

Facultatea de Geodezie
Departamentul de Topografie și Cadastru
Centrul de cercetare:
Măsurători geodezice inginerești și infrastructuri de date spațiale



RAPORT DE CERCETARE II

Studiul tehnicilor de modelare spațială



Conducător de doctorat

Prof. univ. dr. ing. Petre Iuliu DRAGOMIR

Studentă doctorand

Drd. ing. Anca Patricia GRĂDINARU

Cuprins

1.	Introducere.....	3
2.	Produse software și metode de modelare spațială 3D	5
2.1.	Metode de generare a modelelor spațiale 3D pe baza norilor de puncte.....	5
2.2.	Standardele CityGML	5
2.2.1.	Caracteristici generale	5
2.2.2.	Nivelul de detaliere	6
2.2.3.	Principii de modelare	7
2.3.	Produsul software ESRI ArcGIS CityEngine.....	9
2.3.1.	Caracteristici generale	9
2.3.2.	Principii de modelare	10
2.4.	Soluția Esri 3DCIM – 3D City Information Model	13
2.4.1.	Introducere	13
2.4.2.	Principii de modelare	14
2.5.	Produsul software de modelare spațială 3D <i>3dfier</i>	15
2.6.	Utilizarea produsului software ArcGIS Pro în modelarea spațială 3D	16
2.6.1.	Introducere	16
2.6.2.	Principii de modelare	16
2.6.3.	Explorarea posibilităților de modelare 3D în ArcGIS Pro pe baza datelor existente în aplicația eTerra 3 – Studiu de caz	18
2.7.	Utilizarea produselor software de tip CAD în modelarea spațială 3D	20
2.7.1.	Produsul software Autodesk 3ds Max	20
2.7.2.	Produsul software Autodesk Revit.....	21
2.7.3.	Produsul software Autodesk Civil 3D.....	21
3.	Modelarea spațială 3D pe baza imaginilor ortorectificate	22
3.1.	Introducere	22
3.2.	Extragerea elementelor din imagini utilizând tehnici de învățare automată (<i>Machine Learning</i>) 23	
3.2.1.	Algoritmul <i>Support-Vector Machine</i>	23
3.2.2.	Algoritmul <i>Random Forest</i>	25
3.3.	Extragerea elementelor din imagini utilizând rețelele neuronale artificiale.....	26
3.3.1.	Introducere	26
3.3.2.	Arhitectura rețelelor neuronale	27
3.3.3.	Rețelele neuronale convoluționale.....	28
3.4.	Obținerea modelelor 3D ale construcțiilor prin extragerea amprentelor la sol ale acestora cu algoritmul de învățare profundă implementat în ArcGIS Pro – Studiu de caz	29
4.	Concluzii	32
	Bibliografie.....	34

1. Introducere

Modelele care reprezintă elementele geometrice ale unui oraș într-un spațiu tridimensional se numesc modele 3D ale orașului și pot reda cu fidelitate mediul înconjurător. Datelor geometrice li se pot asocia și alte tipuri de date, precum date statistice, sociale, istorice etc., ducând la o abordare holistică a reprezentării spațiale a orașelor, precum și la o dezvoltare și un management sustenabile ale orașelor. Astfel, sunt create modelele semantice 3D, ce includ, pe lângă informațiile geometrice și informații semantice sau cunoștințe despre zona urbană reprezentată (Billen et al., 2014).

Necesitatea dezvoltării modelelor spațiale 3D ale orașelor este în permanentă creștere, acestea găsim și aplicabilitatea într-o mare varietate de domenii. Acestea permit, pe lângă vizualizare, realizarea unor serii de analize și obținerea unor date statistice. Într-un studiu realizat de Biljecki et al. (2015), se evidențiază utilitatea modelelor 3D ale orașelor într-un număr ridicat de domenii, precum estimarea radiației solare, estimarea necesarului de energie, poziționare, clasificarea clădirilor, îmbunătățirea metodelor de vizualizare, analize de vizibilitate, estimarea zonelor de umbră produse de clădiri, estimarea propagării zgomotului, cadastru 3D, planificare urbană, răspunsul în situațiile de urgență, estimarea populației, anticiparea dezastrelor, arheologie etc. (Figura 1.1). Datele necesare unor astfel de reprezentări sunt achiziționate prin diferite metode, precum scanarea laser, preluarea imaginilor fotogrammetrice, extrudarea amprentelor la sol ale construcțiilor, dar și modele și desene arhitecturale (Biljecki et al., 2015).




