



Universitatea
Transilvania
din Braşov

ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Silvicultură și Exploatare Forestiere

Ing. Căţeanu G. Mihnea

**UTILIZAREA TEHNOLOGIEI LIDAR ÎN REALIZAREA
MODELULUI DIGITAL ALTIMETRIC AL TERENURILOR
ACOPERITE CU VEGETAŢIE FORESTIERĂ**

**USING LIDAR FOR THE GENERATION OF DIGITAL ELEVATION
MODELS IN FORESTED TERRAIN**

REZUMAT / ABSTRACT

Conducător științific

Prof.dr.ing. Arcadie CIUBOTARU

BRAŞOV, 2019

D-lui (D-nei)

COMPONENȚA

Comisiei de doctorat

Numită prin ordinul Rectorului Universității Transilvania din Brașov

Nr. din

PREȘEDINTE:

Prof. dr. ing. Alexandru Lucian CURTU

Decanul Facultății de Silvicultură și Exploatare Forestiere
Universitatea Transilvania din Brașov

CONDUCĂTOR ȘTIINȚIFIC:

Prof. dr. ing. Arcadie CIUBOTARU

Universitatea Transilvania din Brașov

REFERENȚI:

Prof. dr. ing. Iosif Vorovencii

Universitatea Transilvania din Brașov

Conf. univ. dr. ing. Adrian SAVU

Universitatea Tehnică de Construcții București

Cercetător științific gr. II Bogdan APOSTOL

Institutul Național de Cercetare-Dezvoltare în Silvicultură
(INCDS) "Marin Drăcea"

Data, ora și locul susținerii publice a tezei de doctorat:

Data, ora, sala

Eventualele aprecieri sau observații asupra conținutului lucrării vă rugăm să le transmiteți în timp util, pe adresa cateanu.mihnea@unitbv.ro

Totodată vă invităm să luați parte la ședința publică de susținere a tezei de doctorat.

Vă mulțumim.

CUVÂNT ÎNAINTE

Prin lucrarea pe care o aveți în față mi-am propus aducerea celor mai recente tendințe ale geomaticii, în ceea ce privește înregistrarea, prelucrarea, analizarea și interpretarea datelor geografice, în sfera silviculturii.

Teza de doctorat a fost elaborată sub îndrumarea riguroasă a domnului prof. univ. dr. ing. Arcadie CIUBOTARU, căruia îi adresez întreaga mea recunoștință pentru că m-a îndemnat să urmez studiile de doctorat, precum și pentru faptul că a ales să mă îndrume. Calitatea lucrării, atât cât este ea, se datorează răbdării, sfaturilor dar și criticilor constructive ale Domniei sale.

Le mulțumesc cu respect domnilor prof. dr. ing. Iosif VOROVENCII, conf. dr. ing. Cornel Cristian TEREȘNEU și conf. univ. Vasile Răzvan CÂMPU pentru profesionalismul, disponibilitatea și sugestiile acordate pe parcursul acestor ani, în calitate de membri ai comisiei de îndrumare.

Aduc mulțumiri domnului prof. dr. ing. Iosif VOROVENCII din cadrul Universității Transilvania Brașov, domnului conf. univ. dr. ing. Adrian SAVU din cadrul Universității Tehnice de Construcții București și domnului cercetător științific gr. Bogdan APOSTOL din cadrul Institutului Național de Cercetare-Dezvoltare în Silvicultură (INCDS) „Marin Drăcea” pentru că au ales să mă onoreze în calitate de referenți științifici, pentru răbdarea de a-mi analiza teza și pentru valorile sugestiilor.

Sincere mulțumiri domnului prof. univ. dr. ing. Alexandru Lucian CURTU, decanul Facultății de Silvicultură și Exploatare Forestiere din cadrul Universității Transilvania din Brașov, pentru faptul că pune la dispoziția doctoranzilor toate resursele Facultății, înlesnind desfășurarea cu succes a studiilor de doctorat. Mulțumesc de asemenea tuturor cadrelor didactice din cadrul Departamentului Exploatare Forestiere, Amenajarea Pădurilor și Măsurători Terestre cu care am interacționat pe parcursul studiilor de doctorat, dar și în anii de studenție, pentru că și-au găsit întotdeauna timp pentru încurajări, sfaturi sau sugestii. Mulțumesc de asemenea cadrelor didactice din cadrul Facultății de Chimie, Biologie, Geografie din cadrul Universității de Vest din Timișoara, unde mi-am realizat masteratul, pentru că au contribuit la dezvoltarea mea profesională și alegerea de a mă îndrepta spre cercetarea științifică.

Teza de doctorat nu ar fi fost posibilă fără amabilitatea domnului dr. ing. Ovidiu BADEA, director general al Institutului Național de Cercetare-Dezvoltare în Silvicultură (INCDS) „Marin Drăcea” care mi-a oferit cu generozitate acces la datele LiDAR deținute de Institut.

Pentru măsurătorile terestre pe care am avut ocazia să le includ în analiză trebuie să adresez călduroase mulțumiri domnului ing. Mihai Doru POPESCU, șef de Ocol, pentru că mi-a permis accesul în cadrul suprafețelor de pădure aflate în administrația Ocolului Silvic Cozia-Negoiu, județul Vâlcea.

În încheiere, dar nu în ultimul rând, mulțumesc familiei și celor dragi pentru răbdarea și înțelegerea de care au dat dovadă, pentru încurajările și sprijinul fără de care nu aș fi putut încheia cu succes această îndelungată etapă.

**Brașov,
Noiembrie 2019**

Autorul,

CUPRINS

		Pg. teză	Pg. rezumat
1	INTRODUCERE	14	9
2	REPREZENTAREA DIGITALĂ A SUPRAFEȚEI TERESTRE	17	11
2.1.	Aspecte generale privind stocarea datelor geografice	17	11
2.1.1.	Modelul vector	17	-
2.1.2.	Modelul raster	18	-
2.2.	Modele folosite la reprezentarea suprafeței terestre.....	19	11
2.2.1.	Modelul Digital Altimetric (MDA)	19	-
2.2.2.	Modelul Numeric al Terenului (MNAT)	19	-
2.3.	Culegerea datelor necesare modelării suprafeței terestre.....	21	11
2.4.	Produse derivate ale Modelului Digital Altimetric	22	-
2.5.	Cercetări în domeniul Modelelor Digitale Altimetrice	25	-
3	TEHNOLOGIA DE MĂSURARE PRIN UNDE LASER	26	12
3.1.	Echipamente laser pentru măsurarea distanței	26	12
3.1.1.	Principiul de funcționare al laserului	26	12
3.1.2.	Principiul de determinare a distanței	26	12
3.1.3.	Metode de determinare a distanței	28	12
3.1.4.	Clasificarea sistemelor de măsurare cu laser	30	-
3.1.5.	Noi direcții de dezvoltare a tehnologiei LiDAR	32	-
3.2.	Tehnologia de scanare laser aeriană (ALS)	33	13
3.2.1.	Componentele unui sistem ALS	33	-
3.2.2.	Surse de erori pentru măsurarea de pe platforme aeropurtate	34	-
4	PROCESAREA DATELOR LIDAR	40	14
4.1.	Ajustarea între benzi	40	14
4.2.	Clasificarea norului de puncte	41	14
4.3.	Filtrarea norului de puncte.....	43	14
4.3.1.	Aspecte generale	43	14
4.3.2.	Cercetări privind filtrarea datelor LiDAR	44	-
4.3.3.	Tipuri de erori la filtrare	45	-
4.4.	Interpolarea suprafeței terestre pe baza măsurătorilor LiDAR	46	15
4.4.1	Aspecte generale	46	15

4.4.2	Generarea suprafețelor prin interpolare	47	-
4.4.3	Erori de interpolare a măsurătorilor LiDAR	48	-
5	ISTORIC AL CERCETĂRIILOR PRIVIND SCANAREA LASER ÎN DOMENIUL FORESTIER	50	16
6	CARACTERISTICI ALE CONDIȚIILOR DE CERCETARE	52	18
6.1.	Scopul și obiectivele cercetărilor	52	18
6.2.	Locul cercetărilor	52	18
6.3	Baza de date	54	20
6.3.1	Date LiDAR	54	20
6.3.2.	Date suport	56	-
6.4	Echipe și instrumente pentru cercetare	56	22
6.4.1.	Sistemul de scanare laser	56	22
6.4.2.	Instrumente topografice și geodezice	57	22
6.4.3.	Suportul informatic al cercetărilor	58	-
7	METODOLOGIA DE CERCETARE	59	23
7.1.	Prezentare generală	59	23
7.2.	Analiza preliminară a datelor LiDAR	59	-
7.3.	Realizarea măsurătorilor geo-topografice	60	23
7.4.	Filtrarea datelor LiDAR. Determinarea erorilor de filtrare	63	26
7.4.1.	Precizări generale	63	-
7.4.2.	Zona de studiu pentru analiza procesului de filtrare	63	26
7.4.3.	Definirea erorii de filtrare	65	28
7.4.4.	Alegerea algoritmilor de filtrare	66	29
7.4.5.	Optimizarea procesului de filtrare	69	29
7.4.6.	Distribuția spațială a erorilor de filtrare	71	30
7.4.7.	Factori de influență a erorilor de filtrare	72	31
7.5.	Interpolarea suprafeței terenului. Determinarea erorilor de interpolare	75	34
7.5.1.	Precizări generale	75	-
7.5.2.	Zona de studiu pentru analiza procesului de interpolare	75	34
7.5.3.	Date pentru validarea interpolării	75	34
7.5.4.	Definirea erorii de interpolare	77	36
7.5.5.	Alegerea algoritmilor de interpolare	77	36

7.5.6.	Alegerea rezoluției spațiale pentru modelul suprafeței	82	37
7.5.7.	Factori de influență a erorilor de interpolare	82	37
8	REZULTATE ȘI DISCUȚII	85	39
8.1.	Filtrarea datelor LiDAR	85	39
8.1.1	Precizări generale	85	39
8.1.2.	Numărul de puncte rezultat în urma filtrării	86	40
8.1.3.	Distribuția spațială a erorilor de filtrare	90	44
8.1.4.	Factori de influență a erorilor de filtrare - <i>suprafața de probă A</i>	93	47
8.1.5.	Factori de influență a erorilor de filtrare - <i>suprafețele de probă nr. 1-7</i>	97	51
8.2	Interpolarea suprafeței terenului	98	52
8.2.1	Precizări generale	98	52
8.2.2.	Efectul rezoluției spațiale a modelului asupra acurateții de interpolare	104	57
8.2.3.	Distribuția spațială a erorilor de interpolare	104	57
8.2.4	Factori de influență a erorilor de interpolare	110	62
9	CONCLUZII ȘI CONTRIBUȚII ORIGINALE	115	67
9.1.	Concluzii	115	67
9.2.	Contribuții originale	119	71
BIBLIOGRAFIE		126	72
Rezumatul tezei		165	74
Curriculum Vitae (limba română)		166	75
Curriculum Vitae (limba engleză)		-	76

CONTENTS

		Thesis pg.	Abstract pg.
1	INTRODUCTION	14	9
2	DIGITAL REPRESENTATIONS OF GROUND SURFACE	17	11
2.1.	General concepts regarding storage of geographical data	17	11
2.1.1.	Vector data models	17	-
2.1.2.	Raster data models	18	-
2.2.	Models for ground surface representation	19	11
2.2.1.	Digital Elevation Models (DEM)	19	-
2.2.2.	Digital Terrain Models (DTM)	19	-
2.3.	Collecting data for ground surface modelling	21	11
2.4.	Derivatives of Digital Elevation Models	22	-
2.5.	Research regarding Digital Elevation Models	25	-
3	LASER RANGING	26	12
3.1.	Equipment for laser ranging	26	12
3.1.1.	Principles of laser light	26	12
3.1.2.	Principles of ranging	26	12
3.1.3.	Ranging methods	28	12
3.1.4.	Classification of laser ranging systems	30	-
3.1.5.	New approaches of LiDAR	32	-
3.2.	Airborne Laser Scanning (ALS)	33	13
3.2.1.	Components of ALS systems	33	-
3.2.2.	Sources of error for ALS measurements	34	-
4	PROCESSING OF LIDAR DATA	40	14
4.1.	Strip adjustment	40	14
4.2.	Point cloud classification	41	14
4.3.	Point cloud filtering	43	14
4.3.1.	General concepts	43	14
4.3.2.	Research regarding LiDAR data filtering	44	-
4.3.3.	Types of filtering errors	45	-
4.4.	Ground surface interpolation using LiDAR data	46	15
4.4.1	General concepts	46	15

4.4.2	Surface interpolation	47	-
4.4.3	Interpolation errors for LiDAR data	48	-
5	PAST RESEARCH REGARDING LASER SCANNING IN FORESTRY	50	16
6	FEATURES OF RESEARCH CONDITIONS	52	18
6.1.	Research purpose and objectives	52	18
6.2.	Research location	52	18
6.3	Database	54	20
6.3.1	LiDAR data	54	20
6.3.2.	Auxiliary data	56	-
6.4	Research equipment and instruments	56	22
6.4.1.	Laser scanning system	56	22
6.4.2.	Topographical and geodetic instruments	57	22
6.4.3.	Computing equipment	58	-
7	METHODS OF RESEARCH	59	23
7.1.	Research overview	59	23
7.2.	Preliminary analysis of LiDAR data	59	-
7.3.	Geo-topographical ground survey	60	23
7.4.	LiDAR data filtering. Filtering errors	63	26
7.4.1.	Overview	63	-
7.4.2.	Study area for the analysis of the filtering process	63	26
7.4.3.	Defining the filtering error	65	28
7.4.4.	Selection of filtering algorithms	66	29
7.4.5.	Optimisation of filtering algorithms	69	29
7.4.6.	Spatial distribution of filtering errors	71	30
7.4.7.	Factors influencing filtering errors	72	31
7.5.	Ground surface interpolation. Interpolation errors.	75	34
7.5.1.	Overview	75	-
7.5.2.	Study area for the analysis of interpolation	75	34
7.5.3.	Data for validation of interpolation	75	34
7.5.4.	Defining the interpolation error	77	36
7.5.5.	Selection of interpolation algorithms	77	36
7.5.6.	Selection of the ground model's spatial resolution	82	37

7.5.7.	Factors influencing interpolation errors	82	37
8	RESULTS AND DISCUSSION	85	39
8.1.	LiDAR data filtering	85	39
8.1.1	Overview	85	39
8.1.2.	The number of filtered points	86	40
8.1.3.	Spatial distribution of filtering errors	90	44
8.1.4.	Factors influencing filtering errors – <i>study site A</i>	93	47
8.1.5.	Factors influencing filtering errors – <i>study site no. 1-7</i>	97	51
8.2	Ground surface interpolation	98	52
8.2.1	Overview	98	52
8.2.2.	Accuracy of interpolation due to model resolution	104	57
8.2.3.	Spatial distribution of interpolation errors	104	57
8.2.4	Factors influencing interpolation errors	110	62
9	CONCLUSIONS AND ORIGINAL CONTRIBUTIONS	115	67
9.1.	Conclusions	115	67
9.2.	Original contributions	119	71
	REFERENCES	126	72
	Thesis summary	165	74
	Curriculum Vitae (Romanian)	166	75
	Curriculum Vitae (English)	-	76

1. INTRODUCERE

Gospodărirea durabilă a pădurilor a devenit o problemă globală, întrucât omul a înțeles importanța pădurii în menținerea echilibrului ecosistemelor. Dincolo de asigurarea necesarului de material lemnos în continuă creștere, pădurea joacă un rol esențial în diminuarea impactului uman negativ asupra mediului înconjurător. Deciziile de gospodărire a pădurilor se fundamentează pe analiza unei multitudini de factori, specifici biotopului și biocenozei, care influențează direct sau indirect dezvoltarea ecosistemelor forestiere.

Unul dintre acești factori este relieful, caracteristicile suprafeței terestre definind condițiile de vegetație ale arboretelor (Nicolescu, 2009) precum și tipurile de ecosisteme forestiere (Smith ș.a., 1997). De asemenea, relieful influențează: stabilitatea arborilor (Bibalani, 2008; Păcurar, 2006), alegerea soluțiilor de exploatare (Ciubotaru, 1998; Borz, 2014), productivitatea mijloacelor de recoltare și colectare (Standgard ș.a., 2014), proiectarea și executarea rețelelor de drumuri forestiere (Bereziuc ș.a., 1987), soluțiile de ameliorare a terenurilor degradate (Ciortuz și Păcurar, 2004), modelarea dezvoltării arboretelor (Pretzsch, 2009) etc. În silvicultură, metoda de lucru tradițională presupune caracterizarea condițiilor de relief prin determinarea unor indicatori specifici (de exemplu altitudinea, înclinarea terenului etc.) ca medie aritmetică la nivel de arboret, fără a lua în seamă variabilitatea acestor condiții la nivel de detaliu.

Obiectul tezei de față este tehnologia LiDAR (*Light Detection and Ranging*), care presupune cartarea suprafețelor prin scanarea cu impulsuri electromagnetice de tip laser. Dincolo de potențialul general al tehnologiei, aceasta este de un real interes în domeniul forestier. Spre deosebire de fotogrammetrie sau teledetecție, impulsurile laser pot pătrunde prin stratul de vegetație până la sol. Se fac deci înregistrări de la nivelul superior al coronamentului, parcurgând întreaga structură verticală a pădurii până la suprafața terenului (Cățeanu ș.a., 2017a). Senzorul LiDAR se montează pe o platformă terestră sau aeriană, alături de un Sistem Inerțial de Măsurare (*IMU*) și un sistem de poziționare globală prin satelit (*GNSS*). Posibilitatea instalării ansamblului de măsurare pe platforme aeropurtate (avioane sau elicoptere) înseamnă că nu trebuie să se renunțe la avantajul fotogrammetriei sau teledetecției, și anume acoperirea eficientă a suprafețelor extinse. Se preconizează că tehnologia va fi indispensabilă, atât în cercetare cât și în scopuri comerciale, în special în regiunile unde pădurea acoperă suprafețe extinse.

Pe plan internațional, tehnologia LiDAR face deja parte din practica uzuală în domeniul forestier, alături de metodele consacrate ale geomatiei precum fotogrammetria sau teledetecția. La noi în țară, tehnologia este încă în faza de început, în care se fac primele cercetări asupra aplicabilității metodei. Majoritatea acestor cercetări se concentrează asupra potențialului tehnologiei pentru rezolvarea problemelor de inventariere sau estimare a anumitor caracteristici dendrometrice. Deși această abordare este una importantă și cu utilitate imediată, considerăm că merită atenție și explorarea tehnologiei LiDAR ca *metodă de cartare a suprafeței terestre acoperite de vegetație forestieră*. În fapt, înțelegerea și urmărirea evoluției arboretelor nu poate fi completă fără analizarea reliefului în care acestea își desfășoară viața.

Transformarea setului de date LiDAR inițiale într-un model digital al suprafeței terestre, adecvat scopurilor de cercetare sau practicii, presupune două etape de prelucrare:

- a. **Filtrarea (sau clasificarea) norului de puncte:** operațiune prin care se separă acele puncte aflate la nivelul solului de restul setului de date (adică acele puncte care reprezintă obstacole aflate deasupra terenului – clădiri, vegetație etc.); filtrarea se poate realiza în trei moduri:
 - i. *Automat* – caz în care se folosesc algoritmi de filtrare.
 - ii. *Manual* – operatorul parcurge o reprezentare tridimensională a norului de puncte și realizează filtrarea pe baza analizei vizuale.
 - iii. *Combinat* – rezultatul filtrării automate este îmbunătățit prin corectare manuală.
- b. **Interpolarea:** procesul prin care norul de puncte filtrat este folosit la generarea unei suprafețe continue, prin care se reprezintă variația coordonatei Z a punctelor (deci un model al suprafeței terestre); interpolarea se realizează exclusiv automat, folosind algoritmi specifici.

Realizarea automată a celor două operațiuni nu se poate face fără erori. În cercetarea de față, aceste erori au fost definite, calculate și analizate din punct de vedere al distribuției statistice și spațiale. S-a analizat de asemenea influența factorilor de teren (înclinare, grad de rugozitate etc.) sau vegetație (gradul de acoperire cu vegetație) asupra variației erorilor.

Pentru procesul de **filtrare**, erorile au fost estimate în două modalități:

- a. Prin compararea rezultatului filtrării automate cu cel al filtrării manuale.
- b. Prin compararea rezultatului filtrării automate cu un set de date independent, obținut prin măsurători geo-topografice.

În ceea ce privește **interpolarea**, erorile au fost determinate prin metoda numită *cros-validare*: cinci la sută din observații au fost extrase aleatoriu din norul de puncte folosit la interpolare, fiind apoi folosite pentru determinarea acurateții suprafeței interpolate.

2. REPREZENTAREA DIGITALĂ A SUPRAFEȚEI TERESTRE

2.1. Aspecte generale privind stocarea datelor geografice

De-a lungul timpului s-au dezvoltat diferite formate de stocare a datelor geografice în format digital, în funcție de scopul pentru care se înregistrează datele, caracteristicile obiectelor reprezentate sau gradul de abstractizare urmărit. Aceste formate (sau modele de stocare) se încadrează în două categorii principale: *vector* și *raster*.

2.2. Modele folosite la reprezentarea suprafeței terestre

Suprafața terestră este suportul pe care se desfășoară orice fenomen geografic. Astfel, reprezentarea reliefului este un domeniu de interes în cadrul *Sistemelor de Informații Geografice*. În principiu, integrarea informației topografice într-un sistem informatic necesită două elemente: o sursă de date de altitudine și un set de metode de lucru care să permită modelarea, stocarea, analizarea și interpretarea reprezentărilor.

Particularitatea modelării suprafeței terestre este faptul că nu sunt necesare reprezentări ale obiectelor geografice bine delimitate în spațiu. În schimb, scopul este surprinderea variației *continue* a altitudinii terenului. Din acest motiv, pentru modelarea suprafeței terestre se pretează modelele de tip *raster*. O reprezentare în format digital a suprafeței terenului este denumită *Model Digital Altimetric* (MDA) sau *Model Numeric al Terenului* (MNAT), în funcție de caracteristicile acesteia.

2.3. Culegerea datelor necesare modelării suprafeței terestre

Realizarea unei reprezentări sub formă de model a suprafeței terestre presupune efectuarea de măsurători prin eșantionare. În urma acestui proces, rezultă un set de observații sub formă de puncte, pentru care se cunosc coordonatele X, Y, Z într-un sistem de coordonate local sau global.

Obținerea acestor date inițiale este etapa cea mai costisitoare și îndelungată. În plus, strategia de alegere a punctelor pentru care se măsoară altitudinea, precum și erorile de determinare a poziției punctelor sunt esențiale pentru calitatea produsului final.

Principalele metode de culegere a datelor privind altitudinea (sau date altimetrice) sunt:

- a. **Măsurători terestre**
- b. **Digitizarea hărților analogice**
- c. **Fotogrammetrie**
- d. **Interferometrie radar**
- e. **LiDAR (Light Detection and Ranging)**

3. TEHNOLOGIA DE MĂSURARE PRIN UNDE LASER

3.1. Echipamente laser pentru determinarea distanței

3.1.1. Principiul de funcționare al laserului

Laserul este un echipament de emisie a unui fascicul coerent de lumină, caracterizat prin: monocromaticitate, directivitate și intensitate. Din punct de vedere fizic, două unde sunt coerente atunci când au aceeași frecvență și lungime de undă, precum și o diferență de fază constantă. Această proprietate permite focalizarea undelor asupra unei suprafețe reduse. De asemenea, coerența permite colimarea undelor (reducerea împrăștierei acestora odată cu îndepărtarea de emițător).

Printre numeroasele aplicații ale tehnologiei se numără măsurarea distanțelor cu un grad ridicat de precizie. În ultimele decenii, pentru tehnologia de cartare în care se folosesc echipamente laser pentru măsurarea distanței s-a consacrat termenul de LiDAR¹ (Bachman, 1979).

3.1.2. Principiul de determinare a distanței

În domeniul măsurătorilor terestre, distanța este elementul care servește, alături de unghiuri, la determinarea poziției în spațiu a punctelor. Cele două procedee de determinare a distanței sunt (Kiss și Chițea, 1997):

- a. **procedeul direct:** instrumentul de măsurare se aplică direct pe distanța de măsurat;
- b. **procedeul indirect:** distanța se deduce în funcție de alte elemente, fără a fi parcursă.

Măsurarea indirectă a distanței se face folosind instrumente optice sau electronice. Primele dispozitive electronice de măsurare a distanței folosite în topografie au fost lămpile cu mercur sau tungsten. Începând din anii 1970, acestea au început să fie înlocuite cu echipamente de tip laser (Shanși Toth, 2009).

3.1.3. Metode de determinare a distanței

Folosind emițătoare de unde laser, înregistrarea distanțelor se poate face în două modalități:

- a. **Prin profile**
- b. **Prin scanare**

În funcție de modalitatea prin care senzorul identifică ecourile, se disting:

- i. **Sisteme de măsurare discretă**, care identifică unul sau mai multe puncte de maxim ale curbei de intensitate, pe care le stochează ca ecouri distincte. Istoric, primele sisteme de măsurare laser aveau capacitatea de a identifica două ecouri (sau vârfuri ale curbei de intensitate): primul și ultimul. În ultimele decenii, s-au răspândit sisteme care pot identifica mai mult de 10 reflexii.

