseguma tipu un jaunaudzēs.

No kļūdaini klasificētajiem cita zemes pārseguma punktiem apmēram 20 % netiek pareizi klasificēti vidējās telpiskās izšķirtspējas un ģeometrisku nobīžu dēļ. Atlikušie 80 % atrodas uz robežām starp mežu teritorijām un citu zemes pārseguma klasi. Attēlā 4.8. redzami daži piemēri, kad citam zemes pārsegumam atbilstošie punkti tiek klasificēti kā mežu teritorijas.



Att. 4.7. Nepareizi klasificētie punkti parādīti ortofotokartēs.



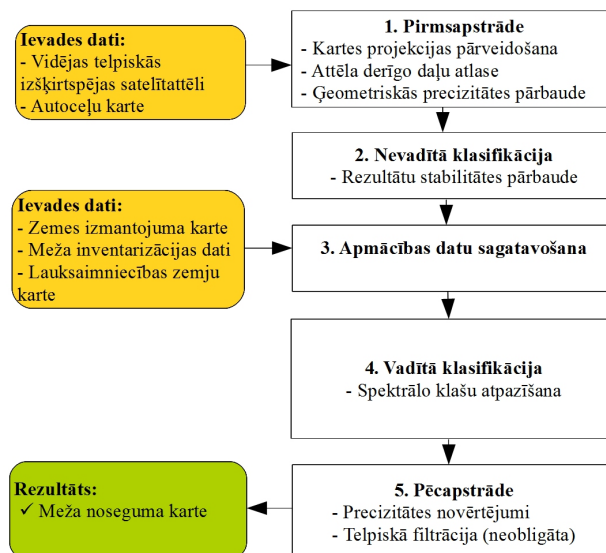
Att. 4.8. Nepareizi klasificētie punkti parādīti ortofotokartēs.

#### 4. 4. 2. Hibrīdās klasifikācijas darbplūsma

**Ievades dati:** apstrādājamais attēls vai tā pārveidojumi, parauga dati (kvalitāte nav tik kritiski svarīgi kā kNN gadījumā).

**Algoritma iekšējie parametri:**  $c, \sigma_c$  - const.

Darbplūsmas galvenie soļi parādīti attēlā 4.9.



Att. 4.9. Darbplūsma koku vainagu noseģuma noteikšanai.

**Datu pirmsapstrāde** ietver visas tās operācijas, kas nepieciešamas, lai nodrošinātu satelītattēlu kvalitāti statistiskās mašīnmācīšanās algoritmu pielietošanai. Pirmsapstrādes operācijas metodoloģijas ietvaros var iedalīt 2 grupās:

1. Ģeometriskās korekcijas. Kopīgas datu apstrādes veikšanai, katram atsevišķam datu avotam ir jāatbilst vietējai kartes projekcijai LKS 92 un satelītattēlu ģeometriskajai precizitātei ir jānodrošina kopīgas apstrādes iespējas ar vektorkartēm un citiem palīgdatu formātiem.
2. Attēla derīgo daļu atlase. Šajā etapā tiek izveidota attēla maska, kurā iezīmēti apgabali, kuriem ir lietderīgi veikt klasifikāciju. Ar maskas palīdzību tiek izņemtas mākoņu un mākoņu ēnu noseģtās teritorijas, ūdens apgabali un pikseļi ar trūkstošām datu vērtībām. Attēla nederīgo daļu atstāšana attēlā nākamajos etapos paildzina skaitļošanas laiku, kā arī negatīvi ietekmē nevadītās klasifikācijas statistiskos parametrus un stabilitāti.

Mākoņu un mākoņu ēnu noteikšanai tika izmantots Fmask algoritms [120]. Fmask algoritms izmanto uz objektiem, nevis atsevišķiem pikseļiem balstītu metodiku. Mākoņu ēnu maska tiek veidota, ņemot vērā identificēto mākoņu slāni un izgaismojuma un satelīta sensora skata leņķi. Fmask pieejama kā brīvprogrammatūras konsoles aplikācija licencēta ar GNU GPL v2 licenci.

Fmask programmatūras izveidotā mākoņu maska tiek pārveidota uz bināro attēlu  $C$ , kas satur vērtības 1 tiem apgabaliem, kas atbilst mākoņiem un mākoņu ēnām un 0 pārējām teritorijām. Ūdens teritorijas tika identificētas, izmantojot normalizētās starpības veģetācijas indeksu NDVI. Ūdens teritorijas  $W$ , pēc NDVI atrašanas tiek aprēķinātas, veicot NDVI sliekšņošanu (angl. *thresholding*)  $W = NDVI < 0$ . Izmantojot NDVI sliekšņošanu, ūdens

teritoriju masku iespējams aprēķināt tikai tām sezonām, kad ūdens apgabalus nesedz ledus. Līdz ar to, šajā pētījumā ziemas satelītattēliem tiek lietotas vasaras satelītattēlu ūdens maskas.

Attēlu derīgo daļu maska  $U$  tiek izveidota, kombinējot iepriekš minētās maskas ar loģisko operatoru palīdzību un šī maska satur vērtību 1, ja pikseli iespējams tālāk klasificēt un 0, ja pikselis atbilst attēla nederīgajām daļām:

$$U = NOT(C) \quad AND \quad NOT(W) \quad AND \quad NOT(N) \quad (4. 6.)$$

Attēlā 4.10. parādīts attēla derīgo daļu maskas piemērs.



Att. 4.10. No kreisās puses: a) mākoņu un mākoņu ēnu maska  $C$ , b) ūdens teritoriju maska  $W$ , c) datu nesaturošo pikseļu maska, d) attēla derīgo daļu maska.

Liela datu apjoma apstrādē svarīgi ir izmantot datus esošās sakarības un ”neuzspiest” klasifikācijas rezultātu, vadoties pēc lietotāja atlasītiem, iespējams, kļūdainiem un neprecīziem datiem, tādēļ pirmajā klasifikācijas etapā tiek izmantota **nevadītā klasifikācija**. Nevadītās klasifikācijas ietvaros attēla dati tiek klasificēti, tos sagrupējot dabiskās spektrālajās klasēs jeb klāsteros. Nevadītās klasifikācijas rezultātā tiek iegūtas spektrālās klases, bet ne zemes izmantojuma klases.

Hibrīdās klasifikācijas shēmās nevadītā klasifikācija parasti tiek iekļauta sekojošos veidos [61]:

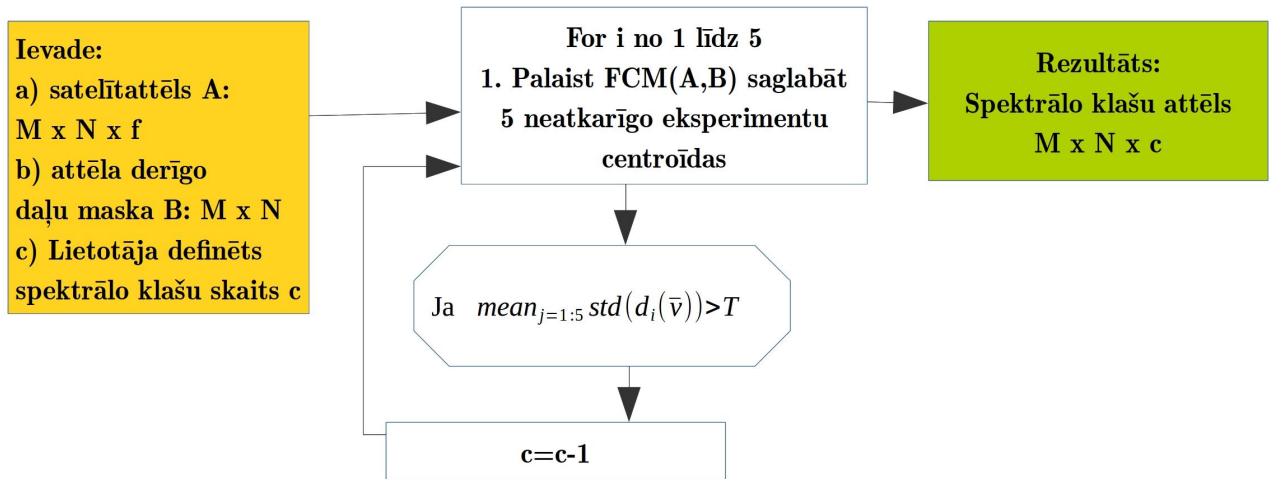
- nevadīto klasifikāciju lieto vadītās klasifikācijas apmācības datu klāsterizācijai;
- apmācības datu atlasei no spektrāli homogēnām teritorijām;
- attēlu sadalīšanai lielos reģionos pirms vadīto metožu pielietošanas.

Galvenais iemesls nevadītās klasifikācijas iekļaušanai tikai apmācības vai robustas klasifikācijas mērķiem ir algoritmu ilgais skaitļošanas laiks [94]. Nevadītā klasifikācija šajā pētījumā tika izvēlēta, lai nodrošinātu robustu klasifikācijas rezultātu neatkarīgi no attēla ieguves datuma un, lai samazinātu parauga datu kvalitātes ietekmi uz gala rezultātu. Līdz ar to tā tiek izmantota visa attēla klasifikācijai, nevis tikai apmācības datu optimizācijai. Mūsdienu pieejamo skaitļošanas resursu gadījumā, algoritmu patērētais skaitļošanas laiks nav kritiski svarīgs.

Viens no būtiskākajiem nevadītās klasifikācijas trūkumiem ir nestabili algoritma rezultāti atkarībā no algoritma inicializācijas ar gadījuma skaitļiem un no reālā spektrālo klašu

skaita attēlā, kas parasti lietotājam nav zināms. Lai novērstu šo trūkumu, metodoloģijai pievienots nevadītās klasifikācijas stabilitātes tests, kas ļauj atrast tādu meklējamo spektrālo klašu skaitu, ar kuru rezultāts būs stabils pie gadījuma sākuma nosacījumiem.

Nevadītās klasifikācijas etaps koku vainagu noseģuma noteikšanas metodoloģijā ir parādīts attēlā 4.11.



Att. 4.11. Nevadītās klasifikācijas shēma ar stabilitātes nosacījumu.

*Fuzzy c-means* (FCM) ir pikseļa līmeņa nevadītās klasifikācijas metode, kas ļauj vienam attēla pikselim piederēt vairāk kā vienam klāsterim jeb spektrālajai klasei. Algoritma rezultāts katram pikselim ir piederības vērtību vektors, piemēram,  $x = [0.8; 0.2]$ , kas nozīmē, ka par 80 % pikselis pieder pirmajai spektrālajai klasei, bet par 20 % otrai spektrālajai klasei. FCM tiek izmantots jaukto pikseļu analīzē, pieņemot, ka piederības vērtības korelē ar katra zemes pārseguma tipa procentuālo telpisko noseģumu pikseļa līmenī [31].

Pamata FCM algoritms [22]:

1. Norāda vēlamu spektrālo klašu skaitu  $c$ .
2. Inicializē gadījuma centroīdu vērtības  $v_i$ .
3. Aprēķina piederības matricas  $U$  elementus  $\mu_{k,i}$  pēc formulas:

$$\mu_{k,i} = \frac{1}{\sum_{j=1}^c \left( \frac{d(x_k, v_i)}{d(x_k, v_j)} \right)^{\frac{2}{m-1}}}, \quad (4.7.)$$

kur  $d(x_k, v_i)$  - parastais Eiklīda attālums no pikseļa  $x_k$  līdz centroīdai  $v_i$ ;


$m$  - fazifikācijas līmenis, testos  $m = 1.2$ .

4. Aprēķina spektrālo klašu centroīdas, izmantojot:

$$v_i = \frac{\sum_{k=1}^n (\mu_{k,i})^m x_k}{\sum_{k=1}^n (\mu_{k,i})^m} \quad (4.8.)$$

5. Ja  $\max_{k,i} [|\mu_{k,i} - \overline{\mu_{k,i}}|] < \varepsilon$ , kur  $\overline{\mu_{k,i}}$  ir vērtība iepriekšējā iterācijā un  $||$  apzīmē skaitļa moduli, tad aprēķini tiek apstādināti.

Attēlā 4.12. redzams FCM algoritma pielietojuma piemērs LC81890202013114LGN01 attēlam 4 spektrālo klašu gadījumam. Spektrālo klašu piederības vērtības attēlotas ar pamatkrāsām sarkanu, zaļu, zilu un melnu, savukārt ar jauktajiem toņiem parādīti jauktie pikseļi kuru piederības pakāpe līdzvērtīgi atbilst vairākām spektrālajām klasēm. FCM apstrādā tikai tos pikseļus, kuri derīgo daļu maskā iezīmēti ar vērtību 1.



Att. 4.12. a) Landsat OLI/TIRS satelītattēla fragments, b) FCM iezīmētās spektrālās klases.

FCM procedūra tika papildināta ar stabilitātes testu, kas ļauj noteikt stabilu spektrālo klašu skaitu. Stabilitātes testa galvenais trūkums ir palielināts skaitļošanas laiks, vienu un to pašu datu komplektu atkārtoti testējot 5 reizes. Stabilitātes tests tiek veikts sekojoši:

1. Lietotājs izvēlas spektrālo klašu skaitu  $c$  nedaudz lielāku nekā intuitīvi būtu sagaidāms, piemēram,  $c = 9$ .
2. FCM tiek testēts attēlam 5 reizes. Centroīdu vērtības saglabā visās 5 iterācijās, bet spektrālo klašu attēls tiek saglabāts tikai pēc pēdējās iterācijas.
3. Visu 5 iterāciju centroīdas tiek pārkārtotas tādā secībā, kādā spektrālās klases izvietotas pirmajā iterācijā, veicot Eiklīda attāluma aprēķinus.
4. Tiek aprēķināts katras spektrālās klases  $i$  vidējais centroīdu vektors  $\bar{v}$ . Katras spektrālās klases vektors  $\bar{v}$  satur tik daudz elementu, cik ir attēlu frekvenču joslas.
5. Tiek aprēķināta katras klases  $i$  centroīdu  $v_i$  Eiklīda attāluma  $d((\bar{v}), v_i)$  līdz vidējam centroīdu vektoram vidējā standarta novirze visos piecos testos  $\sigma_{centr} = \text{mean}_{j=1:5}(\text{std}(d((\bar{v}), v_i)))$ .
6. Ja visu klašu vidējā standarta novirze ir lielāka par sliekšni  $T$ , piemēram  $T > 0.1$ , tad spektrālo klašu skaits  $c$  negarantē stabilu rezultātu un klašu skaits  $c$  tiek samazināts  $c = c - 1$  un stabilitātes pārbaude tiek atkārtota.



Spektrālo klašu klasifikācija, pikseļu klasifikācijas vietā, ļauj samazināt parauga datu ietekmi uz klasifikācijas rezultātu un nodrošināt augstāku precizitāti gadījumos, kad lietotājam nav pieejami kvalitatīvi palīgdati.

Spektrālo klašu zemes pārseguma klašu noteikšana tiek veikta sekojoši:

1. Lietotājs norāda, cik daudz pikseļi  $p$  pēc gadījuma tiek atlasīti no katras spektrālās klases. Jo vairāk pikseļu tiek atlasīti, jo detalizētāku informāciju iespējams iegūt par spektrālās klases sakarībām ar parauga datiem, taču ilgāks skaitļošanas laiks nepieciešams rezultāta iegūšanai.
2. Pēc gadījuma atlasītie pikseļi atbilstošajā satelītattēlā tiek klasificēti, izmantojot kNN un sagatavotos parauga datus. Parauga datus ieteicams atlasīt no tā paša attēla, kam tika veikta nevadītā klasifikācija, taču zemes izmantojuma klašu atpazīšanā iespējams izmantot arī citu attēlu parauga datus ar priekšnoteikumu, ka parauga dati ir iegūti no tās pašas sezonas attēla, kāda ir klasificējamam attēlam.
3. Spektrālajai klasei tiek piešķirta tās zemes pārseguma klases birka, kas visbiežāk sastopama starp pikseļu  $p$  kopas klasifikācijas rezultātiem. Ja vairākām spektrālajām klasēm tiek atpazīts viens un tas pats zemes izmantojuma tips, tad spektrālās klases tiek apvienotas, veicot attēlu saskaitīšanu (saskaitot atbilstošo pikseļu vērtības). Rezultātā tiek iegūts attēls  $R$  ar izmēru  $N \times M \times 2$ , kur  $N$ ,  $M$  ir attēla izmērs pikseļos. Pirmais attēla slānis atbilst cita zemes pārseguma tipa noseģumam, bet otrais attēla slānis koku vainagu noseģumam.

Pētījumos no katras spektrālās klases tika atlasīts 51 pikselis. Šo pikseļu klasifikācijas statistika (cik no 51 pikseļiem tiek klasificēti kā koku vainagu noseģums, cik kā "cits") var tikt izmantota, lai novērtētu "pārlicības" līmeni ar kādu tiek klasificēta spektrāla klase. Ja gandrīz visi no 51 pikseļiem tiek piešķirti vienam zemes pārseguma tipam, tad tas nozīmē, ka klase ir klasificēta ar augstu "pārlicības līmeni". Savukārt, ja katram zemes pārseguma tipam atbilstošo pikseļu skaits ir līdzīgs, tad spektrālā klase visticamāk reprezentē robežklasi starp koku vainagu noseģumu un citu zemes pārseguma tipu.

#### **Pētāmais jautājums: cik stabili ir nevadītās klasifikācijas rezultāti?**

FCM atrastās spektrālās klases ir atkarīgas no diviem parametriem: 1) spektrālo klašu skaita  $c$ , 2) centroīdu gadījumskaitļu inicializācijas.

FCM metode tika izpildīta piecas reizes Ropažu novadam attēlā LC81870202014215LGN00, izmantojot klašu skaitu  $c$  no divām līdz piecpadsmit klasēm, t.i. tika izpildīti 70 FCM eksperimenti. Eksperimentos tika reģistrēta visu spektrālo klašu vidējā standarta novirze  $\sigma_{centr}$ . Zema standarta novirzes vērtība parāda, ka centroīdas visos eksperimentos ir bijušas aptuveni vienādas, bet augsta standarta novirzes vērtība parāda, ka centroīdas katrā eksperimentā ievērojami atšķiras un FCM rezultāti ir nestabili un līdz ar to nav uzticami. Viens no nestabilitātes iemesliem varētu būt patiesais spektrālo klašu skaits, kas lietotājam nav zināms. Ja pieņemam, ka attēlā ir 3 spektrālās klases, bet lietotājs FCM algoritmam norāda, ka nepieciešams atrast 4 spektrālās klases, tad katrā no eksperimentiem kāda no spektrālajām klasēm tiks

mākslīgi pārdalīta, lai rezultātā iegūtu tieši 4 klases. Atšķirīgos eksperimentos var notikt atšķirīgu klašu pārdalīšana.

$c$	2	3	4	5	6	7	8	9	10	11	12	13	14	15
$\sigma_{centr}$	0	204	0.004	136	0.1	0.4	0.01	199	164	72.5	131	160	109	68

Tabula 4. 6. Centroīdu stabilitāte piecos eksperimentos.

Tabulā 4. 6. redzams, ka konkrētajam testa piemēram stabilitāte tiek sasniegta, ja spektrālo klašu skaits  $c$  ir 8, 7, 6, 4 vai 2. No metodoloģijas viedokļa ir svarīgi iegūt lielāko stabilo klašu skaitu, tādēļ pamatojoties uz šo gadījuma izpēti stabilitātes pārbaudē sākotnējais  $c = 9$ . Paaugstinot spektrālo klašu skaitu, stabilitāte vairs netiek sasniegta un tas nozīmē, ka tiek samazināta rezultātu uzticamība, jo atšķirīgos testos iespējams iegūt atšķirīgus rezultātus.

**Pētāmais jautājums: kā unikālie apstākļi attēla ieguves brīdī ietekmē klasifikācijas rezultātus?**

Precizitātes raksturlielumi divām klasēm: koku vainagu noseģums un cits, dažādu datumu satelītattēliem testa apgabalam A2 ir parādīti tabulā 4. 7.

Attēla Nr.	Testa pikseļu skaits	OA (%)	PA (%) TC/O	UA (%) TC/O	$\hat{k}$
LC81870202014023LGN00	1000	94.2	98.7/90.5	90.0/98.8	0.89
LC81870202014055LGN00	1000	91.2	95.5/87.5	86.9/95.7	0.82
LC81870202014087LGN00	1000	93.6	97.8/90.0	89.6/98.0	0.87
LC81870202014135LGN00	1000	83.7	98.9/70.5	74.4/98.7	0.68
LC81870202014215LGN00	1000	86.2	98.9/75.1	77.6/98.8	0.73
LC81870202014247LGN00	973	88.4	98.9/79.2	80.6/98.8	0.77
LC81870202014263LGN00	936	92.8	98.2/88.1	88.0/98.2	0.86
LC81870202015074LGN00	1000	86.6	99.6/75.3	77.8/99.5	0.74
LC81870202015186LGN00	992	86.0	98.5/75.0	77.6/98.3	0.72
LE71870202002238KIS00	1000	83.8	97.2/75.2	72.1/96.7	0.68
LT51870202000241FUI00	656	80.9	95.5/69.2	71.3/95.0	0.63
LE71870202000137EDC00	982	83.2	97.8/70.8	74.2/97.4	0.67
LT51870201988288KIS00	1000	79.9	99.1/63.2	70.2/98.8	0.61
LT51872021987285XXX03	1000	78.8	99.6/60.9	68.9/99.4	0.59
S20150824T094301	1000	91.1	89.7/92.3	91.0/91.1	0.82
S20170316T094021	1000	89.3	85.0/93.1	91.4/87.7	0.78

Tabula 4. 7. Koku vainagu noseģuma klasifikācijas precizitāte testa apgabalam A2.

2014. gada attēlu gadījumā kopējā precizitāte svārstās no 83.7 % līdz 94.2 %. Fluktuācijas nav izteikti saistītas ar attēla ieguves gadalaiku, kas nozīmē, ka liela ietekme uz precizitāti ir citiem faktoriem, piemēram, atmosfēras apstākļiem, kuru izpētei būtu vajadzīgi detalizētāka informācija. Augstāka precizitāte novērojama ziemas attēliem, kad spektrālā atšķirība starp koku vainagu noseģumu un citiem zemes pārseguma tipiem ir lielāka. Vasaras sezonā atsevišķas zemās zaļās veģetācijas teritorijas ir ļoti līdzīgas lapu koku spektrālajām vērtībām. Precizitātes raksturlielumu samazinājums 2002., 2000., 1988 un 1987 ir saistīts

ar parauga datu neatbilstību attēla iegūšanas laikam (parauga dati testa apgabalā A2 ir atbilstoši 2014. gadam). Šie rezultāti parādīti, lai salīdzinātu parauga datu laika neatbilstības ietekmi.

Rezultātus iespējams analizēt sīkāk, atgriežoties pie spektrālajām klasēm, kuras pēc tam tika apvienotas tikai koku vainagu noseguma un cita zemes pārseguma klasēs. Katra spektrālā klase tika atpazīta, izmantojot kNN un nosakot arī pārliecības līmeni. Spektrālo klašu klasifikācijas pārliecības līmeņi ir apkopoti tabulā 4. 8. Tabulā redzams, ka vairākas spektrālās klases ir atpazītas ar augstu pārliecības līmeni, respektīvi, gandrīz visi spektrālās klases gadījuma pikseļi ir piešķirti vienai zemes pārseguma klasei. Taču katrā attēlā novērojamas vismaz divas spektrālās klases, kuras klasificētas ar zemu pārliecības līmeni. LT518702000241FUI00 attēlā novērojamas pat četras zemas pārliecības klases, kas gan varētu būt izskaidrojamas ar intensīvu mākoņu nosegumu un derīgo pikseļu trūkumu. Zemas pārliecības klašu skaits neparāda izteiktas sakarības ar attēlu ieguves gadalaiku.

