

Doktori (PhD) értekezés tézisei

**Földtudományi fejlesztések egyedfakorona csúcsok,
fatörzs és ágtiszta törzsmagasság felismerésére külön-
böző felbontású lézeres szkennelési adatok felhasználá-
sával**

Diószegi Gergő

Témavezető: Dr. Szabó Szilárd



DEBRECENI EGYETEM

Földtudományok Doktori Iskola

Debrecen, 2025

BEVEZETÉS és CÉLKITŰZÉS

Erdő és faállományok dendrometriai leírása kulcsfontosságú a hatékony erdei gazdálkodási stratégiák kidolgozásához. A részletes erdőleltározás, amely magába foglalja a fafajok összetételére, magasságára, mellmagasságára, lombkorona záródásra és a fatérfogatra vonatkozó adatokat, az adott erdei ökoszisztéma alapját képezi. Az erdőleltározás regionális és nemzeti szintű felmérése hagyományosan a szisztematikus területalapú mintavételre támaszkodott (Beaudoin et al., 2017; Blackard et al., 2008; Tomppo, 2006). Az elmúlt két évtizedben azonban a Light Detection and Ranging (LiDAR), különösen légi lézeres szkenneléssel (ALS) kombinálva, új lehetőségként jelent meg az erdőgazdálkodók és kutatók számára (Hyypä et al., 2008; White et al., 2016). A lézeres szkennelési technológiák gyors fejlődése a nagy élőmunkaigényű és költséges terepen történő adatgyűjtésnél hatékonyabb LiDAR-alapú adatgyűjtés erdészeti felmérésekbe való integrálását eredményezte. A LiDAR-adatok részletgazdagsága segíti az erdők szerkezetének leírását és ökológiájának megértését (Koch et al., 2006; Wulder et al., 2008).

Ha LiDAR-adatokat használunk, az erdészeti mintavétel tulajdonságait két fő megközelítéssel modellezzük: a területalapú módszerrel (Bouvier et al., 2015; Parkitna et al., 2021) és az egyesfa módszerrel, amely egy erdő vagy egy erdőrészlet nagy részletességű, precíziós leírását tükrözi (Hardenbol et al., 2023; Popescu et al., 2003). Az egyesfa megközelítés különösen fontos a növényzet szénkészletének számszerűsítéséhez, valamint a fák egészségének és fajok közötti és fajon belüli kompetíció-dinamikájának megértéséhez (Zianis et al., 2005). Stresszes állapotba került fák stresszreakciókat váltanak ki és stresszindikátorok segítségével azonosíthatók; a halálozás és a lassú pusztulás korai felismerése a modern technikákkal támogatja az alkalmazkodó erdőgazdálkodást (Hantsch et al., 2014).

Az egyesfa adatok elengedhetetlenek a koronaplaszticitás kiértékeléséhez is, ami a fajok közti és fajon belüli verseny mutatója (Seidel et al., 2011). Egyesfák elkülönítésének (individual tree detection, ITD) pontossága kulcsfontosságú a fák és erdők összetettségét leíró erdőleltározás szempontjából. Az utóbbi években jelentős előrelépés történt a földi lézeres szkennelés (TLS) kutatásában (Lecigne et al., 2018; Terryn et al., 2023; Xi and Hopkinson, 2021). Az ALS fejlesztései, beleértve a megnövekedett pontsűrűséget és a továbbfejlesztett szenzor érzékelő képességét, lehetővé teszik TLS-alapú mutatók

alkalmazását ALS-adatokra. Ezáltal ALS alapú, nagy felbontású 3D faalakot elemezhetünk. A korona pontos meghatározása különösen fontos, mivel a korona – a fa ágtszta törzsmagasság (crown base height, rövidítve CBH) feletti része – a hagyományos erdőértékszámítás egyik legfontosabb eleme (Kelly et al., 2018; Luo et al., 2018; Stefanidou et al., 2020).

Ez a disszertáció három egymással összefüggő témakörre épül, melynek keretében új erdészeti elemző technikákat fejlesztettem. Az első témakör egy ITD módszert mutat be, amely alacsony pontsűrűségű LiDAR adatokból származó Canopy Height Modellt (CHM) használ. A munka keretében a debreceni Nagyerdő egy mintaterületére egy új ITD algoritmust fejlesztettem ki. Ez az algoritmus a Growing Tree Region (GTR) koncepcióját alkalmazza, melyet egy R csomagban (package-ben) valósítottam meg, TREETOPS néven. A második téma egy CBH-meghatározó módszer, amely nagy pontsűrűségű pontfelhő adatokat használ, és az előbb említett ITD eszközre épül, mivel az ITD pontos meghatározása a CBH-detektálás előfeltétele, a fejlesztés eredménye itt is egy R csomag, *treecbh* néven. Míg a TREETOPS kisebb felbontású LiDAR adatokkal is működik, a *treecbh* nagyfelbontású ALS LiDAR adatokat igényel, mivel maga a feladat is ezt követeli meg. A *treecbh* tehát fa pontfelhők előre szegmentált egyedi fáit használja inputként, így az első témakör TREETOPS algoritmus segítségével az egyedi fák koordinátáinak meghatározása után a pontfelhőt manuálisan szegmentálhatjuk. A *treecbh* egy hierarchikus-grafikus izoláló R csomagot, a *treeiso-t* (Xi and Hopkinson, 2021) használja a fatörzs és az ehhez kapcsolódó első leveles ágak elkülönítésére. A *treecbh* újdonsága abban rejlik, hogy egy függőleges K-means clustering-en alapuló 2D kernel módszert alkalmaz a CBH detektálására. A harmadik témakörben nagy pontsűrűségű TLS-adatok felhasználásával a diszkrét Morse elméletet alkalmaztam egyéni fák izolálására.

A következő célkitűzéseket határoztam meg:

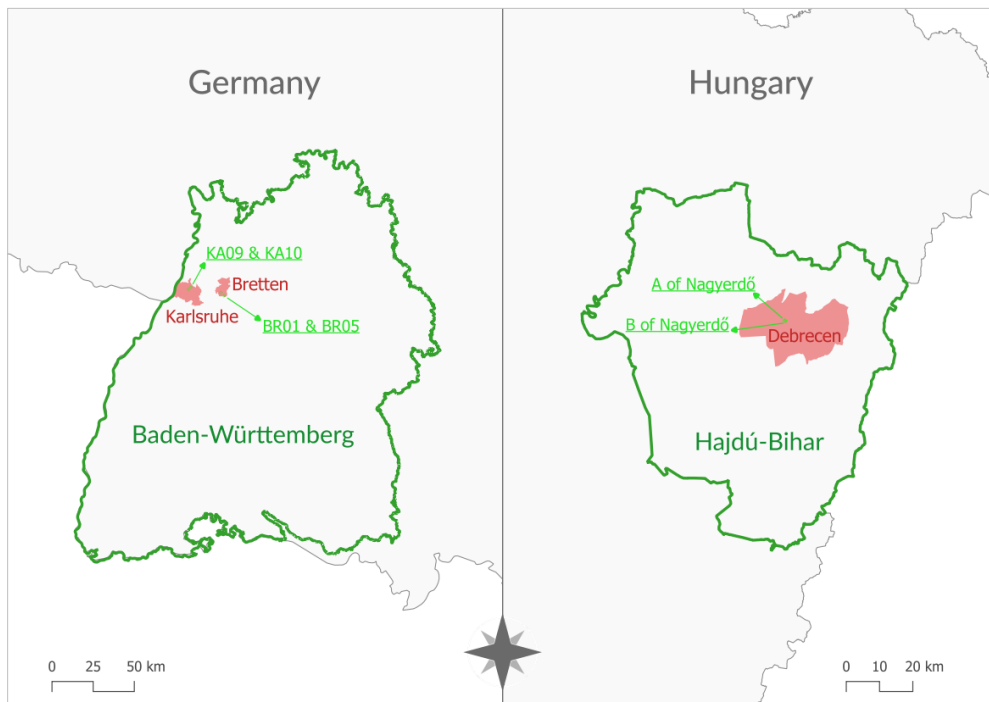
1. Egy egyszerű, CHM-et felhasználó, GTR-alapú lombkorona csúcs-detektáló algoritmus kifejlesztése és R csomagba való integrálása, amely zökkenőmentesen illeszkedik a lidR csomag kódolási keretébe (TREETOPS csomag). Ezen algoritmus különböző sűrűségű és szerkezetű erdőkben való tesztelése, valamint az algoritmus fakorona csúcs detektáló pontosságának

összehasonlítása a Local Maxima (LM) keresést használó Variable Window Filtering (VWF) technika pontosságával.

2. A CBH meghatározására automatizált és könnyen optimalizálható eszköz kifejlesztése (*treecbh*), amely a 3D-alapú egyesfa izoláló algoritmus (*treeiso*) által szegmentált (Xi and Hopkinson, 2022) egyedi fa pontfelhő (ITD) adatait dolgozza be. A *treecbh* hatékonyságának több közép-európai erdőben való tesztelése, erdőleltározási adatokkal összehasonlítva.
3. A fejlesztési fázisban az optimális pontsűrűség elemzése: milyen pontsűrűség reprezentálja a faalakot vagyis a bemeneti fa pontfelhő törzsét és az ehhez tartozó alsó ágakat.
4. A diszkrét Morse elmélet implementálása erdészeti célú felhasználásra, ennek keretében a fák törzsének felismerésére való módszer kidolgozása és R csomagba való implementálása.

ANYAG és MÓDSZER

Az első és a második témakör három erdős helyszínen adatai alapján készült: Hardtwald (Karlsruhe), Bretten (Baden-Württemberg, Németország) és a Nagyerdő (Debrecen, Hajdú-Bihar, Magyarország). A német erdők közé tartoznak a KA09, a KA10 (Karlsruhe) és a BR01, a BR05 (Bretten) jelű erdők (1. ábra), amelyeket erdei fenyő, Douglas fenyő, valamint kocsányos tölgy, vörös tölgy, kocsánytalan tölgy, bükk és gyertyán jellemez (Weiser et al., 2022). Ezek kezelt, többszintes elegyes erdők, sűrű koronával.



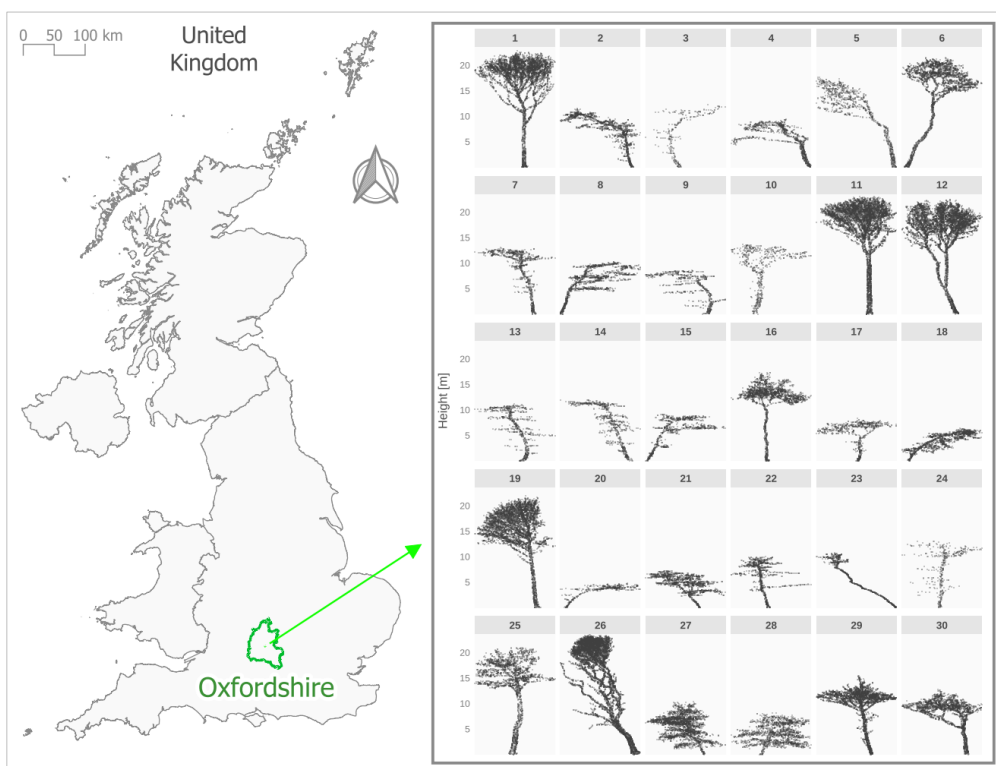
1. ábra. A négy német erdőterület elhelyezkedése (balra) a Baden-Württemberg szövetségi államban, valamint a Nagyerdő A és B területe (jobbra) Hajdú-Bihar megyében.

