


UTCB

Contribuții la automatizarea extragerii informațiilor spațiale în vederea modelării 3D

REZUMAT TEZĂ DE DOCTORAT



Conducător de doctorat: Prof. univ. dr. ing. Petre Iuliu DRAGOMIR

Studentă doctorand: Drd. ing. Iuliana Maria BINĂ (căs. PÂRVU)

Iunie 2021

Mulțumiri

Elaborarea științifică a prezentei teze de doctorat reprezintă rezultatul cercetărilor efectuate în perioada octombrie 2018 – mai 2021, în cadrul Universității Tehnice de Construcții București, Facultatea de Geodezie, în domeniul Inginerie civilă.

În primul rând doresc să mulțumesc conducătorului științific, domnului prof.univ.dr.ing. Petre Iuliu DRAGOMIR, care mi-a îndrumat pașii în perioada studiilor doctorale și mi-a oferit sprijin didactic și idei utile pentru elaboarea tezei de doctorat. Au fost momente mai dificile, pe parcursul ultimului an, în care încrederea oferită de domnia sa m-a ajutat să continui și să ajung la finalizarea acestei cercetări.

Doresc să mulțumesc întregului colectiv de cadre didactice din cadrul Departamentului de Topografie și Cadastru, Facultatea de Geodezie, București, pentru recomandările și aprecierile științifice pe care mi le-au oferit cu prilejul susținerii tezei de doctorat în catedră.

Pe această cale doresc să mulțumesc conducerii Centrului Național de Cartografie și a Serviciului de Cartografie și Fotogrammetrie pentru sprijinul acordat în ceea ce privește furnizarea datelor care stau la baza cercetărilor și a oportunității de a participa activ în proiectul european de cercetare VOLTA. Doresc să mulțumesc pentru colaborarea fructuoasă pe timpul delegării la sediul *Bruno Kessler Foundation* (Trento, Italia), domnului Fabio REMONDINO, conducătorul colectivului *3D Optical Metrology* și domnului Emre OZDEMIR, student doctorand în cadrul colectivului.

Chiar dacă nu l-am cunoscut personal, ci doar prin intermediul cursurilor video, vreau să-i mulțumesc domnului Ian WITTEN, de la Universitatea din Waikato, Noua Zeelandă, de la care am învățat lucruri importante legate de *Data mining* și despre software-ul *Weka*.

Sincere mulțumiri Departamentului de Geodezie și Geoinformații al Universității Tehnice din Viena pentru punerea la dispoziție a software-ului OPALS, cu care am realizat o parte din fluxul de lucru.

Doresc să le mulțumesc părinților mei pentru suportul și încrederea acordată pe parcursul anilor de studiu. Mamei mele doresc să îi transmit că ceea ce sunt i se datorează.

Cei mai importanți susținători ai mei, pe parcursul studiilor doctorale, au fost fiii mei, Eduard (9 ani) și Mihnea (5 ani), și soțul meu, Adrian. Chiar dacă le-a fost greu pentru că nu am mai avut așa de mult timp împreună, în special în ultimul an, au fost mereu încrezători în forțele mele și m-au încurajat. Soțul meu mi-a oferit sfaturi profesionale și m-a ajutat să depășesc momentele de blocaj.

Cuprins

Cuprins	2
1. Introducere.....	7
1.1. Introducere generală.....	7
1.2. Motivație	7
1.3. Obiective și scop	7
1.4. Structura tezei de doctorat.....	8
2. Achiziția datelor spațiale prin scanarea laser	10
2.1. Introducere	10
2.2. Scurt Istoric	10
2.3. Noțiuni introductive.....	10
2.4. Clasificarea sistemelor de scanare laser	10
2.5. Aplicații ale scanării laser.....	11
2.6. Scanarea laser aeriană tradițională	11
2.6.1. Principiul de funcționare al unui sistem ALS	11
2.6.2. Componentele unui sistem ALS	11
2.6.2.1. Scannerul laser	12
2.6.2.2. Sistemul POS	12
2.6.3. Reflectanța și interacțiunea cu obiectele.....	12
2.6.4. Evoluția scannerelor ALS.....	12
2.6.5. Flux de lucru pentru scanarea laser ALS.....	13
2.6.5.1. Planificarea misiunii de scanare	13
2.6.5.2. Măsurători la teren.....	13
2.6.5.3. Achiziționarea datelor prin scanarea laser.....	13
2.6.5.4. Procesarea datelor LiDAR.....	13
2.6.5.5. Generarea Produselor Finale	14
2.7. Scanarea laser aeriană tip SPL	14
2.8. Scanarea laser aeriană Geiger-mode	14
2.9. Prezentarea datelor LiDAR din studiul de caz.....	14
3. Achiziția datelor geospațiale prin aerofotografiere	16
3.1. Introducere	16
3.2. Evoluția fotogrammetriei.....	16

3.3.	Principiile de bază ale fotogrammetriei	16
3.4.	Sisteme fotogrammetrice aeriene	17
3.4.1.	Camere fotogrammetrice nadirale	17
3.4.2.	Camere fotogrammetrice oblice.....	17
3.5.	Flux de lucru fotogrammetric.....	17
3.5.1.	Planificarea misiunii de aerofotografiere.....	17
3.5.2.	Efectuarea măsurătorilor la teren și a zborului fotogrammetric.....	18
3.5.3.	Extragerea punctelor de legătură	18
3.5.4.	Compensarea în bloc a imaginilor	18
3.5.5.	Realizarea DIM și MDS	18
3.5.6.	Generarea ortofotoplanului	18
3.6.	Aplicații ale aerofotografierii	19
3.7.	Prezentarea datelor fotogrammetrice din studiul de caz	19
4.	Extragerea elementelor din norii de puncte LiDAR	20
4.1.	Introducere și scop	20
4.2.	Metode de segmentare a norilor de puncte LiDAR.....	20
4.2.1.	Metode de segmentare bazate pe muchii	20
4.2.2.	Metode de segmentare bazate pe regiuni	20
4.2.3.	Metode de segmentare bazate pe atribute.....	20
4.2.4.	Metode de segmentare bazate pe potrivirea de modele	21
4.2.4.1.	Metode de segmentare bazate pe grafice	21
4.2.5.	Metode hibride de segmentare.....	21
4.2.6.	Metode de segmentare bazate pe machine learning.....	21
4.3.	Metode de clasificare a norilor de puncte bazate pe Machine learning	21
4.3.1.	Caracteristici ale punctelor 3D.....	22
4.3.1.1.	PCA, valori și vectori proprii	22
4.3.1.2.	Generalități despre caracteristicile punctelor 3D	22
4.3.1.2.1.	Caracteristici 3D ale punctelor LiDAR	22
4.3.1.2.2.	Caracteristici 2D ale punctelor LiDAR.....	23
4.3.2.	Selectarea vecinătății	23
4.3.3.	Extragerea caracteristicilor 3D	23
4.3.4.	Selectarea caracteristicilor optime	23
4.3.5.	Clasificarea supervizată.....	23
4.3.6.	Evaluarea calității clasificării norilor de puncte.....	24

4.4.	Studiu de caz pentru clasificarea norilor de puncte	25
4.4.1.	Pregătirea norului de puncte	25
4.4.2.	Selectarea vecinătății în mod dinamic	25
4.4.3.	Extragerea caracteristicilor	26
4.4.4.	Clasificarea norilor de puncte și evaluarea calității rezultatelor	27
4.4.4.1.	Software Weka	27
4.4.4.2.	Crearea setului de date de învățare și de testare	27
4.4.4.3.	Analiza metodelor de Machine learning - studiu comparativ	27
4.4.4.4.	Analiza rezultatelor pentru clasificatorii folosiți	27
4.4.4.5.	Flux de lucru pentru clasificarea norului de puncte	29
5.	Extragerea elementelor din imagini ortorectificate	30
5.1.	Introducere și scop	30
5.2.	Noțiuni introductive	30
5.3.	Extragerea elementelor din imagini utilizând Machine learning	30
5.4.	Extragerea elementelor din imagini utilizând rețele neuronale artificiale	30
5.4.1.	Scurt istoric al dezvoltării rețelelor neuronale	30
5.4.2.	Definiții consacrate ale rețelelor neuronale artificiale	31
5.4.3.	Neuronul natural versus neuronul artificial	31
5.4.3.1.	Neuronul natural	31
5.4.3.2.	Neuronul artificial	31
5.4.4.	Arhitectura rețelelor neuronale artificiale	32
5.4.5.	Rețele neuronale profunde	32
5.4.6.	Procesul de învățare în rețele neuronale artificiale	33
5.4.7.	Aplicații ale RNA	33
5.4.8.	Arhitecturile CNN de bază	33
5.4.8.1.	AlexNet	33
5.4.8.2.	VGGNet	34
5.4.8.3.	NiN Net	34
5.4.8.4.	GoogLeNet	34
5.4.8.5.	ResNet	34
5.4.8.6.	DenseNet	34
5.4.9.	Arhitecturi CNN folosite pentru segmentarea semantică a imaginilor	34
5.4.9.1.	FCN	34
5.4.9.2.	SegNet	34

5.4.9.3.	U-net	35
5.4.9.4.	DeconvNet	35
5.5.	Evaluarea calității clasificării și segmentării semantice a imaginilor	35
5.6.	Cadre de lucru consacrate cu RNA	35
5.7.	Studiu de caz pentru segmentarea semantică a imaginilor	35
5.7.1.	Clasificarea imaginilor pe baza algoritmilor de tip Machine learning.....	35
5.7.1.1.	Clasificarea supervizată la nivel de pixel.....	35
5.7.1.2.	Clasificarea supervizată la nivel de obiect.....	37
5.7.2.	Clasificarea imaginilor pe baza rețelelor neuronale profunde.....	37
6.	Modelarea 3D a clădirilor pe baza norilor de puncte	39
6.1.	Introducere și scop	39
6.2.	Generarea modelelor 3D ale clădirilor	39
6.2.1.	Metode de generare a modelelor 3D bazate pe modele	39
6.2.2.	Metode de generare a modelelor 3D bazate pe date	39
6.2.3.	Software-uri de procesare a norilor de puncte	40
6.3.	Nivelul de detaliere în CityGML	40
6.3.1.	CityGML 2.0.....	40
6.3.2.	CityGML 3.0.....	41
6.4.	Aplicații ale modelelor 3D ale clădirilor	41
6.5.	Situația internațională actuală în modelarea 3D a clădirilor	41
6.6.	Software pentru generarea modelelor digitale 3D ale clădirilor	42
6.6.1.	BuildingReconstruction	42
6.6.2.	Esri CityEngine	42
6.6.3.	3dfier.....	42
6.6.4.	PolyFit.....	42
6.7.	Erori geometrice și semantice în seturile de modele 3D CityGML	43
6.7.1.	Tipuri de erori geometrice și semantice	43
6.7.2.	Software de validare a topologiei	43
6.8.	GIS 3D și BIM.....	43
6.9.	Studiu de caz - generarea modelelor 3D ale clădirilor	43
6.9.1.	Extragerea amprentelor la sol ale clădirilor din norii de puncte LiDAR.....	44
6.9.1.1.	Generarea amprentelor la sol din nori de puncte segmentați.....	44
6.9.1.1.1.	Grupare condiționată	44
6.9.1.1.2.	Extragerea planurilor.....	44

6.9.1.2.	Post-procesarea poligoanelor segmentate	45
6.9.2.	Generarea modelelor 3D ale clădirilor în software-ul 3dfier	46
6.9.3.	Generarea modelelor 3D ale clădirilor în software-ul CityEngine	47
6.9.3.1.	Extragerea înălțimii clădirilor pe baza punctelor centroid.....	47
6.9.3.2.	Extragerea înălțimii clădirilor pe baza punctelor caracteristice	48
6.9.4.	Analiza calității modelelor 3D ale clădirilor.....	49
7.	Generarea și publicarea modelelor 3D ale clădirilor pentru Municipiul Arad.....	51
7.1.	Introducere și scop	51
7.2.	Generarea modelelor 3D pentru MRJ Arad	51
7.2.1.	Date inițiale.....	51
7.2.2.	Prelucrarea setului de date în vederea utilizării software-ului CityEngine.....	51
7.2.3.	Generarea modelelor 3D ale clădirilor în CityEngine	53
7.2.4.	Evaluarea calității modelelor generate pe baza poligoanelor din TopRo5	53
7.3.	Publicarea modelelor 3D ale clădirilor în mediul ArcGIS Online	54
7.3.1.	Despre ArcGIS Online și CityEngine WebViewer.....	54
7.3.2.	Interfața web și prezentare datelor publicate online.....	54
8.	Concluzii generale, contribuții originale și perspective de viitor	56
8.1.	Concluzii generale.....	56
8.2.	Contribuții personale.....	61
8.3.	direcții viitoare de cercetare.....	62
	Bibliografie	63
	Listă de lucrări publicate	68

1. Introducere

1.1. Introducere generală

Fie că este vorba despre nori de puncte LiDAR sau de imagini ortorectificate, extragerea informațiilor spațiale din produsele fotogrammetrice sau de teledetecție suscită un interes deosebit cercetătorilor din domeniu. Dacă până nu demult elementele hărților și planurilor erau exclusiv digitizate, în ultima perioadă extragerea semiautomatizată sau chiar automatizată este soluția folosită de majoritatea companiilor.

Clasificarea sau segmentarea norilor de puncte sau a imaginilor se poate realiza prin diverse tehnici și pe baza unei game variate de algoritmi. Cele mai folosite metode sunt cele bazate pe Machine learning sau chiar pe rețele neuronale artificiale profunde.

Administrațiile locale și nu numai au de îndeplinit sarcini complexe în vederea planificării urbane. Prin urmare, au nevoie de **reprezentarea virtuală** a orașului lor. Astfel, necesitatea trecerii de la modelarea 2D la cea 3D este evidentă și extrem de necesară. Modelele 3D ale orașelor devin o preocupare a agențiilor de cartografiere naționale din multe țări ale lumii.

1.2. Motivație

În majoritatea tezelor de doctorat analizate, precum și în articolele de specialitate, tema modelării 3D a clădirilor este tratată la nivel de clădire individuală (biserici, monumente etc.) sau pe zone mici. În teza de doctorat în cauză, mi-am propus să generez modelul 3D al clădirilor pentru o zonă extinsă, de tipul unui municipiu reședință de județ. Dificultatea generării modelelor 3D ale clădirilor rezidă, în acest caz, din cantitatea mare de date și din necesitățile sporite de performanță hardware-software. Identificarea unui flux de lucru care să conducă la o calitate bună a modelării este una dintre cele mai mari provocări.

1.3. Obiective și scop

În prezenta teză va fi pus accentul pe clădiri.

Obiectivele principale ale tezei sunt: extragerea automatizată a conturilor clădirilor atât din nori de puncte, cât și din imagini ortorectificate și generarea modelelor 3D ale clădirilor cu nivelul de detaliere LoD1, respectiv LoD2. Pe lângă aceste obiective, care reies din titlul tezei, mi-am propus să ofer un cadru specializat și actual în ceea ce privește fluxurile de lucru de scanare laser și de aerofotografiere, procesarea datelor rezultate și situația internațională a modelării 3D a clădirilor. Un alt obiectiv este identificarea unui flux de lucru optimizat pentru clasificarea norilor de puncte ALS.

Pe parcursul tezei de doctorat, testele vor fi realizate pe o zonă din Municipiul Arad cu clădiri cu regim de înălțime mic și mediu. Am ales acest tip de zonă datorită provocărilor pe

care vegetația le creează atât în extragerea clădirilor din nori de puncte, cât și din imagini fotogrammetrice. În final, pe întreaga suprafață a municipiului Arad vor fi generate modele 3D ale clădirilor.

Scopul tezei de doctorat este crearea unui cadru de lucru, astfel încât autoritățile în domeniu să facă demersurile necesare în vederea demarării unui proiect național de generarea a modelelor 3D ale clădirilor pentru toate orașele țării și publicarea acestora, sub formă de date deschise, pe un portal național.

1.4. Structura tezei de doctorat

Teza de doctorat este structurată în 8 capitole, după cum urmează:

Capitolul 1, denumit *Introducere*, cuprinde o prezentare succintă a tezei de doctorat, a obiectivelor, a motivației principale pentru tema aleasă și descrierea structurii la nivel de capitole.

Capitolul 2, denumit *Achiziția datelor spațiale prin scanarea laser*, cuprinde istoricul tehnologiei LiDAR, descrierea sistemelor de scanare laser aeriană tradițională (principiul de funcționare, enumerarea detaliată a sistemelor produse de marile firme din domeniu, aplicațiile acestora, fluxul de lucru complet pentru obținerea datelor spațiale prin scanarea laser), descrierea celor două tehnologii moderne de scanare: SPL (engl. Single Photon LiDAR) și Geiger-mode, precum și prezentarea datelor LiDAR care vor fi folosite în cadrul studiului de caz.

Capitolul 3, denumit *Achiziția datelor spațiale prin aerofotografiere*, cuprinde descrierea evoluției fotogrammetrice (de la analogic la digital), detalierea camerelor de top nadirale și oblice, enumerarea etapelor unui flux de lucru fotogrammetric, de la planificarea zborului până la generarea ortofotoplanului (ortofotoplanului tradițional și a true-ortofotoplanului) și prezentarea setului de date fotogrammetrice pentru studiul de caz.

Capitolul 4, denumit *Extragerea elementelor din norii de puncte LiDAR*, cuprinde descrierea metodelor de segmentare, respectiv de clasificare a norilor de puncte și partea de studiu de caz, în care voi detalia etapele fluxului de lucru propus pentru clasificarea norilor de puncte LiDAR și analiza indicatorilor de calitate obținuți prin rularea diversilor algoritmi de tip *Machine learning*. În cadrul fluxului voi descrie abordarea proprie pentru etapa de selectare dinamică a vecinătății, voi utiliza pentru clasificare o serie de caracteristici proprii ale punctelor 3D și voi testa software-ul *Weka* pentru clasificarea supervizată a norilor de puncte. Software-ul a fost folosit pentru rezolvarea problemelor de extragere a tiparelor din seturi mari de date, cu aplicații în domeniul bancar, diagnosticare, marketing și vânzări.

Capitolul 5, denumit *Extragerea elementelor din imagini ortorectificate*, cuprinde descrierea celor mai cunoscute metode de segmentare semantică a imaginilor bazate pe

tehnici de tip *Machine learning* și o trecere în revistă a celor mai cunoscute arhitecturi de rețele neuronale artificiale (RNA) pentru clasificarea și segmentarea semantică a imaginilor. În partea de studiu de caz voi detalia toate etapele fluxului de lucru pentru segmentarea semantică a imaginilor, atât cu algoritmi de tip *Machine learning*, cât și prin intermediul rețelelor neuronale profunde.