Attēla Nr.	Klase 1	Klase 2	Klase 3	Klase 4	Klase 5	Klase 6	Klase 7	Klase 8
LC81870202014023LGN00	29 O	11 O	1 O	21 O	0 O	46 O	51 O	51
	22 TC	40 TC	50 TC	30 TC	51 TC	5 TC	0 TC	0
LC81870202014055LGN00	7 O	46 O	28 O	51 O	0 O	43 O	9 O	0 O
	44 TC	5 TC	23 TC	0 TC	51 TC	8 TC	42 TC	51 TC
LC81870202014087LGN00	51 O	21 O	47 O	0 O	3 O	9 O	-	-
	0 TC	30 TC	4 TC	51 TC	48 TC	42 TC	-	-
LC81870202014135LGN00	18 O	1 O	49 O	5 O	17 O	42 O	-	-
	33 TC	50 TC	2 TC	46 TC	34 TC	9 TC	-	-
LC81870202014215LGN00	51 O	15 O	0 O	50 O	6 O	46 O	24 O	-
	0 TC	36 TC	51 TC	1 TC	45 TC	5 TC	27 TC	-
LC81870202014247LGN00	24 O	42 O	49 O	3 O	10 O	48 O	0 O	-
	27 TC	9 TC	2 TC	48 TC	41 TC	3 TC	51 TC	-
LC81870202014263LGN00	48 O	8 O	1 O	2 O	6 O	28 O	51 O	36 O
	3 TC	43 TC	50 TC	49 TC	45 TC	23 TC	0 TC	15 TC
LC81870202015074LGN00	0 O	0 O	32 O	6 O	40 O	3 O	51 O	-
	51 TC	51 TC	19 TC	45 TC	11 TC	48 TC	0 TC	-
LC81870202015186LGN00	47 O	21 O	42 O	0 O	3 O	1 O	45 O	14 O
	4 TC	30 TC	9 TC	51 TC	48 TC	50 TC	6 TC	37 TC
LE71870202002238KIS00	4 O	51 O	34 O	51 O	0 O	1 O	3 O	49 O
	47 TC	0 TC	17 TC	0 TC	51 TC	50 TC	48 TC	2 TC
LT51870202000241FUI00	47 O	24 O	7 O	22 O	31 O	5 O	19 O	10 O
	4 TC	27 TC	44 TC	29 TC	20 TC	46 TC	32 TC	41 TC
LE71870202000137EDC00	11 O	51 O	9 O	51 O	27 O	0 O	1 O	48 O
	40 TC	0 TC	42 TC	0 TC	24 TC	51 TC	50 TC	3 TC
LT51870201988288KIS00	51 O	2 O	0 O	0 O	51 O	51 O	15 O	50 O
	0 TC	49 TC	51 TC	51 TC	0 TC	0 TC	36 TC	1 TC
LT51872021987285XXX03	51 O	50 O	51 O	1 O	25 O	51 O	0 O	0 O
	0 TC	1 TC	0 TC	51 TC	26 TC	0 TC	51 TC	51 TC
S20150824T094301	12 O	51 O	51 O	33 O	35 O	1 O	0 O	
	39 TC	0 TC	0 TC	0 TC	18 TC	16 TC	50 TC	51 TC
S20170316T094021	15 )	47 O	51 O	51 O	9 O	0 O	-	-
	36 TC	4 TC	0 TC	0 TC	42 TC	51 TC	-	-

Tabula 4. 8. FCM atrasto spektrālo klašu klasifikācijas statistika. 51 pikselis pēc gadījuma tika atlasīts un klasificēts, izmantojot kNN. Statistika parāda, cik daudz pikseļi no katras spektrālās klases tiek klasificēti kā koku vainagu nosegums (TC) vai cits zemes pārseguma tips (O).

**Pētāmais jautājums: kā meža inventarizācijas raksturlielumi ietekmē klasifikācijas rezultātus?**

Tālāk spektrālās klases tika analizētas no meža inventarizācijas parametru viedokļa, lai izprastu sakarības zemas pārlicības klašu gadījumā. Tabulā 4. 9. parādītas vidējās galveno meža inventarizācijas parametru vērtības spektrālajām klasēm. Novērojams, ka vairumā gadījumu spektrālo klašu klasifikācijas pārlicības līmenis ir saistīts ar audzes krāju, nevis koku sugām. Spektrālās klases ar krāju augstāku par  $100 m^3/ha$  visos attēlos tika identificētas ar augstu pārlicības līmeni. Tikai 3 attēlos spektrālās klases ar vidējo krāju mazāku par  $70 m^3/ha$  tika atpazītas ar augstu pārlicības līmeni. Mežam atbilstošās spektrālās klases ar zemu pārlicības līmeni ietvēra zemas krājas un jaukta tipa audzes. Citam zemes pārseguma tipam atbilstošās klases ar zemu pārlicības līmeni ietvēra audzes ar krāju mazāku par  $45 m^3/ha$  vai izteikti jauktu koku sugu audzes.

Tā kā spektrālās klases parāda patieso attēla informāciju, eksperiments parāda, cik kritiski svarīga ir parauga datu atlase tieši pārejas klašu starp dažādiem zemes pārseguma tiem pētniecībā.

Attēla Nr.	Meža inventarizācijas parametrs	Kl.1	Kl.2	Kl.3	Kl.4	Kl.5	Kl.6	Kl.7	Kl.8
LC81870202014023LGN00	TSF	0.53	0.57	0.61	0.49	0.51	-	-	-
	$M_{inv}$	1	1	1	1	1	-	-	-
	$V_{inv}$	30	66	194	112	240	-	-	-
	$A_{inv}$	11	28	64	40	76	-	-	-
LC81870202014055LGN00	TSF	0.52	-	0.28	-	0.61	-	0.59	0.65
	$M_{inv}$	1	-	1	-	1	-	1	1
	$V_{inv}$	247	-	133	-	233	-	48	162
	$A_{inv}$	82	-	41	-	78	-	20	57
LC81870202014135LGN00	TSF	0.58	0.65	-	-	0.42	-	-	-
	$M_{inv}$	1	1	-	-	4	-	-	-
	$V_{inv}$	48	246	-	-	136	-	-	-
	$A_{inv}$	18	82	-	-	38	-	-	-
LC81870202014215LGN00	TSF	-	0.33	0.71	-	0.38	-	0.57	-
	$M_{inv}$	-	1	1	-	1	-	1	-
	$V_{inv}$	-	93	246	-	164	-	65	-
	$A_{inv}$	-	28	84	-	53	-	26	-
LC81870202014247LGN00	TSF	0.54	-	-	0.47	0.33	-	-	-
	$M_{inv}$	1	-	-	1	1	-	-	-
	$V_{inv}$	58	-	-	172	100	-	-	-
	$A_{inv}$	20	-	-	57	31	-	-	-
LC81870202014263LGN00	TSF	-	0.37	0.62	0.66	0.39	0.52	-	0.46
	$M_{inv}$	-	1	1	1	1	1	-	1
	$V_{inv}$	-	54	204	258	123	44	-	17
	$A_{inv}$	-	17	70	87	41	17	-	7

Tabula 4. 9. Vidējās meža inventarizācijas parametru vērtības spektrālajām klasēm Kl.:  $V_{inv}$  - audzes krāja ( $m^3/ha$ ),  $A_{inv}$  - audzes vecums (gadi),  $M_{inv}$  - dominējošā koku suga, TSF - dominējošās koku sugas audžu daļa procentos.

Attēla LC81870202014023LGN00 rezultātā atrastās spektrālās klases tika salīdzinātas ar koku vainagu kartēšanas rezultātiem, izmantojot sliekšņošanas darbplūsmu, kas ap-

rakstīta nākamajā nodaļā. Katrai spektrālajai klasei tika aprēķināts, cik procentus no tās teritorijas nosedz koku vainagi saskaņā ar sliekšņošanas darbplūsmas rezultātiem, skatīt. 4. 10. Tabulā parādītie dati parāda spēcīgu korelāciju starp koku vainagu noseģuma blīvumu un pārliecības līmeni ar kādu tiek atpazīta spektrālā klase. Zemākais koku vainagu noseģums, kas tika atpazīts kā koku vainagu noseģums bija 57.7 %. Zemā Saules augstuma leņķa dēļ, ziemas attēlos atsevišķas spektrālās klases formē mežaudžu daļas saules un ēnas pusēs. Saskaņā ar loģiskiem apsvērumiem, koku vainagu noseģuma blīvums palielinās palielinoties krājam, tādējādi var secināt, ka arī krājam ir nozīmīga ietekme uz spektrālo klašu atpazīstamību.

Klases Nr.	Klases teritorija ( $km^2$ )	Zemes pārseguma klase saskaņā ar kNN novērtējumu	Vidējais koku vainagu noseģums saskaņā ar sliekšņošanas metodes rezultātiem (%)	Piezīmes
<b>1</b>	<b>47</b>	<b>O</b>	<b>31.9</b>	<b>Ļoti nehomogēna klase</b>
2	65	TC	57.5	Jaunas mežaudzes, izcirtumi, mežaudžu robeža saules apspīdētajā pusē
3	211	TC	91.2	
<b>4</b>	<b>32</b>	<b>TC</b>	<b>67.8</b>	<b>Mežaudžu robeža ēnas pusē</b>
5	108	TC	94.6	
6	36	O	20.2	
7	34	O	10.0	
8	20	O	5.9	

Tabula 4. 10. Vidējais koku vainagu noseģums procentos katrai spektrālajai klasei attēlā LC81870202014023LGN00. Noseģums rēķināts 551  $km^2$  lielā platībā. Tabulā parādīto teritoriju kopsumma atšķiras no 551, jo tiek apskatīti tikai tie pikseļi, kur FCM novērtējums ir augstāks par 0.45. Klases ar zemu pārliecības līmeni ir iekrāsotas treknrakstā.

Hibrīdās klasifikācijas darbplūsma tika pielietota trim vienas sezonas Landsat satelītattēliem (pavasaris bez zaļās veģetācijas) attēli: 20.04.2014. (im1), 27.04.2014. (im2), 24.04.2013. (im3). FCM tika testēts 5 reizes katram attēlam pie klašu skaita no 2 līdz 8 (kopā 35 eksperimenti). FCM rezultāti tika salīdzināti, aprēķinot vidējo normalizēto kvadrātisko kļūdu (nRMSE) starp divu attēlu vienas un tās pašas klases piederības vērtībām. Atsevišķi tika veikti aprēķini homogēniem un nehomogēniem apgabaliem, vadoties pēc lokālās standarta novirzes. Tabula 4. 11. parāda klašu vidējās atšķirības dažādos datumos iegūtiem attēliem.


Dažādu sezonu gadījumā atšķirības ir vēl ievērojamākas, skat. att. 4.13. Šī iemesla dēļ izmaiņu detektēšanu praksē ieteicams veikt tikai tām klasēm, kas atpazītas ar augstu pārliecības līmeni.

#### **Pētāmais jautājums: kādos gadījumos notiek klasifikācijas kļūdas?**

No 1549 testa pikseļiem mežs kļūdaini kā cits zemes pārsegums tika atpazīts 84 testa punktos. Visi šie testa punkti atrodas uz robežas starp mežu un citu zemes pārseguma tipu

	c=2	c=3	c=4	c=5	c=6	c=7	c=8
im1/im3	0.14/0.46	0.27/0.42	0.32/0.37	0.28/0.46	0.14/0.47	0.2/0.53	0.14/0.48
im1/im2	0.11/0.37	0.25/0.35	0.27/0.31	0.29/0.45	0.11/0.38	0.19/0.48	0.14/0.45
im3/im2	0.14/0.45	0.34/0.44	0.32/0.37	0.2/0.47	0.14/0.46	0.12/0.44	0.16/0.51

Tabula 4. 11. Atšķirības hibrīdās klasifikācijas darbplūsmas rezultātos dažādos laika periodos iegūtiem vienas sezonas attēliem (homogēni apgabali/ nehomogēni apgabali).




Att. 4.13. Pirmā attēlu rinda: mežu klase janvāra, aprīļa un jūlija attēlu klasifikācijā. Otrā attēlu rindā atšķirības starp klasifikācijas rezultātiem: ar pelēku krāsu iezīmēti apgabali, kuros nav vērojamas izmaiņas, bet ar baltu un melnu apgabali ar izmaiņām.

tādēļ ir saistīti ar jaukto pikseļu klātbūtni un nobīdēm starp palīgdatu kopu un satelītattēlu. Cits zemes pārsegums kā mežs tika atpazīts 161 testa punktā, skatīt att. 4.14. Daļa no punktiem arī atbilst robežām starp dažādiem zemes pārseguma tipiem, bet pārējie atbilst purva zemes pārseguma tipam.

#### 4. 5. Augstas telpiskās izšķirtspējas datu apstrāde

Šajā nodaļā salīdzinātas 3 dažādas darbplūsmas koku vainagu noseguma kartēšanai, izmantojot augstas telpiskās izšķirtspējas datus. Pirmās divas metodoloģijas ir balstītas uz nosacījumu virknēm, kas ir jāizpilda koku vainagu nosegumam. Metodes izmanto lietotāja norādītas sliekšņu vērtības, kuras ir jāpielāgo empīriski, taču šāda darbplūsma ir ļoti ātri izpildāma, salīdzinot ar klasiskajiem risinājumiem. Kā trešā metode ir apskatīts konvolūcijas neironu tīkla U-Net pielietojums.



Att. 4.14. Sarkanā krāsā iekrāsoti testa punkti, kuros cits zemes pārseguma tips nepareizi klasificēts kā mežs.

#### 4. 5. 1. Attēlu sliekšņošanas darbplūsma

**Ievades dati:** krāsu infrasarkanais (CIR) attēls, normalizētais virsmas modelis (nDSM).

**Algoritma iekšējie parametri:**  $T_{nDSM}$ ,  $T_{NDVI}$  - const.

Ja ir pieejami Lidar un multispektrālie dati, tad iespējams izmantot pavisam vienkāršu un ātru risinājumu koku vainagu noseģuma noteikšanai, kas balstīts uz attēlu aritmētiku un sliekšņošanu.

Koku noseģuma aprēķināšanas shēmā tiek iekļauts  $NDVI$  (normalizētās starpības veģetācijas indekss, angl. *Normalized Difference Vegetation Index*), kuru aprēķina sekojoši [71]:

$$NDVI = (NIR - RED)/(NIR + RED), \quad (4. 9.)$$

kur  $RED$  - sarkanā starojuma frekvenču joslā iegūts attēls;

$NIR$  - tuvā infrasarkanā attēls.

$NDVI$  vērtības dod iespēju atlasīt tikai zaļo veģetāciju, jo indekss raksturo hlorofila klātbūtni pikselim atbilstošajā laukumā uz zemes. Veģetācijas indekss var būt intervālā  $[-1; 1]$ ; augstāka  $NDVI$  vērtība norāda uz augstāku hlorofila klātbūtni apskatītajā teritorijā.

Tipiskie vērtību diapazoni:  $NDVI < 0$  ūdens, sniegs,  $NDVI \rightarrow 0$  mākoņi,  $NDVI \approx 0.025$  atklāta Augsne,  $NDVI \approx 0.7$  blīva veģetācija [115]. Sliekšņa vērtība 0.4 izvēlēta aptuveni, lai atlasītu visu zaļo veģetāciju [115].

Vērtību atlase notiek, veicot attēla  $f$  sliekšņošanu, izmantojot globālu sliekšņa vērtību  $T$ , tā, ka rezultātā tiek iegūts binārais attēls, kur pikseļa  $(i, j)$  vērtība ir 1, ja  $f(i, j) \geq T$ , bet 0, ja  $f(i, j) < T$ .

Lietojot sliekšņošanu, būtiskākais trūkums ir empīriski nosakāmas sliekšņu vērtības, kuras nosaka rezultāta kvalitāti, taču apvienojot Lidar un multispektrālos datus, papildinošā informācija no abām datu kopām ļauj kompensēt arī relatīvi neprecīzas sliekšņa vērtības.

Koku vainagu nosegums  $TC$  tiek aprēķināts sekojoši:

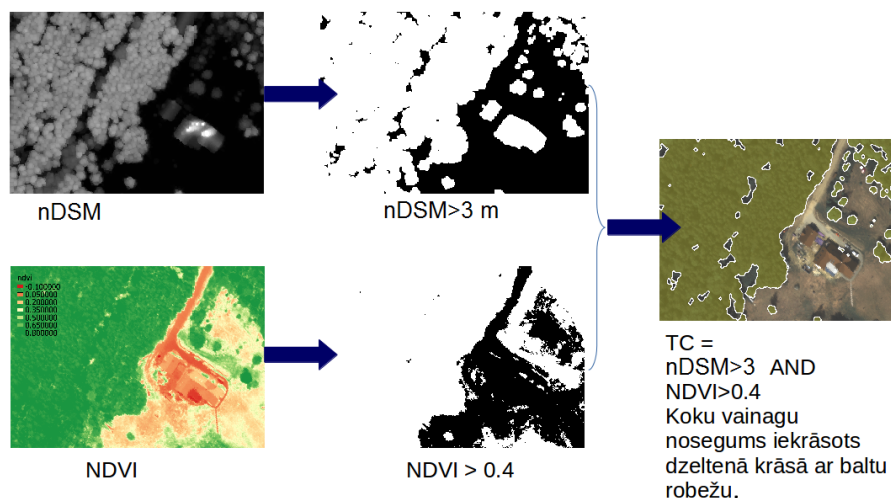
$$TC = nDSM > T_{nDSM} \quad \text{AND} \quad NDVI > T_{NDVI}. \quad (4. 10.)$$

$nDSM$  sliekšņošana ļauj atlasīt tikai relatīvi augstos objektus, izslēdzot no apstrādes zemo veģetāciju kā zāli, paaugu, krūmus un citus objektus, kas ir zemāki par  $T_{nDSM}$  metriem. Saskaņā ar meža definīciju likumdošanā, meža galveno organiskās masas ražošanu veido koki, kas ir augstāki par 7 metriem.  $T_{nDSM}$  sliekšnis šajā pētījumā ir 3 metri, lai būtiski neizņemtu no maskas tos koku vainagiem piederošos pikseļus, kas atbilst koku vainagu apakšējai daļai.

Rezultātā var definēt, ka koku vainagi atbilst visiem objektiem, kas ir augstāki par 3 metriem un kam ir raksturīga relatīvi augsta hlorofila klātbūtne.

Šī pieeja ļoti ātri ļauj aprēķināt koku vainagu noseguma masku, taču maskā var nebūt iekļauti nokaltuši koki un koku vainagu daļas, kas ir zemākas par 3 metriem, bet novērojamas tālzipētes datos.

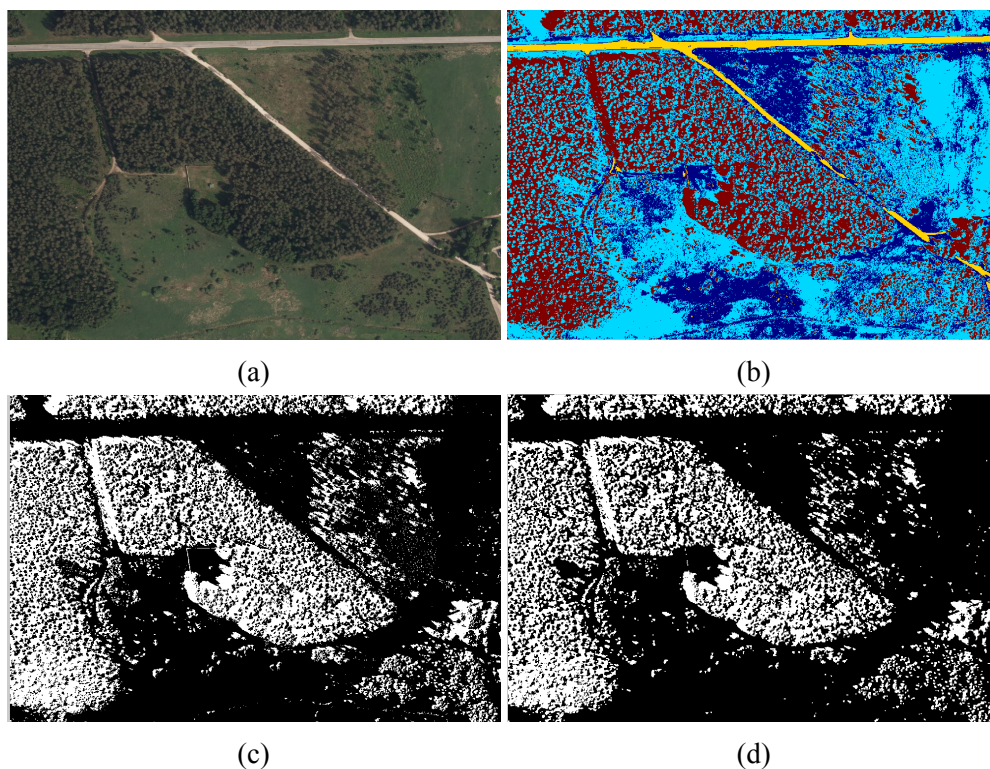
Tā kā attēlu aritmētika tiek veikta pikseļa līmenī, tad vietām ir iespējami trokšņaini rezultāti, piemēram, divi pikseļi pieder koku vainagu noseguma klasei, bet pārējie šo pikseļu kaimiņu pikseļi citam zemes pārseguma tipam. Šādas trokšņainas atbildes ir iespējams ierobežot, veicot telpisko mediānas filtrāciju.



Att. 4.15. Koku vainagu noseguma kartes aprēķināšanas shēma.







Att. 4.16. Ēnu noteikšana, izmantojot  $k - means$  nevadītās klasifikācijas algoritmu: a) dabisko krāsu testa attēls, ortofotokarte mērogā 1:10 000 © Latvijas Ģeotelpiskās informācijas aģentūra, 2013, b)  $k - means$  klasifikācijas rezultāts, atrastās spektrālās klases iezīmētas dažādās krāsās, c) tumšākās spektrālās klases binārais attēls, d) binārais attēls 4.16.c pēc attēla morfoloģiskās atvēršanas, izmantojot 3x3 kvadrātveida struktūrelementu.

objektu, kuru vēlamies binārajā attēlā  $A$  nodzēst. Morfoloģiskā atvēršana ir divu secīgu attēlu morfoloģiskā formālisma operāciju izpilde:


$$A \circ b = (A \ominus b) \oplus b, \quad (4.11.)$$

kur  $\ominus$  apzīmē attēla  $A$  eroziju ar struktūrelementu  $b$ , bet  $\oplus$  attēla  $A$  paplašināšanu ar struktūrelementu  $b$ . Attēla erozijas mērķis ir noņemt elementus, kas ir mazāki par struktūrelementu, taču tiek sašaurinātas arī lielāko objektu robežas. Attēla paplašināšana atjauno lielāko objektu robežas. Soļa rezultāts ir parādīts attēlā 4.16.d.

#### 4. Bufersonu pievienošana, izmantojot distances transformāciju.

Iepriekšējos soļos ir konstatētas dažādu objektu mestās ēnas. Izveidojot buferzonas apkārt visiem binārajiem objektiem tiek aizpildīti sīkāki caurumi binārajos ēnu attēlos, kā arī atsevišķiem koku un krūmu vainagiem tiek iekļauta maskā arī pati vainaga teritorija. Binārā attēla distances transformācijas attēla katra pikseļa vērtība parāda, cik pikseļus tālu atrodas konkrētā pikseļa tuvākais priekšplāna pikselis (ar vērtību 1, baltā krāsā). Rezultāta piemērs parādīts attēlā 4.17.

#### 5. Teritoriju izņemšana, kas atbilst citam zemes pārseguma tipam.



Att. 4.17. a) Distances transformācijas attēls, b) distances transformācijas rezultātā iegūtā maska.

Šajā etapā tiek sagatavota maska, kas izslēdz no attēla dažādus objektus, kas viennozīmīgi nav saistīti ar mežu teritorijām. Mežu teritorijām raksturīga raupja tekstūra un specifiska spektrālā signatūra sarkanās gaismas un tuvā infrasarkanā diapazonā.


Sākumā tiek ģenerēts binārais attēls  $M_{cits}$ , kas satur tikai vērtības 1.

Hlorofila klātbūtne attēlā tiek konstatēta ar veģetācijas indeksa NDVI palīdzību. Ja NDVI ir mazāks par 0, tad hlorofila klātbūtne netiek konstatēta un maskā atbilstošie pikseli tiek iezīmēti ar vērtību nulle.

Tekstūra tiek pārbaudīta ar entropijas palīdzību. Ja pikseļa apkārtnē notiek straujas pelēko toņu izmaiņas, tad entropijas vērtība ir augsta. Savukārt, ja pikseļa apkārtnē straujas pelēko toņu izmaiņas nenotiek, tad tekstūra ir vienmērīga un entropijas vērtība ir zema. Ja entropija ir mazāka par 3.5, tad atbilstošie pikseli tiek iezīmēti ar vērtību nulle. NDVI un entropijas attēlu piemēri parādīti 4.18.