A debreceni Nagyerdőben két területen (A és B) dolgoztam (1. ábra), melyek feketefenyő, erdeifenyő, nyugati ostorfa, közönséges tölgy, fehér nyár és fekete dió fajok keverékéből állnak. Az A erdő szerkezete egyszintű, s inkább lombhullató fajokat foglal magába, a B-t roppant sűrű és többszintű erdőszerkezet jellemzi.

A LiDAR adatokat különböző szenzorokkal gyűjtötték a német és a magyar helyszíneken. A német erdőket 2019. július 5-én RIEGL VQ-780i szenzorral, míg a debreceni Nagyerdőt 2020. május 22-én és 2023. március 3-án RIEGL VQ-780ii szenzorral szkennelték. A pontsűrűség jelentősen különbözött a helyszínek között, a német adatok 40 és 103 pont/m², míg az első magyar adatok 2–10 pont/m² közötti pontsűrűséget kínáltak. A második, többszörös nagyerdei szkennelés átlagosan 185 pont/m² pontsűrűséget eredményezett. Mind Bretten és Karlsruhe erdeiben, valamint a Nagyerdő B erdejében 30 manuális fa szegmenst rajzoltam a GTR-alapú fatető- detektálási algoritmus által meghatározott korona csúcs koordináták (TREETOPS csomag) köré. Majd az ALS pontfelhőből kijelöltem az egyéni fa pontokat a

szegmensek segítségével. Ezt a folyamatot vizuálisan ellenőriztem, s így sikerült a kivont fapontfelhők pontosságát biztosítanom. Ezeket a fapontfelhőket a *treecbh* bemeneteként (input) használtam.

A TLS adatokat a Wytham Woods erdejében, Oxfordshireben, az Egyesült Királyságban gyűjtötték össze (Calders et al., 2022). Harminc fát véletlenszerűen választottam ki (2. ábra), és a pontfelhőiket hat pontsűrűségi kategóriába (20, 53, 111, 156, 205, és 253 pont/m²) osztályoztam. Ezt az adatot a *treecbh* pontsűrűség érzékenységét vizsgáló elemzésben a *treecbh* 'CBH-detect only' módjának alkalmazásával használtam (Diószegi et al., 2024).



2. ábra. A TLS erdő helyszíne, Wytham Woods Oxfordshireben és a harminc véletlenszerűen kiválasztott fa 2D-ben megjelenítve.

A német és magyar ALS-pontfelhők adatfeldolgozása hasonló munkafolyamatot követett. A LiDAR-adatokat talaj- és felszíni pontokra osztályoztam a cloth simulation filtering (CSF) segítségével (Zhang et al., 2016), majd a CHM-t egy pit-free algoritmust használva vontam ki a két osztályozott pontfelhőből. Pixelkép (CHM) simítására és esetleges zaj eltávolítására Gauss szűrőt alkalmaztam. A TLS-adatok esetében a

fapontfelhők pontmagasságát a talajszintnek megfelelően lenulláztam, s a *treecbh* pontsűrűség érzékenységet vizsgáló elemzésben használtam.

Az első témakörben a GTR-t (TREETOPS) hasonlítottam össze a LM kombinált VWF technikával (lidR csomag). A VWF ablakméretet pedig egy általam kidolgozott fmagasság specifikus egyenlet alkalmazásával tettem dinamikussá (Dioszegi et al., 2023). Az egyéni korona csúcs felismerésének kiértékeléshez egy általam módosított összehasonlító algoritmust alkalmaztam, amivel az LM kombinált VWF-et a GTR-rel össze tudtam hasonlítani. A kiértékelés a következő metrikákat használta: matching rate (MR), extraction rate (ER), commission rate (CR), omission rate (OR), és a mean absolute error (MAE).

A második témakörben az azonosított CBH-kat a fent említett MR és MAE használatával hasonlítottam össze a referencia-adatokkal. A *treecbh* pontosságát a CBH-detektáló eszköz három opciója alapján értékeltem ki: faizoláció nélkül (*No treeiso*), alapértelmezett faizolálással (*Default treeiso*) és interaktív vizuális módosítással (*Visual mode*).

A diszkrét Morse, azaz a Forman gradiens (Forman, 1998) esetében, 12 tökéletesen szegmentált szomszédos fát választottam ki a Wytham Woods TLS-adatból, amit tesztadatkészletként használtam. Az Rcpp csomagot (Eddelbuettel et al., 2024) arra használtam, hogy integráljam az R felhasználhatóságát az önállóan megszerkesztett C++ szkriptekkel.

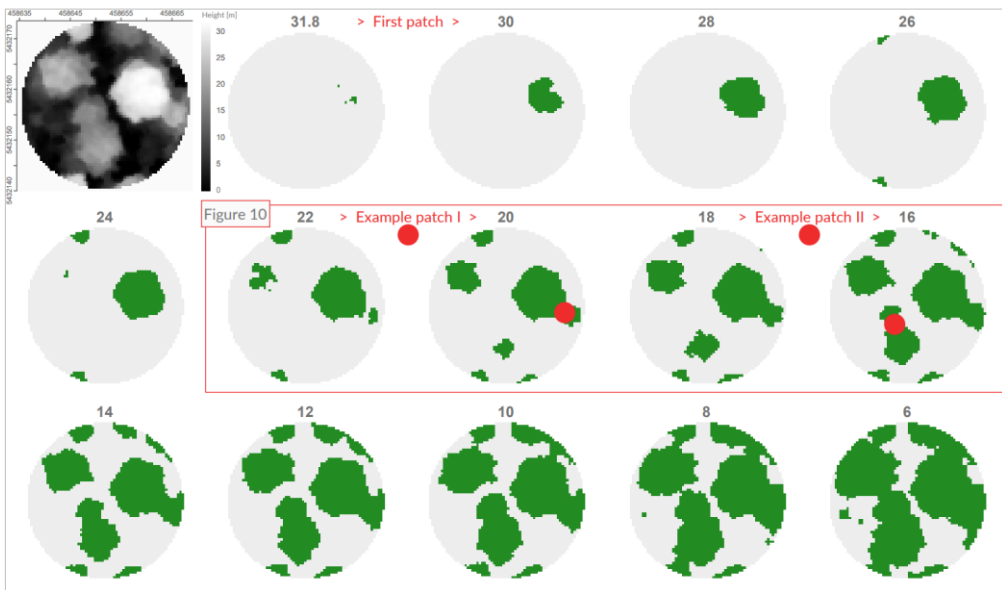
TUDOMÁNYOS EREDMÉNYEK

A tézisek megfelelnek a Bevezetésben meghatározott célkitűzéseknek, a két megjelent tudományos publikáción (Dioszegi et al., 2023; Dioszegi et al., 2024), valamint a diszkrét Morse-alapú fatörzs-észlelésre kidolgozott módszeren alapulnak.

- 1. Kidolgoztam a CHM-alapú GTR algoritmus háromrétegű koncepciójának első lépését, amely a CHM lépcsőzetes vágását és a CHM rétegek tárolását automatizálta. Az új algoritmus pontossága meghaladta a széles körben használt VWF módszert alkalmazó LM-detektáló pontosságát.**

A GTR-algoritmus egy vízszintes síkot használ, hogy felülről lefelé függőlegesen szeletelje a CHM-t raszterképekre, ahol a nem-

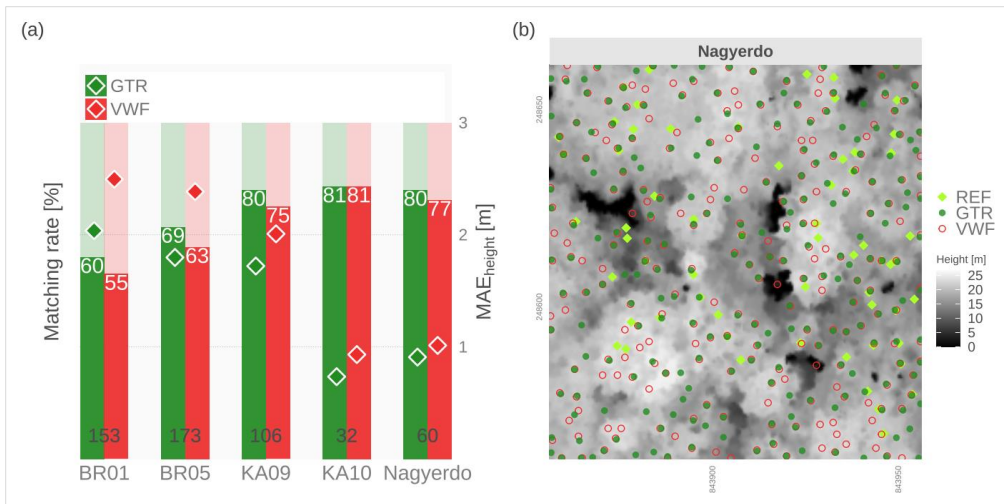
adatmentes pixeleket 1 értékkel látja el (3. ábra). A horizontális raszterrétegek tömörített formátumban vannak tárolva. A függőleges vágási távolság, amelyet magasságnövekedésnek neveztem el, 0,2 m-re állítottam be. Következésképpen minden raszter a CHM-értékeket (1) egy meghatározott magasságban képviseli, a magassági információ (Z) pedig a megfelelő raszterréteg nevében van tárolva a tömörítésben. A növekedési folyamat során a növekedés egyes pixeljei keresztezik egymást, és egy bizonyos magasságban közös új foltot (píxelegységet) képeznek. A példában az első új folt (angolul patch, azaz a kereszteződés) a 31,8 m és 30,0 m magasság között növekedő részek között történik (3. ábra, First patch). A háromrétegű koncepció második lépését két kereszteződés példa (Example patch I és II) szemlélteti a publikáció következő ábráján.



3. ábra. Kör alakú CHM példa, pixelmérete 0,5 m, csökkenő sorrendben megjelenítve, 31,8 m (maximális magasság) és 6 m között. A csökkenési intervallum 2 m. A bal felső sorban a kezdeti CHM van ábrázolva, a többinél a zöld pixel 1 értéket, a szürke pixel pedig az adatmentességet jelent. A két példa folt helyét piros körök jelzik.

Megállapítottam, hogy az GTR-alapú TREETOPS MR-je átlagosan 3,8%-kal meghaladta a VWF-módszert alkalmazó ML

pontosságát az öt vizsgált erdőben (4. ábra). Az MAE átlagosan 0,34 m-rel alacsonyabb volt a GTR esetében.

