



REZUMAT TEZĂ DE DOCTORAT

CONTRIBUȚII LA REPREZENTAREA SPAȚIALĂ A IMOBILELOR



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

Studentă doctorand: Drd. ing. Anca Patricia Grădinaru

**București
2023**

Cuprins

1. Introducere	4
1.1. Motivație	4
1.2. Obiective și scop	4
1.3. Structura tezei de doctorat	4
2. Stadiul actual al cunoașterii	6
2.1. Modele 3D ale orașelor și conceptul de "Smart City"	6
2.2. Modelul informațional al construcției (BIM) și conceptul de "Digital Twin"	6
2.3. Utilizarea realității virtuale și realității augmentate în vizualizarea modelelor 3D ale orașelor	7
2.4. Date geospațiale open-source	7
2.5. Concluzii	8
3. Metode de achiziție a datelor geospațiale	9
3.1. Achiziția datelor spațiale prin scanare laser	9
3.1.1. Scanarea laser aeropurtată	9
3.1.2. Scanarea laser terestră	9
3.1.3. Scanarea laser mobilă	9
3.2. Achiziția datelor geospațiale prin aerofotografiere	10
3.2.1. Principiul fundamental al fotogrammetriei	10
3.2.2. Clasificarea imaginilor fotogrammetrice	10
3.2.3. Sisteme fotogrammetrice	10
3.3. Achiziția datelor geospațiale pentru obținerea modelului 3D al orașului	10
3.4. Concluzii	10
4. Tehnici de modelare spațială	12
4.1. Clasificarea norilor de puncte LiDAR prin metode automate de clasificare	12
4.2. Utilizarea inteligenței artificiale pentru clasificarea norilor de puncte LiDAR	13
4.3. Modelarea spațială 3D pe baza imaginilor ortorectificate	13
4.4. Modelarea spațială 3D pe baza imaginilor street-view	13
4.5. Concluzii	14
5. Studiul de caz	15
5.1. Clasificarea norului de puncte	15
5.1.1. Zona de studiu	15
5.1.2. Clasificarea norului de puncte prin metodele automate implementate în ArcGIS Pro	15
5.1.3. Clasificarea norului de puncte utilizând produsul software Bentley Microstation Terrascan	18

5.1.4. Extragerea datelor din norii de puncte utilizând rețelele neuronale convoluționale	19
5.1.5. Studiu comparativ și concluzii.....	23
5.2. Extragerea amprentelor la sol ale construcțiilor	26
5.2.1. Extragerea amprentelor la sol ale construcțiilor cu ajutorul algoritmului de Deep Learning implementat în ArcGIS Pro	26
5.2.2. Antrenarea unui model de Deep Learning în ArcGIS Pro pentru extragerea amprentelor la sol ale construcțiilor folosind imaginile fotogrammetrice	27
5.2.3. Extragerea amprentelor la sol ale construcțiilor din norul de puncte LiDAR ...	31
5.2.4. Studiu comparativ și concluzii.....	32
5.3. Obținerea modelelor 3D ale construcțiilor.....	35
5.3.1. Modelarea 3D a construcțiilor în ArcGIS Pro	35
5.3.2. Modelarea 3D a construcțiilor în CityEngine	37
5.3.3. Obținerea modelului 3D al orașului pe baza datelor open-source.....	41
5.3.4. Vizualizarea modelelor 3D ale orașelor	42
5.3.5. Aplicație VR și AR pentru vizualizarea modelelor 3D ale orașelor	42
5.4. Concluzii	45
6. Concluzii generale, contribuții originale și perspective	47
6.1. Concluzii generale	47
6.2. Contribuții originale	50
6.3. Perspective	51
Referințe bibliografice	52

1. Introducere

Problemele actuale cu care se confruntă societatea, aflată în continuă schimbare, necesită soluții rapide și eficiente. Extinderea aglomerărilor urbane este o problemă bine cunoscută (Wei et al., 2023), iar creșterea rapidă a populației are un impact puternic asupra mediului înconjurător ("Population growth"). Toate acestea au dus la necesitatea de a dezvolta metode mai bune de gestionare a resurselor și a situațiilor de urgență în zonele urbane. Astfel de metode pot fi dezvoltate pe baza unor modele 3D ale orașelor, generate cu ajutorul unor date geospațiale de calitate.

Cercetările recente indică faptul că inteligența artificială simplifică procesul de extragere a datelor geospațiale necesare modelării 3D, fie pe baza norilor de puncte, fie pe baza imaginilor fotogrammetrice. De asemenea, realitatea virtuală poate fi un cadru eficient de vizualizare și gestionare a modelelor obținute.

1.1. Motivație

Analizând literatura de specialitate, am constatat că deși există numeroase articole ce abordează subiectul modelării spațiale 3D, acestea nu propun un flux de lucru complet, care să analizeze datele din perspectiva specificului zonei și care să includă și un mod eficient de distribuire și vizualizare a acestor modele. Realitatea virtuală și realitatea augmentată sunt tehnologii aflate în plină evoluție și pot oferi noi perspective în gestionarea problemelor actuale cu care se confruntă societatea.

1.2. Obiective și scop

Scopul tezei de doctorat este obținerea modelelor 3D ale construcțiilor printr-un flux de lucru optim, dar și distribuirea și vizualizarea acestor modele, pentru a crește eficiența utilizării lor. Astfel, în cadrul tezei de doctorat vor fi analizate la nivel teoretic diferite tehnologii de achiziție a datelor geospațiale și vor fi testate diferite tehnici de modelare spațială 3D, zona de studiu fiind Municipiul Baia Mare.

Obiectivele tezei de doctorat sunt analiza și compararea unor metode de clasificare a norilor de puncte, analiza și compararea unor metode de extragere a amprentelor la sol ale construcțiilor pe baza imaginilor ortorectificate, și studiul posibilităților de generare, distribuire și vizualizare a modelelor 3D ale construcțiilor. În urma comparațiilor realizate, se va propune un flux de lucru optim pentru scopul propus. Un astfel de flux de lucru va putea fi implementat mai departe de către autorități, sau de către alte persoane interesate.

1.3. Structura tezei de doctorat

Teza de doctorat este structurată în șase capitole.

În **Capitolul 1 – Introducere** sunt prezentate importanța subiectului, motivația realizării tezei de doctorat, obiectivele și scopul tezei și structura lucrării.

Capitolul 2 – Stadiul actual al cunoașterii cuprinde exemple de modele 3D ale orașelor, informații despre standardizarea modelelor 3D, în special standardele CityGML. Sunt abordate subiecte precum conceptele de Smart City, BIM (Building Information Model – Modelul informațional al construcției) și Digital Twin și este evidențiată importanța utilizării realității virtuale și realității augmentate în vizualizarea modelelor 3D ale orașelor. În plus este analizată și posibilitatea de utilizare a datelor geospațiale open-source în modelarea 3D.

Capitolul 3 – Metode de achiziție a datelor geospațiale cuprinde analiza metodelor de achiziție a datelor geospațiale prin scanare laser aeropurtată, terestră și mobilă, prezintă exemple de sisteme de scanare laser și fluxul de lucru în scanarea laser. De asemenea, sunt prezentate și metode de achiziție a datelor geospațiale prin aerofotografiere, tipuri de sisteme fotogrammetrice, exemple de camere fotogrammetrice, dar și fluxul de lucru în preluarea imaginilor fotogrammetrice. La finalul capitolului, sunt prezentate instrumentele cu care au fost achiziționate datele geospațiale utilizate în cadrul tezei de doctorat.

În **Capitolul 4 – Tehnici de modelare spațială** sunt prezentate diferite metode de clasificare a norilor de puncte LiDAR (Light Detection and Ranging) și de extragere a amprentelor la sol ale construcțiilor pe baza imaginilor fotogrammetrice, punându-se accent pe utilizarea rețelelor neuronale convoluționale. Este menționată și modelarea spațială 3D pe baza imaginilor Street-View.

Capitolul 5 – Studiul de caz cuprinde clasificarea norului de puncte, extragerea amprentelor la sol ale construcțiilor, obținerea modelelor 3D și publicarea și vizualizarea modelelor 3D ale orașelor. Pentru clasificarea norului de puncte, au fost folosite produsele software ArcGIS Pro și Bentley Microstation Terrascan, dar și un model de DL (Deep Learning) antrenat pentru zona respectivă, la final realizându-se comparația între rezultatele obținute. Ampretele la sol ale construcțiilor au fost extrase prin trei metode: utilizând un model de DL din ArcGIS Online, utilizând un model de DL antrenat specific pentru zona de studiu și din norul de puncte LiDAR, iar la final au fost comparate între ele rezultatele obținute. A fost realizată și o comparație cu amprenta la sol a unei construcții exportate din eTerra. Obținerea modelelor 3D ale construcțiilor a fost realizată în ArcGIS Pro și în CityEngine. Modelarea în CityEngine a presupus și modelarea avansată a fațadelor construcțiilor, folosind limbajul de programare CGA (Computer Generated Architecture). De asemenea, a fost prezentată și o metodă de generare a modelului 3D al orașului pe baza datelor open-source. La finalul capitolului au fost prezentate și analizate metode de distribuire și vizualizare a modelelor 3D obținute, prin intermediul ArcGIS Online și a unei aplicații de vizualizare într-un mediu VR (Virtual Reality – Realitate virtuală).

Capitolul 6 – Concluzii generale, contribuții originale și perspective cuprinde evidențierea contribuțiilor originale din teza de doctorat, concluziile generale cu privire la rezultatele obținute și perspectivele de continuare a cercetării în viitor.

2. Stadiul actual al cunoașterii

2.1. Modele 3D ale orașelor și conceptul de "Smart City"

Un model 3D al orașului este o reprezentare geometrică tridimensională a obiectelor și structurilor urbane, în special a clădirilor, care poate fi folosită în numeroase aplicații, precum analize de vizibilitate, estimarea necesarului energetic, estimarea umbrelor, gestionarea rețelilor de utilități, estimarea potențialului energetic, cadastru 3D, planificarea infrastructurii, propagarea sunetelor (Biljecki et al., 2015), răspunsul la situațiile de urgență (Grădinaru et al., 2022b), etc. Un model 3D semantic al orașului este un model care integrează atributele obiectelor, precum și diferite relații dintre acestea. Îmbunătățirea semantică a modelelor 3D ale orașelor este un proces care presupune adăugarea de noi informații unui model existent, pentru a-l conecta mai bine la realitatea înconjurătoare (Billen et al., 2014).

Standardizarea modelelor 3D ale orașelor permite schimbul de date și interoperabilitatea între acestea. Standardele CityGML, care definesc un model conceptual pentru reprezentarea modelelor 3D ale orașelor, sunt folosite pentru a descrie complexitatea geometriilor construcțiilor (Biljecki et al., 2014) sau apropierea dintre un model 3D al unui obiect și obiectul în sine (Tang et al., 2020).

Câteva exemple de modele 3D ale orașelor pot fi 3D BAG ("3D BAG Viewer"), un set de date ce conține modelele 3D ale clădirilor din Țările de Jos, modelele 3D ale orașului Helsinki ("Helsinki 3D", 2023), sau modelul orașului Boston ("About 3D | Boston Planning & Development Agency").

Conceptul de "Smart City" a apărut ca o soluție pentru sustenabilitatea urbană (Cai et al., 2023). Creșterea rapidă a populației și migrația acesteia din zonele rurale în zonele urbane au condus la creșterea consumului de resurse, a necesarului de spațiu și a gradului de poluare și în acest context, tehnologiile informației și comunicațiilor integrate într-o infrastructură accesibilă cu resurse regenerabile disponibile, menite să limiteze consumul, pot permite sustenabilitatea și înglobează conceptul de "Smart City" (Liu et al., 2022). Datele geospațiale sprijină conceptul de oraș inteligent, oferind informații despre locație, vecinătăți, obiecte, rețele și acuratețe (Guler and Yomralioglu, 2022).

2.2. Modelul informațional al construcției (BIM) și conceptul de "Digital Twin"

Modelul informațional al construcției este o reprezentare digitală a caracteristicilor fizice și funcționale ale unei construcții (National Institute of Building Sciences buildingSMART alliance, 2015), fiind util în situații precum monitorizarea structurilor construcțiilor (Xu et al., 2023a) sau planificarea pentru evacuările în caz de urgență (Xu et al., 2023b).

Conceptul de "Digital Twin" (DT) reprezintă o simulare probabilistică, ce redă cu fidelitate starea corespondentului din realitate, utilizând atât date primite în timp real,

cât și date istorice referitoare la construcție (Schrotter and Hürzeler, 2020). Diferența dintre BIM și DT este aceea că în timp ce BIM furnizează date statice, DT utilizează senzori și date în timp real (Attaran and Celik, 2023).

2.3. Utilizarea realității virtuale și realității augmentate în vizualizarea modelelor 3D ale orașelor

Cecotti (2022) definește realitatea virtuală ca fiind o experiență simulată. Conform Li et al. (2022), realitatea virtuală este o interfață bazată pe imersiune, interacțiune și imaginație, iar aplicarea acestei tehnologii în mediul urban poate contribui la gestionarea modelării 3D a orașului și la planificarea virtuală a anumitor proiecte.

Wang et al. (2018) propun o platformă de analiză GIS în VR, care servește la analizele spațiale și la vizualizarea modelelor 3D și au concluzionat că platforma de vizualizare și analiză a modelului 3D este un instrument util atât pentru agențiile de servicii sociale, cât și pentru cetățeni, fiind folosită în explorarea și analizarea în mod direct a datelor legate de oraș.

În timp ce VR presupune un mediu complet virtual și necesită ochelari speciali pentru vizualizare, realitatea augmentată (AR – Augmented Reality) integrează lumea reală și reprezentările virtuale și poate fi accesată fără ochelari speciali, prin intermediul unui ecran (“What’s the Difference Between AR and VR?” 2020).

2.4. Date geospațiale open-source

Într-un studiu realizat de Badea & Badea (2022), este subliniată utilitatea datelor geospațiale deschise, sunt analizate caracteristicile acestora și este realizată o corelație cu standardele existente în domeniu. Se pot evidenția în acest sens inițiative precum OSM (Open Street Map), Wikimapia, surse de date și instrumente precum cele puse la dispoziție de NASA (National Aeronautics and Space Administration), Earth Observation, Copernicus Land Monitoring Service, Sentinel, dar și datele oferite de directiva INSPIRE.