Ja ir pieejams normalizētais digitālais virsmas modelis, tad maskas izveidē iespējams pievienot arī tikai augsto objektu atlasī, sliekšņojot nDSM kā iepriekšējā nodaļā.

Arī šajā solī atrastajiem objektiem tiek veidotas buferzonas, izmantojot distances transformāciju, lai samazinātu ēnu efektus no citiem objektiem, kas nav koku vai krūmu vainagi.



Att. 4.18. a) NDVI attēls, b) entropijas attēls, izmantojot  $9 \times 9$  apkārtni.

Rezultātā mežu teritoriju masku var aprēķināt  $M_{mezi} = M_{kmeansApstradats} AND M_{cits}$ .

#### 6. Caurumu aizpildīšana binārajā maskā.

Beidzamais metodes solis ir pārbaudīt caurumu izmēru binārajā maskā  $M_{mezi}$  un ja izmērs ir mazāks par lietotāja definētu sliekšni, tad aizpildīt šos caurumus ar vērtību viens. Algoritmiski tas tiek realizēts, invertējot bināro attēlu  $M_{meziInv} = 1 - M_{mezi}$ , atrodot binārā attēla savienotās komponentes un pārbaudot katras savienotās komponentes izmēru. Ja izmērs ir mazāks par sliekšni, tad savienotās komponentes pikseļu vērtības tiek aizstātas ar vērtību 0. Kad pārbaudītas visas komponentes, tad attēls tiek vēlreiz invertēts. Rezultātu testa attēlam skatīt att. 4.19.



Att. 4.19. TCID metodes rezultāts. Koku vainagu nosegums iekrāsots zaļā krāsā. Attēla pamatslānis: ortofotokarte mērogā 1:10 000 © Latvijas Ģeotelpiskās informācijas aģentūra, 2013.

### **Metodes priekšrocības:**

- Lietotāja definētie parametri ir eksperimentāli viegli pielāgojami un iespējams izmantot noklusētās sliekšņu vērtības.
- Metode spēj apstrādāt ortofotokartes, kas ir dažādos laika periodos iegūtu aerofotogrāfiju mozaīka.
- Nav nepieciešami apmācības dati, jo metode ir nevadīta.

### **Metodes trūkumi:**

- Nav iespējams atšķirt ūdens teritorijas no tumšām ēnām, jo NDVI indeksa vērtības ir ļoti līdzīgas.
- Metodi ieteicams pielietot vasaras sezonas datiem.

Metodes rezultātu kļūdu analīze parādīja, ka kopā mežs netiek atpazīts 143 testa punktos: 122 punktos kļūdas saistītas ar Lidar augstuma mērījumu sliekšni vai punkta atrašanos uz koka vainaga ārējās malas, 21 punkta gadījumā kļūdas iemesls nav viennozīmīgi novērojams līdz ar to tas var būt saistīts ar klāsterizācijas procesa rezultātiem.

Cīts zemes pārsegums kā mežs tiek atpazīts 20 testa punktos un visos punktos izteikti novērojama saistība ar robežām starp zemes pārseguma tipiem.

### **4. 5. 3. Konvolūcijas neironu tīkla U-Net pielietojums**


Konvolūcijas neironu tīkliem (dziļajai apmācībai, konvNN) atšķirībā no pilnībā savienotu neironu tīklu koncepcijas raksturīgi:

- Īpaši konvolūcijas slāņi un spēja atdalīt datu deskriptorus apmācības procesā. Lietotājam pašam nav jāsaprot datu deskriptori.
- Daudz slāņu un daudz perceptronu neironu tīkli, kas satur dažādu uzdevumu slāņus, ar kuru palīdzību iespējams atdalīt dažādu līmeņu deskriptorus.
- Liels datu daudzums, kas nepieciešams tīkla apmācībai.

**Konvolūcijas neironu tīklu** arhitektūrā ir iestrādāts pieņēmums, ka ievades dati ir attēli. Šāda pieņēmuma iekļaušana ļauj efektīvāk apstrādāt izaicinājumus, kas saistīti ar dažādām variācijām attēlos: mūs interesējošais objekts var būt novietots jebkurā attēla apgabalā, iespējamās apgaismojuma, objekta izmēru, rotācijas un skata punkta variācijas, objekta deformācijas un aizsegumi, kā arī iespējama augsta fona sarežģītība, kas apgrūtina objekta atpazīšanu.

**Konvolūcijas slāņi** ļauj sasaistīt atsevišķus attēla apgabalus ar noteiktiem konvNN perceptroniem. Novietojot vairākus konvolūcijas slāņus vienu aiz otra, mēs varam sasaistīt iepriekšējā konvNN slāņa perceptronu apgabalu ar kādu nākamā slāņa perceptronu, skat. att. 4.20.

Sasaistes starp apgabaliem un nākamā slāņa perceptroniem tiek nodrošinātas ar t.s. slīdošo logu palīdzību. Slīdošais logs aptver noteikta izmēra apgabalu, piemēram,  $5 \times 5$  elementu lielu apgabalu. Ievades slāņa gadījumā tas ir  $5 \times 5$  pikseļu apgabals attēlā, bet konvolūcijas slāņu gadījumā tas ir  $5 \times 5$  perceptronu apgabals. Slīdošo logu pārvieto uz priekšu pa slāni, definējot noteiktu soli, piemēram, ik pa 2 elementiem uz priekšu.



Att. 4.20. Konvolūcijas neironu tīkla vispārīgs modelis [85].

Svara koeficienti konvolūcijas slāņu savienojumos ļauj atdalīt atdalīt attēla pazīmes jeb konvolūcijas tīkls spēj iemācīties ne tikai klasifikācijas un citu uzdevumu veikšanu, bet tas spēj arī izvilkt attēla pazīmes, kas ir efektīvas uzdevuma veikšanai. Līdz ar to, konvolūcijas NN apmācības datiem nav jāsaturs manuāli sagatavotas attēla pazīmes. Svara koeficientus varam uzskatīt par filtru, kas tiek lietots attēla pazīmju atdalīšanai. Vienam konvolūcijas slānim dziļuma slāņu skaits atbilst filtru skaitam, kuru vēlamies atrast un bieži lietota aktivizācijas funkcija ir ReLU. Konvolūcijas slāņa izvadē saņemam tā saucamās pazīmju kartes jeb attēlu, kas satur tikai tās pazīmes, kuras ir atdalītas ar filtru palīdzību. Pazīmju karšu pētīšana ir viens no veidiem kā varam izprast kādas attēla pazīmes konvNN ir iemācīties.

Ja izmantojam tikai vienu konvolūcijas slāni, tad mēs pētām relatīvi nelielus ievades attēla apgabalus, kas atbilst lokālām attēla pazīmēm, piemēram, malām. Samazinot ievades datu dimensijas un pielietojot papildu konvolūcijas slāņus varam atdalīt arī augstāka līmeņa attēla pazīmes. Dimensiju samazināšana notiek, izmantojot, t.s., grupēšanas slāņus. Viens no bieži lietotiem risinājumiem datu dimensijas samazināšanai ir grupēšana, izmantojot maksimālo vērtību. Pārvietojam slāņa ieejas datiem pāri slīdošo logu ar izmēru  $M \times N$  un kā izejas datus no katras slīdošā loga pozīcijas atlasām tikai maksimālo vērtību. Šāda pieeja nodrošina, ka no pazīmju kartēm atlasām tikai būtisko informāciju jeb to informāciju, uz kuru konvolūcijas slāņa filtrs ir reaģējis ar nenulles vērtībām.

Secīgs konvolūcijas un grupēšanas slāņu izvietoējums ļauj no ievades datiem atdalīt aizvien augstāka un augstāka līmeņa attēla pazīmes, jo dimensiju samazināšanas un filtru noteikšanas procesā mēs mēģinām identificēt pazīmes jau noteiktām pazīmēm.

Pēc konvolūcijas un grupēšanas slāņiem seko viens vai vairāki t.s. pilnībā savienotie slāņi. Pēdējais no pilnībā savienotajiem slāņiem izvadīs sagaidāmo tīkla rezultātu, piemēram, attēla piederības varbūtību katrai no klasēm, tādēļ pēdējā slāņa aktivizācijas funkcija ir atkarīga no uzdevuma. Klasifikācijas tīkliem bieži lieto softmax funkciju, bet regresijas uzdevumiem lineāru aktivizācijas funkciju.

Konvolūcijas tīklos mēdz iestrādāt vēl citus aspektus:

- Izmešanas slānis pēc gadījuma iestata noteiktu proporciju no ievades datiem kā nulli katrā apmācības solī, lai novērstu tīkla pārtrenēšanos.
- Tikai lokāli savienoti slāņi, kas darbojas līdzīgi konvolūcijas slāņiem, taču svara koeficienti netiek kopīgioti dažādiem apgabaliem. Tā vietā katram apgabalam ir unikāla filtru kopa.
- Rekurentie slāņi, kas ir īpaši piemēroti laika rindu apstrādei.
- Slāņi iepriekšējo slāņu rezultātu savienošanai vai datu formas maiņai.

Praksē strādājot ar dziļo apmācību jāreķinās ar diviem galvenajiem aspektiem. Pirmkārt, jābūt pietiekamam datu nodrošinājumam tīkla apmācībai. Otrkārt, jābūt pietiekamam tehniskajam nodrošinājumam tīkla apmācībai, kas visbiežāk nozīmē grafiskā procesora lietošanu.

Viens no veidiem kā izprast ko tieši neironu tīkls ir iemācījies ir pazīmju karšu vizualizācija. Pazīmju kartēs varam novērot tos attēla apgabalus, kas ir visvairāk reaģējuši uz filtru iedarbību. Ja pazīmju kartes satur tikai nulles vērtības, tad tad efektīva filtra koeficientu atrašana nav izdevusies un viens no potenciālajiem iemesliem varētu būt pārāk straujš mācīšanās koeficients.

Otrs no veidiem ir vizualizēt filtrus jeb svara koeficientus. Pašu filtru vizualizācijas ļauj labāk izprast kādas pazīmes tieši neironu tīkls ir iemācījies. Trokšņaini filtri norāda uz tīkla pārtrenēšanos.

**Kā konvolūcijas neironu tīkla arhitektūra koku vainagu nosejuma atpazīšanai tika izvēlēta U-Net konvolūcijas tīkla arhitektūra [107].**

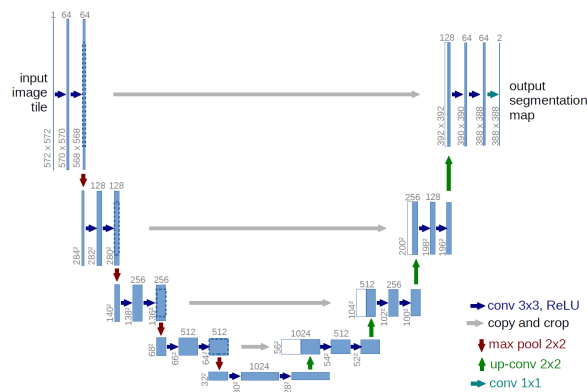
U-Net modelis atbilst kodētāja - dekodētāja (angl. *encoder - decoder*) neironu tīkla koncepcijai un sastāv no divām galvenajām daļām:

1. kodētāja, kura mērķis ir attēla pazīmju izvilkšana un reprezentācija;
2. dekodētāja, kura mērķis ir kļūdu atpazīšana kodētāja reprezentācijā un segmentēto robežu atgūšana, kuras ir zudušas attēla datu samazināšanas procesā.

Attēlā 4.21. parādīta U-Net konceptuālā arhitektūra (koku vainagu nosejuma pētījumiem izmantota arhitektūra ar atšķirīgu slāņu izmēru).

Modeļa uzbūvē lietoti:

- konvolūcijas slāņi;
- datu apjoma samazināšanas slāņi, atlasot maksimālo vērtību loga ietvaros;
- datu izmēra palielināšana, pievienojot dekodētāja slāņiem kodētāja konvolūcijas slāņu izvades datus.



Att. 4.21. U-Net arhitektūra [97].

Kā neironu tīkla apmācības dati tika izmantota sliekšņošanas darbplūsmas rezultātā iegūtā binārā maska. Apmācības datus veido informācija par 757.44 hektāru plašu teritoriju Ventspils pilsētas dienvidu daļā (algoritmu testēšana notiek apgabalam Ventspils ziemeļu daļā). Attēls pirms tīkla apmācības tiek sašķelts 96 x 96 pikseļu lielās daļās. Šāds daļas izmērs tika izvēlēts praktisku apsvērumu dēļ kā lielākais apjoms, kādu iespējams apstrādāt, izmantojot esošos GPU un operatīvās atmiņas resursus. 75 % no apmācības datiem tiek izmantoti apmācības mērķiem, bet 25 % validācijai, lai kontrolētu iespējamo tīkla pārmācīšanos.

**Pētāmais jautājums: kā iestatīt U-Net parametrus?**

Apmācības procesa analīze norādīja uz epochu skaita nozīmību. Lai arī tīklā ir iestrādāta datu izmešana, tomēr pie liela epochu skaita notiek pārmācīšanās (apmācības datiem novērojama ļoti augsta precizitāte, bet validācijas datiem tā ir zema). Šī iemesla dēļ tīkls tika apmācīts, izmantojot 80 epochas, skat. 4. 12.

Epochu skaits	OA (%)	PA (%) fo-rest/other	UA (%) fo-rest/other	$\hat{k}$
600	90.7	84.8/98.1	98.3/83.8	0.81
80	91.0	85.1/98.3	98.4/84.1	0.82

Tabula 4. 12. Epochu skaita ietekme uz rezultātu precizitāti.

**Pētāmais jautājums: kāda datu kopa ļauj sasniegt augstāko rezultātu precizitāti?**

Tabulā 4. 13. apkopoti U-Net rezultāti testa apgabalam A3. Redzams, ka datu kopas izvēle precizitātes rādītājus ietekmē relatīvi maz.

Datu kopa	OA (%)	PA (%) fo-rest/other	UA (%) fo-rest/other	$\hat{k}$
CIR	91.0	85.1/98.3	98.4/84.1	0.82
nDSM	91.3	96.3/85.1	88.8/94.9	0.82
CIR+nDSM	91.2	85.7/97.9	98.1/84.8	0.82

Tabula 4. 13. Dažādu datu kopu apstrādes rezultātu precizitāte.



#### 4. 6. Rezultāti un diskusija

Dati	OA (%)	PA (%) fo- rest/other	UA (%) fo- rest/other	$\hat{k}$
LC81870202014023LGN0 un hibrīdā klasifikācija	94.2	98.7/90.5	90.0/98.8	0.89
Globālā koku vainagu nose- guma karte [42]. Koku vaina- gu nose gums lielāks par 50% tiek uzskatīts par saderīgu ar šī pētījuma rezultātiem	85.9	96.3/76.8	78.3/96.0	0.72
European Commision's Joint Research Centre Pan- European Forest/Non - Forest Map 2000.	80.7	87.7/74.6	75.0/87.5	0.62
CORINE 2012 koku vainagu noseguma karte. Pirmie skait- liskie rādītāji ietver krūmājus un pārējas klasi uz koku vai- nagu nose gumu, otrie šo klasi neietver	84.5, 85.7	98.9/71.1, 86.5/85.0	75.4/98.7, 83.4/87.8	0.69, 0.71

Tabula 4. 14. Pētījumu apgabals A2: precizitātes raksturlielumi publiski pieejamām koku vainagu nose guma kartēm un labākajiem šī pētījuma rezultātiem.

Labākie metožu rezultāti apkopoti tabulās 4. 14. un 4. 15. Precizitātes aprēķini visiem datu produktiem tika veikti, izmantojot neatkarīgu testa punktu kopu, kas detalizēti tika aprakstīta nodaļā "Pētītie apgabali un izmantotie dati".

Globālo koku vainagu nose guma karšu analīze parādīja, ka visu šo karšu kopējā precizitāte ir virs 80%. Lokāli pielāgotie risinājumi šī darba ietvaros uzrāda augstāku precizitāti. Aptuvenais precizitātes palielinājums ir 10 % salīdzinājumā ar globālajiem risinājumiem.

Gadījumu studijas parādīja, ka visu metožu gadījumā kritiski svarīga ir satelītattēlu ieguves sezona un atmosfēras apstākļi attēla ieguves brīdī. Augstāko precizitāti iespējams sasniegt, ja satelītattēli iegūti sezonā bez zaļās veģetācijas. Ja papildu koku vainagu nose gumam plānota arī purvu teritoriju klasifikācija, tad būtiski, lai nebūtu novērojama sniega sega. Precizitāti samazina izteikta dūmaka attēlos.

Nākamais kritiski svarīgais faktors ir apmācības datu izvēle un atlase. Zemā precizitāte Sentinel-2B satelītattēla klasifikācijā, izmantojot kNN Ventspils testa apgabalam A3 ir skaidrojama ar to, ka apmācības un testa dati tika sagatavoti, izmantojot divu dažādu laika perioda ļoti augstas telpiskās izšķirtspējas attēlus. Ja apmācības datu kvalitāte ir zema, tad hibrīdās klasifikācijas darbplūsma uzrāda par aptuveni 10 % augstāku precizitāti nekā kNN, jo apmācības datiem šīs darbplūsmas ietvaros ir mazāka loma. Hibrīdās klasifikācijas metodi spēcīgi ietekmē attēlu sezonālitate, tādēļ šīs metodes gadījumā satelītattēli sezonā bez zaļās veģetācijas ir īpaši būtiski.

Dati	OA (%)	PA (%) fo- rest/other	UA (%) fo- rest/other	$\hat{k}$
Sentinel 28.05.2017. un kNN	73.5	77.7/68.4	75.5/71.0	0.46
Sentinel 28.05.2017. un hib- rīdā klasifikācija	84.18	90.2/76.6	82.8/86.3	0.68
Sliekšņošanas darbplūsma	92.8	91.9/93.9	95.0/90.2	0.85
TCID	89.5	83.0/91.7	97.2/82.9	0.79
U-Net un nDSM	91.3	96.3/85.1	88.8/94.9	0.82
U-Net CIR+nDSM	91.2	85.7/97.9	98.1/84.8	0.82
Globālā koku vainagu nose- guma karte [42]. Koku vaina- gu nose gums lielāks par 50% tiek uzskatīts par saderīgu ar šī pētījuma rezultātiem	83.5	88.9/76.7	82.7/84.8	0.66
European Commision's Joint Research Centre Pan- European Forest/Non - Forest Map 2000.	83.7	87.9/78.5	83.6/83.8	0.66
CORINE 2012 koku vainagu noseguma karte. Pirmie skait- liskie rādītāji ietver krūmājus un pārējas klasi uz koku vai- nagu nose gumu, otrie šo klasi neietver	83.7 (83.1)	86.6/79.9 (84.9/80.8)	84.4/82.7 (84.7/81.0)	0.67 (0.66)

Tabula 4. 15. Pētījumu apgabals A3: precizitātes raksturlielumi publiski pieejamām koku vainagu nose guma kartēm un labākajiem šī pētījuma rezultātiem.

Parametru pētījumi parādīja, ka mežaudzes noteikšanas iespējas vidējas telpiskās izšķirtspējas satelītattēlos ietekmē mežaudzes blīvums. Ar augstu pārlicības līmeni iespējams detektēt mežaudzes, kuru koku vainagu nose gums sasniedz aptuveni 60%. Tā kā koku vainagu nose gums bieži korelē ar mežaudzes krāju, tad rezultāti parādīja, ka ar augstu pārlicības līmeni iespējams noteikt mežaudzes, kuru krāja ir lielāka par  $100 \text{ m}^3/\text{ha}$ .

Nozīmīgs algoritmu un darbplūsmu papildinājums ir pārlicības līmenis. Tas gala rezultātā ļauj novērtēt kartes uzticamību katra pikseļa klases novērtējuma līmenī. kNN pārlicības līmenis viszemākais bija pikseļiem, kas atrodas uz robežas starp dažādām zemes pārseguma klasēm, kas izskaidrojams ar jaukto pikseļu klātbūtni, kā arī purvu teritorijās. Hibrīdās klasifikācijas ietvaros koku vainagu nose guma klases ar zemāko pārlicības līmeni atbilda relatīvi zema blīvuma audzēm.

Salīdzinot vidējas telpiskās izšķirtspējas un ļoti augstas telpiskās izšķirtspējas datu klasifikācijas rezultātus, jāņem vērā testa punktu atrašanās vietas. Punktiem atrodoties homogēnās teritorijās precizitātes raksturlielumi atšķiras 10 - 20 % ietvaros, taču augstās telpiskās izšķirtspējas dati sniedz iespēju daudz precīzāk klasificēt retas mežaudzes un robežteritorijas starp dažādiem zemes pārseguma tipiem.

Pati vienkāršākā augstas telpiskās izšķirtspējas datu klasifikācijas metodika parādīja visaugstāko kopējo precizitāti. Vienkārša sliekšņošanas darbplūsma kļūdas pieļauj tikai no-

teiktos un prognozējamos scenārijos: 1) tā nespēj detektēt nokaltušus kokus un krūmus, kas zemāki par noteikto objekta augstuma sliekšni, 2) tā kļūdaini izlaiž gadījumu, kad koku vainagiem bez lapu noseģuma spīd cauri atklāta augsne vai cits hloforofilu nesaturošs materiāls.

TCID metode salīdzinot ar sliekšņošanas darbplūsmu uzrādīja zemāku precizitāti, taču šī metode ir pielietojama arī gadījumos, kad normalizētais virsmas modelis nav pieejams. Tā kā TCID izmanto veģetācijas indeksu, tad metode pieļauj kļūdas tajos pašos scenārijos kā sliekšņošanas metodika.

Konvolūcijas neironu tīklu pielietojumu visvairāk apgrūtina lielais un precīzais palīgdatu apjoms, kas nepieciešams, lai apmācītu tīklu. Šajā darbā tas tika risināts, izmantojot sliekšņošanas darbplūsmas rezultātus kā palīgdatumus. Tas ļauj sagatavot lielu datu apjomu, taču tajā pašā laikā rada risku, ka konvolūcijas neironu tīkls "iemācās" kopēt sliekšņošanas rezultātus, nekompensējot šīs darbplūsmas trūkumus. Gadījumu izpētes gan parādīja, ka konvolūcijas neironu tīkls U-Net ar līdzvērtīgu precizitāti atdala koku vainagu noseģumu gan krāsu infrasarkanajās ortofotokartēs, gan nDSM, gan apvienotajā datu kopā. Tas nozīmē, ka tīkls ir efektīvi pielietojams jebkura tipa datu apstrādei un to ir iespējams apmācīt arī citu sezonu datu apstrādei, kad veģetācijas indeksa sliekšņošana nav iespējama.

## 5. Metodes atsevišķu koku identifikācijai un vainagu atdalīšanai

### 5. 1. Eksistējošie risinājumi

Uz tālīzpētes datiem balstītu meža inventarizāciju iespējams realizēt, izmantojot divas pieejas [33]:

- Meža inventarizācijas parametru noteikšana pikseļu līmenī. Šīs pieejas ietvaros katrs pikselis tiek apskatīts kā inventarizējamā vienība un klasifikācijas metožu palīdzību katram pikselim tiek veikti meža inventarizācijas parametru novērtējumi.
- Vispirms tiek veikta atsevišķu koku identifikācija un/vai vainagu atdalīšana. Meža inventarizācijas parametri tiek novērtēti atsevišķiem kokiem un pēc tam tiek sarēķināta nogabalu statistika.

Pētījumi rāda, ka meža inventarizācija atsevišķu koku līmenī ir precīzāka nekā pikseļa līmenī, taču rezultāti ir atkarīgi no atsevišķu koku identifikācijas un vainagu atdalīšanas precizitātes [67].

#### Praktiskais uzdevums

Veikt koku vainagu identifikāciju un atdalīšanu, izmantojot ļoti augstas telpiskās izšķirtspējas multispektrālos un Lidar datus (kopīgi apstrādājot vai apstrādājot atsevišķi).

**Atsevišķu koku identifikācija** (angl. *tree identification*) ir koku novietojuma koordinātu atrašana ar datorizētu metožu palīdzību. Tālīzpētes datu gadījumā tas attiecas uz koku vainagu virsotņu koordinātu atrašanu.