- ii. **Sisteme de măsurare continuă**, în cazul cărora echipamentul digitizează și stochează întreaga funcție de intensitate pentru fiecare puls. Determinarea reflexiilor individuale se va face ulterior, la post-procesarea datelor. În plus, funcția de intensitate poate fi analizată pentru a obține informații suplimentare despre textura și morfologia suprafețelor scanate.

Diferențele conceptuale dintre cele două tipuri clase de echipamente sunt ilustrate în figura 3.5.

¹ Light Detection and Ranging.




Fig. 3.5. Modul de colectare a datelor pentru sistemele de măsurare discretă, respectiv continuă.

3.2. Tehnologia de scanare laser aeriană (ALS)

Tehnologia de scanare laser aeriană (ALS – *Airborne Laser Scanning*) presupune montarea unui echipament de măsurare a distanței de tip laser pe o platformă aeropurtată (elicopter, avion sau vehicul autonom – „dronă”) pentru cartarea eficientă a suprafețelor extinse.

3.2.1. Componentele unui sistem ALS

Un sistem tipic de scanare laser aeriană are următoarea structură (figura 3.7.):

- Unitate laser de măsurare a distanței, cu sisteme optice pentru transmisia și recepționarea undelor.
- Mecanism de scanare (oglină sau prismă rotativă) care direcționează pulsurile laser de-a lungul unei traiectorii transversale față de direcția de zbor. De asemenea este atașat un dispozitiv care măsoară cu precizie unghiul sub care se emite un puls, denumit *encoder unghiular*.
- Sistem de poziționare globală prin satelit (GNSS - *Global Navigational Satellite System*) care înregistrează poziția platformei într-un sistem de referință. Aceste date sunt necesare pentru poziționarea punctelor măsurate, dar și pentru a determina elemente necesare la post-procesare, precum altitudinea sau viteza de zbor.
- Sistem inertial de orientare (IMU - *Inertial Measurement Unit*), care servește la determinarea orientării pe trei axe a platformei de zbor (rotație, rulu și tangaj).
- Unitate hardware/software care permite controlul sistemului, asigură funcționarea corectă a echipamentelor și este responsabilă pentru stocarea datelor pe suport electronic.

Poziția geografică a punctelor scanate (latitudine, longitudine, altitudine) rezultă pe baza următoarelor elemente: i. poziția platformei la momentul emisie pulsului; ii. înclinarea platformei pe cele trei axe (X, Y, Z) la momentul emisie pulsului; iii. distanța dintre platformă și suprafața-obiect.

4. PROCESAREA DATELOR LIDAR

Transformarea datelor brute înregistrate de echipamentul pentru scanare laser într-un set de date final, care poate fi utilizat în practică, implică o serie de etape de procesare.

4.1. Ajustarea între benzi

Deplasarea pe două axe a echipamentului de scanare (cu mișcarea longitudinală asigurată de deplasarea aeropurtată, iar mișcarea senzorului în plan transversal dată de mecanismul de baleiere) produce un tipar de înregistrare a punctelor sub formă de benzi succesive.

O anumită suprafață de teren va fi scanată de două sau mai multe ori, fiind cuprinsă în cel puțin două benzi învecinate. Întrucât măsurătorile sunt afectate de o serie de erori sistematice și întâmplătoare (descrise anterior), vor rezulta discrepanțe între benzile învecinate. Un anumit element din teren poate fi poziționat diferit, în funcție de banda în care a fost cuprins.

Aceste diferențe dintre benzi trebuie reduse la minim, pentru a asigura calitatea produsului final. Faptul că discrepanțele urmează un tipar sistematic permite modelarea și deci corectarea acestora. Procesul prin care se realizează această reducere a diferențelor între benzi se numește *ajustare*.

4.2. Clasificarea norului de puncte

Sistemul de măsurare LiDAR realizează scanarea suprafețelor prin efectuarea de măsurători stocate sub formă de puncte. Rezultă în urma zborului o mulțime de puncte (de ordinul milioane) poziționate într-un sistem de referință global, cunoscută cu denumirea uzuală de *nor de puncte*.

Clasificarea este procesul prin care fiecărui punct i se atribuie ca etichetă o anumită categorie, în funcție de semnificația punctului respectiv (teren, clădire, vegetație etc.).

De cele mai multe ori, în funcție de scopul colectării datelor, este necesară determinarea tipului de obiect asociat fiecărui punct (figura 4.2). Acest proces de clasificare se poate face:

- **manual**, de către operatori specializați care analizează vizual norul de puncte împărțit pe secțiuni și atribuie fiecărui punct categoria probabilă;
- **automat**, caz în care se folosesc algoritmi de clasificare care iau în calcul informații precum: intensitatea reflexiei, altitudinea punctelor sau structură geometrică a norului de puncte;

combinat, situație în care rezultatul clasificării automate este analizat de un operator și eventualele erori identificate sunt corectate manual.

4.3. Filtrarea datelor LiDAR

4.3.1. Aspecte generale

După cum s-a descris în secțiunea anterioară, una dintre etapele importante de prelucrare a datelor LiDAR este clasificarea norului de puncte. Atunci când scopul final este modelarea suprafeței terestre, avem de-a face cu un caz particular de clasificare, de tip binar: separarea punctelor aflate la

sol de cele aflate deasupra terenului. Acest tip de clasificare poartă numele de filtrare a terenului, sau mai simplu – **filtrare** (Sithole și Vosselman, 2005; Chen ș.a., 2007). Specificul filtrării este faptul că nu interesează distincția între tipurile de obiecte reprezentate de puncte. Un ecou produs deasupra suprafeței terestre trebuie eliminat, nu identificat ca tip.

Cu alte cuvinte, scopul urmărit prin filtrarea datelor este îndepărtarea acelor observații din norul de puncte inițial care se află deasupra terenului. Aceasta deoarece prezența acelor puncte nu ar permite modelarea corectă a suprafeței terestre. Astfel procesul de filtrare influențează în mod direct acuratețea de modelare a terenului (Cățeanu ș.a., 2017b).

4.4. Interpolarea suprafeței terestre pe baza măsurătorilor LiDAR

4.4.1. Aspecte generale

Variabilitatea în spațiu a fenomenelor fizico-geografice se estimează prin eșantionarea unui număr finit de puncte, de regulă iregular distribuite în timp și spațiu. În același timp, vizualizarea, analiza sau modelarea acestor fenomene în cadrul Sistemelor de Informații Geografice se face prin reprezentarea sub formă de suprafețe *continue*. Transformarea unui set de puncte într-o suprafață continuă necesită estimarea valorilor pentru locații noi, ne-eșantionate (figura 4.4). Acest proces se numește *interpolare* sau aproximare. *Interpolarea* presupune determinarea valorii unui punct ne-eșantionat, pe baza măsurătorilor realizate pentru puncte învecinate acestuia, denumite *puncte de referință* (El-Sheimy ș.a., 2005). Prin contrast, *extrapolarea* este procesul de estimare pentru puncte situate **în afara** zonei de eșantionare.

În ceea ce privește suprafața terestră, o reprezentare fidelă a acesteia ar necesita în principiu determinarea altitudinii pentru un număr infinit de puncte, imposibilă în practică (Tamaș și Tereșneu, 2010). În fapt, indiferent de metoda de înregistrare a datelor altimetrice, se fac determinări pentru un număr limitat de puncte, care stau la baza generării suprafețelor. Modelul suprafeței terestre este de regulă de tip *raster*, adică o rețea de celule egale ca dimensiune cărora li se atribuie o valoare singulară pentru altitudine. Acest model este cunoscut sub numele de Model Digital Altimetric (MDA). Generarea modelului altimetric pe baza punctelor eșantionate necesită estimarea, prin *interpolare*, a valorii coordonatei Z pentru centrele celulelor modelului, pe baza valorilor Z ale punctelor cunoscute din vecinătate.

5. ISTORIC AL CERCETĂRILOR PRIVIND SCANAREA LASER ÎN DOMENIUL FORESTIER

Dezvoltarea tehnologiei de măsurare care folosește impulsuri electromagnetice de tip laser a avut loc concomitent cu realizarea unor progrese importante în domenii variate, precum:

- dezvoltarea și răspândirea Sistemelor de Informații Geografice;
- implementarea primului sistem de poziționare global de către SUA;
- dezvoltarea tehnologiei de poziționare folosind echipamente inerțiale (IMU – *Inertial Measurement Unit*);
- apariția calculatoarelor de tip PC (computer personal) și evoluția capacităților de stocare și procesare a datelor.

Acest cumul de factori a permis răspândirea sistemelor de măsurători laser în toate domeniile în care este necesară cartarea suprafeței terestre.

În silvicultură, potențialul tehnologiei este remarcat încă din anii 1990. Friedrich Ackermann, „părintele” răspândirii tehnologiei LiDAR în comunitatea academică europeană (Carson ș.a., 2004) remarcă faptul că motivația sa inițială pentru cercetarea în domeniul LiDAR a fost dată de nevoile domeniului forestier (ISPRS, 1999). De altfel, primele cercetări cu privire la automatizarea filtrării datelor LiDAR au vizat terenurile acoperite cu vegetație forestieră (Kraus și Pfeifer, 1998). În prezent se poate spune că tehnologia LiDAR a adus o nouă percepție asupra structurii tridimensionale a pădurii, la nivel local sau regional (Bauwens ș.a., 2016).

Potențialul scanării laser pentru domeniul forestier este vast, tehnologia permițând măsurarea unor caracteristici importante ale pădurii. Înregistrarea punctelor la nivelul superior al coronamentului, la nivelul suprafeței terestre, precum și între cele două nivele permite modelarea structurii verticale a pădurii. Primele cercetări privind estimarea structurii arboretelor folosind date LiDAR au fost realizate în 1986 (Maclean și Krabill, 1986 – citat în Lefsky ș.a., 2002). Cercetări ulterioare au dezvoltat în continuare domeniul, prin sporirea numărului de parametri ce pot fi estimați, îmbunătățirea acurateții de modelare a algoritmilor sau testarea în diferite ecosisteme (Popescu ș.a., 2002; Clark ș.a., 2004; Goodwin ș.a., 2006; Van Leeuwen ș.a., 2010; Popescu ș.a., 2011; Birjaru, 2011; Ferraz ș.a., 2016).

Dintre cele mai importante ramuri de cercetare sau aplicative ale silviculturii în care tehnologia LiDAR și-a adus aportul, amintim:

- Inventarierea pădurilor:** primele cercetări privind folosirea tehnologiei LiDAR pentru inventarierea pădurilor au avut loc cu precădere în țările scandinave, începând din anii 1990 (Næsset, 1997; Hyypä ș.a., 2009); ulterior tehnologia s-a răspândit în restul Europei și pe continentul american (Wallace ș.a., 2012).
- Monitorizarea stării de sănătate a pădurii:** deși imaginile satelitare oferite de programele Landsat, MODIS sau SPOT rămân încă cea mai populară sursă de date pentru monitorizarea extensivă a pădurii, Rullan-Silva ș.a. (2013) remarcă faptul că tehnologia

LiDAR devine tot mai populară în acest domeniu (Solberg ș.a., 2004; Vastaranta ș.a., 2013).

- c. **Identificarea arborilor individuali:** densitatea ridicată a observațiilor LiDAR permite în prezent cartografierea structurii pădurii la nivel de arbori individuali, fără necesitatea deplasării în teren (Popescu și Wynne, 2004; Chen ș.a., 2006; Jakubowski ș.a., 2013; Wu ș.a., 2016).
- d. **Estimarea cantității de biomasă:** în acest domeniu de importanță tot mai mare (datorită schimbărilor climatice recente) măsurătorile LiDAR au o tradiție îndelungată, fiind folosite încă din anii 1980 (Nelson ș.a., 1988; Patenaude ș.a., 2004; Popescu ș.a., 2011; Ferraz ș.a., 2016).

În România, tehnologia LiDAR poate fi considerată încă în faza de pionerat. Dintre cercetările realizate în silvicultură, remarcăm folosirea scanării laser pentru: estimarea caracteristicilor structurale ale pădurii (Birjaru, 2011; Petrila ș.a., 2012a; Apostol, 2016), estimarea volumului de masă lemnoasă pe picior pentru arborete de molid (Apostol ș.a., 2012), estimarea cantității de biomasă (Petrila ș.a., 2012b) sau detecția coroanelor (Strâmbu și Strâmbu, 2015).

Majoritatea parametrilor structurali estimați pe baza măsurătorilor LiDAR (de ex. înălțimea coronamentului, înălțimea arborilor individuali, cantitatea de biomasă) necesită modelarea *a priori* a suprafeței terestre (Tinkham ș.a., 2012). Astfel, una din direcțiile de cercetare din domeniu este dezvoltarea algoritmilor de filtrare a măsurătorilor LiDAR, pentru cazul specific al terenurilor acoperite cu vegetație forestieră. Descrierea principalilor algoritmi de filtrare din această categorie se regăsește în **secțiunea 7.4.4.**

Analiza surselor de erori de altimetrie specifice măsurătorilor LiDAR constituie de asemenea o direcție de cercetare importantă (Hopkins ș.a., 2004; Hodgson ș.a., 2005; Aguilar ș.a., 2010; Tinkham ș.a., 2012). Dintre studiile care au urmărit evaluarea acurateții de reprezentare a suprafeței terestre în cazul terenurilor împădurite, menționăm următoarele: Hyypä ș.a. (2000), Reutebuch ș.a. (2003), Hodgson și Bresnahan (2004), Næsset ș.a. (2015), Sterenczak ș.a. (2016), Cățeanu și Arcadie (2017).

Pe lângă faptul că permite determinarea parametrilor structurali ai pădurii, reprezentarea suprafeței terestre poate servi în mod direct la aplicații din domeniul gospodăririi sau exploatării pădurilor. Dintre acestea, amintim posibilitatea identificării sau proiectării drumurilor forestiere (Aruga ș.a., 2005; Pentek ș.a., 2005; White ș.a., 2010), amenajarea căilor de colectare a lemnului (Sterenczak și Moskalik, 2014), alegerea soluțiilor de colectare (Vega-Nieva ș.a., 2009; Mohtashami ș.a., 2012) sau planificarea operațiunilor de exploatare (Chung, 2003).

În privința tendințelor de cercetare recente, se remarcă fuzionarea datelor LiDAR cu alte surse de date (de ex. imagini capturate cu echipamente fără pilot de tip UAV) pentru o modelare mai precisă (Hyde ș.a., 2006; Dalponte ș.a., 2012; Aguilar ș.a., 2019), modelarea de la sol a structurii pădurii folosind echipamente de scanare *fixe* (Moskal și Zeng, 2012; Stovall ș.a., 2017; Schneider ș.a., 2019) sau echipamente instalate pe platforme *mobile* (Strahler ș.a., 2008; Tang ș.a., 2015; Bauwens ș.a., 2016; Liang ș.a., 2018).

6. CARACTERISTICI ALE CONDIȚIILOR DE CERCETARE

6.1. Scopul și obiectivele cercetărilor

Definirea obiectivelor cercetării a pornit de la posibilitatea de obținere a datelor LiDAR înregistrate prin tehnologia scanării laser aeriene (ALS), pentru suprafețe de teren împădurite și cu un grad ridicat de variabilitate sub aspect topografic.

În acest context, s-a stabilit ca **scop al cercetărilor** evaluarea potențialului tehnologiei LiDAR ca sursă de date pentru reprezentarea suprafeței terestre la nivel de detaliu, în domeniul silviculturii.

Pentru atingerea scopului propus, s-au definit o serie de **obiective**:

- a. *Cunoașterea tehnologiei de scanare cu echipament LiDAR*, din perspectivă teoretică și ca aplicabilitate practică generală, dar mai ales în domeniul silviculturii.
- b. *Realizarea unei bibliografii extinse*, cu referire la tehnicile geomaticii forestiere, algoritmi de procesare a datelor LiDAR, studii experimentale privind integrarea tehnologiei LiDAR în domeniul forestier ș.a.
- c. *Obținerea datelor LiDAR*, procesarea preliminară a acestora și delimitarea zonelor de studiu.
- d. *Efectuarea de măsurători geo-topografice în teren*, pentru obținerea datelor independente necesare evaluării preciziei.
- e. *Identificarea acelor etape de procesare* a datelor LiDAR care influențează acuratețea de modelare a suprafeței terestre.
- f. *Procesarea datelor LiDAR*, cu scopul de a obține modele ale suprafeței terestre care vor fi analizate din punct de vedere al acurateții altimetrice.
- g. *Stabilirea unei metodologii de identificare, evaluare și analizare a erorilor* produse de procesarea datelor, pe cât posibil obiectivă și care să permită analiza comparativă a metodelor de procesare alese.
- h. *Interpretarea și analiza rezultatelor*, din prisma distribuției statistice și spațiale a erorilor; estimarea efectului factorilor externi (condiții de teren, vegetație etc.) asupra variației erorilor.
- i. *Elaborarea concluziilor și identificarea contribuțiilor personale*.

6.2. Locul cercetărilor

La noi în țară tehnologia LiDAR nu a cunoscut încă o largă răspândire în domeniul forestier, în principal datorită costurilor ridicate și necesarului de specialiști care să o poată pune în aplicare (Birjaru, 2011). După cunoștințele noastre, această afirmație rămâne valabilă și la momentul elaborării acestei lucrări.

În aceste condiții, singura soluție disponibilă pentru atingerea obiectivelor tezei a fost utilizarea unui set de date LiDAR înregistrate pentru Agenția Națională Apele Române, pus la dispoziție prin amabilitatea Institutului Național de Cercetare-Dezvoltare în Silvicultură „Marin Drăcea”.

Ținând seama de situația expusă anterior, alegerea zonei de studiu s-a făcut pe baza criteriului disponibilității datelor care pot fi utilizate pentru scopurile de cercetare propuse. Astfel, s-au stabilit două areale de cercetare (figura 6.1):

- în *Carpații Meridionali*, în apropierea localității Mălaia, județul Vâlcea (figura 6.2);
- în *Carpații Meridionali*, în apropierea Lacului de acumulare Vidra, județul Vâlcea (figura 6.3).

În ambele locații au fost realizate măsurători LiDAR cu ajutorul platformelor aeropurtate, pentru gestionarea zonelor de risc limitrofe cursurilor de apă (în principal riscul de eroziune). Suprafețele pe care s-au făcut înregistrările cuprind zone împădurite, fiind caracterizate totodată de un relief accidentat, specific regiunii. Datele puse la dispoziție au fost colectate în 2008 și 2011 (pentru arealul *Mălaia*), respectiv în anul 2012 (pentru arealul *Vidra*).

Din punct de vedere geografic, arealul *Mălaia* se înscrie în unitatea de relief *Carpații Meridionali*, regiunea *Munții Căpățâni*. Forma de relief predominantă este versantul, iar panta terenului are valori între 20-30 de grade pe cea mai mare parte a suprafeței, atingând valori maxime de 46 de grade. Altitudinea variază între 480 și 1000 de metri.

Sub aspectul vegetației forestiere, speciile principale sunt molidul și fagul, în arborete pure sau în amestecuri. Vârsta medie a arboretelor de fag este de 60-90 de ani, iar înălțimea medie este de 25-30 metri. Arboretele de molid au o vârstă medie între 80 și 100 de ani, iar înălțimea medie este în jur de 23-25 metri, conform datelor de amenajament.

În ceea ce privește suprafața *Vidra*, aceasta se încadrează în regiunea *Munții Latoriței*, parte a *Carpaților Meridionali*. Forma de relief predominantă este de asemenea versantul, terenul având înclinația între 5 și 35 de grade pe cea mai mare parte a suprafeței. Altitudinea are valori între 1300 și 1900 metri. Suprafața este încadrată în **U.P. IV – Puru, Ocolul Silvic Voineasa**, speciile principale fiind molidul și, într-o mai mică măsură, fagul. Zona sudică a suprafeței este acoperită cu pajiști alpine.

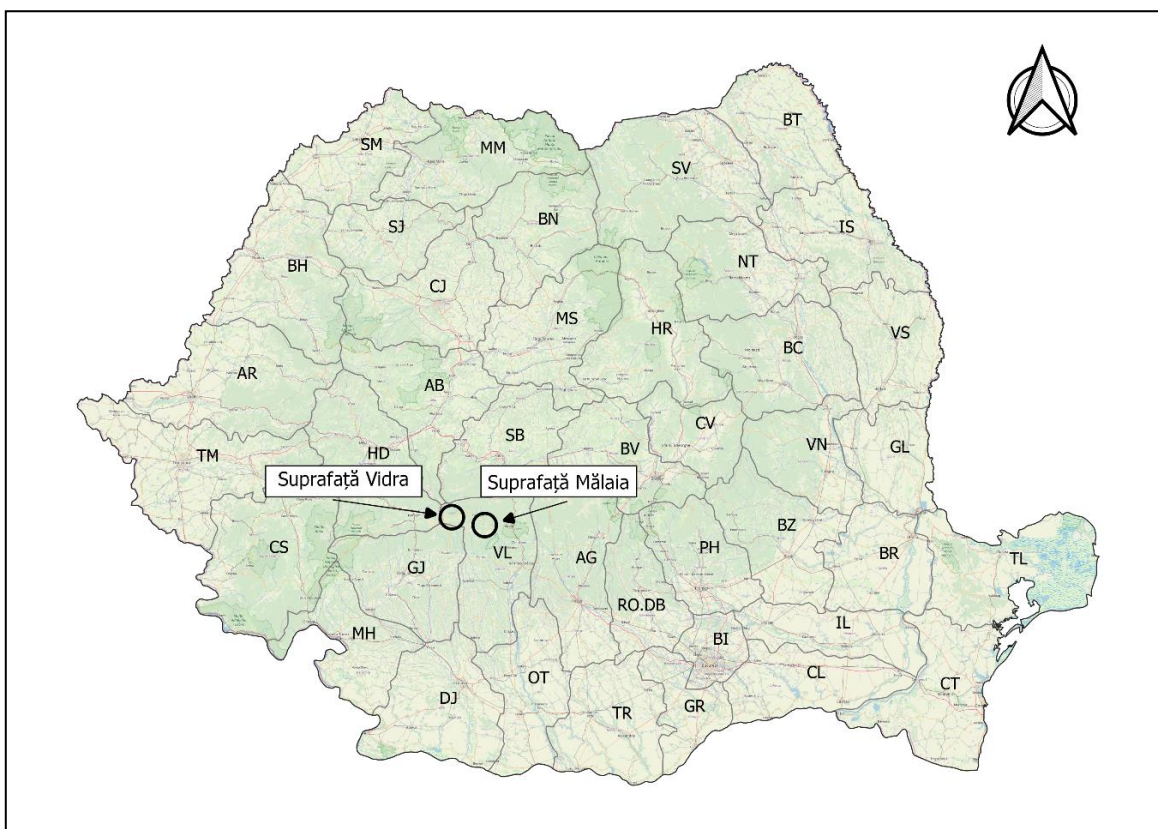


Fig. 6.1. Localizarea suprafețelor cu măsurători LiDAR disponibile.

6.3. Baza de date

6.3.1. Date LiDAR

Datele LiDAR reprezintă suportul de bază în cercetarea de față. Cele două arii descrise anterior au fost cartate prin scanare laser aeriană (ALS - *Airborne Laser Scanning*), rezultând nori de puncte poziționați 3D care descriu suprafața terestră precum și obiectele aflate pe aceasta.

Datele au fost puse la dispoziție de către INCDS „*Marin Drăcea*” în format .las, în formă prelucrată (după ajustarea între benzi) și georeferențiate în sistemul UTM (*Universal Transversal Mercator*) zona 35N, datum *S-42 Pulkovo*.

În ceea ce privește clasificarea norului de puncte, pentru arealul *Mălaia* doar o parte din suprafață este clasificată, restul fiind oferită sub formă de fișiere .las fără clasificare. Pentru arealul *Vidra*, întreg norul de puncte pus la dispoziție este clasificat.

Analiza vizuală a datelor a evidențiat un număr redus de erori de clasificare semnificative, care au fost corectate manual.

Pentru scanarea celor două suprafețe s-a folosit un sistem compus din: senzor laser *Riegl LMS-Q560*, echipament de poziționare globală de tip GPS și sistem inerțial de orientare. Sistemul a fost instalat pe un avion *Diamond Aircraft Industries, model DA42 MPP*.




Fig. 6.2. Delimitarea arealului de studiu *Mălaia*, suprapusă pe imagine satelitară *Bing Maps* (© Microsoft Corporation 2019).




Fig. 6.3 Delimitarea arealului de studiu *Vidra*, suprapusă pe imagine satelitară *Bing Maps* (© Microsoft Corporation 2019).

6.4. Echipamente și instrumente pentru cercetare

6.4.1. Sistemul de scanare laser

Datele LiDAR au fost înregistrate folosind un sistem de scanare laser cu o structură convențională (senzor laser, sistem de poziționare globală de tip GPS și sistem de măsurători inerțiale – IMU) instalat la bordul unei aeronave Diamond Aircraft Industries.

Echipamentul laser model *Riegl LMS-Q560* este un sistem cu măsurare continuă, echipat cu oglindă rotativă poligonală care produce un tipar de scanare sub forma unor linii paralele. Schema constructivă a sistemului se regăsește în figura 6.4.