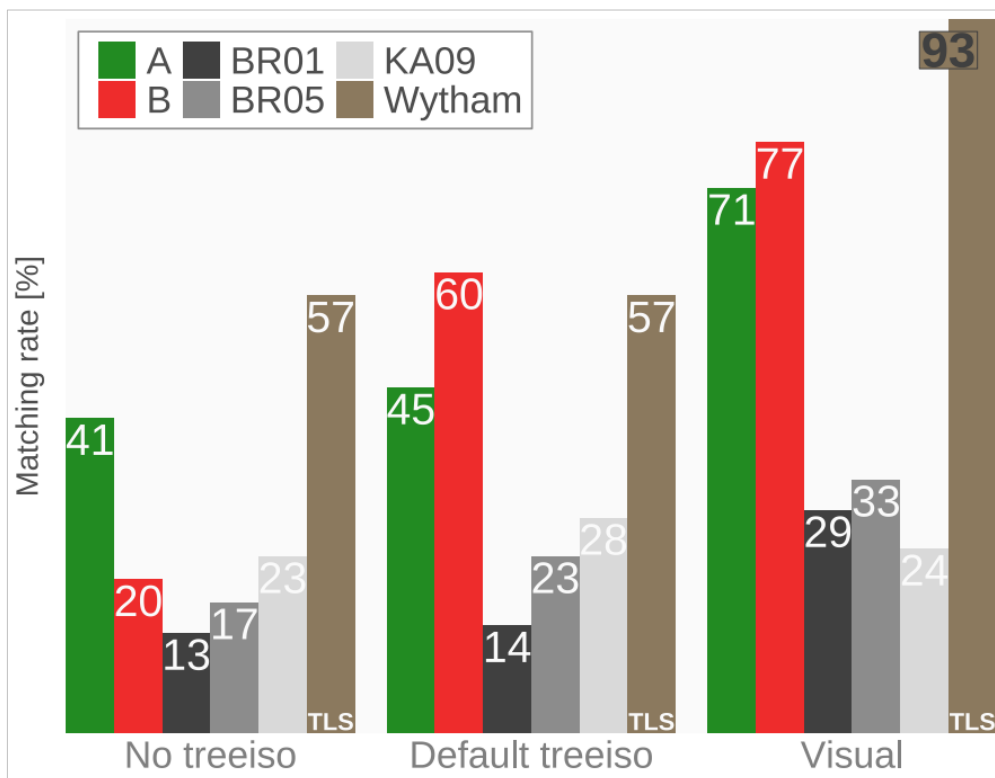


4. ábra. A vizsgált erdőterületekre és a kettős módszerre vonatkozó megfelelési arány (matching rate), MAE, valamint a referencia és detektált korona csúcsok. (a) gyémánt alakú jelek a MAE értékeket jelzik, a sávokon feltüntetett szürke számok az egyes erdőterületek referenciafa számát, a fehér számok az egyes erdőkre vonatkozó MAE hibaarányokat mutatják a következő módszerektől függően: GTR, Growing Tree Region és VWF, Variable Window Filtering. (b) a 60 referencia (REF) fa, valamint a GTR kivont korona csúcsok és a Local Maxima kombinált VWF-ből származó korona csúcsok térbeli elhelyezkedése.

2. A **CBH-detektálására** egy automatizáltan alkalmazható és könnyen optimalizálható eszközt (*treecbh*) fejlesztettem ki, amely szegmentált egyedi fapontfelhőket dolgoz fel (akár vizuális beállítással is). Számszerűsítettem a **CBH-detektor hatékonyságát lombos, illetve lombmentes szkennelt LiDAR** adatok használatával.

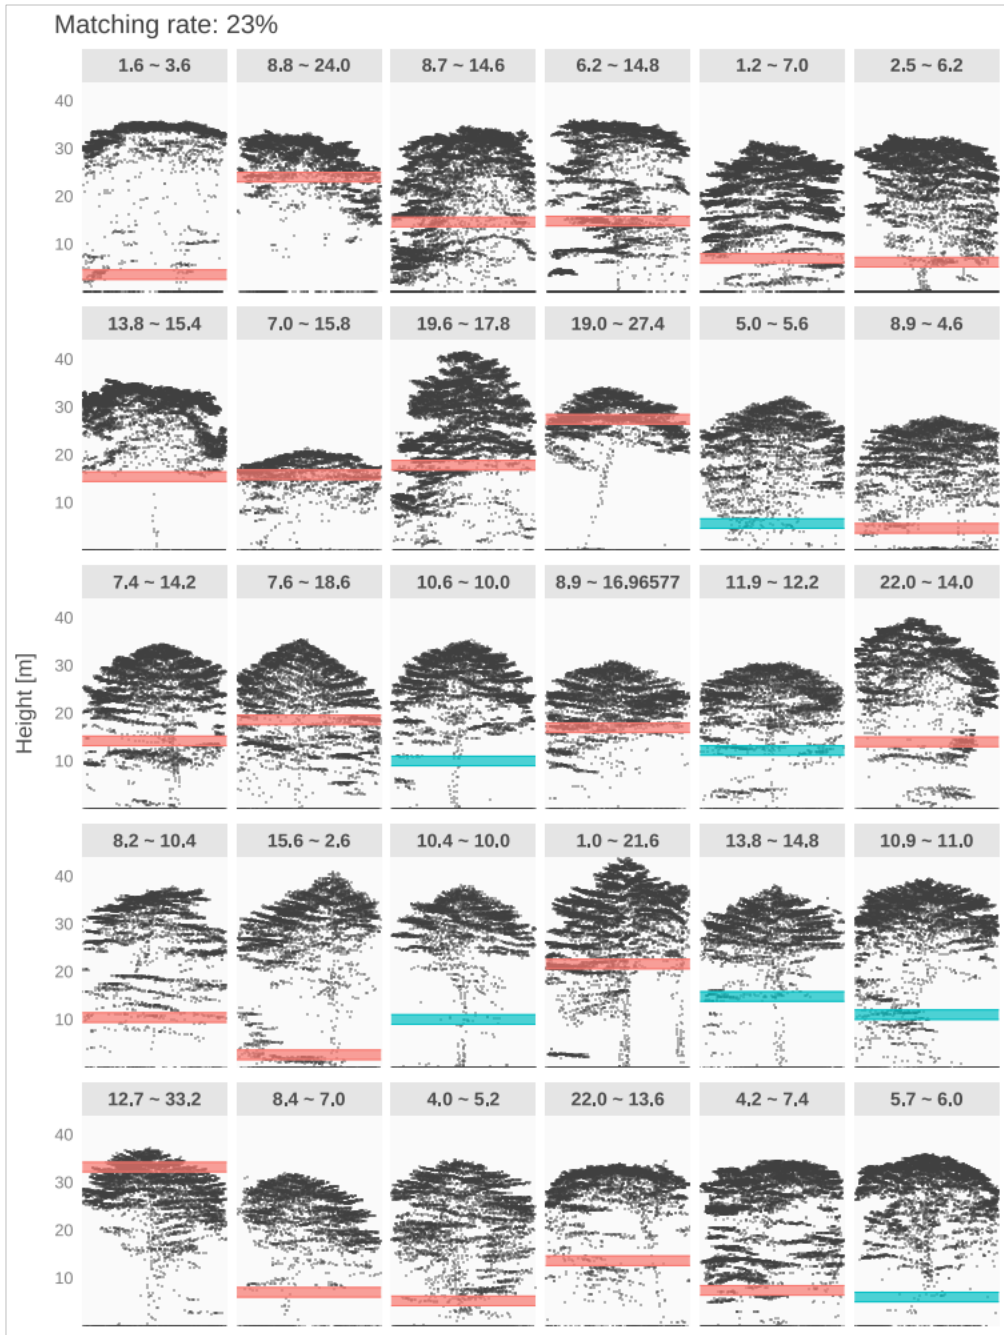
A *treecbh* teljesítményét öt erdőrészletben (három német: BR01, BR05 és K09, két debreceni: A és B teszteltem, valamint a *treecbh* detektált CBH eredményeit erdőleltározási adatokkal vettem össze. Megállapítottam, hogy az alapértelmezett paraméterű *treecbh* 45-60% megfelelési arányokat (matching rate) eredményezett a leaf-off ALS adatok esetében. Ezeket az arányokat

a vizuális CBH beállítás felülmúlta, amely 71-77% -os megfelelési arányt ért el (5. ábra).

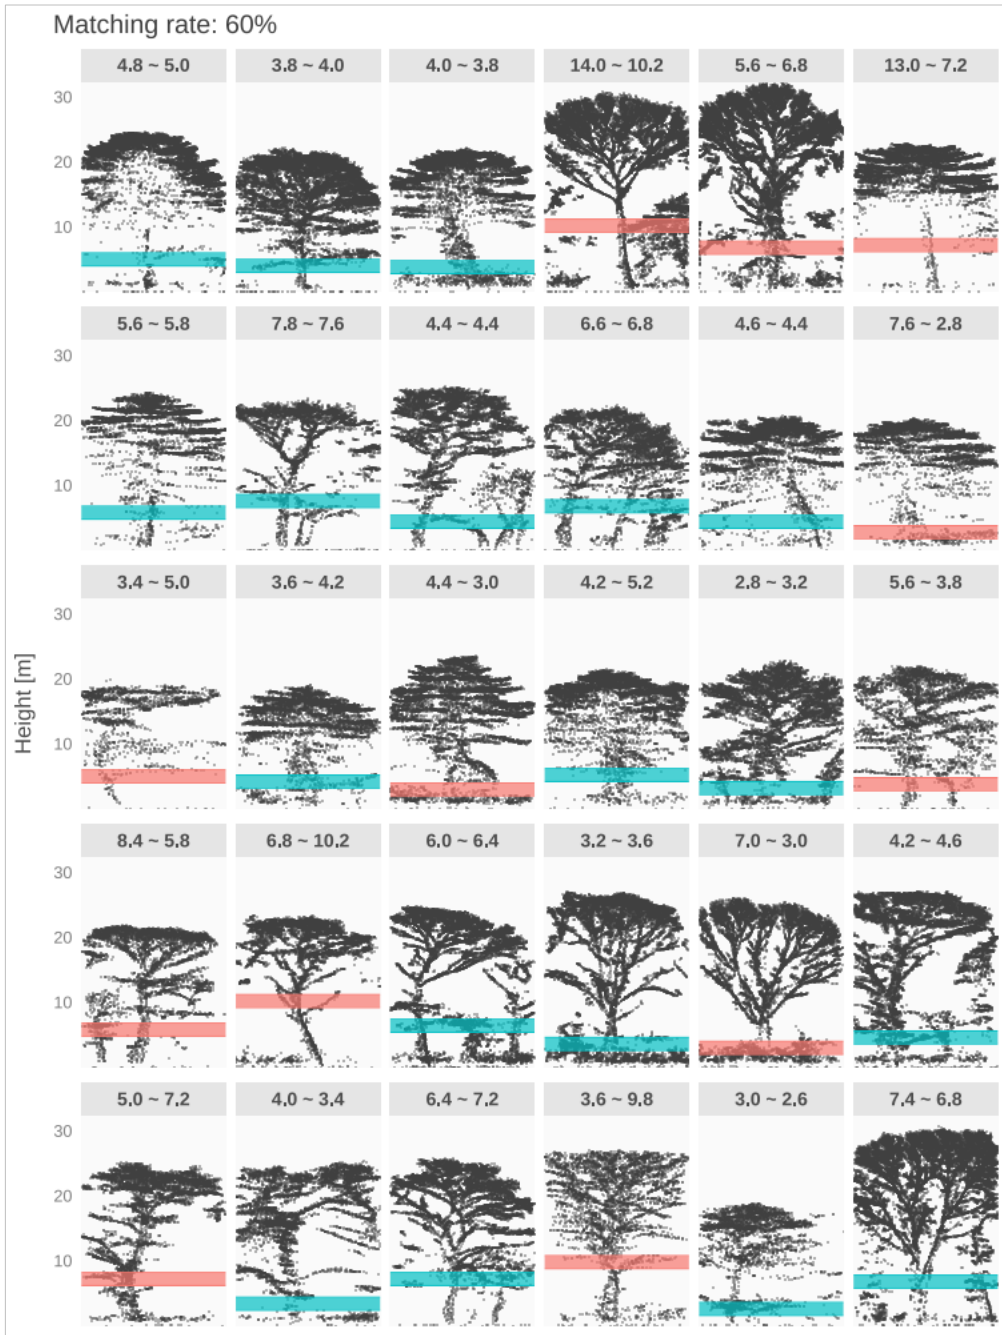


5. ábra. A Crown Base Height érzékelés eredményeinek összehasonlítása az ALS A, B, BR01, BR05, KA09, és a Wytham Woods TLS erdőkben a *treecbh* három működési módjától függően: deaktivált *treeiso* (No *treeiso*), alapértelmezett paraméterű *treeiso* (Default *treeiso*) és interaktív vizuális (*Visual*) CBH beállítási mód

Számszerűsítettem és megállapítottam, hogy lombos szkennelés rendszerint a fakorona tetejében eredményez magas pontsűrűséget (6. ábra), ugyanakkor az ezen farész alatti részeknél a pontsűrűség korlátozott. Egyértelmű, hogy lombos adatokat a CBH-detektor kevésbé tud kezelni, hiszen *treecbh* érzékelési technikája a fa törzsét és az ehhez tartozó alsó ágakat „ábrázoló” pontokra támaszkodik. Ezért elengedhetetlen, hogy a fakorona alatti faszerkezetet a bemeneti fapontfelhő megfelelően tudja letérképezni. Nem véletlen, hogy a *treecbh* a beviteli lombtalan ALS-adatokat részesítette előnyben (7. ábra).