Capitolul 6, denumit ***Modelarea 3D a clădirilor***, cuprinde prezentarea cadrului general al modelării 3D a clădirilor, pornind de la metodele de generare, continuând cu informații actuale despre standardul CityGML (engl. City Geography Markup Language), detalierea aplicațiilor modelării 3D a clădirilor și evidențierea stadiului actual internațional. Ca un preambul la studiul de caz, voi descrie câteva software-uri care permit generarea modelelor 3D și voi identifica erorile geometrice, dar și semantice, întâlnite în modelarea 3D a clădirilor. Studiul de caz va cuprinde extragerea amprentelor la sol ale clădirilor din norii de puncte clasificați în capitolul 4 și regularizarea formei acestora. Modelarea 3D a clădirilor va fi abordată în două software-uri: 3dfier și Esri CityEngine.

Capitolul 7, denumit ***Generarea și publicarea modelelor 3D ale clădirilor pentru Municipiul Arad***, cuprinde exemplificarea modelării la nivel de municipiu, pe baza datelor din baza de date națională TopRo5 și a celor din proiectul LAKI II. Modelarea se va realiza în software-ul *CityEngine*. La final se va evalua calitatea modelelor 3D și va fi realizat un studiu comparativ cu modelele generate în capitolul anterior. Modelele 3D ale clădirilor pentru Municipiul Arad vor fi publicate în mediul ArcGIS Online.

Capitolul 8, denumit ***Concluzii generale, contribuții originale și perspective de viitor***, cuprinde concluziile generale asupra cercetării efectuate în prezenta teză, contribuțiile originale aduse în lucrare, precum și perspective viitoare de cercetare.

2. Achiziția datelor spațiale prin scanarea laser

2.1. Introducere

În cadrul acestui capitol voi prezenta fluxul de lucru pentru obținerea datelor spațiale prin scanarea laser, de la planificarea zborului de achiziție a datelor până la generarea produselor finale. În preambul, voi prezenta istoricul tehnologiei LiDAR (engl. Light Detection and Ranging), pornind din 1930 și până în prezent, dar și noțiuni legate de funcționarea sistemelor ALS (engl. Airborne Laser Scanning - Scanare Laser Aeropurtată). Atât sistemele ALS produse de marile firme din domeniu, cât și aplicațiile acestora vor fi detaliate în cadrul capitolului. În subcapitolele 2.7 și 2.8 voi prezenta cele două tehnologii moderne de scanare: SPL (engl. Single Photon LiDAR) și Geiger-mode. În încheierea capitolului voi prezenta setul de date LiDAR pentru Municipiul Arad, reședință a județului Arad, România, din proiectul *Informații geografice pentru mediu, schimbări climatice și integrare UE – LAKI II* (engl. Land Administration Knowledge Improvement) al Agenției Naționale de Cadastru și Publicitate Imobiliară (ANCPPI).

2.2. Scurt Istoric

Conceptul LiDAR a fost introdus în anii 1930, de către E. H. Synge, care a fost susținut de A. Einstein în publicarea ideilor sale legate de o nouă metodă de imagistică microscopică în care un câmp optic împrăștiat dintr-o mică particulă de aur ar putea fi folosit ca sursă de lumină. Tehnologia a evoluat mult, astfel că în 1992, se foloseau pentru prima dată detectorii de tip Geiger, dezvoltăți de cercetătorul R. Marino. În 2017, Leica Geosystems începe fabricarea scannerului SPL 100, care asigură achiziționarea de date LiDAR pentru suprafețe mari de teren, la costuri minime.

2.3. Noțiuni introductive

LiDAR (engl. **L**ight **D**etection **A**nd **R**anging), cunoscută și sub denumirea de LADAR sau altimetrie laser este o tehnologie activă de teledetecție. Scannerul LiDAR emite un fascicul intens și concentrat de lumină și măsoară timpul necesar pentru ca reflexiile să fie detectate de către senzor. Această informație este folosită pentru a determina distanța până la obiecte (Carter, et al., 2012).

2.4. Clasificarea sistemelor de scanare laser

Clasificarea sistemelor de scanare laser poate fi realizată după diferite caracteristici, cum ar fi:

1. după tehnica de măsurare: sistem cu lungime de undă continuă sau sistem laser pulsant;
2. după platforma folosită: sisteme aeropurtate, pe platformă satelit sau terestre;
3. după sistemul în care este inclus senzorul: sistem LiDAR simplu sau hibrid;
4. după tipul receptorului: mod linear, Geiger (GmLiDAR) sau unic-foton;
5. după scopul scanării și lungimile de undă folosite: topografic sau batimetric;
6. după numărul de surse de lumină: sistem cu lungime de undă singulară sau multispectral.

2.5. Aplicații ale scanării laser

Există numeroase aplicații ale scanării laser, printre care putem aminti: cartografierea terenurilor, a rețelelor de utilități, a zonelor inundate sau afectate de catastrofe și realizarea hărților de hazard (predicția pericolului de inundații), cât și modelarea 3D etc.

2.6. Scanarea laser aeriană tradițională

Scanarea laser aeriană (ALS) permite preluarea norilor de puncte, folosind platforme tip avion, elicopter sau UAV. În cele ce urmează, vor fi prezentate detalii despre scanarea laser aeropurtată cu platformă tip avion.

2.6.1. Principiul de funcționare al unui sistem ALS




Figura 2.1 Principiul de bază al sistemelor ALS
(Adaptare după (Fernandez-Diaz, Carter, Shrestha, & Glennie, 2014))

În figura 2.1 se pot observa liniile de zbor preluate, folosind oglindă oscilantă, ceea ce determină șablonul de preluare sub forma literei Z.

2.6.2. Componentele unui sistem ALS

În figura 2.2 se pot observa componentele de bază ale unui sistem ALS și anume:

1. **componenta aeriană:** platforma aeriană, scannerul laser și sistemul POS;
2. **componenta la sol:** stațiile de referință GNSS și componenta hardware-software.




Figura 2.2 Componentele unui sistem ALS

2.6.2.1. Scannerul laser

Scannerul laser este compus din unitatea laser de măsurare a distanței, dispozitivul de scanare optomecanic și unitatea de control, monitorizare și stocare.

2.6.2.2. Sistemul POS

Sistemul POS este format din componentele IMU și GNSS. Sistemul GNSS folosește și stații de referință la sol, care trebuie amplasate pe suprafața de scanare astfel încât distanța dintre sistemul ALS și stațiile de referință să nu fie mai mare de 25 km (Wehr, 2018).

2.6.3. Reflectanța și interacțiunea cu obiectele

Reflectanța este definită ca raportul dintre radiația incidentă de pe o anumită suprafață și radiația reflectată de pe suprafața respectivă. Din punct de vedere al performanței sistemului LiDAR, această caracteristică a suprafețelor este foarte importantă.

2.6.4. Evoluția scannerelor ALS

Piața de scanere LiDAR la nivel mondial a cunoscut o creștere semnificativă în ultimii ani datorită sectorului reprezentat de vehiculele autonome. Într-un top 10 al producătorilor de instrumente LiDAR, elaborat de (Chakravarty, 2019), se remarcă următoarele firme:

- din Europa: Hexagon Geosystems (Suedia) - locul I, SICK AG (Germania) - locul III, Riegl (Austria) - locul VI;
- din America de Nord: Velodyne LiDAR (California, SUA) - locul II, TOPCON (California, SUA) - locul IV, Trimble (California, SUA) - locul V, Teledyne OPTTECH (Canada).

2.6.5. Flux de lucru pentru scanarea laser ALS

Fluxul de lucru pentru generarea unor produse geospațiale prin măsurători de scanare laser implică planificarea misiunii de scanare, efectuarea măsurărilor, preprocesarea și postprocesarea datelor.

2.6.5.1. Planificarea misiunii de scanare

Pe baza specificațiilor tehnice care stau la baza oricărui proiect de scanare și cu ajutorul unui program specializat, se realizează **planificarea misiunii de scanare**. Primul pas este alegerea sistemului ALS corespunzător necesităților proiectului.

Planificarea scanării fără o suprapunere între benzile adiacente poate conduce la goluri de date; pentru a preîntâmpina o astfel de situație, în practica LiDAR se recomandă o suprapunere de minimum 20%, putând ajunge chiar și la 50% acolo unde se solicită o densitate mare a punctelor de scanare (Heidemann, 2018). Pentru o planificare bună trebuie ținut cont de rapoartele meteorologice locale, modificările mari ale topografiei, bazinele de apă existente și de acoperirea terenului.

2.6.5.2. Măsurători la teren

Prin efectuarea de măsurători la teren trebuie determinate coordonatele punctelor care formează suprafețele de control și ale punctelor de verificare. Aceste coordonate trebuie determinate la teren cu o precizie planimetrică și altimetrică superioară celei de determinare a punctelor LiDAR.

2.6.5.3. Achiziționarea datelor prin scanarea laser

Înainte de scanarea propriu-zisă, trebuie efectuată calibrarea instrumentului; acest pas se realizează la fiecare instalare a sistemului în aeronavă sau după orice modificare în instalarea sistemului, prin măsurarea vectorilor 3D ai brațului pârghiei. Pilotul urmărește, prin intermediul software-ului de ghidare al zborului, planul de scanare, iar la sfârșitul misiunii de scanare, măsurătorile LiDAR și ale sistemului POS sunt stocate pe carduri de memorie sau hard-diskuri, iar măsurătorile de la stațiile de referință la sol sunt stocate local.

2.6.5.4. Procesarea datelor LiDAR

După procesarea secvențială și calibrarea datelor, măsurătorile geocodate sunt stocate în ordine cronologică, cu următoarele atribute: t_{GPS} , X_{WGS84} , Y_{WGS84} , Z_{WGS84} , intensitate.

Pentru asigurarea calității datelor, trebuie realizată compensarea benzilor de scanare pe baza zonelor de suprapunere dintre benzi (inclusiv a celor transversale).

Norii de puncte LiDAR sunt seturi mari de date neregulat spațiate, care conțin milioane de puncte 3D. Formatul standard de stocare al norilor de puncte este formatul las, definit de ASPRS (Societatea Americană de Fotogrammetrie și Teledetecție). Un atribut important al punctelor 3D este clasa. În versiunea 1.4 a fișierelor las, sunt prezentate 256 de clase

standard, împărțite în: 21 definite de ASPRS (de ex. Cale ferată, Clădiri), 42 rezervate și 203 definibile de către utilizator (ASPRS, 2019).

Precizia absolută a punctelor 3D este influențată de soluția GNSS-IMU, caracteristicile scannerului, calitatea calibrării, calitatea compensării benzilor și de precizia transformării în sistemul național de referință. În cadrul subcapitolului sunt detaliate precizia planimetrică absolută, precizia altimetrică relativă și cea absolută.

2.6.5.5. Generarea Produselor Finale

Produsele finale care pot fi generate pe baza norilor de puncte 3D sunt modelele digitale 2.5D (modelele digitale ale terenului, modelele digitale ale suprafețelor, modelele digitale normalizate ale suprafețelor), curbele de nivel, elementele vectoriale 2D (extrase automat/semiautomat/digitizate) și modelele 3D ale obiectelor.

2.7. Scanarea laser aeriană tip SPL

Acronimul SPL vine de la Single Photon LiDAR (LiDAR unic-foton). Principiul de funcționare al instrumentelor tip SPL este emiterea unui singur impuls laser și divizarea acestui fascicul prin intermediul unui element optic difractiv în multiple subfascicule, cu scopul creșterii densității punctelor. Avantajele sistemelor tip SPL (Musäus, 2019) sunt următoarele:

- ✓ înălțimi mari de scanare, cu păstrarea densității punctelor;
- ✓ scanarea zonelor mari, într-un interval de timp de 2- 3 ori mai scurt față de sistemele liniare LiDAR (rata de scanare $> 450\text{km}^2/\text{h}$ la o densitate de $8\text{pct}/\text{m}^2$);
- ✓ penetrează norii și ceața de joasă înălțime, permițând extinderea perioadelor de scanare;
- ✓ eroarea medie pătratică altimetrică $< 10\text{cm}$, iar cea planimetrică $< 15\text{cm}$.

2.8. Scanarea laser aeriană Geiger-mode

L3Harris Technologies Inc. a dezvoltat, în 2015, instrumentul LiDAR cu senzorul GmAPD (Geiger-mode Avalanche Photo Diode), care conține o matrice de 32×128 detectori (SPAR 3D, 2016). Scannerul Geiger-mode achiziționează nori de puncte mult mai denși, într-un timp mult mai scurt și la prețuri reduse. Colectarea datelor sub unghiuri multiple conduce la îmbunătățirea penetrării vegetației, la eliminarea zonelor umbrite și a golurilor de date.

2.9. Prezentarea datelor LiDAR din studiul de caz

Zona de studiu este Municipiul Arad, reședință a județului Arad, România. Datele LiDAR fac parte din proiectul **LAKI II**, pentru care am realizat controlul calității și recepția datelor. Unul dintre obiectivele acestui proiect (ANCPI, 2016) a fost obținerea MDT și MDS prin

scanarea aeriană LiDAR cu o densitate de 8pct/m² pentru zonele cu risc mare de inundații din județele Arad și Bihor, pentru o suprafață de aproximativ 10000km².

Zborul s-a efectuat cu scannerul RIEGL Q780, montat pe platforma tip avion. Norul de puncte pentru Municipiul Arad însumează un număr peste 2 miliarde de puncte 3D, cu răspunsuri de la 0 la 7. Pentru generarea MDT și MDS, norii de puncte au fost clasificați în: puncte la sol (clasa 2), puncte tip pod (clasa 10) și puncte neclasificate (clasa 1). Clasele 7 și 8 sunt clase cu puncte zgomot, care au fost excluse din procesul de generare a modelelor digitale. MDT-ul a fost generat pe baza punctelor din clasa 2, iar MDS pe baza claselor 1, 2 și 10. Pe zona de interes au fost generate câte 23 de tile-uri de MDT, respectiv MDS, cu rezoluția de 1m, în format geotiff.

3. Achiziția datelor geospațiale prin aerofotografiere

3.1. Introducere

În cadrul acestui capitol voi prezenta etapele unui flux de lucru fotogrammetric, de la planificarea zborului și până la generarea produselor finale. Generarea ortofotoplanului tradițional pe baza MDT va reprezenta preambulul pentru explicarea detaliată a generării true-ortofotoplanului. Camerele de top nadirale și oblice vor fi detaliate în continuare. Accentul va fi pus pe tehnologia de achiziționare și prelucrare a imaginilor oblice, dat fiind caracterul inovativ al acestei tehnologii și dezvoltărilor cele mai recente în termeni de procesare. Capitolul se încheie cu prezentarea setului de date fotogrammetrice pentru Municipiul Arad. Datele folosite fac parte din proiectul LAKI II al ANCPI.

3.2. Evoluția fotogrammetriei

Din punct de vedere al metodei de exploatare a stereomodelelor se disting trei tehnici, care reprezintă și cele trei mari epoci ale fotogrammetriei: analogică, analitică și digitală.

Fotogrammetria analogică a fost folosită în perioada 1900-1960 și implica achiziționarea, cu camere clasice analogice, imaginilor pe film (format 19x19cm sau 24x24cm). În România, această tehnică de exploatare a imaginilor a fost folosită până la apariția fotogrammetriei digitale. Fotogrammetria analitică a fost folosită în perioada 1960-2000 și se aseamănă cu cea analogică, cu diferența că aparatul de stereorestituție este analitic (ex. Aviolyt Wild Bc2). Acesta are în componență un computer, pe care se trasează elementele în format vector, iar harta se obține la un plotter. Epoca digitală a debutat cu aceleași imagini analogice, însă prelucrarea s-a realizat cu softuri specializate de stereorestituție digitală. În cadrul acestei epoci fotogrammetrice, orientarea se realizează în regim automat sau semiautomat, exploatarea stereomodelului este interactivă, iar produsele fotogrammetrice obținute sunt într-o gamă largă. Pentru o perioadă, camerele analogice și cele digitale au coexistat, producând simultan date pentru cartografierea zonelor de interes.

3.3. Principiile de bază ale fotogrammetriei

Principiul de bază al fotogrammetriei este **triangulația**. Astfel, pentru a determina coordonatele unui obiect din teren, se achiziționează imagini asupra obiectului din două

poziții diferite. În prezent, se folosesc două tehnologii de achiziționare a imaginilor digitale: cu senzori CCD sau cu senzori CMOS.

Clasificarea imaginilor fotogrammetrice (Upadhyay, 2013) se poate realiza după mai multe criterii, printre care:

1. locația camerei fotogrammetrice în momentul preluării datelor: aeriane sau terestre;
2. unghiul sub care se realizează achiziția datelor față de nadir: nadirale sau înclinate;
3. unghiul FOV al camerei: cu FOV normal, mare sau super-mare.

Preluarea imaginilor digitale se poate realiza fie în mod secvențial cu camere tip pushbroom (ex. Leica ADS40), fie prin expunere unică (ex. Leica DMC).

3.4. Sisteme fotogrammetrice aeriene

3.4.1. Camere fotogrammetrice nadirale

Imaginile nadirale permit observarea optimă a acoperișurilor, oferă avantajele iluminării egale a întregii zone fotografiate și al rezoluției spațiale constante. Primele imagini aeriene comerciale au fost achiziționate în Anglia anilor 1919, de compania Aerofilms, care a desfășurat ulterior activități de fotografiere ample, în scopuri de cartografiere, în Africa, Asia și Anglia (Aerial photography, 2017). Actualmente, pe piața fotogrammetrică sunt multe companii producătoare de camere nadirale aeriene, cum ar fi Leica Geosystems, Vexcel Imaging, Phase One, Teledyne Optech etc.

3.4.2. Camere fotogrammetrice oblice

Camerele oblice sunt folosite încă din anii 1930 în Statele Unite ale Americii, în sectorul militar. De-a lungul anilor au existat mai multe tipuri de camere oblice (Remondino, Toschi, Nex, & Gerke, 2018): cu o singură cameră (VisionMap), 2 camere (IGI Dual), 3 camere (DLR-3K), 4 camere (Rolleimetric AIC x4), 5 camere (Fairchild T-3A) sau camere multiple (Octoblisque Midas). Sistemele oblice pot avea următoarele configurații:

- ✓ **Maltese-cross**: dispun de o cameră orientată nadir și 4 camere dispuse pe 2 direcții perpendiculare, care preiau imagini oblice sub unghiuri de înclinare de 40°-50°;
- ✓ **Fan** (camere gemene - VisionMap A3 Edge);
- ✓ **Block** (4 camere aranjate într-un bloc - IGI Quattro-DigiCAM).

3.5. Flux de lucru fotogrammetric

3.5.1. Planificarea misiunii de aerofotografiere

Pe baza specificațiilor tehnice care stau la baza proiectului de aerofotografiere se selectează senzorul și platforma adecvate și se realizează planificarea zborului. Există diverse pachete software pentru planificarea zborului, fie furnizate de producătorii de senzori, fie de către dezvoltatori independenți (Pepe, Fregonese, & Scaioni, 2018).

3.5.2. Efectuarea măsurătorilor la teren și a zborului fotogrammetric

În teren se vor determina coordonatele punctelor de control și verificare, care au fost planificate în etapa anterioară. Alegerea perioadei optime pentru efectuarea zborului fotogrammetric trebuie să țină cont de următoarele aspecte:

- unghiul de elevație al Soarelui trebuie să fie mai mare de 30° , pentru a limita prezența umbrelor în imagini;
- suprafața terenului nu trebuie să fie acoperită de zăpadă sau inundații;
- condițiile atmosferice de tip ceață, voal atmosferic sau praf vor fi evitate.