Figura 1.1. Exemple de aplicații ale modelelor spațiale 3D ale orașelor (Biljecki et al., 2015)

În ceea ce privește tehnicile de modelare spațială, în mod tradițional, modelele 3D ale orașelor necesitau un volum mare de muncă, ce consta în scanarea hărților și achiziția imaginilor digitale, obținerea amprentelor la sol ale construcțiilor și extrudarea manuală a acestora, în funcție de înălțimea fiecărei construcții, sau modelarea manuală a geometriilor 3D folosind produse software specializate. În prezent, pentru reducerea volumului de muncă și a timpului

investit, se folosesc produse software pentru generarea automată a modelelor 3D ale orașelor (Takase et al., 2003).

Un exemplu de reprezentare spațială 3D a clădirilor generată în mod automat poate fi 3D BAG (Figura 1.2). Acesta este un set de date deschise ce conține modele 3D ale clădirilor din Olanda, având trei grade diferite de detaliere și este permanent actualizat. Datele ce au dus la realizarea acestui model sunt obținute din *Registrul clădirilor și al adreselor* al Olandei (BAG), ce este un set de date referitoare la adresa fiecărei clădiri, precum și destinația și data construirii acesteia. Acest set de date este actualizat pe măsură ce se construiesc sau demolează clădiri. De asemenea, sunt preluate date din Modelul național de înălțime al Olandei (AHN), obținute prin scanare laser, cu o densitate medie de 8 puncte pe metru pătrat (Overview - 3D BAG).




Figura 1.2. Reprezentare 3D a construcțiilor în orașul Rotterdam, Olanda, din setul de date 3D Bag (Overview - 3D BAG)

Virtual Singapore (Figura 1.3) este un model tridimensional semantic și dinamic al orașelor din Singapore ce cuprinde informații detaliate precum textura obiectelor reprezentate, atributele terenului, vegetație, ape, transport, infrastructură, etc. Acesta este construit pe baza datelor geometrice 2D și a datelor de la diferite agenții publice (Virtual Singapore).



Figura 1.3. Modelul Virtual Singapore (Virtual Singapore - Building a 3D-Empowered Smart Nation - GWPrime)

Alegerea unei tehnici de modelare este în strânsă legătură cu gradul de detaliere necesar impus de scopul proiectului, dar și cu metoda de achiziție a datelor spațiale, precum scanarea laser sau metodele fotogrammetrice. În cadrul acestui raport, se vor studia diferite tehnici de modelare spațială 3D, ce utilizează date din diferite surse, precum norii de puncte sau imaginile ortorectificate, dar și diferite produse software ce permit crearea și vizualizarea acestor modele.

2. Produse software și metode de modelare spațială 3D

2.1. Metode de generare a modelelor spațiale 3D pe baza norilor de puncte

Conform Maas & Vosselman (1999), principalele metode de generare automată a modelelor 3D ale clădirilor plecând de la norii de puncte obținuți prin scanarea laser sunt: metode de generare a modelelor 3D bazate pe modele și metode de generare a modelelor 3D bazate pe date.

În cazul metodelor de generare a modelelor 3D bazate pe modele, sunt folosite primitivele, niște forme simple, descrise de un set de parametri, care se regăsesc într-o bibliotecă de modele. Astfel, pentru clădirile simple, se caută în biblioteca respectivă modelul cel mai apropiat de construcție și se calculează valorile cele mai probabile ale parametrilor. Pentru clădirile complexe, o metodă este segmentarea formei complexe a construcției în mai multe primitive, care se poate face pe baza liniilor de întrerupere ale acoperișului (Tarsha-Kurdi et al., 2007).

Metodele de generare a modelelor 3D bazate pe date pleacă de la premisa că orice construcție este un poliedru și presupun modelarea fără descompunerea construcției în mai multe primitive, analizând norul de puncte în întregime (Tarsha-Kurdi et al., 2007).