Luând în considerare situația din România, se pot menționa mai multe surse de date geospațiale. ANCPI (Agenția Națională de Cadastru și Publicitate Imobiliară) pune la dispoziție, printr-un geoportal, situația imobilelor înregistrate în cartea funciară existente în prezent, precum și clădirile existente pe terenurile în cauză (“Imobile eTerra - Public”). Planul TopRO50, conținând amprente la sol ale construcțiilor vectorizate, este pus la dispoziție de ANCPI și poate fi descărcat. Alte date puse la dispoziție de ANCPI prin intermediul geoportalului sunt: foi de hartă la scara 1:50 000 sau date din proiectul LAKI II (Land Administration Knowledge Improvement). OSM (Open Street Map) este o reprezentare digitală a întregii lumi construită de voluntari (“About OpenStreetMap - OpenStreetMap Wiki”) și conține date deschise obținute din măsurători, imagini fotogrammetrice sau date guvernamentale.

2.5. Concluzii

În cadrul acestui capitol a fost analizat stadiul actual al cunoașterii în ceea ce privește modelele 3D ale orașelor și conceptul de "Smart City", modelul informațional al construcției (BIM) și conceptul de "Digital Twin", utilizarea realității virtuale și realității augmentate în vizualizarea modelelor 3D ale orașelor și datele geospațiale open-source ce pot sta la baza modelării spațiale 3D a imobilelor.

Modelele 3D ale orașelor și-au dovedit utilitatea în numeroase domenii, iar standardele CityGML contribuie la creșterea interoperabilității între diferite modele. Astfel, au fost definite diferite standarde, precum standardele CityGML, care evidențiază cinci niveluri de detaliere. Standardizarea modelelor permite schimbul de date între acestea, contribuind la creșterea eficienței procesului de modelare spațială.

Tehnica de achiziție a datelor și gradul de detaliere al modelelor se aleg în funcție de domeniul de utilizare al modelului obținut.

Conceptul de Smart City a condus la creșterea sustenabilității în mediile urbane și la o gestionare mai bună a resurselor. Zonele urbane aflate în continuă schimbare necesită un mediu virtual ce permite analiza diferitelor scenarii în ceea ce privește consumul de resurse, necesarul de spațiu sau gradul de poluare. Un astfel de mediu oferă și posibilități de planificare și de creare a unui mediu urban confortabil și sustenabil.

Au fost exemplificate modele 3D ale orașelor precum 3D BAG, Helsinki 3D, modelul 3D al orașului Boston sau modelul 3D Virtual Singapore, care adoptă și conceptul de oraș inteligent. Astfel, se poate concluziona că modelele 3D ale orașelor pot arăta evoluția acestora de-a lungul unor perioade de timp și pot sta la baza diferitelor analize legate de energie, consumul de apă, încălzire, electricitate sau calcule ale potențialului de energie solară.

Conceptele de BIM și DT utilizează atât date în timp real, cât și date istorice referitoare la construcții, iar aducerea acestora într-un mediu GIS ar contribui la eficientizarea întregului proces de modelare spațială 3D.

Realitatea virtuală și realitatea augmentată vin în sprijinul modelării 3D și contribuie atât la îmbunătățirea modului de vizualizare a modelelor 3D, cât și la utilizarea acestora, prin planificarea virtuală a anumitor proiecte. În plus, un model 3D virtual al orașului este mai ușor de vizualizat și înțeles și de către publicul larg și nespecialist. Astfel, putem concluziona că realitatea virtuală și realitatea augmentată pot contribui semnificativ la creșterea eficienței implementării proiectelor care vizează mai multe domenii de aplicabilitate.

La baza realizării modelelor 3D ale orașelor pot sta și date geospațiale open-source. Respectarea standardelor existente în domeniu este foarte importantă pentru ca aceste date să poată fi folosite într-un mod eficient. Au fost evidențiate date precum cele provenit din OSM, date puse la dispoziție de NASA, Earth Observation, Copernicus Land Monitoring Service, Sentinel, date oferite de directiva INSPIRE, dar și date puse la dispoziție de către ANCPI.

3. Metode de achiziție a datelor geospațiale

Un prim pas spre obținerea modelelor 3D este reprezentat de achiziția datelor geospațiale. Scanarea laser și fotogrammetria reprezintă două tehnologii principale de achiziție a datelor geospațiale de înaltă calitate (Figura 3.1).




Figura 3.1. Exemple de date geospațiale achiziționate pentru reprezentarea spațială a imobilelor (a.reprezentare 3D - captură realizată în programul ArcGIS Pro, date preluate din Portalul ArcGIS Online, b.nor de puncte LiDAR - captură realizată în programul ArcGIS Pro, c.imagini preluate cu ajutorul camerei fotogrammetrice, în cadrul firmei S.C. Cornel&Cornel Topoexim S.R.L.)

3.1. Achiziția datelor spațiale prin scanare laser

3.1.1. Scanarea laser aeropurtată



Figura 3.2. Nor de puncte obținut prin scanare laser aeropurtată

3.1.2. Scanarea laser terestră

3.1.3. Scanarea laser mobilă

3.2. Achiziția datelor geospațiale prin aerofotografieri

3.2.1. Principiul fundamental al fotogrammetriei

3.2.2. Clasificarea imaginilor fotogrammetrice

3.2.3. Sisteme fotogrammetrice

- Camerele fotogrammetrice nadirale
- Camerele fotogrammetrice oblice

3.3. Achiziția datelor geospațiale pentru obținerea modelului 3D al orașului




Figura 3.3. Planul de zbor

Zona de studiu aleasă este în Municipiul Baia Mare, iar datele geospațiale au fost achiziționate pe parcursul a două zboruri (Figura 3.3), primul cu o durată de 3h49m, iar cel de-al doilea cu o durată de 2h45m.

Pentru achiziția datelor geospațiale, a fost folosit un sistem compus dintr-un scanner laser RIEGL VQ-780ii-S, două camere fotogrammetrice Phase One - P1-iXM-RS150F și P1-iXM-RS100F și un sistem de navigație GNSS/INS AEROcontrol-II, montate la bordul unei drone Tecnam P2006T.

3.4. Concluzii

Un prim pas spre obținerea modelelor 3D este reprezentat de achiziția datelor geospațiale. Calitatea și actualitatea datelor geospațiale sunt un factor important în modelarea digitală 3D cu acuratețe.

O metodă de achiziție a datelor geospațiale este scanarea laser, care poate fi aeropurtată, terestră sau mobilă. În capitolul de față au fost prezentate principalele componente ale sistemelor de scanare și mecanismul de funcționare al unui scaner laser. În plus față de sistemul de scanare, este esențial ca la sol să se regăsească o stație GNSS de referință pentru poziționarea diferențială.

Pentru scanarea laser aeropurtată, au fost evidențiate exemplele de sisteme moderne de scanare Leica CityMapper-2 și Scannerul laser RIEGL VQ-780ii-S.

Fluxul de lucru în scanarea laser aeropurtată constă în planificarea zborului de studiu, zborul de studiu și prelucrarea datelor. În ceea ce privește prelucrarea datelor, clasificarea automată a norului de puncte reprezintă principala provocare, datorită structurilor complexe ale obiectelor. Ultimele cercetări în domeniu se bazează pe algoritmi de machine learning precum SVM, Adaboost, Random Forest, Markov Random Field sau CRF (Conditional Random Field). Cea din urmă s-a dovedit a fi mai eficientă, deoarece rezolvă problema informației contextuale. În plus, în cercetările recente se discută despre utilizarea rețelelor neuronale convoluționale în clasificarea norului de puncte, bazate pe modele avansate de DL.

Scanarea laser terestră permite obținerea unor nori de puncte cu o densitate mai ridicată decât cei obținuți din scanarea laser aeropurtată. Au fost prezentate diferite scanere laser terestre, precum Leica ScanStation P50 și Trimble TX8, dar și fluxul de lucru în scanarea laser terestră.

Scanerele laser mobile integrează tehnologii de navigație, fără a avea nevoie de alte informații, precum cele preluate de stațiile de control de la sol. Posibilitățile de scanare laser mobilă implică metoda de observație *"stop-and-go"*, în care scanările sunt efectuate în modul static, vehiculul modificându-și poziția după fiecare scanare și metoda de observație *"on-the-fly"*, în care vehiculul se deplasează de-a lungul unei traiectorii fără a se opri, iar scanerul laser scanează continuu. Se poate concluziona că metoda *"on-the-fly"* se pretează proiectelor cu un termen de execuție redus, deoarece prezintă avantajul unui timp de scanare mai scurt, însă fiecare punct preluat se raportează la un sistem de coordonate individual, spre deosebire de metoda de observație *"stop-and-go"*, unde fiecare nor de puncte este definit în sistemul local de coordonate al scanerului.

O altă tehnică de achiziție a datelor geospațiale este aerofotografierea. În capitolul de față au fost prezentate clasificări ale imaginilor fotogrammetrice și diferite tipuri de sisteme fotogrammetrice, care pot fi nadirale (de exemplu Vexcel UltraCam Eagle Mark 3 sau Leica DMC II) sau oblice (de exemplu Vexcel UltraCam Osprey, Leica RCD30 Oblique, IGI Quattro DigiCAM Oblique). Au fost prezentate principalele etape în preluarea imaginilor fotogrammetrice și a fost subliniată importanța punctelor de control la sol, ușor de identificat și determinate prin măsurători GNSS. Caracteristicile imaginilor digitale joacă un rol important în obținerea unor date geospațiale de calitate pe baza imaginilor ortorectificate. Se poate concluziona că în special o rezoluție spațială ridicată a imaginii conduce la obținerea unor date geospațiale cu acuratețe ridicată.

4. Tehnici de modelare spațială

4.1. Clasificarea norilor de puncte LiDAR prin metode automate de clasificare

Pentru obținerea unui model 3D al orașului pe baza datelor LiDAR, este necesar ca norul de puncte să fie clasificat corespunzător. Există numeroase produse software care permit acest lucru. Unul dintre acestea este ArcGIS Pro, care folosește modelul de clasificare definit de Societatea americană pentru fotogrammetrie și teledetecție (ASPRS – American Society for Photogrammetry and Remote Sensing), ce este structurat conform Tabelului 4.1 (“Change LAS Class Codes (3D Analyst)– ArcGIS Pro | Documentation”).

Tabel 4-1. Clase de puncte utilizate în ArcGIS Pro

Cod clasificare	Tip clasificare
0	Neclasificat
1	Fără clasă atribuită
2	Sol
3	Vegetație joasă
4	Vegetație medie
5	Vegetație înaltă
6	Construcție
7	Zgomot jos
8	Cheie model / Rezervat
9	Apă
10	Șină
11	Suprafață drum
12	Suprapuneri / Rezervat
13	Rețele (Wire – Guard)
14	Rețele (Wire – Conductor)
15	Turn de transmisie
16	Rețele (Wire – Connector)
17	Pod
18	Zgomot înalt
19-63	Rezervat pentru definiții ASPRS
32-255	Rezervat pentru definiții ale utilizatorului

4.2. Utilizarea inteligenței artificiale pentru clasificarea norilor de puncte LiDAR

Inteligența artificială (AI – Artificial Intelligence) este tehnologia care folosește un computer pentru a simula inteligența umană și antrenează computerul pentru a învăța în continuare comportamente umane, în vederea luării de decizii (Zhang & Lu, 2021).

Rețelele neuronale sunt un concept al inteligenței artificiale, inspirate de creierul uman, care reproduc modul în care neuronii umani transmit semnale unul altuia. Acestea sunt compuse din straturi de noduri: un strat de intrare, unul sau mai multe straturi ascunse și un strat de ieșire. Rețelele neuronale convoluționale se diferențiază de alte rețele neuronale prin superioritatea acestora în ceea ce privește datele de intrare de tip imagine, vorbire sau semnal audio și prin cele trei straturi principale: stratul convoluțional, stratul de grupare și stratul complet conectat. Există diferite tipuri de arhitecturi de rețele neuronale convoluționale, precum AlexNET, VGGNet, GoogLeNet, ResNet, ZFNet (“What are Convolutional Neural Networks?”).

4.3. Modelarea spațială 3D pe baza imaginilor ortorectificate

Procesul de clasificare a imaginilor presupune aplicarea unor reguli specifice, concepute pe baza unor caracteristici spectrale sau texturale ale imaginii, pentru atribuirea etichetelor unor grupuri de pixeli sau vectori din imaginea respectivă. Clasificarea poate fi supervizată, prin selectarea manuală a datelor de antrenare și repartizarea acestora în clasa corespunzătoare, sau nesupervizată, care utilizează algoritmi specifici pentru clasificarea complet automată a imaginii (Jog and Dixit, 2016).

Generarea amprentelor la sol ale construcțiilor poate fi realizată prin antrenarea unui model de DL bazat pe o arhitectură de tip MaskRCNN (“Automate Building Footprint Extraction using Deep learning”), dezvoltată din necesitatea îmbunătățirii tehnicilor de detectare a obiectelor din imagini. Pentru obținerea unor forme ale amprentelor la sol ale construcțiilor cât mai regulate, există posibilitatea de geoprocesare care permite folosirea unui algoritm de compresie a poliliniilor pentru a corecta distorsiunile acestora (“Regularize Building Footprint (3D Analyst)—ArcGIS Pro | Documentation”).

4.4. Modelarea spațială 3D pe baza imaginilor street-view

O altă sursă de date pentru modelarea spațială 3D a orașelor pot fi imaginile street-view. Biljecki & Ito, 2021 au realizat un studiu în ceea ce privește utilizarea imaginilor street-view în analizele urbane și GIS și au concluzionat că majoritatea modelelor existente se bazează în special pe Google Street View, însă orientarea altor companii către realizarea produselor de tip street-view poate deschide noi orizonturi

și îmbunătăți datele, incluzând o acoperire mai mare și imagini din interiorul construcțiilor.

4.5. Concluzii

În capitolul de față au fost analizate diferite tehnici de modelare spațială. Prelucrarea datelor presupune clasificarea norului de puncte LiDAR și extragerea elementelor geometrice din imaginile ortorectificate, în vederea obținerii modelelor 3D ale construcțiilor.

Cercetările recente au condus la demonstrarea eficienței implicării AI în clasificarea norului de puncte LiDAR. Utilizarea unei rețele neuronale convoluționale PointCNN presupune pregătirea unui fișier de date de antrenare și a unui fișier de date de validare. Cu cât aceste fișiere prezintă un volum mai mare de date, cu atât acuratețea modelului de clasificare antrenat va crește.