3.5.3. Extragerea punctelor de legătură

Această etapă fotogrammetrică constă în extragerea punctelor corespondente în 2 sau mai multe imagini între care există suprapunere. Automatizarea acestui pas de lucru în cazul imaginilor oblice este o activitate laborioasă, datorită perspectivelor și iluminării diferite sub care sunt preluate imaginile. Identificarea punctelor de legătură se poate baza pe strategia **forței brute**, care presupune compararea fiecărui descriptor al imaginii A cu fiecare descriptor al imaginii B. Această abordare este simplă, dar destul de inefficientă. Alternative la strategia de forță brută sunt: **FLANN** (Fast Library for Approximate Nearest Neighbors), care folosește o structură de căutare rapidă și **MatchMe**, care folosește măsurători de similitudine între descriptori (Shragai, Barnea, & Even-Paz, 2012).

3.5.4. Compensarea în bloc a imaginilor

În urma compensării în bloc a imaginilor, pe baza coordonatelor punctelor GCP, a parametrilor de orientare interioară, a coordonatelor și a unghiurilor de rotație măsurate pentru fiecare centru de proiecție și a punctelor de legătură identificate anterior, se vor determina coordonatele 3D ale punctelor și parametrii de orientare exterioară compensați. Atât extragerea punctelor de legătură, cât și compensarea în bloc se pot realiza cu softuri specializate, de tipul Inpho Match-AT (Trimble), UltraMap (Vexcel), Leica Xpro (Hexagon), pachetul Pix4D (Pix4D).

3.5.5. Realizarea DIM și MDS

După realizarea orientării imaginilor nadirale și/sau oblice, se trece la generarea norului de puncte dens (DIM). Pentru achiziție de imagini nadirale la un GSD de 10 cm se poate genera un nor de puncte cu densitatea de 100 puncte/m². În cazul imaginilor oblice, se pot obține nori de puncte de 3 ori mai denși (Rupnik, Nex, & Remondino, 2014).

3.5.6. Generarea ortofotoplanului

Ortofotoplanul este produsul de bază al fluxului fotogrammetric și reprezintă o imagine ortorectificată, unde efectele de perspectivă datorate achiziției și reliefului au fost eliminate. Pentru generarea ortofotoplanului, în mod tradițional, se folosea MDT, dar utilizarea MDS a

devenit un standard în domeniul cartografierii. Precizia ortofotoplanului generat pe baza MDS, denumit și true-ortofotoplan, depinde de calitatea MDS.

Cea mai cunoscută metodă de generare a true-ortofotoplanurilor este **metoda Z-Buffer**, dezvoltată pentru rezolvarea problemei suprafețelor ascunse (Catmull, 1974).

3.6. Aplicații ale aerofotografierii

La finalul fluxului fotogrammetric se află datele vector, rezultate fie prin digitizarea 3D în stereomodele sau 2D pe ortofotoplan, fie prin extragerea datelor prin procedee automate/semiautomate. Aceste elemente fac obiectul diverselor aplicații fotogrammetrice (planificare urbană, situații de urgență și hazarde etc.).

3.7. Prezentarea datelor fotogrammetrice din studiul de caz

Zona de studiu este cea prezentată în subcapitolul 2.9, iar datele fac parte din același proiect **LAKI II**. Pe lângă obiectivele deja descrise ale proiectului, putem aminti aerofotografierea și realizarea ortofotoplanului cu rezoluția în teren a pixelului de 20 cm și precizie corespunzătoare (ANCPI, 2016). Zborul de aerofotografiere s-a efectuat cu camera Vexcel Ultracam Eagle Mark2, montat pe o platformă tip avion. Aerofotografierea s-a executat pe direcția Est-Vest, cu respectarea tuturor cerințelor meteorologice, atunci când unghiul de elevație al Soarelui a fost mai mare de 30°. Aerofotografierea pentru zona Municipiului Arad a fost realizată în luna martie 2017, prin preluare a 39 de imagini aeriene, dispuse pe 4 linii de zbor. Suprapunerea longitudinală a fost de 65%, iar cea transversală de 35%. După rularea fluxului fotogrammetric în software-ul UltraMap, s-a obținut ortofotoplanul RGB cu rezoluția spațială de 20cm și cu precizia planimetrică absolută de $\pm 0.20\text{m}$.

4. Extragerea elementelor din norii de puncte LiDAR

4.1. Introducere și scop

În cadrul acestui capitol voi prezenta cele mai cunoscute metode de segmentare a norilor de puncte. Voi continua cu prezentarea caracteristicilor punctelor 3D și metodelor de clasificare supervizată a norilor de puncte bazate pe *Machine learning*. Scopul trecerii în revistă a tuturor metodelor de segmentare și clasificare este de a crea un cadru pentru prezentarea studiului de caz, în care voi detalia toate etapele fluxului de lucru propus pentru clasificarea norilor de puncte LiDAR.

4.2. Metode de segmentare a norilor de puncte LiDAR

Segmentarea norilor de puncte este procesul de clasificare a punctelor în regiuni omogene multiple, pe baza măsurătorilor de similitudine a diferitelor caracteristici (Nguyen & Le, 2013). Metodele de segmentare au fost clasificate de mai mulți cercetători din domeniu, printre care (Sapkota, 2008), (Nguyen & Le, 2013) și (Xie, Tian, & Zhu, 2020).

4.2.1. Metode de segmentare bazate pe muchii

Aceste metode constau în două etape: extragerea muchiilor (limite între diferite regiuni) și gruparea punctelor din interiorul acestor limite. Identificarea muchiilor se face pe baza schimbărilor proprietăților suprafeței față de un prag stabilit inițial. Una dintre proprietățile folosite pentru identificarea muchiilor este intensitatea.

4.2.2. Metode de segmentare bazate pe regiuni

Metoda de segmentare bazată pe regiuni, cunoscută sub denumirea de *region growing*, a fost introdusă de (Besl & Jain, 1988). Avantajul principal al acestei metode este robustețea la punctele zgomot. O colecție de algoritmi tip region growing sunt disponibili în biblioteca de coduri C++ pentru procesarea norilor de puncte, denumită PCL (Rusu & Cousins, 2011).

4.2.3. Metode de segmentare bazate pe atribute

În cadrul acestor metode se realizează gruparea punctelor pe baza atributelor. Astfel, primul pas constă în calculul atributelor, spre exemplu, măsurători ale texturii suprafețelor (Filin S., 2002). (Filin & Pfeifer, 2006) au folosit metoda pantei adaptabile pentru selectarea vecinătății pe baza următoarelor atribute ale norului de puncte: densitatea, spațierea pe orizontală și verticală și precizia de măsurare a punctelor.

4.2.4. Metode de segmentare bazate pe potrivirea de modele

Această metodă (engl. model fitting) a pornit de la ideea că majoritatea obiectelor artificiale pot fi descompuse în forme geometrice primitive, precum planuri, cilindri, sfere și conuri (Schnabel, Wahl, & Klein, 2006). Metodele robuste de estimare a parametrilor sunt transformarea 3D Hough și metoda RANSAC (engl. RANdom SAMple Consensus).

Metoda RANSAC a fost definită de către (Fischler & Bolles, 1987) și folosește un număr minim de puncte, alese în mod aleatoriu, pentru a construi o soluție inițială, pe baza căreia calculează parametrii modelului inițial. Acest set de date este mărit cu punctele care se potrivesc în modelul inițial. Astfel, sunt generate mai multe ipoteze de primitive, iar alegerea variantei optime se bazează pe o schemă de votare.

Această metodă are la bază metoda lui (Hough, 1962) de recunoaștere a elementelor 2D (linii și cercuri) în cadrul imaginilor. Trecerea de la spațiul 2D (imagini) la spațiul 3D (nor de puncte) a fost realizată în mai multe etape și putem aminti activitatea de cercetare pentru a detecta forme arbitrare (Ballard, 1991).

4.2.4.1. Metode de segmentare bazate pe grafice

În cea mai simplistă abordare, metodele de segmentare bazate pe grafice consideră norul de puncte ca fiind un grafic, în care fiecare punct este un nod, iar conexiunile dintre anumite perechi de puncte învecinate reprezintă muchii. Abordarea lui (Golovinskiy & Funkhouser, 2009) este de creare a unui grafic 3D pe baza metodei KNN, unde punctele apropiate sunt mai strâns conectate.

4.2.5. Metode hibride de segmentare

Metodele hibride folosesc pentru segmentare combinarea mai multor metode și încearcă să micșoreze dezavantajele generate de utilizarea unei metode prin exploatarea avantajelor alteia.

4.2.6. Metode de segmentare bazate pe machine learning

Învățarea nesupervizată (engl. unsupervised learning) de tip *machine learning* se reduce la problema de determinare a modului de organizare a datelor. Unele dintre metodele de segmentare care nu se bazează pe date de instruire sunt **K-means** (Zhu & Shahzad, 2014), **Fuzzy clustering** (Sampath & Shan, 2010), **Mean-shift** (Ukrainitz & Sarel, 2014) și **gruparea ierarhică**: **SLink** (Sibson, 1973), **P-Linkage** (Lu, et al., 2016).

4.3. Metode de clasificare a norilor de puncte bazate pe Machine learning

Sunt cunoscute trei abordări ale problemei de segmentare semantică (Grilli, Menna, & Remondino, 2017): supervizată, nesupervizată și interactivă. În figura 4.1 este reprezentat schematic un flux de lucru pentru clasificarea supervizată a unui nor de puncte.




Figura 4.1 Flux de lucru pentru clasificarea supervizată a norilor de puncte

4.3.1. Caracteristici ale punctelor 3D

4.3.1.1. PCA, valori și vectori proprii

Tehnica PCA (engl. Principal Component Analysis) realizează sarcina de reducere a dimensiunii prin calcularea principalelor componente ale datelor - seturi de valori și vectori proprii. Valorile proprii indică dimensiunile unui elipsoid 3D de-a lungul celor trei axe principale și respectă inecuația:

$$\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0 \quad (4.1)$$

4.3.1.2. Generalități despre caracteristicile punctelor 3D

O **caracteristică** este o reprezentare specifică a datelor, prin care este descrisă o proprietate care permite diferențierea anumitor elemente în cadrul scenei (Weinmann M. , 2013). În cazul norilor de puncte, caracteristicile pot reprezenta trăsături geometrice locale sau globale.

4.3.1.2.1. Caracteristici 3D ale punctelor LiDAR

Caracteristicile 3D pot fi structurate în caracteristici geometrice și caracteristici locale-abstracte. **Caracteristicile geometrice** 3D pot fi: cota punctelor, densitatea locală a punctelor, verticalitatea, diferența maximă de cotă între punctele din vecinătatea respectivă, abaterea standard a cotelor în vecinătatea respectivă. Cele mai cunoscute **caracteristici locale 3D** sunt caracteristicile proprii abstracte (Weinmann M. , 2016), calculate pe baza valorilor proprii, cum ar fi: liniaritatea, planaritatea, împrăștierea.

- liniaritatea
$$L = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (4.2)$$

- planaritatea
$$P = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (4.3)$$

4.3.1.2.2. Caracteristici 2D ale punctelor LiDAR

Caracteristicile 2D permit identificarea anumitor obiecte din scena urbană, care sunt aproape perfect verticale (fațade clădiri, stâlpi) și sunt complementare celor 3D.

4.3.2. Selectarea vecinătății

Definirea vecinătății unui punct 3D, $\mathcal{P}$, reprezintă selectarea punctelor vecine lui $\mathcal{P}$, iar acest lucru poate fi făcut folosind diferite strategii (Weinmann, et al., 2015), printre care:

- vecinătate fixă** pentru toate punctele norului 3D: sferică sau cilindrică.
- vecinătate dată de numărul de vecini K apropiați**: formată din cele mai apropiate K puncte 3D din jurul punctului $\mathcal{P}$, în termeni de distanță metrică 3D sau 2D.

Ambele abordări prezentate necesită cunoaștere prealabilă a zonei analizate și definirea unei valori constante: fie a razei sferei/cilindrului, fie a numărului de vecini.

4.3.3. Extragerea caracteristicilor 3D

Majoritatea caracteristicilor definite anterior se bazează pe calcule în interiorul vecinătății definite. Spre exemplu, un punct poate avea ca atribute următoarea serie de 16 caracteristici calculate: $P(L, P, S, C, O, A, E, \Sigma, H, D_{3D}, V, \Delta H_{3D}, \sigma_H, D_{2D}, \Sigma_{2D}, R_{2D})$.

4.3.4. Selectarea caracteristicilor optime

În selectarea caracteristicilor optime de folosit în procesul de clasificare trebuie să se țină cont de **fenomenul Hughes**. Acest fenomen implică o creștere a preciziei clasificării, urmată de atingerea unui maxim și de o ușoară scădere. Acest trend are legătură și cu numărul caracteristicilor folosite în procesul de clasificare. În abordarea extrasă din (Weinmann, Jutzi, & Mallet, 2014) se folosește măsura de **câștig informațional** (engl. information gain - IG). IG este evaluat independent pentru fiecare caracteristică și cele care obțin valori mai mari sunt considerate relevante și se vor folosi în procesul de clasificare.

4.3.5. Clasificarea supervizată

Clasificarea supervizată se poate realiza prin mai multe metode, dar toate au în comun cele două seturi:

$$\checkmark \text{ de învățare } X = \{(x_i, l_i)\}, \quad i = 1 \dots N_x, \quad l_i \in \{1 \dots N_c\} \quad (4.4)$$

$$\checkmark \text{ de testare } Y = \{y_j\}, \quad j = 1 \dots N_y \quad (4.5)$$

unde,

x_i = vectorul caracteristicilor punctului i ;

l_i = clasa aferentă punctului i ;

y_j = vectorul caracteristicilor punctului j

și scopul final de atribuire a unei clase l_j ($j = 1 \dots N_c$) fiecărui punct j din setul de testare.

Metodele de clasificare supervizată se pot diferenția în **clasificatori standard**, care se bazează doar pe caracteristicile individuale extrase și **clasificatori contextuali**, care

exploatează atât caracteristicile individuale extrase, cât și relațiile dintre punctele 3D din cadrul vecinătății. Clasificatorii supervizați utilizați cu precădere sunt **Nearest Neighbour**, **Arbore de decizie**, **Random Forest**, **AdaBoost**, **Support Vector Machines** și **Maximum Likelihood**. O altă abordare este clasificarea norilor de puncte prin intermediul **rețelelor neuronale profunde**.

Clasificatorul **Nearest Neighbour** (NN) folosește învățarea bazată pe instanțe. Regula folosită este de comparare a caracteristicilor punctelor noi cu cele ale punctelor din setul de învățare, spre exemplu prin folosirea distanțelor Euclidiene.

Clasificatorul **Arbore de decizie** (engl. decision tree - DT) este un tip de învățare bazat pe reguli. Pe baza caracteristicilor norului de puncte sunt selectate o serie de decizii sau „întrebări”. În funcție de „răspunsurile” primite la aceste „întrebări” un punct este atribuit unei anumite clase.

Clasificatorul tip **Random Forest** (RF) are la bază teoria definită de L. Breiman (Breiman L. , 2001). Este un clasificator care se bazează pe regulile de învățare de ansamblu. RF este reprezentat de un ansamblu de arbori de decizie binari, care pe baza „răspunsurilor” (adevărat sau fals) la nivelul fiecărei ramuri, partiționează setul de date. Nodul „rădăcină” cuprinde întreg spațiul predictor, iar nodurile care nu mai sunt partiționate reprezintă frunze și sunt deciziile finale ale clasificării.

Clasificatorul **Adaboost**, în cadrul fiecărei iterații, concepe o distribuție a subsetului de învățare și aplică o ipoteză cu o eroare scăzută în ceea ce privește clasa reală. După rularea tuturor iterațiilor, ipotezele individuale trebuie combinate într-o singură regulă de predicție (Freund & Schapire, 1997).

Bazele teoretice ale acestui algoritm au fost definite de către (Cortes & Vapnik, 1995), cu scopul inițial de separare a două clase, metodă denumită **support-vector network**. **Support Vector Machines** (SVM) este un clasificator de maximizare a marginilor. Algoritmul SVM pentru clasificarea multi-clasă poate fi privit ca un clasificator tip **unu versus restul** (Morariu, 2007) sau **unu versus unu** (Chang & Lin, 2011).

Naive Bayesian este un clasificator probabilistic, care deduce cea mai probabilă clasă pentru fiecare punct pe baza teoremei Bayes și a ipotezei că toate caracteristicile sunt condiționat independente (John & Langley, 1995). Pentru a elimina problema caracteristicilor corelate, a fost dezvoltat algoritmul **Maximum Likelihood** (ML), care se bazează pe ipoteza conform căreia clasele pot fi reprezentate prin diferite distribuții tip Gauss.

4.3.6. Evaluarea calității clasificării norilor de puncte

După clasificarea setului de date de testare, se trece la etapa finală a procesului de clasificare, și anume, la evaluarea calității clasificării. Această evaluare se realizează la nivel

de indicatori de calitate, pe baza valorilor extrase din matricea de confuzie (Weinmann M. , 2019).

4.4. Studiu de caz pentru clasificarea norilor de puncte

4.4.1. Pregătirea norului de puncte

Primul pas în fluxul de lucru pentru clasificarea supervizată este pregătirea norului de puncte, prin selectarea zonelor de învățare, de testare și de validare a rezultatelor clasificării, filtrarea punctelor zgomot aferente acestor zone și codarea RGB a norilor de puncte. Împărțirea acestor puncte pe cele trei zone și procentul de puncte aferent fiecărui set sunt detaliate în figura 4.2.




Figura 4.2 Împărțirea setului de date
Albastru - zona de învățare; Portocaliu - zona de testare; Gri - zona de clasificat

Filtrarea zgomotului am realizat-o cu opțiunea **Statistical Outlier Removal (SOR)**, în software-ul **CloudCompare**. Prin această filtrare au fost eliminate 31444 puncte (2.8%). Numărul total de puncte folosite în această etapă este de 978337 (figura 4.3).




Figura 4.3 Filtrare zgomot din norul de puncte
a) cu zgomot; b) fără zgomot

4.4.2. Selectarea vecinătății în mod dinamic

În literatura de specialitate se folosesc valori fixe pentru toate punctele norului (raza sau numărul de vecini apropiați). Este de preferat o abordare unde parametrul K să fie flexibil și să poată varia în cadrul norului de puncte 3D. Dar cum putem selecta vecinătatea diferit, într-un mod dinamic? Răspunsul ar fi să ne concentrăm asupra unei selecții generice a vecinătăților individuale descrise de un parametru de scară optimizat pentru fiecare punct 3D, astfel evitând complet utilizarea cunoștințelor a-priori despre scenă și/sau date. În acest sens, am decis să folosesc algoritmul **region growing** și să selectez dinamic cei mai apropiați K vecini ai punctului, prin partiționarea norului de puncte în regiuni omogene și

disjuncte, pornind de la un punct dat ca fiind punct nucleu. Apoi, se va continua cu extinderea regiunii, pe baza măsurătorilor de similitudine.