**Koku vainagu atdalīšana** (angl. *tree delineation*) nozīmē koka vainaga kontūras iezīmēšanu un visbiežāk tas ir nākamais solis pēc atsevišķu koku identifikācijas. Tālīzpētes datu gadījumā koku vainagu kontūra tiek iezīmēta atbilstoši datos pieejamajai informācijai un ne visos gadījumos tas nozīmē koka vainaga projekcijas uz zemes atrašanu.

Automatizēto procedūru efektivitāte koku vainagu identifikācijas un atdalīšanas uzdevumu veikšanai ir atkarīga no konkrētā koka parametriem, mežaudzes apstākļiem, datu ieguves sensora veida, izšķirtspējas un izmantotā algoritma [68].

Pasīvo multispektrālo sensoru gadījumā un Lidar normalizētā virsmas modeļa gadījumā visas populārās metodes ir balstītas uz pieņēmumu, ka koka virsotne ir gaišāka. Lidar datu gadījumā šis pieņēmums loģiski seko no Lidar datu pamatkonceptijas. Savukārt multispektrālo datu gadījumā, tiek pieņemts, ka vainaga centrs ir gaišāks par vainaga malām, jo tas vairumā gadījumu tiek spēcīgāk apgaismots. Papildu tam, blīvās audzēs blakus esošie koki aptumšos vainagu malas viens otram, pastiprinot vēlamo efektu. Dažām koku sugām izpildās sakarība, ka lapas, ka aug ēnā absorbē vairāk starojuma zaļajā un tuvā infrasarkanā diapazonā [16].

Metodes atsevišķu koku identifikācijai, izmantojot **viena sensora attēlus** visbiežāk klasificējamās vienā no 4 kategorijām [56]:

### 1. **Lokālo maksimumu filtrācija** (angl. *Local maximum filtering*).

**Metodes koncepcija:** tiek pieņemts, ka koku virsotnēm atbilst pikseļu vērtību lokālie maksimumi. Lokālie maksimumi tiek atrasti "bīdot" pāri attēlam fiksēta vai mainīga izmēra logu un meklējot maksimālās vērtības šo logu ietvaros. Ja koku vainagu izmēri ir dažādi, tad lieli logi izraisa identifikācijas kļūdas, kamēr mazi logi izraisa apstiprinājuma kļūdas, kuru ietvaros lieli koku vainagi tiek pieskaitīti vairākas reizes. Lokālo maksimumu filtrācija tiek izmantota ļoti plaši gan multispektrālo, gan Lidar datu apstrādē [10], [5], [114], [58].

### 2. **Attēlā binarizācija** (angl. *image binarization*)

**Metodes koncepcija:** pelēko toņu attēls tiek pārveidots par bināro attēlu, kur baltie pikseli reprezentē koku vainagus, bet melnie reprezentē fonu [52]. Koku novietojumi tiek atrasti, meklējot lokālās maksimuma vērtības binārā attēla priekšplāna objektos.

### 3. **Mērogu analīze** (angl. *Scale analysis*)

**Metodes koncepcija:** vienas attēla telpiskās izšķirtspējas gadījumā ir grūti noteikt atšķirīgu izmēru koku vainagus. Mērogu analīzes ietvaros attēla izšķirtspēja tiek mākslīgi samazināta, pielietojot attēla izlīdzināšanas metodes un pie dažādiem izlīdzinājuma līmeņiem tiek pielietota lokālo maksimumu filtrācija [51], [8].

### 4. **Šablonu salīdzināšana** (angl. *Template Matching*)

**Metodes koncepcija:** attēlam tiek "bīdīts pāri" šablons, kas reprezentē koka vainagu un katram pikselim tiek aprēķināts normalizētais korelācijas koeficients. Pikseliem, kuros tiek sasniegta augsta korelācijas koeficienta vērtība tiek atrastas koka koordinātes [89], [88].

**Metodes atsevišķu koku vainagu atdalīšanai, izmantojot vienu datu avotu:**

- Ieleju sekošanas algoritmi (angl. *Valley following*) [36], [69], [53].
- Reģionu audzēšanas algoritmi (angl. *Region growing*) [10].
- Ūdensšķirtnes segmentācija (angl. *watershed segmentation*) [18], [73].

Pētījumā [55] tika salīdzināti 3 algoritmi, kas balstīti uz šīm pieejām un lai arī labus rezultātus sniedza visi algoritmi skujkoku gadījumā, visaugstāko vainagu atdalīšanas precizitāti varēja sasniegt ar reģionu audzēšanas algoritmu. Savukārt lapukoku gadījumā neviens no algoritmiem nesniedza apmierinošus rezultātus.

Pētījumā [18] tika salīdzināti koku vainagu atdalīšanas rezultāti Lidar nDSM modelim (7 punkti/ $m^2$  uz 0.2 m režģa) un hiperspektrālo datu joslai 810 nm (uz 0.4 m režģa), izmantojot uz ūdensšķirtnes segmentācijas metodes balstītu algoritmu. Pētījumā apskatītas līdzīgas koku sugas kā Latvijā, bet ar lielāku skujkoku īpatsvaru (Norvēģija). Rezultātā Lidar datus tika atpazīti divreiz vairāk koki nekā hiperspektrālajos, telpiskās izšķirtspējas atšķirību dēļ

un ēnu efektu dēļ. Koku identifikācijas precizitāte hiperspektrālo datu gadījumā bija 28.4 %, bet Lidar datu gadījumā 48.5% . Pētījuma autori uzsvēra, ka visas koku identifikācijas metodes ir paredzētas dominējošo koku noteikšanai. Kvalitāte ir atkarīga arī no koku sugas, jo dažādām sugām ir dažādas preferences attiecībā uz augšanas apstākļiem, piemēram, priedei un eglei. Hiperspektrālie dati slikti ļāva atdalīt koka vainaga formu, it sevišķi, tie nespēja atdalīt blakus esošus kokus. Hiperspektrālajos datos tika iegūta mazāka koku vainagu izmēru variācija. Algoritmu precizitāti ierobežo pikseļu intensitāšu variācijas vainagu iekšienē un vainagu atšķiramība; kļūdu palielina vainagi, kas pārklājas un zemsedze [92].

Pie vienas telpiskās izšķirtspējas ir grūti noteikt gan ļoti mazus, gan ļoti lielus koku vainagus, tādēļ heterogēnu mežu apstākļu gadījumā, labi noder mērogu analīzes metode [9]. Mērogu analīzes metode īpaši piemērot ārkārtīgi augstas izšķirtspējas datiem, jo zemāku izšķirtspēju vienmēr ir iespējams iegūt, veicot interpolāciju uz citas izšķirtspējas režģa.

Gandrīz visu iepriekšminēto koncepciju rezultāti ir atkarīgi no algoritmu parametru izvēles, kuru optimālā noteikšana bieži nav atrisināta un ir balstīta uz eksperimentālu procesu [5]. Parametru noteikšanu potenciāli iespējams optimizēt pievienojot papildus informāciju koku vainagu atdalīšanas procesā, piemēram, koku augstumu [9].

Retāk tiek izmantoti algoritmi, kas apstrādā Lidar datus 3D formātā [100], [70]. Šīs pieejas ir balstītas uz Lidar punktu klāsterizāciju, piemēram, izmantojot *k-means* klāsterizācijas algoritmu.

Datu kopīgās apstrādes metodes, kas atbilst datu kopīgās apstrādes definīcijai, koku vainagu atdalīšanā ir pētītas maz. Izmantotās metodes ietver datu kopīgu apstrādi pazīmju līmenī un lēmumu līmenī.

**Daudzpazīmju segmentācija** (angl. *multifeature segmentation*) darbojas pazīmju līmenī. Daudzpazīmju segmentācijas ietvaros segmentācijas uzdevuma veikšanai tiek izmantoti dažādu tipu deskriptori vai deskriptori, kas aprēķināti no dažādiem datu avotiem. Atsevišķu koku daudzpozīmju segmentācijai pētījumos izmantoti komerciālajās programmatūrās *eCognition* [106], [19], [6] un ERDAS IMAGINE [62] iekļautie algoritmi. *eCognition* iekļautais algoritms ir reģionu audzēšanas metode, kas kā segmentācijas novērtēšanas kritēriju izmanto nosacījumu, ka pikseļu vidējo heterogenitāti nepieciešams minimizēt. Heterogenitāte iekļauj gan spektrālo, gan formas informāciju. Kā papildus parametrs metodē tiek izmantots arī mazākā sagaidāmā objekta izmērs.

Pētījuma [106] autori *eCognition* segmentācijas metodi pielietoja egļu audzes segmentācijai, izmantojot multispektrālos datus ar 25 cm izšķirtspēju un Lidar datus ar punktu blīvumu 3-4 punkti/ $m^2$ . Segmentācija tikai veikta RGB krāsu attēlam un Lidar nDSM. Labākās lietotāja definēto parametru vērtības tika noteiktas eksperimentu rezultātā. Koku vainagu identifikācijas un atdalīšanas precizitāte rakstā netika apskatīta, taču tikai novērtēta koku augstuma noteikšanas precizitāte izmantojot noteiktos koku vainagus. Rezultātā 73% gadījumu augstuma noteikšanas kļūda bija 1 m robežās, 91 % gadījumu 1.5 m, 96 % gadījumu 2 m. Pētījuma rezultātā tika secināts, ka izmantotā metode ir ļoti atkarīga no attēla datiem un segmentācijas un klasifikācijas parametri netiek definēti automātiski, ne arī uzrāda sakarības

ar alometriskajiem faktoriem, tā vietā parametrus nepieciešams atrast intensīvu eksperimentu ceļā.

Pētījuma [62] autori secināja, ka Lidar un hiperspektrālo datu kopīga apstrāde segmentācijas procesā uzlabo identifikācijas precizitāti vidēji par 3-8 % biezas mežaudzes gadījumā (samazinot nepareizi patiesas atbildes par 1 - 12 %) un 13 - 29 % retas mežaudzes gadījumā (samazinot nepareizi patiesas atbildes par 8 -21%). Rezultātā labākā identifikācijas precizitāte 70% biežām audzēm un 92 % retām audzēm. Koku identifikācija tika veikta jauktam skujkoku un lapkoku mežam, izmantojot Lidar datus ar punktu blīvumu 4.3 punkti / $m^2$  un hiperspektrālajiem datiem ar izšķirtspēju 0.5 m. Pētījumā telpiskā izšķirtspēja tika atzīta par pārāk mazu.

**Algoritmu rezultātu apvienošana** darbojas lēmumu līmenī. Koku atdalīšanas algoritmi tiek pielietoti katram datu avotam atsevišķi un rezultāti tiek apvienoti. Šī pieeja pirmo reizi prezentēta [68]. Atsevišķi koki tiek segmentēti, izmantojot ieleju sekošanas algoritmu gan multispektrālajiem, gan Lidar datiem. Algoritms atrod lokālos minimumus un seko tiem starp koku vainagiem. Pēc tam, katram potenciālajam koku vainagam tiek veikta malu apsekošana pulksteņrādītāja kustības virzienā un pārbaudīts, vai forma atbilst gaidāmajai koka formai. Ja neatbilst, tad potenciālais koku vainags tiek sadalīts vai izņemts no rezultātiem. Pirms algoritma pielietošanas tiek veikta attēla izlīdzināšana ar 3x3 vidējā aritmētiskā filtru. Atrastie koku vainagi tiek pārbaudīti ar nDSM vērtību palīdzību: ja nDSM vērtība ir pārāk zema, tad segments neatbilst kokam, bet gan zemei. Galvenie pētījuma secinājumi bija, ka uz multispektrālajiem datiem balstīta koku identifikācija sasniedza 80 -90 % atbilstību ar manuāli iezīmētiem koku vainagiem. Segmentācija kā koku vainagus nepareizi iezīmē koku vainagiem cauri spīdošu augsni. Tas tika novērsts, izmantojot Lidar koku augstuma novērtējumus. Lidar novērtētie koku augstumi bija aptuveni par 1.3 m zemāki kā lauka mērījumos noteiktie. Grūti segmentēt retas vai pārāk blīvas audzes.

Šāda pieeja realizēta arī pētījumā [117], apvienojot ieleju sekošanas algoritmu rezultātus, kas iegūti atsevišķi Lidar CHM un augstas izšķirtspējas QuickBird satelītattēliem. Autori norāda, ka datu kopīgā apstrāde ļauj uzlabot rezultātu, taču konkrēti precizitātes raksturlielumi netiek parādīti.

Pētījumā [45] atsevišķu koku vainangu atdalīšana tika veikta, izmantojot Lidar nDSM un metodi, kas balstīta un lokālo maksimumu filtrāciju un reģionu audzēšanu vai ūdensšķirtnes segmentāciju [44]. Atrastie segmenti tiek salīdzināti ar pikseļa līmeņa koku sugu klasifikāciju. Ja koka vainaga segments satur vairāk kā vienu koku sugu, tad vainags tiek sadalīts pa koku sugu robežlīniju.

Savukārt, pētījumā [90] koku sugu klasifikācija tiek izmantota, lai atrastu optimālos ievades parametrus lokālo maksimumu filtrācijas metodei, izmantojot Lidar datus.

Rezultātā tika secināts, ka priedes meža inventarizācijas parametru noteikšana uzlabojās, izmantojot aplveida filtru un multispektrālos datus, savukārt lapu koku gadījumā nodēvēgāks bija kvadrātveida filtrs. Lidar un multispektrālo datu kopīga apstrāde uzlabo augstuma noteikšanas precizitāti.

Apkopojot literatūras apskatā konstatētās problēmas koku identifikācijā un vainagu atdalīšanā, var iezīmēt sekojošus izaicinājumus datorizētajām metodēm:

1. Koku vainagu izmēri dabiskās audzēs var būt ļoti atšķirīgi nelielā teritorijā.
2. Lapu kokiem raksturīga augsta pelēko toņu standarta novirze koka vainaga teritorijā gan Lidar, gan multispektrālo datu gadījumā. Lapu koku vainagu formai nav raksturīga izteikta koniska forma kā skujkoku gadījumā, līdz ar to koka vainagā var būt vairāki pelēkā toņu maksimumi, kas nav saistīti ar patieso koka virsotni.
3. Koku vainagi savstarpēji pārklājas un nav atšķirami pēc vizuālā novērtējuma. Pelēkā toņi noēnotajās teritorijās starp koku vainagiem ir līdzīgas tumšākajiem toņiem koku vainagu iekšienē.
4. Lidar datu gadījumā var būt vairāki scenāriji, kad Lidar pulss netrāpa patiesajai koka galotnei.

## 5. 2. Piedāvātie risinājumi

Šajā apakšnodaļā uzskaitīti promocijas darbā sasniegtie rezultāti un pamatota to novitāte.

**Promocijas darba rezultāti atsevišķu koku vainagu identifikācijai un kontūru noteikšanai:**

1. Notestēta šablonu salīdzināšanas metode, realizējot Lidar un multispektrālo datu kopīgu apstrādi.  
Autores zināšanu robežās, šablonu salīdzināšanas metode ir pielietota atsevišķi multispektrālajiem datiem un Lidar datiem, bet pētījumos nav apskatīta metodes pielietošana šo datu kopīgai apstrādei.
2. Veiktas šablonu salīdzināšanas metodes modifikācijas un gadījumu izpētes, lai parādītu modifikāciju ietekmi.  
Klasiskajai šablonu salīdzināšanas metodes realizācijai ir pievienota atbilžu filtrācija, šablonu izmēru maiņa un iespēja apvienot vairāku attēlu rezultātus.
3. Izstrādāta jauna metode EATG optimālas šablonu kopas ģenerēšanai, izmantojot evolucionāro algoritmu pamatidejas.  
Šī šablonu ģenerēšanas metode atšķiras no citām ar to, ka tā neizmanto iepriekš definētus koku vainagu un attēlu ģeometrijas parametrus, bet konstruē šablonus, izmantojot apmācības datu kopu. Metodes unikāla iezīme ir optimizācijas process šablonu veidošanas procedūrā, kas ļauj noteikt optimālu šablonu kopu, balstoties uz precizitātes novērtējumiem.
4. Izstrādāta jauna metode koku vainagu atdalīšanai, izmantojot Lidar un multispektrālo datu kopīgu apstrādi. Metodes pamatideja ir atdalīt koku vainagus, izmantojot dažādu



datu analīzi, balstoties uz pieņēmumu, ka apvienoti rezultāti ir precīzāki nekā viena datu avota rezultāti.

Metode no līdzīgām koncepcijām atšķiras ar iespēju iekļaut neierobežotu attēlu skaitu (tai skaitā diskrētu attēlus kā koku sugu klasifikācijas rezultātus) un trīskāršu rezultātu korekciju. Metode darbojas efektīvāk salīdzinot ar Mask R-CNN risinājumu, jo tā spēj apvienot ļoti daudz attēlu sniegto informāciju un tā izmanto pieņēmumu, ka koku vainaga formai ir jābūt apaļai.

5. Latvijas mežu apstākļos notestēta konvolūcijas neironu tīklu pielietošana koku vainagu atdalīšanai.
6. Iepriekš minētajām metodēm veikti pētījumi par multispektrālo un Lidar datu kopīgas apstrādes lietderību.

Šo gadījuma izpēšu novitāte ir saistīta ar koku identifikāciju un vainagu atdalīšanu sarežģītos meža augšanas apstākļos, izmantojot Lidar un multispektrālo datu savstarpēji papildinošo informāciju.


### 5. 3. Precizitātes novērtēšana

Kā jebkurā citā tālizpētes datu pielietojuma jomā, pilnīgi objektīva precizitātes novērtēšana nav iespējama [30]. Iespējams tikai datorizēto metožu salīdzinājums ar atsevišķos parauglaukumos veiktiem mērījumiem. Ideālā gadījumā parauglaukumiem ir jāreprezentē nozīmīgākie koku vainagu raksturlielumi konkrētajā teritorijā un lauka mērījumos jāreģistrē pilnīgi visi koki parauglaukumā. Koku novietojuma koordinātes parasti nosaka ar augstas precizitātes GPS mērījumiem.

Problemātiskāka ir datu ievākšana koku vainaga formas precizitātes pārbaudei. Vairumā gadījumā palīgdati tiek iegūti cilvēkam ar roku, pēc vizuālā novērtējuma iezīmējot koka vainaga formu.

Šajā pētījumā palīgdatu kopu veido:

1. **Atsevišķu koku vainagu daudzstūri.** Atkarībā no datu pieejamības iespējams izmantot lauka mērījumos noteiktas koku atrašanās vietu koordinātes vai arī daudzstūrus sagatavot, vadoties tikai pēc vizuālā novērtējuma. Koku vainagus ērti saglabāt .SHP datnē, kur katram koku vainaga daudzstūrim ir piešķirts unikāls numurs. Turpmāk tekstā šie daudzstūri tiks saukti par references daudzstūriem. Piemēru skatīt att. 5.1.b.
2. **Maska, kas norāda, kuros apgabalos noteikti neatrodas koku vainagi.** Ja references daudzstūri pilnībā nosedz testa apgabalu, tad šo masku iespējams ērti aprēķināt, atņemot no testa apgabala maskas masku, kas iezīmē references daudzstūrus. Ja references daudzstūri nenosedz visu testa apgabalu, tad nepieciešams atsevišķā maskā iezīmēt teritorijas, kurās precizitātes raksturlielumi netiks rēķināti un atņemt šo masku no iepriekšminētās attēlu starpības. Piemēru skatīt att. 5.1.c.



Att. 5.1. a) Testa apgabala robežas ir iezīmētas ar zaļu līniju, bet punkti parāda atsevišķu koku novietojumu saskaņā ar GPS mērījumiem. Punkti iekrāsoti atkarībā no koka sugas grupas: sarkanā - skujkoki, zaļā - lapkoki, dzeltenā - nokaltušie koki. b) Attēlam 5.1.a pievienoti references daudzstūri, kas iekrāsoti atbilstoši to unikālajiem numuriem. c) Teritorijas, kurās neatrodas koku vainagi ir iekrāsotas sarkanā krāsā.

Datorizētās metodes koku vainagu identifikācijai rezultātā izvada punktu kopu  $P$ , kura satur koku atrašanās vietu koordinātes.

Izmantojot palīgdatu kopu, kļūdas koku identifikācijā raksturo apstiprinājuma kļūda (nepareizi patieso atbilžu skaits) un identifikācijas kļūda (neidentificēto koku skaits).

Kļūdu aprēķinu definēšanai tiks pievienots apzīmējums  $R$  - patieso koku koordinātu kopa. Kopa satur  $i$ -tā koka  $R_i$  kartes projekcijas koordinātes  $(x_i, y_i)$ . Šī kopa var tikt iegūta lauka mērījumos vai arī aprēķinot references daudzstūru centroīdu koordinātes.

Punkti no kopām  $P$  un  $R$  tiek savienoti, atrodot  $P$  kopas tuvāko punktu kopas  $R$  punktam, saskaņā ar Eiklīda distanci attēla koordinātu telpā. Abiem savienotajiem punktiem ir jāatrodas vienā references daudzstūrī. Tikai viens kopas  $P$  punkts drīkst būt savienots ar konkrētu  $R$  kopas punktu un abās kopās var būt punkti, kam atbilstošās saites nav atrastas.

Identifikācijas kļūda (angl. *omission error*) raksturo, cik procenti no testa apgabalā esošajiem kokiem nav identificēti. Identifikācijas kļūdu parasti izsaka procentos un tās teorētiskās robežas ir  $[0\%, 100\%]$ , kur  $0\%$  nozīmē, ka visi koki testa apgabalā ir atrasti pareizi, bet  $100\%$  nozīmē, ka neviens koks testa apgabalā nav identificēts.

Identifikācijas kļūdu aprēķina sekojoši:

$$e_o = N_o / N_t * 100, \quad (5.1)$$

kur  $N_o$  ir punktu skaits no kopas  $R$ , kas nav savienoti ne ar vienu punktu no kopas  $P$ , t.i. neidentificēto koku skaits testa apgabalā.

$N_t$  - kopējais koku skaits testa reģionā, kopējais kopas  $R$  punktu skaits.

Apstiprinājuma kļūda (angl. *commission error*) raksturo, cik daudz citi objekti, kas nav koki tiek atpazīti kā koki un, cik daudzos gadījumos lielāki koku vainagi tiek identificēti kā vairāki koki. Zemākā apstiprinājuma kļūdas robeža ir  $0\%$ , kas nozīmē, ka nav nepareizi patiesu atbilžu, bet augšējā robeža nav teorētiski ierobežota, jo iespējama situācija, ka nepareizi patiesu atbilžu skaits ir lielāks par koku skaitu testa apgabalā.

Apstiprinājuma kļūdu aprēķina sekojoši:

$$e_c = (N_c)/N_t * 100, \quad (5. 2.)$$

kur  $N_c$  - punktu skaits kopā  $P$ , kuri nav savienoti ar ne ar vienu punktu no kopas  $R$ ;

Precizitātes indekss (angl. *Accuracy Index*, AI) apvieno apstiprinājuma un identifikācijas kļūdu:

$$AI(\%) = (N_t - (N_c + N_o))/N_t * 100 \quad (5. 3.)$$

Ja precizitātes indekss divām gadījumu izpētēm ir vienāds, tad nepieciešams pievērst papildus uzmanību apstiprinājuma un izlaišanas kļūdām. No praktiskā viedokļa ieteicams izvēlēties gadījumu ar mazāko apstiprinājuma kļūdu. Metodes visbiežāk neidentificē maza izmēra kokus, kuru krājas vērtība ir relatīvi maza un būtiski neietekmē automatizētās meža inventarizācijas rezultātus. Savukārt augsta apstiprinājuma kļūda var sniegt nepatiesus krājas novērtējumus.

Šajā darbā precizitāte ērtības labad tiek raksturota ar  $N_o$ ,  $N_c$ ,  $N_p = N_t - N_o$  un  $AI$  rādītājiem.

Koku vainagu atdalīšanas precizitāti izsaka, pārbaudot pārklāšanos starp metožu atrastajiem daudzstūriem un references daudzstūriem, kas iezīmēti manuāli.