Într-un studiu comparativ al celor două metode, Tarsha-Kurdi et al. (2007) au concluzionat că principalul avantaj al metodei bazate pe modele este că permite obținerea rapidă a unor modele geometrice fără deformări din punct de vedere vizual, în timp ce metodele bazate pe date duc la modele 3D poliedrice, ce reprezintă cu mai multă fidelitate realitatea. Dezavantajul celor din urmă este acela că apar unele deformări vizuale, care pot fi reduse printr-o distribuție omogenă a norului de puncte și o densitate a punctelor potrivită, în strânsă legătură cu dimensiunea elementelor ce vor fi modelate.

2.2. Standardele CityGML

2.2.1. Caracteristici generale

Standardele CityGML definesc un model conceptual semantic și un mijloc de schimb al datelor pentru reprezentarea și stocarea modelelor spațiale 3D ale orașelor, contribuind la integrarea datelor geospațiale din zonele urbane într-un număr mare de aplicații. CityGML se bazează pe limbajul GML (Geography Markup Language), ce este un format XML utilizat pentru modelarea caracteristicilor geometrice (CityGML | OGC).

CityGML a fost dezvoltat încă din 2002 ca un model de date deschise și definește atât clasele de obiecte din mediul urban, cât și relațiile dintre acestea. Clasele de obiecte pot defini nu doar construcțiile, ci și vegetația, elevația, apele, precum și "mobilierul urban" (Gröger et al., 2008). Astfel, modelele 3D ale orașelor sunt reprezentate atât din punct de vedere geometric sau topologic, cât și prin baze de date ce conțin informații relevante despre zonele urbane reprezentate.

Modelul CityGML este alcătuit dintr-un modul de bază și o serie de extensii tematice. Modulul de bază cuprinde componentele esențiale ale modelului de date CityGML, iar pe baza acestuia fiecare extensie definește anumite modele spațiale 3D tematice, care pot fi utilizate în diferite

combinații alături de modulul principal, alcătuind *profile CityGML*. Principalele extensii tematice implementate de standardul CityGML sunt: *Appearance*, *Building*, *CityFurniture*, *CityObjectGroup*, *Generics*, *LandUse*, *Relief*, *Transportation*, *Vegetation*, *WaterBody* și *TexturedSurface* (Gröger et al., 2008).

În prezent, este implementat CityGML 3.0, care este o evoluție a celor două versiuni anterioare (1.0 și 2.0) și permite codificarea datelor atât în format GML/XML, cât și în format JSON (JavaScript Object Notation) sau schemă a bazei de date.

2.2.2. Nivelul de detaliere

Termenul de "nivel de detaliere" (LOD - *level of detail*) este folosit pentru a defini cât de complete sunt datele din alcătuirea modelului 3D (Biljecki et al., 2014), sau gradul de apropiere al modelului de realitatea din teren (Tang et al., 2020). Standardele CityGML 2.0 definesc 5 niveluri de detaliere (*Figura 2.1*), după cum urmează (Gröger et al., 2006):

- LOD0 este un model digital 2.5D al terenului, peste care poate fi suprapusă o imagine fotogrammetrică sau o hartă;
- LOD1 este un model ce cuprinde construcțiile reprezentate prin forme paralelipipedice, cu acoperișuri plate;
- LOD2 cuprinde, în plus, forme diferențiate ale acoperișurilor precum și suprafețe tematice și elemente de vegetație;
- LOD3 reprezintă modele arhitecturale cu elemente ale pereților, acoperișurilor și balcoanelor detaliate;
- LOD4 completează modelul LOD3 cu structurile interioare ale construcțiilor.