6. ábra. A *trecbch* CBH érzékelési eredményei: a lombos ALS erdő BR05 megfelelési aránya (matching rate) *Default treeiso* módban. A vízszintes átlátszó piros csíkok (2 m széles) nem megfelelést jelentenek, míg az átlátható zöld csíkokat (2 m szélességű) a megfelelést jelzik. Minden panel címe magába foglalja a mért és a detektált CBH-kat, melyeket a ~ szimbólum választ el egymástól.



7. ábra. A *trecbh* CBH érzékelési eredményei: a lombtalan ALS erdő B megfelelési aránya (matching rate) *Default treeiso* módban. A vízszintes átlátszó piros csíkok (2 m széles) nem megfelelést jelentenek, míg az átlátható zöld csíkokat (2 m szélességű) a megfelelést jelzik. Minden panel címe magába foglalja a mért és a detektált CBH-kat, melyeket a ~ szimbólum választ el egymástól.

3. **Meghatároztam a *treecbh* optimális működése által megkövetelt beviteli pontfelhő minimum és optimum pontsűrűségét.**

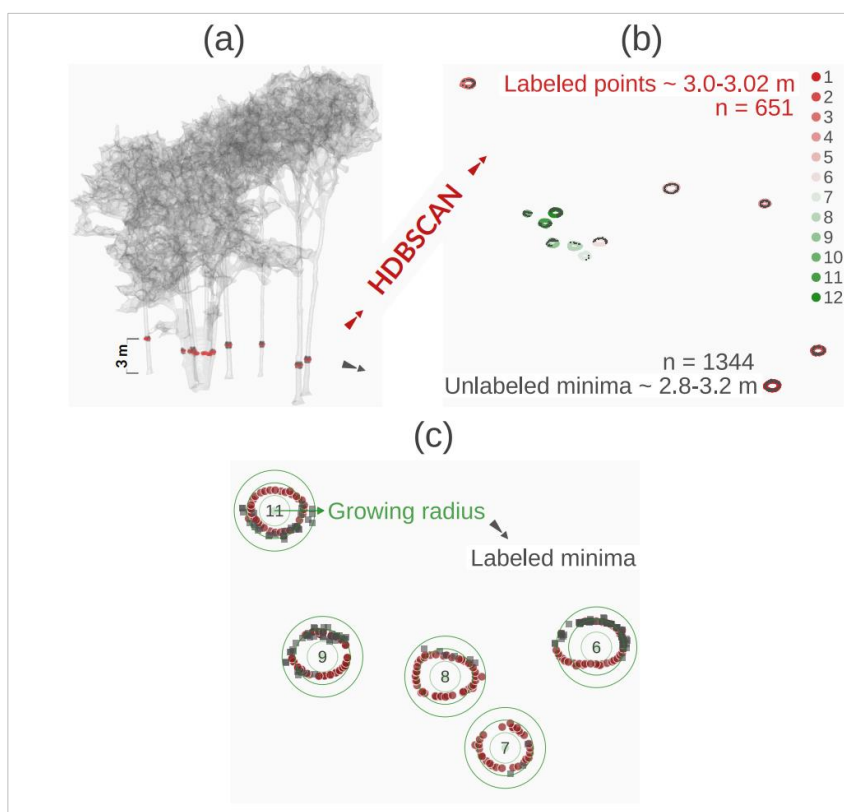
Kimutattam, hogy a *treecbh* teljesítménye a *No treesio* módban csak akkor javult, ha a pontsűrűség 20 pont/m² (minimum) és 111 pont/m² (optimum) között növekedett (8. ábra). A pontsűrűség-érzékenységi elemzést a Wytham Woods TLS adatkészletből származó homogenizáltan ritkított 12 szomszédos fafelhőt felhasználva hat pontsűrűségi osztály (20, 53, 111, 156, 205, és 253 pont/m²) összehasonlításával végeztem.



8. ábra. A CBH pontérzékenységi elemzésének eredményei (*No treesio* mód) a pontsűrűségi osztályok függvényében. A vízszintes fekete vonal a hivatkozási CBH-kat jelöli, a vízszintesen áthúzó piros szaggatott vonalak a függőleges zöld sűrűségi grafika által megjelenített eltérési sávok maximumait jelölik, amelyek a 30 bemeneti fapontfelhő eloszlását képviselik (zöld pontok). A vízszintes piros átlátszó sáv (2 m széles) jelzi a ± 1 m-es elfogadási területet. A panel címek magukba foglalják a pontsűrűség osztályát, valamint a ~ szimbólummal elkülönített az adott pontsűrűség osztályhoz tartozó megfelelési arányt (matching rate).

4. Kifejlesztettem a címke-továbbítás (Label-Passing) módszerét, amely a faazonosító címkéket a HDBSCAN által azonosított kezdeti fapontokról a nem jelölt (címkézetlen) kritikus pontokra továbbítja.

A Hierarchical Density-Based Spatial Clustering-et (HDBSCAN-t) az xy síkra alkalmaztam, a kezdeti és a kritikus pontfelhők egy olyan magasságába vágva (a pont felhő z attribútuma), ahol a fatörzsek egyértelműen el vannak különítve egymástól (9. ábra). Ezt a magasságot 3 méterre állítottam be figyelembe véve a két pontfelhőt (beviteli 12 tagú kezdeti fa- és a Morse komplexumos pontfelhő) (9a. ábra).



9. ábra. (a) Háromszögezett 12 tagú kezdeti fapont felhő, amelyen minima komplexek sötét szürke színben 2,8 és 3,2 m magasságban vannak, valamint a kezdeti pontfelhőből kivont piros pontok 3,0 és 3,02 m magasság között vannak. (b) A jelölés nélküli minima pontok és annak száma szürke színben, HDBSCAN-felismerés által faazonosítóval megjelölt pontok és annak száma piros színben, a jelölés az xy síkon vörös-zöld színpalettát követve a megjelölt fatörzseket színezi be. (c) A b)-ből származó 6,7,8,9 és 11-gyel címkézett fák, melyek a sugárnövekedési technikát alkalmazó címke-továbbítást mutatják be.

A kezdeti pontfelhőből származó pontokat (3,00 és 3,02 méter közötti magasságban) a HDBSCAN jelölte meg faazonosítóval. Azonban a 2,8 és 3,2 m közötti kritikus pontok nem jelöltek (9b. ábra).

A címke-továbbítás módszer egy fokozatos sugárnövekedési technikát alkalmaz, ami koncentrikus köröket generál. A koncentrikus kör sugara meghatározott (illetve meghatározhatóan állandó), vagyis a sugár a kezdeti pontfelhő (3,00 és 3,02 méter közötti magasságú) pontjainak kétdimenzionált középpontjából a koncentrikus kör sokszorosával egyenes arányban sokszorozódik. Egy koncentrikus körben lévő jelölt kezdeti fa pontok faazonosítója az ugyanabban a koncentrikus körben megtalálható jelöletlen kritikus pontokra átíródik. A koncentrikus körök növekedése automatikusan leáll, ha a következő koncentrikus kör nem tartalmaz új jelölt vagy jelöletlen pontot (9c. ábra).

HIVATKOZOTT IRODALOM

- Beaudoin, A., Bernier, P., Villemaire, P., Guindon, L., Guo, X., 2017. Tracking forest attributes across Canada between 2001 and 2011 using a kNN mapping approach applied to MODIS imagery. *Can. J. For. Res.* 48. <https://doi.org/10.1139/cjfr-2017-0184>
- Blackard, J.A., Finco, M.V., Helmer, E.H., Holden, G.R., Hoppus, M.L., Jacobs, D.M., Lister, A.J., Moisen, G.G., Nelson, M.D., Riemann, R., Ruefenacht, B., Salajanu, D., Weyermann, D.L., Winterberger, K.C., Brandeis, T.J., Ph.D., Czaplewski, R.L., McRoberts, R.E., Patterson, P.L., Tymcio, R.P., 2008. Mapping U.S. forest biomass using nationwide forest inventory data and moderate resolution information. *Remote Sens. Environ.* 112 1658-1677 12, 1658-1677. <https://doi.org/10.1016/j.rse.2007.08.021>
- Bouvier, M., Durrieu, S., Fournier, R.A., Renaud, J.-P., 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sens. Environ.* 156, 322-334. <https://doi.org/10.1016/j.rse.2014.10.004>
- Calders, K., Verbeeck, H., Burt, A., Origo, N., Nightingale, J., Malhi, Y., Wilkes, P., Raunonen, P., Bunce, R.G.H., Disney, M., 2022. Laser scanning reveals potential underestimation of biomass carbon in temperate

- forest. *Ecol. Solut. Evid.* 3, e12197. <https://doi.org/10.1002/2688-8319.12197>
- Dioszegi, G., Molnar, V.E., Nagy, L.A., Enyedi, P., Szabo, S., 2023. A novel algorithm using the growing tree region and the three-layer concept for individual treetop detection with aerial laser scanned data. under review.
- Diószegi, G., Molnár, V.É., Nagy, L.A., Enyedi, P., Török, P., Szabó, S., 2024. Testing treecbh in Central European forests: an R package for crown base height detection using high-resolution aerial laser-scanned data. *For. Int. J. For. Res.* cpae044. <https://doi.org/10.1093/forestry/cpae044>
- Eddelbuettel, D., Francois, R., Allaire, J.J., Ushey, K., Kou, Q., Russell, N., Ucar, I., Chambers, D.B. and J., 2024. Rcpp: Seamless R and C++ Integration.
- Forman, R., 1998. Morse Theory for Cell Complexes. *Adv. Math.* 134, 90–145. <https://doi.org/10.1006/aima.1997.1650>
- Hantsch, L., Bien, S., Radatz, S., Braun, U., Auge, H., Bruelheide, H., 2014. Tree diversity and the role of non-host neighbour tree species in reducing fungal pathogen infestation. *J. Ecol.* 102, 1673–1687. <https://doi.org/10.1111/1365-2745.12317>
- Hardenbol, A.A., Korhonen, L., Kukkonen, M., Maltamo, M., 2023. Detection of standing retention trees in boreal forests with airborne laser scanning point clouds and multispectral imagery. *Methods Ecol. Evol.* 14, 1610–1622. <https://doi.org/10.1111/2041-210X.13995>
- Hyyppä, J., Hyyppä, H., Leckie, D., Gougeon, F., Yu, X., Maltamo, M., 2008. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *Int. J. Remote Sens. - INT J REMOTE SENS* 29, 1339–1366. <https://doi.org/10.1080/01431160701736489>
- Kelly, M., Su, Y., Guo, Q., Luo, L., Zhai, Q., ma, Q., 2018. A simple method for direct crown base height estimation of individual trees using airborne LiDAR data. *Opt. Express* 26. <https://doi.org/10.1364/OE.26.00A562>
- Koch, B., Heyder, U., Weinacker, H., 2006. Detection of Individual Tree Crowns in Airborne LiDAR Data. *Photogramm. Eng. Remote Sens.* 72, 357–363. <https://doi.org/10.14358/PERS.72.4.357>
- Lecigne, B., Delagrangé, S., Messier, C., 2018. Exploring trees in three dimensions: VoxR, a novel voxel-based R package dedicated to analysing the complex arrangement of tree crowns. *Ann. Bot.* 121, 589–601. <https://doi.org/10.1093/aob/mcx095>
- Luo, L., Zhai, Q., Su, Y., Ma, Q., Kelly, M., Guo, Q., 2018. Simple method for direct crown base height estimation of individual conifer trees using airborne LiDAR data. *Opt. Express* 26, A562–A578. <https://doi.org/10.1364/OE.26.00A562>
- Parkitna, K., Krok, G., Miścicki, S., Ukalski, K., Lisańczuk, M., Mitelsztedt, K., Magnussen, S., Markiewicz, A., Stereńczak, K., 2021. Modelling growing stock volume of forest stands with various ALS area-based