Katram palīgdatu daudzstūrim tiek meklēts metodes daudzstūris, kurš pārklājas ar references daudzstūri vislielākajā mērā. Ja tāds metodes daudzstūris tiek atrasts, tad tiek aprēķināts laukums, kādā daudzstūri pārklājas  $A_{overlap,i}$ . Pārklāšanās laukums tiek pētīts attiecībā pret references daudzstūra laukumu  $A_{ref,i}$  un metodes atrastā daudzstūra laukumu  $A_{m,i}$ :

$$o_{ref,i} = A_{overlap,i}/A_{ref,i}, \quad (5. 4.)$$

$$o_{m,i} = A_{overlap,i}/A_{m,i}. \quad (5. 5.)$$

Lielumi  $o_{ref,i}$  un  $o_{m,i}$  tiek apkopoti, saskaitot, cik daudz koku vainagu ierindojas sekojošās pārklāšanās kategorijās: 1) 1% - 19% pārklāšanās, 2) 20% - 39% pārklāšanās, 3) 40% - 59% pārklāšanās, 4) 60% - 79%, 5) 80% - 100%.

Papildu kategorijām iespējams izmantot arī vidējo laukumu starpību, lai raksturotu atšķirības starp koku vainagu izmēriem:

$$E_A = \sum_{i=1}^{N_t} (|A_{ref,i} - A_{m,i}|)/N_t. \quad (5. 6.)$$

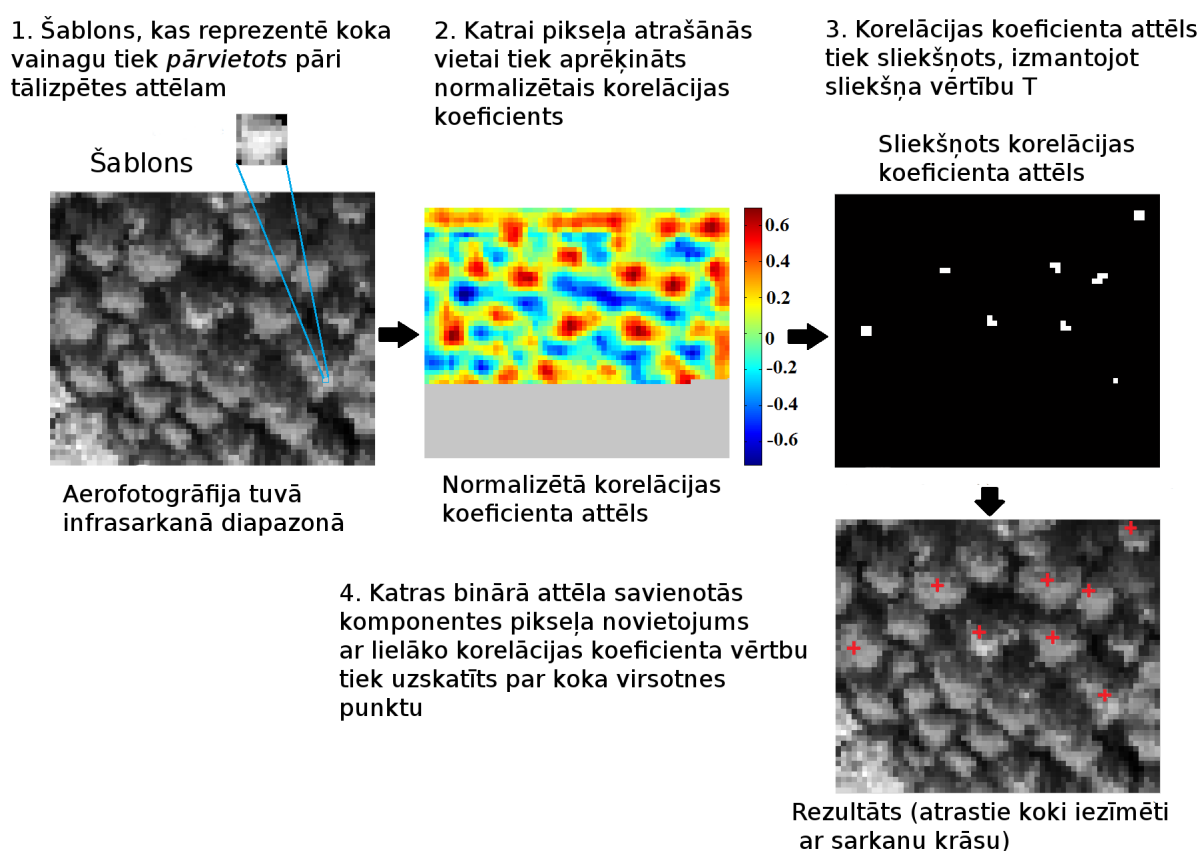
## 5. 4. Atsevišķu koku identifikācija

### 5. 4. 1. Šablonu salīdzināšanas metode un tās papildinājumi

**Šablonu salīdzināšanas metode** (angl. *Template Matching*, turpmāk tekstā TM) ir viens no biežāk izmantotajiem risinājumiem atsevišķu koku identifikācijai augstas telpiskās izšķirtspējas datos [56].

Šablonu salīdzināšanas metodes pamatideja (skat. 5.2.) ir pikseli pa pikselim attēlam "pārvietot pāri" šablonu un meklēt šablona novietojumus ar vislielāko sakritību starp šablonu un attēla apakšapgabalu [89].

**Šablons** (angl. *template*) ir parauga attēls, kurš raksturo, kā koku vainags izskatās tāluzpētes datos pie konkrētiem attēla ieguves apstākļiem un konkrētas koku sugas, koka vainaga izmēra un citiem parametriem.



Att. 5.2. Šablonu salīdzināšanas metodes vispārīga shēma.

TM metodes rezultāts ir punktu saraksts, kas apraksta atsevišķu koku virsotņu potenciālās atrašanās vietas. TM metodes veiktspēja precizitātes un skaitļošanas laika ziņā ir atkarīga no šablonu izvēles. Divas biežāk sastopamās pieejas koku vainagu šablonu sagatavošanā ir modelēšana un parauga koku vainagu atlasīšana ar roku.

Manuāla atlasīšana nodrošina šablona piemērotību konkrētajam datu komplektam [59], bet ir aktuāls jautājums kā atlasīt reprezentatīvākos koku vainagus, lai nodrošinātu augstāko iespējamo precizitāti un izvairītos no šablonu redundances.

Modelēšana aiztaupa nepieciešamību pēc cilvēka manuālā darba, bet tai ir nepieciešami plaši ievades dati par attēla ieguves apstākļiem un koku raksturlielumiem, kuri var

nebūt pieejami. Pollock darbos [88, 89] tika konstruēts sintētisks, vispārīgs attēla šablons, kas iekļāva gan ģeometriskos, gan radiometriskos atsevišķu koku parametrus. Šablons tika ģenerēts ņemot vērā atsevišķu koku vainagu trīsdimensionālo aprakstu, sensora ģeometriju, ainas apgaismojuma līmeni, sakarības starp ainas apgaismojumu un koku vainagu un sensora saņemto apgaismojumu. Larsen darbos [66, 64] tika uzlabots Pollock modelis iekļaujot šablonā arī fonu, kursā tika simulēts atstarojums no fona objektiem kā koku vainagu ēnas. Larsen prezentēja arī šablonu optimizācijas metodi, maksimizējot pareizi noteiktos koku vainagus. Šablonu optimizācija iekļāva optimālā izmēra un eliptiskās robežas formas noteikšanu.

Pētījumā [65] TM metode tika salīdzināta ar vēl sešām citām metodēm dažādos meža augšanas apstākļos un tipos. TM metode parādīja priekšrocību starp citām metodēm sarežģītu meža augšanas apstākļu un sensora - skata ģeometrijas gadījumā.

Promocijas darba ietvaros TM tika papildināta ar sekojošiem parametriem un papildus metodēm:

1. Parametrs  $D_{min}$  nosaka tuvāko iespējamo attālumu starp diviem koka virsotņu punktiem. Šis parametrs tiek lietots TM procedūras beigās. Tiek apskatīta katra punkta apkārtnē rādiusā  $D_{min}$ . Ja šajā apkārtņē tiek atrasti vairāki TM noteiktie virsotņu punkti, tad tiek atstāts tikai punkts ar augstāko korelācijas koeficienta vērtību, bet pārējie tiek izdzēsti.
2. Parametrs  $TE_{size}$  ļauj mainīt šablona attēla izmērus TM procesa laikā, izmantojot attēlu pārdiskretizāciju.
3. Vairāku slāņu attēlu (t.sk., vairāku avotu datu) apstrāde, izmantojot attēlu aritmētiku.
4. Vairāku slāņu attēlu (t.sk., vairāku avotu datu) apstrāde, izmantojot datu apvienošanu pazīmju līmenī.
5. Šablonu ģenerēšana, izmantojot apmācības datu kopu un evolucionāro algoritmu pamatidejas.

**Ievades dati:**  $im$  - vienas vai vairāku frekvenču joslu pelēktoņu attēls ( $N \times M \times f$ );  $templates$  - šablonu kopa, šabloniem jāsaturs tikpat daudz frekvenču joslas kā  $im$ .

**Metodes iekšējie parametri:**  $T_\gamma$  - sliekšnis normalizētā korelācijas koeficienta sliekšņošanai (const.);  $D_{min}$  - mazākais atļautais attālums starp divām koka virsotnēm (const.);  $TE_{size}$  - šablona izmēru izmaiņu proporcijas (vektors).

Šablonu salīdzināšanas metode tiek realizēta četros vispārīgos soļos.

### 1. Šablonu kopas izveide.

Šablons ir vispārināts paraugs kā koka vainags izskatītos konkrētajos tālzipētes attēlos pie noteiktiem attēlu ieguves apstākļiem un meža raksturlielumiem. Parasti viens

šablons nespēj gana precīzi raksturot meža audzi (ja vien tā nav viena vecuma plantācija), tādēļ tiek izmantotas šablonu kopas. Tā kā šablona mērķis ir simulēt koku vainagu konkrētos tālīzpētes datus, tad šabloni lielākoties ir unikāli katram tālīzētes datu komplektam. Vienkāršākais šablonu kopas sagatavošanas veids ir atlasīt koku vainagu šablonus manuāli, ar roku no apstrādājamā attēla. Šablonu kopai vajadzētu ietvert biežāk sastopamās koku sugas un arī biežāk sastopamos koku vainagu izmērus. Tādējādi efektīvas šablonu kopas atrašana prasa iepriekšējas zināšanas par testa teritoriju.

Ja tiek izmantoti vairāki šabloni, tad nākamie divi soļi tiek izpildīti katram šablonam atsevišķi un rezultāti tiek apvienoti pēdējā solī. Algoritms tika papildināts ar iespēju šablonus palielināt un samazināt "mākslīgi", izmantojot attēlu pārdiskretizāciju un tuvākā kaimiņa interpolāciju [35].

## 2. Normalizētā korelācijas koeficienta aprēķināšana.

Atbilstība starp šablonu  $w$  un attēla reģionu  $f$  tiek aprēķināta, izmantojot normalizēto korelācijas koeficientu:

$$\gamma(x, y) = \frac{\sum_{s,t} [w(s, t) - \bar{w}] [f(x + s, y + t) - \bar{f}_{xy}]}{\sqrt{\sum_{s,t} [w(s, t) - \bar{w}]^2 \sum_{s,t} [f(x + s, y + t) - \bar{f}_{xy}]^2}}, \quad (5. 7.)$$

kur  $\bar{w}$  - šablona vidējā pikseļu vērtība;

$\bar{f}_{xy}$  - attēla pikseļu vidējā vērtība reģionā, kas pārklājas ar šablonu  $w$ .

$s, t$  - summēšanas mainīgie, kas izvēlēti tā, lai attēls un šablons pārklātos.

Normalizētā korelācijas koeficienta vērtība var būt intervālā  $[-1, 1]$  un augsta koeficienta vērtība norāda un labu atbilstību starp attēlu  $f$  un šablonu  $w$ , kas centrēts attēla  $f$  koordinātēs  $(x, y)$ .

Šablonu salīdzināšanas metodi iespējams pielietot arī vairāku slāņu attēliem. Vairāku slāņu gadījumā normalizētais korelācijas koeficients tiek aprēķināts katram attēla slānim ar katra šablona atbilstošo slāni un rezultātā korelācijas koeficientu attēli tiek savstarpēji saskaitīti un izdalīti ar slāņu skaitu.

Attēlu kopīgā apstrāde tika testēta arī gadījumam, kad attēli tiek apvienoti mērījumu jeb pikseļu līmenī:

$$FusedIm1 = (NIR + nDSM)/2, \quad (5. 8.)$$

kur  $NIR$  - tuvā infrasarkanā diapazona attēls,

$nDSM$  - normalizētais virsmas modelis.

Šādā veidā apvienotu attēlu iespējams lietot tāpat kā jebkuru viena slāņa attēlu, protams ņemot vērā faktu, ka arī šabloniem ir jābūt atlasītiem no apvienotā attēla.

## 3. Koku virsotņu atrašana.

Korelācijas koeficienta attēls tiek pārveidots binārajā attēlā (slietšņots), lai noteiktu attēla apgabalus ar vislabāko atbilstību, izmantojot empīriski noteiktu sliekšni  $T_\gamma$ . Sliekšnis  $T_\gamma$  ir vissvarīgākais TM metodes iekšējais parametrs, kas nosaka līdzsvaru starp nepatiesi identificētiem objektiem un objektu izlaišanu.

Kad korelācijas koeficienta attēls ir pārveidots binārajā attēlā, tam tiek veikta savienoto komponentu identifikācija, lai atdalītu atsevišķus priekšplāna objektus. Koka virsotnes koordinātes ir katras savienotās komponentes korelācijas koeficienta maksimuma atrašanās vietas koordinātes.

#### 4. Rezultātu filtrācija.

Ja tiek izmantoti vairāki šabloni, tad vienu un to pašu koku vainagu iespējams identificēt ar vairākiem šabloniem. Tādējādi vienam koka vainagam metode atrod vairākus savstarpēji nedaudz nobīdītus virsotnes punktus. Šādi punkti tiek izņemti, izvēloties vienu punktu un apskatot tā tuvāko apkārtni  $D_{min}$  pikseļu rādiusā. Ja apkārtne atrodas vairāki punkti, tad rezultātu kopā tiek atstāts punkts ar visaugstāko korelācijas koeficientu, bet pārējie punkti tiek izdzēsti.

Pirmie šablonu salīdzināšanas metodes rezultāti tika apkopoti zinātniskajā rakstā [39].

Šajā nodaļā apskatīti rezultāti vienkāršai šablonu atlasīšanas metodei, kuras ietvaros šablonam netiek noņemts fons. Šabloni atlasīti, iezīmējot ar roku vēlamos koku vainagus un izgriežot tos QGIS, izmantojot rīku *GDAL Clipper*.

Pētāmajā apgabalā A1 no 277 kokiem bija 55 priedes, 68 egles, 96 bērzi, 34 apses un 15 ozoli. Koku vainagu izmēru statistika apkopota tabulā 5. 1.


Koku suga	Vidējais $G$	$G$ standarta novirze	Min $G$	Max $G$	Vidējais $D_{crown}$	$D_{crown}$ standarta novirze	Min $D_{crown}$	Max $D_{crown}$
Priede	14.4	10.3	4.8	75.2	4.7	1.4	2.5	11.0
Egle	20.4	11.2	6.0	65.0	5.6	1.4	3.5	10.5
Bērzs	22.3	13.9	5.8	73.0	5.9	1.8	3.0	11.0
Apse	40.7	24.8	8.5	110.0	8.0	2.6	3.5	14.5
Ozols	44.8	47.6	10.25	200.25	8.1	4.1	4.50	21.00

Tabula 5. 1. Koku vainagu raksturlielumu statistika pētāmajam apgabalam A1:  $G$  - references koka vainaga izmērs;  $D_{crown}$  - references koka vainaga diametrs.

Tā kā visu testa apgabalu datus ietekmēja nesistemātiskas nobīdes starp Lidar nDSM un multispektrālajiem datiem, tad šablonu kopas tika atlasītas pēc vizuālā novērtējuma. Vizuāli novērtējot tika ņemtas vērā biežās sastopamās koku sugas un koku vainagu ģeometriskā sakritība starp Lidar un multispektrālajiem attēliem.

Parametru testiem šabloni tika atlasīti kā taisnstūrveida attēla reģioni bez fona noņemšanas.

**Pētāmais jautājums: kā izvēlēties sliekšņa  $T_\gamma$  vērtību?**



Att. 5.3. Šabloni, kas izvēlēti pēc vizuālā novērtējuma.

Slieksnis  $T_\gamma$  nosaka, cik augstas korelācijas koeficienta vērtības tiek atlasītas kā potenciālie koku vainagu novietojumi. Ja sliekšņa vērtība ir augsta, tad tiek atlasītas labākās atbilstības starp attēla reģioniem un šablonu. Rezultātā ir mazāk nepareizi patiesu atbilžu, taču daudzi koku vainagi tiek izlaisti. Ja sliekšņa vērtība ir zema, tad iespējams sasniegt augstāku identifikācijas precizitāti, taču palielinās nepareizi patieso atbilžu skaitu.

$T_\gamma$	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes in- dekss (AI) %
0.5	187	80	44	55.2
0.55	167	110	26	50.9
0.6	133	144	13	43.3
0.65	92	185	5	31.4
0.7	46	231	2	15.9
0.75	18	259	0	6.5

Tabula 5. 2. Sliekšņa  $T_\gamma$  ietekme apgabala A1 datu komplektam un NIR attēlam. Kopā 277 koki.

Izvēloties sliekšņa vērtību ir nepieciešams veikt eksperimentālus testus un izvēlēties sliekšņa vērtību ņemot vērā ne tikai AI, bet arī apstiprinājuma kļūdu.

Optimāla sliekšņa vērtība pētītajam datu komplektam bija  $T_\gamma = 0.6$ . Lai arī AI ir augstāks pie  $T_\gamma = 0.5$ , tomēr meža inventarizācijas vajadzībām būtiskāka mazāka apstiprinājuma kļūda.

**Pētāmais jautājums: kā precizitāti ietekmē minimālās atļautās distances izvēle starp 2 koku virsotnēm?**

Lietojot vairākus šablonus vai viena šablona vairākus izmērus iespējamas vairākas identifikācijas atbildes vienam un tam pašam koka vainagam. Rezultātus filtrējot, šādi punkti tiek noņemti, apskatot apkārtni, kuru nosaka minimālā atļautā distance starp kokiem metros  $D_{min}$ .

Labākā atļautā minimālās distances vērtība ir vienāda ar koku vainagu vidējo rādiusu.

**Pētāmais jautājums: kā šablonu skaita palielināšana ietekmē precizitāti?**



$D_{min}$ (metros)	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes in- dekss ( $AI$ ) %
1	162	115	63	35.7
3	152	125	19	48
5	98	179	9	32.1

Tabula 5. 3. Minimālās atļautās distances ietekme pētāmajam apgabalam A1 un NIR attēlam. Šablonu skaits: 4. Kopā 277 koki.

Šīs gadījuma izpētes ietvaros tika pētīta atsevišķu šablonu ietekme uz kopējo koku identifikācijas precizitāti.

Šablonu numuri	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes in- dekss ( $AI$ ) %
Priede	136	141	16	43.3
Egle	43	234	1	15.1
Priede, egle	145	132	17	46.2
Bērzs	16	261	0	5.7
Apse	37	240	1	13.0
Visi 4 šabloni	152	125	19	48.0

Tabula 5. 4. Šablonu izvēles ietekme pētāmajam apgabalam A1 un NIR attēlam. Kopā 277 koki.

Šablona izvēle ir kritiski svarīga. Veiksmīgi izvēloties šablonu, ar viena šablona palīdzību iespējams sasniegt augstu precizitāti kā priedes šablona gadījumā. Savukārt, neveiksmīga šablona izvēle neļauj izmantot TM metodes augsto veiktspēju precizitātes ziņā. Jo vairāk šablonu tiek izmantoti, jo augstāka precizitāte, taču ievērojami tiek paildināts arī skaitļošanas laiks. Tādēļ ir būtiski novērst šablonu redundanci.

#### **Pētāmais jautājums: vai šablona izmēra maiņa ietekmē precizitāti?**

Šablonu izmērus iespējams mainīt arī digitāli palielinot vai samazinot attēlu.

Izmēra maiņa (%)	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes in- dekss ( $AI$ ) %
Bez izmēra iz- maiņām	152	125	19	48.0
75:100	205	72	53	54.8
50:75:100	177	100	96	34.7
100:125	155	122	25	46.9
100:150	156	121	22	48.4
75:100:150	200	77	53	53.1

Tabula 5. 5. Izmēru maiņas ietekme pētāmajam apgabalam A1 un NIR attēlam. Kopā 277 koki.

Šablona izmēra mainīšana TM procesa laikā, izmantojot attēlu palielināšanu vai samazināšanu kopumā pozitīvi ietekmē precizitāti. Ja šablons ir mazs, tad uzmanīgi ir jāpielieto

šablona izmēra samazināšana, jo mazākiem šabloniem ir tendence producēt vairāk apstiprinājuma kļūdu.

#### **Pētāmais jautājums: kā rezultātus ietekmē datu avota izvēle?**

Tabulā 5. 6. apkopoti precizitātes aprēķini, izmantojot dažādus datu avotus. Datu kopīga apstrāde tiek realizēta divos veidos: a) šablonu salīdzināšanas metode tiek pielietota vairāku joslu attēlam, kā aprakstīts iepriekšējā nodaļā, b) vairāki attēli tiek apvienoti ar attēlu aritmētikas palīdzību.

Apstrādājamo attēls	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes indekss (AI) %
NIR	205	72	53	54.8
nDSM	152	125	104	26.7
Fused NIR & nDSM	178	99	91	31.4
NIR + nDSM (2 slāņu attēls)	225	52	50	63.2

Tabula 5. 6. Datu avotu ietekme testa apgabalā A1.  $T_\gamma=0.6$ ,  $D_{min} = 3$ . Kopā 277 koki.

Datu kopīgā apstrāde ļāva būtiski paaugstināt precizitāti, taču jāņem vērā, ka testa apgabala A1 aerofotogrāfijas ir iegūtas pie īpaši koku detektēšanai piemērotiem apstākļiem. Ja attēlā novērojams izteikts reljefs un attēli iegūti pie zema Saules augstuma leņķa, tad tas varētu būtiski palielināt pelēko toņu variācijas un noteikšanas precizitāti pat pasliktināt. Papildu tam, datu kopīgo apstrādi nepieciešams realizēt, izmantojot vairāku frekvenču joslu attēlu, nevis attēlu, kurā NIR un nDSM apvienoti mērījumu līmenī. Taču rezultātus ļoti būtiski nosaka šablonu kopas izvēle.

#### **5. 4. 2. Šablonu sagatavošana, izmantojot evolucionāro algoritmu EATG**

Gadījumu izpēti iepriekšējā nodaļā parādīja, ka precizitāti visnozīmīgāk ietekmē šablonu izvēle, tādēļ ir aktuāls jautājums, kā pareizāk izvēlēties šablonus un cik daudz šablonu nepieciešami, lai efektīvi veiktu koku identifikāciju?

Šajā nodaļā tiks prezentēta jauna pieeja optimālai šablonu izveidei, izmantojot (1+1) evolucionāro algoritmu (EA).

Piedāvātajai pieejai nepieciešams palīgdatu komplekts. Šablonu ģenerēšana tiek uzskatīta par optimizācijas uzdevumu, kura laikā tiek maksimizēts koku identifikācijas precizitātes indekss AI attiecībā pret palīgdatu kopu.


Evolucionārie algoritmi ir bieži izmantotas metodes optimizācijas problēmu risināšanai, kurām analītisks atrisinājums nav iespējams. EA pieeja realizē evolūcijas teorijas idejas, imitējot paaudžu nomaiņu un indivīdu mutācijas apkārtnes faktoru ietekmē.

(1+1) evolucionārais algoritms ir viena no vecākajām un vienkāršākajām evolūcijas stratēģijām optimizācijas uzdevumu risināšanai. Algoritma ietvaros viens *Vecāks* tiek modificēts, lai izveidotu *Pēcnācēju*. Saskaņā ar fitnesa funkciju, tiek izvēlēts vai nu *Vecāks* vai *Pēcnācējs* kā *Vecāks* nākamajā iterācijā. Iterācijas tiek turpinātas tik ilgi līdz tiek sasniegts apstāšanās kritērijs, kas visbiežāk ir saistīts ar fitnesa funkciju.