De asemenea, amprentele la sol ale construcțiilor pot fi extrase din imaginile fotogrammetrice. Clasificarea imaginilor poate fi supervizată, prin selectarea manuală a datelor și repartizarea acestora în clasa corespunzătoare, sau nesupervizată, care utilizează algoritmi specifici pentru clasificarea complet automată a imaginii. Antrenarea unui model de DL se poate baza pe o arhitectură de tip MaskRCNN, folosită pentru detectarea obiectelor din imagine. Astfel, datele de antrenare presupun un fișier cu amprentele la sol ale construcțiilor determinate anterior. Prin antrenarea unui astfel de model pentru o zonă specifică se pot obține amprente la sol ale construcțiilor cu o acuratețe mai ridicată față de utilizarea unui model existent, antrenat pentru un alt tip de zonă. Cu cât fișierul de antrenare conține un volum mai mare de date, cu atât acuratețea modelului obținut va crește.

O altă sursă de date pentru modelarea spațială 3D a orașelor pot fi imaginile street-view, prin antrenarea unor modele specifice de DL, însă, datorită naturii imaginilor de acest tip, acuratețea este una mai redusă față de modelele prezentate anterior.

În concluzie, am propus fluxul de lucru din Figura 4.1 pentru obținerea modelului 3D al unui oraș, iar în cadrul studiului de caz vor fi analizate și comparate diferite metode de lucru.




Figura 4.1. Flux de lucru pentru obținerea modelelor 3D ale orașelor

5. Studiul de caz

5.1. Clasificarea norului de puncte

5.1.1. Zona de studiu

Zona de studiu aleasă este în Municipiul Baia Mare (Figura 5.1).



Figura 5.1. Zona de studiu

5.1.2. Clasificarea norului de puncte prin metodele automate implementate în ArcGIS Pro

Fișierul în format *.LAS (LASer) ales pentru clasificare conține un număr de 44,913,903 puncte. Au fost clasificate punctele ce aparțin claselor sol, construcții și vegetație joasă, medie și înaltă. Rezultatele clasificării se regăsesc în Figurile 5.2, 5.3 și 5.4.




Figura 5.2. Norul de puncte clasificat

Item	Category	Pt_Cnt	Percent	Z_Min	Z_Max
1_Unclassified	ClassCodes	32197	0.07	205.83	248.08
2_Ground	ClassCodes	7735046	17.22	201.08	222.9
3_Low_Vegetation	ClassCodes	11271865	25.1	201.17	227.26
4_Medium_Vegetation	ClassCodes	9548292	21.26	207.38	243.22
5_High_Vegetation	ClassCodes	81217	0.18	232.09	264.41
6_Building	ClassCodes	10161344	22.62	202.55	258.91
7_Low_Point(noise)	ClassCodes	6083682	13.55	193.85	222.66
14_Reserved	ClassCodes	43	0	216.73	222.42
18_Reserved	ClassCodes	217	0	202.03	274.55

Figura 5.3. Rezultatele clasificării norului de puncte cu produsul software ArcGIS Pro




Figura 5.4. Grafic cu rezultatul clasificării norului de puncte

În cadrul acestei metode, unele puncte au fost clasificate eronat. Principala eroare în clasificare a fost clasificarea unor elemente ale construcțiilor ca puncte de vegetație (Figura 5.5). Aceste erori necesită intervenție manuală.




Figura 5.5. Erori de clasificare cu produsul software ArcGIS Pro

Pentru un volum mai mare de date, am propus utilizarea ArcGIS Pro ModelBuilder. Astfel, am creat modelul din Figura 5.6., care urmează pașii de

clasificare a norului de puncte prezentați anterior ("Use ModelBuilder—ArcGIS Pro | Documentation").




Figura 5.6. Model de clasificare a norului de puncte în ArcGIS Pro ModelBuilder

O altă variantă de automatizare a procesului de clasificare a norului de puncte în ArcGIS Pro este utilizarea ArcGIS API (Application Programming Interface) for Python, un limbaj de programare utilizat pentru vizualizarea și analiza datelor într-un mediu GIS ("Overview of the ArcGIS API for Python"), prin utilizarea următoarei secvențe de cod:

```
import arcpy
```

```
def Model_Lidar_PC_Classification(): # Model_Lidar_PC_Classification
```

```
    # To allow overwriting outputs change overwriteOutput option to True.
    arcpy.env.overwriteOutput = False
```

```
    # Check out any necessary licenses.
    arcpy.CheckOutExtension("3D")
```

```
    DOC_15_las = "DOC_15.las"
```

```
    # Process: Classify LAS Ground (Classify LAS Ground) (3d)
    DOC_15_las_2_ = arcpy.ddd.ClassifyLasGround(in_las_dataset=DOC_15_las,
method="CONSERVATIVE", reuse_ground="RECLASSIFY_GROUND", dem_resolution="",
compute_stats="COMPUTE_STATS", extent="23.5528862297105 47.6563134028331
23.5716906627965 47.6633591935169", boundary="", process_entire_files="PROCESS_EXTENT",
update_pyramid="UPDATE_PYRAMID")[0]
```

```
    # Process: Classify LAS Building (Classify LAS Building) (3d)
    DOC_15_las_3_ = arcpy.ddd.ClassifyLasBuilding(in_las_dataset=DOC_15_las_2_, min_height="2
Meters", min_area="6 SquareMeters", compute_stats="COMPUTE_STATS",
extent="23.5528862297105 47.6563134028331 23.5716906627965 47.6633591935169",
boundary="", process_entire_files="PROCESS_EXTENT", point_spacing="",
```



```
reuse_building="RECLASSIFY_BUILDING",
photogrammetric_data="NOT_PHOTOGRAMMETRIC_DATA", method="STANDARD",
classify_above_roof="NO_CLASSIFY_ABOVE_ROOF", above_roof_height="1.5 Meters",
above_roof_code=6, classify_below_roof="CLASSIFY_BELOW_ROOF", below_roof_code=6,
update_pyramid="UPDATE_PYRAMID")][0]
```

```
# Process: Classify LAS By Height (Classify LAS By Height) (3d)
DOC_15_las_4 = arcpy.ddd.ClassifyLasByHeight(in_las_dataset=DOC_15_las_3,
ground_source="GROUND", height_classification=[[3, 5], [4, 25], [5, 50]], noise="ALL_NOISE",
compute_stats="COMPUTE_STATS", extent="23.5528862297105 47.6563134028331
23.5716906627965 47.6633591935169", process_entire_files="PROCESS_EXTENT", boundary="",
update_pyramid="UPDATE_PYRAMID")][0]
```

```
if __name__ == '__main__':
    # Global Environment settings
    with
arcpy.EnvManager(scratchWorkspace=r"D:\Doctorat\3_An_III\5_Teza\4_1_Clasificarea_norului_de_p
uncte\ArcGIS\I\2\I2\model_builder\MyProject74\MyProject74.gdb",
workspace=r"D:\Doctorat\3_An_III\5_Teza\4_1_Clasificarea_norului_de_puncte\ArcGIS\I\2\I2\model
_builder\MyProject74\MyProject74.gdb"):
    Model_Lidar_PC_Classification()
```

5.1.3. Clasificarea norului de puncte utilizând produsul software Bentley Microstation Terrascan

Cu produsul software Bentley Microstation Terrascan au fost clasificate punctele ce aparțin claselor sol, construcții, vegetație joasă, vegetație medie și vegetație înaltă. Rezultatele clasificării se regăsesc în Figurile 5.7, 5.8 și 5.9.




Figura 5.7. Norul de puncte clasificat cu ajutorul produsului software Bentley Microstation Terrascan

All points		44 913 903	193.85	274.55
Active points		44 913 903		
Neighbour points		0		
Class	Description	Count	Min Z	Max Z
1	Default	4 877 731	201.15	261.70
2	Ground	8 537 934	201.02	222.73
3	Low vegetation	11 773 888	201.16	227.29
4	Medium vegetation	10 034 580	207.38	243.07
5	High vegetation	96 482	231.36	264.41
6	Building	9 591 490	201.61	260.12
7	Low point	1 556	193.85	222.13
8	Model keypoints	0	-	-
14	Class 14	43	216.73	222.42
18	Class 18	199	202.03	274.55

Figura 5.8. Rezultatul clasificării norului de puncte cu ajutorul produsului software Bentley Microstation Terrascan

Nor de puncte clasificat în Bentley Microstation Terrascan




Figura 5.9. Grafic cu rezultatul clasificării norului de puncte

În ceea ce privește erorile de clasificare, cea mai întâlnită eroare a fost clasificarea pereților ca elemente de vegetație. De asemenea, o altă eroare frecvent întâlnită a fost clasificarea elementelor de sol sau vegetație joasă din proximitatea construcțiilor ca elemente ale construcțiilor. Aceste erori se pot observa Figura 5.10 și necesită intervenție manuală.




Figura 5.2. Pereții construcției clasificați ca elemente de vegetație

5.1.4. Extragerea datelor din norii de puncte utilizând rețelele neuronale convoluționale

Întrucât rețelele neuronale convoluționale sunt modele bazate pe date, eficiența acestor modele în domeniile lor de aplicație este dată de reprezentativitatea datelor

de antrenament (Kattenborn et al., 2021). În continuare, norul de puncte va fi clasificat cu algoritmi de DL și rețele neuronale convoluționale. La antrenarea unui model PointCNN, norul de puncte este împărțit în blocuri de puncte ce conțin un anumit număr de elemente ("Point cloud classification using PointCNN").

Pentru antrenarea unui model PointCNN, sunt necesare două tipuri de fișiere: un fișier de antrenare și un fișier de validare. Aceste fișiere au fost create cu ajutorul metodelor de clasificare automate existente în ArcGIS Pro, iar ulterior, erorile de clasificare au fost rectificate manual. În cele din urmă, am obținut cele două seturi de date (Figura 5.11), având în total un procent de 68% date de antrenare și 32% date de validare.



Figura 5.11. Seturile de date de antrenare și validare

Au fost pregătite datele de antrenare și validare, iar rezultatul se regăsește în Figurile 5.12 și 5.13.




Figura 5.12. Histograma blocurilor de puncte din datele de antrenare




Figura 5.13. Histograma blocurilor de puncte din datele de validare

Pentru antrenarea modelului, am folosit limbajul de programare Python în ArcGIS Pro și am ales un număr de 20 de epoci de antrenare:

```
from arcgis.learn import export_point_dataset, prepare_data, PointCNN
output_path=r'D:\Doctorat\3_An_III\5_Teza\4_1_Clasificarea_norului_de_puncte\Deep_learning_ArcGIS\V4\Model_train\Model_training_2\export2.pctd'
data = prepare_data(output_path, dataset_type='PointCloud', batch_size=2)
pointcnn = PointCNN(data)
pointcnn.fit(20)
```

Rezultatele antrenării modelului din fiecare epocă se pot observa în Figura 5.14 și sunt următoarele:

epoch	train_loss	valid_loss	accuracy	precision	recall	f1	time
0	2.017702	1.939532	0.420038	0.166875	0.162660	0.141807	15:11
1	1.719348	1.835655	0.478760	0.238613	0.218548	0.173044	14:07
2	1.416687	2.675217	0.428926	0.315331	0.270709	0.202408	13:59
3	1.066752	6.231255	0.305902	0.283549	0.239897	0.155649	13:58
4	0.927440	1.815611	0.484227	0.369048	0.326948	0.266849	13:58
5	0.834291	1.367668	0.560290	0.418993	0.370895	0.317546	13:58
6	0.800354	0.895765	0.669276	0.483309	0.407822	0.387601	13:56
7	0.750165	0.918152	0.672131	0.482960	0.421462	0.395064	13:57
8	0.731268	0.801657	0.690178	0.510082	0.410125	0.402040	13:57
9	0.716202	0.735054	0.708160	0.528342	0.408976	0.406577	14:02
10	0.682229	0.697355	0.720835	0.539543	0.431926	0.435531	14:24
11	0.669484	0.692361	0.726409	0.540671	0.437687	0.441238	14:08
12	0.665540	0.699732	0.733367	0.561855	0.458471	0.464235	13:55
13	0.656838	0.720050	0.721775	0.553432	0.428550	0.431470	13:56
14	0.641315	0.680481	0.734322	0.566254	0.447624	0.459272	13:55
15	0.629172	0.688940	0.728866	0.562753	0.439414	0.450087	14:10


16	0.631952	0.664263	0.733555	0.574948	0.446280	0.458066	13:58
17	0.612834	0.662378	0.736640	0.574113	0.451032	0.462522	13:48
18	0.610737	0.691800	0.730252	0.569812	0.447568	0.456362	13:55
19	0.603156	0.673858	0.732018	0.573324	0.442920	0.451286	13:48

PointCNN

Backbone: None

Learning Rate: 4.7863e-04

Training and Validation loss



Sample Results

Ground Truth / Predictions (Displaying randomly sampled 20000 points.)




Figura 5.14. Rezultatul antrenării modelului de DL

În continuare, am clasificat norul de puncte cu modelul antrenat și am obținut rezultatele din Figurile 5.15, 5.16 și 5.17.




Figura 5.15. Rezultatul clasificării norului de puncte cu modelul antrenat

Field: Add Calculate		Selection: Select By Attributes Zoom To Switch				
	Item	Category	Pt_Cnt	Percent	Z_Min	Z_Max
12	All	Returns	44913903	100	193.85	274.55
13	2_Ground	ClassCodes	18335153	40.82	201.1	243.51
14	3_Low_Vegetation	ClassCodes	6468741	14.4	201.25	254.58
15	4_Medium_Vegetation	ClassCodes	6114374	13.61	205.5	264.25
16	6_Building	ClassCodes	13696156	30.49	201.71	264.41
17	7_Low_Point(noise)	ClassCodes	220791	0.49	193.85	226.4
18	18_Reserved	ClassCodes	165	0	201.91	274.55
19	19_Reserved	ClassCodes	78523	0.17	201.94	272.85
20	Return_No	Attributes	<Null>	<Null>	<Null>	<Null>

Figura 5.16. Rezultatul clasificării norului de puncte cu modelul antrenat

Nor de puncte clasificat cu modelul antrenat de
Deep Learning




Figura 5.17. Grafic cu rezultatul clasificării norului de puncte

5.1.5. Studiu comparativ și concluzii

În urma clasificării norului de puncte prin cele trei metode prezentate anterior, am obținut rezultatele din Tabelul 5.1 și Figura 5.18.