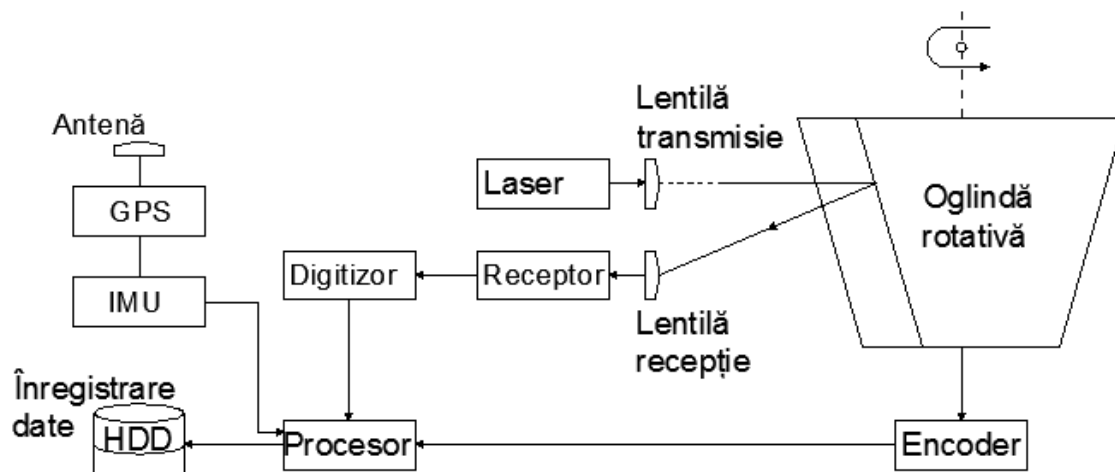


Fig. 6.4. Componenta sistemului de scanare laser LMS-Q560 dezvoltat de compania Riegl
(*Riegl Technical Brochure*)

6.4.2. Instrumente topografice și geodezice

Necesitatea realizării de măsurători topografice cu o precizie de poziționare comparabilă cu cea oferită de sistemul LiDAR a impus folosirea instrumentului de tip stație totală pentru cartarea terenului, respectiv a două echipamente de tip GNSS pentru geo-referențierea măsurătorilor.

Stația totală folosită, model *Leica TCR 407*, are o structură clasică, cu trei părți: componenta mecanică, optică și electronică.

Echipamentul de poziționare globală prin satelit, model *Leica SR20*, a fost folosit pentru georeferențierea măsurătorilor realizate cu stația totală în sistemul de proiecție UTM 35N, permițând astfel suprapunerea măsurătorilor topografice cu datele LiDAR. Dispozitivul *Leica SR20* este un echipament de tip GPS cu 12 canale, în simplă frecvență, care permite determinarea punctelor cu precizie centimetrică, pentru măsurători statice cu post-procesare.

7. METODOLOGIA DE CERCETARE

7.1. Prezentare generală

Unul dintre obiectivele cercetării a fost identificarea acelor etape de procesare a datelor LiDAR care influențează gradul de acuratețe al produsului final (Modelul Digital Altimetric). În urma analizării literaturii de specialitate s-au identificat trei factori principali cu efect asupra acurateții Modelului Digital Altimetric. Aceștia sunt:

1. **Caracteristicile datelor de intrare:** precizie de poziționare, densitatea punctelor, numărul de reflexii per puls etc.; acestea depind de elemente precum: senzorul laser, altitudinea de zbor, viteza de deplasare a platformei, unghiul maxim de scanare sau acoperirea terenului.
2. **Procedura de filtrare a datelor LiDAR,** prin care se urmărește separarea punctelor aflate la sol de punctele reprezentând obstacole aflate deasupra suprafeței terestre (în cazul de față obstacolul este de regulă vegetația forestieră).
3. **Procedura de interpolare a setului de puncte filtrat,** prin care se generează modelul suprafeței terestre.

Întrucât nu a fost posibilă realizarea unui campanii proprii de înregistrări LiDAR, nu s-a putut interveni asupra factorilor din prima categorie. Astfel, cercetarea s-a concentrat asupra ultimelor două categorii de factori care influențează acuratețea de modelare a suprafeței terestre.

Pentru atingerea obiectivelor propuse s-au definit următoarele etape de lucru:

- i. Analiza preliminară a seturilor de date LiDAR disponibile și delimitarea unor suprafețe de studiu.
- ii. Prelucrarea preliminară a datelor LiDAR.
- iii. Planificarea și realizarea măsurătorilor în teren.
- iv. Definirea, calcularea și analiza erorilor produse de **procesul de filtrare** a datelor LiDAR.
- v. Definirea, calcularea și analiza erorilor produse de **procesul de interpolare** a suprafeței.

7.3. Realizarea măsurătorilor geo-topografice

Scopul cercetării îl reprezintă estimarea potențialului de utilizare a tehnologiei LiDAR în silvicultură, ca sursă de date altimetrice pentru modelarea suprafeței terestre. Astfel, încă de la început s-a avut în vedere necesitatea obținerii unui set de date independent, folosit ca bază la estimarea gradului de acuratețe al datelor LiDAR. Un set de măsurători de control ar trebui să aibă un nivel de precizie și o densitate de eșantionare relativ apropiate față de tehnologia LiDAR. Dacă se iau în considerare condițiile de teren specifice scopului urmărit (acoperirea terenului cu vegetație forestieră), rezultă că singura sursă viabilă de date de control o reprezintă măsurătorile geo-topografice realizate cu aparatură modernă, de tip stație totală, geo-referențiate folosind echipament de tip GNSS.

De la bun început, posibilitatea de realizare a măsurătorilor topografice în arealul *Vidra* a fost exclusă, datorită unui cumul de factori: relieful accidentat, densitatea foarte ridicată a arboretului care

îngreunează utilizarea echipamentelor GNSS, precum și lipsa unei infrastructuri rutiere care să permită accesul cu aparatura geo-topografică, în condiții de siguranță.

Astfel, singura variantă fezabilă a reprezentat-o amplasarea suprafețelor de probă în cadrul arealului *Mălaia*. În etapa de planificare s-au stabilit, ca amplasare generală, un număr de opt suprafețe (figura 7.3), la delimitarea cărora s-a avut în vedere:

- situația infrastructurii rutiere, pentru a facilita accesul în condiții de siguranță dar și pentru a asigura apropierea de zone deschise, necesare înregistrărilor GNSS;
- amplasarea în condiții de înclinare a terenului și consistență a vegetației cât mai variate.

Măsurătorile topografice s-au desfășurat în condiții de lucru dificile, cu teren accidentat și vizibilitate îngreunată datorită frunzișului și trunchiurilor arborilor. Luând în seamă și numărul ridicat de puncte de radiat, randamentul redus de lucru a impus limitarea zonelor test la suprafețe de aproximativ 1000-2000 m².

Dintre cele opt suprafețe de probă, șapte au fost amplasate în interiorul pădurii (figura 7.1), cea de-a opta (identificată în continuare cu denumirea **suprafață de referință**) fiind amplasată în exteriorul acesteia, pentru control (figura 7.2).



Fig. 7.1. Suprafața de probă 1, amplasată în interiorul pădurii, în cadrul arealului Mălaia.

Cartarea suprafețelor de probă a presupus amplasarea a 27 puncte de stație, parte a opt drumuiri (cinci sprijinite și trei închise pe punctul de plecare). Pentru geo-referențierea măsurătorilor, coordonatele a 12 dintre punctele de stație (amplasate în zone deschise, în afara pădurii) au fost determinate cu echipamentul GPS *Leica SR-20*, folosind procedeul de măsurare „static cu post-procesare”. Această metodă presune folosirea simultană a cel puțin două receptoare GPS: unul dintre acestea (denumit *bază*) este instalat pe un punct cunoscut, înregistrând date pentru un anumit interval de timp. Un al doilea receptor GPS (denumit *rover*) înregistrează date pentru o serie de puncte noi. Atâta timp cât intervalul de înregistrare al *rover*-ului se încadrează în intervalul de timp în care receptorul

bază este activ, rezultă prin post-procesare o serie de corecții aplicate măsurătorilor care sporesc precizia de poziționare.

În cazul de față, dintre cele 12 puncte poziționate prin GPS, 4 au fost folosite ca bază. S-a folosit o valoare pentru unghiul-mască de 15 grade (ignorarea semnalelor provenite de la sateliți aflați mai jos de 15 grade față de orizont) și un prag minim de 5 vectori (atâta timp cât nu sunt disponibile semnale de la minim 5 sateliți, înregistrarea datelor este întreruptă). Timpul de staționare pentru receptorul *bază* a fost setat la 90 minute (5400 epoci de măsurare), iar pentru echipamentul *rovers*-au staționat câte 30-45 minute (1800-2700 epoci) pe fiecare punct. Toate punctele determinate cu receptorul *rovers*-au aflat la cel mult un kilometru de receptorul *bază* la care au fost legate prin post-procesare. Astfel, majoritatea valorilor pentru indicatorul de precizie PDOP (*Position Dilution of Precision*) se situează în final între 1 și 3.



Fig. 7.2. Suprafața de probă pentru referință, amplasată în afara pădurii (parțial acoperită de o livadă), în cadrul arealului Mălaia.

Caracteristicile generale pentru cele opt suprafețe-test descrise anterior sunt prezentate în tabelul 7.2. Reprezentarea reliefului pentru suprafețele-test este inclusă în **Anexa 1**.

Se observă faptul că, pentru o parte dintre suprafețele de probă, densitatea punctelor rezultate prin măsurători topografice este redusă prin comparație cu densitatea punctelor LiDAR din clasa *Teren* (valori de 0.1-0.2 față de 0.6-0.7). Trebuie amintit însă faptul că, în timp ce punctele LiDAR sunt distribuite aleatoriu, măsurătorile topografice sunt realizate manual, astfel că pot surprinde variația topografică prin mai puține puncte măsurate.

Tabelul 7.2. Caracteristici generale pentru suprafețele test delimitate în cadrul măsurătorilor topografice.

Nr. suprafață	Suprafață (m ²)	Densitate puncte măsurători topografice (pct/m ²)	Înclinare medie (grade)	Grad de acoperire vegetație (%)	Densitate puncte LiDAR la sol (pct/m ²)
1	1184	0.14	25.4	95.0	0.2
2	988	0.16	27.1	96.7	0.2
3	688	0.21	33.6	92.6	0.4
4	1045	0.16	18.9	97.0	0.3
5	1856	0.12	19.1	84.3	0.7
6	1584	0.20	12.5	90.9	0.6
7	889	0.21	21.4	77.9	0.7
8 (Supr. referință)	2652	0.05	13.9	22.3	2.8
Medie aritmetică	1360.8	0.16	21.5	82.2	0.7
Abatere standard	644.5	0.05	7.0	24.8	0.9

7.4. Filtrarea datelor LiDAR. Determinarea erorilor de filtrare.

7.4.2. Zona de studiu pentru analiza procesului de filtrare

Determinarea erorilor de filtrare s-a făcut în două variante:

- i. prin comparare cu setul de LiDAR filtrat corect, referința fiind clasificarea pusă la dispoziție de către INCDS „*Marin Drăcea*”;
- ii. prin compararea cu o sursă de date independentă (măsurători geo-topografice).

Pentru prima variantă s-a delimitat o suprafață extinsă, acoperind aproximativ 1.2 km² (figura 7.3). Prin delimitarea suprafeței s-a urmărit surprinderea unui relief complex, cu expoziții variate și factor de fragmentare ridicat (figura 7.4). În cadrul acesteia, densitatea punctelor LiDAR este de 14.7 puncte/m², densitatea punctelor din clasa *Teren* este de 1.7 puncte/m², panta medie are valoarea de 33 de grade iar gradul de acoperire cu vegetație este de 83 la sută. Pentru claritate, această suprafață va fi identificată în continuare ca **suprafața de probă A**.

Estimarea impactului filtrării asupra acurateții de reprezentare a suprafeței terestre s-a făcut deci pentru:

- i. suprafața de probă A;
- ii. suprafețele de probă 1-8, măsurate în teren.

Menționăm că dintre cele opt suprafețe de probă pentru care s-au realizat măsurători topografice, suprafața nr. 3 este amplasată în interiorul **suprafeței de probă A**, iar restul se află în imediata vecinătate a acesteia (figura 7.3).

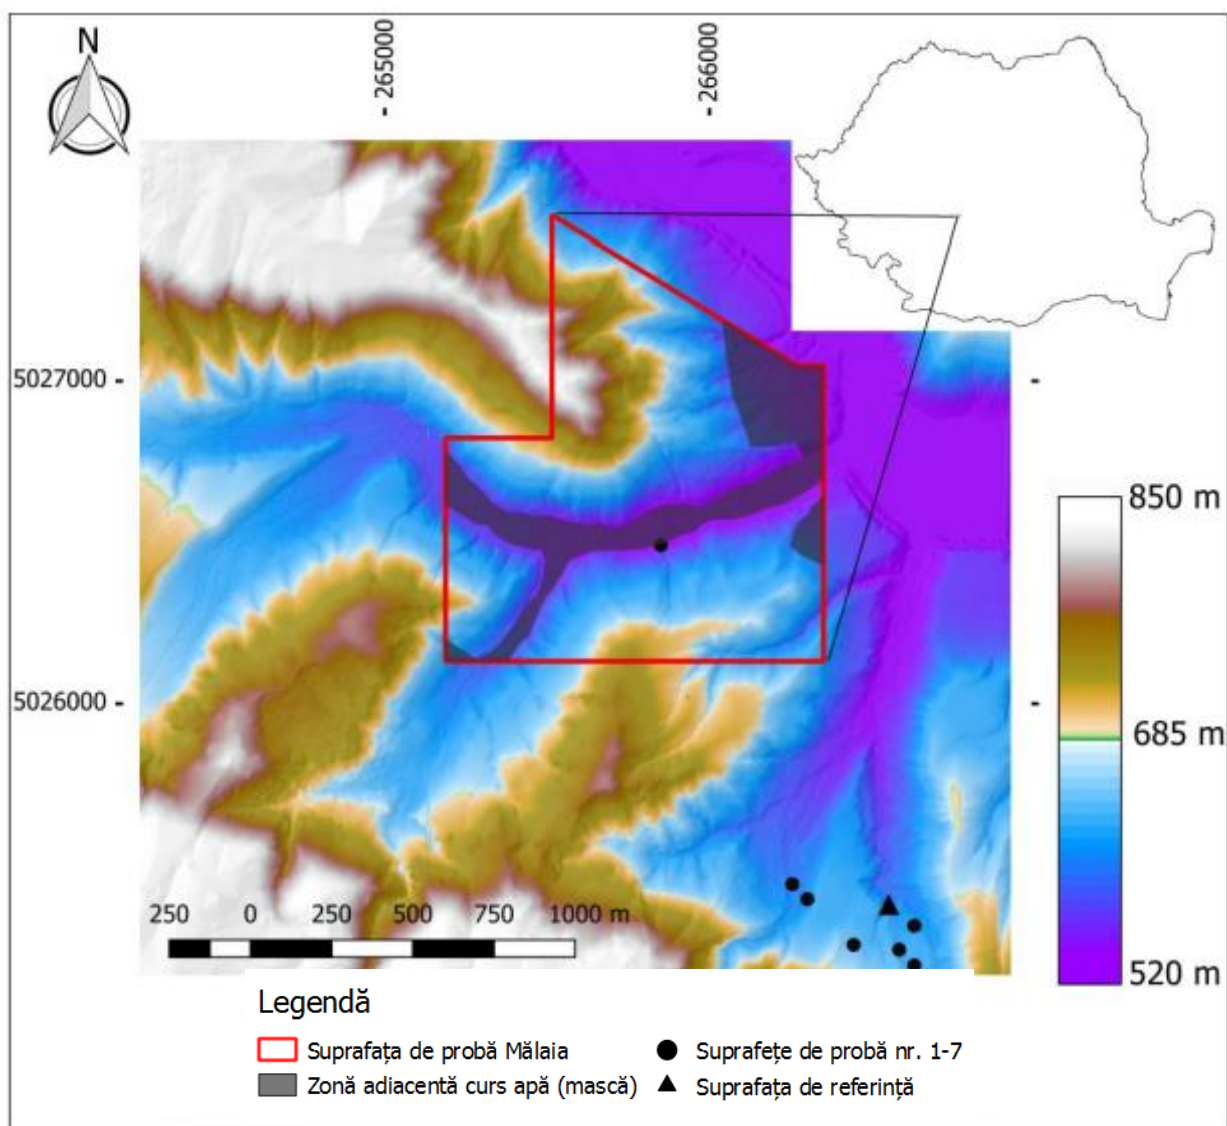


Fig. 7.3. Hartă cu amplasamentul pentru suprafețele pentru care s-au analizat erorile de filtrare a datelor LiDAR. Sistem de proiecție: UTM zona 35N.




Fig. 7.4. Model Digital Altimetric pentru suprafața de studiu A, aleasă pentru analiza erorilor de filtrare (*factor de exagerare verticală: 1.5*).

7.4.3. Definirea erorii de filtrare

Pentru determinarea erorilor verticale datorate filtrării s-au parcurs următoarele etape:

- i. filtrarea norului de puncte;
- ii. generarea prin interpolare a unui model *raster* pentru suprafața terenului (cu rezoluția de 0.5 metri) folosind ca date de intrare norul de puncte obținut în urma filtrării;
- iii. suprapunerea modelului *raster* cu un model al suprafeței *de referință*, obținut tot prin interpolare, pe baza datelor de control;
- iv. determinarea *erorii verticale*, pentru fiecare celulă a modelului, ca diferența dintre valorile de altitudine asociate celei în cadrul celor două modele.

Rezultă astfel un model *raster* al erorilor, ale cărui celule se suprapun cu celulele suprafețelor interpolate. Pe baza acestui model, s-au calculat o serie de indicatori generali ai acurateții suprafeței:

- i. eroarea medie, al cărei semn (pozitiv sau negativ) indică tendința de supra-estimare sau sub-estimare a altitudinii;
- ii. eroarea medie absolută, indicator general al gradului de apropiere dintre suprafața obținută și suprafața de referință;
- iii. eroarea medie pătratică (RMSE – *Root Mean Square Error*), indicator global al calității produsului, din punct de vedere al acurateții.

Eroarea medie pătratică s-a calculat cu formula (Li, 1988):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n E_{(i)}^2}{n-1}} \quad [7.1]$$

unde:

- RMSE este eroarea medie pătratică;
- $E_{(i)}$ eroarea verticală asociată celulei i ;
- n numărul de celule ale modelului.

7.4.4. Alegerea algoritmilor de filtrare

La alegerea algoritmilor s-a urmărit ca aceștia să se încadreze în categorii diferite, ca metodă de filtrare. De asemenea, s-au ales atât algoritmi de filtrare generali, cât și algoritmi specifici pentru filtrarea terenului acoperit de vegetație forestieră. Un alt considerent a fost includerea (în măsura posibilităților) a algoritmilor disponibili în mod gratuit, în detrimentul programelor comerciale.

În final, a rezultat un set de nouă algoritmi de filtrare, șapte dintre care sunt disponibili gratuit. În funcție de modul de lucru, aceștia se încadrează în trei categorii principale (Cățeanu și Arcadie, 2017):

A. Algoritmi bazați pe interpolarea de suprafețe:

- **GroundFilter**
- **Height Filtering**
- **Multiscale Curvature Classification**
- **gLidar**

B. Algoritmi care folosesc metoda TIN-adaptation (adaptarea Rețelei Neregulate de Triunghiuri)

- **Lasground**
- **Lasground-new**

C. Algoritmi bazați pe morfologia matematică

- **Elevation Threshold with Expand Filter**
- **Maximum Local Slope**
- **Simple Morphological Filter**

7.4.5. Optimizarea procesului de filtrare

Fiecare dintre algoritmii de filtrare aleși pentru analiza acurateții implică setarea unor parametri de către utilizator, prin care se controlează procesul de filtrare. Acolo unde prin studierea literaturii de specialitate s-au găsit menționate valorile optime pentru parametri, acestea au fost folosite. Unde acest lucru nu a fost posibil, s-a apelat la următoarea procedură:

- i. pentru fiecare algoritm, se pornește de la valorile standard ale parametrilor;
- ii. valoarea fiecărui parametru se modifică (în plus sau minus), rezultatele fiind analizate vizual;
- iii. dacă modificarea parametrului nu afectează rezultatul filtrării în mod vizibil, parametrul se elimină din analiză, rămânând la valoarea standard;

- iv. dacă modificarea parametrului are efect vizibil asupra filtrării, se continuă modificarea acestuia până când valoarea nu mai apar modificări vizibile - rezultă astfel o listă de valori de testat pentru fiecare parametru;
- v. pentru a testa interacțiunea dintre parametri, se realizează combinațiile dintre valorile alese ca fiind reprezentative pentru fiecare parametru.

Prin procedura descrisă mai sus, a rezultat un număr de combinații ale valorilor parametrice pentru fiecare algoritm, situat între 25 (pentru algoritmul *ETEW*) și 104 (pentru algoritmul *Groundfilter*). În total, pentru cei nouă algoritmi s-au analizat 568 de combinații.

Analizarea unei combinații de valori parametrice presupune următoarele etape:

- i. filtrarea datelor LiDAR pentru *suprafața de probă A*, folosind setul de valori parametrice pentru combinația curentă;
- ii. generarea unui model al suprafeței cu rezoluția de 1.0 metri, prin interpolare cu algoritmul IDW (*Inverse Distance Weighted*), folosind setul de puncte filtrate;
- iii. calcularea erorii medii pătratice a modelului, pe baza erorilor verticale ale celulelor (diferența de altitudine dintre modelul interpolat și suprafața de referință);
- iv. pentru fiecare algoritm, se identifică acea combinație de parametri care conduce la cea mai precisă modelare a suprafeței terestre (cea mai mică valoare pentru eroarea medie pătratică).

Rezultă astfel nouă seturi de puncte filtrate, câte unul pentru fiecare dintre algoritmi testați. Aceste seturi de date sunt folosite în continuare pentru analiza comparativă între algoritmi.

7.4.6. Distribuția spațială a erorilor de filtrare

Norul de puncte LiDAR, ca obiect asupra căruia se aplică procedura de filtrare a observațiilor, este orientat în spațiu – fiecărui punct i se asociază un set de coordonate X, Y, Z . Astfel, filtrarea datelor LiDAR este un proces cu o componentă spațială. Este de interes deci analizarea erorilor de filtrare nu doar ca distribuție spațială, ci și ca distribuție în spațiu. Pentru a reduce din variabilitatea erorilor de filtrare, cu scopul de a simplifica analiza, s-au delimitat o serie de clase ale erorilor verticale, astfel:

- erori foarte reduse, între 0.0 și 0.2 metri;
- erori reduse, între 0.2 și 0.5 metri;
- erori semnificative, între 0.5 și 1.0 metri;
- erori majore, peste 1 metru.

După clasificarea erorilor, s-au generat hărțile cu distribuția spațială a claselor și s-a calculat suprafața acoperită de fiecare dintre clase.

De asemenea, s-a analizat gradul de auto-corelație spațială a erorilor de filtrare, sau măsura în care erorile tind să se organizeze spațial în grupuri cu valori apropiate. Cu alte cuvinte, auto-corelația spațială determină gradul în care o observație influențează sau depinde de observațiile aflate în apropiere. O grupare a unui număr de valori apropiate, care depășește probabilitatea de grupare aleatorie poartă numele de *cluster* (Webster și Oliver, 2007). Gruparea unor valori mai mari decât

media setului de observații se numește *cluster pozitiv*, iar gruparea unor valori mai mici decât media setului de observații se numește *cluster negativ*. Pentru cuantificarea gradului de auto-corelație spațială, s-a folosit tehnica LISA¹ propusă de Anselin (1995).

Analiza distribuției spațiale a erorilor s-a efectuat pentru *suprafața de probă A*, în cazul filtrării cu ajutorul algoritmilor: *Lasground-new*, *MLS* și *gLiDAR*.

7.4.7. Factori de influență a erorilor de filtrare

Este de așteptat ca erorile de filtrare să fie influențate de condițiile de teren și de caracteristicile datelor LiDAR. Factorii care au fost identificați ca având o potențială legătură cu amplitudinea erorilor sunt:

- a. *Înclinarea terenului*, care s-a determinat pe baza Modelului Digital Altimetric de referință.
- b. *Rugozitatea suprafeței terenului*, calculată pe baza Indicelui de Rugozitate al Terenului (TRI^2).

Indicele de Rugozitate al Terenului cuantifică gradul de omogenitate topografică a suprafeței terestre, prin prisma diferențelor de nivel dintre celulele Modelului Digital Altimetric (Riley ș.a., 1999). Calcularea indicelui se face pentru fiecare celulă a modelului în parte, cu formula:

$$TRI = \sqrt{\frac{\sum_{i=1}^3 \sum_{j=1}^3 (Z_{ij} - Z_0)^2}{8}} \quad [7.3]$$

unde:

- TRI este Indicele de Rugozitate al Terenului;
 - Z_0 altitudinea celulei curente;
 - Z_{ij} altitudinea pentru cele 8 celule învecinate celulei curente.
- c. *Curbura maximă a suprafeței*, este valoarea maximă dintre curbura în profil și curbura în plan a suprafeței.
 - d. *Gradul de acoperire cu vegetație*, pentru estimarea căreia s-au folosit acele observații din setul de date LiDAR care sunt atribuite altor clase decât *Teren* (de regulă *Vegetație joasă*, *Vegetație medie* sau *Vegetație înaltă*). Determinarea densității s-a făcut într-o rețea rectangulară de celule, cu formula (McGaughey, 2004):

$$\delta_i = \frac{n}{N} * 100 \quad [7.4]$$

unde:

- δ_i este densitatea coronamentului (exprimată în procente) pentru celula i ;

¹ Local Indicator of Spatial Association – Indicator Local al Asocierii Spațiale.