(1+1) EA ideja var tikt paplašināta šablonu noteikšanas uzdevumam sekojošā veidā:

1. Ģenerējam pirmo šablonu kā ļoti vispārinātu koka vainaga attēlu un nosaucam to par *Vecāku*.
2. Ģenerējam *Pēcnācēju*, pievienojot *Vecākam* Gausa troksni.
3. Izvēlamies labāko šablonu starp *Vecāku* un *Pēcnācēju* saskaņā ar fitnesa funkcijas vērtību.
4. Labākais šablons kļūst par jauno *Vecāku* un soļi 2. -4. tiek atkārtoti tik ilgi līdz tiek sasniegts apstāšanās kritērijs.

Šīs koncepcijas demonstrācijai vispirms tiks izmantots vienkāršs piemērs. Attēlā 5.4. parādīts vienkāršs pelēko toņu attēls. Uzdevums ir ģenerēt šablonu pēc iespējas līdzīgāku piemēra attēlam, izmantojot Gausa trokšņa attēlus, kas ir tādā pašā izmērā kā piemēra attēls un pēcnācēju paaudzes. Fitnesa funkcija ir normalizētā korelācijas koeficienta vērtība starp piemēra attēlu un potenciālo šablonu attēla vidus punktā. Jo augstāka korelācijas koeficienta vērtība, jo labāka atbilstība starp piemēra attēlu un šablonu. Katrā iterācijā, ja korelācijas koeficienta vērtība ir augstāka *Pēcnācējam*, tad tas tiek uzskatīts par labāku un kļūst par jauno *Vecāku*, kuram atkal tiek pieskaitīts Gausa trokšņa attēls. Ja *Vecāks* ir labāks saskaņā ar fitnesa funkciju, tad tam tiek pieskaitīts Gausa trokšņa attēls un tiek veidots jauns *Pēcnācējs*. Attēlā 5.4. redzams, ka pēc 50 000 iterācijām ir izveidots līdzīgs šablons piemēra attēlam (fitnesa funkcijas vērtība ir 0.85), izmantojot tikai Gausa trokšņa attēlus.



Att. 5.4. Vienkāršs metodoloģijas piemērs. a) Piemēra attēls. b) *Vecāks* pirmajā iterācijā. c) *Vecāks* 10 000. iterācijā, d) *Vecāks* 50 000. iterācijā.

**Metodes ievades dati un iekšējie parametri:**  $f$  - pelēko toņu attēls (viena vai vairākas frekvenču joslas);  
palīgdati fitnesa funkcijas vērtības aprēķināšanai;  
 $a$  - ģenerējamā šablona matricas rindiņu un kolonnu skaits (tiek ģenerēti kvadrātveida šabloni);  
 $\sigma$  - Gausa filtra standarta novirze pirmā šablona izveidei;  
 $\sigma_{noise}$  - Gausa trokšņa standarta novirze;  
 $s$  - apstāšanās kritērijs: iterāciju skaits, kad *Vecāka* šablons nav mainīts.

### Fitnesa funkcija

Kā fitnesa funkcija tiek izmantots precizitātes indekss AI, kura vērtība tiek maksimizēta.

### Šablona izveide pirmajā iterācijā

Vecāka šablons ( $V$ ) tiek izveidots, simulējot koka vainaga formu, izmantojot Gausa filtru ar izmēru  $a \times a$  un standarta novirzi  $\sigma$ :

$$V = \frac{e^{-2a^2/2\sigma^2}}{\sum \sum e^{-2a^2/2\sigma^2}} \quad (5.9.)$$

Pēcncēja šablons  $P$  tiek izveidots, pieskaitot Vecāka šablonam  $V$  Gausa troksni ar vidējo vērtību nulle un standarta novirzi  $\sigma_{noise}$ . Jo lielāka standarta novirze, jo spēcīgāks troksnis tiek pievienots attēlam. Gausa troksnis tiek ģenerēts, izmantojot izteiksmi:

$$p_G(z) = \frac{1}{\sigma_{noise} \sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma_{noise}^2}}, \quad (5.10.)$$

kur  $z$  - pelēkā toņa vērtība no pelēko toņu skalas;

$\mu$  - trokšņa vidējā vērtība, šajās studijās  $\mu = 0$ . TM metode tiek pielietota, izmantojot šablonus  $V$  un  $P$  un abu šablonu rezultāti tiek salīdzināti, izmantojot fitnesa funkciju. Šablons ar augstāku fitnesa funkcijas vērtību (tiek veikta maksimizācija) tiek uzskatīts par labāku un kļūst par šablonu  $V$  nākamajā iterācijā.

Šablons  $P$  atkal tiek izveidots, pieskaitot Gausa troksni šablonam  $V$ . Iterācijas tiek pārtrauktas tad, kad šablons  $V$  ir palicis nemainīgs noteiktu iterāciju skaitu. Ja šablons netiek mainīts vairākas iterācijas, tad var pieņemt, ka labāku šablonu nav iespējams atrast.

Izmantojot šo metodoloģiju iespējams ģenerēt vairākus šablonus. Kad viena šablona aprēķināšana sasniedz apstāšanās kritēriju, tad tie koki, kurus bija iespējams atrast, izmantojot šo šablonu, tiek izņemti no palīgdatu kopas un procedūra atkal tiek atkārtota, lai atrastu nākamo šablonu. Šāda procedūra nodrošina to, ka pirmais šablons būs visefektīvākais, t.i., tā būs vispārīgākā koka vainaga reprezentācija, bet pārējie šabloni sāks pielāgoties specifiskākiem koku vainagu raksturlielumiem attēlā.

### Pētāmais jautājums: kā EATG apstāšanās kritērijs ietekmē AI?

Tabulā 5. 7. apkopoti precizitātes indeksi, lietojot dažādu iterāciju skaitu bez šablona maiņas kā apstāšanās kritēriju. Rezultātus ietekmē EATG metodē iestrādātā trokšņa gadījuma raksturs, taču pie augstāka iterāciju skaita pirmais šablons tiek veidots kā vispārīgāks. Turpmākajos testos viena slāņa attēlam apstāšanās kritērijs tiek iestatīts kā 250.


Attēlā 5.5. redzami EATG veidotie šabloni tuvā infrasarkanā attēlam.

### Pētāmais jautājums: kādi ir EATG rezultāti dažādām datu kopām?

Tabulā 5. 8. apkopotie rezultāti parādā, ka EATG visefektīvāk darbojas NIR attēla gadījumā, paaugstinot precizitātes indeksu par aptuveni 12%, ierobežojot apstiprinājuma kļūdas. Veiksmīgais pielietojums tieši NIR attēla gadījumā varētu būt izskaidrojams ar koku

Iterāciju skaits bez Vecāka šablona mainīšanas	AI pirmajam šablonam	AI 5 šabloniem
50	33.2	48.4
100	40.8	49.5
150	41.5	46.6
200	35	52.35
250	49.46	54.87

Tabula 5. 7. EATG veidoto šablonu precizitātes indekss atkarībā no apstāšanās kritērija.



Att. 5.5. EATG aprēķinātie 5 šabloni, ja apstāšanās kritērijs ir 100 iterācijas bez imaiņām.

vainagu vizuālo trokšņainību NIR attēlā, kas loģiskāk pamato Gausa trokšņa izmantošanu šablonu ģenerēšanas procesā.

Datu kopa	AI 1. šablonam	$N_c$ 1. šab.	$N_o$ 1. šab.	AI 5 šabloniem	$N_c$ 5 šab.	$N_o$ 5 šab.
NIR	49.46	9	131	54.87	21	104
nDSM	34.3	5	177	38.99	19	150
(NIR+nDSM)/2	37.9	6	166	45.9	128	22
NIR+nDSM atsevišķos attēla slāņos	24	3	205	29.2	3	193

Tabula 5. 8. EATG veidoto šablonu precizitātes indekss atkarībā no izmantotās datu kopas. Apstāšanās kritērijs: 250 iterācijas bez šablona maiņas viena slāņa attēla gadījumā, 600 iterācijas bez šablona maiņas divu slāņu attēlam.

### Pētāmais jautājums: kā EATG rezultātus ietekmē šablona izmēra izmaiņas?

EATG ģenerēto šablonu palielināšana, izmantojot attēlu pārdiskretizāciju, metodes rezultātu precizitāti samazina kā redzams tabulā 5. 9.

Šablona izmērs	AI 1. šablonam	$N_c$ 1. šab.	$N_o$ 1. šab.	AI 5 šabloniem	$N_c$ 5 šab.	$N_o$ 5 šab.
10	49.46	9	131	54.87	21	104
Šablona maiņa ārpus EATG						
5:10	-	-	-	-	-	-
10:15	29.6	35	160	31.8	58	131
Šablona maiņa EATG optimizācijas procesā						
5:10	45.5	91	60	10.8	222	25
10:15	45.1	15	137	48.4	35	108

Tabula 5. 9. EATG veidoto šablonu precizitātes indekss atkarībā no šablona izmēra. Apstāšanās kritērijs: 250 iterācijas bez šablona maiņas.

## 5. 5. Koku vainagu atdalīšana

### 5. 5. 1. Lēmumu balstīta koku vainagu atdalīšanas metode

Doktora darbā piedāvātās koku vainagu atdalīšanas metodes pamatideja ir izpētīt pikseļu vērtības 16 dažādos virzienos no koka centra un atrast potenciālās koku vainagu robežas dažādos datu avotos. Dažādu datu avotu rezultāti tiek apvienoti, lai kompensētu iespējamās kļūdas, meklējot koku vainagu vienā datu avotā.

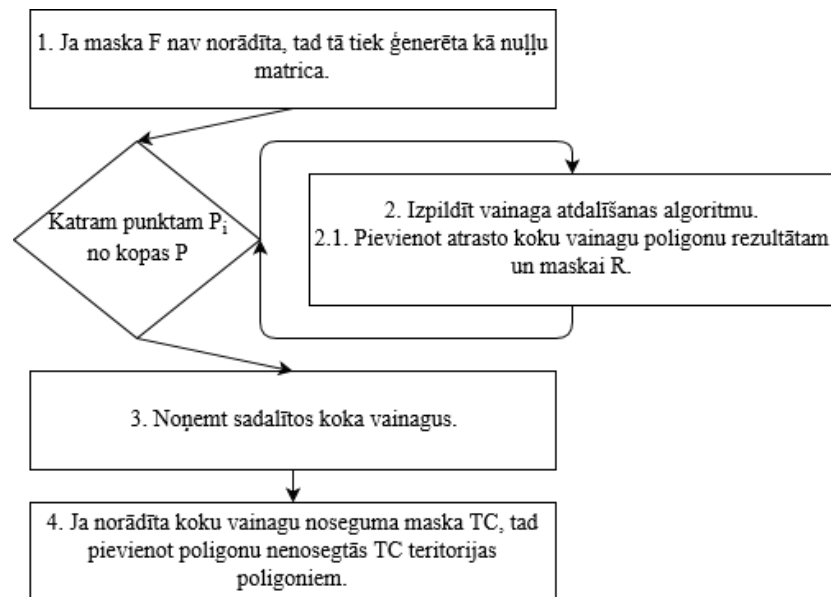
#### Ievades dati:

- Pelēko toņu attēli: nDSM, multispektrālo aerofotogrāfiju frekvenču joslu attēli utml.
- Klašu numuru attēli, piemēram, koku vainagu noseģuma maskas. Izmantojamās attēlus iespējams kombinēt atkarībā no datu pieejamības. Ja visi datu avoti nav pieejami, iespējams izmantot arī tikai vienu vai dažus pieejamos.
- Koku atrašanās vietu punkti  $P$ .
- Maskas  $F$ , kas parāda teritorijas, kurās koku vainagi noteikti neatrodas. Maskas nav obligātas.

#### Metodes iekšējie parametri:

$m$  - maksimālais pieļaujamais koka vainaga rādiuss pikseļos;

Kopējo koku vainagu atdalīšanas shēmu skatīt att. 5.6. Katrs koka vainaga atrašanās punkts tiek apskatīts atsevišķi, nepieļaujot koku vainagu pārklāšanos algoritma izpildes laikā. Ja tiek izmantota, koku vainagu noseģuma maska, tad pēc visu punktu apstrādes, koku vainagu noseģuma maskas daļas, kuras nenosedz koku vainagu daudzstūri, tiek piešķirtas daudzstūrim, ar kuru šai daļai ir garākā kopīgā robeža.




Att. 5.6. Koku vainagu atdalīšanas vispārīgā shēma.

Koku vainagu atdalīšanas algoritms vienam koka atrašanās vietas punktam aprakstīts nākamajās rindkopās.

### 1. Koku atrašanās punktu pārvietošana uz lokālā maksimuma atrašanās vietu.

Koku vainagu atdalīšanas algoritms ir pielietojams jebkuras koku identifikācijas metodes atrastajiem punktiem, tādēļ pirmais solis ir punkta pārvietošana uz lokālo maksimumu katrā pelēko toņu attēlā. Kļāšu numuru attēliem punkts tiek pārvietots uz to pašu punktu, kurā tas ir novietots pirmajā pelēko toņu attēlu sarakstā.



Att. 5.7. a) Koka vainaga atrašanās vieta  $P_i$  iezīmēta ar zaļu punktu. Punktam  $P_i$  tiek apskatīta  $m \times m$  apkārtnē. b) Punkta  $P_i$  apkārtnē tiek atrasti visi lokālie maksimumi, izmantojot maksimālās vērtības filtru ar izmēru  $m \times m$ . Tiek atrasts punktam tuvākais lokālais maksimums, saskaņā ar parasto Eiklīda attālumu attēla koordinātu plaknē  $(x, y)$ . c) Tuvākais maksimuma punkts kļūst par jauno koka novietojuma punktu  $P_{new}$  (iekrāsots dzeltens) un šim punktam atkal tiek atlasīta  $m \times m$  apkārtnē tālākai analīzei.

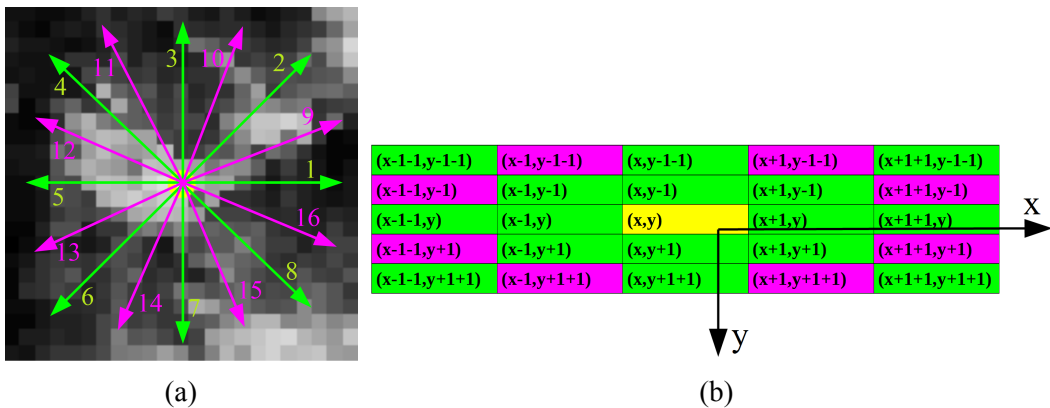
Koka atrašanās vietas punktam  $P_i$  no punktu kopas  $P$  tiek apskatīta  $m \times m$  izmēru apkārtnē. Šajā apkārtnē tiek atrasti visi lokālie maksimumi. Lokālo maksimumu noteikšana notiek, pielietojot maksimālās vērtības filtru un meklējot tos pikselus, kuri ir vienādi starp sākotnējo attēla fragmentu un filtrēto attēlu. No punkta  $P_i$  līdz visiem maksimumu punktiem

tiek aprēķināts parastais Eiklīda attālums attēla koordinātu telpā. Koka virsotnes atrašanās punktu pārvieto uz to lokālo maksimuma punktu, kurš atrodas vistuvāk punktam  $P_i$  un tas kļūst par jauno koka virsotnes punktu  $P_{new}$ .

## 2. Pikseļu vērtību šķērsgriezumu atrašana 16 virzienos no koka atrašanās vietas.

Gan pelēko toņu, gan klašu numuru attēliem tiek noteikti pikseļu vērtību šķērsgriezumi 16 dažādos virzienos, sākot no pikseļa  $P_{new}$ . Šķērsgriezuma vērtību noteikšana nozīmē pikseļu vērtību, kas izvietoti konkrētā virzienā secīgu ielasīšanu vektorā. Šķērsgriezumi tiek ielasīti pieskaitot  $P_{new}$  attēla koordinātēm  $(r, k)$  indeksu pārus, kas realizē kustību pa attēla matricu konkrētajā virzienā:

$$V_m = \begin{bmatrix} [0, 1] & [0, 1] \\ [0, 1] & [-1, 1] \\ [-1, 1] & [-1, 1] \\ [-1, 0] & [-1, 1] \\ [-1, 0] & [-1, 0] \\ [-1, 0] & [-1, -1] \\ [-1, -1] & [-1, -1] \\ [0, -1] & [-1, -1] \\ [0, -1] & [0, -1] \\ [0, -1] & [1, -1] \\ [1, -1] & [1, -1] \\ [1, 0] & [1, -1] \\ [1, 0] & [1, 0] \\ [1, 0] & [1, 1] \\ [1, 1] & [1, 1] \\ [0, 1] & [1, 1] \end{bmatrix} \quad (5. 11.)$$




Att. 5.8. a) Pikseļu vērtību šķērsgriezumi tiek pētīti 16 dažādos virzienos no sākotnējā pikseļa  $P_{new}$ , b) Pikseļu attēla koordinātu piemēri, ja  $P_{new}$  koordinātes ir  $(x, y)$ .

Attēlā 5.9. parādīti šķērsgriezumi virzienos Nr. 1 - 4. Grafikā iespējams novērot, ka šķērsgriezumiem raksturīgi trokšņaini lokālie minimumi un maksimumi, kas saistīti ar pelēkā toņa variācijām koku vainaga teritorijā, bet ne ar koka virsotnēm vai noēnotajiem apgaba-



liem starp kokiem. Potenciāls risinājums varētu būt attēla izlīdzināšana, izmantojot Gausa filtru. Taču praksē šāds risinājums ir pielietojams tikai gana augstas telpiskās izšķirtspējas gadījumā. Pētījumā izmantotā datu komplekta gadījumā telpiskā izšķirtspēja ir pārāk zema un izlīdzināšana vēl vairāk samazinātu sīko detaļu izšķirtspēju, tādēļ trokšņainos ekstrēma punktus nepieciešams apstrādāt, bez informācijas samazināšanas.



Att. 5.9. Pikseļu vērtību šķersgriezumu piemēri attēlam 5.7.c virzienos Nr. 1 -4.

### 3. Šķersgriezuma analīze, lai atrastu koka vainaga kontūras punktu.

Par koka vainaga kontūras punktu tiek uzskatīts pirmais lokālais minimums katrā šķersgriezumā. Daļa no lokālajiem minimumiem ir saistīti ar apgaismojuma ietekmi un lāzera signāla atstarojumiem no zemākām koka vainaga struktūrām, tādēļ nākamie divi soļi paredzēti šādu gadījumu ietekmes samazināšanai uz gala rezultātu.

### 4. Kontūras punktu korekcijas vienam datu avotam.


Ņemot vērā sarežģītos meža augšanas apstākļus, kuru vajadzībām šāds koku vainagu atdalīšanas algoritms tiek konstruēts, ir iespējamās situācijas, kad iepriekšējā solī aprakstītā lēmumu balstītā sistēma dažus punktus iezīmē nepareizi.

Punktu korekcija tiek veikta, balstoties uz pieņēmumu, ka koku vainaga forma skatoties no augšas ir apuveni apaļa. Līdz ar to visiem koka vainaga kontūras punktiem vajadzētu atrasties aptuveni vienādā attālumā no koka virsotnes.

Korekcija tiek veikta sekojoši:

1. Visiem koka vainaga kontūras punktiem  $B_i$  tiek sarēķinātā centroīda  $C$ .
2. Visiem koka vainaga kontūras punktiem tiek aprēķināts Eiklīda attālums attēla koordinātu telpā no punkta  $B_i$  līdz centroīdai  $C$ :  $d(B_i, C)$ .
3. Tiek aprēķināta attālumu  $d(B_i, C)$  vidējā aritmētiskā vērtība  $m_{d(B,C)}$ .
4. Katra punkta attālums no centroīdas tiek salīdzināts ar vidējo vērtību  $m_{d(B,C)}$ . Ja punkta attālums ir lielāks par  $s_1 * m_{d(B,C)}$  vai mazāks par  $s_2 * m_{d(B,C)}$ , kur  $s_1 > 0$ ,  $s_2 > 0$  - const., tad punkts tiek izdzēsts un atbilstošajā virzienā tiek novietots punkts, kas atrodas attālumā  $m_{d(B,C)}$  no centroīdas.

Attēlā 5.12. parādīts piemērs punktu korekcijai. Iepriekšminētie soļi tiek izpildīti katram datu avotam atsevišķi, gan pelēko toņu attēliem, gan diskkrēto vērtību attēliem. Rezultātā katram koku vainaga atrašanās punktam  $P_i$  tiek atrasti  $16 * b$ , kur  $b$  ir attēlu kopējais skaits.




Att. 5.10. a) Koka vainaga potenciālie robežpunkti parādīti zaļā krāsā. Ilustrācijas nolūkos parādīti tikai 8 no 16 vainaga robežpunktiem, b) Punkti kuri atrodas tālāk vai tuvāk par vidējo punktu attālumu no punkta  $P_{new}$  tiek pārvietoti tā, lai to attālums no  $P_{new}$  būtu vienāds ar punktu vidējo attālumu.

### 5. Kontūras punktu viduvējošana, izmantojot vairākus datu avotus.

Nākamais solis ir viduvējot visos datu avotos atrastos koka vainaga kontūras punktus katrā virzienā, lai aprēķinātu rezultējošo kontūras punktu atrašanās vietas katrā virzienā.

Izmantojot vairākus datu avotus iespējams ne tikai samazināt kļūdu ietekmi, bet arī novērst kādas konkrētas tendences, kas piemīt vienam datu avotam. Piemēram attēlā 5.11. redzams, ka nDSM atrastie punkti parāda lielāku koka vainaga formu nekā šķiet pamatojami, taču pēc punktu viduvējošanas tie ir novietoti atbilstoši koka vainaga patiesajai formai pēc vizuālā novērtējuma.

Punktu koordinātu viduvējošana notiek, aprēķinot koordinātu vidējās vērtības katrā no apskatāmajiem virzieniem.



Att. 5.11. Tuvā infrasarkanā attēls un atrastie koka vainaga kontūras punkti. Sarkanā krāsā parādīti viduvējojie punkti. Punkti zaļā krāsā atrasti, izmantojot nDSM, rozā krāsā - segmentēta nDSM koku sugu klāsterizācijas attēlu, tumši zilā - koku vainagu noseģuma masku, gaiši zilā krāsā segmentēta NIR attēla koku sugu klāsterizācijas attēlu. Ja kādam datu avotam visi 16 punkti nav redzami, tad tas nozīmē, ka vizualizācijā punkti dažādiem datu avotiem pārklājas.

## 6. Koka vainaga daudzstūra konstruēšana un rezultātu noformēšana.


Pēc rezultējošo punktu atrašanas, tiek konstruēts koka vainaga daudzstūris, kuru veido 16 virsotnes. Sešpadsmit punkti ir pietiekami, lai pēc vizuālā novērtējuma konstruētu koka vainaga formai atbilstošu daudzstūri. Punktu skaita palielināšana rezultētos augstākā skaitļošanas laikā un līdz ar to lēnākā datu apstrādē. Katram daudzstūrim atbilstošajiem pikseļiem rezultējošajā attēlā tiek piešķirts unikāls numurs.

Pēc koku vainagu daudzstūru atrašanas tiek izpētīta koku vainagu noseģumu maska. Ja nelieli maskas pikseļu reģioni nav iekļauti kādā no koku vainagiem, tad tie tiek pievienoti tam koku vainagam ar kuru šim reģionam ir garākā kopējā robeža.

Garākās kopējās robežas atrašana notiek sekojoši:

1. Koku vainagi tiek pārveidoti binārajā maskā  $mask_{delineatedCrowns}$  un apskatām starpību starp koku vainagu noseģumu masku  $mask_{TC}$  un  $mask_{delineatedCrowns}$ :  $diff = mask_{TC} - mask_{delineatedCrowns}$ ,  $diff[diff < 0] = 0$ .
2. Starpībai atrod savienotās komponentes, t.i. reģionus, kas bija reģistrēti koku vainagu noseģuma maskā, bet ne koku vainagu maskā un apskata katru savienoto komponenti atsevišķi.