Tabel 5-1. Rezultatele clasificării norului de puncte

Clasa/Metoda		ArcGIS Pro	Bentley Microstation TerraScan	ArcGIS Pro - model antrenat de Deep Learning
Nr.puncte	Sol	7,735,046	8,537,934	18,335,153
	Vegetație joasă	11,271,865	11,773,888	6,468,741
	Vegetație medie	9,548,292	10,034,580	6,114,374
	Vegetație înaltă	81,217	96,482	-
	Construcții	10,161,344	9,591,490	13,696,156
	Zgomot jos	6,083,682	1,556	220,791
	Neclasificat	-	4,877,731	-

Din Tabelul 5.1 se poate observa că în urma clasificării norului de puncte cu produsele software ArcGIS Pro și Bentley Microstation Terrascan am obținut rezultate similare. Acest lucru se datorează și faptului că au fost stabiliți parametri de clasificare similari pentru cele două metode. Un factor ce a determinat diferența între numerele de puncte cărora li s-a atribuit clasa Construcții este faptul că produsul software Bentley Microstation Terra Scan nu a clasificat și pereții construcțiilor, ci doar acoperișurile acestora. În Figura 5.19, se poate observa că punctele ce aparțin pereților construcției au fost clasificate ca puncte de vegetație medie, în cazul clasificării cu produsul software Bentley Microstation Terrascan. De asemenea, există o diferență considerabilă în ceea ce privește punctele de Sol, aceasta datorându-se faptului că în cazul clasificării cu produsul software ArcGIS Pro, multe dintre acestea au fost clasificate ca puncte de zgomot, reprezentate cu roșu în Figura 5.19-a, iar în cazul clasificării cu produsul software Bentley Microstation Terrascan, acestea au rămas neclasificate, reprezentate cu alb în Figura 5.19-b.

Grafic comparativ al metodelor de clasificare a norului de puncte




Figura 5.18. Grafic comparativ al metodelor de clasificare a norului de puncte




Figura 5.19. Nor de puncte clasificat în ArcGIS Pro (a.) și nor de puncte clasificat în Bentley Microstation Terrascan (b.) – aceeași construcție

În ceea ce privește clasificarea norului de puncte cu ajutorul modelului de DL antrenat, se constată diferențe mai mari față de primele două metode. Analizând norul de puncte clasificat (Figura 5.20), se poate observa faptul că multe puncte de vegetație medie au fost clasificate ca puncte ale construcțiilor și de asemenea, multe puncte ce alcătuiesc suprafețe plane au fost interpretate ca fiind acoperișuri ale construcțiilor, deși ele se află la nivelul solului (Figura 5.21).




Figura 5.20. Clasificarea norului de puncte cu modelul de DL antrenat – aceeași construcție regăsită în Figura 5.19




Figura 5.21. Nor de puncte clasificat cu modelul de DL antrenat

În ceea ce privește construcțiile mai complexe (Figura 5.22), toate cele trei metode s-au dovedit a fi insuficiente pentru a utiliza o clasificare complet automată, norul de puncte necesitând intervenție manuală de fiecare dată. Principala problemă

constă în faptul că formele neregulate ale acoperișurilor fac ca multe dintre punctele acestora să fie încadrate în diferite clase de vegetație.




Figura 5.22. Construcție clasificată cu ajutorul modelului antrenat de DL (a.) și cu produsele software ArcGIS Pro (b.) și Bentley Microstation Terrascan (c.)

În concluzie, cele trei metode de clasificare a norului de puncte au dus la rezultate similare, însă cea mai eficientă din punct de vedere al rezultatelor obținute și al intervențiilor manuale de corectare a erorilor a fost utilizarea instrumentelor de clasificare automată a norului de puncte implementate în ArcGIS Pro, aceasta pretându-se la clasificarea unui volum mai mare de date precum cele care fac obiectul studiului de caz din teza de doctorat. Pe lângă un număr mai mic de erori de clasificare, această metodă permite și automatizarea procesului de clasificare prin utilizarea ArcGIS API for Python.

5.2. Extragerea amprentelor la sol ale construcțiilor

5.2.1. Extragerea amprentelor la sol ale construcțiilor cu ajutorul algoritmului de Deep Learning implementat în ArcGIS Pro

În ArcGIS Living Atlas există diferite modele de extragere a amprentelor la sol ale construcțiilor pe baza imaginilor satelitare (Grădinaru, 2022). Am ales din Living Atlas modelul Building Footprint Extraction – USA, bazat pe o arhitectură de tip MaskRCNN implementat folosind ArcGIS API for Python (“Building Footprint Extraction - USA - Overview”). Modelul de DL a fost rulat pe un fișier raster de intrare, pentru a produce o clasă de caracteristici ce va conține obiectele găsite (“Detect Objects Using Deep

Learning (Image Analyst)–ArcGIS Pro | Documentation”). Modelul utilizat este antrenat pentru a identifica acoperișurile construcțiilor, pe care le va reprezenta sub forma unor poligoane. În total, au fost detectate 464 de geometrii. Pentru a corecta distorsiunile poligoanelor, am folosit un algoritm de compresie a poliliniilor (“Regularize Building Footprint (3D Analyst)–ArcGIS Pro | Documentation”). Apoi am eliminat suprapunerile și am obținut un număr de 390 de geometrii. Rezultatele se regăsesc în Figura 5.23.




Figura 5.23. Rezultatul extragerii amprentelor la sol ale construcțiilor cu modelul din ArcGIS Living Atlas

5.2.2. Antrenarea unui model de Deep Learning în ArcGIS Pro pentru extragerea amprentelor la sol ale construcțiilor folosind imaginile fotogrammetrice

Pentru antrenarea unui model de Deep Learning, am pregătit un set de date de antrenare ce constau în geometriile vectorizate manual pentru 298 de construcții (Figura 5.24), cărora li s-a atribuit clasa 1 în tabelul de attribute corespunzător.



OBJECTID *	Shape *	LAYER	Shape_Length	Shape_Area	Class
285	Polygon	BUILDING_FOOTPRINT	44.942156	95.354718	1
286	Polygon	BUILDING_FOOTPRINT	34.48643	68.044512	1
287	Polygon	BUILDING_FOOTPRINT	44.617227	118.026166	1
288	Polygon	BUILDING_FOOTPRINT	25.269639	36.083164	1
289	Polygon	BUILDING_FOOTPRINT	61.313964	193.506527	1
290	Polygon	BUILDING_FOOTPRINT	40.111155	98.879195	1
291	Polygon	BUILDING_FOOTPRINT	33.036483	54.922212	1
292	Polygon	BUILDING_FOOTPRINT	11.137674	7.743777	1
293	Polygon	BUILDING_FOOTPRINT	36.733587	69.891108	1
294	Polygon	BUILDING_FOOTPRINT	42.948108	76.319349	1
295	Polygon	BUILDING_FOOTPRINT	18.840946	22.017138	1
296	Polygon	BUILDING_FOOTPRINT	36.426775	72.114274	1
297	Polygon	BUILDING_FOOTPRINT	29.019433	41.704403	1
298	Polygon	BUILDING_FOOTPRINT	14.451096	12.950163	1

Figura 5.24. Datele de antrenare a modelului

Primul pas în antrenarea modelului a fost exportarea datelor de antrenare în formatul RCNN Masks ("Export Training Data For Deep Learning (Image Analyst)– ArcGIS Pro | Documentation"). În continuare, am convertit datele vectoriale etichetate în seturi de date de antrenament, pe baza imaginii raster. Rezultatul a fost un set de imagini mai mici, de 256x256 pixeli și un set de fișiere de metadate în formatul specificat. Următorul pas a fost antrenarea modelului de Deep Learning cu ajutorul datelor obținute la pasul anterior. Rezultatele antrenării în cele 20 de epoci au fost următoarele:

Start Time: Sunday, April 30, 2023 23:07:32

Learning Rate - slice(4.365158322401661e-06, 4.365158322401661e-05, None)

epoch	training loss	validation loss
0	1.1618988513946533	1.2790905237197876
1	1.1265311241149902	0.9537186622619629
2	1.067383885383606	0.8906569480895996
3	1.1501880884170532	0.8541356921195984
4	1.0023037195205688	0.7756800055503845
5	0.9016749858856201	0.7570561170578003
6	0.7635862231254578	0.731697678565979
7	0.8380852341651917	0.6944260597229004
8	0.7321746349334717	0.6711621284484863
9	0.9564940929412842	0.6712456345558167
10	0.7845675945281982	0.6268543004989624
11	0.656985342502594	0.5794755816459656
12	0.8817278146743774	0.607085108757019
13	0.582132875919342	0.5567061305046082
14	0.6240612864494324	0.5660204887390137
15	0.5917166471481323	0.5256257057189941
16	0.5708335638046265	0.5232657194137573
17	0.5908197164535522	0.5226365923881531
18	0.5473408102989197	0.5186260342597961
19	0.5487155914306641	0.5161070823669434

{'average_precision_score': {'1': 0.8224424088745176}}

Succeeded at Sunday, April 30, 2023 23:32:53 (Elapsed Time: 25 minutes 20 seconds)

În continuare, am folosit modelul antrenat pentru a obține amprente la sol ale construcțiilor, iar apoi am corectat distorsiunile poligoanelor. Am obținut în total 1262 poligoane. Ultimul pas a fost eliminarea zonelor de suprapunere și unirea geometriilor suprapuse într-o singură geometrie. Am obținut în total un număr de 628 de poligoane, iar rezultatul se regăsește în Figura 5.25.



Figura 5.25. Ampretele la sol ale construcțiilor obținute cu modelul antrenat de Deep Learning

Pentru gestionarea unui număr mai mare de fotograme, am propus utilizarea ArcGIS Pro ModelBuilder (Figura 5.26).




Figura 5.26. Model de extragere a amprentelor la sol ale construcțiilor în ArcGIS Pro ModelBuilder

De asemenea, pentru automatizarea procesului de extragere a amprentelor la sol ale construcțiilor, poate fi utilizat ArcGIS API for Python, cu următoarea secvență de cod:

```
import arcpy
```

```
def Model(): # Model
```

```
    # To allow overwriting outputs change overwriteOutput option to True.
```

```
    arcpy.env.overwriteOutput = False
```

```

# Check out any necessary licenses.
arcpy.CheckOutExtension("ImageExt")
arcpy.CheckOutExtension("ImageAnalyst")
arcpy.CheckOutExtension("3D")

arcpy.ImportToolbox(r"c:\program
files\arcgis\prol\Resources\ArcToolbox\toolboxes\GeoAnalytics Desktop Tools.tbx.tbx")
DOC_15_ecw = arcpy.Raster("DOC_15.ecw")
MODEL_dlpk =
"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learnin_Trained\1_V4_dupa_v5\1_V4\MODEL\MODEL.dlpk"

# Process: Detect Objects Using Deep Learning (Detect Objects Using Deep Learning) (ia)
DOC_15_Building_FP =
"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learning_implementat\1_V1\1_V1.gdb\DOC_15_Building_FP"
arcpy.ia.DetectObjectsUsingDeepLearning(in_raster=DOC_15_ecw,
out_detected_objects=DOC_15_Building_FP, in_model_definition=MODEL_dlpk,
arguments=[["padding", "128"], ["batch_size", "4"], ["threshold", "0.9"], ["return_bboxes", "False"],
["tile_size", "512"]], run_nms="NO_NMS", confidence_score_field="Confidence",
class_value_field="Class", max_overlap_ratio=0,
processing_mode="PROCESS_AS_MOSAICKED_IMAGE")
.save(Detect_Objects_Using_Deep_Learning)

# Process: Regularize Building Footprint (Regularize Building Footprint) (3d)
DOC_15_Building_FP_Regulariz =
"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learning_implementat\1_V1\1_V1.gdb\DOC_15_Building_FP_Regulariz"
arcpy.ddd.RegularizeBuildingFootprint(in_features=DOC_15_Building_FP,
out_feature_class=DOC_15_Building_FP_Regulariz, method="RIGHT_ANGLES", tolerance=1,
densification=None, precision=0.15, diagonal_penalty=1.5, min_radius=0.1, max_radius=1000000,
alignment_feature="", alignment_tolerance="", tolerance_type="DISTANCE")

# Process: Dissolve Boundaries (Dissolve Boundaries) (gapro)
Output_Feature_Class =
"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learning_implementat\1_V1\1_V1.gdb\DOC_15_Building_FP_Regulariz_DissolveBoundaries"
arcpy.gapro.DissolveBoundaries(input_layer=DOC_15_Building_FP_Regulariz,
out_feature_class=Output_Feature_Class, multipart="SINGLE_PART", dissolve_fields="", fields=[],
summary_fields=[])

if __name__ == '__main__':
# Global Environment settings
with
arcpy.EnvManager(scratchWorkspace=r"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learning_implementat\1_V1\1_V1.gdb",
workspace=r"D:\Doctorat\3_An_III\5_Teza\4_2_Extragerea_amprentelor_la_sol_ale_construcțiilor\1_ArcGIS_Pro_Deep_Learning_implementat\1_V1\1_V1.gdb"):
Model()

```


5.2.3. Extragerea amprentelor la sol ale construcțiilor din norul de puncte LiDAR

Pentru extragerea amprentelor la sol ale construcțiilor din norul de puncte LiDAR, am folosit produsul software ArcGIS Pro. Prima etapă a fost aplicarea unui filtru asupra norului de puncte deja clasificat, pentru a afișa doar punctele ce aparțin construcțiilor. În continuare, am creat o imagine raster a cărei valori reflectă informații statistice despre norul de puncte. Pentru uniformizarea geometriilor construcțiilor și umplerea golurilor din imaginea raster, am folosit funcția *Elevation Void Fill*. În cele din urmă, am obținut rezultatul din Figura 5.27.




Figura 5.27. Imaginea raster cu amprentele la sol ale construcțiilor extrase din norul de puncte LiDAR

Din imaginea raster obținută, am extras poligoanele amprentelor la sol ale construcțiilor. În cele din urmă, am corectat distorsiunile poligoanelor. Am obținut un număr de 545 poligoane, iar rezultatul se regăsește în Figura 5.28.



Figura 5.28. Ampretele la sol ale construcțiilor obținute din norul de puncte LiDAR

5.2.4. Studiu comparativ și concluzii

Rezultatele obținute prin cele trei metode de extragere a amprentelor la sol ale construcțiilor se regăsesc în tabelul 5.2.