² Terrain Ruggedness Index.

- n numărul de puncte din celula i situate deasupra unui prag de înălțime ales (în cazul de față, doi metri deasupra terenului);
- N numărul total de puncte din interiorul celulei i .

e. *Densitatea punctelor LiDAR*, care s-a determinat sub forma unei rețele de celule rectangulare, cu suprafața de 1 m^2 , pentru fiecare celulă fiind calculat numărul de puncte aflate în interiorul acesteia. Pentru reducerea nivelului de zgomot al modelului, s-a aplicat un filtru de medie cu dimensiunea ferestrei de 5×5 celule.

Limitele claselor sunt prezentate în tabelul 7.4. În lipsa unor valori standardizate, clasele s-au delimitat în funcție de distribuția statistică a valorilor. Semnificația atribuită claselor este una descriptivă, relativă la suprafața aleasă pentru analiza procesului de filtrare (suprafața de probă *Mălaia*).

Distribuția spațială a factorilor analizați, reprezentată grafic sub formă de hărți tematice, se regăsește în **Anexa 2**.

Pentru analizarea efectului factorilor de influență menționați asupra erorilor, s-au ales trei dintre algoritmi de filtrare ca fiind reprezentativi, câte unul din fiecare categorie. Aceștia sunt:

- *gLiDAR*, pentru clasa algoritmilor bazați pe interpolarea de suprafețe.
- *Lasground-new*, pentru clasa de algoritmi bazați pe adaptarea Rețelei de Triunghiuri Neregulate (TIN).
- *MLS*, pentru algoritmi de tip morfologic.

Tabelul 7.4. Gruparea pe clase a factorilor luați în considerare la analiza erorilor de filtrare.

Factor	Nr. clasă	Limite clasă		Semnificație
		Inferioară	Superioară	
Înclinarea terenului (grade)	1	0	10	Înclinare foarte redusă
	2	10	20	Înclinare redusă
	3	20	30	Înclinare medie
	4	30	40	Înclinare ridicată
	5	40	50	Înclinare foarte ridicată
	6	50	-	Înclinare extremă
Indicele de Rugozitate a Terenului – TRI (adimensional)	1	0.00	0.25	Fără rugozitate
	2	0.25	0.50	Rugozitate redusă
	3	0.50	0.75	Rugozitate medie
	4	0.75	1.00	Rugozitate ridicată
	5	1.00	-	Rugozitate foarte ridicată
Curbura maximă (adimensional)	1	0.00	0.25	Curbură foarte redusă
	2	0.25	0.50	Curbură redusă
	3	0.50	0.75	Curbură medie
	4	0.75	1.00	Curbură ridicată
	5	1.00	-	Curbură foarte ridicată
Gradul de acoperire cu vegetație (procente)	1	0	10	Teren descoperit
	2	10	40	Acoperire redusă
	3	40	60	Acoperire medie
	4	60	80	Acoperire ridicată
	5	80	100	Acoperire foarte ridicată
Densitate set de observații LiDAR (puncte/m ²)	1	0.0	5.0	Densitate foarte redusă
	2	5.0	10.0	Densitate redusă
	3	10.0	15.0	Densitate medie
	4	15.0	20.0	Densitate ridicată
	5	20.0	25.0	Densitate foarte ridicată

7.5. Interpolarea suprafeței terenului. Determinarea erorilor de interpolare.

7.5.2. Zona de studiu pentru analiza procesului de interpolare

Pentru estimarea și analizarea erorilor de interpolare, s-a folosit setul de date LiDAR pentru arealul *Vidra*. Întrucât acesta are o formă neregulată (figura 6.3) care poate influența negativ procesul de interpolare, s-a delimitat o zonă sub formă regulată de paralelogram, în interiorul acestui areal (figura 7.5). Totodată, prin această delimitare s-a eliminat secțiunea sudică din setul de date, lipsită de vegetație forestieră. A rezultat *suprafața de probă Vidra*, care acoperă 160 de hectare, pe care vegetația forestieră este prezentă aproape în întregime. Altitudinea variază între 1350 și 1750 metri și înclinarea medie a terenului este de 26 de grade. Densitatea medie a observațiilor LiDAR, reprezentată de numărul de puncte pe unitatea de suprafață, este de 5.2 puncte/m², respectiv 0.9 puncte/m² pentru punctele atribuite clasei *Teren*.

7.5.3. Date pentru validarea interpolării

După cum s-a menționat anterior, din considerente de timp, costuri și siguranță, nu s-au putut efectua măsurători topografice în arealul *Vidra*. Astfel, fără o sursă de date independente, care să poată servi ca referință pentru estimarea erorilor de interpolare, s-a recurs la metoda numită *cros-validare* (Davis, 1987). Tehnica este folosită în mod uzual în studiile de analiză a erorilor de măsurare, în situația în care nu sunt disponibile măsurători independente pentru validare (Anderson ș.a., 2005; Aguilar, 2005).

În esență, metoda presupune împărțirea, în mod aleatoriu, a setului de observații în două subseturi: unul pentru *predicție* (care cuprinde majoritatea observațiilor) și unul pentru *validare* (care cuprinde o mică parte dintre observații). Pentru cercetarea de față, s-a optat pentru o împărțire 95 procente observații pentru *predicție* cu 5 procente observații pentru *validare*. Proportia a fost aleasă pentru ca testarea acurateții să fie semnificativă, dar fără a se compromite integritatea datelor de predicție (Bater și Coops, 2009).

Astfel, din setul de observații LiDAR inițial, s-a extras aleatoriu un număr reprezentând 5 procente din total ($n = 52358$), care au servit la validare. Restul de 95 de procente din observații (aprox. 1.06 milioane puncte) au fost folosite pentru interpolare.

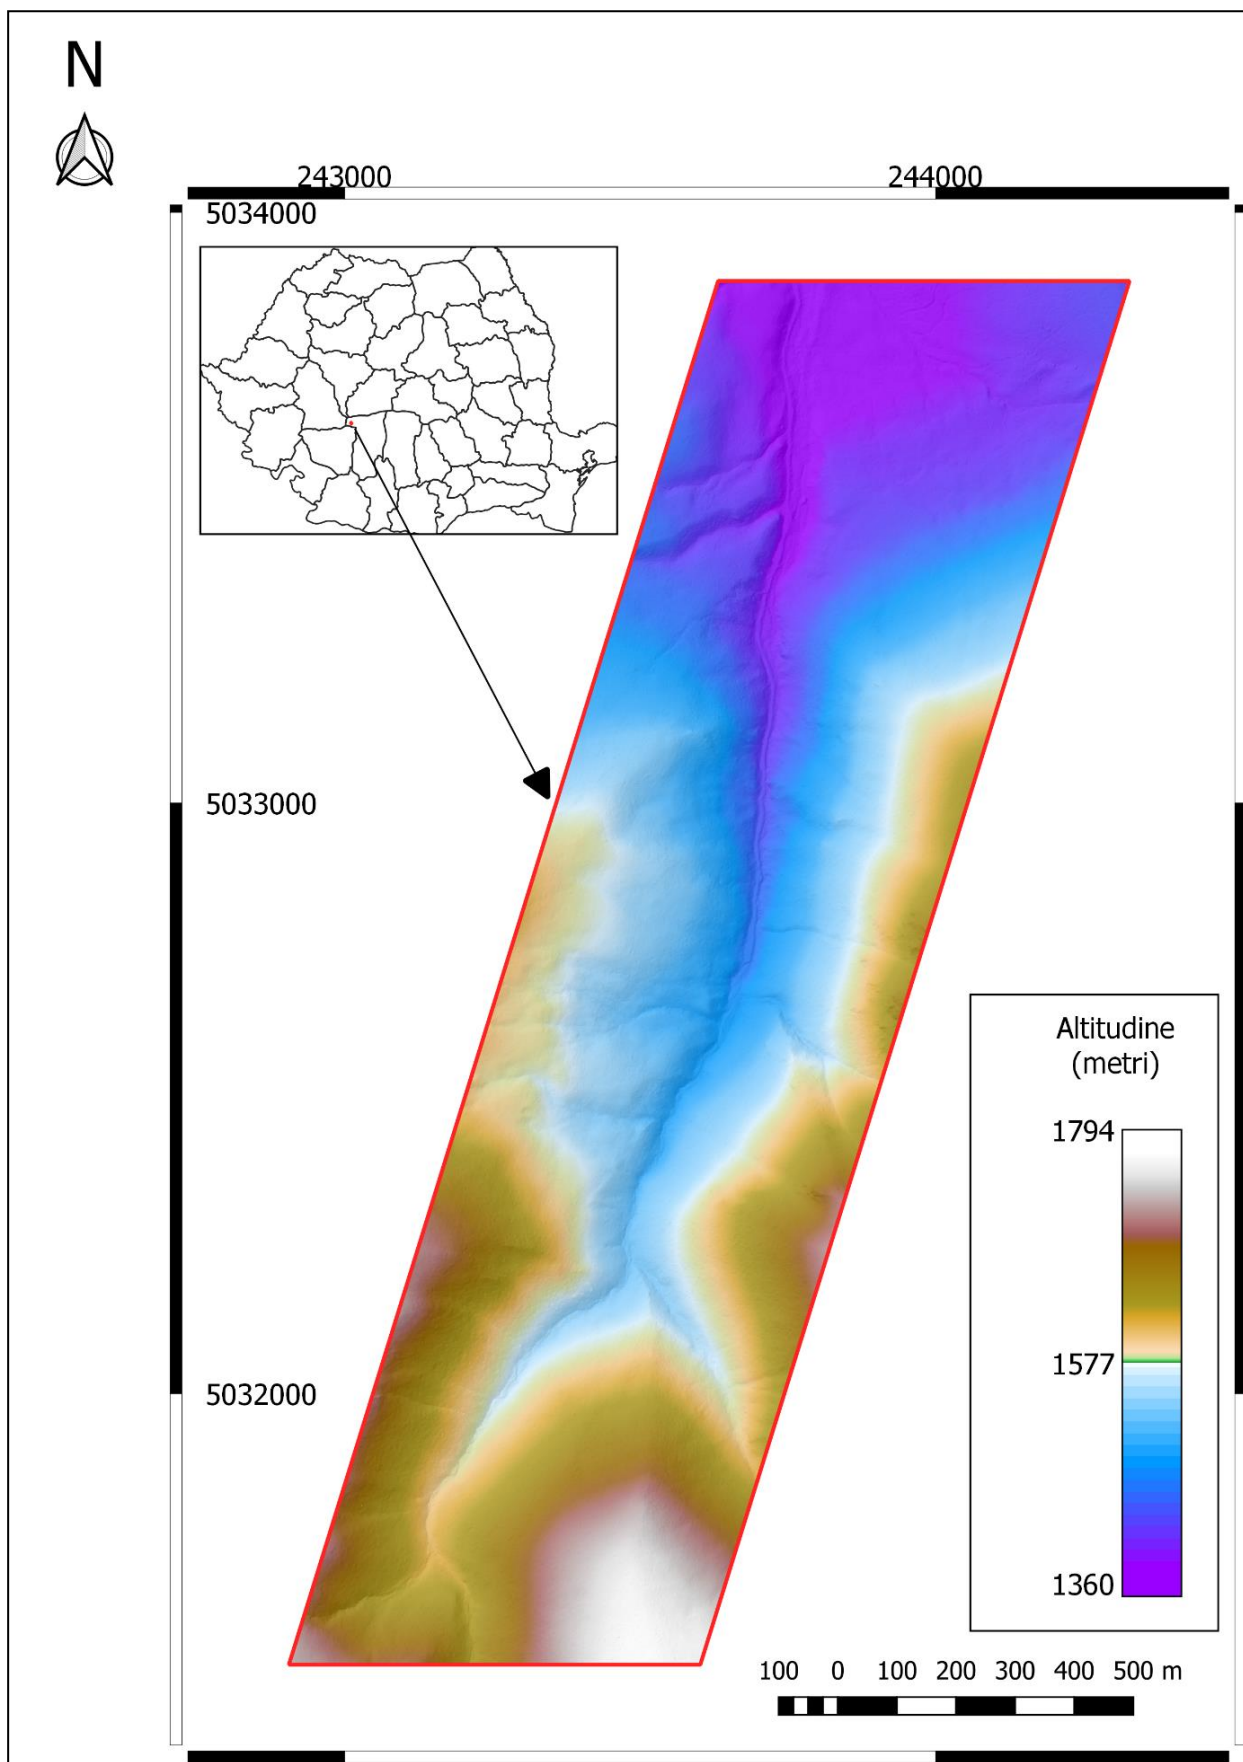


Fig. 7.5. *Suprafața de probă Vidra*, delimitată pentru analiza procesului de interpolare.

7.5.4. Definirea erorii de interpolare

Interpolarea urmărește generarea unei suprafețe continue pornind de la un set de observații discrete. Astfel, este necesară estimarea valorilor pentru locații unde nu există observații, deci procesul este afectat de un anumit grad de incertitudine. Această incertitudine se poate cuantifica prin determinarea și analizarea erorilor de interpolare. Pentru aceasta, suprafața interpolată se suprapune cu observațiile de validare. Pentru fiecare din punctele de validare se cunosc două valori: cea specifică punctului (considerată corectă) și cea interpolată (considerată incertă). Astfel, pentru fiecare punct de validare se poate calcula eroarea de interpolare, cu formula:

$$E_{(i)} = Z_{DTM(i)} - Z_{LiDAR(i)} \quad [7.5]$$

unde:

- $E_{(i)}$ este eroarea verticală pentru punctul i ;
- $Z_{DTM(i)}$ valoarea interpolată pentru poziția planimetrică a punctului i ;
- $Z_{LiDAR(i)}$ valoarea de altitudine a punctului i , așa cum a rezultat în urma măsurărilor.

Odată calculate erorile verticale individuale pentru cele n puncte de validare, o serie de indicatori statistici oferă informații privind acuratețea generală a suprafeței interpolate:

- i. eroarea medie, al cărei semn (pozitiv sau negativ) indică prezența unei tendințe de supra-estimare sau sub-estimare a valorilor de elevație;
- ii. eroarea medie absolută, indicator general al gradului de apropiere dintre suprafața obținută și suprafața de referință;
- iii. eroarea medie pătratică (RMSE), calculată cu formula 7.1.

7.5.5. Alegerea algoritmilor de interpolare

Până în prezent, s-au dezvoltat numeroase metode de interpolare, menite să estimeze valorile pentru locații ne-eșantionate (Mitas și Mitsova, 1999). Astfel, s-a remarcat necesitatea de a testa mai mulți algoritmi de interpolare, pentru a realiza analiza comparativă a gradului de acuratețe oferit de aceștia. La alegerea algoritmilor s-a urmărit ca aceștia să fie de diferite tipuri (conform clasificării descrise în **secțiunea 4.4.2**). De asemenea, s-a ținut seama de faptul că același algoritm, implementat în programe software diferite, nu produce în mod necesar rezultate identice (Pietrzak, 2013, citat în Sterenczak, 2016). Din acest motiv, s-a urmărit ca algoritmi selectați să fie disponibili într-un pachet software comun.

În final s-a selectat un număr de nouă algoritmi, enumerați în continuare:

- **Inverse Distance Weighted (IDW)**
- **Nearest Neighbour (NeN)**
- **Natural Neighbour (NN)**
- **Delauney Triangulation (DT)**

- **Ordinary Kriging (OK)**
- **Algoritmi Radial Basis Functions (RBF): Multilevel B-Spline (BS), Cubic Spline (CS), Thin Plate Spline (TPS), Thin Plate Spline with TIN (TPS_{TIN}).**

Pentru a reduce efectul de margine, la toate interpolările a fost folosită o zonă-tampon (buffer) care înconjoară zona de studiu la distanța de 5 metri.

7.5.6. Alegerea rezoluției spațiale pentru modelul suprafeței

Rezoluția modelului de suprafață (dată de dimensiunea celulelor rețelei) este unul dintre factorii care influențează acuratețea reprezentării. Din acest motiv, s-a considerat că este oportună analiza modelelor la diferite rezoluții spațiale. Un model al suprafeței care să conserve cea mai mare parte din informația setului de date inițial ar avea o mărime a celulei egală cu jumătate din media spațierii minime dintre perechile de puncte (Bater și Coops, 2009).

În cazul de față, media distanțelor minime dintre puncte are valoarea de 0.56 metri. Întrucât testarea unei rezoluții spațiale de 0.25-0.30 metri implică resurse de procesare semnificative, s-au testat următoarele rezoluții: 0.5, 1.0, 1.5 și 2.0 metri. Astfel, pentru cei nouă algoritmi de interpolare, unii dintre ei cu mai multe variante de setare a parametrilor, au rezultat în final 92 de modele *raster* de analizat (câte 23 de modele pentru fiecare rezoluție).

7.5.7. Factori de influență a erorilor de interpolare

Analiza literaturii de specialitate din domeniu a scos la iveală o serie de factori externi care pot avea efect asupra mărimii erorilor de interpolare. O parte dintre aceștia au putut fi calculați folosind datele avute la dispoziție, astfel că au fost incluși în analiză.

Factorii luați în considerare pentru procesul de *interpolare* sunt aceiași cu factorii identificați pentru procesul de *filtrare* a datelor LiDAR:

- a. *Înclinarea terenului.*
- b. *Indicele de Rugozitate al Suprafeței (TRI – Terrain Rugedness Index).*
- c. *Curbura maximă a suprafeței.*
- d. *Gradul de acoperire cu vegetație.*
- e. *Densitatea punctelor de predicție.*

Descrierea factorilor menționați mai sus se regăsește în **secțiunea 7.4.7**.

Pentru analiza stratificată a erorilor, factorii amintiți mai sus au fost grupați pe clase. Limitele claselor pentru fiecare factor sunt prezentate în tabelul 7.6. În lipsa unor valori standardizate, clasele s-au delimitat în funcție de distribuția statistică a valorilor. Semnificația atribuită claselor este una descriptivă, specifică suprafeței pentru care s-a analizat procesul de interpolare (arealul *Vidra*).

Distribuția spațială a factorilor analizați, reprezentată grafic sub formă de hărți tematice, se regăsește în **Anexa 3**.

Tabelul 7.6. Gruparea pe clase a factorilor luați în considerare la analiza erorilor de interpolare.

Factor	Nr. clasă	Limite clasă		Semnificație
		Inferioară	Superioară	
Înclinarea terenului (grade)	1	0	10	Înclinare foarte redusă
	2	10	20	Înclinare redusă
	3	20	30	Înclinare medie
	4	30	40	Înclinare ridicată
	5	40	50	Înclinare foarte ridicată
	6	50	-	Înclinare extremă
Indicele de Rugozitate a Terenului – TRI (adimensional)	1	0.00	0.10	Fără rugozitate
	2	0.10	0.20	Rugozitate redusă
	3	0.20	0.30	Rugozitate medie
	4	0.30	0.40	Rugozitate ridicată
	5	0.40	0.50	Rugozitate foarte ridicată
Curbură maximă (adimensional)	1	0.00	0.25	Curbură foarte redusă
	2	0.25	0.50	Curbură redusă
	3	0.50	0.75	Curbură medie
	4	0.75	1.00	Curbură ridicată
	5	1.00	-	Curbură foarte ridicată
Gradul de acoperire cu vegetație (procente)	1	0	10	Teren descoperit
	2	10	40	Acoperire redusă
	3	40	60	Acoperire medie
	4	60	80	Acoperire ridicată
	5	80	100	Acoperire foarte ridicată
Densitatea punctelor de predicție (pct/m ²)	1	0.00	0.25	Densitate foarte redusă
	2	0.25	0.50	Densitate redusă
	3	0.50	0.75	Densitate medie
	4	0.75	1.00	Densitate ridicată
	5	1.00	-	Densitate foarte ridicată

8. REZULTATE ȘI DISCUȚII

8.1. Filtrarea datelor LiDAR.

8.1.1. Precizări generale

Filtrarea datelor LiDAR, identificată ca una dintre sursele de erori care influențează calitatea Modelului Digital Altimetric, a fost analizată prin testarea a nouă algoritmi de filtrare (enumerați în tabelul 7.3). Procesul de filtrare s-a realizat în două variante (**secțiunea 7.4.2**):

- i. Pentru o suprafață extinsă, de aprox. 1.2 km², identificată ca *suprafața de probă A* în cadrul arealului *Mălaia* (figura 7.3); evaluarea acurateții de filtrare s-a făcut prin compararea cu datele LiDAR clasificate corect, așa cum au fost puse la dispoziție de INCDS „*Marin Drăcea*”.
- ii. Pentru opt suprafețe de probă, în care s-au efectuat măsurători geo-topografice, identificate ca *suprafețe de probă nr. 1-8* (figura 7.3); evaluarea acurateții de filtrare s-a făcut în acest caz prin compararea cu măsurătorile geo-topografice, ca sursă de date independentă.

Pentru fiecare situație analizată s-au calculat valorile pentru eroarea medie și pentru eroarea medie pătratică (RMSE) – acestea sunt prezentate în tabelul 8.1.

În primul rând, pentru *suprafața de probă nr. 8* (care a fost delimitată în afara domeniului forestier, pentru a servi ca referință – figura 7.2) se remarcă faptul că valorile pentru eroarea medie și eroarea medie pătratică (RMSE) sunt similare pentru majoritatea algoritmilor de filtrare. Pe această suprafață terenul este în mare parte descoperit, astfel că filtrarea norului de observații LiDAR se desfășoară în condiții optime. Astfel, șapte dintre algoritmi (*MCC*, *gLiDAR*, *Lasground*, *Lasground-new*, *ETEW*, *MLS* și *SMRF*) au valori ale RMSE între 0.25 și 0.27 metri, în timp ce valorile erorii medii sunt de 0.10-0.11 metri, indicând o supra-estimare minoră a altitudinii. Ceilalți doi algoritmi de filtrare, *Groundfilter* și *BCAL* au o performanță mult mai scăzută, valorile indicelui RMSE asociate acestora fiind de 0.50 și respectiv 0.49 metri. Cei doi algoritmi au o ușoară tendință de sub-estimare a altitudinii, având valori ale erorii medii de -0.10 și respectiv -0.11 metri.

Se poate deci afirma că o valoare de 0.25-0.30 metri pentru eroarea medie pătratică reprezintă o referință față de care se pot raporta celelalte rezultate, pentru suprafețele în care condițiile de filtrare nu sunt optime (datorită prezenței vegetației forestiere).

În ceea ce privește *suprafețele de probă nr. 1-7*, amplasate în interiorul pădurii, se observă diferențe semnificative ale erorilor de filtrare. Eroarea medie pătratică variază de la o suprafață de probă la alta, chiar dacă algoritmul rămâne constant. Spre exemplu, algoritmul *SMRF* are valori ale erorii medii pătratice între 0.32 metri pentru suprafața de probă 6 și 1.30 metri pentru suprafața de probă 3. Diferențe apar și între algoritmi, la filtrarea punctelor pentru aceeași suprafață de probă. De exemplu, pentru *suprafața de probă 6* eroarea medie pătratică are valori între 0.31 și 2.02 metri.

Pentru *suprafața de probă A*, indicele RMSE are valori între 0.34 și 2.25 metri, în timp ce eroarea medie relativă indică o minoră supra-estimare a altitudinii terenului pentru toți algoritmi, în afară de *BCAL*. Analiza erorilor asociate acestei suprafețe confirmă observațiile pentru *suprafețele de probă 1-*

7, care au o întindere mai redusă. Astfel, se remarcă o performanță relativ scăzută a algoritmilor *BCAL* și *Groundfilter*, în timp ce între ceilalți algoritmi performanța este în general apropiată.

Algoritmii de filtrare care au fost testați se împart în trei categorii principale: algoritmi bazați pe interpolare (*Groundfilter*, *BCAL*, *MCC* și *gLIDAR*), bazați pe adaptarea Rețelei Neregulate de Triunghiuri (*Lasground* și *Lasground-new*) și algoritmi morfologici (*ETEW*, *MLS* și *SMRF*). Calcularea erorilor pătratice medii între algoritmi, pe clase, arată faptul că algoritmi morfologici și cei care folosesc metoda *adaptare-TIN* produc erori de filtrare semnificativ reduse, prin comparație cu algoritmi care folosesc interpolarea suprafețelor pentru filtrare (figura 8.1). Acuratețea ridicată oferită de algoritmi de filtrare de tip *adaptare-TIN* este de asemenea remarcată de cercetări anterioare (Korzeniowska ș.a., 2014; Montealegre ș.a., 2015).




Fig. 8.1. Acuratețea medie de filtrare, pentru cele trei clase de algoritmi analizați.

Pentru fiecare categorie de algoritmi, acuratețea procesului de filtrare este mai ridicată pentru *suprafața de probă A* decât pentru *suprafețele nr. 1-7*. Posibile explicații sunt: gradul foarte ridicat de acoperire cu vegetație specific *suprafețelor nr. 1-7* (care limitează penetrarea la sol a undelor laser), influența erorilor asociate etapei de măsurători terestre și efectul procesului de interpolare a suprafețelor. De asemenea, trebuie ținut seamă de faptul că algoritmi de filtrare au fost optimizați pentru *suprafața de probă A*, aceleași valori parametrice fiind apoi folosite și pentru *suprafețele 1-8* (vezi **secțiunea 9.4.5**).

O reprezentare vizuală a rezultatului filtrării se regăsește în **Anexa 4**.