3. Katra savienotā komponente atsevišķi tiek morfoloģiski paplašināta, izmantojot  $3 \times 3$  struktūrelementu. Atņemot no paplašinātās komponentes oriģinālo komponenti, iegūstam komponentes ārējo robežu, kas var pārklāties ar atdalītajiem koka vainagiem.
4. Komponentes robeža tiek pareizināta ar atdalīto koku vainagu attēlu. Nosakot reizinājumā nenulles elementus un saskaitot nenulles elementu vērtību sastopamības biežumu. Visbiežāk sastopamā elementa vērtība atbilst koka vainaga numuram, kuram ir visgarākā kopējā robeža ar konkrēto reģionu.

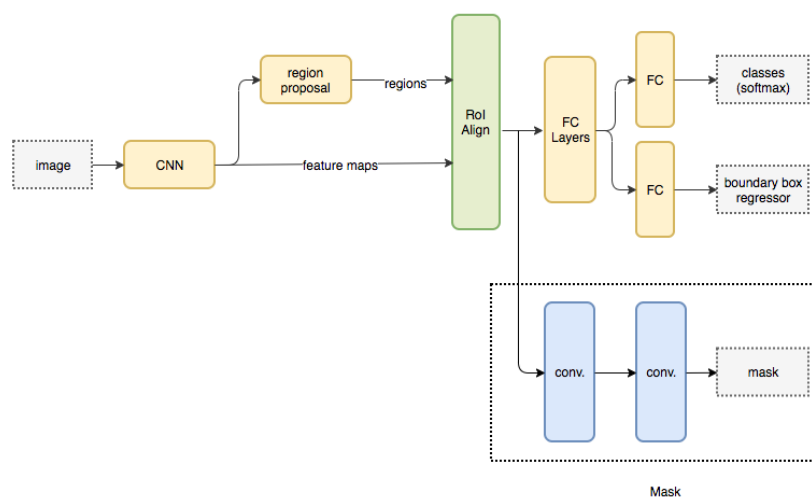


Att. 5.12. a) Iespējams, ka visi pikseļi no koku vainagu noseģuma maskas nav iekļauti kādā konkrētā koka vainagā, b) Pikseļi, kuri veido pietiekami mazus reģionus tiek piešķirti koku vainagam, ar kuru reģionam ir visgarākā kopīgā robeža.

Tā kā metodes mērķis ir kopīgi apstrādāt dažādus datu avotus, tad atsevišķi datu avoti šeit apskatīti netiks. Metodes rezultāti ir parādīti sadaļā "Rezultāti un diskusija".

### 5. 5. 2. Mask R-CNN pielietojums koku vainagu atdalīšanai

Instanču segmentācija dod iespēju identificēt kokus un atdalīt koku vainagus vienas metodes ietvaros. Koku vainagu segmentācijas uzdevuma realizācijai, izvēlēta Mask R-CNN konvolūcijas tīkla arhitektūra [43], skat. att. 5.13. Arhitektūras pamatideja ir vispirms atrast atsevišķas interesējošo objektu instances un pēc tam veikt katras atsevišķās instances segmentāciju.



Att. 5.13. Mask RCNN arhitektūras shematisks attēlojums [119].


Mask R-CNN pamatu (angl. *backbone*) veido konvolūcijas neironu tīkls, kas kalpo kā pazīmju izvilkējs (angl. *feature extractor*). Secīgos konvolūcijas slāņos notiek zema, vidēja un augsta līmeņa pazīmju atdalīšana.

Pēc konvolūcijas neironu tīkla seko attēla reģionu atrašana, kas potenciāli satur interesējošos objektus. Šajā fāzē attēla reģioni tiek šķirti tikai divās klasēs: attēla priekšplāns un fons. Attēla reģioni tiek meklēti saskaņā ar slīdošā loga koncepciju, pielietojot dažādu izmēru logus, lai atrastu dažādu izmēru objektus. Logi, kuros tiek pārbaudīta objekta klātbūtne, tiek vienmērīgi izvietoti visā attēlā. Apskatāmo logu izmēri ir viens no Mask R-CNN parametriem, par kura atbilstību jāpārliedzinās pirms tīkla apmācības.

Izmantojot dažādu izmēru logus, varam noteikt dažādu izmēru objektus, taču tajā pašā laikā tiek apgrūtināta reģionu klasifikācijas fāze, pievienojot tai izmēru variācijas. Šī problēma tiek risināta, pārveidojot atlasītos priekšplāna reģionus uz fiksēta izmēra reģioniem.

Tālāk seko divi paralēli atzari: 1) objekta atpazīšanas atzars, 2) semantiskās segmentācijas atzars. Objektu atpazīšanas atzaru veido pilnībā savienoti slāņi un rezultātā tiek noteikta reģionā esošā objekta klase un uzlabota objektu ierobežojošā loga forma. Semantiskās segmentācijas atzaru līdzīgi kā kodētāju-dekodētāju arhitektūrā veido konvolūcijas slāņi, kuru rezultātā tiek sagatavota instanču maska.

Tīkla apmācībai tika sagatavoti apmācības dati papildu apgabaliem no testa teritorijas A1. Šajos papildu apgabalos ar roku tika iezīmēti redzamie koku vainagi kā parādīts attēlā 5.14. Kopā tika iezīmēti 313 koku vainagi apmācībai un 50 koku vainagi validācijas mērķiem.



Att. 5.14. Mask R-CNN apmācības datu piemērs.

Tā kā šāds datu apjoms ir pārāk mazs konvolūcijas tīkla pilnīgai apmācībai, tad 1) tika izmantoti internetā pieejami svāra koeficienti jau apmācītam tīklam (izmantojot Image-

Net datu bāzi), 2) tika veikta mākslīga datu apjoma palielināšana, izmantojot rotācijas un atspoguļojumus.

Mask R-CNN tika apmācīti tikai augšējie slāņi 30 epohās, izmantojot 200 soļus epohā.

**Pētāmais jautājums: kāda ir Mask R-CNN koku vainagu identifikācijas un atdalīšanas precizitāte dažādu datu avotu gadījumā?**

Apstrādājamais attēls	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_c$	Precizitātes indekss (AI) %
NIR	198	79	41	56.67
nDSM	158	119	49	39.35
NIR + nDSM (2 slāņu attēls)	183	94	28	55.96

Tabula 5. 10. Datu avotu ietekme testa apgabalā A1.

Kategorija	$o_{ref,i}$ NIR	$o_{m,i}$ NIR	$o_{ref,i}$ nDSM	$o_{m,i}$ nDSM	$o_{ref,i}$ NIR+nDSM	$o_{m,i}$ NIR+nDSM
1%-19%	42	38	44	48	34	42
20%-39%	40	16	62	39	31	20
40%-59%	44	23	66	56	35	19
60%-79%	59	73	26	37	55	74
80%-100%	65	100	36	54	79	79
$E_A$	11.29	-	12.91	-	12.14	-

Tabula 5. 11. Koku vainagu atdalīšanas precizitāte. Kopā 277 koki.

## 5. 6. Rezultāti un diskusija

Koku identifikācijas un vainaga atdalīšanas uzdevuma precizitāti ietekmē vairāku faktoru mijiedarbība: datu telpiskā izšķirtspēja, koku vainagu izmērs, koku vainagu forma un audzes blīvums.

Pētījumos, kuros veikta dažādu koku identifikācijas metožu salīdzināšana, kā viena no piemērotākajām metodēm sarežģītu datu kopu apstrādē tika atzīta šablonu salīdzināšanas metode. Šablonu salīdzināšanas metode ir relatīvi robusta un tās precizitāti visvairāk ietekmē šablonu izvēle.

Gadījumu izpētes parādīja, ka jo vairāk šablonu tiek izmantoti, jo augstāks ir precizitātes indekss. Taču, pētot atsevišķi dažādu ar roku atlasītu šablonu precizitāti, redzams, ka visu šablonu efektivitāte nav vienlīdzīga. Tā kā pie konkrētās datu kopas telpiskās izšķirtspējas, atsevišķām koku sugām specifiskas vainagu pazīmes nebija novērojamas, tad efektīvākie šabloni atbilda biežāk sastopamajiem koku vainagu izmēriem.

Efektīvs risinājums koku vainagu izmēru dažādības iekļaušanai metodē ir šablona izmēru maiņa TM procesa laikā, digitāli palielinot vai samazinot attēlu. Ja šabloni tiek samazināti pārāk daudz, tad būtiski pieaug apstiprinājuma kļūdas, šabloniem atrodot nelielus lokālos maksimumus, kas neatbilst reāliem koku vainagiem.

Datu avota izvēles ziņā precizitātes indekss augstāks bija NIR attēla, nevis nDSM gadījumā. Tas ir pilnībā izskaidrojams ar telpiskās izšķirtspējas ietekmi. Ja telpiskā izšķirtspēja būtu augstāka, tad augstāks AI būtu raksturīgs nDSM, jo NIR attēla apstrādi apgrūtinātu koku vainagu tekstūra un apgaismojuma efekti.

Kopīga datu apstrāde ir efektīva, ja atsevišķi apstrādājam NIR un nDSM, apvienojot tikai TM metodes rezultātus. Testa apgabalā datu kopīgu apstrādi ievērojami apgrūtinā nesisistemātiskās ģeometriskās nobīdes starp attēliem. Ja aerofotogrāfijas ģeometriskās korekcijas tiktu veiktas, izmantojot Lidar mērījumus, tad kopīgās apstrādes efektivitāte būtu augstāka.

Optimālai šablonu izvēlei tika izstrādāta šablonu ģenerēšanas metodes EATG uz evolucionārā algoritma 1+1 bāzes.

Metodes priekšrocības ir iespēja novērtēt mazāko nepieciešamo šablonu skaitu un nav nepieciešami tālzpētes datu metadati. EATG aprēķina šablonus, izmantojot tikai palīgdatu kopu, bez ievades datiem par unikālajiem apstākļiem attēla ieguves brīdī, pelēkā toņa vērtībām attēlā un mežaudžu struktūru, koku sugām vai vainaga formām.

Lai EATG sasniegtu noderīgus rezultātus, lietotājam ir jānodrošina, ka palīgdatu kopā tiek iekļauti tipiskākie koku vainagi, t.i. biežāk sastopamie koku vainagu izmēri un biežāk sastopamās koku sugas.

Tā kā identifikācijas un apstiprinājuma kļūdas korelē inversi, tad EATG nepieļauj "pārtrenēšanos" pirmajiem šabloniem. Šabloni tiek ģenerēti sakārtotā secībā, saskaņā ar to atrasto koku skaitu, piemēram, pirmā šablona pielietojuma rezultātā tika atraksti 44 % koku testa apgabalā, otrā 14 %, trešā 8 % un tā tālāk.

Diemžēl EATG metode nespēja efektīvi konstruēt vairāku joslu šablonus, kas varētu būt izskaidrojams ar nesisistemātiskajām nobīdēm starp NIR attēlu un nDSM, kuras grūti simulēt, ja tiecamies uz vispārīgu šablonu izveidi.

Tabulā 5. 12. apkopoti labākie rezultāti, izmantojot ar roku atlasītus šablonu un EATG veidotus šablonus.

Konvolūcijas neironu tīkls Mask R-CNN veic instanču segmentāciju, tādējādi, apvienojot identifikācijas un vainagu atdalīšanas uzdevumu. Precizitātes indekss visaugstākais bija NIR attēla apstrādes rezultātiem un tas par 2% pārspēja EATG šablonu kopas pielietojumu. Tomēr visaugstākā precizitāte ir ar roku atlasītiem šabloniem un NIR un nDSM attēla kopīgajai apstrādei, jo tajā ir ņemtas vērā nobīdes starp abām datu kopām.

Koku vainagu atdalīšanas rezultāti ir apkopoti tabulā 5. 13. Testa teritorijā A1, nelielā apgabalā sastopami dažādu izmēru un dažādu koku sugu vainagi, kā arī bieži novērojama vainagu pārklāšanās. Atlasot palīgdatus pēc vizuālā novērtējuma, vairākos gadījumos bija problemātiski atšķirt konkrēta koka vainaga formu. palīgdati tika atlasīti, izmantojot attēlus redzamās gaismas diapazonā, tādēļ references daudzstūri varētu būt mazāki par patieso koku vainagu noēnojuma dēļ.

Mask R-CNN augstākie rezultāti tika sasniegti NIR attēlam, kas arī ir izskaidrojams ar ģeometriskajām nobīdēm starp datu kopām. Attēlos 5.15. un 5.16. redzams, ka Mask R-CNN segmentē izteikti apgaismotās koku daļas, lai gan apmācības dati tika sagatavoti,

Izmēra maiņa (%)	Atrasti koki $N_p$ (gab.)	Izlaisti koki $N_o$	Apstiprinājuma kļūda $N_e$	Precizitātes indekss (AI) %
Ar roku atlasīti 4 šabloni, NIR attēls, 75:100:150	200	77	53	53.1
Ar roku atlasīti 4 šabloni, NIR + nDSM (2 slāņu attēls), 75:100:150	225	52	50	63.2
5 EATG veidoti šabloni, NIR, fiksēts šablona izmērs	173	104	21	54.87
Mask R-CNN +NIR	199	79	41	56.7


Tabula 5. 12. TM metodes rezultāti testa apgabalam A1.

ietverot arī noēnoto daļu, bet lēmumu balstītā metode datu kopu apvienošanas rezultātā sniedz palīgdatiem līdzīgākas kontūras.


Piedāvātās lēmumu balstītās metodes nozīmīgākās priekšrocības ir iespēja brīvi komplektēt attēlus un apmācības dati nav nepieciešami. Lai identificētu koku vainagus, ir jābūt vismaz vienam pelēko toņu attēlam, bet maksimālais attēlu skaits nav ierobežots un ir iespējams izmantot arī jau apstrādātus datus, piemēram, koku sugu klasifikācijas rezultātus pikseļu līmenī.

Rezultāti parādīja, ka lēmumu balstītās metodes iezīmētās kontūras vairāk atbilst augsta pārklājuma kategorijām, salīdzinot ar Mask R-CNN. Taču šāda veikspēja attiecināma tikai uz gadījumiem, kad izdodas atrast kvalitatīvus lokālos maksimumus kā sākuma punktus. Izmantojot Mask R-CNN rezultātus kā ievades datus lēmumu balstītajai metodei, rezultāti ievērojami neatšķirās no Mask R-CNN semantiskās segmentācijas rezultātiem.





Att. 5.15. Konvolūcijas neironu tīkla Mask R-CNN instanču segmentācijas rezultāti tuvā infrasarkanā attēlam testa apgabalā A1. Atrastās koku vainagu kontūras iezīmētas ar baltu līniju. Rezultāti parādīti 6 A1 apakšapgabaliem. Pamatslānis: NIR attēls.



Att. 5.16. Lēmumu balstītā algoritma koku vainagu atdalīšanas rezultāti. Atrastās koku vainagu kontūras iezīmētas ar baltu līniju. Rezultāti parādīti 6 A1 apakšapgabaliem. Pamatslānis: NIR attēls.

Kategorija	$O_{ref,i}$ Mask R- CNN+NIR	$O_{m,i}$ Mask R- CNN+NIR	$O_{ref,i}$ lēmu- mu balstīta- jai metodei koku vaina- gu centroī- dām no pa- līgdatiem	$O_{m,i}$ lēmumu balstītajai metodei koku vainagu centroīdām no palīgdatiem	$O_{ref,i}$ lēmumu balstītajai metodei tikai Mask R-CNN atrstajiem kokiem	$O_{m,i}$ lēmumu balstītajai metodei tikai Mask R-CNN atrstajiem kokiem
1%-19%	42	38	9	3	31	33
20%-39%	40	16	20	28	57	45
40%-59%	44	23	59	61	51	60
60%-79%	59	73	87	79	67	55
80%-100%	65	100	102	106	57	64
$E_A$	11.29	-	11.9	-	13.5	-
References vainu kopskaits	250	250	277	277	257	257

Tabula 5. 13. Koku vainagu atdalīšanas precizitāte.

## 6. Secinājumi un priekšlikumi

Promocijas darba ietvaros tika izstrādātas pusautomatizētas datorizētas metodes koku vainagu noseguma noteikšanai gan pikseļa līmenī, gan identificējot atsevišķus kokus un to vainagus. Šādi pusautomatizētie risinājumi ļautu iegūt noderīgu informāciju mežu apsaimniekošanas vajadzībām, izmantojot jau eksistējošās datu kopas un neieguldot papildu finanšu līdzekļus. Datorizēto metožu izstrādes procesā īpašs uzsvars tika likts uz metožu pielietojamību plašās teritorijās un intuitīvi uztveramu algoritmu iekšējo parametru iekļaušanu (piemēram, minimālais atļautais attālums starp kokiem, maksimālais pieļaujamais koka vainaga diametrs u.c.). Pētījumu gaitā tika izdarīti sekojoši galvenie secinājumi:

1. Lai arī Latvijas mežos nav sastopamas daudz koku sugas, mežaudžu telpiskā struktūra mēdz būt atšķirīga relatīvi nelielā teritorijā un sarežģīta no audzes sastāva, vecuma un biežības viedokļa.
2. Meža kā likumā definēta termina pārņemšana tematisko karšu izveides uzdevuma formulēšanai ir komplicēta, jo meža definīcijā ietverti praksē grūti un finansiāli dārgi nosakāmi parametri (vainagu kopējā projekcija attiecībā pret mežaudzes kopējo teritoriju), kā arī aizaugošās teritorijas un dabiskie biotopi bieži neatbilst meža formālajai definīcijai. Šī iemesla dēļ darbā tika pētīts koku vainagu nosegums, kas neierobežo tālākās tematisko karšu izmantošanas iespējas.
3. Literatūras izpēte parādīja, ka tālīzpētes dati var nodrošināt unikālu informācijas telpisko detalizētību, taču meža inventarizācijas parametru mērījumi ir neprecīzāki salīdzinot ar lauka mērījumiem pat augstas telpiskās izšķirtspējas Lidar un aerofotogrāfiju gadījumā. Potenciāli optimālai meža inventarizācijas procedūrai būtu nepieciešami Lidar dati ar punktu blīvumu  $> 8$  punkti/ $m^2$  un multispektrālie dati ar 0.3 m telpisko izšķirtspēju un vairāk kā 12 frekvenču joslām redzamās gaismas un infrasarkanā diapazonā.
4. Jo augstāka tālīzpētes datu telpiskā izšķirtspēja, jo efektīvāka koku vainagu identifikācija un atdalīšana. Nepieciešamības gadījumā telpisko izšķirtspēju vienmēr iespējams samazināt, taču zemāka telpiskā izšķirtspēja nosaka tehnoloģiski nepārvaramus ierobežojumus.
5. Lokāli pielāgoti risinājumi koku vainagu noseguma kartēšanai sniedz par aptuveni 10% augstāku precizitāti nekā publiski pieejamās koku vainagu noseguma kartes.
6. Praktiski nozīmīgs koku vainagu noseguma kartēšanas algoritmu papildinājums ir t.s. pārļiecības līmenis. Pārļiecības līmenis raksturo viennozīmību no algoritmiskā viedokļa, ar kādu pikselis vai spektrālā klase tiek piešķirta kādam zemes pārseguma tipam un tas sniedz vērtīgu iespēju novērtēt tematiskās kartes uzticamību katra atsevišķa apstrādājamā elementa (pikselis, reģions vai spektrāla klase) līmenī.

7. Hibrīdās klasifikācijas darbpļūsma salīdzinājumā ar kNN metodi uzrāda atšķirīgas tendences precizitātē. Kvalitatīvu apmācības datu gadījumā augstāka precizitāte ir kNN, kas izskaidrojams ar kNN spēju izmantot apmācības datus bez vispārināta datu modeļa konstruēšanas. Vidējas kvalitātes apmācības datu gadījumā augstāka precizitāte ir hibrīdajai darbpļūsmai, jo tā efektīvāk izmanto apstrādājamā attēla informāciju un mazāka ietekme ir apmācības datiem.
8. Satelītattēlu hibrīdās klasifikācijas precizitātes fluktuācijas neparādīja viennozīmīgas sakarības ar attēla ieguves sezonu. Tas nozīmē, ka precizitāti spēcīgi ietekmē atmosfēras un apgaismojuma apstākļi. Tomēr precizitātes novērtējumi apstiprināja loģisku pieņēmumu, ka koku vainagu noseģumu iespējams precīzāk kartēt sezonā bez zaļās veģetācijas, jo ir augstāka spektrālo vērtību atšķirība starp lapkokiem un zālājiem.
9. Ar augstu pārlicības līmeni satelītattēlos iespējams konstatēt mežaudzes ar koku vainagu noseģumu aptuveni virs 60% (statistiski šādam noseģumam bieži atbilst krājas vērtības virs  $100 \text{ m}^3/\text{ha}$ ). Parametru analīze parādīja, ka koku suga pārlicības līmeni praktiski neietekmē. Pārlicības līmenis un atšķiršanas spēja mežaudzēm ar noseģumu zem 60 % ir atkarīgs no attēlu unikālajiem parametriem un bieži ir nesaderīgs, apstrādājot dažādos datumos iegūtus attēlus. Turpretī mežaudzēm ar noseģumu virs 60%, klasifikācijas rezultāti dažādos datumos iegūtiem satelītattēliem ir sakrītoši.
10. Ļoti augstas telpiskās izšķirspējas datu gadījumā, vienkāršota NDVI un nDSM sliekšņošana sniedz līdzvērtīgu precizitāti konvolūcijas neironu tīklam U-Net, taču U-Net ar līdzīgu precizitāti spēj segmentēt gan aerofotogrāfijas, gan Lidar datus un tam nav nepieciešami abi datu avoti.
11. Datu kopīga apstrāde ļauj paaugstināt šablonu salīdzināšanas metodes precizitāti, taču datu kopu ģeometriskā sakrītība ir kritiski svarīga. Datu nesistemātisko ģeometrisko nobīžu dēļ, Mask R-CNN un EATG metodes neuzrādīja nekādus ieguvumus datu kopīgai apstrādei.
12. Šablonu salīdzināšanas metodes precizitāti iespējams paaugstināt, ieviešot minimālo pieļaujamo attālumu starp koku vainagiem, lai filtrētu vairākas atbildes vienam koka vainagam un iespējot šablona izmēra izmaiņas.
13. EATG aprēķina šablonus, izmantojot tikai palīgdatu kopu, bez ievades datiem par unikālajiem apstākļiem attēla ieguves brīdī, pelēkā toņa vērtībām attēlā un mežaudžu struktūru, koku sugām vai vainaga formām. Taču, lai EATG sasniegtu noderīgus rezultātus, lietotājam ir jānodrošina, ka palīgdatu kopā tiek iekļauti tipiskākie koku vainagi, t.i. biežāk sastopamie koku vainagu izmēri un biežāk sastopamās koku sugas.
14. EATG viena datu avota gadījumā ļauj izveidot efektīvāku šablonu kopu, nekā iespējams atlasīt ar roku. EATG šablonu kopā novērojamas vairākas sakarības: 1) tiek

simulēts koka vainaga noēnojums, 2) koka vainaga šablonā tiek iekļauta daļa no cita koka vainaga.

15. Lēmumu balstītā metode koku vainagu atdalīšanai uzrādīja augstāku sakritību ar pa-līgdatiem nekā Mask R-CNN. Šī metode ir ļoti elastīga: nav nepieciešami apmācības dati un lietotājs var ievadīt jebkurus mežaudžu tālīzpētes vai datorizētās apstrādes datus attēlu formā, tādējādi ļaujot izmantot pēc iespējas vairāk informācijas koku vainagu atdalīšanas procesā.
16. Tā kā konvolūcijas neironu tīkliem nepieciešams liels apmācības datu apjoms, tad citu algoritmu rezultātus iespējams ērti izmantot šo apmācības datu automatizētai sagata-vošanai.
17. Salīdzinot vidējas un ļoti augstas telpiskās izšķirtspējas datu klasifikācijas rezultātus ir kritiski jāanalizē testa punktu novietojums un to attālums līdz dažādu zemes pārseguma tipu robežām.
18. No praktiskā viedokļa, konvolūcijas neironu tīklu pielietojums ir ļoti līdzīgs specializē-tajiem algoritmiem, jo mainoties datu telpiskajai izšķirtspējai vai citiem parametriem tīkla augšējiem slāņiem tāpat nepieciešams veikt pārāpmācību.