- approaches. *For. Int. J. For. Res.* 94, 630–650. <https://doi.org/10.1093/forestry/cpab011>
- Popescu, S., Wynne, R., Nelson, R., 2003. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Can. J. Remote Sens.* 29, 564–577. <https://doi.org/10.5589/m03-027>
- Seidel, D., Leuschner, C., Müller, A., Krause, B., 2011. Crown plasticity in mixed forests—Quantifying asymmetry as a measure of competition using terrestrial laser scanning. *For. Ecol. Manag.* 261, 2123–2132. <https://doi.org/10.1016/j.foreco.2011.03.008>
- Stefanidou, A., Gitas, I.Z., Korhonen, L., Stavrakoudis, D., Georgopoulos, N., 2020. LiDAR-Based Estimates of Canopy Base Height for a Dense Uneven-Aged Structured Forest. *Remote Sens.* 12, 1565. <https://doi.org/10.3390/rs12101565>
- Terryn, L., Calders, K., Åkerblom, M., Bartholomeus, H., Disney, M., Levick, S., Origo, N., Raunonen, P., Verbeeck, H., 2023. Analysing individual 3D tree structure using the R package ITSMe. *Methods Ecol. Evol.* 14, 231–241. <https://doi.org/10.1111/2041-210X.14026>
- Tomppo, E., 2006. The Finnish National Forest Inventory. pp. 179–194. https://doi.org/10.1007/1-4020-4381-3_11
- Weiser, H., Schäfer, J., Winiwarter, L., Krašovec, N., Höfle, B., Fassnacht, F., 2022. Individual tree point clouds and tree measurements from multi-platform laser scanning in German forests. *Earth Syst. Sci. Data* 14, 2989–3012. <https://doi.org/10.5194/essd-14-2989-2022>
- White, J.C., Coops, N.C., Wulder, M.A., Vastaranta, M., Hilker, T., Tompalski, P., 2016. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Can. J. Remote Sens.* 42, 619–641. <https://doi.org/10.1080/07038992.2016.1207484>
- Wulder, M.A., Bater, C.W., Coops, N.C., Hilker, T., White, J.C., 2008. The role of LiDAR in sustainable forest management. *For. Chron.* 84, 807–826. <https://doi.org/10.5558/tfc84807-6>
- Xi, Z., Hopkinson, C., 2022. 3D Graph-Based Individual-Tree Isolation (Treeiso) from Terrestrial Laser Scanning Point Clouds. *Remote Sens.* 14, 6116. <https://doi.org/10.3390/rs14236116>
- Xi, Z., Hopkinson, C., 2021. Detecting Individual-Tree Crown Regions from Terrestrial Laser Scans with an Anchor-Free Deep Learning Model. *Can. J. Remote Sens.* 47, 228–242. <https://doi.org/10.1080/07038992.2020.1861541>
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G., 2016. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sens.* 8, 501. <https://doi.org/10.3390/rs8060501>
- Zianis, D., Muukkonen, P., Mäkipää, R., Mencuccini, M., 2005. Biomass and stem volume equations of tree species in Europe. *Silva Fenn.* 4. <https://doi.org/10.14214/sf.sfm4>



Nyilvántartási szám: DEENK/554/2024.PL
Tárgy: PhD Publikációs Lista

Jelölt: Diószegi Gergő
Doktori Iskola: Földtudományok Doktori Iskola
MTMT azonosító: 10097933

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű tudományos közlemények külföldi folyóiratban (2)

- Diószegi, G.**, Molnár, V. É., Nagy, L. A., Enyedi, P., Török, P., Szabó, S.: A new method for individual treetop detection with low-resolution aerial laser scanned data.
Modeling Earth Systems and Environment. 10, 5225-5240, 2024. ISSN: 2363-6203.
DOI: <http://dx.doi.org/10.1007/s40808-024-02060-w>
IF: 2.7 (2023)
- Diószegi, G.**, Molnár, V. É., Nagy, L. A., Enyedi, P., Török, P., Szabó, S.: Testing 'treecbh' in Central European forests: an R package for crown base height detection using high-resolution aerial laser-scanned data.
Forestry. [Epub ahead of print] (-), 1-15, 2024. ISSN: 0015-752X.
DOI: <http://dx.doi.org/10.1093/forestry/cpae044>
IF: 3 (2023)

A közlő folyóiratok összesített impakt faktora: 5,7

A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre): 5,7

A DEENK a Jelölt által az iDEa Tudóstérbe feltöltött adatok bibliográfiai és tudományometriai ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2024.11.07.



Short thesis for the degree of doctor of philosophy (PhD)

**Advancements in Individual Treetop, Tree stem and
Crown Base Height Location Using Laser Scanning
Data of Various Resolutions**

by Gergő Diószegi

Supervisor: Dr. Szilárd Szabó



UNIVERSITY OF DEBRECEN
Doctoral School of Earth Sciences

Debrecen, 2025

INTRODUCTION and OBJECTIVES

Describing the status of forest ecosystems is crucial for effective management strategies. Detailed tree inventories, which include data on species composition, height, canopy closure, and biomass, provide the foundation for these assessments. Traditionally, such inventories have relied on sparse or systematic plot-level sampling to calibrate regional and national analyses (Beaudoin et al., 2017; Blackard et al., 2008; Tomppo, 2006). However, over the past two decades, Light Detection and Ranging (LiDAR), particularly in combination with airborne laser scanning (ALS), has emerged as a transformative tool for forest managers and researchers (Hyypä et al., 2008; White et al., 2016). The rapid development of laser scanning technologies is driving the shift from labour-intensive, costly field inventories to more efficient, LiDAR-based forest inventories. LiDAR data can enhance our understanding of forest structure and ecology (Koch et al., 2006; Wulder et al., 2008).

Forest inventory attributes are typically modelled using LiDAR data through two main approaches: the area-based approach (Bouvier et al., 2015; Parkitna et al., 2021) and the individual tree-based approach, which accounts for finer-scale variability (Hardenbol et al., 2023; Popescu et al., 2003). The individual tree-based approach is particularly important for quantifying vegetation carbon distribution, as well as for understanding tree health and competition dynamics (Zianis et al., 2005). Individual trees can host insects and pathogens, and early detection of stress indicators like mortality and dieback can support adaptive forest management (Hantsch et al., 2014). Tree-level data is also essential for assessing crown plasticity, an indicator of inter- and intraspecific competition (Seidel et al., 2011). High accuracy in individual tree detection (ITD) and segmentation is crucial for capturing robust metrics that describe the complexity of trees and forests. Recent years have seen significant advances in terrestrial laser scanning (TLS) research (Lecigne et al., 2018; Terryn et al., 2023; Xi and Hopkinson, 2022). Advances in ALS, including increased point density and enhanced sensor capabilities, now allow the application of TLS-derived metrics to ALS data, enabling high-resolution 3D tree structural analyses. Accurate crown detection and isolation are particularly important, as the tree canopy - defined as the part of the tree above the Crown Base Height

(CBH) - is a key focus in traditional forest inventory techniques (Kelly et al., 2018; Luo et al., 2018; Stefanidou et al., 2020).

This dissertation presents three interrelated studies. The first study introduces an Individual Tree Detection (ITD) method using a Canopy Height Model (CHM) derived from low-resolution LiDAR data. The second study describes a Crown Base Height (CBH) detection tool, which utilizes high-resolution point cloud data and builds on the ITD tool. These studies are connected, as the ITD tool is a prerequisite for the CBH detector.

In the first study, a novel ITD algorithm was developed based on the Growing Tree Region (GTR) concept, specifically designed for Central-European mixed forests. Using LiDAR-derived CHMs, the algorithm enables accurate detection of treetops across various canopy densities and species compositions. This method was implemented in the open-source TREETOPS R package, offering a flexible and robust tool for forest analysis.

Building on this foundation, the second study introduces *treecbh*, a tool designed to estimate Crown Base Height (CBH) using high-resolution aerial laser-scanned data. Applicable to forests with pre-segmented individual trees, *treecbh* leverages the GTR-based ITD algorithm developed in the first study. It further employs the hierarchical graph clustering software *treeiso* (Xi and Hopkinson, 2022) to detect tree trunks and the first leaved branches. The key innovation of *treecbh* lies in its vertical cross-sectional K-means clustering-based 2D kernel method, which enhances the precision of CBH detection.

Finally, the third study explores an experimental approach using Discrete Morse Theory for isolating tree stems within very high-resolution Terrestrial Laser Scanning (TLS) data. This method offers a promising new direction for improving the accuracy of tree isolation in complex forest environments.

I have defined the following objectives:

1. To develop a simple yet flexible CHM-based Growing Tree Region (GTR) method for treetop detection. To integrate this method into an open-source tool that seamlessly fits within the coding framework of the *lidR* package in the R computational

environment (TREETOPS package). To test the proposed algorithm in mixed forests with various compositions and canopy densities, and to compare its performance with the most robust and freely available treetop detection method that employs Local Maxima search using Variable Window Filtering technique.

2. To provide an automated, adaptable, and easily optimizable tool for detecting CBH (*treecbh*) using point cloud data of already segmented individual trees. To validate the effectiveness of *treecbh* in detecting CBH using leaf-off and leaf-on ALS data against field-measured data obtained from central European forests with diverse compositions.
3. To determine the optimal point density necessary to accurately represent the structure of the input tree point cloud, particularly focusing on the tree trunk and lower branches.
4. To implement the fundamental concepts of discrete Morse theory to an application in forestry as an R package. To create a framework using existing algorithms for detecting tree stems.

MATERIALS and METHODS

The first two were conducted in three forests: Hardtwald (Karlsruhe), Bretten (both in Baden-Württemberg, Germany), and Nagyerdő (Debrecen, Hajdú-Bihar, Hungary). The German forests include plots KA09, KA10 (Karlsruhe), and BR01, BR05 (Bretten) (Fig. 1), characterized by a mix of species such as Norway spruce, Scots pine, Douglas fir, common oak, red oak, sessile oak, European beech, and European hornbeam (Weiser et al., 2022).