Astfel, am elaborat un cod în limbajul C++, pe baza bibliotecii de coduri PCL. Pe baza mai multe teste cu diverse seturi de parametri de segmentare am identificat parametri optimi (tabelul 4.1). Această activitate am realizat-o în cadrul detașării la centrul de cercetare *FBK* (Bruno Kessler Foundation), în Trento, Italia, în cadrul Proiectului VOLTA (GA nr. 734687 – VOLTA –H2020-MSCA-RISE-2016).

K - KDTree	50
Neighbours for Normals Computation	15
MinClusterSize	20
MaxClusterSize	100
NumberOfNeighbours	15
CurvatureThreshold	0.3
SmoothnessThreshold	12.5/180* π

Tabel 4.1 Parametrii optimi pentru segmentare

4.4.3. Extragerea caracteristicilor

Calculul caracteristicilor proprii abstracte a fost implementate într-un cod C++. Codul dezvoltat pentru selectarea dinamică a lui K a fost inclus în acest cod, după rularea și testarea separată. Față de caracteristicile proprii abstracte utilizate în literatura de specialitate, am definit o serie de caracteristici noi. Prin intermediul testărilor succesive am constatat că doar caracteristica N_2 este relevantă în procesul de clasificare.

$$N_2 = \frac{\lambda_1 + \lambda_2 + \lambda_3}{\lambda_1} \quad (4.6)$$

În figura 4.4 se pot observa caracteristici precum liniaritatea (a), planaritatea (b), schimbarea curburii (c) și N_2 (d) pe setul de date de învățare.




Figura 4.1 Câteva caracteristici proprii abstracte

4.4.4. Clasificarea norilor de puncte și evaluarea calității rezultatelor

4.4.4.1. Software Weka

Weka este un software dezvoltat de Universitatea din Waikato, Noua Zeelandă și conține o colecție de algoritmi de **Machine learning** pentru rezolvarea problemelor din domeniul **Data Mining**, scriși în limbajul Java (Waikato, 2021).

4.4.4.2. Crearea setului de date de învățare și de testare

Clasele de puncte pe care voi testa clasificatorii sunt:

- ✓ 0 - puncte la sol;
- ✓ 1 - puncte vegetație;
- ✓ 2 - puncte tip acoperiș clădiri;
- ✓ 3 - alte puncte (stâlpi, linii electrice, mașini, fațade clădiri, garduri etc.).

Pe baza caracteristicilor abstracte, dar și a atributelor punctelor 3D (inclusiv valorile RGB), am realizat clasificarea manuală a norilor de puncte aferenți zonelor de învățare și testare, în softul *CloudCompare*. Punctele la sol le-am extras automat utilizând instrumentul **Cloth Simulation Filter** (Zhang, et al., 2016). Din restul punctelor non-sol, printr-o serie de decupări și uniri succesive, am generat seturile de date clasificate. Operațiunea de clasificare manuală este foarte mare consumatoare de timp, întregul proces durând cca. 40 de ore.




Figura 4.5 Seturile de date de învățare și testare

Caracteristicile tuturor punctelor 3D sunt următoarele: coordonatele 3D translate, valorile RGB, componentele normalelor pe cele trei direcții, valoarea curburii, valorile proprii, caracteristicile proprii abstracte, caracteristicile implicite ale norului de puncte, ID unic și valoarea clasei.

4.4.4.3. Analiza metodelor de Machine learning - studiu comparativ

În **Machine learning** se folosesc noțiunile de instanță (punct 3D) și de atribut (caracteristica). Clasificatorii vor fi antrenați pe 266987 instanțe, folosind următoarele atribute: normalele (3), curbura, valorile proprii (3), caracteristicile abstracte (8), atributele implicite ale punctelor (cota translatată, numărul de răspunsuri și intensitatea) și clasa.

4.4.4.4. Analiza rezultatelor pentru clasificatorii folosiți

Din analiza timpului necesar creării și testării modelului pentru cei 7 clasificatori rulați în software-ul *Weka* (figura 4.6), putem concluda că timpul cel mai mare a fost necesar

clasificatorului **IBk**. Clasificatorul care are nevoie de cel mai puțin timp, atât pentru creare cât și pentru testare, este **Naive Bayes**. Clasificatorul **J48** s-a dovedit de 6 ori mai rapid decât **Random Forest**, iar clasificatorii **Random Forest** și **SMO** au avut cerințe similare de timp.




Figura 4.6 Analiza timpului necesar pentru crearea și testarea modelelor

Din punct de vedere al calității clasificării (figurile 4.7), definită de valoarea OA (engl. overall accuracy), clasificatorul **SMO**, urmat de **Random Forest** și de **Naive Bayes** ocupă primele trei locuri, cu valori de aproximativ 93%. Clasificatorul **AdaBoost** oferă cea mai mică valoare a calității OA, doar 76%.




Figura 4.7 Analiza calității clasificării pentru clasificatori testați

Din analiza indicatorilor de calitate pentru clasa Clădiri (figura 4.8) putem concluziona că metodele **Random Forest** și **SMO** oferă cele mai bune rezultate; valorile preciziei sunt de aproximativ 98%, completitudinea este în jurul valorii de 90%, iar scorul F1 este de aproximativ 93%.




Figura 4.8 Analiza indicatorilor de calitate pentru clasa CLĂDIRI

Prin rularea modelului salvat pentru clasificatorul *Random Forest*, am obținut rezultatul din figura 4.9 într-un interval de 6 minute.




Figura 4.9 Rezultat clasificare cu Random Forest

4.4.4.5. Flux de lucru pentru clasificarea norului de puncte

În figura 4.10 este descris schematic fluxul de lucru pentru clasificarea norului de puncte cu algoritmi de tip Machine Learning.




Figura 4.10 Clasificarea norului de puncte cu algoritm de tip Machine Learning

5. Extragerea elementelor din imagini ortorectificate

5.1. Introducere și scop

În cadrul capitolului voi prezenta cele mai cunoscute metode de segmentare semantică a imaginilor. În preambul voi prezenta succint metodele de segmentare semantică supervizată a imaginilor bazate pe tehnici de tip **Machine learning**. Voi face o descriere a celor mai cunoscute arhitecturi de rețele neuronale artificiale pentru clasificarea imaginilor, pornind cu **AlexNet** și ajungând la **DenseNet** și pentru segmentarea semantică, precum **FCN**, **SegNet**, **U-Net**. În cadrul studiului de caz voi detalia toate etapele fluxului de lucru pentru segmentarea semantică a imaginilor, atât cu algoritmi de tip **Machine learning**, cât și prin intermediul rețelelor neuronale profunde. Analiza va fi realizată pe un subset al ortofotoplanului pentru Municipiul Arad, în software-ul *ArcGIS Pro*.

5.2. Noțiuni introductive

Inteligența artificială (AI) reprezintă simularea inteligenței umane de către mașini, care sunt programate să gândească ca un om. Termenul își are originea în anul 1956, fiind atribuit lui J. McCarthy de la MIT. *Învățarea automată* (engl. Machine learning) este o aplicație a AI, care conține algoritmi care analizează datele, învață despre datele respective și aplică ceea ce au învățat pentru a lua deciziile optime (Grossfeld, 2021). *Învățare profundă* este un subdomeniu al *învățării automate*, în care aplicațiile pot învăța și lua decizii proprii pe baza unei rețele neuronale artificiale.

5.3. Extragerea elementelor din imagini utilizând Machine learning

Algoritmii cunoscuți de *învățare automată*, precum **SVM**, **Random Forest**, **K-means clustering**, oferă rezultate bune în segmentarea semantică a imaginilor.

5.4. Extragerea elementelor din imagini utilizând rețele neuronale artificiale

5.4.1. Scurt istoric al dezvoltării rețelelor neuronale

Noțiunea de **rețea neuronală** a pornit de la cercetările lui W. McCulloch și a lui W. Pitts, de la Universitatea din Chicago, în anii 1943. Lucrarea lor "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" a stat la baza teoriei conform căreia funcția de activare a unui neuron este unitatea de bază a activității creierului (McCulloch & Pitts, 1943). Pasul următor a fost dezvoltarea algoritmului **Perceptron** în anul 1958, de către F. Rosenblatt, cu

scopul învățării supervizate a clasificatorilor binari. Acest domeniu a cunoscut o evoluție uimitoare, iar dezvoltarea componentelor hardware și software va dicta, cu siguranță, viitorul rețelelor neuronale artificiale.

5.4.2. Definiții consacrate ale rețelelor neuronale artificiale

O **rețea neuronală artificială** (RNA) este “un procesor distribuit, masiv paralel, compus din unități simple de procesare cu abilitatea naturală de stocare a cunoștințelor noi pe baza experienței anterioare și a le face disponibile pentru utilizarea ulterioară” (Haykin, 2008).

5.4.3. Neuronul natural versus neuronul artificial

5.4.3.1. Neuronul natural

Neuronul uman este unitatea morfo-funcțională a sistemului nervos și este format din corpul celular și prelungiri (dendrite și axoni). Figura 5.1 evidențiază traseul parcurs de stimul.




Figura 5.1 O rețea de neuroni umani
(Phillips, 2015)

5.4.3.2. Neuronul artificial

O rețea neuronală artificială este un model simplificat al rețelei neuronale umane. Fiecare neuron artificial este format din următoarele componente de bază (figura 5.2):

- **setul de conexiuni** sau sinapse între unități, cu ponderile aferente;
- **sumatorul**, care adună semnalele de intrare, ponderate cu puterea sinaptică a neuronului respectiv;
- **funcția de activare**, care limitează amplitudinea semnalului de ieșire la o anumită valoare finită;
- **polarizarea** (engl. bias), care se aplică din exteriorul rețelei și are scopul de a crește sau micșora intrarea netă a funcției de activare (în funcție de valoarea pozitivă sau negativă).




Figura 5.2 Modelul neuronului k
(Adaptată după (Haykin, 2008))

$$u_k = \sum_j w_{kj} \cdot x_j \quad (5.1)$$

$$y_k = \varphi(u_k + b_k) = \varphi(v_k) \quad (5.2)$$

unde,

w_{kj} = ponderile neuronului k;

x_j = semnalele de intrare ($j=1\dots m$);

u_k = ieșirea obținută prin însumarea semnalelor de intrare ponderate;

b_k = polarizator al neuronului k;

v_k = ieșirea u_k polarizată.

5.4.4. Arhitectura rețelelor neuronale artificiale

A. Rețele uni-direcționale unistrat

O rețea de tip uni-direcțional unistrat (engl. single-layer feedforward network) face ca stratul de intrare să se proiecteze direct pe stratul de ieșire de neuroni.

B. Rețele uni-direcționale multistrat

O rețea de tip uni-direcțional multistrat (engl. multilayer feedforward network) conține unul sau mai multe *straturi ascunse*, format/e din *unități ascunse*.

C. Rețele bidirecționale

O rețea neuronală bidirecțională sau recurentă (engl. feedback network) reprezintă cea mai complexă arhitectură RNA, care prezintă minimum o *bucă feedback*.

5.4.5. Rețele neuronale profunde

Rețeaua neuronală profundă (engl. deep neural network - DNN) este o rețea neuronală complexă cu multiple straturi interpușe între straturile de intrare și de ieșire (figura 5.3). Funcția de activare folosită este funcția non-liniară ReLU (engl. rectified linear unit). DNN sunt folosite pentru înțelegerea textului (DeepText), recunoașterea facială (DeepFace) etc.




Figura 5.3 Rețea neuronală profundă cu trei straturi ascunse

O rețea neuronală convoluțională (engl. convolutional neural network - CNN) este o rețea neuronală profundă, compusă din straturi convoluționale, stratul de agregare și unul sau mai multe straturi complet conectate de tip Perceptron multistrat (Vrejoiu, 2019).

5.4.6. Procesul de învățare în rețele neuronale artificiale

Tehnicile de învățare se pot clasifica în următoarele categorii: supervizată (figura 5.4), nesupervizată, semi-supervizată sau cu întărire.




Figura 5.4 Algoritm de învățare supervizată
(Adaptată după (Yadav, Yadav, & Kumar, 2015))

5.4.7. Aplicații ale RNA

Aplicațiile de bază ale rețelelor neuronale artificiale, în lucrul cu imagini digitale, sunt: segmentarea semantică, clasificarea, detectarea obiectelor și segmentarea instanțelor (Agarwal, 2018).

5.4.8. Arhitecturile CNN de bază

5.4.8.1. AlexNet

AlexNet este compusă din cinci straturi convoluționale, trei dintre ele urmate de straturi de agregare, tip max pooling și trei straturi complet conectate. În total sunt utilizați aproximativ 60 de milioane de parametri și 650000 de neuroni. Pentru a face procesul de învățare mai rapid, au fost folosiți neuroni nesaturați și o implementare GPU foarte eficientă a operației de convoluție (Krizhevsky, Sutskever, & Hinton, 2012).

5.4.8.2. VGGNet

Rețeaua neuronală **VGGNet** constă în 16 sau 19 straturi, dintre care primele sunt convoluționale și ultimele 3 straturi sunt complet conectate. **VGGNet** este o arhitectură de tip bloc, unde fiecare bloc este format dintr-o succesiune de straturi convoluționale, urmate de un strat de agregare de tip max pooling.

5.4.8.3. NiN Net

Pe baza arhitecturilor **AlexNet** și **VGGNet**, a fost dezvoltată rețeaua neuronală **NiN** (engl. Network in network - Rețea în rețea) (Lin, Chen, & Yan, 2014). Diferențele esențiale dintre **NiN** și arhitecturile precedente sunt: folosirea stratului *Mlpconv* (echivalentul unui strat convoluțional cu filtru kernel de dimensiunea 1×1) în locul stratului convoluțional liniar și a stratului de agregare medie globală în locul straturilor complet conectate.

5.4.8.4. GoogLeNet

În comparație cu arhitectura **AlexNet**, **GoogLeNet** folosește de 12 ori mai puțini parametri și furnizează rezultate de o acuratețe superioară (Szegedy, et al., 2015). La baza acestei arhitecturi se află blocurile de tip *Inception*.

5.4.8.5. ResNet

Conceptul arhitecturii **ResNet** (engl. Residual Networks - rețele reziduale) are la bază utilizarea blocurilor care redirectionează datele de intrare și le adaugă la conceptul învățat deja din stratul anterior (Residual Net, 2020). Au fost create 5 arhitecturi ale **ResNet**, pornind de la 18 straturi, continuând cu 34, 50, 101 și terminând cu 152 de straturi. Rețeaua neuronală reziduală cu 152 de straturi a fost, în 2015, cea mai profundă rețea prezentată la competiția *ImageNet*.

5.4.8.6. DenseNet

DenseNet este o variantă ușor îmbunătățită a **ResNet**, propusă în 2016 (Huang, Liu, Van Der Maaten, & Weinberger, 2017). Hiperparametrul folosit în rețelele **DenseNet** este rata de creștere (k). Fiecare strat adaugă k caracteristici proprii la starea respectivă. Rata de creștere reglează numărul de informații noi cu care contribuie fiecare strat la starea globală.

5.4.9. Arhitecturi CNN folosite pentru segmentarea semantică a imaginilor

5.4.9.1. FCN

FCN (engl. Fully convolutional networks) sunt rețele neuronale compuse din straturi convoluționale, dar care nu prezintă straturi finale complet conectate (Long, Shelhamer, & Darrell, 2015). Diferența de bază față de CNN este aceea că straturile de decizie de la sfârșitul rețelei sunt tot filtre.

5.4.9.2. SegNet

SegNet este o rețea CNN profundă, formată dintr-o rețea de codificatori, o rețea de decodori corespondenți și un strat final de clasificare la nivel de pixel.

5.4.9.3. U-net

Rețeaua neuronală **U-net** a fost câștigătoarea competiției */SBI/* (International Symposium on Biomedical Imaging) din 2015. Această arhitectură, bazată pe **FCN**, a fost dezvoltată pentru domeniul microscopiei electronice medicale (Ronneberger, Fischer, & Brox, 2015).

5.4.9.4. DeconvNet

Rețeaua neuronală **DeconvNet** (Noh, Hong, & Han, 2015) folosește pe lângă straturile de convoluție (care extrag caracteristicile din imagini) și straturi de deconvoluție (generează hărți de probabilitate). În primă fază, se aplică convoluția și se folosesc straturile conform arhitecturii **VGG16**. Deconvoluția este imaginea în oglindă a primei etape și este formată dintr-o serie de straturi de non-agregare, deconvoluție și rectificare.

5.5. Evaluarea calității clasificării și segmentării semantice a imaginilor

Indicele Jaccard reprezintă cuantificarea procentului de suprapunere între masca de referință și rezultatul clasificării/segmentării. Restul de indicatori de calitate au fost descriși în subcapitolul 4.3.6.

5.6. Cadre de lucru consacrate cu RNA

Cele mai populare cadre de lucru cu rețele neuronale artificiale sunt: *TensorFlow*, *PyTorch*, *Keras*, *DL4J*, *Caffe*, *Microsoft Cognitive Toolkit*. În cadrele de lucru prezentate, se pot urma toți pașii din fluxul de lucru pentru clasificarea/segmentarea imaginilor.

5.7. Studiu de caz pentru segmentarea semantică a imaginilor

Studiul de caz a fost realizat în software-ul *ArcGIS Pro*, prin testarea capabilităților de segmentare semantică a imaginilor atât prin algoritmi de tip **Machine learning** (SVM, Random Trees și Maximum Likelihood), cât și prin rețele neuronale artificiale profunde. Testele au fost realizate pe un subset din ortofotoplanul aferent Municipiului Arad, cu rezoluția spațială a rasterului este de 20 cm, iar cea spectrală de 32 biți.

5.7.1. Clasificarea imaginilor pe baza algoritmilor de tip Machine learning

5.7.1.1. Clasificarea supervizată la nivel de pixel

Pe baza unei analize vizuale a imaginii și pe baza necesității extragerii clasei CLĂDIRI, am stabilit următoarea schema de clasificare: *clădiri*, *vegetație*, *drumuri* și *pământ*. Cu ajutorul instrumentului *Training Samples Manager*, am cules eșantioanele de învățare, astfel încât numărul lor să permită o bună clasificare, iar pixeli aferenți eșantioanelor să reprezinte clar și fără echivoc clasa respectivă. Au fost selectate 175 de eșantioane de învățare, sub forma unor cercuri cu raze variabile. Inițial am rulat procesul de învățare supervizată a modelelor,

fără a folosi date auxiliare, doar pe baza următoarelor atribute: culoare, numărul digital mediu, abaterea standard, numărul de pixeli și rectangularitatea. Clasificatorii supervizați disponibili în *ArcGIS Pro* sunt: **Maximum Likelihood** (clasificator probabilistic), **Random Trees** (clasificator de ansamblu) și **Support Vector Machine**.