Figura 2.1. Gradele de detaliere ale standardului CityGML 2.0 (Kolbe et al., 2005)

Biljecki et al. (2016) au ajuns la concluzia că cele cinci niveluri de detaliere sunt insuficiente din perspectivă geometrică și au redefinit conceptul de LOD precum în *Figura 2.2*:




	LOD x.0	LOD x.1	LOD x.2	LOD x.3
LOD0	 LOD0.0	 LOD0.1	 LOD0.2	 LOD0.3
LOD1	 LOD1.0	 LOD1.1	 LOD1.2	 LOD1.3
LOD2	 LOD2.0	 LOD2.1	 LOD2.2	 LOD2.3
LOD3	 LOD3.0	 LOD3.1	 LOD3.2	 LOD3.3

Figura 2.2. Cele 16 niveluri de detaliere definite de Biljecki et al., 2016

Conform Biljecki et al. (2016), diferite tehnici de achiziție a datelor spațiale duc la reprezentări spațiale diferite ale obiectelor și implicit la un grad de detaliere diferit al modelelor obținute, deși conform standardelor CityGML 2.0, ele se încadrează în aceeași categorie. Studiul realizat de aceștia este concentrat asupra exteriorului construcțiilor și subliniază importanța conceptului de LOD în numeroase aplicații, pe lângă cea inițială de vizualizare, de unde reiese importanța fragmentării celor 5 grade de detaliere existente.

În cazul CityGML 3.0, conceptul de LOD a fost modificat astfel încât fiecare nivel de detaliere să cuprindă și o reprezentare a obiectelor interioare, iar LOD4 a fost exclus (Kutzner et al., 2020).

2.2.3. Principii de modelare

Un principiu de bază în modelarea conform standardelor CityGML este legătura coerentă dintre elementele geometrice/topologice și atributele acestora (Figura 2.3). Din punct de vedere semantic, entitățile sunt reprezentate prin diferite atribute și relații, iar din punct de vedere

spațial, obiectele sunt reprezentate de geometrii 3D. Astfel, modelul este împărțit în două structuri ierarhice: modelul semantic și modelul geometric (Stadler & Kolbe, 2012).




Figura 2.3. Construcție complexă cu structura spațio-semantică (Stadler & Kolbe, 2012)

Un alt aspect important al modelării este integrarea obiectelor 3D și a terenului pe care acestea se află. În unele cazuri, obiectele 3D sunt reprezentate deasupra terenului sau scufundate în acesta, iar pentru a rezolva această problemă este utilizată o curbă de intersecție cu terenul – *TerrainIntersectionCurve* (Figura 2.4), care sugerează linia de intersecție dintre teren și elementul reprezentat (Gröger et al., 2008). Acest aspect este foarte important în anumite analize, precum calculul radiației solare sau estimarea propagării zgomotului, unde doar obiectele situate pe suprafața terenului sunt relevante (Gröger & Plümer, 2012).

Obiectele care nu sunt relevante pentru scopul dorit nu sunt modelate printr-un volum 3D, ci sunt reprezentate cu ajutorul suprafețelor de închidere – *ClosureSurfaces* (Figura 2.4). De asemenea, acestea pot fi folosite și pentru reprezentarea obiectelor care nu se află la suprafața terenului, precum tunelurile sau pasajele subterane, care sunt necesare pentru efectuarea unor analize precum simulările de inundații (Gröger et al., 2008).




Figura 2.4. Modelarea unui tunel cu *TerrainIntersectionCurve* (roșu) și *ClosureSurfaces* (verde) (Kolbe et al., 2005)

Pentru a evita greșelile în clasificarea obiectelor prin intermediul atributelor și pentru a asigura interoperabilitatea datelor, sunt folosite liste de coduri externe – *ExternalCodeLists*, care sunt implementate cu ajutorul unor dicționare (în CityGML 3.1.1.: *Simple Dictionary Profile*) în care sunt incluse toate tipurile de attribute (Gröger et al., 2008).

Referințele externe (*External References*) sunt folosite pentru situațiile în care obiectele 3D reprezentate provin din seturi de date externe, de exemplu modele arhitecturale, sau există relații între acestea și anumite baze de date, de exemplu bazele de date cadastrale și sunt utile în special pentru actualizarea datelor (Gröger et al., 2008).

Pe lângă aspectele spațiale și semantice, obiectele 3D modelate sunt caracterizate și de niște proprietăți observabile ale suprafețelor exterioare (*Appearances*), care reprezintă atât texturile suprafețelor, cât și diferite teme precum radiația în infraroșu, poluarea fonică, etc. Acestea contribuie la îmbunătățirea vizualizării, dar și la procesele de analiză a datelor (Gröger & Plümer, 2012).