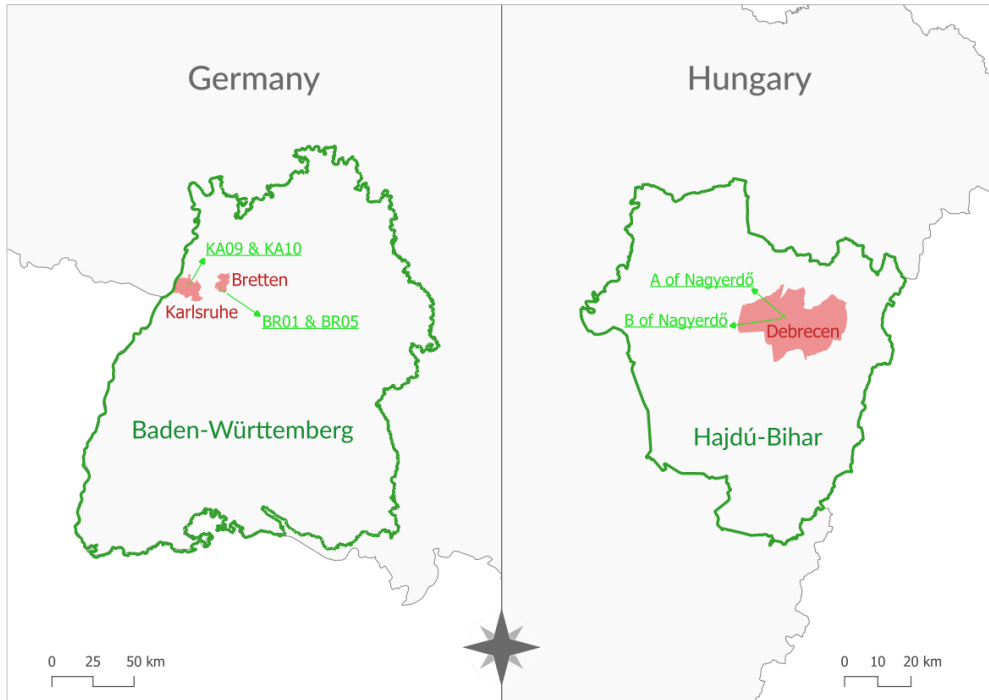


Figure 1. The four German forest sites (links panel) in the federal state of Baden-Württemberg, and the sites of Nagyerdő A and B (right panel) of Hajdú-Bihar county.

These forests are managed and exhibit diverse species compositions, dense canopy covers, and multiple layers. The Hungarian Nagyerdő forest has sites A and B (Fig. 1), featuring a mix of species like Austrian pine, Scots pine, common hackberry, common oak, silver poplar, and black walnut, with site A having a more deciduous-dominant, single-layer canopy structure. B is characterised by very dense canopy and multiple layers.

LiDAR data were collected using different sensors for the German and Hungarian study sites. The German forests were scanned with the RIEGL VQ-780i sensor on 5 July 2019, while the Hungarian Nagyerdő forest was scanned with the RIEGL VQ-780ii sensor on 22 May 2020 and on 03 March 2023. The point density differed significantly between the sites, with the German data offering a resolution between 40 and 103 pts/m² and the first Hungarian data a lower resolution of 2–10 pts/m². The second multiple Hungarian scan resulted in an average resolution of 185 pts/m². For the Bretten, Karlsruhe, and one of the Debrecen sites, 30 tree segments were manually drawn from ALS-

derived vertical profiles after applying the Growing Tree Region-based treetop detection algorithm (TREETOPS package). This process was aided by visual validation, ensuring the accuracy of extracted tree point clouds, which were used as input for the CBH detection tool.

The TLS data were collected from Wytham Woods, Oxfordshire, UK, and is managed by Oxford University, focusing on European ash, sycamore, and common hazel (Calders et al., 2022). Thirty trees were randomly selected (Fig. 2), and their point clouds were decimated into six point density classes (20, 53, 111, 156, 205, and 253 pts/m²) to analyse the sensitivity of the CBH detection tool to point density. This analysis was performed using the CBH-detect-only mode of the *treecbh* tool (Diószegi et al., 2024).

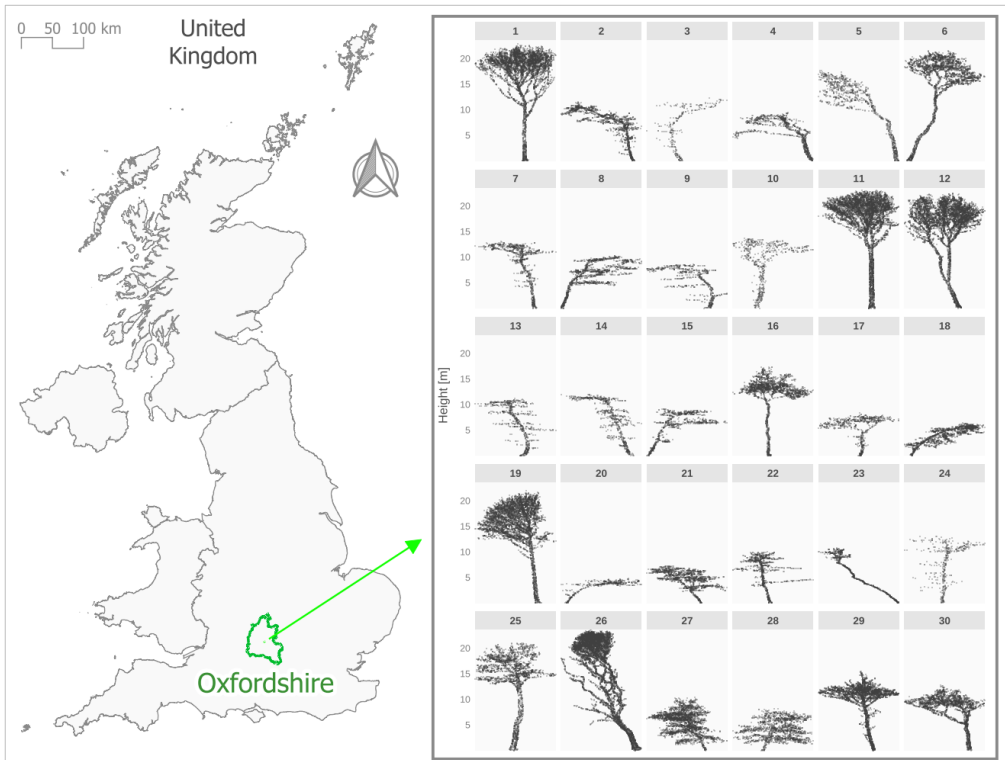


Figure 2. Location of the TLS plot, Wytham Woods in Oxfordshire and the thirty randomly selected trees displayed in 2D.

Data preprocessing for the German and Hungarian datasets followed a similar workflow. Raw LiDAR data were classified into ground and

surface points using cloth simulation filtering (CSF), and Canopy Height Models (CHMs) were derived using a pit-free algorithm. Gaussian filtering was applied for image smoothing and noise removal. For TLS data, point clouds were normalized and extracted for analysis using the *treecbh* tool, with a focus on point density sensitivity.

In the first study, the GTR method (TREETOPS) was compared with the Local Maxima (LM) and Variable Window Filtering (VWF) technique in the lidR package, with the VWF window size adjusted based on tree height using a study-specific equation (Dioszegi et al., 2023). The accuracy assessment for individual treetop detection involved a modified Matching Algorithm (MA) to compare LM with VWF against GTR, evaluating metrics such as matching rate, extraction rate, commission rate, omission rate, and mean absolute error (MAE) for tree height.

In the second study, the detected CBHs were compared with reference data using matching rate and MAE. The accuracy was evaluated across three options of *treecbh*: without tree isolation (*No treeiso*), with default tree isolation (*Default treeiso*), and using an interactive visual adjustment mode (*Visual mode*).

For Discrete Morse, i.e., the Forman gradient (Forman, 1998) implementation plus tree stem detection 12 perfectly isolated adjacent trees were selected from the Wytham Woods TLS data and used as test dataset. I utilized the Rcpp package (Eddelbuettel et al., 2024) to integrate R with self-written C++ scripts, optimizing C++ scripts for efficient performance processing and execution on a very low performance computer.

RESULTS

The theses align with the objectives set forth in the Introduction. These theses are brief excerpts from my two published scientific articles (Dioszegi et al., 2023; Diószegi et al., 2024), as well as from the research method developed for tree stem detection based on discrete Morse theory.

1. I have developed the first step of the three-layer concept of the CBH-based GTR algorithm. During the development, I used simple R syntax, raster images, and basic mathematical expressions. I compared the accuracy of the TREETOPS algorithm I developed with the detection accuracy of the widely used LM method that implements the VWF approach.

In Figure 3, the first step of the algorithm's three-layer concept: cutting and storing CHM, has been presented to the reader clearly and transparently.

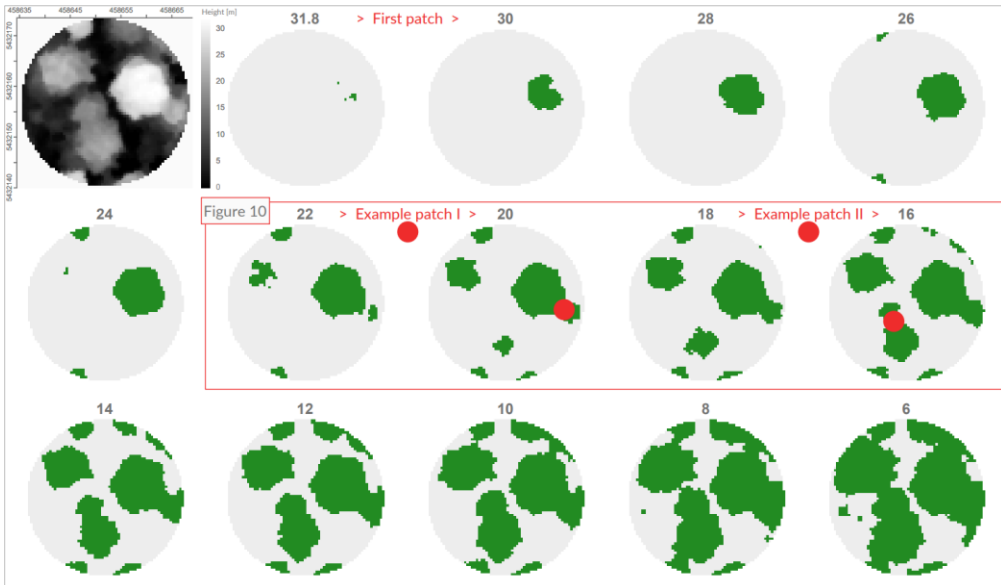


Figure 3. Circular example of a CHM with a pixel size of 0.5-0.5 m, displayed in decreasing order between 31.8 m (maximum height) and 6 m. The decrement interval is 2 m. In the top row on the left, the initial example CHM is depicted, with green representing value 1 and grey indicating no data. The locations of the two example patches are highlighted by filled red circles.

The GTR algorithm employs a horizontal plane to vertically slice the CHM from top to bottom into multiple horizontal raster layers, where non-no data values are labelled as 1 (Fig. 3). The files were stored in a stacked format. The vertical cutting distance, referred to as the height increment, is set at 0.2 m. Consequently, each raster represents the CHM values (1) at a specific height, with the height information (Z) stored in the filename of the corresponding raster file within the stack. During the tree-growing process, sections of growth intersect, forming

a new patch at a certain height. In our example, the first new patch (i.e., intersection) occurs between heights of 31.8 m and 30 m (Fig. 3, First patch).

I found that TREETOPS outperformed the widely used LM with VWF by an average of 3.8% matching rate across the five studied forests (Fig. 4). This was confirmed by an average MAE difference of 0.34 in favor of GTR.

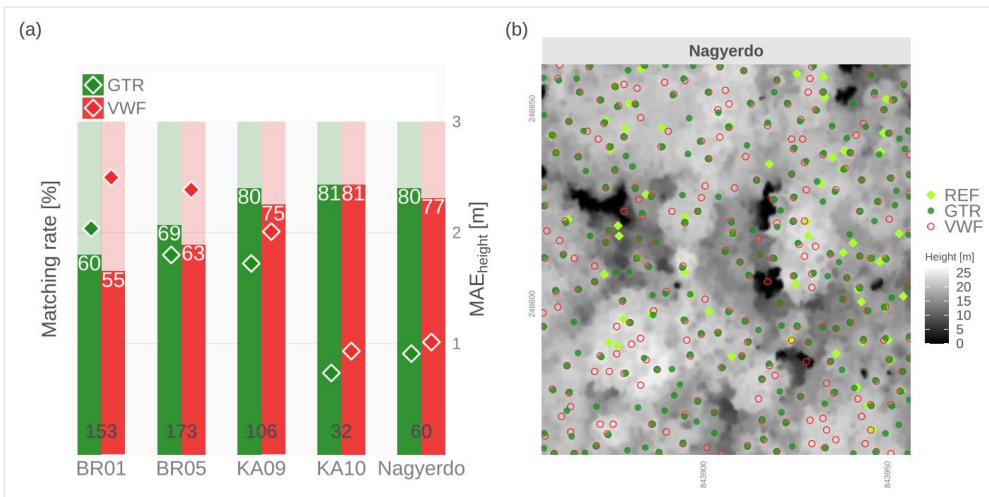


Figure 4. Matching rates concerning forest sites and the dual methods (a; diamonds indicate MAE values, grey numbers on bars represent the number of reference trees for each forest site, white numbers show the matching error rates for each forest depending on the methods: GTR, Growing Tree Region, and VWF, Variable Window Filtering). The spatial locations of the 60 reference (REF) trees, GTR-extracted treetops, and Local Maxima with VWF-extracted treetops of the Nagyerdó forest are shown in (b).