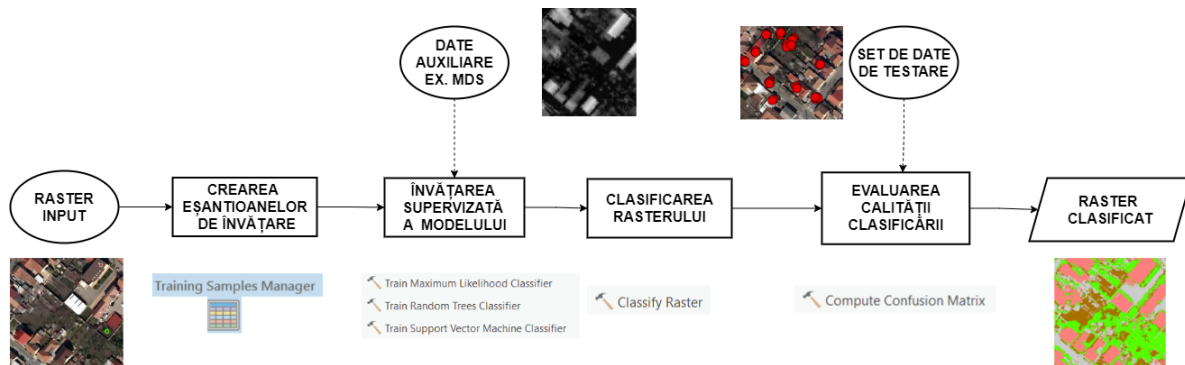


Figura 5.1 Clasificarea supervizată la nivel de pixel în software-ul ArcGIS Pro

Pentru calculul indicatorilor de calitate ai clasificării, am parcurs următorii pași:

- ✓ digitizarea eșantioanelor de testare și salvarea rezultatului în format vector;
- ✓ transformarea fișierului vector în raster;
- ✓ pe baza acestui raster, se creează numărul dorit de puncte de testare (de exemplu 5000), prin aplicarea unei strategii de eșantionare;
- ✓ clasa de obiecte rezultată se va actualiza cu valoarea aferentă fiecărui punct extrasă din rasterul clasificat;
- ✓ pe baza punctelor de testare și a rezultatului clasificării, se vor calcula matricea de confuzie și indicatorii de calitate.

În graficul din figura 5.6 sunt detaliați indicatorii de calitate ai clasificării pentru clasa CLĂDIRI obținuți pentru cei trei algoritmi folosiți.




Figura 5.6 Indicatori de calitate pentru clasa Clădiri



Figura 5.7 Rezultat clasificare utilizând algoritmul SVM

Am decupat MDS aferent zonei de analiză și am refăcut fluxul de lucru, introducând rasterul MDS ca dată auxiliară în procesul de clasificare. Pentru această analiză am aplicat doar clasificatorul SVM (abordare SVM-V2). Includerea informațiilor din MDS a condus la creșterea preciziei clasificării. Valorile indicatorilor de calitate sunt afișate în figura 5.8.




Figura 5.8 Indicatori de calitate SVM-V2

Comparând cele două abordări folosite pentru clasificarea imaginii cu algoritmul SVM: cu sau fără includerea informației din MDS, observăm o creștere a calității clasificării cu cel puțin 10% pentru fiecare indicator analizat (figura 5.9).




Figura 5.9 Analiza indicatorilor de calitate pentru clasificarea imaginii

5.7.1.2. Clasificarea supervizată la nivel de obiect

Față de clasificarea bazată pe pixel, această abordare diferă prin includerea în fluxul de lucru a etapei de segmentare a imaginii, bazată pe algoritmul *Mean Shift* și selectarea eșantioanelor din segmentele rezultate.

5.7.2. Clasificarea imaginilor pe baza rețelelor neuronale profunde

După pregătirea imaginii, se trece la faza de creare a eșantioanelor de antrenare. Am digitizat conturul a 138 de acoperișuri. Aceste eșantioane, de tip poligon, vor fi transformate în format tipic RNA, utilizând instrumentul *Export Training Data*, cu opțiunea *Classified Tiles*. Au rezultat 52 de imagini, fiecare imagine având 3 benzi și dimensiunea de 256x256 pixeli. RNA a extras 556 de caracteristici, cu o medie de 10.69 caracteristici/imagine. Următorul pas este antrenarea modelului. Pe baza setului de date de antrenare, *ArcGIS Pro* creează modelul rețelei, folosind tipul rețelei **U-Net** cu modelul structural **ResNet34**. Am aplicat modelul creat pe setul de date de testare și am obținut, pentru singura clasă creată - CLĂDIRI, precizia de 90.4%, completitudinea de 62.7% și scorul F1 de 73.8%. Ultimul pas al fluxului de lucru este clasificarea la nivel de pixel, pe baza modelului creat anterior.




Figura 5.2 Rezultat segmentare semantică




Figura 5.11 Indicatorii de calitate ResNet34 și ResNet50

Am reluat antrenarea rețelei folosind tipul rețelei **U-Net** cu modelul structural **ResNet50**. Timpul necesar creării modelului a fost de 15 ore. Am obținut, pentru clasa - CLĂDIRI, precizia de 87.9%, completitudinea de 67.8% și scorul F1 de 76.2%. Putem concluziona că timpul necesar creării modelului folosind ResNet50 este foarte mare, iar indicatorii de calitate nu au cunoscut o creștere importantă față de cei rezultați pentru modelul ResNet34.

6. Modelarea 3D a clădirilor pe baza norilor de puncte

6.1. Introducere și scop

Administrațiile locale și centrale au nevoie de **reprezentarea virtuală** a orașului lor. Elementele din modelele 3D ale orașelor pe care va fi pus accentul în cadrul acestui capitol sunt reprezentate de **clădiri**. În mod uzual, pentru modelele 3D ale clădirilor sunt folosite MDS, cărora li se aplică o textură. Din păcate, aceste modele nu conțin informații semantice sau geometrice și nu permit diferențierea între elemente și realizarea de analize, simulări etc. Modelele 3D în care fiecare clădire este reprezentată individual pot fi reconstituite din imagini fotogrammetrice, din nori de puncte (fie LiDAR, fie derivați fotogrammetric), din amprente la sol sau pe baza unei combinații dintre aceste tipuri de date.

6.2. Generarea modelelor 3D ale clădirilor

Modelele 3D ale orașelor sunt formate din modele 3D ale clădirilor, vegetației, elementelor străzilor, infrastructurii urbane (ex. construcții hidrografice, linii de înaltă tensiune) și ale obiectelor urbane (ex. semne de circulație, monumente, statui, fântâni). MDS la rezoluții superioare, cuprind toate aceste elemente, dar nu fac distincție între obiecte individuale. Prin urmare, generarea modelelor 3D din nori de puncte este varianta preferabilă, deoarece conservă precizia și facilitează analizele la nivel de clase de elemente sau chiar între elemente.

6.2.1. Metode de generare a modelelor 3D bazate pe modele

În această situație, se consideră că o clădire este formată din primitive simple. Aceste primitive sunt stocate într-o bibliotecă de modele predefinite. În cazul clădirilor cu forme complexe, soluția pentru o reconstrucție apropiată de realitate este descompunerea clădirii în forme multiple și potrivirea modelelor pe aceste forme.

6.2.2. Metode de generare a modelelor 3D bazate pe date

Folosind această abordare, nu se fac presupuneri legate de forma clădirilor, astfel eliminându-se problemele întâlnite în cazul metodelor bazate pe modele. Metodele bazate pe date au la bază segmentarea norului de puncte, urmată de asamblarea segmentelor individuale și reconstrucția modelelor. Metodele folosite pentru segmentare au fost detaliate în subcapitolul 4.2. și cuprind algoritmi precum **region growing**, **RANSAC**. (Dorninger & Pfeifer, 2008) propun pentru generarea conturului clădirilor folosirea metodei **α Shape** (Edelsbrunner, Kirkpatrick, & Seidel, 1983). O formă **α Shape 2D** este o limită poligonală a unui set de puncte (figura 6.1).




Figura 6.1 α Shape 2D
(Ohbuchi & Takei, 2003)

6.2.3. Software-uri de procesare a norilor de puncte

Există diverse software-uri de procesare a norilor de puncte, care pot fi împărțite în:

- software furnizate de producătorii de sisteme LiDAR, de exemplu RiPROCESS produs de Riegl (RIEGL, RiProcess_Datasheet, 2021);
- software academice sau open-source: LAS tools (Hug, Krzystek, & Fuchs, 2004), CloudCompare (Girardeau-Montaut, 2019);
- software comercial pentru realizarea tuturor etapelor dintr-un flux de producție, de exemplu TerraScan (Terrasolid, 2021).

Din categoria software-urilor academice face parte și *OPALS* (engl. Orientation and Processing of Airborne Laser Scanning - Orientarea și Procesarea Datelor ALS). Acest sistem de programe modulare a fost dezvoltat în cadrul *Grupului de Cercetare în Fotogrammetrie și Teledetecție*, din cadrul Universității Tehnice Viena (OPALS, 2019a). Modulele disponibile în *OPALS* permit atât procesări la nivel de date LiDAR, POS brute (georeferențierea directă, compensarea benzilor, calibrarea), cât și clasificarea norilor de puncte, modelări geomorfologice și generarea de modele digitale ale terenului și suprafețelor (Pfeifer, Mandlbürger, Otepka, & Karel, 2014).

6.3. Nivelul de detaliere în CityGML

Detalierea geometrică și semantică a unui model 3D este cunoscută ca nivel de detaliere (LoD). Standardizare definită de către Consorțiul OGC (engl. Open Geospatial Consortium) este cunoscută sub denumirea de standardul CityGML. CityGML este un model de date deschise, folosit pentru stocarea și schimbul modelelor 3D virtuale ale orașelor, care are la bază familia de standarde internaționale ISO 19100. Standardul CityGML versiunea 2.0 a fost adoptată de către OGC, în martie 2012, și se află încă în uz. Din 2013 se lucrează la versiunea 3.0, care nu a fost încă lansată.

6.3.1. CityGML 2.0

În standardul CityGML 2.0 sunt definite cinci clase cu diferite LoD (figura 6.2). Nivelele mai mari au un grad mai mare de detaliere, sunt mai precise și au o structură de o complexitate mai mare.



Figura 6.2 Cele cinci LoD definite în standardul CityGML 2.0

(Biljecki, Ledoux, & Stoter, 2016)

În standardul CityGML, obiectele prezintă modelele de definire semantice și geometrice. **Modelul semantic** are la bază standardele ISO 19109 și GML3 și conține definiția claselor. Utilizarea semanticii diferențiază modelele 3D tipice de cele standardizate CityGML. La nivelul semantic, obiectele din lumea reală sunt reprezentate prin caracteristici, cum ar fi tipul elementelor: clădiri, pereți, ferestre etc. **Modelul geometric** are la bază standardul ISO 19107 și reprezintă proprietățile spațiale ale geometriei 3D a obiectelor. Dacă un model 3D prezintă ambele tipuri de ierarhii, atunci acestea trebuie să fie coerente și în corespondență.

6.3.2. CityGML 3.0

CityGML 3.0 va aduce mari îmbunătățiri versiunilor anterioare, prin împărțirea pe etaje, eliminarea LoD4 și includerea de specificații pentru interior și exterior pentru toate nivelele de detaliere.

6.4. Aplicații ale modelelor 3D ale clădirilor

Modelele 3D ale orașelor, prin componenta de bază - modele 3D ale clădirilor, acoperă o gamă variată de aplicații. Cele mai cunoscute aplicații ale modelării 3D a clădirilor sunt estimarea potențialului de energie solară, estimarea necesarului de energie pentru clădirile individuale, realizarea cadastrului 3D, analiza vizibilității, răspunsul prompt în cazul situațiilor de urgență și studiul posibilului impact generat de inundații, cutremure etc.

6.5. Situația internațională actuală în modelarea 3D a clădirilor

Website-ul <https://3dbag.nl/> conține seturi de modele 3D ale clădirilor pentru orașele din Olanda. Clădirile sunt disponibile la diverse nivele de detaliere și sunt actualizate regulat.

Modelul 3D al orașelor din Singapore a fost lansat sub formă de date deschise în anul 2019. Amprentele clădirilor disponibile în OpenStreetMap au fost extrudate pe baza informațiilor despre numărul de etaje oferite de către instituția HDB (Consiliu pentru locuințe și dezvoltare).

Elveția este o altă țară care a trecut la hărți topografice 3D, cu o acoperire totală a teritoriului cu obiecte 3D.

6.6. Software pentru generarea modelelor digitale 3D ale clădirilor

6.6.1. BuildingReconstruction

Software-ul *BuildingReconstruction*, dezvoltat de *virtualcitySYSTEMS* (2018) generează modele digitale ale clădirilor cu nivelul de detaliere LoD1 sau LoD2. Pentru fiecare poligon 2D al unei clădiri, este produs un model 3D separat, al cărui volum este în corespondență cu geometria 2D a amprente la sol și cu înălțimea clădirii extrasă din MDS.

6.6.2. Esri CityEngine

Software-ul *CityEngine*, dezvoltat de către *Esri*, se află la versiunea 2020.1. Procedura de generare 3D are la bază o serie de fișiere de reguli, scrise într-un limbaj de programare unic denumit CGA (Computer Generated Architecture). Aceste reguli stau la baza extrudării poligoanelor și a generării modelelor 3D ale clădirilor (figura 6.3). Texturile pentru clădiri pot fi adăugate în fișierul de reguli.

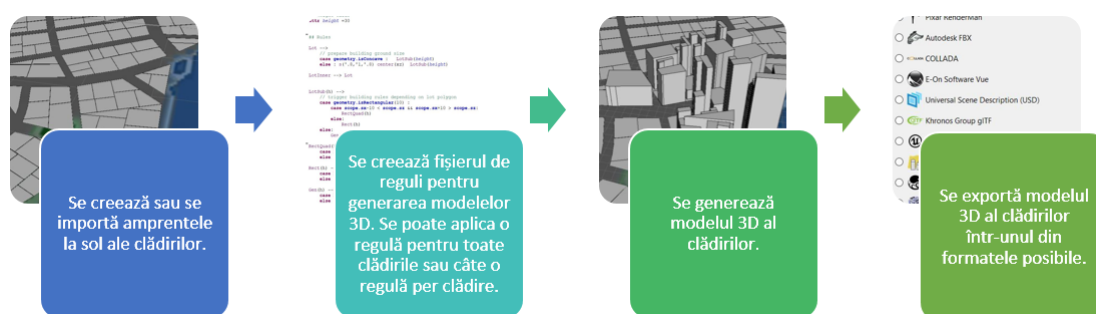


Figura 6.3 Generarea modelului 3D al clădirilor în Esri CityEngine

6.6.3. 3dfier

3dfier este un instrument open-source pentru crearea modelelor 3D, dezvoltat în cadrul Universității de Tehnologie Delft, Olanda. Modelele 3D ale clădirilor sunt generate pe baza poligoanelor 2D și a norului de puncte aferent zonei (TUDelft, 2021). Ampretele clădirilor sunt extrudate la înălțimea dată de cota punctelor din norul 3D (figura 6.4).




Figura 6.4 Metoda de generare a modelelor 3D ale orașelor în software-ul 3dfier (TUDelft, 2021)

6.6.4. PolyFit

Software-ul *PolyFit* realizează reconstrucția suprafețelor pe baza unor strategii de ipoteze și selecții, generând modele 3D ale clădirilor cu cât mai puține suprafețe planare.

6.7. Erori geometrice și semantice în seturile de modele 3D CityGML

6.7.1. Tipuri de erori geometrice și semantice

CityGML folosește primitive geometrice pentru a reprezenta obiectele, conform standardului ISO 19107, astfel: o primitivă 0D este un punct, o primitivă 1D este o polilinie închisă, o primitivă 2D este o suprafață și o primitivă 3D este un solid. Primitivele geometrice cu aceeași dimensionalitate pot fi combinate pentru a forma agregate. Acestea pot fi structurate în patru clase: multi-suprafață, suprafață tip compozit, înveliș/cochilie, solid tip compozit.

Fiecare suprafață poate stoca atribute și acest fapt este recomandat pentru facilitarea analizelor ulterioare. Pentru evidențierea și corectarea erorilor semantice, clasele pot fi simbolizate diferit și astfel erorile pot fi ușor sesizate la o inspecție vizuală.

6.7.2. Software de validare a topologiei

Software-ul open-source *val3dity* permite validarea primitivelor 3D în concordanță cu standardele internaționale ISO 19107 - *Informații geografice - Schemă spațială*, folosind linia de comandă. Ca date de intrare se pot folosi fișiere GML, CityJSON, CityGML, OBJ. Modul de validare este ierarhic, astfel că întâi sunt validate primitivele de dimensiune inferioară.

6.8. GIS 3D și BIM

Privind ciclul de viață al unei clădiri, primul pas ar trebuie să fie reprezentat de generarea unui BIM (engl. Building Information Models). Standardul IFC (engl. Industry Foundation Classes) reprezintă toate elementele componente ale unei clădiri (ex. *IfcDoorType* - tipul ușii). Prin urmare, pentru clădiri construite pe baza unui BIM nu mai este necesară generarea unui model 3D pe baza elementelor măsurate în teren, ci doar maparea semantică și conversia geometrico-semantică din standardul IFC în GML. Există câteva software-uri care permit această conversie, precum *Building Information Modelserver* (BIMserver, 2021), *IFCExplorer* (SECOM, 2020), *FME* (SAFE, 2021).

6.9. Studiu de caz - generarea modelelor 3D ale clădirilor

Primul pas în generarea modelelor 3D ale clădirilor este extragerea amprentelor la sol ale clădirilor din norii de puncte, în software-ul *OPALS*. Ulterior, voi aplica două abordări pentru determinarea înălțimii clădirilor, fie direct din norul de puncte, fie pe baza informațiilor extrase din nMDS.

6.9.1. Extragerea amprentelor la sol ale clădirilor din norii de puncte LiDAR

6.9.1.1. Generarea amprentelor la sol din nori de puncte segmentați

Pentru studiul de caz am folosit doar clasa **clădiri** din norul de puncte clasificat în etapele anterioare. Primul pas în *OPALS* a fost transformarea norului de puncte din format las în format odm.

6.9.1.1.1. Grupare condiționată

Pe baza exemplelor disponibile pe website-ul OPALS, <https://opals.geo.tuwien.ac.at/>, am realizat un cod Python, pe care l-am rulat din software-ul *PyCharm*. Am aplicat două criterii de grupare diferite pentru segmentarea bazată pe gruparea condiționată a punctelor. Acestea vor fi descrise în continuare.

Grupare condiționată varianta 1

Criteriul de omogenitate este dat de diferența altimetrică a punctelor vecine. Dacă diferența altimetrică este mai mică de 10cm, atunci punctele aparțin aceluiași segment.

În urma rulării segmentării, au rezultat 44 de segmente; pentru fiecare segment, software-ul afișează parametrii planului și valoarea sigma0. Prin aplicarea algoritmului **alpha shape**, au rezultat 57 de poligoane. Unele poligoane conțin mai multe clădiri, dar majoritatea au fost extrase corect.