Tabel 5-2. Rezultatele obținute cu cele trei metode de extragere a amprentelor la sol ale construcțiilor

Nr. crt.	Metodă	Nr. construcții identificate inițial	Nr. construcții obținute după unirea geometriilor apropiate și eliminarea suprapunerilor
1	Extragerea amprentelor la sol ale construcțiilor cu ajutorul algoritmului de Deep Learning implementat în ArcGIS Pro	464	390
2	Extragerea amprentelor la sol ale construcțiilor cu ajutorul unui model de Deep Learning antrenat	1263	628
3	Extragerea amprentelor la sol ale construcțiilor din norul de puncte LiDAR	545	545

În cazul utilizării modelului antrenat de DL, se constată obținerea unui număr mai mare de construcții decât cu modelul implementat în ArcGIS Pro. Acest lucru se datorează și faptului că există o segmentare mai bună a construcțiilor în funcție de diferențele sesizate la acoperișuri. Astfel, mai multe blocuri alăturate au fost identificate ca fiind construcții diferite și nu aceeași construcție ca în cazul utilizării modelului de DL implementat în ArcGIS Pro. În urma unirii geometriilor apropiate și eliminării suprapunerilor, această diferență a scăzut considerabil. În cazul extragerii amprentelor la sol ale construcțiilor din norii de puncte LiDAR, deoarece obținerea acestora se bazează și pe date de elevație, iar mai multe blocuri alăturate pot avea același număr de niveluri și implicit aceeași înălțime, acestea au fost identificate ca fiind o singură construcție (Figura 5.29).




Figura 5.29. Blocuri identificate cu modelul de DL implementat în ArcGIS Pro (a.), cu modelul de DL antrenat (b.) și pe baza norului de puncte LiDAR (c.)

În ceea ce privește construcțiile mai complexe, precum biserica din Figura 5.30, se constată faptul că în cazul modelului implementat în ArcGIS Pro, aceasta nu a fost clasificată ca fiind construcție, iar în cazul modelului antrenat, deși a fost identificată, geometria rezultată nu corespunde cu realitatea, necesitând intervenția manuală. Și în cazul utilizării norului de puncte LiDAR, pot apărea erori, din cauza clasificării necorespunzătoare a punctelor sau a lipsei punctelor din unele zone.




Figura 5.30. Biserică identificată cu modelul de DL implementat în ArcGIS Pro (a.), cu modelul de DL antrenat (b.) și pe baza norului de puncte LiDAR (c.)

În cadrul segmentării imaginii cu modelul de DL antrenat, porțiuni ale râului au fost identificate ca fiind construcții (Figura 5.31), necesitând intervenția manuală pentru eliminarea acestora.



Figura 5.31. Porțiune de râu clasificată ca fiind construcție

Pentru a evalua mai eficient performanța modelelor studiate, am realizat o comparație cu geometriile construcțiilor din eTerra. Pentru aceasta, am ales construcția cu formă dreptunghiulară din figura 5.32. Analizând diferențele dintre coordonatele celor 4 colțuri ale construcției din Tabelul 5.3. și considerând coordonatele construcției din eTerra ca fiind valoarea justă, se poate concluziona că am obținut cea mai mică sumă a erorilor din modelul de DL antrenat.

Tabel 5.3. Comparația coordonatelor amprentei la sol ale unei construcții obținute prin cele 3 metode descrise și coordonatele geometriei din eTerra

Coordonate din modelul de Deep Learning implementat în ArcGIS Pro			
E [m]	er. [m]	N [m]	er. [m]
391540.970	-0.355	685519.900	0.078
391612.020	-0.791	685527.610	-0.807
391613.170	-0.894	685516.290	-1.703
391542.310	-0.269	685508.510	-0.884
S=	-2.310	S=	-3.316
Coordonate din modelul de Deep Learning antrenat			
E [m]	er. [m]	N [m]	er. [m]
391540.250	-1.075	685520.400	0.578
391613.260	0.449	685529.180	0.763
391614.650	0.586	685517.580	-0.413
391541.640	-0.939	685508.800	-0.594
S=	-0.980	S=	0.334
Coordonate din norul de puncte LiDAR			
E [m]	er. [m]	N [m]	er. [m]
391540.010	-1.315	685520.610	0.788
391612.830	0.019	685529.580	1.163
391614.480	0.416	685516.260	-1.733
391541.410	-1.169	685508.160	-1.234
S=	-2.050	S=	-1.016
Coordonate din eTerra			
E [m]	N [m]		
391541.325	685519.822		
391612.811	685528.417		
391614.065	685517.993		
391542.579	685509.394		




Figura 5.32. Construcții identificate cu modelul de DL implementat în ArcGIS Pro (a.), cu modelul de DL antrenat (b.), din norul de puncte LiDAR (c.) și din eTerra (d.)

5.3. Obținerea modelelor 3D ale construcțiilor

5.3.1. Modelarea 3D a construcțiilor în ArcGIS Pro

Pentru modelarea 3D a construcțiilor în ArcGIS Pro se folosesc obiectele de tip *multipatch*. În cazul de față, am utilizat amprentele la sol ale construcțiilor obținute pe baza norului de puncte LiDAR și norul de puncte clasificat cu ajutorul instrumentelor de clasificare automată implementate în ArcGIS Pro, cu rectificările manuale ale erorilor de clasificare. Modelul 3D obținut se regăsește în figura 5.33.



Figura 5.33. Modelul 3D al construcțiilor – vedere de ansamblu

Analizând de aproape construcțiile obținute, se observă că suprafața acestora este neregulată (Figura 5.34).




Figura 5.34. Modelul 3D – vedere de detaliu

Pentru rezolvarea acestei probleme, am optat pentru o rectificare manuală a amprentelor la sol ale construcțiilor, urmată de extrudarea acestora cu ajutorul funcției Extrusion la o înălțime determinată din norul de puncte LiDAR, ce a fost introdusă în tabelul de attribute ale construcțiilor. Astfel, au fost obținute modelele 3D ale construcțiilor cu gradul de detaliere LOD1 (Figura 5.35).




Figura 5.35. Modelul 3D al construcțiilor obținut cu funcția Extrusion în ArcGIS Pro, reprezentare cu gradul de detaliere LOD1

Pentru reprezentarea construcțiilor cu gradul de detaliere LOD2, au fost modelate suprafețele acoperișurilor dintr-o zonă și au fost aplicate texturi pe baza unui pachet de reguli din CityEngine. În cazul de față, a fost aplicat pachetul de reguli Building Shell

with Detail, ce adaugă fațade cu detalii arhitecturale unui corp 3D (Schueren). Rezultatul modelării se regăsește în figura 5.36.




Figura 5.36. Modelul 3D al construcțiilor - reprezentare cu gradul de detaliere LOD2

5.3.2. Modelarea 3D a construcțiilor în CityEngine

CityEngine este un pachet software de modelare urbană bazată pe reguli (Kelly, 2021). Limbajul de programare folosit în CityEngine este CGA – Computer-generated Architecture și pe baza acestuia se creează fișierele format *.cga care conțin reguli ce sunt aplicate unei geometrii 2D pentru a obține modelul 3D al construcției (“CGA modeling overview—ArcGIS CityEngine Resources | Documentation”).

Prima etapă a fost generarea străzilor, pentru care s-a vectorizat axul, iar apoi au fost aplicate regulile CGA CompleteStreets_2022 (Wasserman, 2023). Printre acestea, se regăsesc regulile din Figura 5.37, care împart strada în trotuar și benzi și regulile din Figura 5.38, care dau textură străzilor. Pentru fiecare stradă au fost aleși parametri corespunzători lății suprafeței carosabile și a trotuarelor. În urma generării străzilor, au rezultat loturile, cărora le-au fost aplicate texturi. Rezultatul se regăsește în figura 5.39.

```
RightSide-->
split(v,unitSpace,0){(_Transit_Lane_Width_Switch(0,"Sidewalk Side")):Transit_Lane_Reporting(0)
|_RightSplitSum:RightSplitSpace
|(_Transit_Lane_Width_Switch(0,"Right Most Lane")):Transit_Lane_Reporting(0)
|(_Distribute_Right_Lanes*_Actual_Lane_Width):Lanes(0,(case rightHandTraffic: Stop_End else: Stop_Begin))
|(_Transit_Lane_Width_Switch(0,"Left Most Lane")):Transit_Lane_Reporting(0)}

LeftSide-->
split(v,unitSpace,0){(_Transit_Lane_Width_Switch(2,"Left Most Lane")):scaleUV(0,-1,-1) Transit_Lane_Reporting(2)
|(_nLanesLeft*_Actual_Lane_Width):translateUV(0,0,-geometry.vMax) scaleUV(0,-1,-1)
|Lanes(2,(case rightHandTraffic: Stop_Begin else: Stop_End))
|(_Transit_Lane_Width_Switch(2,"Right Most Lane")):scaleUV(0,-1,-1) Transit_Lane_Reporting(2)
|_LeftSplitSum:LeftSplitSpace
|(_Transit_Lane_Width_Switch(2,"Sidewalk Side")):scaleUV(0,-1,-1) Transit_Lane_Reporting(2)}
```

Figura 5.37. Regula CGA pentru împărțirea străzilor în trotuare și benzi

```

@StartRule
Street -->
  set(material.name,"Road_Bed")
  Initial_Street_Settings

Initial_Street_Settings-->
  case Specularity==1 && Transparency==0:
    Short_Long_Street
  else:
    Short_Long_Street_Altered

Short_Long_Street_Altered-->
  case Transparency>0 && Specularity==1:
    set(material.opacity,1-Transparency)
    Short_Long_Street
  else:
    set(material.specular.g,Specularity)
    set(material.specular.b,Specularity)
    set(material.specular.r,Specularity)
    Short_Long_Street

Short_Long_Street-->
  case _uScale==1:
    Long_Street

  else:
    Short_Street

Long_Street-->
  ReportMultimodalMetrics(reportingOn)
  BridgeMain
  split(u,uvSpace,1){_crosswalkBeginWidth/10: Asphalt("Auto","asphalt")
                    |_crosswalkBeginWidth : Crosswalk( Crosswalk_Begin ,1)
                    |~1 : StreetWithCrosswalkEnd }

Short_Street-->
  ReportMultimodalMetrics(reportingOn)
  BridgeMain
  set( Right_Bike_Box ,"false")
  set( Left_Bike_Box ,"false")
  set( Stop_Begin ,"none")
  set( Stop_End ,"none")
  StreetWithEntries

```

Figura 5.38. Extras din regula CGA pentru stabilirea texturii străzilor



Figura 5.39. Loturile generate cu texturile aplicate

Pentru obținerea modelelor 3D ale construcțiilor, am importat în CityEngine fișierul în format *shapefile* cu amprentele la sol ale construcțiilor generate cu ajutorul modelului de DL antrenat și corectate manual, având înălțimea acestora determinată din norul de puncte LiDAR menționată în tabelul de attribute. Au fost aplicate regulile CGA din Figura 5.40 pentru extrudarea amprentelor la sol ale construcțiilor, generarea acoperișurilor în patru ape, modelarea fațadelor construcțiilor, fiind diferențiată fațada frontală, care include și intrările, de cele laterale, împărțirea construcțiilor în parter și

etaje, generarea ferestrelor și aplicarea texturilor și culorilor. Rezultatul final se regăsește în Figura 5.41.

```

attr Inaltimea_ = 0
attr groundfloor_height = 3.5
attr floor_height = 3
attr tile_width = 4
const window_color = "#a1c2e6"
const frame_color = "#c2c2c2"
const door_color = "#b8b8b8"

@StartRule
Lot -->
  extrude(Inaltimea_)
  Volume
Volume --> comp(f) { front : Frontfacade | side : Sidefacade | top : Top }
Frontfacade -->
  split(y) { groundfloor_height : Groundfloor
            | { ~floor_height : Floor}* }
Top -->
  roofHip(30, 1)
  color("#9e3b2c")

Sidefacade -->
  split(y) { groundfloor_height : Floor
            | { ~floor_height : Floor}* }
Floor -->
  split(x) { 0.4 : SolidWall
            | { ~tile_width : Tile }*
            | 0.4 : SolidWall }
Groundfloor -->
  split(x) { 0.4 : SolidWall
            | { ~tile_width : Tile }*
            | ~tile_width : EntranceTile
            | 0.4 : SolidWall }
Tile -->
  split(x) { 1 : SolidWall
            | ~1 : split(y) { 1.2 : SolidWall | ~1.3 : Window | 0.5 : SolidWall }
            | 1 : SolidWall }
EntranceTile -->
  split(x) { ~1 : SolidWall
            | 2.5 : split(y) { 3 : Door | ~2 : SolidWall }
            | ~1 : SolidWall }
SolidWall -->
  s('1, '1, -0.4)
  primitiveCube()
  color("#f7fad4")

Window -->
  t(0, 0, -0.2)
  split(y) { 0.1 : Frame
            | ~1 : split(x) { 0.1 : Frame | { ~1 : Glass | 0.1 : Frame }* }
            | 0.1 : Frame }
Glass -->
  color(window_color)
  set(material.specular.r, 0.5)
  set(material.specular.g, 0.5)
  set(material.specular.b, 1)
  set(material.reflectivity, 1)
  set(material.shininess, 100)
  set(material.opacity, 0.5)

Frame -->
  color(frame_color)

Door -->
  t(0, 0, -0.3)
  split(y) { ~1 : split(x) { 0.15 : Frame
                           | ~1 : Panel
                           | 0.05 : Frame
                           | ~1 : Panel
                           | 0.15 : Frame }
            | 0.15 : Frame }
Panel -->
  color(door_color)

```

Figura 5.40. Modelarea fațadelor construcțiilor




Figura 5.3. Modelarea construcției în CityEngine cu nivelul de detaliere LOD3 (LOD3.1, conform clasificării realizate de Biljecki et al. (2016))

Aceleași reguli, cu variații în ceea ce privește culorile, au fost aplicate și celorlalte construcții, obținând rezultatul din Figurile 5.42, 5.43 și 5.44.



Figura 5.4. Modelarea zonei în CityEngine cu nivelul de detaliere LOD 3 (LOD3.1, conform clasificării realizate de Biljecki et al. (2016)), vedere de ansamblu



Figura 5.5. Modelul 3D al zonei, vedere de detaliu



Figura 5.6. Modelul 3D al zonei, vedere de detaliu

5.3.3. Obținerea modelului 3D al orașului pe baza datelor open-source

Am utilizat OpenStreetMap ca sursă de date deschise ce pot fi importate în CityEngine. Datele importate constau în rețeaua de drumuri, amprentele la sol ale construcțiilor și imaginea satelitară. Au fost generate modelele 3D ale construcțiilor pe baza amprentelor la sol importate. Volumelor obținute li s-a aplicat un pachet de reguli precum cele descrise anterior, conceput pentru construcțiile modelate pe baza datelor din OpenStreetMap, iar modelul 3D al Municipiului Baia Mare se regăsește în Figura 5.45.




Figura 5.45. Modelul 3D al Municipiului Baia Mare (LOD2)

5.3.4. Vizualizarea modelelor 3D ale orașelor

Pentru vizualizarea modelului 3D al Municipiului Baia Mare am realizat publicarea acestuia sub forma unui *hosted scene layer* (Figura 5.46).