În unele situații, CityGML poate avea anumite limitări, motiv pentru care modelul este extins cu ajutorul unui mecanism ADE (*Application Domain Extensions*). Un astfel de mecanism permite adăugarea unor noi clase de obiecte, a unor noi attribute sau a unor noi geometrii standard pentru anumite clase de obiecte (Biljecki et al., 2021).

2.3. Produsul software ESRI ArcGIS CityEngine

2.3.1. Caracteristici generale

CityEngine este o aplicație dezvoltată de ESRI folosită pentru modelarea spațială 3D a zonelor urbane, pe baza datelor geospațiale importate în format Esri *geodatabase* (.gdb) sau *shapefile* (.shp) (*Advanced 3D City Design Software* | *ArcGIS CityEngine*).

La baza modelării cu produsul software CityEngine stă o abordare procedurală a etapelor de lucru, ceea ce conduce la creșterea eficienței procesului de modelare, eliminând interacțiunea manuală între utilizator și program prin introducerea unui cod alcătuit dintr-o serie de comenzi ce vor fi executate de către program. Limbajul de programare este *CGA shape grammar*, conceput special pentru generarea modelelor arhitecturale 3D. Ideea de bază este definirea unor reguli care se aplică în mod iterativ, generând mai multe detalii (*Figura 2.5*). Modelarea construcțiilor este realizată în următoarele etape (*About CityEngine—ArcGIS CityEngine Resources* | *Documentation*):

- Amprentele la sol ale construcțiilor sunt fie generate de CityEngine, fie importate;
- Utilizatorul selectează fișierul .cga cu regulile ce vor fi aplicate fie tuturor construcțiilor, fie individual;
- Utilizatorul poate porni procesul de modelare prin aplicarea regulilor stabilite asupra geometriilor selectate;
- Pentru editarea modelului rezultat, se pot edita regulile aplicate, sau modifica parametri unor construcții individuale;
- După finalizarea procesului de modelare, rezultatul poate fi exportat.



Figura 2.5. Procesul iterativ de definire a detaliilor construcțiilor în softul CityEngine
(About CityEngine—ArcGIS CityEngine Resources | Documentation)

2.3.2. Principii de modelare

Datele de intrare necesare în modelarea cu produsul software CityEngine, după cum reiese și din studiul realizat de Turksever (2015) pot fi: modelul digital al terenului (DTM), sau modelul digital de elevație (DEM), în format *TIFF*, axele drumurilor, având geometriile de tip *linie* și un tabel de atribute ce conține denumirile străzilor, tipurile de drumuri, trotuare, limite de viteză, etc., amprente la sol ale construcțiilor, având geometriile de tip *poligon* și tabelul de atribute ce poate cuprinde tipurile de construcții, înălțimile construcțiilor, numărul de niveluri, zonele cu vegetație și ape, etc..

În cadrul procesului de modelare, sunt folosite diferite unelte care alcătuiesc fluxul de lucru reprezentat în Figura 2.6. În prima etapă, sunt importate datele necesare și se generează rețeaua de drumuri. Zonele delimitate de drumuri sunt apoi divizate pentru crearea loturilor pe care se situează construcțiile, urmând apoi generarea geometriilor construcțiilor (Parish & Müller, 2001).




Figura 2.6. Mecanismul de generare al modelelor 3D cu produsul software CityEngine
(About CityEngine—ArcGIS CityEngine Resources | Documentation)

Pentru crearea rețelei de drumuri pot fi importate fișiere în format DXF, GDB, OSM sau Shapefile, ce conțin segmente de străzi (linie) și nodurile rețelei (Turksever, 2015). Pentru aceasta, există unealta *Grow streets* care permite, pe lângă crearea unei noi rețele de străzi, extinderea rețelelor existente. Algoritmul permite diferențierea între străzile mai mari, care închid un cvartal și străzile mai mici, din interiorul acestora (Generation of street networks—ArcGIS CityEngine Resources | Documentation). Există trei tipuri de șabloane ale rețelelor de străzi, reprezentate în Figura 2.7.




Figura 2.7. Tipuri de rețele de străzi ce pot fi reprezentate cu produsul software CityEngine (Parish & Müller, 2001)

Pentru adaptarea rețelei de străzi la modelul digital al elevației (Figura 2.8), trebuie să fie selectat terenul, iar funcția de adaptare să fie activată (Generation of street networks—ArcGIS CityEngine Resources | Documentation).