2. I developed an automated, applicable, and easily optimizable (with visual CBH settings) **tool** that processes segmented individual point clouds, which I named *treecbh*. I quantified **the efficiency of the CBH detector using LiDAR data scanned during the vegetation period and before the vegetation period.**

I tested the performance of *treecbh* in five forest sections (three German: BR01, BR05, and K09, two Debrecen: A and B), and compared the CBH results detected by *treecbh* with forest inventory data. I found that the default parameter *treeiso-treecbh*

resulted in matching rates of 45-60% for the leaf-off ALS data. These ratios were surpassed by the visual CBH setting, which achieved matching rates of 71-77% (Fig. 5).

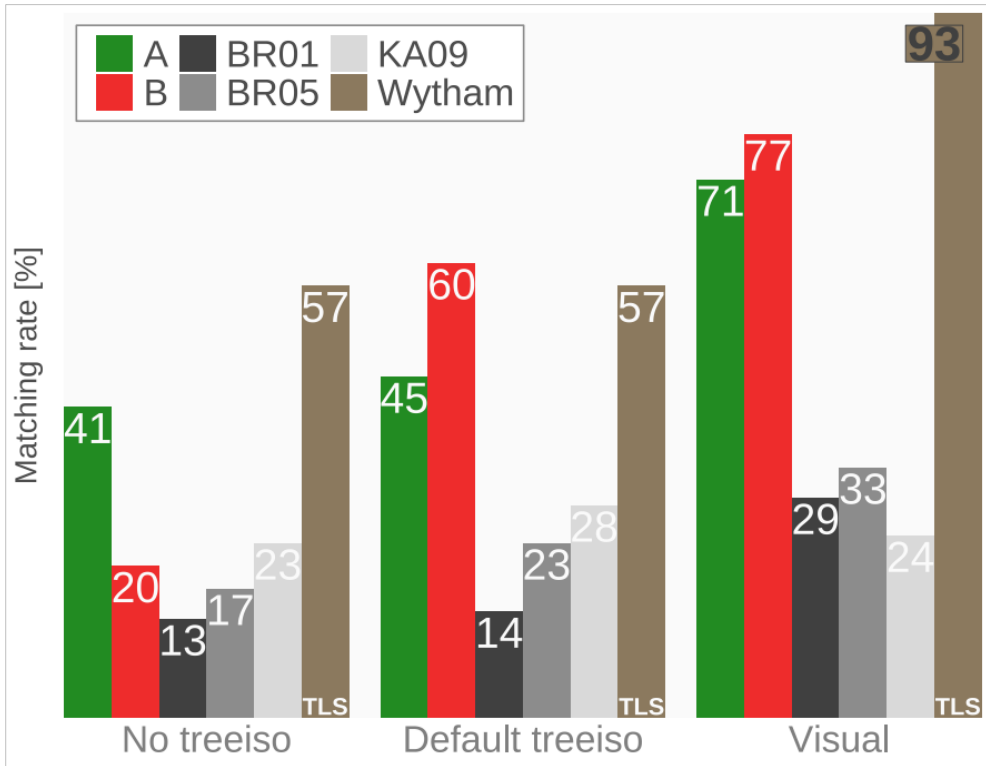


Figure 5. Comparison of Crown Base Height detection results from ALS sites A, B, BR01, BR05, KA09, and TLS site Wytham Woods across three operating modes of the *treecbh* tool: deactivated *treeiso* (*No treeiso*), default parameter *treeiso* (*Default treeiso*), and interactive visual (*Visual*) CBH adjustment mode.

Leaf-on scanning tends to detect high point density at the top of the tree canopy (Fig. 6), while the point density in the areas below this tree part is limited. It is clear that the CBH detector is less capable of handling leaf-on data, as the *treecbh* detection technique relies on points that represent the trunk of the tree and its lower branches. Therefore, it is essential that the tree canopy structure is adequately mapped under and within the tree canopy by the input point cloud. It is no coincidence that *treecbh* prefers leaf-off ALS data as input (Fig. 7).

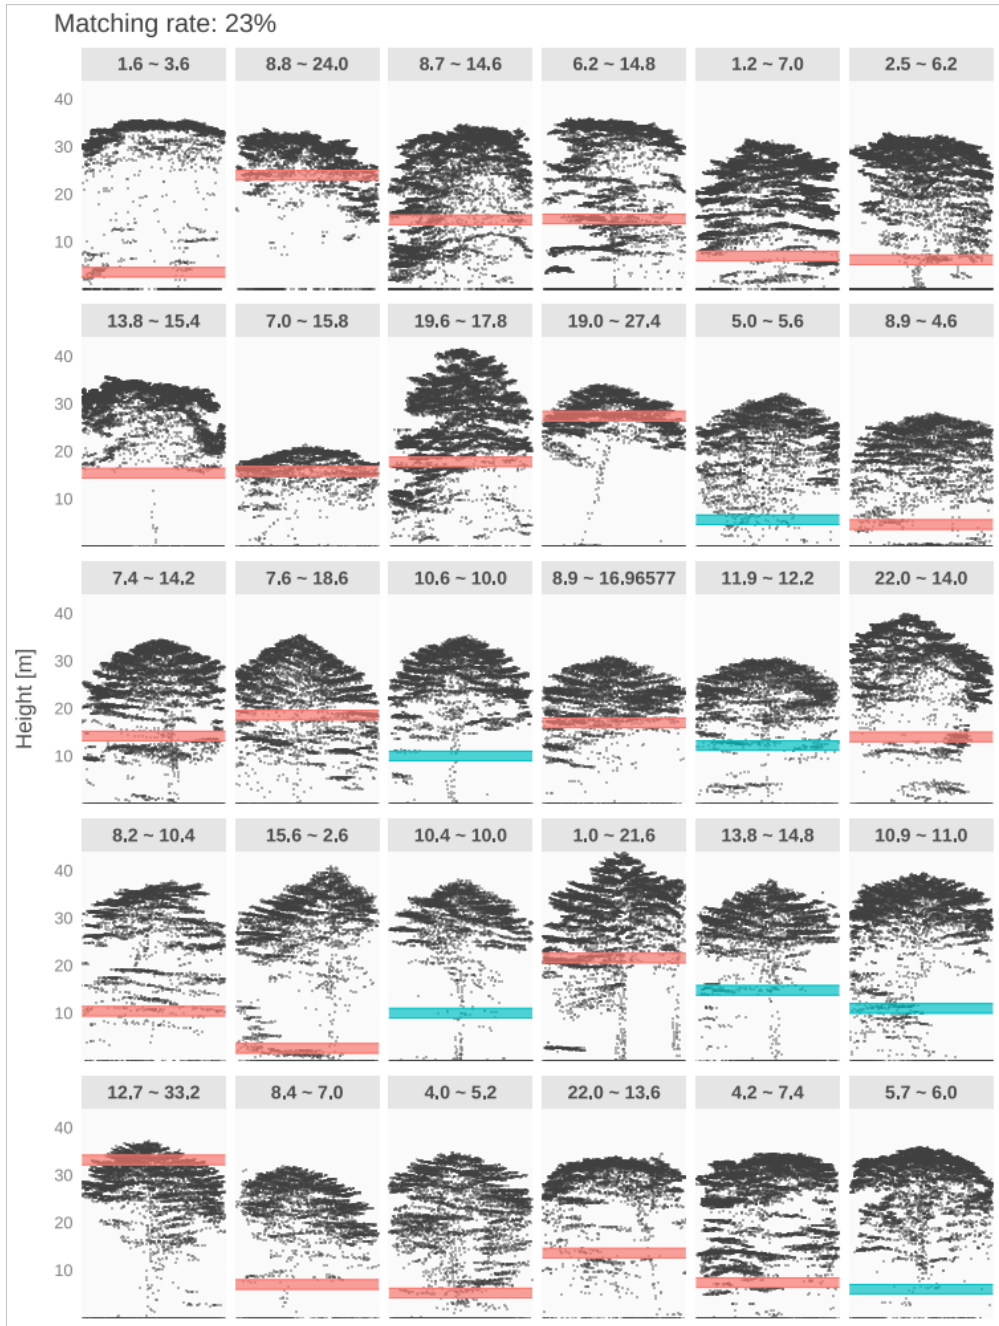


Figure 6. Crown Base Height detection results of *treecbh*: matching rate of the leaf-on ALS site BR05 in *Default treeiso* mode. Horizontal transparent red bands (2 m wide) indicate non-matches, while transparent green bands (2 m wide) represent matches. Each panel is labelled with the reference CBH and its corresponding estimated CBH, separated by the ~ symbol.

3. I have determined the minimum and optimum point density required for the optimal operation of treecbh regarding its input point cloud.

I demonstrated that the performance of *treecbh* in the *No treeiso* mode improved only when the point density increased from 20 pts/ to 111 pts/m² (Fig. 8). I have conducted a point density analysis using the six point density classes (20, 53, 111, 156, 205, and 253 pts/m²) from the 12 adjacent tree cloud derived from the Wytham Woods TLS dataset.




Figure 8. Crown Base Height detection results of point sensitivity analysis (*No treeiso* mode) for point density classes. The horizontal dark line represents the reference CBHs, and the red horizontal dashed lines mark the maxima of the deviation densities displayed by the vertical green densities, which represent the distributions of the 30 input point clouds (green dots). Horizontal red transparent band (2 m wide) marks the ± 1 m acceptance region. Each panel is labelled with its point density class along with its respective matching rate separated by the ~ symbol.

4. I developed the Label-Passing method, which transmits tree identification labels from the initial tree points identified by HDBSCAN to the unlabeled critical points.

The HDBSCAN was applied to the xy plane, cutting through both the initial and critical point clouds at a suitable height (z attribute of the point cloud) where the tree trunks are clearly separated from one another (Fig. 9b). In my datasets (both the 12 trees' input and the Morse complexes calculated point clouds), this height was set at 3 meters (Fig. 9a).