Figura 5.46. Reprezentarea modelului 3D al Municipiului Baia Mare în ArcGIS online, cu setarea unui moment al zilei

5.3.5. Aplicație VR și AR pentru vizualizarea modelelor 3D ale orașelor

Pentru a putea accesa modelul 3D al orașului într-un mediu VR și AR, am creat Bookmark-uri cu zone de interes, pe care le-am exportat într-un format *.3vr, compatibil cu aplicațiile de vizualizare a realității virtuale. Mediul AR creat poate fi vizualizat într-un browser (Figurile 5.47 și 5.48) prin rotirea imaginii cu ajutorul mouse-ului, sau pe aplicații mobile (Figurile 5.49 și 5.50), prin rotirea imaginii mișcând telefonul. Mediul VR creat poate fi accesat prin intermediul ochelarilor VR, utilizatorul mișcându-se pentru a putea roti imaginea.



Figura 5.47. Vizualizarea modelului 3D al Municipiului Baia Mare, generat pe baza datelor open-source, în mediul AR în browser



Figura 5.48. Vizualizarea modelului 3D AR al unei zone din Municipiul Baia Mare, generat pe baza norului de puncte LiDAR și a imaginilor fotogrammetrice




Figura 5.49. Vizualizarea modelului 3D al Municipiului Baia Mare, generat pe baza datelor open-source, în mediul AR pe mobil



Figura 5.50. Vizualizarea modelului 3D AR al unei zone din Municipiul Baia Mare, generat pe baza norului de puncte LiDAR și a imaginilor fotogrammetrice

HTC Vive Cosmos (Figura 5.51) este un sistem VR dotat cu șase camere, cu o rezoluție a pixelilor de 2880x1700 și poate fi conectat la computer, pentru a vizualiza diferite aplicații VR ("VRpro.ro: HTC Vive Cosmos"). Acest sistem a fost folosit pentru vizualizarea modelului 3D al orașului într-un mediu VR (Figura 5.52).



Figura 5.51. Sistemul VR HTC Vive Cosmos ("VRpro.ro: HTC Vive Cosmos")



Figura 5.52. Vizualizarea modelului 3D al Municipiului Baia Mare, generat pe baza datelor open-source, într-un mediu VR prin intermediul sistemului VR HTC Vive Cosmos

5.4. Concluzii

În cadrul acestui capitol au fost testate două produse software pentru clasificarea norului de puncte și un model de Deep Learning antrenat pe un set de date din zona de studiu. Am constatat că pentru antrenarea eficientă a unui astfel de model, este necesar ca setul de date de antrenare să cuprindă un volum foarte mare și diversificat de date, iar performanțele sistemului hardware folosit reprezintă un factor foarte important. Cea mai eficientă soluție din punct de vedere al rezultatelor obținute și al necesității mai reduse de corectare manuală a erorilor a fost utilizarea instrumentelor de clasificare automată a norului de puncte implementate în ArcGIS Pro. Această variantă s-a pretat cel mai bine la clasificarea unui volum mai mare de date precum cel aferent unei zone urbane întinse. Crearea unei aplicații în limbajul de programare Python a crescut gradul de automatizare al procesului și a contribuit la reducerea duratei de timp dedicată clasificării norului de puncte.

Pentru extragerea amprentelor la sol ale construcțiilor am folosit produsul software ArcGIS Pro, prin diferite metode: utilizarea unui model de DL existent, utilizarea norului de puncte și antrenarea unui model de DL pentru specificul zonei de studiu. Deși toate cele trei metode necesită intervenții manuale de corectare a erorilor

de clasificare a imaginilor, prin comparația cu geometria aferentă unei construcții din eTerra, modelul de DL antrenat s-a dovedit a oferi rezultatul cel mai apropiat de realitate.

În ceea ce privește obținerea modelelor 3D ale construcțiilor, utilizarea unui algoritm de generare a acestora pe baza norului de puncte LiDAR nu a oferit rezultatele dorite, suprafețele construcțiilor fiind unele neregulate. O astfel de metodă presupune intervenții manuale majore de rectificare a erorilor rezultate. Astfel, am optat pentru folosirea unei funcții de extrudare a amprentelor la sol ale construcțiilor, la o înălțime determinată din norul de puncte LiDAR și introdusă în tabelul de attribute ale acestora. În mod similar am procedat și în aplicația CityEngine, însă în cazul acesta modelarea a fost realizată în amănunt. În acest sens, am propus un set de reguli ce au fost aplicate amprentelor la sol ale construcțiilor pentru a obține modelele 3D ale acestora, inclusiv detalii precum uși și ferestre de la nivelul fațadelor. O astfel de modelare poate fi utilizată pentru gestionarea răspunsului la situațiile de urgență, în care elementele de fațadă pot reprezenta un factor important.

Datele geospațiale open-source s-au dovedit a fi suficiente pentru a obține un model 3D al orașului, însă acuratețea acestuia este una redusă.

Modul de prezentare al modelelor 3D ale construcțiilor și posibilitatea de distribuire și vizualizare a acestora reprezintă un factor important. Dacă aceste modele sunt folosite pentru a veni în sprijinul societății, prin eficientizarea gestionării resurselor și prin planificarea situațiilor de urgență, ele trebuie să poată fi accesate și înțelese de către publicul larg. Distribuirea modelelor într-un mediu GIS Online sau vizualizarea acestora prin intermediul unui computer, a unui mobil sau a unui sistem VR în aplicația VR creată, pot veni atât în sprijinul cetățenilor cât și al autorităților, prin reducerea deplasărilor la fața locului în situațiile în care acest lucru este necesar pentru analiza diferitelor scenarii.

6. Concluzii generale, contribuții originale și perspective

6.1. Concluzii generale

Modelele 3D ale orașelor stau la baza unor analize temeinice ce sprijină îmbunătățirea metodelor de rezolvare a problemelor cu care societatea actuală se confruntă, iar acuratețea cu care acestea sunt realizate este un factor important în obținerea unor predicții în situații precum analizele de vizibilitate, estimarea necesarului energetic, estimarea umbrelor, estimarea potențialului energetic, sau propagarea sunetelor. Standardizarea acestora permite schimbul de date între diferite modele, iar standardele CityGML, cu cele cinci niveluri de detaliere, sunt utilizate la scară largă în prezent. În funcție de domeniul de aplicabilitate al modelului 3D obținut, pot fi alese LOD0, LOD1, sau LOD2 de exemplu pentru analizele de vizibilitate, de estimare a necesarului de energie electrică, sau a potențialului energetic, LOD3, care cuprinde și elemente ale pereților, acoperișurilor și balcoanelor detaliate, pentru analize de estimare a umbrelor sau de propagare a sunetelor, sau LOD4, care cuprinde și structurile interioare ale construcțiilor, pentru gestionarea răspunsului la situații de urgență.

Conceptul de "Smart City" se referă la o replică digitală 3D a unui oraș, construită atât pe baza datelor geospațiale, cât și pe baza altor date legate de populație și de modul de gestionare a resurselor în cadrul unei zone urbane, date dinamice, primite în timp real.

Obiectivul principal al tezei de doctorat a fost identificarea unui flux de lucru optim pentru generarea, distribuirea și vizualizarea modelelor 3D ale orașelor, ce va putea fi implementat mai departe de către autorități sau alte persoane interesate. În acest sens, am analizat principalele metode de achiziție a datelor geospațiale necesare modelării 3D a imobilelor și principalele tehnici de modelare spațială 3D, zona de studiu fiind în Municipiul Baia Mare.

În funcție de nivelul de detaliere ales, se va alege tehnica de achiziție a datelor geospațiale. Pentru nivelurile de detaliere LOD0, LOD1 și LOD2 achiziția datelor prin scanare laser aeropurtată poate fi suficientă. Pentru nivelul de detaliere LOD3, acuratețea modelului 3D generat depinde de densitatea norului de puncte, iar scanarea laser terestră, care permite obținerea unui nor de puncte cu o densitate ridicată poate fi mai eficientă. Pentru generarea unui model cu un nivel de detaliere LOD4, este necesară o scanare laser terestră sau mobilă și în interiorul construcțiilor. Prin achiziția imaginilor fotogrammetrice se asigură posibilitatea de a extrage amprente la sol ale construcțiilor cu o acuratețe mai mare decât extragerea acestora pe baza norului de puncte LiDAR.

Pentru scanarea laser aeropurtată, scanere precum Leica CityMapper-2 sau RIEGL VQ-780ii-S pot fi folosite, în vederea obținerii norului de puncte pentru o suprafață mai extinsă. Pentru obținerea unui nor de puncte cu o densitate mai ridicată, pot fi folosite scanere laser terestre, precum Leica ScanStation P50, sau Trimble TX8. Scanarea laser mobilă poate fi realizată prin platforme precum Leica ProScan G-Series

sau Sistemul de scanare FGI ROAMER, dezvoltat de Institutul Geodezic din Finlanda și utilizat pentru cartografierea drumurilor.

Imaginile fotogrammetrice pot fi aeriene, preluate de la nivelul unei platforme de zbor, terestre, preluate cu ajutorul unei camere amplasate la sol, sau satelitare. În funcție de unghiul de preluare, acestea pot fi nadirale sau înclinate. Astfel, pentru achiziția imaginilor fotogrammetrice aeriene, pot fi folosite camere fotogrammetrice nadirale, precum UltraCam Eagle Mark 3 (Vexcel) sau Leica DMC II (Leica), iar pentru preluarea imaginilor fotogrammetrice oblice pot fi folosite camere fotogrammetrice oblice, precum UltraCam Osprey (Vexcel), Leica RCD30 Oblique (Leica) sau IGI Quattro DigiCAM Oblique (IGI).

Datele din cadrul studiului de caz din teza de doctorat au fost achiziționate prin scanare laser aeropurtată, cu ajutorul scannerului laser RIEGL VQ-780ii-S, în cazul norilor de puncte LiDAR și cu ajutorul camerelor fotogrammetrice Phase One P1-iXM-RS150F și P1-iXM-RS100F în cazul imaginilor fotogrammetrice.

Clasificarea norului de puncte LiDAR și extragerea amprentelor la sol ale construcțiilor sunt pași importanți ce stau la baza realizării modelelor 3D ale orașelor. Cercetările recente în domeniu se bazează în special pe clasificarea prin învățarea automată (Machine Learning) cu algoritmi precum SVM, Adaboost, Random Forest, Markov Random Field sau Conditional Random Field (CRF).

Utilizarea algoritmilor de DL pentru realizarea acestor operații reprezintă standardul actual în domeniu, iar în acest sens, se remarcă rețelele neuronale convoluționale de tip PointCNN, pentru clasificarea norului de puncte LiDAR și MaskRCNN, pentru extragerea elementelor geometrice din imaginile fotogrammetrice.

În cadrul tezei de doctorat, pentru clasificarea norului de puncte LiDAR, am folosit modelul de clasificare definit de ASPRS, care cuprinde și clasele Sol, Zgomot jos, Construcții, Vegetație joasă, Vegetație medie și Vegetație înaltă, asupra cărora s-a concertat studiul comparativ din cadrul lucrării. Diferite produse software pot oferi rezultate diferite, deoarece se bazează pe metode de clasificare diferite, iar în acest sens, am realizat clasificarea norului de puncte cu produsele software ArcGIS Pro și Bentley Microstation Terrascan. În cele din urmă, am antrenat un model de DL, bazat pe o rețea neuronală convoluțională de tip PointCNN, care s-a dovedit a fi eficient pentru scopul propus. În cazul unui volum mai mare de date, care din considerente tehnice legate de performanțele componentelor hardware folosite, trebuie împărțite în mai multe fișiere, este necesar ca întregul proces de clasificare a norilor de puncte LiDAR să fie automatizat. Astfel, am conceput un flux de lucru în limbajul de programare Python, ce s-a dovedit a fi util pentru gestionarea datelor într-un mediu GIS.

Pentru extragerea amprentelor la sol ale construcțiilor, am folosit ca date de plecare atât imaginile fotogrammetrice, cât și norul de puncte LiDAR. În plus, am utilizat un model de clasificare a imaginilor existent, preluat din ArcGIS Online, dar și un model antrenat de DL, cel din urmă oferind rezultatele cele mai apropiate de realitate. Prin algoritmi de compresie a poliliniilor se pot corecta distorsiunile

poligoanelor obținute, pentru a obține niște forme ale amprentelor la sol ale construcțiilor cât mai regulate.

În ceea ce privește generarea modelelor 3D ale construcțiilor, realizarea acestei operații exclusiv pe baza norului de puncte s-a dovedit a fi inefficientă, datorită iregularităților din norul de puncte. O soluție optimă s-a dovedit a fi extrudarea amprentelor la sol ale construcțiilor extrase din imaginile fotogrammetrice, la o înălțime a acestora determinată din norul de puncte LiDAR. Astfel, s-a confirmat ipoteza inițială și anume necesitatea achiziționării celor două tipuri de date geospațiale.

Limbajul de programare folosit în CityEngine – CGA – permite aplicarea unor reguli asupra unor geometrii 2D, pentru obținerea modelelor 3D ale construcțiilor. Posibilitățile de programare a modelării sunt numeroase, iar în cadrul studiului de caz am modelat construcțiile cu nivelele de detaliere LOD1, LOD2 și LOD3. Astfel, modelele 3D ale construcțiilor au fost generate inclusiv cu detalii ale fațadelor, modele ce pot fi folosite pentru gestionarea răspunsului la situațiile de urgență, în care elementele de fațadă precum ușile și ferestrele pot reprezenta un factor important.

În cele din urmă, modul de distribuire și vizualizare a rezultatului modelării reprezintă un factor foarte important, întrucât aceste modele trebuie să poată fi accesate și înțelese de către publicul larg. Realizarea unor aplicații GIS Desktop sau mobile au constituit o soluție pentru această problemă, iar vizualizarea într-un mediu VR a modelului 3D al orașului aduce aceste aplicații la standardele actuale și oferă posibilitatea gestionării mai eficiente a timpului și a resurselor de către autoritățile cu responsabilități în domeniile în care aceste modele pot fi utilizate.

În concluzie, pentru reprezentarea spațială a imobilelor, am propus fluxul de lucru din figura 6.1.