8.1.2. Numărul de puncte rezultat în urma filtrării

Prin procesul de filtrare se identifică acele observații din norul de puncte LiDAR care este probabil să se afle la nivelul solului. Acestor puncte li se atribuie clasa *Teren*, restul punctelor fiind eliminate din setul de date. Pentru *suprafața de probă A*, numărul de puncte filtrate variază între 0.59 și 3.61 milioane de puncte în funcție de algoritm (tabelul 8.2). Numărul de puncte atribuite clasei *Teren*, conform clasificării puse la dispoziție de INCDS „*Marin Drăcea*”, este de 1.3 milioane.

Se constată că doar doi algoritmi filtrează un număr de puncte mai mic decât cel corect. Aceștia sunt:

- *Groundfilter*, care filtrează 45 la sută din numărul corect de puncte și are o acuratețe scăzută relativ la ceilalți algoritmi (eroare medie pătratică de 1.23 metri pentru *suprafața de probă A*).

- *MLS*, care filtrează 69 la sută din numărul corect de puncte și are o acuratețe bună, prin raportarea la ceilalți algoritmi (eroare medie pătratică de 0.56 metri pentru *suprafața de probă A*).

Pentru ceilalți algoritmi, numărul de puncte îl depășește pe cel real, de până la aproape 3 ori (în cazul *SMRF*, cu 3.6 milioane puncte filtrate). Rezultă deci că majoritatea algoritmilor sunt afectați de erori de comitere mai semnificative decât erorile de omitere. Cu alte cuvinte, este mai probabil ca un punct reprezentând un obstacol să fie etichetat incorect ca reprezentând suprafața terenului, decât invers. Întrucât valorile pentru RMSE sunt relativ bune, se presupune că o parte semnificativă din aceste puncte incorect atribuite clasei *Teren* se află la joasă înălțime față de sol. Astfel impactul lor asupra acurateții de modelare a suprafeței terestre este relativ redus. De exemplu, deși algoritmul *Lasground-new* filtrează un număr de puncte aproape dublu față de cel real (2.37 față de 1.3 milioane), valoarea RMSE asociată acestuia este de 0.34 metri (*pentru suprafața de probă A*).

În ceea ce privește *suprafețele de probă nr. 1-7*, majoritatea algoritmilor filtrează un număr de puncte apropiat de cel corect. Excepție fac algoritmi *BCAL* și *Groundfilter*, care omit o parte semnificativă din punctele aflate la sol, în toate situațiile. De exemplu, pentru *suprafața de probă nr. 4*, algoritmul *BCAL* identifică doar 10 puncte aflate la sol, reprezentând 4 procente din numărul real. Algoritmul *Groundfilter* are o performanță similară din acest punct de vedere, identificând între 33 și 67 la sută din punctele aflate la sol, în cazul *suprafețelor de probă nr. 1-7*. Cei doi algoritmi (*BCAL* și *Groundfilter*) au totodată cea mai slabă acuratețe de filtrare, din punct de vedere al erorilor medii pătratice. Performanța relativ scăzută a algoritmului *Groundfilter* în situația terenurilor împădurite confirmă o serie de cercetări anterioare (Kraus și Pfeifer, 1998; Montealegre, 2015).

Tabelul 8.1. Erori verticale datorate procesului de filtrare.

Algoritm	Eroarea medie pătratică a Modelului Digital Altimetric (RMSE) - în metri								
	Suprafața A	Suprafața 1	Suprafața 2	Suprafața 3	Suprafața 4	Suprafața 5	Suprafața 6	Suprafața 7	Suprafața 8 (referință)
<i>Groundfilter</i>	1.23	1.56	1.22	1.30	0.57	1.22	0.59	0.94	0.50
<i>BCAL</i>	2.25	5.90	5.51	2.28	5.84	0.99	2.02	2.08	0.49
<i>MCC</i>	0.79	1.41	1.04	1.39	0.47	0.57	0.46	1.43	0.26
<i>gLiDAR</i>	0.76	0.99	1.14	1.29	0.41	0.55	0.47	0.74	0.26
<i>Lasground</i>	0.53	0.97	1.04	1.24	0.40	0.56	0.33	0.67	0.26
<i>Lasground-new</i>	0.34	0.92	1.04	1.24	0.40	0.54	0.31	0.59	0.25
<i>ETEW</i>	0.61	1.02	1.27	1.24	0.40	0.56	0.32	0.66	0.26
<i>MLS</i>	0.56	0.99	1.09	1.23	0.38	0.54	0.31	0.66	0.25
<i>SMRF</i>	0.60	1.03	1.09	1.30	0.42	0.55	0.32	0.64	0.27
Algoritm	Eroarea medie a Modelului Digital Altimetric - în metri								
	Suprafața A	Suprafața 1	Suprafața 2	Suprafața 3	Suprafața 4	Suprafața 5	Suprafața 6	Suprafața 7	Suprafața 8 (referință)
<i>Groundfilter</i>	0.00	0.73	0.42	0.25	0.15	0.33	0.34	-0.19	-0.09
<i>BCAL</i>	-0.12	4.76	4.19	-1.00	3.99	0.28	0.89	1.67	-0.08
<i>MCC</i>	0.07	0.69	0.63	0.31	0.11	0.08	0.26	0.72	0.11
<i>gLiDAR</i>	0.12	0.47	0.76	0.27	0.14	0.08	0.27	0.20	0.11
<i>Lasground</i>	0.03	0.46	0.65	0.15	0.13	0.08	0.16	0.18	0.10
<i>Lasground-new</i>	0.01	0.41	0.68	0.08	0.13	0.04	0.16	0.23	0.10
<i>ETEW</i>	0.08	0.49	0.85	0.19	0.14	0.09	0.17	0.33	0.10
<i>MLS</i>	0.01	0.48	0.74	0.18	0.14	0.08	0.17	0.28	0.10
<i>SMRF</i>	0.06	0.42	0.72	0.15	0.14	0.07	0.17	0.20	0.10

Tabelul 8.2. Numărul de puncte filtrate de către algoritmi.

Algoritm	Numărul de puncte atribuite clasei <i>Teren</i>								
	<i>Suprafața de probă A (milioane)</i>	<i>Suprafața de probă 1 (puncte)</i>	<i>Suprafața de probă 2 (puncte)</i>	<i>Suprafața de probă 3 (puncte)</i>	<i>Suprafața de probă 4 (puncte)</i>	<i>Suprafața de probă 5 (puncte)</i>	<i>Suprafața de probă 6 (puncte)</i>	<i>Suprafața de probă 7 (puncte)</i>	<i>Suprafața 8 -referință- (puncte)</i>
<i>Groundfilter</i>	0.59	118	60	107	104	737	306	291	1932
<i>BCAL</i>	1.99	24	14	64	10	802	189	255	5513
<i>MCC</i>	3.56	103	124	342	191	1629	1004	613	8126
<i>gLiDAR</i>	3.61	233	215	397	295	1760	1105	671	8155
<i>Lasground</i>	3.07	207	164	295	275	1490	990	626	7999
<i>Lasground-new</i>	2.37	193	190	265	268	1329	956	615	7464
<i>ETEW</i>	1.62	214	176	309	239	1094	871	402	4109
<i>MLS</i>	0.91	183	123	235	204	668	648	259	2100
<i>SMRF</i>	3.60	226	187	301	299	1590	1077	586	7739
Algoritm	Numărul de puncte atribuite clasei <i>Teren</i> (procent din nr. de puncte la sol, conform clasificării INCDS)								
	<i>Suprafața de probă A</i>	<i>Suprafața de probă 1</i>	<i>Suprafața de probă 2</i>	<i>Suprafața de probă 3</i>	<i>Suprafața de probă 4</i>	<i>Suprafața de probă 5</i>	<i>Suprafața de probă 6</i>	<i>Suprafața de probă 7</i>	<i>Suprafața 8 -referință-</i>
<i>Groundfilter</i>	45%	67%	33%	38%	39%	56%	33%	49%	26%
<i>BCAL</i>	151%	14%	8%	23%	4%	61%	20%	43%	74%
<i>MCC</i>	270%	59%	69%	121%	72%	123%	109%	103%	109%
<i>gLiDAR</i>	273%	133%	119%	140%	112%	133%	119%	112%	110%
<i>Lasground</i>	232%	118%	91%	104%	104%	113%	107%	105%	108%
<i>Lasground-new</i>	179%	110%	106%	94%	102%	100%	103%	103%	101%
<i>ETEW</i>	123%	122%	98%	109%	91%	83%	94%	67%	55%
<i>MLS</i>	69%	105%	68%	83%	77%	50%	70%	43%	28%
<i>SMRF</i>	273%	129%	104%	106%	113%	120%	116%	98%	104%

8.1.3. Distribuția spațială a erorilor de filtrare

Erorile de filtrare, în valoare absolută, au fost stratificate pe patru clase, pentru fiecare clasă calculându-se acoperirea (cu alte cuvinte, ce procent din numărul total de celule al modelului corespunde fiecărei clase). Analiza s-a realizat pentru trei dintre algoritmi de filtrare, câte unul din fiecare categorie: *Lasground-new* (din categoria **adaptare-TIN**), *MLS* (algoritm **morfologic**) și *gLiDAR* (algoritm **bazat pe interpolare**). Analiza distribuției s-a realizat pentru *suprafața de probă A*, deoarece numărul scăzut de celule ale modelelor pentru *suprafețele de probă 1-8* (datorită întinderii mai reduse a acestora) nu garantează semnificația statistică a rezultatelor. Limitele stabilite pentru clase, împreună cu rezultatul clasificării, sunt prezentate în tabelul 8.3.

Se observă că *suprafața de probă A* este acoperită în proporție de 80-85 la sută de erori pe care le putem considera ne semnificative pentru practică (mai mici de 0.20 metri), pentru fiecare dintre algoritmi. Totuși, indiferent de metoda de filtrare, apar și erori majore, de peste 1 metru. Aceste erori acoperă 2-3 procente din suprafață în cazul algoritmilor *Lasground-new* sau *MLS*. Performanța algoritmului *gLiDAR* este relativ slabă, cu aproape 6 procente din suprafață caracterizată prin erori de peste 1 metru. Astfel de erori afectează calitatea modelului suprafeței, fiind necesară corectarea lor anterior folosirii reprezentărilor în scopuri practice.

Distribuția spațială a erorilor de filtrare clasificate s-a reprezentat și grafic, sub formă de hărți tematice. În figura 8.2 se prezintă distribuția spațială pentru cazul algoritmului *Lasground-new*, cu mențiunea că hărțile pentru ceilalți algoritmi sunt similare.

Tabelul 8.3. Clasificarea erorilor verticale de filtrare.

Semnificație clasă	Limită inferioară clasă (m)	Limită superioară clasă (m)	Acoperire (% din suprafața de probă A)		
			<i>Lasground-new</i>	<i>MLS</i>	<i>gLiDAR</i>
Erori nesemnificative	0.00	0.20	84.24	79.96	74.04
Erori reduse	0.20	0.50	10.82	13.36	14.33
Erori semnificative	0.50	1.00	3.24	3.86	5.80
Erori majore	1.00	-	1.70	2.81	5.83

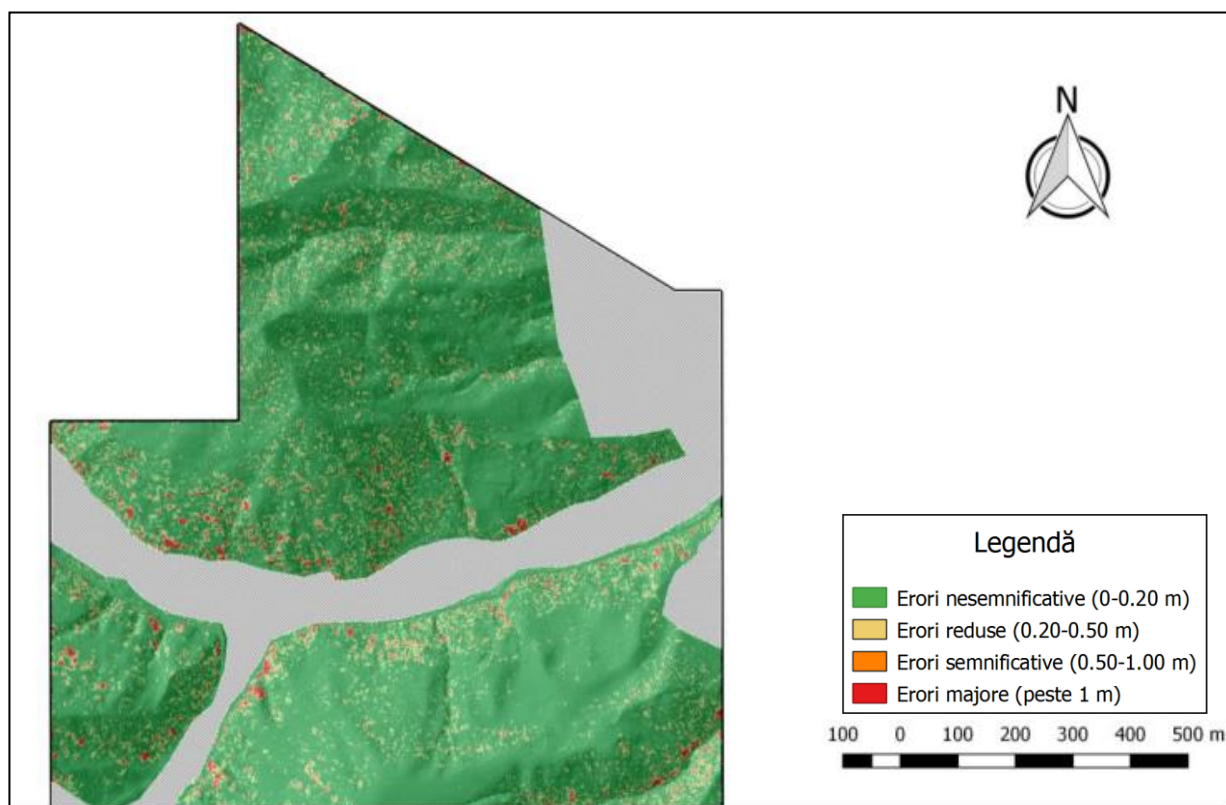


Fig. 8.2. Distribuția spațială a erorilor verticale de filtrare pentru algoritmul *Lasground-new*.

Pentru analiza cantitativă a distribuției spațiale a erorilor s-a apelat la tehnica *LISA* (*Local Indicator of Spatial Association*) detaliată în **secțiunea 7.4.6**. Tehnica urmărește cuantificarea gradului în care valorile tind să se grupeze spațial (prin formarea așa-numitor *cluster*e – grupuri de observații învecinate cu valori similare).

În cazul *suprafeței de probă A*, analiza *LISA* scoate în evidență un număr redus de *cluster*e pozitive sau negative (figura 8.3). Majoritatea *cluster*-elor negative (grupuri de celule învecinate cu valori relativ mici, raportat la media aritmetică a întregii suprafețe) sunt aliniat pe latura nordică a *suprafeței de probă A*, indicând un posibil efect de margine al tehnicii *LISA*. Pentru *cluster*-ele pozitive (grupuri de celule învecinate cu valori relativ mari, raportat la media aritmetică a întregii suprafețe) se observă o anumită tendință de grupare în zona limitrofă albiei râului (care străbate central *suprafața de probă A*, de la Vest la Est). Această zonă este caracterizată de versanți abrupti pe ambele părți ale

râului care încadrează relieful plat caracteristic albiei (cu alte cuvinte, o discontinuitate topografică – figura 8.4). Este de așteptat ca aceste discontinuități să influențeze procesul de filtrare a norului de puncte, rezultând erori de filtrare relativ ridicate.

Cei trei algoritmi de filtrare analizați au valori similare pentru indicatorul *Local Moran's I* (calculat cu formula 7.2), care cuantifică gradul de auto-corelație spațială: 0.28 pentru algoritmul *Lasground-new*, 0.31 pentru *MLS*, respectiv 0.32 pentru *gLiDAR*. Fiind mai apropiate de 0 decât de 1, valorile indică faptul că, la nivelul întregii suprafețe, gradul de organizare pe *cluster* a erorilor de filtrare este redus.




Fig. 8.3. Distribuția spațială a *cluster*-elor identificate de tehnica *LISA*, pentru erorile verticale datorate procesului de filtrare.




Fig. 8.4. Exemplu de discontinuitate a suprafeței terestre, la intersecția dintre zona plată a albiei și versanții abrupti de pe cele două maluri.

8.1.4. Factori de influență a erorilor de filtrare - suprafața de probă A

La analiza procesului de filtrare s-au avut în vedere o serie de factori cu potențială influență asupra variației erorilor de filtrare (detaliați în **secțiunea 7.4.7**). Valorile celor cinci factori (înclinarea terenului, Indicele de Rugozitate al Terenului, curbura maximă, gradul de acoperire cu vegetație și densitatea punctelor LiDAR) au fost stratificate pe clase, în funcție de distribuția statistică a valorilor. Semnificația clasificării factorilor și limitele claselor se regăsesc în tabelul 7.4).

În ceea ce privește înclinarea terenului (figura 8.5) se remarcă o creștere constantă a erorii medii pătratice odată cu înclinarea, pentru fiecare dintre algoritmi. Algoritmul *Lasground-new* are o performanță constantă, având cea mai mică valoare a RMSE pentru fiecare dintre categoriile de înclinare. În schimb, algoritmul *MLS* este aparent cel mai afectat de creșterea înclinării terenului. Performanța acestuia scade relativ la ceilalți doi algoritmi în cazul categoriilor superioare de înclinare (clasele 5 și 6). Valorile indicelui de corelație R^2 confirmă această legătură sugerată de reprezentarea grafică (tabelul 8.4).

Situația este asemănătoare pentru Indicele de Rugozitate a Terenului *TRI* (figura 8.6), precum și pentru curbura maximă a suprafeței (figura 8.7). Performanța fiecărui algoritm de filtrare este afectată negativ de creșterea valorilor celor doi indicatori, care exprimă gradul de fragmentare a suprafeței terenului. Algoritmul *Lasground-new* are asociate cele mai mici valori ale erorii medii pătratice, la fiecare categorie a celor doi indici. Performanța algoritmului *MLS* este în scădere relativ la ceilalți doi algoritmi în cazul categoriilor superioare de rugozitate sau curbura maximă a terenului (clasele 4-5). Valorile indicelui de corelație R^2 confirmă influența indicatorilor asupra rezultatului filtrării. (tabelul 8.4).

Cu alte cuvinte, se poate spune că acuratețea procesului de filtrare este puternic influențată de condițiile de teren (înclinare, rugozitate, curbură). Din acest punct de vedere, rezultatele confirmă cercetările anterioare (Hyypä ș.a., 2000; Fisher și Tate, 2006; Meng ș.a., 2010).




Fig. 8.5. Eroarea medie pătratică pentru filtrare, în funcție de înclinarea terenului.

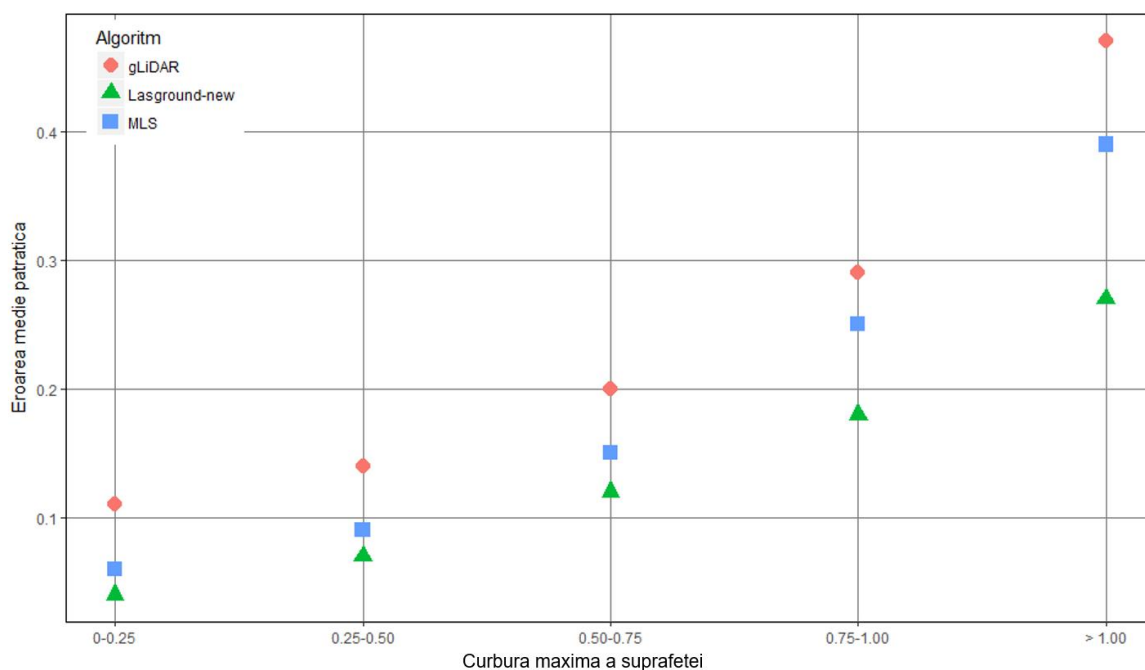


Fig. 8.6. Eroarea medie pătratică pentru filtrare, în funcție de Indicele de Rugozitate a Terenului (TRI).




Fig. 8.7. Eroarea medie pătratică pentru filtrare, în funcție de curbura maximă a terenului.

Creșterea gradului de acoperire cu vegetație al suprafeței (care limitează capacitatea de penetrare la sol a undelor laser) se asociază cu o creștere a erorii medii pătratice (figura 8.8). În situația terenului descoperit (prima clasă a gradului de acoperire), algoritmi *Lasground-new* și *MLS* au o performanță similară. Pentru restul claselor, situație în care apare vegetația forestieră, se respectă aceeași ierarhie relativă: cele mai mici erori sunt asociate algoritmului *Lasground-new*, urmat de algoritmi *MLS* și *gLiDAR*. Indicele R^2 , care exprimă legătura dintre erorile de filtrare și gradul de acoperire cu vegetație, este prezentat în tabelul 8.4.

În ceea ce privește densitatea punctelor LiDAR, analiza vizuală a graficului (figura 8.9) nu indică o legătură aparentă între acest factor și valorile pentru eroarea medie pătratică. Valorile indicelui de corelație R^2 indică de asemenea o legătură slabă între densitatea punctelor LiDAR și erorile de filtrare asociate celor trei algoritmi (tabelul 8.4).

Sithole și Vosselman (2004) remarcă faptul că influența densității punctelor LiDAR este minoră prin comparație cu efectul complexității suprafeței terestre, iar rezultatele de față confirmă această ipoteză. Și alte cercetări anterioare descoperă o influență relativ scăzută a densității punctelor LiDAR asupra erorilor de filtrare (Zhang și Whitman, 2005; Montealegre ș.a., 2015).

Tabelul 8.4. Valorile coeficientului de corelație R^2 pentru legătura între factorii analizați și acuratețea de filtrare a algoritmilor.

Factor	Algoritm de filtrare	R^2 (suprafața de probă A)	R^2 (media valorilor pt. suprafețele de probă 1-7)
Înclinarea terenului	<i>Lasground-new</i>	0.99	0.95
	<i>MLS</i>	0.95	0.93
	<i>gLIDAR</i>	0.88	0.89
Indice de Rugozitate (TRI)	<i>Lasground-new</i>	0.99	0.93
	<i>MLS</i>	1.00	0.90
	<i>gLIDAR</i>	0.99	0.85
Curbura maximă a suprafeței	<i>Lasground-new</i>	0.98	0.93
	<i>MLS</i>	0.99	0.95
	<i>gLIDAR</i>	0.98	0.91
Gradul de acoperire cu vegetație	<i>Lasground-new</i>	0.93	0.26
	<i>MLS</i>	0.90	0.26
	<i>gLIDAR</i>	0.92	0.30
Densitatea punctelor LiDAR	<i>Lasground-new</i>	0.50	0.14
	<i>MLS</i>	0.17	0.11
	<i>gLIDAR</i>	0.50	0.15

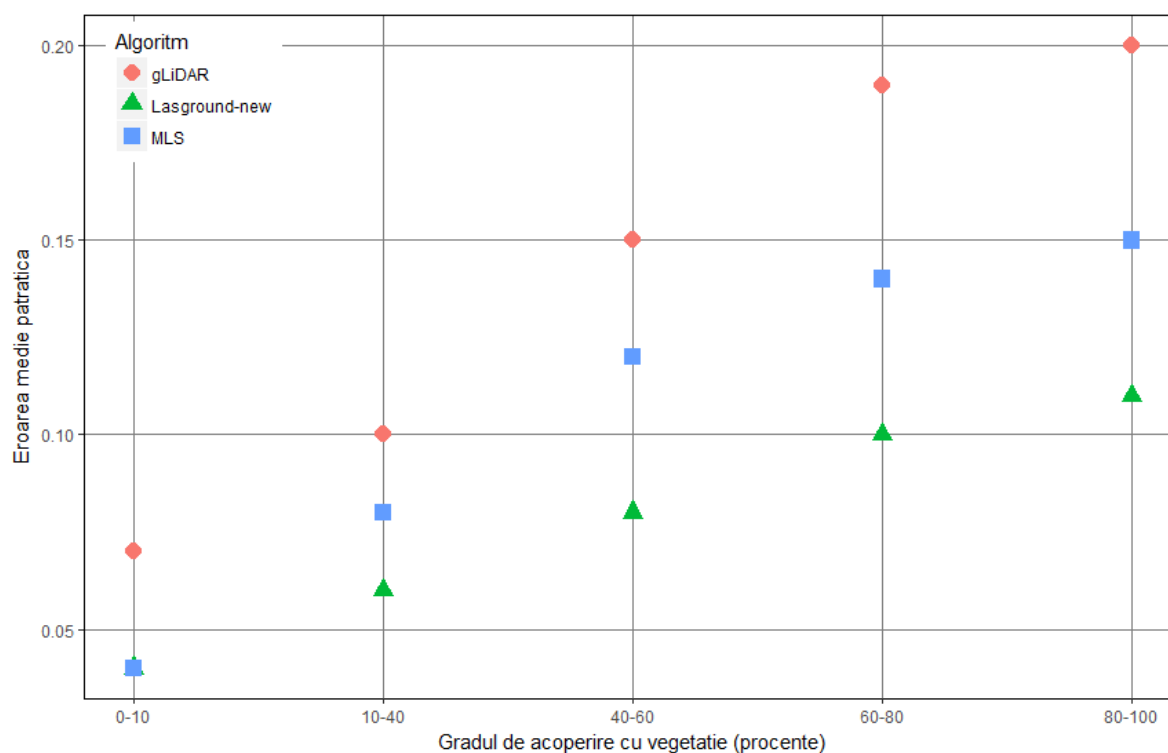


Fig. 8.8. Eroarea medie pătratică pentru filtrare, în funcție de gradul de acoperire cu vegetație.