Grupare condiționată varianta 2

În acest caz, criteriul de omogenitate este dat de unghiul dintre vectorii normalelor în punctele vecine. Pentru unghiul dintre normale am folosit valoarea de 10°. În urma rulării segmentării, au rezultat 64 de segmente. Prin aplicarea algoritmului **alpha shape**, au rezultat 71 de poligoane.

6.9.1.1.2. Extragerea planurilor

Pe baza exemplelor disponibile pe website-ul OPALS, <https://opals.geo.tuwien.ac.at/>, am realizat un cod Python, pe care l-am rulat din software-ul *PyCharm*. După efectuarea mai multor teste, am ales folosirea următorilor parametri pentru segmentare:

- ✓ **raza de căutare** (searchRadius) = 1;
- ✓ **dimensiunea minimă a unui segment** (minSegSize) = 50;
- ✓ **distanța maximă dintre un punct și plan** (maxDist) = 0.25;
- ✓ **abaterea standard maximă a vectorului normalelor pentru un segment**, în procesul de identificare a planului segmentului respectiv (maxSigma) = 0.15;
- ✓ **calculatorul nucleelor** (seedCalculator) = "NormalSigma0 < 0.1 ? NormalSigma0 : invalid";
- ✓ **raza pentru alpha shape** (alphaRadius) = 1.

În urma rulării segmentării, au rezultat 210 segmente, iar prin aplicarea algoritmului **alpha shape**, au rezultat 222 poligoane. Din rezultatele obținute, se poate afirma că segmentarea care reușește să grupeze punctele care aparțin unui singur acoperiș este realizată prin

metoda de extragere a planurilor. Dezavantajul metodei este dat de lipsa poligoanelor pe coamele clădirilor, ceea ce complică procesul de simplificare și regularizare a conturului. În figura 6.5 se observă analiza comparativă a metodelor de segmentare testate. Indiferent de metoda de segmentare aleasă, trebuie aplicate operații GIS de regularizare a poligoanelor.



Figura 6.5 Poligoanele contur clădiri rezultate pe baza segmentărilor
a) prin metoda extragerii planurilor; b) prin metoda grupării condiționate varianta 2

În urma evaluării comparative a rezultatelor obținute prin cele două tipuri de segmentări în OPALS, putem concluziona că metode de extragere a planurilor oferă cele mai bune rezultate și va fi folosită în continuare în fluxul de lucru.

6.9.1.2. Post-procesarea poligoanelor segmentate

Amprente la sol ale clădirilor generate cu ajutorul segmentării prin metoda extragerii planurilor necesită aplicarea de operațiuni pentru simplificare și regularizare, într-un mediu GIS, în vederea utilizării lor ca bază a modelelor 3D ale clădirilor. Datorită golurilor rezultate pe coamele acoperișurilor, este necesară aplicarea mai multor funcții GIS. Fluxul de lucru propus pentru regularizarea poligoanelor a fost realizat în mediul *ArcGIS Pro*. Funcțiile aplicate sunt detaliate în figura 6.6.




Figura 6.6 Regularizarea amprentelor la sol



Figura 6.7 Amprețele la sol ale clădirilor
a) rezultatele segmentării; b) rezulatele postprocesării

O etapă ulterioară regularizării a fost cea de filtrare a clădirilor cu suprafețe mai mici decât 20m^2 . În final, pentru cvartalul testat, au rămas 53 de poligoane reprezentând amprente la sol ale clădirilor. După filtrări și generalizări, setul de date trebuie corectat de erorile topologice de tipul suprapunerilor sau golurilor. Am rulat topologia și am identificat 24 de erori, pe care le-am corectat.

Din analiza setului de date, se poate concluziona că peste 90% din clădiri au amprente la sol corespunzătoare cu realitatea. Diferența de 10 procente de clădiri neconforme se datorează unor erori de clasificare a norului de puncte, cât și de segmentare a acestuia.

6.9.2. Generarea modelelor 3D ale clădirilor în software-ul 3dfier

Pentru rularea software-ului este nevoie de pregătirea mediului de lucru (figura 6.8). Așa cum am descris în subcapitolul anterior, amprente la sol (*cladiri_shp.shp*) au fost regularizate și corectate de toate erorile topologice înainte de a fi introduse în software-ul de generare a modelelor 3D. Norul de puncte folosit (*cladiri_ground.las*) este format doar din clasele puncte la sol, respectiv clădiri. Am actualizat fișierul de configurare model cu informațiile aferente, extrase pe baza setului de date. Software-ul poate fi rulat din linia de comandă (Command Prompt). După navigarea la locația unde este salvat *3dfier*, se execută comanda `.. \3dfier.exe testarea_config.yml -OBJ output\ARAD.obj`.



Figura 6.8 Date de intrare pentru software-ul 3dfier

Pentru vizualizare, rezultatul final, modelul 3D al clădirilor cu nivelul de detaliere LoD1, a fost încărcat în software-ul *MeshLab*. *ARAD.obj* este format din 1030 de vertecși și 1976 fețe (figura 6.9).




Figura 6.9 Model 3D al clădirilor generat în software-ul 3dfier

6.9.3. Generarea modelelor 3D ale clădirilor în software-ul CityEngine

Această abordare necesită informații legate de înălțimea fiecărei clădiri individuale. Am ales livrarea acestor înălțimi sub formă de atribute ale amprentelor la sol. Astfel, pe baza amprentelor la sol post-procesate anterior, a înălțimii clădirilor extrase din nMDS și a regulilor CGA se vor genera modele 3D cu nivel de detaliere LoD1 sau LoD2.

6.9.3.1. Extragerea înălțimii clădirilor pe baza punctelor centroid

În software-ul *Global Mapper* am generat, pe zona de interes, următoarele modele digitale: MDT - din punctele la sol, MDS - din punctele la sol și punctele din clasa clădiri și nMDS - pe baza diferenței dintre MDS și MDT. Toate modelele au fost generate la rezoluția spațială de 1m, folosind metoda biliniară de interpolare.

Transferul acestor valori către poligoanele reprezentând amprentele la sol se poate realiza în software-ul *ArcGIS Pro*, urmând pașii de mai jos:

- ✓ generarea de puncte centroid ale clădirilor (figura 6.10);
- ✓ extragerea cotei pixelului, din nMDS, aferente punctului centroid;
- ✓ crearea câmpului *Înălțime* (tip Numeric - Double);
- ✓ crearea unui join spațial între punctele centroid și amprentele la sol (*Clădiri.shp*);
- ✓ transferul de atribute și popularea câmpului *Înălțime*.




Figura 6.10 Punctele centroid ale clădirilor și statisticile aferente

Din figura 6.10 se poate observa că înălțimea medie a clădirilor din cvartalul de test este de 4.6 metri și că majoritatea clădirilor au înălțimi sub valoarea de 7 metri.

În software-ul *CityEngine* am definit regulile CGA: tipul de acoperiș (gable roof - acoperiș în două ape), unghiul de înclinare al acestuia (22.5°) și textura folosită pentru fațadele clădirilor. Analizând înălțimile clădirilor din modelele generate față de norii de puncte clasificați, se poate constata că există o diferență mare pentru unele clădiri ale căror acoperișuri sunt foarte înclinate (figura 6.11).




Figura 6.11 Diferențe mari de înălțime între modelele generate și norii de puncte

Aceste erori se datorează modului în care înălțimea clădirilor a fost extrasă din nMDS și anume față de centroidul clădirilor, care în majoritatea cazurilor se află pe coama acoperișurilor, în punctul cel mai înalt.

6.9.3.2. Extragerea înălțimii clădirilor pe baza punctelor caracteristice

Pentru a evita problema de mai sus, am aplicat un alt flux de extragere a înălțimii clădirilor, după cum urmează:

- ✓ aplicarea unui buffer negativ (-1m) poligoanelor din clasa de obiecte *Clădiri.shp*;
- ✓ transformarea conturului clădirilor în format vector tip linie;
- ✓ generarea de puncte pe fiecare contur al clădirilor (figura 6.12);
- ✓ extragerea cotei pixelului, din nMDS, aferente punctului;
- ✓ crearea câmpului *Înălțime* (tip Numeric - Double);
- ✓ crearea unui join spațial între punctele caracteristice și amprente la sol (*Clădiri.shp*);
- ✓ transferul de attribute și popularea câmpului *Înălțime*.

Prin aplicarea acestui nou flux, se trece de la **punctele centroid** ale clădirilor la **punctele caracteristice**, aflate pe acoperiș, mult mai apropiate de muchiile inferioare ale acoperișului.




Figura 6.12 Punctele caracteristice ale clădirilor și statisticile aferente

Această abordare nouă conduce la generarea unor modele 3D realiste, cu înălțimi corecte ale clădirilor (figura 6.13). Din figura 6.12 se observă că cea mai înaltă clădire are 7.6 metri

și că înălțimea medie a clădirilor din cvartalul de test este de 3.9 metri, față de 4.6 metri în versiunea anterioară.




Figura 6.13 Detalii din modelul 3D optimizat al clădirilor

6.9.4. Analiza calității modelelor 3D ale clădirilor

Modelul 3D al clădirilor rezultat în software-ul *3dfier* are nivelul de detaliere LoD1, iar cel generat în software-ul *CityEngine* are nivelul de detaliere LoD2. Prin urmare, pentru analiza calității modelelor generate voi folosi varianta rezultată în software-ul *CityEngine* prin folosirea înălțimilor optimizate determinate din punctele caracteristice ale clădirilor.


În scopul evaluării calității modelelor 3D, vor fi analizați următorii indicatori:

A. eroarea medie pătratică planimetrică


Am ales 17 puncte distribuite aleatoriu în cvartalul analizat, amplasate atât la baza clădirii, cât și în partea superioară reprezentată de colțul de sus al clădirii. Coordonatele planimetrice ale acestor puncte au fost comparate cu punctele corespondente (cele mai apropiate) din norul de puncte. Eroarea medie pătratică planimetrică rezultată este de 0.38m.

B. eroarea medie pătratică altimetrică

Am ales 22 de puncte distribuite aleatoriu în cvartalul analizat, amplasate în partea superioară a acoperișurilor. Coordonatele altimetrice ale acestor puncte (înălțimea clădirilor) au fost comparate cu valorile pixelilor din nMDS. De menționat că toate acoperișurile au fost generate cu același unghi de înclinare. Prin urmare, acoperișurile tip bloc sau cele înclinate pe direcții diferite pot genera erori semnificative în calculele următoare. Din analiza datelor se pot observa diferențe foarte mari, de ordinul metrilor pentru 6 situații care vor fi analizate în continuare.



Nr.crt. 7



Nr.crt.11




Figura 6.14 Analiza vizuală și statistică a situațiilor cu diferențe mari ale înălțimilor

Situațiile prezentate în figura 6.14 demonstrează că diferențele mari identificate se datorează acoperișurilor tip bloc (Nr.crt.7) și acoperișurilor înclinate pe alte direcții (Nr.crt.11). Eliminând aceste situații, se obține o valoare finală a erorii medii pătratice altimetrice de 0.63m.

Eroarea medie pătratică 3D se calculează pe baza celor trei erori medii pătratice ale coordonatelor.

$$\sigma_{3D} = \sqrt{\sigma_X^2 + \sigma_Y^2 + \sigma_H^2} = 0.73m$$

Din literatura de specialitate, precizia 3D a punctelor pentru modelele 3D ale clădirilor cu LoD2 este de 2 metri, prin urmare, se poate afirma că eroarea medie pătratică 3D obținută pe setul de date analizat (0.73 metri) se încadrează în standardele din domeniu.

Ținând cont de toate etapele parcurse și de rezultatele obținute în capitolele 4 și 6, fluxul de lucru urmat de la norii de puncte neclasificați la modelele 3D ale clădirilor este exemplificat schematic în figura 6.15.

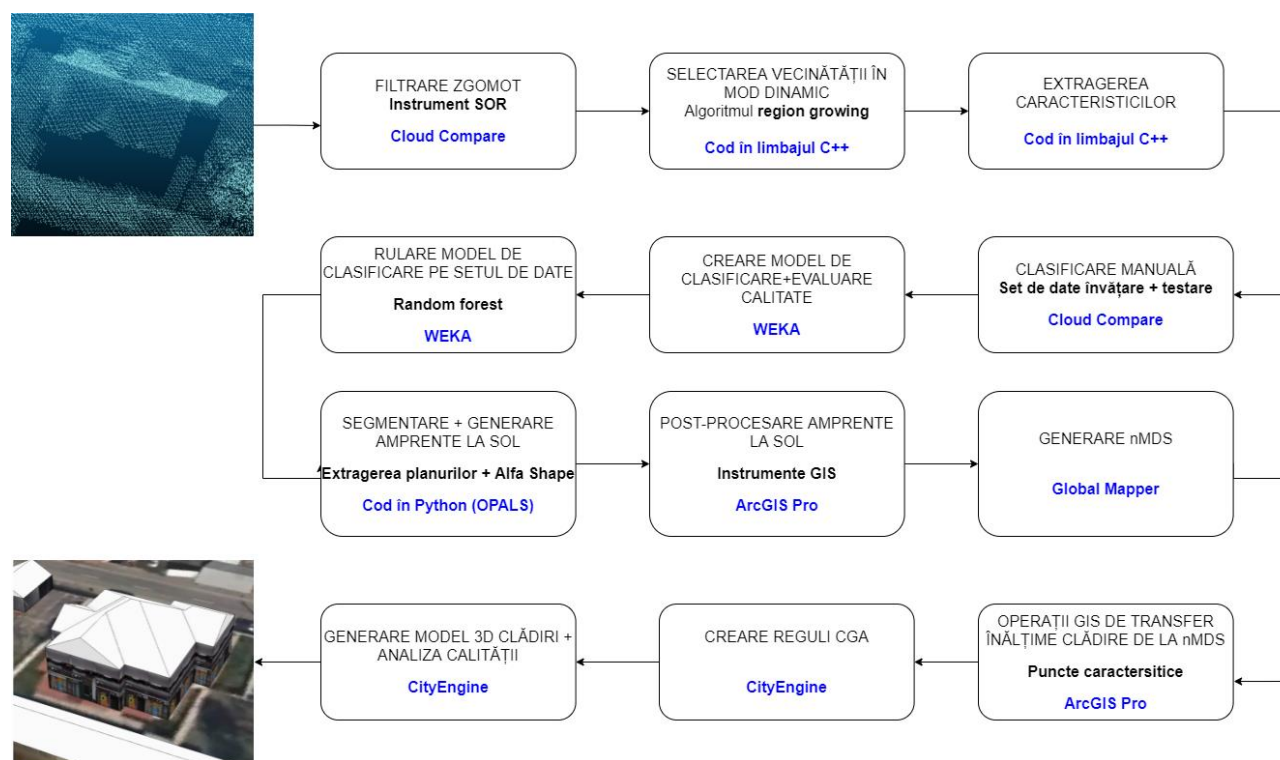


Figura 6.15 Flux de lucru propus pentru generarea modelelor 3D ale clădirilor

7. Generarea și publicarea modelelor 3D ale clădirilor pentru Municipiul Arad

7.1. Introducere și scop

Modelarea 3D a clădirilor la nivel de municipiu poate furniza date utile atât la nivel central, cât și local. Fluxul de date prezentat în cadrul capitolului 6 poate conduce la generarea corectă și coerentă a modelelor 3D. Pentru exemplificarea modelării la nivel de municipiu am ales să folosesc baza de date națională TopRo5 și date legate de înălțimea clădirilor extrase din proiectul LAKI II.

7.2. Generarea modelelor 3D pentru MRJ Arad

7.2.1. Date inițiale

Ca date inițiale pentru modelarea 3D a clădirilor din Municipiul reședință de județ Arad am folosit următoarele:

- clasa de obiecte spațiale CONSTRUCȚII din baza de date TopRo5;
- MDT și MDS din Proiectul LAKI II.

TopRo5 este planul topografic de referință al României în format digital, corespunzător scării 1:5.000. Acesta a fost realizat și este actualizat permanent în cadrul Centrului Național de Cartografie, în prezent aflându-se la versiunea 6 (CNC, 2020a). În mare măsură, modul de populare cu date geospațiale este digitizarea elementelor pe ortofotoplanurile disponibile. Adicional, se folosesc și surse externe, precum conturul imobilelor din aplicația *e Terra* (ANCP, 2021), date vectoriale rezultate din recepția lucrărilor de specialitate etc.

7.2.2. Prelucrarea setului de date în vederea utilizării software-ului CityEngine

O primă filtrare a elementelor extrase din TopRo5 a fost eliminarea clădirilor cu suprafețe mai mici de 20m², rezultând 50390 poligoane clădiri.

Pe baza MDS și MDT am generat, în software-ul *Global Mapper*, nMDS, cu ajutorul instrumentului *Combine/Compare Terrain Layers*. Toate cele 23 de modele nMDS conțin punctele aflate deasupra solului și au fost exportate la rezoluția spațială de 1m (figura 7.1).

Chiar dacă există un decalaj între momentul achiziției datelor fotogrammetrice (2016), respectiv a norilor de puncte LiDAR (2017), un procent de peste 90% din clădiri nu prezintă modificări în timp care să afecteze modelarea 3D.




Figura 7.1 Detaliu dintr-un tile de nMDS pentru MRJ Arad






Figura 7.2 Punctele centroid ale clădirilor cu atribute pentru înălțimea clădirilor

Pentru toate poligoanele clădiri am generat puncte centroid, cărora le-am transferat înălțimea din modelul normalizat al suprafețelor (figura 7.2). În urma analize succinte a valorilor transferate din nMDS, am constatat că unele puncte centroid au valoarea înălțimii egale cu 0 și am decis să fac o verificare amănunțită la nivel de tile nMDS. Din analizele efectuate, pentru un număr de 1119 puncte centroid s-au regăsit valori nule ale înălțimii. Prin urmare, aceste clădiri fie au fost demolate, fie digitizarea lor nu a fost realizată întocmai cu situația din teren (figura 7.4). Un număr de 6669 de clădiri au valori ale înălțimilor mai mici de 2 metri și sunt considerate clădiri anexe, care pot fi eliminate din analizele viitoare (figura 7.3).

Figura 7.3 Analiză statistică a valorilor înălțimilor clădirilor



Pentru încărcarea terenului în *CityEngine* am generat un sigur fișier raster MDT pentru întreg municipiul, cu rezoluția spațială de 5 metri.

Figura 7.4 Situații concrete cu poligoane-clădiri cu înălțime nulă
(a) clădire demolată; (b) clădire digitizată necorespunzător

7.2.3. Generarea modelelor 3D ale clădirilor în CityEngine

Pe baza amprentelor la sol ale clădirilor, cu atributul *înălțime* aferent, a MDT și a regulilor CGA am generat, în software-ul *CityEngine*, modelele 3D ale clădirilor din Municipiul Arad. Pe baza celor 42602 poligoane clădiri 2D au rezultat 525613 fețe 3D (figurile 7.5). Prin setarea unghiului acoperișurilor la valoarea 0, am generat clădiri tip bloc, cu acoperiș plat, pentru toate clădirile de pe suprafața municipiului. De menționat că bisericile și alte clădiri cu forme complexe nu au fost tratate diferit de restul, modelarea lor 3D nefiind conformă cu realitatea.