Figura 2.8. Adaptarea rețelei de străzi la elevația terenului în CityEngine (Generation of street networks—ArcGIS CityEngine Resources | Documentation)

Alte instrumente ce pot fi folosite sunt *Edit street/curves* (pentru editarea lățimii străzii și a trotuarelor, precum și a curburii acestora), *Cleanup streets* (pentru unirea segmentelor de străzi și crearea nodurilor la intersecția acestora), *Align streets to terrain* (pentru alinierea rețelei cu layer-urile de hărți ce au elevația definită), *Generate Bridges* (utilă în cazul modelelor ce nu dispun de date despre elevație și este necesar să se reprezinte 3D diferite pasaje), *Fit widths to shapes* (pentru seturile de date ce nu conțin atribute care definesc lățimile străzilor) sau *Simplify graph* (pentru transformarea poliliniilor cu multe puncte de inflexiune în linii mai lungi, curbate).

Pentru modelarea construcțiilor, se pot importa amprente la sol ale acestora în format *shapefile*, însoțite de atribute ce definesc înălțimea clădirilor (Turkseven, 2015). Pentru modelarea acestora, se importă fișierul în format *.cga*, ce conține regulile ce vor fi aplicate. Procesul este unul iterativ, ceea ce înseamnă că în fiecare etapă este preluată o geometrie și modificată pentru obținerea unei noi geometrii. În crearea fișierului *.cga* se pot pune condiții legate de înălțimile construcțiilor (*attr minheight=...*, *attr maxheight=...*) sau de extrudarea amprentelor la sol ale construcțiilor în funcție de înălțimea stabilită (*lot --> extrude*) (Work with rules—ArcGIS CityEngine Resources | Documentation).

Operații ce se pot efectua cu geometriile importate sunt: (Figura 2.9) *Extrusion* (pentru extrudarea geometriei la o înălțime dată), *Transformation* (plasează, orienează și dimensionează geometria), *Component split* (împarte o geometrie în mai multe componente), *Subdivision split* (împarte geometria de-a lungul unor axe), *Insert assets* (încarcă diferite elemente și le inserează în modelul creat) (Essential shape operations overview—ArcGIS CityEngine Resources | Documentation).




Figura 2.9. Operații ce se pot efectua cu geometriile importate în CityEngine (Essential shape operations overview—ArcGIS CityEngine Resources | Documentation)

Pentru aplicarea texturilor fațadelor și acoperișurilor clădirilor, se pot utiliza diferite imagini cu fațadele sau imagini satelitare pentru acoperișuri, imagini ce se regăsesc și în bibliotecile Esri.

Rezultatele obținute în urma procesului de modelare pot fi exportate într-un format *CityEngine WebScene*, vizualizate și distribuite online prin intermediul *CityEngine web viewer*, în formatul *.3ws* (Figura 2.10).




Figura 2.10. Model 3D vizualizat în CityEngine Web Viewer (CityEngine Web Viewer - Kisumu3D)

2.4. Soluția Esri 3DCIM – 3D City Information Model

2.4.1. Introducere

Modelul informațional 3D al orașului (3DCIM – 3D City Information Model) este un model dezvoltat de Esri pentru managementul, analiza și vizualizarea datelor (Figura 2.11). Modelele 3D ale orașelor pot fi aduse în ArcGIS și CityEngine și pot fi utilizate într-o gamă largă de aplicații. 3DCIM și CityGML sunt complementare și interoperabile (Maren, 2014).