Fig. 8.9. Eroarea medie pătratică pentru filtrare, în funcție de densitatea punctelor LiDAR.

8.1.5. Factori de influență a erorilor de filtrare - *suprafețele de probă nr. 1-7*

În ceea ce privește *suprafețele de probă nr 1-7*, pentru a investiga influența factorilor analizați (înclinarea terenului, Indicele de Rugozitate al Terenului, curbura maximă, gradul de acoperire cu vegetație și densitatea punctelor LiDAR) asupra acurateții de filtrare a algoritmilor s-au calculat:

- media aritmetică a fiecărui factor pe suprafață de probă;
- eroarea medie pătratică (RMSE) a valorilor de altitudine, pentru fiecare suprafață de probă.

Variația erorii medii pătratice (RMSE) în raport cu fiecare dintre factori s-a reprezentat sub forma graficelor de tip *scatterplot* (**Anexa 5**). Analiza indică o situație similară cu *suprafața de probă A* pentru: înclinarea terenului (**Anexa 5.1**), Indicele de Rugozitate a Terenului (**Anexa 5.2**) și curbura maximă (**Anexa 5.3**). În general, suprafețelor care au o medie aritmetică mai mare pentru acești factori li se asociază o scădere a acurateții de filtrare (valori mai mari pentru RMSE).

Referitor la gradul de acoperire cu vegetație, nu este aparentă o legătură între variația acestui factor și erorile medii pătratice asociate suprafețelor (**Anexa 5.4**). Această situație este în contrast cu cea întâlnită pentru *suprafața de probă A* (figura 8.8). O posibilă explicație este că gradul de acoperire cu vegetație nu are o variabilitate suficientă pentru a evidenția efectul acestui factor asupra acurateții de filtrare. În fapt, cele șapte suprafețe au un grad de acoperire cu vegetație ridicat (între 78 și 97 la sută).

Efectul modificării densității punctelor LiDAR (**Anexa 5.5**) este asemănător cu situația pentru *suprafața de probă A*. Astfel, între acest factor și eroarea medie pătratică se identifică o corelație slabă.

Valorile indicelui de corelație R^2 , calculat pentru *suprafețele de probă nr. 1-7*, sunt prezentate în tabelul 8.4.

8.2. Interpolarea suprafeței terenului

8.2.1. Precizări generale

Indicatorii statistici ai erorilor verticale de interpolare sunt prezentați în tabelul 8.5. În toate cazurile, indiferent de algoritm sau rezoluție, erorile medii au valori sub-centimetrice indicând lipsa unei tendințe de supra-estimare sau sub-estimare a variabilei interpolate. Acest rezultat este în contradicție cu o serie de cercetări anterioare, care descoperă o tendință de supra-estimare a altitudinii în situația terenurilor acoperite cu vegetație forestieră. Astfel, Reutebuch (2003) comunică o eroare medie a Modelului Digital Altimetric de 0.31 metri pentru păduri de conifere, iar Su și Bork (2006) calculează o valoare de 0.23 metri pentru situația pădurilor de plop.

În ceea ce privește eroarea medie pătratică (RMSE), valorile sunt relativ apropiate între algoritmi (de la 0.11 până la 0.40 metri). Ca un alt indicator al acurateții de interpolare, s-a calculat media aritmetică a erorilor de interpolare ca valori absolute (în modul). Pentru o anumită rezoluție, acest indicator are valori apropiate între algoritmi. De exemplu, la rezoluția maximă (0.5 metri) media erorilor absolute are valori între 0.08 și 0.20 metri. În cazul rezoluției minime (2.0 metri), același indicator are valori între 0.26 și 0.30 metri.

Intervalul de valori al erorilor (sau diferența dintre eroarea maximă și eroarea minimă) are valori între 5.88 și 11.29 metri. În general, algoritmilor din categoria *Radial Basis Functions (Multilevel B-Spline, Cubic Spline, Thin-Plate Spline și Thin-Plate Spline – TIN)* li se asociază un interval al erorilor mai redus. Aceasta deoarece algoritmii de tip *RBF* urmăresc generarea unei suprafețe netede, caracterizată de o tensiune minimă. Astfel, la nivel local fluctuațiile variabilei interpolate tind să fie reduse.

Tabelul 8.5. Statistici ale erorilor verticale de interpolare.

Algoritm interpolare	Eroare medie (m)	Media erorilor absolute (m)	Eroare minimă (m)	Eroare maximă (m)	Intervalul erorilor (m)	RMSE (m)
Rezoluția spațială a modelului: 0.5 metri						
Inverse Distance Weighted (<i>IDW</i>)	-0.0042	0.1401	-3.66	3.82	7.48	0.20
Nearest Neighbour (<i>NeM</i>)	-0.0030	0.2022	-5.47	5.30	10.77	0.28
Natural Neighbour (<i>NM</i>)	0.0005	0.0835	-4.10	1.78	5.88	0.11
Delauney Triangulation (<i>DT</i>)	-0.0003	0.0840	-3.54	2.34	5.88	0.12
Multilevel B-Spline (<i>BS</i>)	-0.0037	0.0825	-4.20	2.12	6.32	0.11
Cubic Spline (<i>CS</i>)	0.0061	0.1149	-4.48	2.04	6.52	0.16
Thin Plate Spline (<i>TPS</i>)	-0.0024	0.0818	-4.06	1.82	5.88	0.11
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	-0.0022	0.0818	-4.10	1.80	5.90	0.11
Ordinary Kriging (<i>OK</i>)	-0.0015	0.2011	-3.71	4.38	8.09	0.11
Rezoluția spațială a modelului: 1.0 metri						
Inverse Distance Weighted (<i>IDW</i>)	-0.0032	0.1785	-3.34	3.17	6.51	0.24
Nearest Neighbour (<i>NeM</i>)	-0.0012	0.2280	-4.41	5.30	9.71	0.31
Natural Neighbour (<i>NM</i>)	0.0004	0.1389	-4.10	1.78	5.88	0.18
Delauney Triangulation (<i>DT</i>)	0.0005	0.1394	-3.54	2.34	5.88	0.18
Multilevel B-Spline (<i>BS</i>)	-0.0024	0.1383	-3.76	2.12	5.88	0.18
Cubic Spline (<i>CS</i>)	0.0066	0.1589	-4.48	2.41	6.89	0.21
Thin Plate Spline (<i>TPS</i>)	-0.0010	0.1380	-4.06	1.86	5.92	0.18
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	-0.0008	0.1379	-4.08	1.95	6.03	0.18
Ordinary Kriging (<i>OK</i>)	-0.0012	0.2234	-3.71	2.86	6.57	0.31
Rezoluția spațială a modelului: 1.5 metri						
Inverse Distance Weighted (<i>IDW</i>)	0.0030	0.2261	-5.67	4.42	10.09	0.30
Nearest Neighbour (<i>NeM</i>)	-0.0013	0.2652	-6.84	4.45	11.29	0.36
Natural Neighbour (<i>NM</i>)	0.0006	0.2008	-5.53	4.40	9.93	0.26
Delauney Triangulation (<i>DT</i>)	0.0007	0.2013	-5.52	4.65	10.17	0.26
Multilevel B-Spline (<i>BS</i>)	-0.0020	0.2004	-5.570	4.28	9.85	0.26
Cubic Spline (<i>CS</i>)	0.0058	0.2149	-5.16	2.72	7.88	0.28
Thin Plate Spline (<i>TPS</i>)	-0.0002	0.2002	-5.97	4.42	10.39	0.26
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	0.0001	0.2003	-5.98	4.39	10.37	0.26
Ordinary Kriging (<i>OK</i>)	-0.0014	0.2592	-4.20	5.01	9.21	0.35

Tabelul 8.5. Statistici ale erorilor verticale de interpolare (continuare).

Algoritm interpolare	Eroare medie (m)	Media erorilor absolute (m)	Eroare minimă (m)	Eroare maximă (m)	Intervalul erorilor (m)	RMSE (m)
Rezoluția spațială a modelului: 2.0 metri						
Inverse Distance Weighted (<i>IDW</i>)	-0.0040	0.2720	-4.78	4.42	9.20	0.36
Nearest Neighbour (<i>NeM</i>)	-0.0039	0.3056	-5.47	4.45	9.92	0.41
Natural Neighbour (<i>NN</i>)	0.0008	0.2600	-4.99	4.40	9.39	0.34
Delauney Triangulation (<i>DT</i>)	0.0007	0.2621	-5.20	4.65	9.85	0.34
Multilevel B-Spline (<i>BS</i>)	-0.0016	0.2618	-5.24	4.25	9.49	0.34
Cubic Spline (<i>CS</i>)	0.0053	0.2717	-3.26	3.94	7.20	0.35
Thin Plate Spline (<i>TPS</i>)	0.0010	0.2615	-5.46	4.42	9.88	0.34
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	0.0012	0.2600	-5.47	4.39	9.86	0.34
Ordinary Kriging (<i>OK</i>)	-0.0032	0.2972	-3.65	4.44	8.09	0.40

În ansamblu, cel mai puțin precis model al suprafeței rezultă în urma interpolării cu algoritmul *Nearest Neighbour* (cu valori ale RMSE între 0.28 și 0.41 metri), urmat de *Ordinary Kriging* (RMSE între 0.11 și 0.40) și *Inverse Distance Weighted* (RMSE între 0.20 și 0.36). La polul opus se situează algoritmul *Natural Neighbour* (NN), suprafețele interpolate de acesta având un grad ridicat de acuratețe (indicatorul RMSE are valori între 0.11 și 0.34 metri). Se face mențiunea că diferențele între algoritmi *TPS* și *TPS_{TIN}* sunt foarte reduse, cel puțin din prisma indicatorilor acurateții globale. Având în vedere timpul de procesare mult mai ridicat al *TPS_{TIN}* (care necesită generarea unui model de tip Rețea Neregulată de Triunghiuri cu milioane de vârfuri), utilizarea acestui algoritm nu se justifică.

Figura 8.10 include reprezentarea grafică a Modelului Digital Altimetric obținut cu algoritmul *Nearest Neighbour*, la rezoluția de 0.5 metri. Menționăm că, la scara de reprezentare necesară încadrării în pagină a imaginilor, nu se observă diferențe între suprafețele interpolate de diferiți algoritmi. Pentru a remarca diferențele este necesară o scară de reprezentare mai mare, astfel că se prezintă un subset al Modelului Digital Altimetric pentru *suprafața de probă Vidra*, așa cum a fost interpolat de cei nouă algoritmi (**Anexa 6**).

Analiza vizuală a rezultatelor evidențiază faptul că fiecare dintre suprafețe include anumite „artefacte” de interpolare (adică modificări sub aspect vizual ale modelului provocate de procedeele de lucru al algoritmilor), în special în zonele unde densitatea punctelor cunoscute este relativ redusă.

Se observă artefacte de interpolare pentru:

- algoritmul *Nearest Neighbour*, unde se distinge forma poligoanelor Thiessen generate anterior interpolării, în zonele unde cresc distanțele dintre puncte cunoscute;
- algoritmul *Delauney Triangulation*, unde se observă triunghiurile rețelei TIN, în zonele cu densitate redusă a punctelor cunoscute;
- algoritmul *Cubic Spline*, caz în care apar artefacte de formă regulată în zonele cu o variație ridicată a altitudinii;

- algoritmul *Inverse Distance Weighted*, care prezintă un efect vizual general de „granularitate”;
- algoritmul *Ordinary Kriging*, unde apare un efect similar cu cel de la *IDW*, dar mai puțin evident.

În general, se constată că algoritmul *Natural Neighbour*, împreună cu algoritmi din categoria RBF (sau *Spline*), generează modele ale suprafeței relativ apropiate de realitate, sub aspect vizual. Acuratețea ridicată de interpolare a algoritmului *Nearest Neighbour* în situația terenurilor împădurite este constatată și de Sterenczak ș.a. (2016). Performanța relativ scăzută a algoritmului *Inverse Distance Weighted* este de asemenea în acord cu cercetări anterioare (Bater și Coops, 2009; Ismail, 2016).

⁴ Cunoscut în literatura de specialitate sub denumirea salt-and-pepper („sare și piper”), provocat de variații locale bruște ale variabilei interpolate.

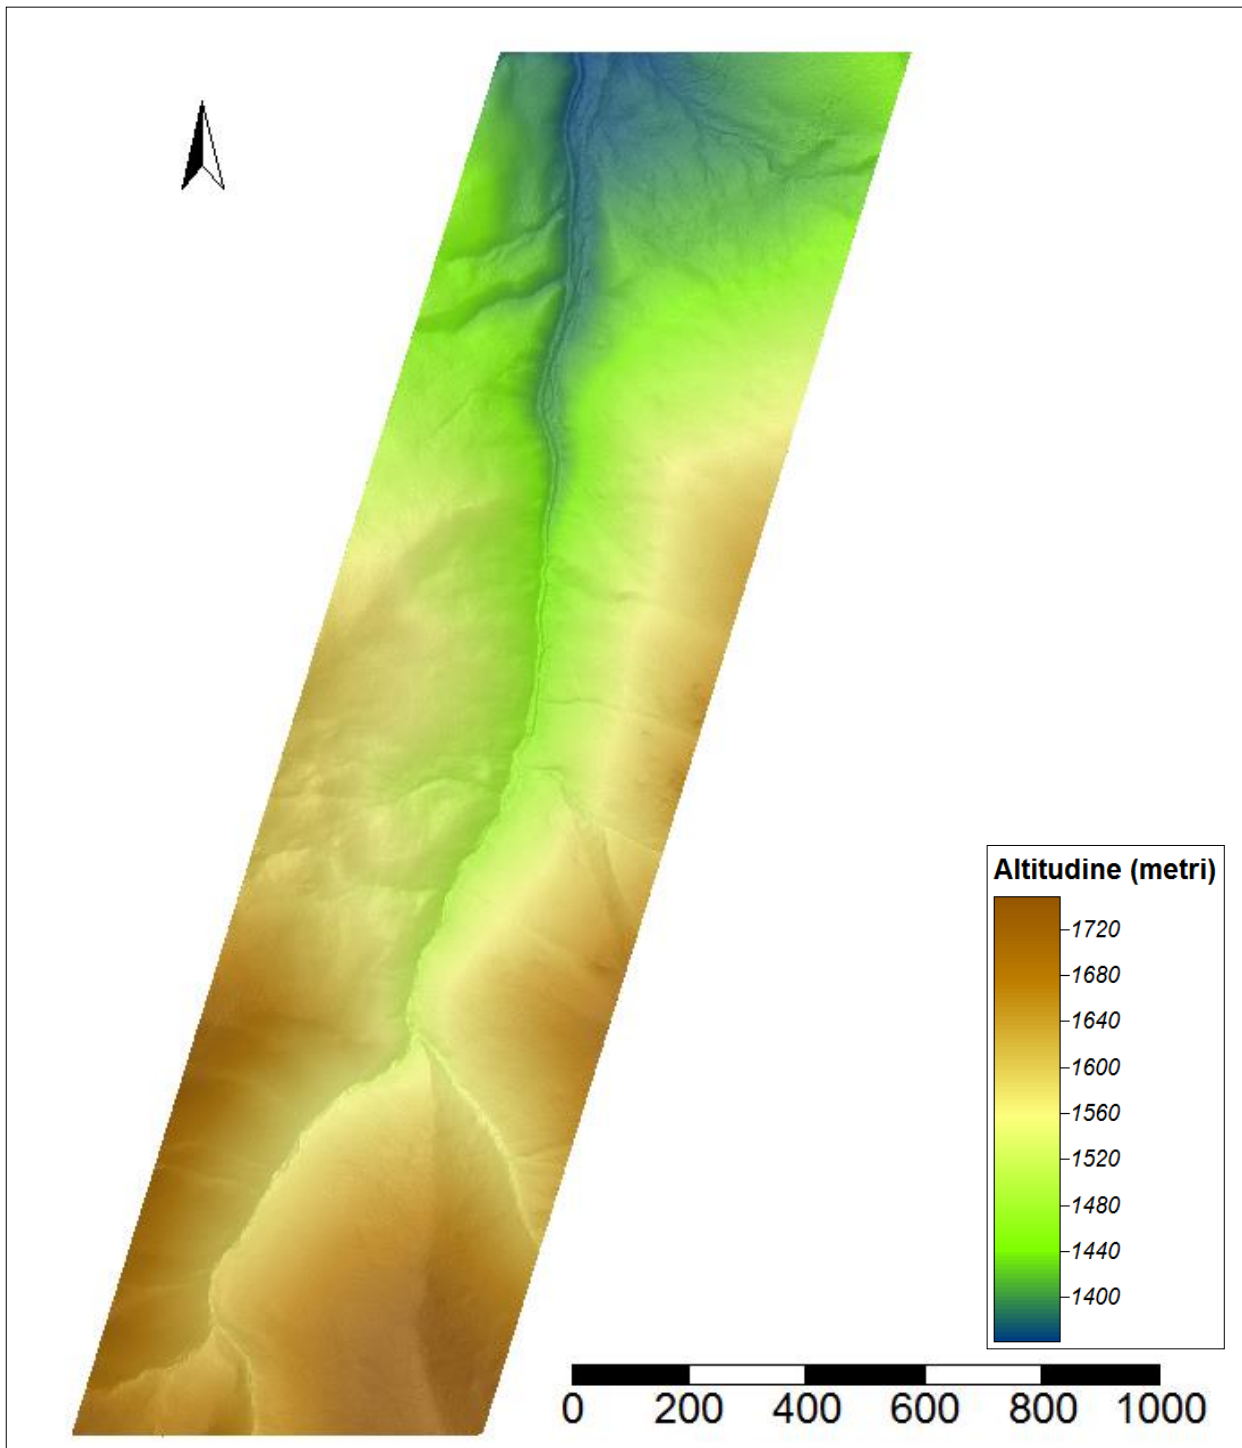


Fig. 8.10. Model Digital Altimetric pentru *suprafața de probă Vidra*, interpolat folosind algoritmul *Natural Neighbour* (rezoluția modelului: 0.5 metri).

8.2.2. Efectul rezoluției spațiale a modelului asupra acurateții de interpolare

Pentru fiecare dintre algoritmi, erorile verticale datorate interpolării cresc odată cu scăderea rezoluției (adică modificarea în sens pozitiv a dimensiunii celulelor). Erorile medii pătratice pentru cele patru rezoluții studiate sunt prezentate în figura 8.11. Se observă că acuratețea de predicție scade la rezoluțiile inferioare (de 1.5 și 2.0 metri). Pentru o anumită rezoluție, ierarhizarea algoritmilor în funcție de acuratețe rămâne în general aceeași. Această influență a rezoluției de modelare este constatată și în cercetările anterioare (Weng, 2006; Bater și Coops, 2009; Ismail, 2016).




Fig. 8.11. Eroarea medie absolută pentru cele patru rezoluții testate la interpolare.

8.2.3. Distribuția spațială a erorilor de interpolare

Pentru analizarea modului în care erorile de interpolare se distribuie spațial, acestea au fost transformate în valori absolute și grupate pe clase. Limitele claselor de erori și justificarea alegerii acestora este similară cu situația erorilor de filtrare, detaliată în **secțiunea 7.4.6**.

Rezultatele prezentate în tabelul 8.6 sunt pentru rezoluția de 0.5 metri, cu mențiunea că situația pentru celelalte trei rezoluții de modelare (1.0, 1.5 și respectiv 2.0 metri) este foarte asemănătoare. Se remarcă faptul că, pentru majoritatea algoritmilor, erorile de interpolare de peste 0.50 metri au o rată redusă de apariție (mai puțin 1 la sută din punctele de validare au asociate astfel de erori). Excepție fac algoritmii *Inverse Distance Weighted* (unde erorile mai mari de 0.50 metri sunt asociate la aproximativ 2.5 procente din puncte), *Natural Neighbour* și *Ordinary Kriging* (care au erori de interpolare de peste 0.50 metri pentru 6-7 la sută din punctele de validare).

Algoritmii cu acuratețe de interpolare relativ ridicată (*Natural Neighbour*, *Delauney Triangulation*, *Multi-level B-spline*, *Thin-Plate Spline*, *Thin-Plate Spline TIN*) au erori de interpolare reduse (de până la 0.20 metri) pentru majoritatea punctelor de validare (93-95 de procente).

Pentru reprezentarea distribuției spațiale s-au realizat hărți tematice ale erorilor de interpolare clasificate. Pentru lucrarea de față s-au ales doi algoritmi ca fiind sugestivi: *Nearest Neighbour* ca algoritm cu acuratețe ridicată de interpolare (figura 8.12), respectiv *Ordinary Kriging*, care are o performanță scăzută prin raportarea la ceilalți algoritmi de interpolare (figura 8.13).

Tabelul 8.6. Proportia claselor de erori de interpolare pentru *suprafața de probă Vidra*.

Algoritm	Număr puncte validare (procent din total)			
	Erori ne semnificative*	Erori reduse**	Erori semnificative**	Erori majore****
Inverse Distance Weighted (<i>IDW</i>)	77.73%	19.87%	2.24%	0.17%
Nearest Neighbour (<i>NeM</i>)	62.20%	30.93%	6.32%	0.54%
Natural Neighbour (<i>NM</i>)	93.78%	6.05%	0.15%	0.02%
Delauney Triangulation (<i>DT</i>)	93.59%	6.22%	0.17%	0.02%
Multilevel B-Spline (<i>BS</i>)	94.04%	5.82%	0.13%	0.02%
Cubic Spline (<i>CS</i>)	84.80%	14.42%	0.73%	0.05%
Thin Plate Spline (<i>TPS</i>)	94.17%	5.68%	0.13%	0.02%
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	94.17%	5.68%	0.13%	0.02%
Ordinary Kriging (<i>OK</i>)	63.45%	29.15%	6.78%	0.62%

* mai mici de 0.20 metri; ** între 0.20-0.50 metri
 *** între 0.50-1.00 metri; **** mai mari de 1.00 metri

Pentru cuantificarea gradului de auto-corelare spațială (măsura în care erori de mărime similară tind să se grupeze) s-a folosit analiza *LISA* (*Local Indicator of Spatial Association*). Această tehnică presupune calcularea indicatorului *Local Moran's I*, prin care se estimează la nivel global tendința de grupare a valorilor setului de date. Valorile indicatorului *Local Moran's I* (formula 7.2) sunt foarte similare între cei nouă algoritmi de interpolare analizați, toate fiind cuprinse în intervalul 0.13-0.17 (Tabelul 8.7). Faptul că valorile sunt apropiate de zero indică un grad redus de organizare spațială pe grupuri (sau *cluster*) a erorilor de interpolare, indiferent de algoritm. Ca reprezentare grafică a acestei organizări spațiale se prezintă harta *cluster*-elor pentru algoritmul *Inverse Distance Weighted* (figura 8.14), cu mențiunea că situația pentru ceilalți algoritmi este similară sub aspect vizual. În reprezentare se observă așezarea aleatorie a *cluster*-elor pozitive (grupuri de erori relativ ridicate învecinate între ele), în timp ce majoritatea *cluster*-elor negative (grupuri de erori relativ scăzute învecinate între ele) se situează:

- în zona sudică a *suprafeței de probă Vidra* (caracterizată de o înclinare mai redusă și vegetație forestieră mai puțin consistentă sau chiar absentă);
- de-a lungul căii de acces care străbate valea de la Sud la Nord, unde terenul este descoperit.

Tabelul 8.7. Valorile indicatorului *Local Moran's I*, pentru erorile de interpolare.