Figura 7.5 Model 3D al clădirilor MRJ Arad - vedere de ansamblu

7.2.4. Evaluarea calității modelelor generate pe baza poligoanelor din TopRo5

Am ales să realizez un studiu comparativ între modelele 3D rezultate în capitolul 6 și modelele rezultate în prezentul capitol. Analiza distanțelor de la modele 3D la norul de puncte format din clasa CLĂDIRI a fost realizată în software-ul *CloudCompare*, utilizând instrumentul *Cloud/Mesh Distances*. În urma evaluării, au rezultat datele statistice, pe baza distanțelor aproximative pentru 147565 de puncte, din tabelul 7.1. Astfel, abaterea standard în cazul modelelor generate pe baza amprentelor din TopRo5 este de 1.57m, față de 1.08m pentru situația generării modelelor din date LiDAR.

Modele 3D ale clădirilor	Distanța medie (m)	Abaterea standard (m)
Generate exclusiv din date LiDAR	0.26	1.08
Generate pe baza amprentelor din TopRo5	0.42	1.57

Tabel 7.1 Analiza calității modelelor față de norul de puncte

Cele două seturi de modele 3D ale clădirilor se diferențiază și prin numărul de fețe poligonale rezultate în urma generării: 1187 amprente din TopRo5 și 3084 amprente generate din date LiDAR (figura 7.6).

Pe baza tuturor analizelor prezentate anterior, putem concluda că modelele generate exclusiv din date LiDAR prin fluxul de lucru propus în capitolul 6 oferă rezultate de calitate superioară.




Figura 7.6 Modele 3D ale clădirilor
(a) generate exclusiv din date LiDAR; (b) generate pe baza amprentelor din TopRo5

7.3. Publicarea modelelor 3D ale clădirilor în mediul ArcGIS Online

7.3.1. Despre ArcGIS Online și CityEngine WebViewer

ArcGIS Online este un software-disponibil-ca-serviciu (SaaS) care pune la dispoziția utilizatorului o serie de instrumente de cartografiere și analiză a datelor 2D, respectiv 3D (ESRI, 2021).

7.3.2. Interfața web și prezentare datelor publicate online

Pe baza documentării inițiate cu ocazia redactării articolului despre hărți și aplicații web pentru municipiul Oradea (Pârvu I. M., Cuibac Picu, Dragomir, & Pantan, 2021), am decis să continui studiul capabilităților lui *ArcGIS Online* în lucru cu datele 3D. În acest sens, am exportat scena din *CityEngine*, care conținea modelul 3D al clădirilor din Municipiul Arad și terenul reprezentat de MDT, în format *CityEngine WebScene*. Noul fișier trebuie stocat în platforma *ArcGIS Online*, prin opțiunea *Share As*. Apoi, datele sunt disponibile în Conținutul

propriu din *ArcGIS Online* și pot fi vizualizate și analizate în software-ul *CityEngine Web Viewer* (figura 7.7).




Figura 7.7 Model 3D al clădirilor disponibil în CityEngine WebViewer

8. Concluzii generale, contribuții originale și perspective de viitor

8.1. Concluzii generale

Concluzii privind achiziția de date geospațiale prin teledetecție și aerofotografiere

În ceea ce privește tehnologia LiDAR, scanerile convenționale liniare oferă performanțe certe și, odată cu evoluția tehnologică oferită de scanerile tip SPL și Geiger-mode, capabilitățile și productivitatea au cunoscut o creștere considerabilă. Din analiza performanțelor celor trei tipuri de instrumente LiDAR (scanere liniare, SPL și Geiger-mode), se observă că rata de scanare a unui sistem SPL este de 3 ori mai mare ca a unui sistem liniar, iar rata de scanare a unui sistem Geiger-mode este de 2 ori mai mare ca a unui sistem SPL.

Pentru orice proiect, fie el de scanare, fie de aerofotografiere, partea de planificare este extrem de importantă, iar dacă această etapă nu este tratată cu seriozitatea cuvenită procesarea datelor poate fi mult îngreunată sau chiar imposibil de realizat.

Fluxul de prelucrare a norilor de puncte implică atât calibrarea datelor, compensarea benzilor, cât și transformarea în sistemul de coordonate și clasificarea punctelor. ASPRS a definit în 2019 cea mai recentă versiune a formatului LAS, versiunea 1.4, cu 256 de clase. În funcție de tipul proiectului este nevoie de identificarea claselor optime pentru clasificarea norilor de puncte. În acest sens, trebuie ținut cont de faptul că un număr mare de clase complică procesul de clasificare și crește confuzia dintre clase (Pârvu I. M., Cuibac Picu, Dragomir, & Poli, 2020).

În prezent, se folosesc camere fotogrammetrice de top produse de firme precum Leica Geosystems, Vexcel Imagine, care pot prelua imagini nadirale, cât și oblice. Față de fotogrammetria tradițională, tehnologia de preluare a imaginilor oblice oferă o serie de avantaje, cum ar fi: vizibilitatea foarte bună a fațadelor, vederi multiple și interpretarea facilă a clădirilor ca număr de etaje, amprente la sol etc. Dezavantajele utilizării imaginilor oblice sunt date de iluminarea diferită a obiectelor, rezoluțiile spațiale diferite în cadrul imaginilor și cerințe hardware-software mărite. Cea mai întâlnită configurație pentru camerele oblice este *Maltese-cross*.

În prezenta teză am detaliat fluxul de lucru fotogrammetric, prezentând informații de ultimă oră legate de producerea de true-ortofotoplanuri din imagini oblice. În ceea ce privește planificarea zborului folosind platforme tip avion, cea mai folosită metodă utilizează înălțimi de zbor proprii fiecărei benzi. În cazul sistemelor UAV/UAS se folosește metoda de urmărire a terenului. În ceea ce privește extragerea punctelor de legătură din

imaginile oblice, procedeul este extrem de laborios și solicitant din punct de vedere computațional. Utilizarea operatorului SIFT, în acest scop, a ușurat procesul de extragere.

În cazul imaginilor cu o rezoluție spațială de 10cm, norul de puncte dens rezultat (DIM) din imagini nadirale are o densitate de 100 puncte/m², față de DIM-ul obținut din imagini nadirale și oblice care oferă o densitate triplă, datorită punctelor aflate pe fațadele clădirilor. Chiar dacă norul de puncte este mult mai dens, apar probleme din cauza procentului mare de puncte tip zgomot. Pentru a diminua acest efect, în cazul imaginilor oblice se folosesc suprapuneri longitudinale și transversale de 80%.

Pentru extragerea precisă a clădirilor în mod semiautomat sau automat, true-ortofotoplanul este alegerea optimă, pentru că obiectele artificiale sunt poziționate corect la sol și zonele obstrucționate sunt eliminate.

Concluzii privind clasificarea norilor de puncte LiDAR și segmentarea semantică a imaginilor ortorectificate

Am analizat metodele de segmentare ale norilor de puncte, pornind cu segmentarea bazată pe muchii, continuând cu segmentarea tip **region growing**, ajungând la metode de potrivire a modelelor și finalizând cu segmentarea bazată pe **Machine learning**.

Pornind de la etapele de lucru pentru clasificarea supervizată a norilor de puncte, am elaborat un flux de lucru propriu. Prima etapă constă în selectarea vecinătății, pe baza căreia se vor calcula caracteristicile proprii ale punctelor. În literatura de specialitate se cunosc următoarele modalități de selectare a vecinătății: alegerea valorii razei sferei sau cilindrului care determină vecinătatea în jurul punctului, alegerea/calculul valorii lui K de vecini apropiați. Analizând opțiunile, am decis că utilizarea numărului K de vecini apropiați este varianta optimă. În acest sens, am propus și implementat într-un cod C++ utilizarea **vecinătății dinamice a lui K pe baza algoritmului region growing**. Astfel, fiecare punct va avea propriul număr K_i de vecini, în funcție de măsurătorile de similitudine tipice metodei de segmentare bazată pe regiuni.

Cele mai cunoscute **caracteristici locale 3D** sunt caracteristicile proprii abstracte, care sunt determinate pe baza valorilor proprii. Astfel, am dezvoltat un cod C++ pentru calculul caracteristicilor proprii, precum liniaritatea, planaritatea, schimbarea curbării, sfericitate, anisotropie. Pe lângă aceste caracteristici 3D din literatura de specialitate, am definit o serie de caracteristici noi, din care caracteristica N_2 s-a dovedit relevantă în procesul de clasificare.

În clasificarea supervizată, atribuirea clasei se face prin învățarea modelului pe baza unui set de date de învățare și rularea ulterioară pe întregul set de date. Setul de învățare trebuie să reprezinte foarte bine datele și clasificarea lui trebuie realizată extrem de precisă. Setul de testare se folosește pentru evaluarea calității clasificării. Ambele seturi de date pot fi clasificate **manual**, **automat** sau prin **metoda crowdsourcing**.

Software-ul *Weka*, dezvoltat de Universitatea din Waikato, Noua Zeelandă, conține o colecție de algoritmi de **Machine learning** pentru rezolvarea problemelor de extragere a tiparelor din seturi mari de date, cu aplicații în domeniul bancar, diagnosticare, marketing și vânzări. În cadrul tezei, am folosit acest software pentru clasificarea supervizată a norilor de puncte LiDAR.

În testele efectuate, am început analiza utilizând trei clase (puncte la sol, vegetație și clădiri), însă rezultatele clasificării au avut indicatori de calitate foarte scăzuți, pentru că toate punctele de tip linii electrice, mașini, garduri etc. au fost clasificate într-una din clasele de bază. Astfel, am decis includerea clasei *Altele*, care să conțină puncte care nu aparțin punctelor la sol, vegetației sau clădirilor.

Din analizele referitoare la timpul necesar generării și testării modelului pentru cei 7 clasificatori rulați în software-ul *Weka*, timpul cel mai mare a fost necesar clasificatorului **IBk** (1 oră și 45 minute), iar cel mai scurt, clasificatorului **Naive Bayes** (9 secunde). Clasificatorul **Random Forest** a generat și testat modelul în doar 7 minute.

Clasamentul, din punct de vedere al indicatorilor de calitate a clasificării, este următorul: locul I - **SMO**, locul II - **Random Forest** și locul III - **Naive Bayes**. Precizia clasificării obținută de acești clasificatori este de aproximativ 93%. Analizând indicatorii de calitate pentru clasa *Clădiri*, am arătat că metodele **Random Forest** și **SMO** oferă cele mai bune rezultate, cu valori ale scorului F1 de aproximativ 93%.

În urma tuturor testelor rulate, pot afirma că *Weka* este un mediu de lucru foarte performant și permite clasificarea precisă a norilor de puncte.

În ceea ce privește extragerea conturului clădirilor din imagini ortorectificate, am analizat metodele de segmentare semantică de tip Machine learning și de tipul Rețelelor Neuronale Artificiale Profunde, în software-ul *ArcGIS Pro*. Am testat algoritmi de învățare automată, precum **Maximum Likelihood**, **Random Trees** și **SVM**. Chiar dacă indicatorii de calitate ai segmentării semantice au fost apropiați, **SVM** a generat cele mai bune rezultate. Pentru creșterea calității clasificării, am introdus, ca date auxiliare, MDS. Astfel, precizia clasificării a atins 93.9%, iar clasa *CLĂDIRI* a generat un scor F1 de 93.3%, cu 7% mai bun decât abordarea fără utilizarea MDS.

Am testat capabilitățile RNA folosind rețeaua U-Net cu arhitectura ResNet și am rulat clasificarea pe CPU. Rezultatele obținute pentru clasa *CLĂDIRI*, folosind ResNet34 și ResNet50 au fost similare, observându-se o mică scădere a preciziei (2.5%) și o ușoară creștere a completitudinii (5%). Pentru singura clasă creată *CLĂDIRI*, am obținut utilizând ResNet34, precizia de 90.4%, completitudinea de 62.7% și scorul F1 de 73.8%. Timpul necesar creării modelului ResNet50 a fost de 15 ore, de 7 ori mai mare decât la ResNet34.

În ceea ce privește rularea modelelor de tip RNA, recomand utilizarea unităților de procesare grafică, care micșorează cu mult timpul de procesare.

Din păcate, amprentele la sol rezultate nu pot fi folosite în procesul de generare a modelelor 3D ale clădirilor, datorită faptului că imaginea ortorectificată folosită este un ortofotoplan, unde majoritatea clădirilor apar înclinate în imagine. Prin urmare, în scopul extragerii automate a conturului clădirilor, se recomandă clasificarea true-ortofotoplanurilor aferente.

Concluzii cu privire la modelarea 3D a clădirilor

Necesitatea trecerii de la hărți 2D la modelele 3D este importantă, atât din punct de vedere al alinierii la standardele internaționale, cât și al utilității aplicațiilor de genul: estimarea potențialului de energie solară, estimarea necesarului de energie pentru clădirile individuale, realizarea cadastrului 3D, analiza vizibilității, răspunsul prompt în cazul situațiilor de urgență și studiul posibilului impact generat de inundații, cutremure.

Țările care reprezintă modele internaționale de urmat în ceea ce privește modelarea 3D a clădirilor sunt Olanda, Singapore, Elveția, Estonia etc. Acestea au realizat modele LoD1 sau LoD2 pentru toate clădirile și le-au publicat ca **date deschise** pe portalurile naționale. Consider că România poate și trebuie să treacă la realizarea modelelor 3D ale clădirilor pentru orașele sale. Studiile și rezultatele pe care le-am prezentat în cadrul acestei teze pot sta la bazele unui nou proiect național de modelare 3D a clădirilor.

În studiul de caz efectuat, am pornit de la norii de puncte clasificați anterior și am extras amprentele la sol, fără intervenție manuală. Pe baza exemplurilor disponibile pe website-ul <https://opals.geo.tuwien.ac.at/>, am realizat un cod Python, în cadrul căruia am calculat normalele, am aplicat segmentarea bazată pe **region growing**, folosind cele două abordări: *gruparea condiționată* și *extragerea planurilor* și am extras conturul clădirilor pe baza algoritmului *alpha shape*. Fluxul propus pentru trecerea de la poligoanele segmentate la amprentele clădirilor regularizate a fost realizat în software-ul *ArcGIS Pro*.

Testarea generării modelelor 3D ale clădirilor am realizat-o în două software-uri: *3dfier* și *CityEngine*.

În software-ul *3dfier* am introdus amprentele la sol, norul de puncte format din clasa *puncte la sol* și *clădiri* și fișierul de configurare actualizat. Rezultatul a fost un fișier tip *obj* cu modelele 3D ale clădirilor, cu nivelul de detaliere LoD1.

Pentru rularea în software-ul *CityEngine* sunt necesare informațiile referitoare la înălțimea clădirilor. Acestea au fost extrase pe baza nMDS generat, folosind următoarele două abordări: pe baza punctelor centroid ale amprentelor la sol și pe baza unor puncte caracteristice aflate pe acoperiș, mult mai apropiate de muchiile inferioare ale acestuia. Din analizele efectuate, abordarea care a folosit punctele caracteristice a generat cele mai bune rezultate. Menționez că ambele abordări reprezintă contribuție proprie și nu au avut la bază alte abordări similare din literatura de specialitate. Pe baza regulilor CGA, de genul tipului

de acoperiș, unghiului de înclinare al acestuia, al texturii care va fi folosită pentru fațadele clădirilor etc., se generează modelele 3D ale clădirilor cu nivel de detaliere LoD2.

Evaluarea calității modelelor 3D a analizat componenta planimetrică și altimetrică. Eroarea medie pătratică planimetrică a fost determinată pe baza a 17 puncte cu corespondent în norul de puncte, rezultând o valoare de 0.38 metri. Eroarea medie pătratică altimetrică a fost evaluată pe baza a 22 de puncte distribuite aleatoriu în modelele 3D, amplasate în partea superioară a acoperișurilor, prin compararea cu valorile corespondente din nMDS, rezultând o valoare de 1.55 metri. Din analiza detaliată a situațiilor care au generat această valoare, pot afirma că unele puncte sunt amplasate pe clădiri cu tipuri diferite de acoperiș față de cel impus prin regulile CGA (plat, nu înclinat) sau cu acoperiș cu coama pe o altă direcție. Prin eliminarea acestor puncte din calcul, se obține o valoare a erorii medii pătratice altimetrice de 0.63m. Din literatura de specialitate, precizia 3D a punctelor pentru modelele 3D ale clădirilor cu LoD2 este de 2 metri, prin urmare, se poate afirma că eroarea medie pătratică 3D obținută pe setul de date analizat (0.73 metri) se încadrează în standardele din domeniu.

Atunci când se realizează modelarea 3D trebuie ținut seama că modelele 3D ale clădirilor nu reprezintă întocmai realitatea, dar pentru a avea o calitate superioară, acestea trebuie să fie actuale, consistente și fără erori topologice sau semantice.

În capitolul 7, am generat modelele 3D ale clădirilor pe baza amprentelor la sol din baza de date națională (din TopRo5, la nivelul anului 2016) și a înălțimilor din nMDS (din Proiectul LAKI II, la nivelul anului 2017). Dacă clădirile ar fi fost digitizate pe baza ortofotoplanului din Proiectul LAKI II, atunci se putea realiza o corespondență 1:1 între conturul digitizat al clădirilor și conturul din nMDS, ceea ce ar fi permis modelarea 3D a tuturor clădirilor și ar fi condus la o creștere a preciziei 3D a modelelor. Unghiul acoperișurilor a fost setat la valoarea 0, ceea ce a condus la generarea unor modele 3D tip bloc, cu acoperiș plat, pentru toate clădirile de pe suprafața municipiului. Pe baza celor 42602 poligoane clădiri 2D aferente Municipiului Arad, s-au obținut 525613 fețe 3D.

Comparând modelele generate exclusiv din date LiDAR, prin fluxul de lucru propus în capitolul 6, cu modelele rezultate pe baza amprentelor la sol din baza de date națională TopRo5 și a înălțimilor din nMDS putem concluziona că:

- modelele generate exclusiv din date LiDAR oferă rezultate superioare din punct de vedere calitativ;
- modelele generate pe baza amprentelor la sol extrase din baza de date națională pot fi folosite cu succes pentru generarea modelelor 3D ale clădirilor cu nivelul de detaliere LoD1 și o abatere standard de aproximativ 1.5 metri.

Modelele 3D ale clădirilor generate pentru Municipiul Arad sunt stocate în platforma *ArcGIS Online*, la adresa <https://bit.ly/3fzndY2>, dar **nu au fost publicate ca date deschise** datorită drepturilor de autor asupra datelor brute.

Se pot obține modele 3D ale clădirilor de calitate superioară prin corectarea topologică a amprentelor la sol, prin includerea, la nivelul fiecărei clădiri, de atribute care să conțină informații despre tipul acoperișului, panta acestuia etc. și prin segmentarea clădirilor cu mai multe nivele de înălțime.