Figura 2.11. Soluția Esri 3DCIM (Maren, 2014)

2.4.2. Principii de modelare

Modelul 3DCIM este compatibil cu standardele CityGML și cu formatul datelor necesar pentru a asigura interoperabilitatea modelelor. Din perspectiva conținutului, modelul 3DCIM cuprinde trei teme de bază (Reitz & Schubiger-Banz, 2014):

- **Mediul construit** (Figura 2.12) – alcătuit din caracteristici și rețele precum structuri (clădiri, poduri, tunele), elementele de interior ale construcțiilor, instalații (hidranți, stâlpi, coșuri de gunoi, suporturi pentru biciclete), rețele de utilități, de transporturi, etc.; elementul *Building* reprezintă amprenta la sol a construcției și conține cele mai multe atribute, *BuildingShell* este folosit pentru reprezentarea 3D a corpului construcției, iar *BuildingShellParts* este folosit în procesul de separare a diferitelor elemente precum acoperișuri sau pereți (Reitz et al., 2014);




Figura 2.12. Mediul construit în 3DCIM (Reitz et al., 2014)

- **Mediul legal** (Figura 2.13) – cuprinde elemente de zonare urbană, reglementări (de exemplu înălțimea maximă admisă a construcțiilor) și limitele proprietăților;




Figura 2.13. Mediul legal în 3DCIM (Reitz et al., 2014)

În acest scop, există și aplicația ArcGIS Urban, care permite transformarea digitală a orașului și planificarea regională (*Planificare și proiectare urbană—Planificare Urbană Inteligentă | ArcGIS Urban*).

- **Mediul natural** (Figura 2.14) – cuprinde caracteristici naturale precum acoperirea terenurilor cu zone de vegetație sau ape, dar și structuri geologice, atmosferă, vreme sau climat.




Figura 2.14. Mediul natural în 3DCIM (Reitz et al., 2014)

2.5. Produsul software de modelare spațială 3D 3dfier

Produsul software 3dfier este o soluție open-source de modelare spațială 3D dezvoltat de un grup de cercetători din cadrul Universității de Tehnologie Delft, bazat pe un proces automatizat de reconstrucție a obiectelor 3D. Acesta folosește date geografice 2D, reprezentate prin poligoane, iar pe baza unui nor de puncte se obțin elevația și elementele semantice necesare extrudării geometriilor 2D (Figura 2.15). Scopul final este obținerea unor suprafețe fără erori, fără suprapuneri și fără goluri (Ledoux et al., 2021).

Datele de intrare utilizate în modelare sunt poligoane 2D ce reprezintă clădiri, lacuri, drumuri, etc. și puncte de elevație, obținute de obicei prin scanare laser, în format LAS, sau extrase din imagini fotogrammetrice. Fiecare poligon 2D este atribuit unei clase specifice: *Terrain*, *Forest*, *Water*, *Road*, *Building*, *Bridge/Overpass* și *Separation* (pentru pereți sau garduri). Datele semantice corespunzătoare fiecărui poligon sunt folosite pentru obținerea unei geometrii 3D prin extrudare. Geometriile obținute sunt unite pentru a alcătui o singură suprafață, lipsită de goluri și de suprapuneri (Ledoux et al., 2021).




Figura 2.15. Modelarea spațială 3D cu produsul software 3dfier (Ledoux et al., 2021)

2.6. Utilizarea produsului software ArcGIS Pro în modelarea spațială 3D

2.6.1. Introducere

ArcGIS Pro este o aplicație GIS care permite integrarea, vizualizarea, editarea, analiza și distribuirea datelor geospațiale, în spațiile 2D, 3D sau 4D, fiind compatibilă cu o serie de alte produse ArcGIS, precum ArcGIS Online sau ArcGIS Enterprise (2D, 3D & 4D GIS Mapping Software | ArcGIS Pro).

2.6.2. Principii de modelare

În cadrul ArcGIS Pro, datele sunt stocate într-o bază de date geospațiale, ce poate cuprinde entități de tip vector, raster sau atribut (*Figura 2.16*). Datele de tip vector sunt stocate pe straturi tematice numite clase de elemente (*feature classes*). Acestea reprezintă o colecție de obiecte spațiale ce au aceeași geometrie (punct, linie sau poligon), aceleași atribute și același sistem de coordonate de referință. Un *Feature Dataset* reprezintă o colecție de clase de elemente, ce sunt stocate împreună și au aceeași referință spațială. O clasă de elemente care stochează date textuale sau reprezentări care redau informații despre obiectele spațiale se numește *Annotation* (ArcGIS Pro Resources | Tutorials, Documentation, Videos & More).