Algoritm de interpolare	Valoare <i>Local Moran's I</i>
<i>Inverse Distance Weighted</i> (IDW)	0.15
<i>Nearest Neighbour</i> (NeN)	0.15
<i>Natural Neighbour</i> (NN)	0.15
<i>Delauney Triangulation</i> (DT)	0.13
<i>Multilevel B-Spline</i> (BS)	0.14
<i>Cubic Spline</i> (CS)	0.17
<i>Thin Plate Spline</i> (TPS)	0.13
<i>Thin Plate Spline – TIN</i> (TPSTIN)	0.13
<i>Ordinary Kriging</i> (OK)	0.16

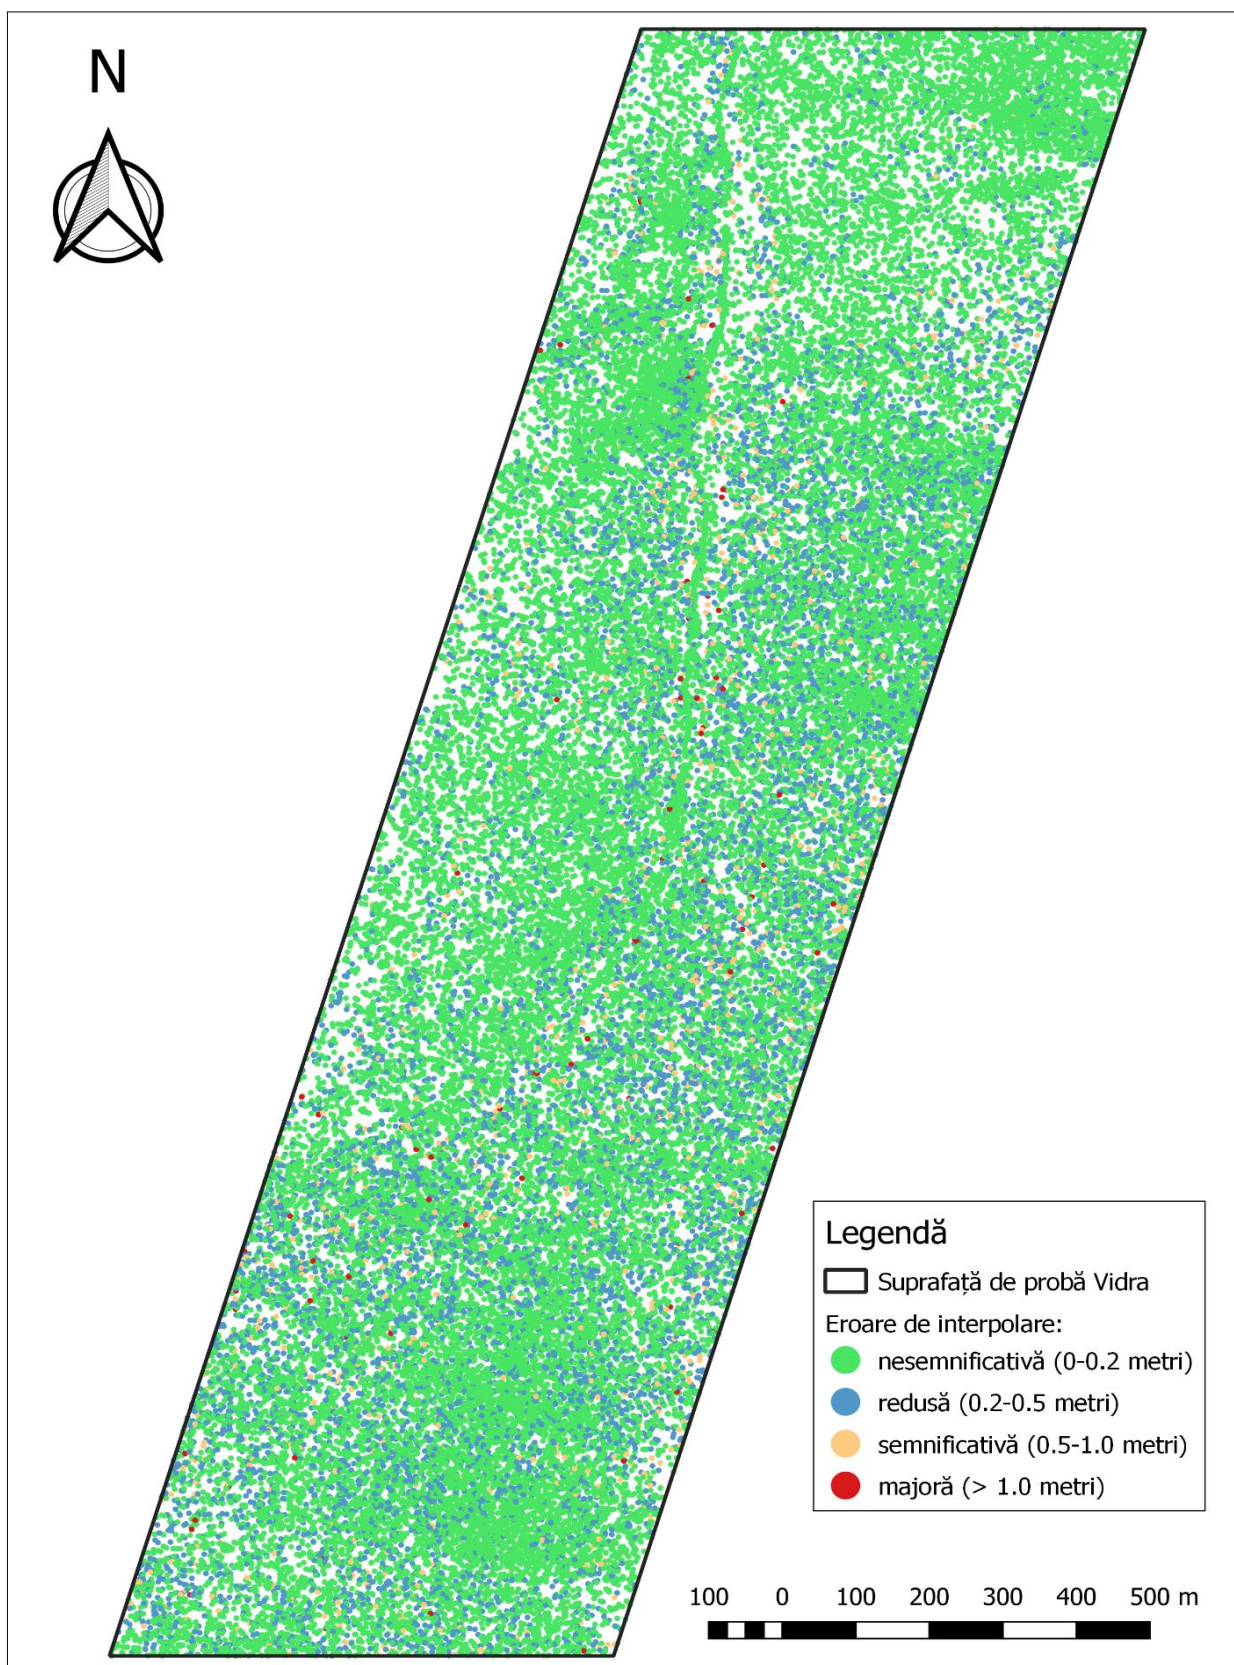


Fig. 8.12. Distribuția spațială a erorilor de interpolare clasificate, pentru algoritmul *Nearest Neighbour*.

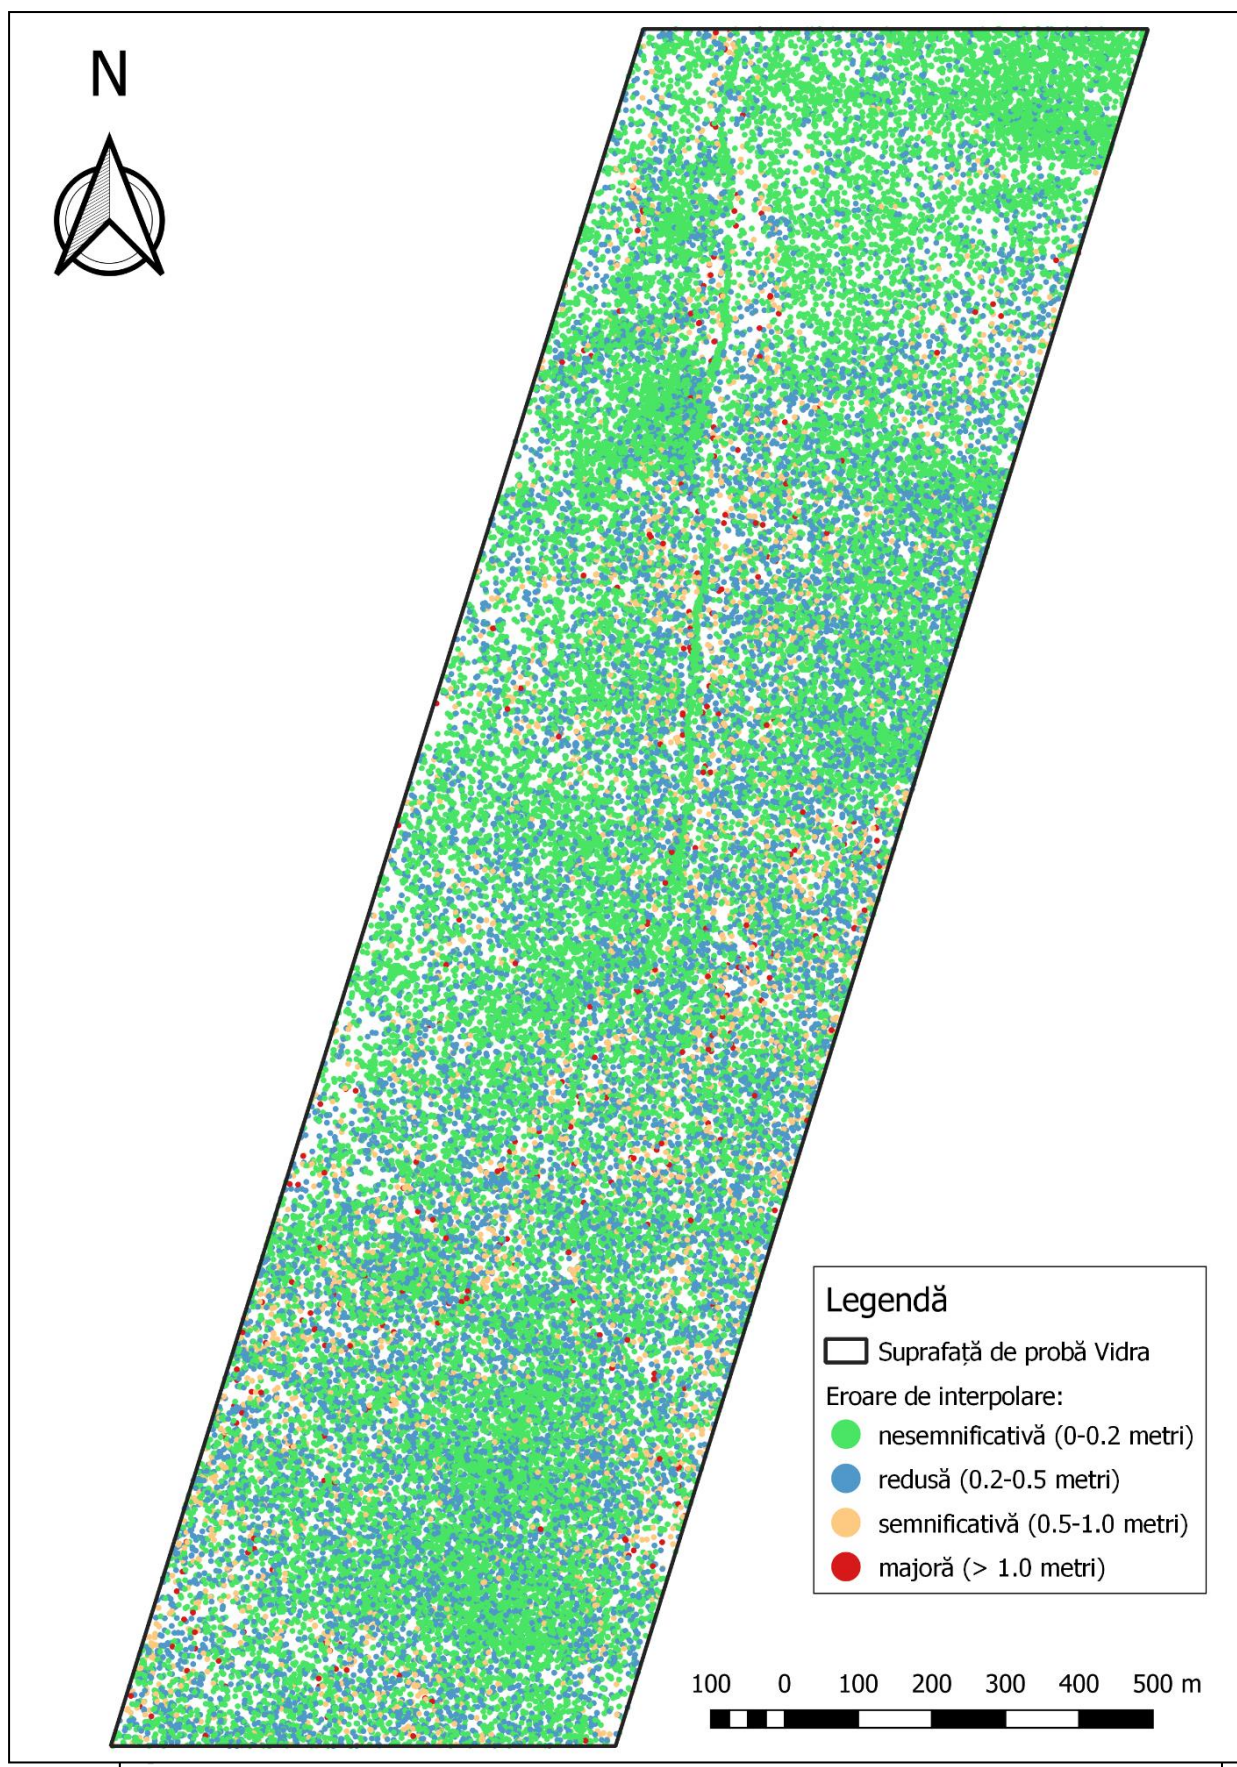


Fig. 8.13. Distribuția spațială a erorilor de interpolare clasificate, pentru algoritmul *Ordinary Kriging*.

Fig. 8.14. Distribuția spațială a grupurilor (*cluster*) de erori identificate prin analiza *LISA*, pentru erorile de interpolare.

8.2.4. Factori de influență a erorilor de interpolare

La analiza erorilor de interpolare au fost luați în considerare un număr de cinci factori pentru care s-a analizat o eventuală influență asupra acurateții de interpolare: înclinarea terenului, Indicele de Rugozitate al Suprafeței (*TRI*), curbura suprafeței, gradul de acoperire cu vegetație și densitatea punctelor cunoscute. Semnificația acestor factori, împreună cu modalitatea de determinare se regăsește în **secțiunea 7.5.7**. După determinare, factorii au fost clasificați, în funcție de distribuția statistică a valorilor. Limitele claselor și semnificația atribuită acestora sunt prezentate în tabelul 7.6.

Legătura dintre erori și variația factorilor a fost analizată pentru cele patru rezoluții spațiale: 0.5, 1.0, 1.5 și 2.0 metri. Rezultatele fiind foarte asemănătoare, se prezintă doar situația pentru rezoluția de 0.5 metri.

a. Înclinarea terenului

Analiza erorilor de interpolare, stratificate pe categorii de înclinare a terenului, arată că acuratețea de modelare a suprafeței terenului scade odată cu creșterea înclinării (figura 8.15). De exemplu, pentru algoritmul *Natural Neighbour*, eroarea medie pătratică (RMSE) crește de la 0.06 metri (pentru punctele de validare aflate pe teren plat) până la 0.51 metri (pentru punctele de validare asociate clasei de înclinare de peste 50 grade). Pentru aceleași două clase, eroarea maximă crește de la 1.38 metri la 4.94 metri. Situația este asemănătoare pentru fiecare dintre cei nouă algoritmi de interpolare analizați. Valorile indicelui de corelație R^2 confirmă legătura dintre înclinarea terenului și amplitudinea erorilor de interpolare (tabelul 8.8). Cea mai strânsă legătură (valori ale indicelui R^2 de peste 0.90) se regăsește la algoritmi *Nearest Neighbour*, *Inverse Distance Weighted* și *Ordinary Kriging*. Aceiași algoritmi au cea mai scăzută performanță în ansamblu (tabelul 8.5). Legătura dintre înclinarea terenului și acuratețea procesului de interpolare este în acord cu cercetări anterioare (Hypppa ș.a., 2005; Aguilar, 2005; Su și Bork, 2006; Ismail, 2016; Sterenczak ș.a., 2016).




Fig. 8.15. Eroarea medie pătratică pentru interpolare, în funcție de înclinarea terenului. Pentru claritate, punctele sunt deplasate pe orizontală.

b. Indicele de Rugozitate a Terenului

Efectul Indicelui de Rugozitate a Terenului (TRI) este asemănător cu cel al înclinării terenului (figura 8.16). De exemplu, pentru indicatorul *Ordinary Kriging*, valorile erorii medii pătratice cresc de la 0.13 (pentru clasa *Fără rugozitate*) la 0.80 metri (pentru clasa *Rugozitate ridicată*). Valorile indicelui de corelație R^2 (peste 0.85 pentru fiecare algoritm) confirmă efectul indicelui TRI asupra variației erorilor de interpolare (tabelul 8.8). La fel ca în cazul înclinării terenului, cea mai strânsă legătură apare pentru cei trei algoritmi cu cea mai slabă acuratețe de interpolare (*NeN*, *IDW* și *OK*), cu valori ale indicelui R^2 de 0.97, 0.95 și respectiv 0.94.

c. Curbura maximă a suprafeței

La fel ca înclinarea terenului sau Indicele de Rugozitate a Terenului, curbura maximă exprimă într-un anumit sens gradul de complexitate al suprafeței terestre. Astfel, la fel ca în cazul primilor doi indicatori, erorile de interpolare sunt în general mai mari pentru clasele de curbură ridicată (figura 8.17). Modificarea cea mai accentuată apare între ultimele două clase ale curburii. Ca exemplu, eroarea medie pătratică pentru algoritmul *Thin-Plate Spline* are valori de 0.12-0.19 metri pentru primele patru clase de curbură, în timp ce valoarea acestui indicator pentru cea de-a cincea clasă (curbură *foarte ridicată*) este de 0.47 metri. Indicele de corelație R^2 are valori de peste 0.85 pentru fiecare algoritm, indicând o legătură puternică între curbura suprafeței și erorile de interpolare.




Fig. 8.16. Eroarea medie pătratică pentru interpolare, în funcție de Indicele de Rugozitate a Terenului (TRI). Pentru claritate, punctele sunt deplasate pe orizontală.




Fig. 8.17. Eroarea medie pătratică pentru interpolare, în funcție de curbura maximă a terenului. Pentru claritate, punctele sunt deplasate pe orizontală.

d. Gradul de acoperire cu vegetație

Vegetația limitează capacitatea de penetrare la nivelul terenului a undelor laser, afectând nu doar densitatea punctelor aflate la sol ci și modul de distribuție al acestora (densitatea va fi ridicată în cazul terenului descoperit și mult mai redusă în zonele acoperite de pădure). Din acest motiv este de așteptat ca acest factor să influențeze într-o anumită măsură variația erorilor de interpolare. Rezultatele confirmă în parte această ipoteză (figura 8.18). Pentru o parte dintre algoritmi (*Nearest Neighbour*, *Ordinary Kriging*, *Inverse Distance Weighted*) erorile cresc pentru clasele superioare ale gradului de acoperire cu vegetație.

Ceilalți algoritmi au însă o performanță relativ stabilă din acest punct de vedere. De exemplu, valorile erorii medii pătratice (RMSE) pentru algoritmul *Delauney Triangulation* variază între 0.10 și 0.16 metri. Pentru algoritmul *Cubic Spline* se remarcă o oarecare scădere a RMSE (de la 0.22 metri pentru clasa *Teren descoperit*) la 0.15 metri (pentru clasa de *Acoperire foarte ridicată*). Acest comportament este însă cel mai probabil aleatoriu, fără semnificație statistică. Valorile indicelui de corelație R^2 sunt prezentate în tabelul 8.8.




Fig. 8.18. Eroarea medie pătratică pentru interpolare, în funcție de gradul de acoperire cu vegetație. Pentru claritate, punctele sunt deplasate pe orizontală.

e. Densitatea punctelor cunoscute

În ceea ce privește densitatea punctelor din setul de date pentru predicție (folosit la interpolarea suprafețelor), se remarcă o legătură puternică între acest factor și erorile de interpolare (figura 8.19). Influența este mai puternică pentru algoritmi care au în general o acuratețe de interpolare scăzută (*Inverse Distance Weighted*, *Nearest Neighbour*, *Ordinary Kriging*). Ceilalți algoritmi au valori relativ apropiate ale erorii medii pătratice (RMSE) indiferent de clasa de densitate a punctelor. De exemplu, indicatorul RMSE pentru algoritmul *Natural Neighbour* are o variație redusă, de la 0.14 la 0.11 metri.

Valorile indicelui de corelație R^2 (tabelul 8.8), indică o corelație negativă pentru fiecare algoritm: creșterea densității punctelor folosite la predicție se asociază unor valori reduse pentru eroarea medie pătratică. Efectul densității punctelor cunoscute asupra preciziei de interpolare confirmă cercetările anterioare (Aguilar, 2005; Guo, 2010). De asemenea se observă o mai mare variabilitate între acuratețea algoritmilor, în situația claselor de densitate scăzută. Acest aspect este remarcat și de Chaplot (2006).

Tabelul 8.8. Valoarea coeficienților de corelație R^2 pentru legătura între factorii analizați și acuratețea de filtrare a algoritmilor.

Algoritm de interpolare	Coeficient de corelație (R^2)				
	Înclinarea terenului	Indicele de Rugozitate a Terenului (TRI)	Curbura maximă	Gradul de acoperire cu vegetație	Densitatea punctelor cunoscute
Inverse Distance Weighted (<i>IDW</i>)	0.91	0.95	0.90	0.59	-0.99
Nearest Neighbour (<i>NeM</i>)	0.94	0.97	0.88	0.66	-1.00
Natural Neighbour (<i>NM</i>)	0.83	0.88	0.87	-0.62	-0.93
Delauney Triangulation (<i>DT</i>)	0.84	0.90	0.89	-0.59	-0.93
Multilevel B-Spline (<i>BS</i>)	0.81	0.87	0.86	-0.63	-0.93
Cubic Spline (<i>CS</i>)	0.81	0.88	0.91	-0.86	-0.88
Thin Plate Spline (<i>TPS</i>)	0.81	0.87	0.85	-0.63	-0.87
Thin Plate Spline – TIN (<i>TPS_{TIN}</i>)	0.81	0.87	0.85	-0.63	-0.93
Ordinary Kriging (<i>OK</i>)	0.92	0.94	0.94	0.95	-0.98




Fig. 8.19. Eroarea medie pătratică pentru interpolare, în funcție de densitatea punctelor cunoscute. Pentru claritate, punctele sunt deplasate pe orizontală.

9. CONCLUZII ȘI CONTRIBUȚII ORIGINALE

9.1. Concluzii

Teza de doctorat a avut ca obiect general stabilirea potențialului tehnologiei de scanare laser (LiDAR) ca sursă de date pentru generarea modelului suprafeței terestre, în condițiile terenurilor acoperite cu vegetație forestieră.

Prin parcurgerea etapelor de cercetare necesare atingerii obiectivelor propuse, s-au desprins o serie de constatări generale, prezentate pe secțiuni:

Stadiul actual al cunoștințelor (Capitolele 2-5)

- a.** Metodele moderne ale geomaticii forestiere permit o cunoaștere la nivel de detaliu a pădurii ca poziție, structură, caracteristici și evoluție în timp.
- b.** Tehnologia LiDAR, bazată pe emisia undelor electromagnetice de tip laser, se înscrie în metodele moderne de cartare ale geomaticii, alături de fotogrammetrie sau teledetecție.
- c.** Tehnologia folosește fascicule coerente de lumină pentru a determina indirect distanța între emițător și suprafața care produce reflexia fasciculelor, cu scopul de a poziționa în spațiu suprafața scanată.
- d.** Avantajul tehnologiei LiDAR pentru silvicultură este dat de capacitatea de penetrare a frunzișului, care permite pulsurilor laser să atingă suprafața terestră. Se pot astfel obține simultan date despre caracteristicile vegetației și ale reliefului.
- e.** Scanarea laser aeriană (ALS), care presupune montarea senzorului LiDAR pe o platformă aeropurtată, aduce tehnologia pe același nivel cu fotogrammetria, din punct de vedere al randamentului de acoperire a suprafețelor.
- f.** Tehnologia LiDAR s-a răspândit pe plan internațional în ultimele decenii, ca o metodă precisă de cartare a suprafețelor la nivel de detaliu. Această răspândire a avut loc și în silvicultură, unde scanarea laser permite automatizarea procesului de obținere a datelor geografice și structurale ale pădurii și solului.
- g.** În România, tehnologia este încă în faza de pionerat, studiile realizate până în prezent fiind axate în general asupra estimării anumitor caracteristici dendometrice.
- h.** Datele obținute prin scanare sunt reprezentate sub forma unui nor de puncte pentru care se cunoaște poziția planimetrică și altimetrică. Trecerea la o structură comună de reprezentare a suprafeței terestre, sub forma unui Model Digital Altimetric, este un proces complex, afectat de multiple surse de erori.
- i.** Dintre sursele de erori care intervin pe parcursul procesului de trecere de la norul de puncte inițial la un model al suprafeței terestre, au fost luate în considerare pentru analiză: filtrarea datelor LiDAR (prin care se separă din norul de puncte acele observații aflate la nivelul solului) și interpolarea (prin care se generează o suprafață continuă pe baza observațiilor discrete).