8.2. Contribuții personale

Subiectele de bază ale tezei, și anume extragerea automată a datelor geospațiale și modelarea 3D, sunt de mare interes deoarece prezintă probleme actuale în domeniul cercetării la nivel internațional. Drept contribuții personale pot aminti următoarele aspecte:

- Realizarea unei analize amănunțite a celor mai recente realizări tehnologice din punct de vedere al aparaturii, dar și a procesării datelor rezultate prin scanarea laser aeriană și prin aerofotografiere;
- Participarea la realizarea controlului calității datelor din proiectul LAKI II, care au fost folosite în această teză, de la etapa de planificare până la generarea produselor finale;
- Utilizarea celor mai actuale date LiDAR la nivel național;
- Realizarea unei analize amănunțite a tuturor metodelor de clasificare a norilor de puncte, punând accent pe ultimele realizări;
- Realizarea unei analize amănunțite a tuturor metodelor de segmentare semantică a imaginilor, punând accent de tehnici de Machine learning și pe rețele neuronale profunde;
- Implementarea metodei region growing pentru selectare dinamică a vecinătății, în vederea clasificării supervizate a norilor de puncte;
- Utilizarea software-ului *Weka* pentru clasificarea supervizată a norilor de puncte și analiza comparativă a algoritmilor de tip Machine learning
- Realizarea fluxului de trecere de la poligoanele segmentate în software-ul *OPALS* la amprentele clădirilor regularizate;
- Transferul valorilor înălțimilor clădirilor din nMDS folosind cele două abordări: pe baza punctelor centroid ale amprentelor la sol și pe baza unor puncte caracteristice aflate pe acoperiș, mult mai apropiate de muchiile inferioare ale acoperișului;
- Elaborarea unui flux de lucru de generare a modelelor 3D ale clădirilor utilizând doar date LiDAR;
- Generarea modelelor 3D ale tuturor clădirilor din Municipiul Arad.

8.3. Direcții viitoare de cercetare

Studiile realizate în această teză pot fi continuate; în acest sens, voi menționa câteva direcții viitoare de cercetare:

- Aplicarea fluxului de lucru propus pentru extragerea amprentelor și generarea modelelor 3D ale clădirilor, exclusiv din date LiDAR, pentru toată suprafața Municipiului Arad;
- Includerea de attribute elementelor tip clădiri în vederea generării, în CityEngine, a unor acoperișuri conforme cu realitatea din teren;
- Extragerea amprentelor clădirilor din true-ortofotoplanuri și analiza comparativă a rezultatelor cu amprente la sol rezultate din date LiDAR.

Bibliografie

- Aerial photography. (2017). În F. Ramon (Ed.), *Basic Photography in 180 Days* (pg. 107-123).
- Agarwal, R. (2018, September 22). *Object Detection: An End to End Theoretical Perspective*. Preluat pe March 23, 2021, de pe [towardsdatascience.com](https://towardsdatascience.com/object-detection-using-deep-learning-approaches-an-end-to-end-theoretical-perspective-4ca27eee8a9a): <https://towardsdatascience.com/object-detection-using-deep-learning-approaches-an-end-to-end-theoretical-perspective-4ca27eee8a9a>
- ANCPI. (2016). *Informații generale proiect*. Retrieved from <http://www.ancpi.ro/>: <http://www.ancpi.ro/laki2/>
- ANCPI. (2021). *Portal ANCPI*. Preluat pe May 28, 2021, de pe <https://geoportal.ancpi.ro/>: <https://geoportal.ancpi.ro/geoportal/imobile/Harta.html>
- ASPRS. (2019). *LAS Specification 1.4 - R14*. Bethesda, Maryland: The American Society for Photogrammetry & Remote Sensing.
- Ballard, D. H. (1991). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Recognition*, 13(2), 183-194.
- Biljecki, F., Ledoux, H., & Stoter, J. (2016). An improved LOD specification for 3D building models. *Computers, Environment and Urban Systems*. 59, pg. 25-37. Elsevier.
- Biljecki, F., Ledoux, H., Du, X., Stoter, J., Soon, K. H., & Khoo, V. H. (2016). THE MOST COMMON GEOMETRIC AND SEMANTIC ERRORS IN CITYGML DATASETS. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W1, 13-22. doi:10.5194/isprs-annals-IV-2-W1-13-2016
- BIMserver. (2021, March 16). Preluat pe April 30, 2021, de pe <https://github.com/>: <https://github.com/opensourceBIM/BIMserver#readme>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 5-32.
- Carter, J., Schmid, K., Waters, K., Betzhold, L., Hadley, B., Mataosky, R., & Halleran, J. (2012). *Lidar 101: An Introduction to Lidar Technology, Data, and Applications*. National Oceanic and Atmospheric Administration (NOAA) Coastal Services Center.
- Catmull, E. (1974). *A subdivision algorithm for computer display of curved surfaces*. Technical report, DTIC Document.
- Chakravarty, S. (2019, April 22). *Top 10 LiDAR Manufacturers in World*. Preluat de pe <https://www.marketresearchreports.com/>: https://www.marketresearchreports.com/blog/2019/04/22/top-10-lidar-manufacturers-world?fbclid=IwAR0jTBdNFGnkylFYFRlr54eRw19VbHt_XaEHZyVH0yUSTMBQPctPIBaYE8
- Chang, C. C., & Lin, C. J. (2011). LIBSVM: a library for support vector machines. *ACM Transactions on intelligent systems and technology*, 2(3).
- CNC. (2020a). *TOPRO5*. Preluat pe May 2021, de pe <https://cngcft.ro/>: <https://cngcft.ro/index.php/ro/portofoliu/lucrari-finalizate/topro5>
- Dorning, P., & Pfeifer, N. (2008). A Comprehensive Automated 3D Approach for Building Extraction, Reconstruction, and Regularization from Airborne Laser Scanning Point Clouds. *Sensors*, 7323-7343.
- Edelsbrunner, H., Kirkpatrick, D. G., & Seidel, R. (1983). On the Shape of a Set of Points in the Plane. *IEEE TRANSACTIONS ON INFORMATION THEORY*, IT-29(4), 551-559.
- ESRI. (2021). *ArcGIS Online*. Preluat pe May 30, 2021, de pe <https://www.esri.com/>: <https://www.esri.com/ro-ro/arcgis/products/arcgis-online/overview>

- Fernandez-Diaz, J. C., Carter, W. E., Shrestha, R. L., & Glennie, C. L. (2014). Now You See It... Now You Don't: Understanding Airborne Mapping LiDAR Collection and Data Product Generation for Archaeological Research in Mesoamerica. *Remote Sensing*, 6, 9951-10001. doi:10.3390/rs6109951
- Filin, S. (2002). SURFACE CLUSTERING FROM AIRBORNE LASER SCANNING DATA. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIV, 119-124.
- Filin, S., & Pfeifer, N. (2006). Segmentation of airborne laser scanning data using a slope adaptive neighborhood. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60(2), 71-80.
- Fischler, M. A., & Bolles, R. C. (1987). Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. (M. A. Fischler, & O. Firschein, Ed.) *Readings in Computer Vision*, 726-740. doi:10.1016/B978-0-08-051581-6.50070-2
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of computer and system sciences*, 55, 119-139.
- Girardeau-Montaut, D. (2019, December 4-5). CloudCompare. *Point Cloud Processing Workshop*. Stuttgart.
- Golovinskiy, A., & Funkhouser, T. (2009). Min-cut based segmentation of point clouds. *IEEE Workshop on Search in 3D and Video at ICCV*.
- Grilli, E., Menna, F., & Remondino, F. (2017). A REVIEW OF POINT CLOUDS SEGMENTATION AND CLASSIFICATION ALGORITHMS. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-2/W3*, 339-344.
- Grossfeld, B. (2021, April 7). *Deep learning vs machine learning: a simple way to learn the difference*. Preluat pe April 19, 2021, de pe [www.zendesk.com](https://www.zendesk.com/blog/machine-learning-and-deep-learning/): <https://www.zendesk.com/blog/machine-learning-and-deep-learning/>
- Haykin, S. (2008). *NEURAL NETWORKS AND LEARNING MACHINES*. New Jersey, United States of America: Pearson Education.
- Heidemann, H. K. (2018). Lidar Base Specification. *Collection and Delineation of Spatial Data*.
- Hough, P. (1962). METHOD AND MEANS FOR RECOGNIZING COMPLEX PATTERNS.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *IEEE Conference on Computer Vision and Pattern Recognition*, (pg. 2261-2269). Honolulu.
- Hug, C., Krzystek, P., & Fuchs, W. (2004). ADVANCED LIDAR DATA PROCESSING WITH LASTOOLS. *ISPRS*.
- John, G. H., & Langley, P. (1995). Estimating continuous distributions in Bayesian classifiers. *Proceedings of the conference on uncertainty in artificial intelligence*, 338-345.
- Jokela, J. (2016). *CityGML building model production from airborne laser scanning*. Master Thesis - Science in Technology, Aalto University, School of Engineering, Espoo.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). IMAGENET CLASSIFICATION WITH DEEP CONVOLUTIONAL NEURAL NETWORKS. *Advances in neural information processing systems*, 25(2). doi:10.1145/3065386
- Lin, M., Chen, Q., & Yan, S. (2014). NETWORK IN NETWORK. *ICLR 2013*. arXiv:1312.4400v3.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA, USA: IEEE.

- Lu, X., Yao, J., Tu, J., Li, K., Li, L., & Liu, Y. (2016). PAIRWISE LINKAGE FOR POINT CLOUD SEGMENTATION. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, III-3, 201-208.
- McCullough, W., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Morariu, I. D. (2007). *Contribuții la extragerea automată de cunoștințe din masive de date*. Teză de doctorat, Universitatea Lucian Blaga, Facultatea de Inginerie Hermann Oberth, Sibiu, România.
- Musäus, S. (2019). The SPL 100 in Europe. *EUROSDR Workshop on Single Photon and Geiger-Mode LiDAR*. Barcelona, Spain.
- Nguyen, A., & Le, B. (2013). 3D point cloud segmentation: A survey. *6th International Conference on Robotics, Automation and Mechatronics*, 225-230.
- Noh, H., Hong, S., & Han, B. (2015). LEARNING DECONVOLUTION NETWORK FOR SEMANTIC SEGMENTATION. *IEEE International Conference on Computer Vision*, 1520-1528.
- Ohbuchi, R., & Takei, T. (2003). Shape-Similarity Comparison of 3D Models. *Pacific Graphics*. Canmore, Canada.
- Pârvu, I. M., Cuibac Picu, I. A., Dragomir, P. I., & Pantan, R. (2021). Promoting Open Data services to decision-makers: Providing interactive data through Web Maps and Web Applications for Oradea city and Bihor county. *IOP Conference Series: Earth and Environmental Science*, 664. doi:10.1088/1755-1315/664/1/012073
- Pârvu, I. M., Cuibac Picu, I. A., Dragomir, P. I., & Poli, D. (2020). URBAN CLASSIFICATION FROM AERIAL AND SATELLITE IMAGES. *JOURNAL OF APPLIED ENGINEERING SCIENCES*, 10(23)(2/2020), 163-172.
- Pepe, M., Fregonese, L., & Scaioni, M. (2018). Planning airborne photogrammetry and remote-sensing missions with modern platforms and sensors. *European Journal of Remote Sensing*, 51(1), 412-436. doi:10.1080/22797254.2018.1444945
- Pfeifer, N., Mandlbürger, G., Otepka, J., & Karel, W. (2014). OPALS - A framework for Airborne Laser Scanning data analysis. *Computers, Environment and Urban Systems*, 45, 125 - 136.
- Phillips, D. K. (2015, May 13). *Speed of the Human Brain*. Preluat pe April 16, 2021, de pe <https://askabiologist.asu.edu/>: <https://askabiologist.asu.edu/plosable/speed-human-brain>
- Remondino, F., Toschi, I., Nex, F., & Gerke, M. (2018). *Oblique Aerial Camera Systems for Mapping Purposes*. e-learning course: EuroSDR.
- Residual Net*. (2020). Preluat pe April 10, 2021, de pe <https://leonardoaraujosantos.gitbook.io/>: https://leonardoaraujosantos.gitbook.io/artificial-intelligence/machine_learning/deep_learning/residual_net
- RIEGL. (2021, May 17). *RiProcess_Datasheet*. Preluat pe May 19, 2021, de pe [riegl.com](http://www.riegl.com/): http://www.riegl.com/uploads/tx_pxpriegl/downloads/RiProcess_Datasheet_2021-05-17.pdf
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI 2015*, 234-241. doi:10.1007/978-3-319-24574-4_28
- Rupnik, E., Nex, F., & Remondino, F. (2014). OBLIQUE MULTI-CAMERA SYSTEMS - ORIENTATION AND DENSE MATCHING ISSUES. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-3/W1, 107-114. doi:10.5194/isprsarchives-XL-3-W1-107-2014

- Rusu, R. B., & Cousins, S. (2011). 3D is here: Point Cloud Library (PCL). *IEEE International Conference on Robotics and Automation*, 1-4.
- SAFE. (2021). *FME Transformer Gallery*. Preluat pe April 30, 2021, de pe <https://www.safe.com/>: <https://www.safe.com/transformers/?datatype=BIM>
- Sampath, A., & Shan, J. (2010). Segmentation and reconstruction of polyhedral building roofs from aerial lidar point clouds. *IEEE Transactions on geoscience and remote sensing*, 48(3), 1554–1567.
- Sapkota, P. P. (2008). *Segmentation of coloured point cloud data*. Thesis for Master of Science, International Institute Geo-Information Science and Earth Observation, Enschede, Netherlands.
- Schnabel, R., Wahl, R., & Klein, R. (2006). Shape Detection in Point Clouds. *SIGGRAPH 2006*. Preluat de pe <https://cg.cs.uni-bonn.de/aigaion2root/attachments/cg-2006-2.pdf>
- SECOM. (2020, July 30). *IFCExplorer 1.0*. Preluat pe April 30, 2021, de pe <https://ifcexplorer.software.informer.com/>: <https://ifcexplorer.software.informer.com/>
- Shragai, Z., Barnea, S., & Even-Paz, A. (2012). Automatic Tie-point Extraction. *Gim International*.
- Sibson, R. (1973). SLINK: an optimally efficient algorithm for the single-link cluster method. *The Computer Journal*, 16(1), 30-34.
- SPAR 3D. (2016). *Answers, Not Data: A Year of Harris' Commercial Geiger-Mode LiDAR*. Preluat de pe [spar3d.com](https://www.spar3d.com/news/lidar/answers-not-data-a-year-of-harris-commercial-geiger-mode-lidar/): <https://www.spar3d.com/news/lidar/answers-not-data-a-year-of-harris-commercial-geiger-mode-lidar/>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9. doi:10.1109/CVPR.2015.7298594
- Terrasolid. (2021). *TerraScan*. Preluat pe May 17, 2021, de pe <https://terrasolid.com/>: <https://terrasolid.com/products/terrascan/>
- TU Delft. (2021, February 26). *The open-source tool for creation of 3D models*. Preluat pe May 9, 2021, de pe <http://tudelft3d.github.io/>: <http://tudelft3d.github.io/3dfier/>
- Ukrainitz, Y., & Sarel, B. (2014, November 20). *Segmentation and Clustering*. Preluat pe April 15, 2021, de pe <https://www.slideserve.com/>: <https://www.slideserve.com/hamilton-moore/cse-473-573-computer-vision-and-image-processing-cvip>
- Upadhyay, N. (2013). *Basics of Photogrammetry*. Preluat de pe <https://www.gisresources.com/>: https://www.gisresources.com/basic-of-photogrammetry_2/
- Vrejoiu, M. H. (2019). REȚELE NEURONALE CONVOLUȚIONALE, BIG DATA ȘI DEEP LEARNING ÎN ANALIZA AUTOMATĂ DE IMAGINI. *Romanian Journal of Information Technology and Automatic Control*, 29(1), 91-114.
- Waikato, U. o. (2021). *WEKA*. Preluat de pe www.cs.waikato.ac.nz: <https://www.cs.waikato.ac.nz/ml/weka/>
- Wehr, A. (2018). LIDAR Systems and Calibration. În J. Shan, & C. Toth, *Topographic Laser Ranging and Scanning: principles and processing* (pg. 159-200). CRC Press.
- Weinmann, M. (2013). Visual Features—From Early Concepts to Modern Computer Vision. În *Advanced Topics in Computer Vision* (pg. 1-34). London: Springer-Verlag.

- Weinmann, M. (2016). *Reconstruction and Analysis of 3D Scenes*. Springer International Publishing Switzerland.
- Weinmann, M. (2019). *An Introduction to Classification*. EuroSDR EduServ17.
- Weinmann, M., Jutzi, B., & Mallet, C. (2014). SEMANTIC 3D SCENE INTERPRETATION: A FRAMEWORK COMBINING OPTIMAL NEIGHBORHOOD SIZE SELECTION WITH RELEVANT FEATURES. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, II-3*, 181-188.
- Weinmann, M., Schmidt, A., Mallet, C., Hinz, S., Rottensteiner, F., & Jutzi, B. (2015). CONTEXTUAL CLASSIFICATION OF POINT CLOUD DATA BY EXPLOITING INDIVIDUAL 3D NEIGHBOURHOODS. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, II-3/W4*, 271-278. doi:10.5194/isprsannals-II-3-W4-271-2015
- Xie, Y., Tian, J., & Zhu, X. X. (2020). Linking Points With Labels in 3D: A Review of Point Cloud Semantic Segmentation. *IEEE GEOSCIENCE AND REMOTE SENSING MAGZINE*.
- Yadav, N., Yadav, A., & Kumar, M. (2015). *An Introduction to Neural Network Methods for Differential Equations*. Springer.
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., & Yan, G. (2016). An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sensing, 8*(6). doi:10.3390/rs8060501
- Zhu, X. X., & Shahzad, M. (2014). Facade reconstruction using multiview spaceborne tomosar point clouds. *IEEE Transactions on Geoscience and Remote Sensing, 52*(6), 3541–3552.

Listă de lucrări publicate

- Pârvu, I. M.,** Cuibac Picu, I. A., Dragomir, P. I. (2018). Pixel Based Classification of Images. *RevCAD* 25/2018, 83-90.
- Pârvu, I. M.,** Remondino, F., & Özdemir, E. (2018). LOD2 building generation experiences and comparisons. *JOURNAL OF APPLIED ENGINEERING SCIENCES*. doi:10.2478/jaes-2018-0019.
- Pârvu, I. M.,** Özdemir, E., & Remondino, F. (2020). Aerial point cloud classification using an alternative approach for the dynamic computation of k-Nearest Neighbors. *JOURNAL OF APPLIED ENGINEERING SCIENCES*, 10(23)(2/2020), 155-162.
- Pârvu, I. M.,** Cuibac Picu, I. A., Dragomir, P. I., & Poli, D. (2020). Urban classification from aerial and satellite images. *JOURNAL OF APPLIED ENGINEERING SCIENCES*, 10(23)(2/2020), 163-172.
- Pârvu, I. M.,** Cuibac Picu, I. C., Dragomir, P. I., & Pantan, R. (2021). Promoting Open Data services to decision-makers: Providing interactive data through Web Maps and Web Applications for Oradea city and Bihor county. *IOP CONFERENCE SERIES: EARTH AND ENVIRONMETAL SCIENCE*, 664. doi:10.1088/1755-1315/664/1/012073.