Priekšlikumi:

1. Efektīvai valsts mēroga aerodatu datu bāzes izmantošanai nepieciešami risinājumi ne-sistemātisku ģeometrisku nobīžu korekcijām.
2. Latvijas mērogā būtu nepieciešama etalondatu kopa zemes lietojuma un koku identifi-kācijas un vainaga kontūru noteikšanas lokāli pielāgoto algoritmu testēšanai.
3. Konvolūcijas neironu tīklus koku identifikācijai nepieciešams izpētīt detalizētāk, jo iespējama tālāki uzlabojumi.

## Izmantotās literatūras un avotu saraksts

- [1] Meža likums, pieņemts 24.02.2000., stājas spēkā: 17.03.2000. "Latvijas Vēstnesis", 98/99 (2009/2010), 16.03.2000., "Ziņotājs", 8, 20.04.2000.
- [2] European Commission's Joint Research Centre Pan-European forest/non-forest map 2000. <https://data.jrc.ec.europa.eu/dataset/a401bc45-fb14-4535-b86c-73aabe816443>, 2000.
- [3] A. Amin and S. Fazal. Assessment of Forest Fragmentation in District Shopian Using Multi-temporal Land Cover ( A GIS Approach ). *Journal of Geosciences and Geomatics*, 5(1):12–23, 2017.
- [4] J. R. Anderson. *A land use and land cover classification system for use with remote sensor data*, volume 964. US Government Printing Office, 1976.
- [5] P. Anttila. Assessment of manual and automated methods for updating stand-level forest inventories based on aerial photography. *Academic dissertation. Faculty of Forestry, University of Joensuu.*, 2005.
- [6] M. Baatz and A. Schäpe. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung XII*, pages 12–23, 2000.
- [7] B. Bhatta. *Research Methods in Remote Sensing*. 2013.
- [8] T. Brandtberg and F. Walter. An algorithm for delineation of individual tree crowns in high spatial resolution aerial images using curved edge segments at multiple scales. *Proceedings of Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, Victoria, British Columbia, Canada*, pages 41–54, 1998.
- [9] T. Brandtberg, T. A. Warner, R. E. Landenberger, and J. B. McGraw. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in north america. *Remote sensing of Environment*, 85(3):290–303, 2003.
- [10] J. Breidenbach, E. Næsset, V. Lien, T. Gobakken, and S. Solberg. Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. *Remote Sensing of Environment*, 114(4):911–924, 2010.
- [11] P. Bunting and R. Lucas. The delineation of tree crowns in australian mixed species forests using hyperspectral compact airborne spectrographic imager (casi) data. *Remote Sensing of Environment*, 101(2):230–248, 2006.

- [12] G. Büttner, J. Feranec, G. Jaffrain, L. Mari, G. Maucha, and T. Soukup. The corine land cover 2000 project. *EARSeL eProceedings*, 3(3):331–346, 2004.
- [13] M. Castelluccio, G. Poggi, C. Sansone, and L. Verdoliva. Land use classification in remote sensing images by convolutional neural networks. *Computer Vision and Pattern Recognition*, *arXiv:1508.00092*, 2015.
- [14] D. L. Civco. Artificial neural networks for land-cover classification and mapping. *International Journal of Geographical Information Science*, 7(2):173–186, 1993.
- [15] A. P. Cracknell. Review article synergy in remote sensing-what’s in a pixel? *International Journal of Remote Sensing*, 19(11):2025–2047, 1998.
- [16] D. S. Culvenor. Tida: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Computers & Geosciences*, 28(1):33–44, 2002.
- [17] M. Dalponte, L. Bruzzone, and D. Gianelle. Fusion of hyperspectral and lidar remote sensing data for classification of complex forest areas. *Geoscience and Remote Sensing, IEEE Transactions on*, 46(5):1416–1427, 2008.
- [18] M. Dalponte, H. O. Ørka, L. T. Ene, T. Gobakken, and E. Næsset. Tree crown delineation and tree species classification in boreal forests using hyperspectral and als data. *Remote sensing of environment*, 140:306–317, 2014.
- [19] F. Devriendt, F. Van Coillie, R. De Wulf, L. Bertels, P. Kempeneers, K. Vandekerckhove, and F. Morsdorf. Classification of unmanaged forest reserves in flanders (belgium) at the tree crown level using airborne hyperspectral and lidar data. In *4th International conference on Geographic Object Based Image Analysis (GEOBIA 2012)*, pages 141–145, 2012.
- [20] R. Dinuls, G. Erins, A. Lorencs, I. Mednieks, and J. Sinica-Sinavskis. Tree species identification in mixed baltic forest using lidar and multispectral data. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 5(2):594–603, 2012.
- [21] R. O. Duda, P. E. Hart, and D. G. Stork. *Pattern classification*. John Wiley & Sons, 2012.
- [22] P. Dulyakarn and Y. Rangsanseri. Fuzzy c-means clustering using spatial information with application to remote sensing. In *Paper presented at the 22nd Asian Conference on Remote Sensing*, volume 5, page 9, 2001.
- [23] Latvijas Ģeotelpiskās Informācijas Aģentūra. Aerofotogrāfēšana. [http://map.lgia.gov.lv/index.php?lang=0&cPath=4\\_16&txt\\_id=23](http://map.lgia.gov.lv/index.php?lang=0&cPath=4_16&txt_id=23). Online: apskatīts 30.04.2015.

- [24] Latvijas Ģeotelpiskās informācijas aģentūra. Aerolāzerskenēšana. [http://map.lgia.gov.lv/index.php?lang=0&cPath=4\\_5&txt\\_id=126](http://map.lgia.gov.lv/index.php?lang=0&cPath=4_5&txt_id=126). Skatīts: 03.04.2019.
- [25] Latvijas Ģeotelpiskās informācijas aģentūra. Ortofotokartes: specifikācijas un normatīvie dokumenti. [http://map.lgia.gov.lv/index.php?lang=0&cPath=4\\_16&txt\\_id=90](http://map.lgia.gov.lv/index.php?lang=0&cPath=4_16&txt_id=90). Skatīts: 03.04.2019.
- [26] ESRI. Arcgis 9.2. user manual, 2008.
- [27] L. Eysn, M. Hollaus, K. Schadauer, and N. Pfeifer. Forest Delineation Based on Airborne LIDAR Data. *Remote Sensing*, 4(12):762–783, March 2012.
- [28] J. Fan, M. Han, and J. Wang. Single point iterative weighted fuzzy c-means clustering algorithm for remote sensing image segmentation. *Pattern Recognition*, 42(11):2527–2540, 2009.
- [29] P. F. Fisher, A. J. Comber, and R. Wadsworth. Land use and land cover: Contradiction or complement. *Re-presenting GIS*, pages 85–98, 2005.
- [30] G. M. Foody. Status of land cover classification accuracy assessment. *Remote sensing of environment*, 80(1):185–201, 2002.
- [31] G. M. Foody and D. P. Cox. Sub-pixel land cover composition estimation using a linear mixture model and fuzzy membership functions. *Remote sensing*, 15(3):619–631, 1994.
- [32] H. Franco-Lopez, A. R. Ek, and M. E. Bauer. Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method. *Remote sensing of environment*, 77(3):251–274, 2001.
- [33] S. E. Franklin. *Remote sensing for sustainable forest management*. CRC Press, 2001.
- [34] C. Gómez, J. C. White, and M. A. Wulder. Optical remotely sensed time series data for land cover classification : A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116:55–72, 2016.
- [35] R. C. Gonzales and R. E. Woods. *Digital image processing*, 2-nd edition, 2002.
- [36] F. A. Gougeon. Automatic individual tree crown delineation using a valley-following algorithm and rule-based system. In *Proc. International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, Victoria, British Columbia, Canada*, pages 11–23, 1998.
- [37] A. Grīnvalds. Meža statistiskās inventarizācijas dati meža apsaimniekošanas plānošanā, 2013.



- [38] L. Gulbe, M. Lang, A. Traskovs, and A. Stepcenko. Biomass mapping and potential assessment in kurzeme planning region. purebiomas project report, 2013.
- [39] L. Gulbe and I. Mednieks. Automatic identification of individual tree crowns in mixed forests using fusion of lidar and multispectral data. *Technologies of Computer Control.*, 2013.
- [40] R. Haapanen, A. R. Ek, M. E. Bauer, and A. O. Finley. Delineation of forest/nonforest land use classes using nearest neighbor methods. *Remote Sensing of Environment*, 89(3):265–271, 2004.
- [41] M. C. Hansen and T. R. Loveland. A review of large area monitoring of land cover change using landsat data. *Remote sensing of Environment*, 122:66–74, 2012.
- [42] M. C. Hansen, P. V. Potapov, R. Moore, M. Hancher, S. A. Turubanova, A. Tyukavina, D. Thau, S. V. Stehman, S. J. Goetz, T. R. Loveland, et al. High-resolution global maps of 21st-century forest cover change. *Science*, 342(6160):850–853, 2013.
- [43] K. He, G. Gkioxari, P. Dollár, and R. Girshick. Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 2961–2969, 2017.
- [44] J. Heinzl and B. Koch. Investigating multiple data sources for tree species classification in temperate forest and use for single tree delineation. *International Journal of Applied Earth Observation and Geoinformation*, 18:101–110, 2012.
- [45] J. N. Heinzl, H. Weinacker, and B. Koch. Full automatic detection of tree species based on delineated single tree crowns—a data fusion approach for airborne laser scanning data and aerial photographs. *Proceedings of SilviLaser*, 2008:8th, 2008.
- [46] T. Hengl. Finding the right pixel size. *Computers & Geosciences*, 32(9):1283–1298, 2006.
- [47] P. Holmgren and T. Thuresson. Satellite remote sensing for forestry planning—a review. *Scandinavian Journal of Forest Research*, 13(1-4):90–110, 1998.
- [48] F. Hu, G. Xia, J. Hu, and L. Zhang. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 7(11):14680–14707, 2015.
- [49] C. Huang, L. S. Davis, and J. R. G. Townshend. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4):725–749, 2002.
- [50] J. Jansons. Meža statistiskā inventarizācija Latvijā: metode, provizoriskie rezultāti. [http://www.lob.lv/download/Meza\\_statist\\_inventarizacija\\_LV\\_provizor\\_rezult\\_JansonsJ\\_2009\\_01\\_16.pdf](http://www.lob.lv/download/Meza_statist_inventarizacija_LV_provizor_rezult_JansonsJ_2009_01_16.pdf).

- [51] L. Jing, B. Hu, T. Noland, and J. Li. An individual tree crown delineation method based on multi-scale segmentation of imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70:88–98, June 2012.
- [52] H. Kaartinen, X. Liang, P. Litkey, A. Kukko, X. Yu, and M. Holopainen. Accuracy of automatic tree extraction using airborne laser scanner data. *Proceedings of SilviLaser*, pages 467–476, 2008.
- [53] M. Katoh and F. A. Gougeon. Improving the Precision of Tree Counting by Combining Tree Detection with Crown Delineation and Classification on Homogeneity Guided Smoothed High Resolution (50 cm) Multispectral Airborne Digital Data. *Remote Sensing*, 4(12):1411–1424, May 2012.
- [54] T. Kavzoglu and P. M. Mather. The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23):4907–4938, 2003.
- [55] Y. Ke and L. J. Quackenbush. A comparison of three methods for automatic tree crown detection and delineation from high spatial resolution imagery. *International Journal of Remote Sensing*, 32(13):3625–3647, 2011.
- [56] Y. Ke and L. J. Quackenbush. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*, 32(17):4725–4747, 2011.
- [57] R. Khatami, G. Mountrakis, and S. V. Stehman. Remote Sensing of Environment A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes : General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177:89–100, 2016.
- [58] B. Koch, U. Heyder, and H. Weinacker. Detection of Individual Tree Crowns in Airborne Lidar Data. *Photogrammetric Engineering & Remote Sensing*, 72(4):357–363, April 2006.
- [59] I. Korpela, B. Dahlin, E. Bruun, F. Haapaniemi, J. Honkasalo, S. Ilvesniemi, V. Kuutti, M. Linkosalmi, J. Mustonen, M. Salo, O. Suomi, and H. Virtanen. Single-tree forest inventory using lidar and aerial images for 3d treetop positioning, species recognition, height and crown width estimation. *Proceedings of ISPRS workshop on laser scanning*, 2002.
- [60] J. Kozak, C. Estreguil, and K. Ostapowicz. European forest cover mapping with high resolution satellite data: The Carpathians case study. *International Journal of Applied Earth Observation and Geoinformation*, 10(1):44–55, February 2008.

- [61] T. Kuemmerle, V. C. Radeloff, K. Perzanowski, and P. Hostert. Cross-border comparison of land cover and landscape pattern in eastern europe using a hybrid classification technique. *Remote sensing of environment*, 103(4):449–464, 2006.
- [62] H. P. La, Y. D. Eo, A. Chang, and C. Kim. Extraction of individual tree crown using hyperspectral image and lidar data. *KSCE Journal of Civil Engineering*, pages 1–10, 2014.
- [63] M. Långkvist, A. Kiselev, M. Alirezaie, and A. Loutfi. Classification and segmentation of satellite orthoimagery using convolutional neural networks. *Remote Sensing*, 8(4):329, 2016.
- [64] M. Larsen. Finding an optimal match window for spruce top detection based on an optical tree model. In *Proc. International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry, Victoria, British Columbia, Canada*, pages 55–66. Citeseer, 1998.
- [65] M. Larsen, M. Eriksson, X. Descombes, G. Perrin, T. Brandtberg, and F. A. Gougeon. Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *International Journal of Remote Sensing*, 32(20):5827–5852, 2011.
- [66] M. Larsen and M. Rudemo. Using ray – traced templates to find individual trees in aerial photographs. In *Proceedings of the 10th Scandinavian Conference on Image Analysis*, 1997.
- [67] H. Latifi, F. E. Fassnacht, J. Müller, A. Tharani, S. Dech, and M. Heurich. Forest inventories by lidar data: A comparison of single tree segmentation and metric-based methods for inventories of a heterogeneous temperate forest. *International Journal of Applied Earth Observation and Geoinformation*, 42:162–174, 2015.
- [68] D. Leckie, F. Gougeon, D. Hill, R. Quinn, L. Armstrong, and R. Shreenan. Combined high-density lidar and multispectral imagery for individual tree crown analysis. *Canadian Journal of Remote Sensing*, 29(5):633–649, 2003.
- [69] D. G. Leckie, F. A. Gougeon, S. Tinis, T. Nelson, C. N. Burnett, and D. Paradine. Automated tree recognition in old growth conifer stands with high resolution digital imagery. *Remote Sensing of Environment*, 94(3):311–326, February 2005.
- [70] W. Li, Q. Guo, M. K. Jakubowski, and M. Kelly. A new method for segmenting individual trees from the lidar point cloud. *Photogrammetric Engineering & Remote Sensing*, 78(1):75–84, 2012.
- [71] T. M. Lillesand, R. W. Kiefer, J. W. Chipman, et al. *Remote sensing and image interpretation*. Number Ed. 5. John Wiley & Sons Ltd, 2004.

- [72] K. Lim, P. Treitz, M. Wulder, B. St-Onge, and M. Flood. LiDAR remote sensing of forest structure. *Progress in Physical Geography*, 27(1):88–106, March 2003.
- [73] C. Lin, G. Thomson, C. Lo, and M. Yang. A Multi-level Morphological Active Contour Algorithm for Delineating Tree Crowns in Mountainous Forest. *Photogrammetric Engineering & Remote Sensing*, 77(3):241–249, March 2011.
- [74] T. R. Loveland and J. L. Dwyer. Landsat: Building a strong future. *Remote Sensing of Environment*, 122:22–29, 2012.
- [75] M. Mahdianpari, B. Salehi, M. Rezaee, F. Mohammadimanesh, and Y. Zhang. Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, 10(7):1119, 2018.
- [76] H. Mäkelä and A. Pekkarinen. Estimation of forest stand volumes by landsat tm imagery and stand-level field-inventory data. *Forest ecology and management*, 196(2):245–255, 2004.
- [77] G. Mallinis, N. Koutsias, M. Tsakiri-Strati, and M. Karteris. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(2):237–250, March 2008.
- [78] P. Mather and M. Koch. *Computer processing of remotely-sensed images: an introduction*. John Wiley and Sons, 2010.
- [79] P. M. Mather and M. Koch. *Computer Processing of Remotely Sensed Images*. Wiley Online Library, 2004.
- [80] I. Mohd Hasmadi, H. Pakhriazad, and M. Shahrin. Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia-Malaysian Journal of Society and Space*, 1(1):1–10, 2009.
- [81] S. Morsy, A. Shaker, and P. E. Larocque. AIRBORNE MULTISPECTRAL LIDAR DATA FOR LAND-COVER CLASSIFICATION AND LAND / WATER MAPPING USING DIFFERENT SPECTRAL INDEXES. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III(July):12–19, 2016.
- [82] G. Mountrakis, J. Im, and C. Ogole. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3):247–259, 2011.
- [83] M. Pal and P. M. Mather. An assessment of the effectiveness of decision tree methods for land cover classification. *Remote sensing of environment*, 86(4):554–565, 2003.
- [84] M. Pal and P. M. Mather. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5):1007–1011, 2005.

- [85] M. Peng, C. Wang, T. Chen, and G. Liu. Nirfacenet: A convolutional neural network for near-infrared face identification. *Information*, 7(4):61, 2016.
- [86] L. E. Peterson. K-nearest neighbor. *Scholarpedia*, 4(2):1883, 2009.
- [87] C. Pohl and J. L. Van Genderen. Review article multisensor image fusion in remote sensing: concepts, methods and applications. *International journal of remote sensing*, 19(5):823–854, 1998.
- [88] J. Pollock. The automatic recognition of individual trees in aerial images of forests based on a synthetic tree crown image model. *PhD Thesis*, 1996.
- [89] R. Pollock. Individual tree recognition based on a synthetic tree crown image model. In *Proceedings of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry*. Victoria, BC: Canadian Forest Service, Pacific Forestry Center, pages 25–34, 1998.
- [90] S. C. Popescu, R. H. Wynne, and R. F. Nelson. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Canadian journal of remote sensing*, 29(5):564–577, 2003.
- [91] P. V. Potapov, S. A. Turubanova, A. Tyukavina, A. M. Krylov, J. L. McCarty, V. C. Radeloff, and M. C. Hansen. Eastern europe’s forest cover dynamics from 1985 to 2012 quantified from the full landsat archive. *Remote Sensing of Environment*, 159:28–43, 2015.
- [92] D. A. Pouliot, D.J. King, F.W. Bell, and D.G. Pitt. Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment*, 82(2-3):322–334, October 2002.
- [93] Vidzemes Plānošanas Reģions. Daba un resursi. [http://www.vidzeme.lv/lv/daba\\_un\\_resursi/](http://www.vidzeme.lv/lv/daba_un_resursi/). Online: apskatīts 30.04.2015.
- [94] J. A. Richards and J. A. Richards. *Remote sensing digital image analysis*, volume 3. Springer, 1999.
- [95] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67:93–104, 2012.
- [96] F. Rohrbach. Point density and point spacing. <https://felix.rohrba.ch/en/2015/point-density-and-point-spacing/>. Skatīts: 03.05.2019.
- [97] O. Ronneberger, P. Fischer, and T. Brox. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015.

- [98] O. Rozenstein and A. Karnieli. Comparison of methods for land-use classification incorporating remote sensing and gis inputs. *Applied Geography*, 31(2):533–544, 2011.
- [99] D. Schepaschenko, I. McCallum, A. Shvidenko, S. Fritz, F. Kraxner, and M. Obersteiner. A new hybrid land cover dataset for russia: a methodology for integrating statistics, remote sensing and in situ information. *Journal of Land Use Science*, 6(4):245–259, 2011.
- [100] M. Schluse and P. Krahwinkler. Single tree detection using airborne laser scanner data in forestry management. *Proceedings of the ISPRS Workshop on Laser Scanning*, pages 350–354, 2007.
- [101] J. J. Schulz, L. Cayuela, C. Echeverria, J. Salas, and J. M. Rey Benayas. Monitoring land cover change of the dryland forest landscape of central chile (1975–2008). *Applied Geography*, 30(3):436–447, 2010.
- [102] G. J. Scott, M. R. England, W. A. Starms, R. A. Marcum, and C. H. Davis. Training deep convolutional neural networks for land–cover classification of high-resolution imagery. *IEEE Geoscience and Remote Sensing Letters*, 14(4):549–553, 2017.
- [103] A. Sharma, X. Liu, and X. Yang. Land Cover Classification from Multi-temporal , Multi-spectral Remotely Sensed Imagery using Patch-Based Recurrent Neural Networks. *Neural Networks*, pages 1–18, 2018.
- [104] B. Somers, G. P. Asner, L. Tits, and P. Coppin. Endmember variability in spectral mixture analysis: A review. *Remote Sensing of Environment*, 115(7):1603–1616, 2011.
- [105] P. K. Srivastava, D. Han, M. A. Rico-Ramirez, M. Bray, and T. Islam. Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50(9):1250–1265, 2012.
- [106] J. C. Suárez, C. Ontiveros, S. Smith, and S. Snape. Use of airborne lidar and aerial photography in the estimation of individual tree heights in forestry. *Computers & Geosciences*, 31(2):253–262, 2005.
- [107] K. Sumit. Satellite imagery feature detection with spacenet dataset using deep unet. <https://github.com/reachsumit/deep-unet-for-satellite-image-segmentation>. Skafits: 31.05.2019.
- [108] J. R. G. Townshend, C. Huang, S. N. V. Kalluri, R. S. Defries, S. Liang, and K. Yang. Beware of per-pixel characterization of land cover. *International Journal of remote sensing*, 21(4):839–843, 2000.

- [109] ģeoloģijas un meteoroloģijas centrs” VSIA ”Latvijas Vides. Latvijas klimats. <https://www.meteo.lv/lapas/laika-apstakli/klimatiska-informacija/latvijas-klimats/latvijas-klimats?id=1199&nid=562>. Skatīts: 03.04.2019.
- [110] L. Wald. Some terms of reference in data fusion. *IEEE Transactions on Geosciences and Remote Sensing*, 37(3):1190–1193, 1999.
- [111] Q. Weng. Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends. *Remote Sensing of Environment*, 117:34–49, 2012.
- [112] G. G. Wilkinson. Results and implications of a study of fifteen years of satellite image classification experiments. *Geoscience and Remote Sensing, IEEE Transactions on*, 43(3):433–440, 2005.
- [113] P. T. Wolter, D. J. Mladenoff, G. E. Host, and T. R. Crow. Improved forest classification in the northern lake states using multi-temporal landsat imagery. *Photogrammetric Engineering and Remote Sensing*, 61(9):1129–1144, 1995.
- [114] M. A. Wulder, J. C. White, K. O. Niemann, and T. Nelson. Comparison of airborne and satellite high spatial resolution data for the identification of individual trees with local maxima filtering. *International Journal of Remote Sensing*, 25(11):2225–2232, June 2004.
- [115] Y. Xie, Z. Sha, and M. Yu. Remote sensing imagery in vegetation mapping: a review. *Journal of plant ecology*, 1(1):9–23, 2008.
- [116] Y. Ye and J. Shan. A local descriptor based registration method for multispectral remote sensing images with non-linear intensity differences. *ISPRS Journal of Photogrammetry and Remote Sensing*, 90:83–95, 2014.
- [117] M. Zaremba and F. Gougeon. Fusion of High-Resolution Satellite and Lidar Data for Individual Tree Recognition. *2006 Canadian Conference on Electrical and Computer Engineering*, pages 1112–1115, 2006.
- [118] J. Zhang. Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 1(1):5–24, 2010.
- [119] X. Zhang. Simple understanding of mask rcnn. <https://medium.com/@alittlepain833/simple-understanding-of-mask-rcnn-134b5b330e95>. Skatīts: 18.06.2019.
- [120] Z. Zhu, S. Wang, and C. E. Woodcock. Improvement and expansion of the fmask algorithm: cloud, cloud shadow, and snow detection for landsats 4–7, 8, and sentinel 2 images. *Remote Sensing of Environment*, 159:269–277, 2015.
- [121] V. Znotiņa. Meži. <http://latvijas.daba.lv/biotopi/mezi.shtml>. Skatīts: 03.04.2019.