Caracteristici ale condițiilor de cercetare (Capitolele 6-7)

- a. Scopul stabilit pentru teza de doctorat a fost evaluarea potențialului tehnologiei LiDAR ca sursă de date altimetrice pentru reprezentarea cu precizie ridicată a suprafeței terestre, în situația terenurilor împădurite.
- b. Pentru atingerea scopului propus, s-au stabilit două areale de studiu, denumite *Mălaia* și *Vidra*, caracterizate de un relief montan și acoperire extinsă cu vegetație forestieră.
- c. Pentru cercetare s-au folosit două tipuri de date: date LiDAR colectate prin scanare laser aeriană și date geo-topografice, colectate folosind stație totală și echipament GNSS.
- d. Pentru estimarea acurateții de modelare a suprafeței terestre, s-au identificat două tipuri de erori (de filtrare și respectiv interpolare) care au fost definite, calculate și analizate statistic.
- e. În ceea ce privește procesul de filtrare, s-a testat un număr de nouă algoritmi. S-au analizat condițiile de filtrare pentru două cazuri: (1) pentru suprafața de probă *Mălaia* (unde referința este setul de date LiDAR corect clasificat) și (2) pentru șapte suprafețe de probă delimitate în teren (unde referința este un set de date independent rezultat prin prelucrarea măsurătorilor topografice).
- f. Factorii identificați ca având o posibilă influență asupra erorilor de filtrare sunt: înclinarea terenului, Indicele de Rugozitate al Suprafeței (TRI), curbura maximă a suprafeței, gradul de acoperire cu vegetație și densitatea punctelor LiDAR.
- g. În ceea ce privește procesul de interpolare, s-a testat un număr de nouă algoritmi. Interpolarea s-a analizat pentru cazul suprafeței de probă *Vidra*, iar ca factori cu influență asupra erorilor s-au identificat înclinarea terenului, Indicele de Rugozitate al Suprafeței (TRI), curbura maximă a suprafeței, gradul de acoperire cu vegetație și densitatea punctelor pentru predicție. Analiza interpolării s-a efectuat pentru patru rezoluții spațiale de modelare: 0.5, 1.0, 1.5 și 2.0 metri.

Rezultate și discuții (Capitolul 8)

1. Cu privire la filtrarea datelor LiDAR

- a. Dintre algoritmi de filtrare analizați, acuratețea de filtrare cea mai bună este oferită de algoritmul *Lasground-new* – eroare medie pătratică de 0.34 metri pentru suprafața de probă A și un procent de 84 la sută din suprafață caracterizată de erori de determinare a altitudinii de sub 0.20 metri.
- b. Principiul de filtrare al algoritmilor afectează acuratețea filtrării: cei trei algoritmi bazați pe generarea de suprafețe (*GroundFilter*, *BCAL* și *MCC*) se asociază cu erori medii pătratice mai mari, relativ la algoritmi morfologici sau cei din categoria adaptare-TIN.

- c. Șapte dintre cei nouă algoritmi analizați filtrează un număr de puncte mai mare decât cel real – erorile de comitere (atribuirea în clasa *Teren* a punctelor aflate deasupra suprafeței terestre) sunt deci mai probabile decât cele de omitere.
- d. Distribuția spațială a erorilor a fost analizată pentru trei algoritmi de filtrare, câte unul din fiecare categorie (*Lasground-new*, *MLS*, *gLiDAR*); rezultatele indică o acuratețe ridicată pentru cea mai mare parte a *suprafeței de probă A* (între 74 și 84 la sută din suprafață este caracterizată de erori absolute de până la 0.20 metri). Totuși, apar și erori semnificative, de peste 1 metru, chiar dacă acestea sunt rare (între 2 și 6 la sută din suprafața de probă, în funcție de algoritm). Se impune astfel necesitatea corectării manuale a rezultatului filtrării pentru a obține o reprezentare adecvată a suprafeței terestre.
- e. Situația erorilor pentru *suprafețele de probă 1-7*, cartate folosind metode geo-topografice, este în linii mari aceeași cu situația pentru *suprafața de probă A*, descrisă la punctul anterior.
- f. Condițiile de teren (înclinarea terenului, Indicele de Rugozitate a Suprafeței și curbura maximă a suprafeței) au o influență semnificativă asupra erorilor de filtrare (indicele de corelație R^2 are valori între 0.88 și 1, în funcție de factor și algoritm).
- g. Pentru analiza corelației spațiale a erorilor s-a calculat indicatorul *Local Moran's I*, valorile acestuia indicând un grad redus de grupare pe *clustere* a erorilor de filtrare.
- h. Referitor la procesul de filtrare automată a datelor LiDAR, putem afirma că rezultatele sunt mulțumitoare sub aspectul preciziei. Trebuie ținut seama de faptul că scanarea laser s-a realizat în perioada de vegetație, iar ecosistemele forestiere reprezintă o provocare pentru orice algoritm de filtrare (Guan ș.a., 2014; Maguya ș.a., 2014; Montealegre ș.a., 2015).

2. Cu privire la interpolarea suprafeței terestre

- a. Cei nouă algoritmi de interpolare testați au o precizie similară, estimată prin eroarea medie pătratică. Media aritmetică a erorilor este apropiată de zero în toate cazurile, indicând lipsa unei tendințe de supra-estimare sau sub-estimare a predicției.
- b. Întrucât nivelul de acuratețe globală este relativ similar între algoritmi, se impune analiza calitativă (sub aspect vizual) a suprafețelor interpolate (Wood și Fischer, 1993). Se remarcă prezența artefactelor vizuale de interpolate în toate cazurile, dar acestea sunt mai puțin pronunțate în cazul algoritmului *Nearest Neighbour* și al algoritmilor din categoria RBF (*Radial Basis Functions*).
- c. Se constată o variație semnificativă a erorilor de interpolare în funcția de rezoluția modelului. Trebuie ținut seama însă de faptul că la estimarea erorilor s-a folosit metoda *cross-validation* – în acest caz, valoarea unui punct de validare se compară cu cel mai apropiat punct pentru care s-a realizat predicția (reprezentat de centrul unei celule a modelului); atunci când rezoluția scade (celulele au o dimensiune mai mare), distanțele între punctele

de validare și cele de predicție cresc, deci crește și posibilitatea unei diferențe reale (nu cauzate de o eroare) între valorile altimetrice ale celor două puncte.

- d. Modificarea înclinației terenului influențează negativ acuratețea de predicție indiferent de algoritmul de interpolare folosit, rezultat în acord cu cercetările anterioare (Aguilar, 2005; Su și Bork, 2006; Sterenczak ș.a., 2016). Astfel, dacă pentru terenurile plate (cu înclinare de până la 5 grade) eroarea medie pătratică este de sub 0.10 metri, aceasta crește la peste 0.50 metri în zonele cu înclinație de peste 30-40 grade.
- e. Densitatea punctelor cunoscute influențează de asemenea acuratețea de interpolare, rezultat care confirmă cercetări anterioare (Aguilar, 2005; Guo, 2010). Se remarcă faptul că, atunci când densitatea punctelor scade, se accentuează diferențele de acuratețe între algoritmi. În această situație capătă importanță alegerea algoritmului de interpolare.
- f. În ceea ce privește gradul de acoperire cu vegetație, acest factor influențează negativ magnitudinea erorilor. Astfel, la acoperire de până la 20 la sută erorile medii pătratice au valori în jur de 0.20 metri, iar la o acoperire cu vegetație de peste 90 la sută erorile medii pătratice au valori de 0.35-0.45 metri.
- g. Luând în considerare valorile erorilor precum și analiza vizuală a rezultatelor, cel mai adecvat algoritm de interpolare pentru situația de față este *Natural Neighbour*. Dincolo de erori, care sunt similare cu cele ale celorlalți algoritmi, avantajul *Natural Neighbour* este timpul redus de procesare și ușurința utilizării (algoritmul nu necesită setare de parametri).
- h. În final, putem afirma că acuratețea de interpolare este relativ bună, ținând seama de topografia complexă a suprafeței de studiu. Totuși, apar izolat erori de ordinul metrilor, care necesită corecții manuale sau automate (prin aplicarea filtrelor de trecere sau "umplerea golurilor"⁵).

În ansamblu, putem concluziona că procesarea automată a datelor LiDAR cu scopul de a obține un model detaliat al suprafeței terestre oferă un grad satisfăcător de acuratețe. Trebuie avut în vedere faptul că datele LiDAR folosite la cercetare nu au fost înregistrate în scopuri forestiere. Astfel, prin planificarea adecvată scopurilor a campaniei de zbor (de exemplu, realizarea înregistărilor în perioada de toamnă/primăvară, când frunzișul este absent dar terenul nu este acoperit de zăpadă) ne așteptăm ca volumul de muncă implicat la procesare să se reducă, în timp ce acuratețea de reprezentare a reliefului să crească.

Stadiul actual al dezvoltării algoritmilor (atât în cazul procesului de filtrare, cât și al interpolării) impune realizarea unor corecții manuale a rezultatelor. Alegerea algoritmului, stabilirea parametrilor de operare și condițiile de teren influențează volumul de lucru necesar la corecția manuală. Dintre cele două operațiuni, filtrarea este cea care are potențialul de a produce erori verticale mai mari. Astfel, în urma filtrării folosind algoritmul *Lasground-new*, care oferă cel mai precis rezultat, se obține o reprezentare a suprafeței terestre caracterizată în proporție de 84 la sută de erori verticale mai mici de

⁵ în engl. *sink-fill*

0.20 metri și sub 2 procente din suprafață cu erori majore, de peste 1 metru. În situația interpolării, aplicarea algoritmului *Nearest Neighbour*, cu care s-a obținut cel mai precis rezultat, conduce la un model al terenului cu erori mai mici de 0.20 metri pentru aproape 94 la sută din suprafață, respectiv erori majore (de peste 1 metru) cu o acoperire nesemnificativă (0.02 procente din suprafața analizată).

9.2. Contribuții originale

Rezultatele obținute prin desfășurarea cercetărilor și concluziile formulate pe baza acestora scot în evidență o serie de contribuții personale:

- a. Desfășurarea unei cercetări bibliografice exhaustive asupra tehnologiei LiDAR, ca metodă generală a geomaticii, în special din perspectiva aplicabilității în domeniul forestier.
- b. Axarea cercetărilor asupra potențialul scanării laser de a oferi date privind relieful suprafeței terestre, în situația terenurilor acoperite cu vegetație forestieră.
- c. Stabilirea unei proceduri ample de evaluare a erorilor, ca distribuție statistică și spațială, care permite compararea obiectivă a algoritmilor sau a procedurilor de lucru. Această metodă a presupus și realizarea măsurătorilor geo-topografice, pentru obținerea unor date independente.
- d. Testarea detaliată a celor două etape principale de prelucrare a datelor LiDAR (filtrarea, respectiv interpolarea suprafeței): s-au analizat un număr ridicat de algoritmi, cu diferite procedee de lucru.
- e. Analizarea erorilor nu doar sub aspectul distribuției statistice, dar și ca distribuție spațială. S-au stabilit de asemenea proceduri de estimare a influenței condițiilor de teren sau vegetație asupra procesului de filtrare, respectiv interpolare.
- f. Formularea avantajelor tehnologiei LiDAR, dar și identificarea limitărilor, din perspectiva geomaticii forestiere.

BIBLIOGRAFIE SELECTIVĂ

- Aguilar, F.J., Mills, J.P., Delgado, J., Aguilar, M.A., Negreiros, J., Pérez, J.L. (2010). Modelling vertical error in LiDAR-derived digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing* **65**, p. 103-110.
- Axelsson, P. (2000). DEM generation from laser scanner data using adaptive TIN models. *International archives of photogrammetry and remote sensing* **33.4**, p. 110-117.
- Baltsavias, E.P. (1999). A comparison between photogrammetry and laser scanning. *ISPRS Journal of photogrammetry and Remote Sensing* **54**, p. 83-94.
- Bater, C.W., Coops, N.C. (2009). Evaluating error associated with lidar-derived DEM interpolation. *Computers & Geosciences* **35**, p. 289-300.
- Birjaru, C. (2011). *Cercetari privind utilizarea tehnologiei LiDAR in lucrarile din silvicultura*. Ph.D. thesis, Universitatea "TRANSILVANIA" din Brasov.
- Cățeanu, M., Arcadie, C. (2017). ALS for terrain mapping in forest environments: an analysis of lidar filtering algorithms. *EARSeL eProceedings* **16**, p. 9-20.**
- Cățeanu, M., Ciubotaru, A., Tereșneiu, C.-C. (2017a). Lidar for ground surface mapping in forest environments. *Journal of Young Scientist* **5**, p. 173-178.**
- Cățeanu, M., Ciubotaru, A., Tereșneiu, C.-C. (2017b). LiDAR data for terrain slope estimation in forest areas. *Proceedings of the Biennial International Symposium. Forest and Sustainable Development, Brasov, 7-8th October 2016*, p. 35-40.**
- Chaplot, V., Darboux, F., Bourennane, H., Leguédois, S., Silvera, N., Phachomphon, K. (2006). Accuracy of interpolation techniques for the derivation of digital elevation models in relation to landform types and data density. *Geomorphology* **77**, p. 126-141.
- Chen, Q., Gong, P., Baldocchi, D., Xie, G. (2007). Filtering airborne laser scanning data with morphological methods. *Photogrammetric Engineering & Remote Sensing* **73**, p. 175-185.
- Ciubotaru, A. (1998). *Exploatarea padurilor*. Ed. Lux Libris, Brasov.
- Csanyi, N., Toth, C.K. (2007). Improvement of lidar data accuracy using lidar-specific ground targets. *Photogrammetric Engineering & Remote Sensing* **73(4)**, p. 385-396.
- Evans, J.S., Hudak, A.T. (2007). A multiscale curvature algorithm for classifying discrete return LiDAR in forested environments. *IEEE Transactions on Geoscience and Remote Sensing* **45**, p. 1029-1038.
- Fisher, P.F., Tate, N.J. (2006). Causes and consequences of error in digital elevation models. *Progress in physical Geography* **30**, p. 467-489.
- Guan, H., Li, J., Yu, Y., Zhong, L., Ji, Z. (2014). DEM generation from lidar data in wooded mountain areas by cross-section-plane analysis. *International journal of remote sensing* **35**, p. 927-948.
- Guo, Q., Li, W., Yu, H., Alvarez, O. (2010). Effects of topographic variability and lidar sampling density on several DEM interpolation methods. *Photogrammetric Engineering & Remote Sensing* **76**, p. 701-712.
- Hodgson, M.E., Bresnahan, P. (2004). Accuracy of airborne LiDAR-derived elevation. *Photogrammetric Engineering & Remote Sensing* **70**, p. 331-339.
- Hyyppä, H., Yu, X., Hyyppä, J., Kaartinen, H., Kaasalainen, S., Honkavaara, E., Rönnholm, P. (2005). Factors affecting the quality of DTM generation in forested areas. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* **36**, p. 85-90.
- Hyyppä, J., Pyysalo, U., Hyyppä, H., Samberg, A. (2000). Elevation accuracy of laser scanning-derived digital terrain and target models in forest environment. *Proceedings of EARSeL-SIG-Workshop LIDAR*, p. 14-17.
- ISPRS (1999). Special issue on airborne laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing* **54**, p. 61-214.
- Kobler, A., Pfeifer, N., Ogrinc, P., Todorovski, L., Oštir, K., Džeroski, S. (2007). Repetitive interpolation: a robust algorithm for DTM generation from aerial laser scanner data in forested terrain. *Remote sensing of environment* **108**, p. 9-23.

- Korzeniowska, K., Pfeifer, N., Mandlbürger, G., Lugmayr, A. (2014). Experimental evaluation of ALS point cloud ground extraction tools over different terrain slope and land-cover types. *International Journal of Remote Sensing* **35**, p. 4673-4697.
- Kraus, K., Pfeifer, N. (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* **53**, p. 193-203.
- Li, Z. (1988). On the measure of digital terrain model accuracy. *The photogrammetric record* **12**, p. 873-877.
- Maguaya, A.S., Junttila, V., Kauranne, T. (2014). Algorithm for extracting digital terrain models under forest canopy from airborne LiDAR data. *Remote Sensing* **6**, p. 6524-6548.
- McGaughey, R (2014). *FUSION/LDV: software for LiDAR data analysis and visualization. Version 3.41. Seattle, WA: US Department of Agriculture, Forest Service.* .
- Meng, X., Currit, N., Zhao, K. (2010). Ground filtering algorithms for airborne LiDAR data: A review of critical issues. *Remote Sensing* **2**, p. 833-860.
- Montealegre, A.L., Lamelas, M.T., de la Riva, J. (2015). A comparison of open-source LiDAR Filtering algorithms in a mediterranean forest environment. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of* **8**, p. 4072-4085.
- Petrila, M., Gancz, V., Apostol, B., Loren , A. (2012a). Comparing height of individual spruce trees determined on LiDAR data and reference field measurements. *EARSeL Symposium*, p. 251-262. Mykonos Island, Greece.
- Pingel, T.J., Clarke, K.C., McBride, W.A. (2013). An improved simple morphological filter for the terrain classification of airborne LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* **77**, p. 21-30.
- Popescu, S.C., Zhao, K., Neuenschwander, A., Lin, C. (2011). Satellite lidar vs. small footprint airborne lidar: Comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. *Remote Sensing of Environment* **115.11**, p. 2786-2797.
- Reutebuch, S.E., McGaughey, R.J., Andersen, H.-E., Carson, W.W. (2003). Accuracy of a high-resolution lidar terrain model under a conifer forest canopy. *Canadian journal of remote sensing* **29**, p. 527-535.
- Shan, J., Toth, C.K. (2009). *Topographic laser ranging and scanning*. Ed. CRC press.
- Silván-Cárdenas, J.L., Wang, L. (2006). A multi-resolution approach for filtering LiDAR altimetry data. *ISPRS Journal of Photogrammetry and Remote Sensing* **61**, p. 11-22.
- Sithole, G., Vosselman, G. (2005). Filtering of airborne laser scanner data based on segmented point clouds. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* **36**, p. W19.
- Stereńczak, K., Ciesielski, M., Balazy, R., Zawiła-Niedźwiecki, T. (2016). Comparison of various algorithms for DTM interpolation from LIDAR data in dense mountain forests. *European Journal of Remote Sensing* **49**, p. 599-621.
- Su, J., Bork, E. (2006). Influence of vegetation, slope, and lidar sampling angle on DEM accuracy. *Photogrammetric Engineering & Remote Sensing* **72**, p. 1265-1274.
- Tamas, S., Teresneu, C. (2010). *Concepte si tehnici ale sistemelor de informatii geografice*. Ed. Lux Libris, Brasov.
- Vosselman, G. (2000). Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing* **33**, p. 935-942.
- Wehr, A., Lohr, U. (1999). Airborne laser scanning-an introduction and overview. *ISPRS Journal of photogrammetry and remote sensing* **54**, p. 68-82.
- Weng, Q. (2006). An evaluation of spatial interpolation accuracy of elevation data. Riedl, Andreas, W.K., and Elmes, G.A. (Ed.), *Progress in spatial data handling*, Springer.
- Wood, J.D., Fisher, P.F. (1993). Assessing interpolation accuracy in elevation models. *IEEE Computer Graphics and Applications* **13**, p. 48-56.
- Zhang, K., Whitman, D. (2005). Comparison of three algorithms for filtering airborne lidar data. *Photogrammetric Engineering & Remote Sensing* **71**, p. 313-324.
- Zhao, X., Guo, Q., Su, Y., Xue, B. (2016). Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas. *ISPRS Journal of Photogrammetry and Remote Sensing* **117**, p. 79-91.

REZUMAT: Teza de doctorat realizează un studiu aprofundat al tehnologiei de scanare prin laser (LiDAR), cu privire la utilizarea acesteia ca sursă de date altimetrice pentru modelarea suprafeței terestre în cazul terenurilor împădurite. Metoda de scanare laser aeriană (ALS) permite folosirea senzorilor LiDAR la cartarea suprafețelor extinse, în urma măsurătorilor rezultând un nor de puncte poziționate în spațiu. Transformarea norului de puncte inițial într-un model digital al suprafeței terestre presupune două etape de prelucrare: (1) filtrarea, prin care se elimină din setul de date acele observații aflate deasupra nivelului terenului și (2) interpolarea, prin care pornind de la setul de puncte aflate la sol se generează o suprafață continuă care modelează altitudinea terenului.

S-a stabilit o procedură de evaluare a performanței algoritmilor de filtrare, respectiv interpolare, din punct de vedere al acurateții modelului obținut. Erorile de filtrare, respectiv interpolare au fost definite, calculate și analizate ca distribuție statistică și spațială. Acuratețea de filtrare a fost testată în două variante, folosind ca referință: (1) norul de puncte filtrat manual, considerat corect și (2) date independente, obținute prin măsurători geo-topografice desfășurate pentru opt suprafețe de probă. În cazul interpolării, pentru estimarea erorilor s-a folosit metoda cros-validării.

Rezultatele obținute arată o performanță de filtrare optimă pentru algoritmul *Lasground-new*, Modelul Digital Altimetric având o eroare medie pătratică de 0.34, respectiv 0.66 metri, în funcție de varianta de testare. În ceea ce privește interpolarea, cea mai bună performanță se asociază algoritmului *Nearest Neighbour*, cu o eroare medie pătratică de 0.34 metri. Dintre factorii externi analizați, s-a identificat o legătură între condițiile de teren (înclinare, rugozitate, curbură) și acuratețea de filtrare, respectiv interpolare.

ABSTRACT: The doctoral thesis is an elaborate study of laser scanning (LiDAR), with regards to its use as a source of altimetry data for ground surface modelling in forested areas. Airborne Laser Scanning (ALS) uses LiDAR sensors for mapping vast areas by generating geo-referenced point clouds. Obtaining a digital model of the ground surface from the initial point cloud requires two processing steps: (1) filtering, by which those observations located above the ground level are eliminated from the dataset and (2) interpolation, which generates a continuous surface that models altitude using the remaining ground points.

A procedure that evaluates the performance of filtering and interpolation algorithms with regards to model accuracy, was developed. Filtering and interpolation errors were defined, calculated and their statistical and spatial distribution was analysed. Filtering accuracy was tested using two methods, with the reference being: (1) the manually filtered point cloud, considered correct and (2) independent data, from topographical surveys carried out in eight test plots. Regarding the interpolation, error estimation was carried out using cross-validation.

Results show an optimum filtering performance for the *Lasground-new* algorithms, with the Digital Elevation Model having a RMSE value of 0.34, or 0.66 metres, depending on the testing method. With regards to interpolation, the best performance is associated with the *Nearest Neighbour* algorithm, which has a RMSE of 0.34 metres. Of the external factors used in the analysis, a correlation between ground surface parameters (slope, ruggedness, curvature) and the accuracy of filtering and interpolation was identified.

CURRICULUM VITAE

Nume și prenume: CĂȚEANU MIHNEA

E-mail: , cateanu.mihnea@unitbv.ro

Studii:

2014 – prezent. Doctorand cu frecvență în domeniul Silvicultură, în cadrul Universității Transilvania din Brașov, Facultatea de Silvicultură și Exploatare Forestiere.

2012 – 2014. Masterat. Universitatea de Vest din Timișoara, Facultatea de Chimie, Biologie, Geografie, specializarea "Sisteme Informaționale Geografice".

2008 – 2012. Licență. Universitatea Transilvania din Brașov, Facultatea de Silvicultură și Exploatare Forestiere, specializarea Măsurători Terestre și Cadastru.

Experiență profesională:

11.2014 – 02.2016. Inginer geodez, S.C. DANINA STAR S.R.L., Brașov.

01.2014 – 08.2014. Inginer geodez, S.C. GEOLINK S.R.L., Timișoara.

08.2013 – 01.2014. Curier, S.C. GEOLINK S.R.L., Timișoara.

Competențe lingvistice: limba engleză (utilizator independent).

Competențe tehnice: Operare PC, suita Microsoft Office, programe CAD, SIG, programe prelucrare statistică (SPSS, Statistica), programe prelucrare măsurători topografice, folosire aparatură topografică (stație totală, receptor GNSS etc.).

CURRICULUM VITAE

Name and Surname: CĂȚEANU MIHNEA

E-mail: [c](mailto:cateanu.mihnea@unitbv.ro) , cateanu.mihnea@unitbv.ro

Education:

2014 – present. PhD student in Silviculture, Transilvania University of Braşov, Faculty of Silviculture and Forest Engineering.

2012 – 2014. Master degree. West University of Timișoara, Faculty of Chemistry, Biology, Geography, study programme “Geographical Information Systems”.

2008 – 2012. Bachelor degree. Transilvania University of Braşov, Faculty of Silviculture and Forest Engineering, Land Survey and Cadaster study programme.

Professional experience:

11.2014 – 02.2016. Geodetic engineer, S.C. DANINA STAR S.R.L., Braşov.

01.2014 – 08.2014. Geodetic engineer, S.C. GEOLINK S.R.L., Timișoara.

08.2013 – 01.2014. Courier, S.C. GEOLINK S.R.L., Timișoara.

Language skills: English (independent user).

Technical skills: PC operator, Microsoft Office suite, CAD and SIG software, software for statistical analysis (SPSS, Statistica), software for processing topographical data, using topographical equipment (total stations, GNSS receiver etc.).