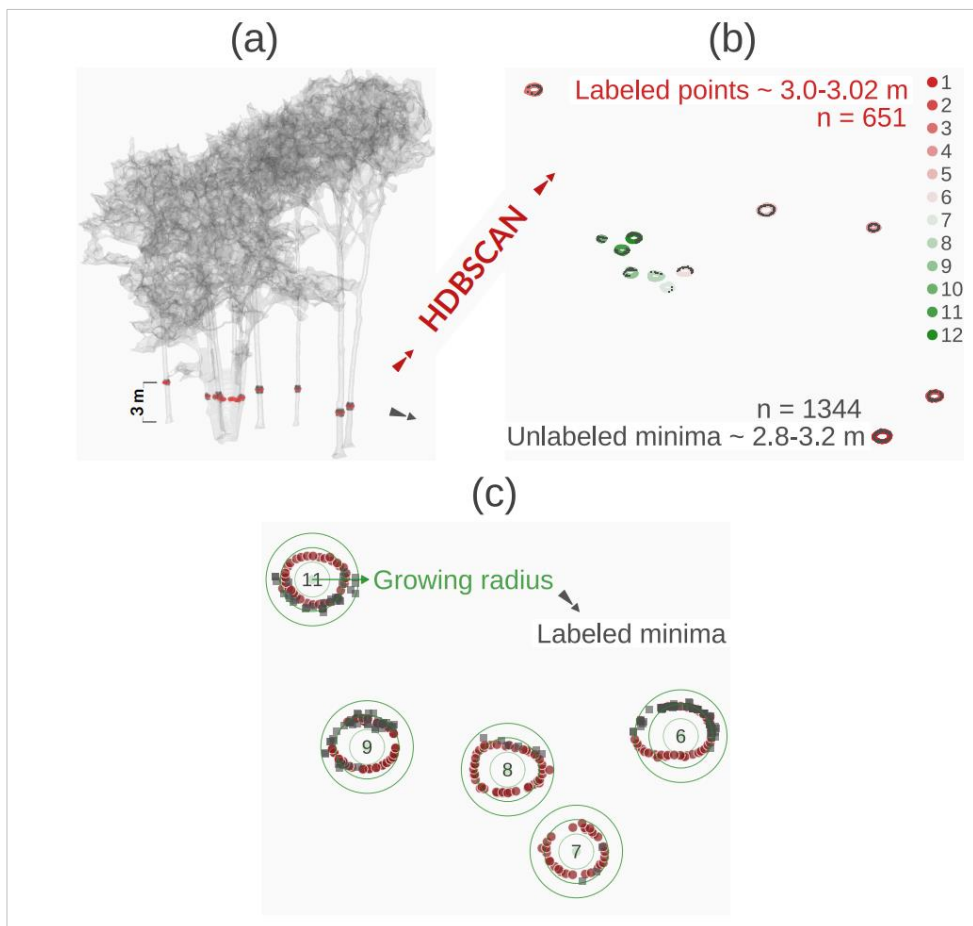


Figure 9. (a) Triangulated 12-member initial tree point cloud overlaid with the minima at height between 2.8 and 3.2 m in grey, and with the points extracted from the initial point cloud between 3.0 and 3.02 m height in red. (b) Unlabeled minima and its count in grey, HDBSCAN-detected and -labeled (tree ID) points of the initial point cloud scale coloured after a red-green colour palette, point count is expressed in red. (c) Tree IDs 6,7,8,9 and 11 from (b), displaying label-passing, which utilises the growing radius technique (concentric circles).

After applying HDBSCAN, the points from the initial point cloud between the heights of 3.0 and 3.02 meters are tagged with the HDBSCAN-identified tree ID. However, the critical points between 2.8 and 3.2 m remain unlabeled (Fig. 9b).

The Label-Passing method employs a gradual radius growth technique that generates concentric circles. The radius of the concentric circle is defined (or determinably constant), meaning the radius increases in direct proportion to the multiples of the concentric circle (Fig. 9c). The initial tree identifiers (i.e., labels) of the candidate points in a concentric circle are overwritten to the unlabeled critical points found in the same concentric circle. The growth of concentric circles automatically stops if the next concentric circle does not contain any new labeled or unlabeled point (Fig. 9c).

REFERENCES

- Beaudoin, A., Bernier, P., Villemaire, P., Guindon, L., Guo, X., 2017. Tracking forest attributes across Canada between 2001 and 2011 using a kNN mapping approach applied to MODIS imagery. *Can. J. For. Res.* 48. <https://doi.org/10.1139/cjfr-2017-0184>
- Blackard, J.A., Finco, M.V., Helmer, E.H., Holden, G.R., Hoppus, M.L., Jacobs, D.M., Lister, A.J., Moisen, G.G., Nelson, M.D., Riemann, R., Ruefenacht, B., Salajanu, D., Weyermann, D.L., Winterberger, K.C., Brandeis, T.J., Ph.D..Czaplewski, R.L., McRoberts, R.E., Patterson, P.L., Tymcio, R.P., 2008. Mapping U.S. forest biomass using nationwide forest inventory data and moderate resolution information. *Remote Sens. Environ.* 112 1658-1677 12, 1658-1677. <https://doi.org/10.1016/j.rse.2007.08.021>
- Bouvier, M., Durrieu, S., Fournier, R.A., Renaud, J.-P., 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sens. Environ.* 156, 322-334. <https://doi.org/10.1016/j.rse.2014.10.004>
- Calders, K., Verbeeck, H., Burt, A., Origo, N., Nightingale, J., Malhi, Y., Wilkes, P., Raunonen, P., Bunce, R.G.H., Disney, M., 2022. Laser scanning reveals potential underestimation of biomass carbon in temperate forest. *Ecol. Solut. Evid.* 3, e12197. <https://doi.org/10.1002/2688-8319.12197>

- Dioszegi, G., Molnar, V.E., Nagy, L.A., Enyedi, P., Szabo, S., 2023. A novel algorithm using the growing tree region and the three-layer concept for individual treetop detection with aerial laser scanned data. under review.
- Diószegi, G., Molnár, V.É., Nagy, L.A., Enyedi, P., Török, P., Szabó, S., 2024. Testing treecbh in Central European forests: an R package for crown base height detection using high-resolution aerial laser-scanned data. *For. Int. J. For. Res.* cpae044. <https://doi.org/10.1093/forestry/cpae044>
- Eddelbuettel, D., Francois, R., Allaire, J.J., Ushey, K., Kou, Q., Russell, N., Ucar, I., Chambers, D.B. and J., 2024. Rcpp: Seamless R and C++ Integration.
- Forman, R., 1998. Morse Theory for Cell Complexes. *Adv. Math.* 134, 90–145. <https://doi.org/10.1006/aima.1997.1650>
- Hantsch, L., Bien, S., Radatz, S., Braun, U., Auge, H., Bruelheide, H., 2014. Tree diversity and the role of non-host neighbour tree species in reducing fungal pathogen infestation. *J. Ecol.* 102, 1673–1687. <https://doi.org/10.1111/1365-2745.12317>
- Hardenbol, A.A., Korhonen, L., Kukkonen, M., Maltamo, M., 2023. Detection of standing retention trees in boreal forests with airborne laser scanning point clouds and multispectral imagery. *Methods Ecol. Evol.* 14, 1610–1622. <https://doi.org/10.1111/2041-210X.13995>
- Hyypä, J., Hyypä, H., Leckie, D., Gougeon, F., Yu, X., Maltamo, M., 2008. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *Int. J. Remote Sens. - INT J REMOTE SENS* 29, 1339–1366. <https://doi.org/10.1080/01431160701736489>
- Kelly, M., Su, Y., Di Tommaso, S., Fry, D.L., Collins, B.M., Stephens, S.L., Guo, Q., 2018. Impact of Error in Lidar-Derived Canopy Height and Canopy Base Height on Modeled Wildfire Behavior in the Sierra Nevada, California, USA. *Remote Sens.* 10, 10. <https://doi.org/10.3390/rs10010010>
- Koch, B., Heyder, U., Weinacker, H., 2006. Detection of Individual Tree Crowns in Airborne LiDAR Data. *Photogramm. Eng. Remote Sens.* 72, 357–363. <https://doi.org/10.14358/PERS.72.4.357>
- Lecigne, B., Delagrangé, S., Messier, C., 2018. Exploring trees in three dimensions: VoxR, a novel voxel-based R package dedicated to analysing the complex arrangement of tree crowns. *Ann. Bot.* 121, 589–601. <https://doi.org/10.1093/aob/mcx095>

- Luo, L., Zhai, Q., Su, Y., Ma, Q., Kelly, M., Guo, Q., 2018. Simple method for direct crown base height estimation of individual conifer trees using airborne LiDAR data. *Opt. Express* 26, A562–A578. <https://doi.org/10.1364/OE.26.00A562>
- Parkitna, K., Krok, G., Miścicki, S., Ukalski, K., Lisańczuk, M., Mitelsztedt, K., Magnussen, S., Markiewicz, A., Stereńczak, K., 2021. Modelling growing stock volume of forest stands with various ALS area-based approaches. *For. Int. J. For. Res.* 94, 630–650. <https://doi.org/10.1093/forestry/cpab011>
- Popescu, S., Wynne, R., Nelson, R., 2003. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Can. J. Remote Sens.* 29, 564–577. <https://doi.org/10.5589/m03-027>
- Seidel, D., Leuschner, C., Müller, A., Krause, B., 2011. Crown plasticity in mixed forests—Quantifying asymmetry as a measure of competition using terrestrial laser scanning. *For. Ecol. Manag.* 261, 2123–2132. <https://doi.org/10.1016/j.foreco.2011.03.008>
- Stefanidou, A., Gitas, I.Z., Korhonen, L., Stavrakoudis, D., Georgopoulos, N., 2020. LiDAR-Based Estimates of Canopy Base Height for a Dense Uneven-Aged Structured Forest. *Remote Sens.* 12, 1565. <https://doi.org/10.3390/rs12101565>
- Terryn, L., Calders, K., Åkerblom, M., Bartholomeus, H., Disney, M., Levick, S., Origo, N., Raumonon, P., Verbeeck, H., 2023. Analysing individual 3D tree structure using the R package ITSM. *Methods Ecol. Evol.* 14, 231–241. <https://doi.org/10.1111/2041-210X.14026>
- Tomppo, E., 2006. The Finnish National Forest Inventory. pp. 179–194. https://doi.org/10.1007/1-4020-4381-3_11
- Weiser, H., Schäfer, J., Winiwarter, L., Krašovec, N., Höfle, B., Fassnacht, F., 2022. Individual tree point clouds and tree measurements from multi-platform laser scanning in German forests. *Earth Syst. Sci. Data* 14, 2989–3012. <https://doi.org/10.5194/essd-14-2989-2022>
- White, J.C., Coops, N.C., Wulder, M.A., Vastaranta, M., Hilker, T., Tompalski, P., 2016. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Can. J. Remote Sens.* 42, 619–641. <https://doi.org/10.1080/07038992.2016.1207484>
- Wulder, M.A., Bater, C.W., Coops, N.C., Hilker, T., White, J.C., 2008. The role of LiDAR in sustainable forest management. *For. Chron.* 84, 807–826. <https://doi.org/10.5558/tfc84807-6>

- Xi, Z., Hopkinson, C., 2022. 3D Graph-Based Individual-Tree Isolation (Treeiso) from Terrestrial Laser Scanning Point Clouds. *Remote Sens.* 14, 6116. <https://doi.org/10.3390/rs14236116>
- Zianis, D., Muukkonen, P., Mäkipää, R., Mencuccini, M., 2005. Biomass and stem volume equations of tree species in Europe. *Silva Fenn.* 4. <https://doi.org/10.14214/sf.sfm4>



Registry number: DEENK/554/2024.PL
Subject: PhD Publication List

Candidate: Gergő Diószegi
Doctoral School: Doctoral School of Earth Sciences
MTMT ID: 10097933

List of publications related to the dissertation

Foreign language scientific articles in international journals (2)

1. **Diószegi, G.**, Molnár, V. É., Nagy, L. A., Enyedi, P., Török, P., Szabó, S.: A new method for individual treetop detection with low-resolution aerial laser scanned data.
Modeling Earth Systems and Environment. 10, 5225-5240, 2024. ISSN: 2363-6203.
DOI: <http://dx.doi.org/10.1007/s40808-024-02060-w>
IF: 2.7 (2023)
2. **Diószegi, G.**, Molnár, V. É., Nagy, L. A., Enyedi, P., Török, P., Szabó, S.: Testing 'treecbh' in Central European forests: an R package for crown base height detection using high-resolution aerial laser-scanned data.
Forestry. [Epub ahead of print] (-), 1-15, 2024. ISSN: 0015-752X.
DOI: <http://dx.doi.org/10.1093/forestry/cpae044>
IF: 3 (2023)

Total IF of journals (all publications): 5,7

Total IF of journals (publications related to the dissertation): 5,7

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on the basis of the Journal Citation Report (Impact Factor) database.

07 November, 2024