Figura 6.1. Flux de lucru propus pentru reprezentarea spațială a imobilelor

6.2. Contribuții originale

Contribuțiile personale au fost următoarele:

- Analiză detaliată a principalelor tehnici de achiziție a datelor geospațiale necesare modelării spațiale 3D;
- Analiza posibilității de utilizare a datelor open-source în modelarea spațială 3D a orașelor;
- Analiza tehnicilor actuale de modelare spațială 3D;
- Clasificarea norului de puncte cu produsul software ArcGIS Pro;
- Clasificarea norului de puncte cu produsul software Bentley Microstation Terrascan;
- Antrenarea unui model de DL pentru clasificarea norului de puncte și implementarea acestuia;
- Realizarea unei propuneri de automatizare a fluxului de lucru pentru clasificarea norului de puncte LiDAR utilizând limbajul de programare Python;
- Studiu comparativ al metodelor de clasificare a norului de puncte;
- Extragerea amprentelor la sol ale construcțiilor în produsul software ArcGIS Pro din imagini fotogrammetrice;
- Extragerea amprentelor la sol ale construcțiilor în produsul software ArcGIS Pro din norul de puncte LiDAR;
- Antrenarea unui model de DL pentru extragerea amprentelor la sol ale construcțiilor și implementarea acestuia;
- Realizarea unei propuneri de automatizare a fluxului de lucru pentru extragerea amprentelor la sol ale construcțiilor utilizând limbajul de programare Python;
- Studiu comparativ al metodelor de extragere a amprentelor la sol ale construcțiilor;
- Modelarea spațială 3D a unei zone în produsul software ArcGIS Pro;
- Propunerea unui set de reguli în limbajul de programare CGA pentru modelarea spațială 3D a unei zone;
- Modelarea spațială 3D a unei zone în produsul software CityEngine;
- Generarea modelelor 3D ale construcțiilor din Municipiul Baia Mare pe baza datelor open-source disponibile;
- Crearea unei aplicații ArcGIS Online de vizualizare a modelului 3D al orașului;
- Crearea unei aplicații VR de vizualizare a modelului 3D al orașului;
- Propunerea unui flux de lucru pentru reprezentarea spațială a imobilelor.

6.3. Perspective

În vederea continuării studiului din teza de doctorat, se pot realiza următoarele:

- Îmbunătățirea modelelor de DL antrenate prin extinderea zonelor cu datele de antrenare;
- Studiu privind îmbunătățirea metodelor de generare a modelelor 3D ale construcțiilor pe baza norilor de puncte LiDAR și identificarea unei metode de netezire a suprafețelor rezultate;
- Îmbunătățirea regulilor CGA de modelare, prin crearea unor reguli diferite pentru diferite tipuri de construcții;
- Modelarea spațială 3D a întregului municipiu Baia Mare pe baza datelor achiziționate prin tehnologiile prezentate pe parcursul tezei de doctorat;
- Completarea modelului 3D al Municipiului Baia Mare cu date legate de populație și de modul de gestionare a resurselor, pentru a contribui la realizarea unui oraș inteligent.

Referințe bibliografice

- 3D BAG Viewer. Disponibil la URL <https://3dbag.nl/en/viewer?lod=lod22&rdx=154956.97283040546&rdy=462911.66065216874&ox=53.01514268013125&oy=274.55557689257734&oz=-277.67738732388534> (accesat la 12.07.2023).
- About 3D | Boston Planning & Development Agency. Disponibil la URL <http://www.bostonplans.org/3d-data-maps/3d-smart-model/about-3d> (accesat la 27.05.2022).
- About Linear Regression | IBM . Disponibil la URL <https://www.ibm.com/topics/linear-regression> (accesat la 14.07.2023).
- About OpenStreetMap - OpenStreetMap Wiki. Disponibil la URL https://wiki.openstreetmap.org/wiki/About_OpenStreetMap (accesat la 07.09.2023).
- Art Collection. The Metropolitan Museum of Art. Disponibil la URL <https://www.metmuseum.org/art/the-collection> (accesat la 13.07.2023).
- Attaran, M., Celik, B.G., 2023. Digital Twin: Benefits, use cases, challenges, and opportunities, *Decision Analytics Journal* 6, 100165. <https://doi.org/10.1016/j.dajour.2023.100165>.
- Automate Building Footprint Extraction using Deep learning. ArcGIS API for Python. Disponibil la URL <https://developers.arcgis.com/python/samples/automate-building-footprint-extraction-using-instance-segmentation/> (accesat la 14.07.2023).
- Badea, A.C., Badea, G., 2022. Open Geospatial Data and Tools for Sustainable Cities - Advantages and Disadvantages, FIG Congress 2022, Warsaw, Poland.
- Biljecki, F., Ito, K., 2021. Street view imagery in urban analytics and GIS: A review. *Landscape and Urban Planning* 215, 104217. <https://doi.org/10.1016/j.landurbplan.2021.104217>.
- Biljecki, F., Ledoux, H., Stoter, J., 2016. An improved LOD specification for 3D building models. *Computers, Environment and Urban Systems* 59, 25–37. <https://doi.org/10.1016/j.compenvurbsys.2016.04.005>.
- Biljecki, F., Ledoux, H., Stoter, J., Zhao, J., 2014. Formalisation of the level of detail in 3D city modelling. *Computers, Environment and Urban Systems* 48, 1–15. <https://doi.org/10.1016/j.compenvurbsys.2014.05.004>.
- Biljecki, F., Stoter, J., Ledoux, H., Zlatanova, S., Çöltekin, A., 2015. Applications of 3D City Models: State of the Art Review. *ISPRS International Journal of Geo-Information* 4, 2842–2889. <https://doi.org/10.3390/ijgi4042842>.
- Billen, R., Cutting-Decelle, A., Marina, O., Almeida, J.-P., Caglioni, M., Falquet, G., Leduc, T., Métral, C., Moreau, G., Perret, J., Rabino, G., García, R., Yatskiv, I., Zlatanova, S., 2014. 3D City Models and urban information: Current issues and perspectives. *European COST Action TU0801*, 1-118. <https://doi.org/10.1051/TU0801/201400001>
- Building Footprint Extraction - USA - Overview. Disponibil la URL <https://sd-utcb.maps.arcgis.com/home/item.html?id=a6857359a1cd44839781a4f113cd5934> (accesat la 12.04.2022).
- Buildings. Disponibil la URL <https://terrasolid.com/guides/tscan/crbuildings.html> (accesat la 25.04.2023).

- By height from ground. Disponibil la URL <https://terrasolid.com/guides/tscan/crbyheightfromground.html> (accesat la 25.04.2023).
- Cai, M., Kassens-Noor, E., Zhao, Z., Colbry, D., 2023. Are smart cities more sustainable? An exploratory study of 103 U.S. cities. *Journal of Cleaner Production* 416, 137986. <https://doi.org/10.1016/j.jclepro.2023.137986>.
- Cecotti, H., 2022. Cultural Heritage in Fully Immersive Virtual Reality. *Virtual Worlds* 1, 82–102. <https://doi.org/10.3390/virtualworlds1010006>.
- CGA modeling overview—ArcGIS CityEngine Resources | Documentation. Disponibil la URL <https://doc.arcgis.com/en/cityengine/2020.1/help/help-cga-modeling-overview.htm> (accesat la 07.09.2023).
- Change LAS Class Codes (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/change-las-class-codes.htm> (accesat la 25.04.2023).
- Creating a street asset inventory from point clouds by using AI | PointlyAI. Disponibil la URL <https://pointly.ai/use-case/creating-a-sign-and-street-asset-inventory-from-point-clouds-by-using-ai/> (accesat la 14.07.2023).
- The automated labeling of point clouds from highway scans. 3D point cloud classification made smart, fast and easy | PointlyAI. Disponibil la URL <https://pointly.ai/use-case/the-automated-labeling-of-point-clouds-from-highway-scans/> (accesat la 14.07.2023).
- The new way of generating BIM models from 3D point clouds | PointlyAI. Disponibil la URL <https://pointly.ai/use-case/the-new-way-of-generating-bim-model-from-3d-point-clouds/> (accesat la 14.07.2023).
- CityGML | OGC. Disponibil la URL <https://www.ogc.org/standards/citygml> (accesat la 18.02.2022).
- Citywide 3D Model | Boston Planning & Development Agency. Disponibil la URL <http://www.bostonplans.org/3d-data-maps/3d-smart-model/citywide-3d-model> (accesat la 12.07.2023).
- Classify LAS Building (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/classify-las-building.htm> (accesat la 25.04.2023).
- Classify LAS By Height (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/classify-las-by-height.htm> (accesat la 25.04.2023).
- Classify LAS Ground (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/2.9/tool-reference/3d-analyst/classify-las-ground.htm> (accesat la 10.12.2022).
- crowdAI Mapping Challenge: Baseline, 2023. Disponibil la URL <https://github.com/crowdAI/crowdai-mapping-challenge-mask-rcnn> (accesat la 14.07.2023).
- Deep Learning with ArcGIS Pro Tips & Tricks: Part 2. ArcGIS Blog. Disponibil la URL <https://www.esri.com/arcgis-blog/products/arcgis-pro/imagery/deep-learning-with-arcgis-pro-tips-tricks-part-2/> (accesat la 01.05.2023).
- Descărcare LAKI MNT. Disponibil la URL <https://geoportal.ancpi.ro/portal/apps/webappviewer/index.html?id=3f34ee5af71c400396dda574f0d53274> (accesat la 14.07.2023).

- Descarcare TopRO50. Disponibil la URL <https://geoportal.ancpi.ro/portal/apps/webappviewer/index.html?id=6fcbd33e7ca64215985b478e94cbab64> (accesat la 14.07.2023).
- Detect Objects Using Deep Learning (Image Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/detect-objects-using-deep-learning.htm> (accesat la 01.05.2023).
- Deuber, M., Cavegn, S., Nebiker, S., 2014. Dense Image Matching - Performance Analysis on Oblique Imagery. GIM International 28, 23–25.
- Export Training Data For Deep Learning (Image Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/export-training-data-for-deep-learning.htm> (accesat la 01.05.2023).
- Fields. Disponibil la URL <https://terrasolid.com/guides/tscan/mwfields.html> (accesat la 25.04.2023).
- Geography Markup Language. Open Geospatial Consortium. Disponibil la URL <https://www.ogc.org/standard/gml/> (accesat la 12.07.2023).
- Goad, C.C., 1991. The Ohio State University Highway Mapping Project: The Positioning Component. Proceedings of the 47th Annual Meeting of The Institute of Navigation (1991), pp. 117–120.
- Goel, S., Kealy, A., Lohani, B., 2018. Development and Experimental Evaluation of a Low-Cost Cooperative UAV Localization Network Prototype. Journal of Sensor and Actuator Networks 7, 42. <https://doi.org/10.3390/jsan7040042>.
- Grădinaru, A.P., Badea, A.C., Dragomir, P.I., 2022a. Classifying LiDAR Point Cloud Using Bentley Microstation Terrasolid and Arcgis Pro Software Products, RevCAD 32/2022, 123-136.
- Grădinaru, A.P., Badea, A.C., Dragomir, P.I., 2022b. Using GIS Tools to Analyse Emergency and Civil Protection Situations Specific Issues, RevCAD 32/2022, 51-58.
- Grădinaru, A.P., 2022. Raport de cercetare II - Studiul tehnicilor de modelare spațială, Școala Doctorală a Universității Tehnice de Construcții, București.
- Grădinaru, A.P., Badea, A.C., Dragomir, P.I., Badea, G., 2023. Integrating Cadastral Data with Seismic Risk Data in an Online Building Database for the Historical Centre of Bucharest City. Land 12, 1594. <https://doi.org/10.3390/land12081594>.
- Gribov, A., 2019. Optimal Compression of a Polyline While Aligning to Preferred Directions, International Conference on Document Analysis and Recognition Workshops (ICDARW), 98–102. <https://doi.org/10.1109/ICDARW.2019.00022>.
- Gröger, G., Kolbe, T.H., Czerwinski, A., 2006. Candidate OpenGIS® CityGML Implementation Specification (City Geography Markup Language). Open Geospatial Consortium Inc.
- Ground. Disponibil la URL <https://terrasolid.com/guides/tscan/crground.html> (accesat la 25.04.2023).
- Guler, D., Yomralioglu, T., 2022. Reviewing the literature on the tripartite cycle containing digital building permit, 3D city modeling, and 3D property ownership. Land Use Policy 121, 106337. <https://doi.org/10.1016/j.landusepol.2022.106337>.

- Haring, A., 2007. Die Orientierung von Laserscanner- und Bilddaten bei der fahrzeuggestützten Objekterfassung. Technical University of Vienna.
- He, K., Gkioxari, G., Dollár, P., Girshick, R., 2018. Mask R-CNN. <https://doi.org/10.48550/arXiv.1703.06870>.
- He, N., Li, G., 2021. Urban neighbourhood environment assessment based on street view image processing: A review of research trends. *Environmental Challenges* 4, 100090. <https://doi.org/10.1016/j.envc.2021.100090>.
- Helsingin 3D-mallit. Disponibil la URL <https://kartta.hel.fi/3d/mesh/> (accesat la 27.05.2022).
- Helsinki 3D (2023). City of Helsinki. Disponibil la URL <https://www.hel.fi/en/decision-making/information-on-helsinki/maps-and-geospatial-data/helsinki-3d> (accesat la 12.07.2023).
- Home - IGI - Integrated Geospatial Innovations. Disponibil la URL <https://www.igi-systems.com/home.html> (accesat la 13.07.2023).
- Hosted layers—Portal for ArcGIS | Documentation for ArcGIS Enterprise. Disponibil la URL <https://enterprise.arcgis.com/en/portal/11.0/use/hosted-web-layers.htm> (accesat la 08.09.2023).
- Huisman, O., de By, R., 2009. Principles of geographic information systems: an introductory textbook, The International Institute for Geo-Information Science and Earth Observation, Enschede.
- Imobile eTerra - Public. Disponibil la URL <https://geoportal.ancpi.ro/imobile.html> (accesat la 18.07.2022).
- iXM-RS150F Camera, Phase One Geospatial. Disponibil la URL <https://geospatial.phaseone.com/cameras/ixm-rs150f/> (accesat la 26.05.2023).
- Jog, S., Dixit, M., 2016. Supervised classification of satellite images, in Conference on Advances in Signal Processing (CASP), 93–98. 10.1109/CASP.2016.7746144.
- Jovanović, D., Milovanov, S., Ruskovski, I., Govedarica, M., Sladić, D., Radulović, A., Pajić, V., 2020. Building Virtual 3D City Model for Smart Cities Applications: A Case Study on Campus Area of the University of Novi Sad. *ISPRS International Journal of Geo-Information* 9, 476. <https://doi.org/10.3390/ijgi9080476>.
- Kattenborn, T., Leitloff, J., Schiefer, F., Hinz, S., 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 173, 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>.
- Kelly, T., 2021. CityEngine: An Introduction to Rule-Based Modeling, Urban Informatics, The Urban Book Series. Springer, Singapore, 637–662. https://doi.org/10.1007/978-981-15-8983-6_35.
- Kolbe, T., Gröger, G., Plümer, L., 2005. CityGML - Interoperable access to 3D city models, *Geo-information for Disaster Management*, Springer, Delft, 883–889. https://doi.org/10.1007/3-540-27468-5_63.
- Kukko, A., Andrei, C.-O., Salminen, V.-M., Kaartinen, H., Chen, Y., Rönholm, P., Hyypä, H., Hyypä, J., Chen, R., Haggrén, H., Kosonen, I., Čapek, K., 2006. Road Environment Mapping System of the Finnish Geodetic Institute—FGI Roamer. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, 241–247.

- Kutzner, T., Chaturvedi, K., Kolbe, T.H., 2020. CityGML 3.0: New Functions Open Up New Applications. PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science 88, 43–61. <https://doi.org/10.1007/s41064-020-00095-z>.
- LAS Building Multipatch (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/las-building-multipatch.htm> (accesat la 02.09.2023).
- LAS Point Statistics As Raster (Data Management)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/data-management/las-point-statistics-as-raster.htm> (accesat la 18.07.2023).
- Leica Geosystems. Disponibil la URL <https://leica-geosystems.com/> (accesat la 13.07.2023).
- Lemmens, M., 2011. Terrestrial Laser Scanning, In: Geo-information. Geotechnologies and the Environment 5. Springer, Dordrecht, 101–121. https://doi.org/10.1007/978-94-007-1667-4_6.
- Li, B., Luo, Z., Mao, B., 2022. Non-photorealistic Visualization of 3D City Models using Visual Variables in Virtual Reality Environments. Procedia Computer Science, 9th International Conference on Information Technology and Quantitative Management 214, 1516–1521. <https://doi.org/10.1016/j.procs.2022.11.338>.
- Li, Y., Bu, R., Sun, M., Wu, W., Di, X., Chen, B., 2018. PointCNN: Convolution On X-Transformed Points, Advances in Neural Information Processing Systems 31. <https://doi.org/10.48550/arXiv.1801.07791>.
- Li, Z., Chen, J., Baltsavias, E., 2008. Advances in Photogrammetry, Remote Sensing and Spatial Information Sciences: 2008 ISPRS Congress Book. CRC Press, Beijing.
- Liu, J., Chen, N., Chen, Z., Xu, L., Du, W., Zhang, Y., Wang, C., 2022. Towards sustainable smart cities: Maturity assessment and development pattern recognition in China. Journal of Cleaner Production 370, 133248. <https://doi.org/10.1016/j.jclepro.2022.133248>
- Lv, Z., Li, X., Zhang, B., Wang, W., Zhu, Y., Hu, J., Feng, S., 2016. Managing Big City Information Based on WebVRGIS. IEEE Access 4, 407–415. <https://doi.org/10.1109/ACCESS.2016.2517076>.
- Upadhyay, N., 2013. Disponibil la URL https://www.gisresources.com/basic-of-photogrammetry_2/ (accesat la 13.07.2023).
- Miller, C., Abdelrahman, M., Chong, A., Biljecki, F., Quintana, M., Frei, M., Chew, M., Wong, D., 2021. The Internet-of-Buildings (IoB) -Digital twin convergence of wearable and IoT data with GIS/BIM. Journal of Physics Conference Series 2042, 12041. <https://doi.org/10.1088/1742-6596/2042/1/012041>
- Multipatches—ArcMap | Documentation. Disponibil la URL <https://desktop.arcgis.com/en/arcmap/latest/extensions/3d-analyst/multipatches.htm> (accesat la 03.09.2023).
- National Institute of Building Sciences buildingSMART alliance, 2015. National BIM Standard - United States® Version 3. Disponibil la URL <https://www.nibs.org/bimc> (accesat la 03.09.2023).
- Oberst, J., Gwinner, K., Preusker, F., 2014. Exploration and Analysis of Planetary Shape and Topography Using Stereophotogrammetry. The Encyclopedia of the Solar

- System, Third Edition, Elsevier, 1223–1233. <https://doi.org/10.1016/B978-0-12-415845-0.00057-8>
- Overview - 3D BAG. Disponibil la URL <https://docs.3dbag.nl/en/> (accesat la 02.09.2022).
- Overview of the ArcGIS API for Python. ArcGIS API for Python. Disponibil la URL <https://developers.arcgis.com/python/guide/overview-of-the-arcgis-api-for-python/> (accesat la 02.09.2023).
- P2006T By Tecnam: Affordable Twin Engine Aircraft for Sale, Tecnam Aircraft. Disponibil la URL <https://tecnam.com/aircraft/p2006t/> (accesat la 26.05.2023).
- Pang, H.E., Biljecki, F., 2022. 3D building reconstruction from single street view images using deep learning. *International Journal of Applied Earth Observation and Geoinformation* 112, 102859. <https://doi.org/10.1016/j.jag.2022.102859>.
- Pârvu, I.M., Picu, I.A.C., Dragomir, P.I., Poli, D., 2020. Urban Classification from Aerial and Satellite Images. *Journal of Applied Engineering Sciences* 10, 163–172. <https://doi.org/10.2478/jaes-2020-0024>.
- 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, 412–436. <https://doi.org/10.1080/22797254.2018.1444945>.
- Point cloud classification using PointCNN. ArcGIS API for Python. Disponibil la URL <https://developers.arcgis.com/python/guide/point-cloud-segmentation-using-pointcnn/> (accesat la 25.04.2023).
- Population growth. Understanding Global Change. Disponibil la URL <https://ugc.berkeley.edu/background-content/population-growth/> (accesat la 08.09.2023).
- Prepare Point Cloud Training Data (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/prepare-point-cloud-training-data.htm> (accesat la 25.04.2023).
- Products and Solutions | Trimble Geospatial. Disponibil la URL <https://geospatial.trimble.com/products-and-solutions> (accesat la 13.07.2023).
- Quintero, M.S., Van Genechten, B., De Bruyne, M., Poelman, R., Hankar, M., Barnes, S., Caner, H., Budei, L., Heine, E., Reiner, H., Lerma García, J.L., Biosca Taronger, J.M., 2008. *Theory and practice on Terrestrial Laser Scanning*. Universidad Politécnica de Valencia, Valencia.
- Raster to Polygon (Conversion)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/conversion/raster-to-polygon.htm> (accesat la 18.07.2023).
- Regularize Building Footprint (3D Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/regularize-building-footprint.htm> (accesat la 01.05.2023).
- Rezultate definitive: Caracteristici demografice – Recensământul Populației și Locuintelor. Disponibil la URL <https://www.recensamantromania.ro/rezultate-rpl-2021/rezultate-definitive-caracteristici-demografice/> (accesat la 08.09.2023).
- RIEGL - Produktdetail. Disponibil la URL <http://www.riegl.com/nc/products/airborne-scanning/produktdetail/product/scanner/72/> (accesat la 26.05.2023).

- Rohil, M.K., Ashok, Y., 2022. Visualization of urban development 3D layout plans with augmented reality. *Results in Engineering* 14, 100447. <https://doi.org/10.1016/j.rineng.2022.100447>.
- Rupnik, E., Nex, F., Remondino, F., 2014. Oblique Multi-Camera Systems - Orientation and Dense Matching Issues. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-3/W1. <https://doi.org/10.5194/isprsarchives-XL-3-W1-107-2014>.
- Samadzadegan, F., Ramzi, P., Schenk, T., 2008. Aerial Triangulation of Digital Aerial Imagery Using Hybrid Features. *The international Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37.
- Schrotter, G., Hürzeler, C., 2020. The Digital Twin of the City of Zurich for Urban Planning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 88, 99–112. <https://doi.org/10.1007/s41064-020-00092-2>.
- Schueren, M.. CityEngine Rule of the Week. *ArcGIS Blog*. Disponibil la URL <https://www.esri.com/arcgis-blog/products/3d-gis/3d-gis/cityengine-rule-of-the-week/> (accesat la 04.09.2023).
- Seitz, P., 2007. Photon-noise limited distance resolution of optical metrology methods, in: *Optical Measurement Systems for Industrial Inspection V*, SPIE, 109–118. <https://doi.org/10.1117/12.732040>.
- Soininen, A., 2022. TerraScan USER GUIDE.
- Solar Energy Potential. Disponibil la URL <https://kartta.hel.fi/3d/solar/#/> (accesat la 27.05.2022).
- Sun, T., Xu, Z., Yuan, J., Liu, C., Ren, A., 2017. Virtual Experiencing and Pricing of Room Views Based on BIM and Oblique Photogrammetry, *Procedia Engineering* 196, 1122-1129. <https://doi.org/10.1016/j.proeng.2017.08.071>.
- Tang, L., Ying, S., Li, L., Biljecki, F., Zhu, H., Zhu, Y., Yang, F., Su, F., 2020. An application-driven LOD modeling paradigm for 3D building models. *ISPRS Journal of Photogrammetry and Remote Sensing* 161, 194–207. <https://doi.org/10.1016/j.isprsjprs.2020.01.019>.
- Tao, V., Li, J., 2007. *Advances in Mobile Mapping Technology*, 1st edition. ISPRS Book Series. Taylor&Francis, London.
- Terrasolid UAV. Disponibil la URL <https://terrasolid.com/products/terrasolid-uav/> (accesat la 14.07.2023).
- Train Deep Learning Model (Image Analyst)—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm> (accesat la 01.05.2023).
- Use ModelBuilder—ArcGIS Pro | Documentation. Disponibil la URL <https://pro.arcgis.com/en/pro-app/latest/help/analysis/geoprocessing/modelbuilder/modelbuilder-quick-tour.htm> (accesat la 02.09.2023).
- Vexcel Imaging. Vexcel Imaging. Disponibil la URL <https://www.vexcel-imaging.com/> (accesat la 13.07.2023).
- Virtual Singapore, 2019. Dassault Systèmes. Disponibil la URL <https://www.3ds.com/insights/customer-stories/virtual-singapore> (accesat la 12.07.2023).
- Virtual Singapore. Disponibil la URL <https://www.sla.gov.sg/geospatial/gw/virtual-singapore> (accesat la 12.07.2023).

- VirtualcitySYSTEMS, 2017a. Disponibil la URL <https://kartta.hel.fi/3d/#/> (accesat la 27.05.2022).
- VirtualcitySYSTEMS, 2017b. Disponibil la URL <https://kartta.hel.fi/3d/atlas/#/> (accesat la 27.05.2022).
- Vosselman, G., Maas, H.-G., 2010. Airborne and Terrestrial Laser Scanning. Whittles Publishing, Dunbeath.
- VRpro.ro: HTC Vive Cosmos. Disponibil la URL <https://www.vrpro.ro/vive-cosmos> (accesat la 08.09.2023).
- Wang, H., Chen, X., Jia, F., Cheng, X., 2023. Digital twin-supported smart city: Status, challenges and future research directions. Expert Systems with Applications 217, 119531. <https://doi.org/10.1016/j.eswa.2023.119531>.
- Wang, W., Lv, Z., Li, X., Xu, W., Zhang, B., Zhang, X., 2015. Virtual Reality Based GIS Analysis Platform, in: Arik, S., Huang, T., Lai, W.K., Liu, Q. (Eds.), Neural Information Processing, Lecture Notes in Computer Science. Springer International Publishing, Cham, 638–645. https://doi.org/10.1007/978-3-319-26535-3_73.
- Wang, W., Lv, Z., Li, X., Xu, W., Zhang, B., Zhu, Y., Yan, Y., 2018. Spatial query based virtual reality GIS analysis platform. Neurocomputing, Query Understanding 274, 88–98. <https://doi.org/10.1016/j.neucom.2016.06.099>.
- Wasserman, D., 2023. What is the Complete Street Rule? Disponibil la URL https://github.com/d-wasserman/Complete_Street_Rule (accesat la 13.09.2023).
- Wei, G., He, B.-J., Sun, P., Liu, Y., Li, R., Ouyang, X., Luo, K., Li, S., 2023. Evolutionary trends of urban expansion and its sustainable development: Evidence from 80 representative cities in the belt and road initiative region. Cities 138, 104353. <https://doi.org/10.1016/j.cities.2023.104353>.
- Weil, C., Bibri, S.E., Longchamp, R., Golay, F., Alahi, A., 2023. Urban Digital Twin Challenges: A Systematic Review and Perspectives for Sustainable Smart Cities. Sustainable Cities and Society 99, 104862. <https://doi.org/10.1016/j.scs.2023.104862>.
- Wen, C., Li, X., Yao, X., Peng, L., Chi, T., 2021. Airborne LiDAR point cloud classification with global-local graph attention convolution neural network. ISPRS Journal of Photogrammetry and Remote Sensing 173, 181–194. <https://doi.org/10.1016/j.isprsjprs.2021.01.007>.
- What are Convolutional Neural Networks? | IBM. Disponibil la URL <https://www.ibm.com/topics/convolutional-neural-networks> (accesat la 14.07.2023).
- What are Neural Networks? | IBM. Disponibil la URL <https://www.ibm.com/topics/neural-networks> (accesat la 14.07.2023).
- What Is BIM | Building Information Modeling | Autodesk. Disponibil la URL <https://www.autodesk.com/industry/aec/bim> (accesat la 12.07.2023).
- What's the Difference Between AR and VR? 2020. Tulane School of Professional Advancement. Disponibil la URL <https://sopa.tulane.edu/blog/whats-difference-between-ar-and-vr> (accesat la 13.07.23).
- Wolf, P.R., Dewitt, B.A., Wilkinson, B.E., 2014. Elements of Photogrammetry with Applications in GIS, 4th Edition. McGraw-Hill Education.
- Xu, J., Shu, X., Qiao, P., Li, S., Xu, J.-G., 2023a. Developing a digital twin model for monitoring building structural health by combining a building information

- model and a real-scene 3D model. *Measurement* 217, 112955. <https://doi.org/10.1016/j.measurement.2023.112955>.
- Xu, J., Wang, C., Li, S., Qiao, P., 2023b. Emergency Evacuation Shelter Management and Online Drill Method Driven by Real Scene 3d Model. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4343148>
- Zhang, C., Lu, Y., 2021. Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration* 23, 100224. <https://doi.org/10.1016/j.jii.2021.100224>.
- Zhu, L., Hyypä, J., Kukko, A., Kaartinen, H., Chen, R., 2011. Photorealistic Building Reconstruction from Mobile Laser Scanning Data. *Remote Sensing* 3, 1406–1426. <https://doi.org/10.3390/rs3071406>.