Figura 2.16. Tipuri de obiecte în GIS (ArcGIS Pro Resources | Tutorials, Documentation, Videos & More)

Datele de tip raster (*Figura 2.17*) sunt stocate în seturi de date raster, fiecare imagine fiind stocată pe un strat tematic. Seturile de date raster pot fi stocate în mai multe formate, precum TIFF, MrSid, ESRI Grid, etc. Datele raster pot servi drept hartă de bază pentru zona ce urmează a fi modelată (ArcGIS Pro Resources | Tutorials, Documentation, Videos & More).




Figura 2.17. Imagine raster în ArcGIS Pro (ArcGIS Pro Resources | Tutorials, Documentation, Videos & More)

În cadrul ArcGIS Pro, prin intermediul șablonului *Local Scene*, se poate crea o scenă 3D a proiectului, într-un sistem de coordonate proiectat, în care nu este necesar să se ia în considerare curbura Pământului. O scenă locală cu obiecte 3D poate fi utilizată în reprezentarea și vizualizarea obiectelor precum clădirile sau modele 3D ale orașelor. Pentru editarea 3D a construcțiilor (Figura 2.18), se poate converti amprenta clădirii într-o caracteristică *multipatch*. Se pot utiliza date din nori de puncte LiDAR pentru a obține înălțimile corecte ale construcțiilor. Se poate importa un nor de puncte în ArcGIS Pro, fie în format *ASCII*, fie în format *LAS*, pe baza căruia se pot reprezenta diferite construcții sau detalii ale acestora. În cadrul reprezentării, poate fi modificată simbologia, sau pot fi adăugate texturi elementelor, pentru o reprezentare cât mai realistă. Texturile se pot adăuga din tab-ul *Edit*, cu funcția *Multipatch texture*. Pentru reprezentarea construcțiilor, se pot adăuga texturi din lumea reală, pentru fațadele construcțiilor și pentru acoperiș (Badea, 2020).




Figura 2.18. Editarea construcțiilor în ArcGIS Pro (Model realizat în cadrul cursului de Sisteme Informatic Geografice, Universitatea Tehnică de Construcții București, Școala Doctorală)

În cadrul procesului de modelare, se pot folosi atât date geospațiale obținute de utilizator prin diferite tehnici de achiziție, cât și date existente în catalogul on-line – Living Atlas – care cuprinde diferite date, hărți sau aplicații create de utilizatori ArcGIS din întreaga lume. Datele disponibile pot fi imagini fotogrammetrice, hărți de bază, date demografice, limite administrative, linii de transport, sisteme urbane, hărți istorice, sau observații asupra Pământului (cutremure, incendii, vreme, etc.) (*The ArcGIS Book | The ArcGIS Book*).

Pentru cazurile în care datele preluate nu sunt complete, valorile care lipsesc pot fi interpolate pe baza datelor culese din aceeași zonă. Există diferite metode de interpolare – de exemplu funcția *Kriging* – alese în funcție de datele disponibile și obiectele sau fenomenele modelate (*The ArcGIS Book | The ArcGIS Book*).

2.6.3. Explorarea posibilităților de modelare 3D în ArcGIS Pro pe baza datelor existente în aplicația eTerra 3 – Studiu de caz

Zona de studiu aleasă este un complex de blocuri din orașul Bragadiru (*Figura 2.19*).




Figura 2.19. Zona de studiu (Google Maps)

Datele inițiale au fost preluate din aplicația eTerra3 și reprezintă: amprentele la sol ale construcțiilor, adresa și numărul de niveluri ale construcțiilor, în funcție de care s-a aproximat înălțimea, considerându-se că înălțimea unui nivel este de 2,75 m.

Pentru a putea extruda amprentele la sol ale construcțiilor, am importat în format .shp fișierul cu acestea, iar stratul creat a fost mutat în zona de straturi 3D (*Figura 2.20*). În tabelul de attribute am adăugat următoarele câmpuri noi: Număr_de_niveluri, Înălălțime_etaj, Înălălțime_construcție, Adresă. După ce am populat tabelul cu datele preluate din aplicația eTerra3, cu funcția *Field Calculator* am determinat înălălțimea aproximativă a fiecărei construcții. Rezultatul se poate observa în *Figura 2.21*.




Figura 2.20. Ampretele la sol ale construcțiilor importate în ArcGIS Pro

constructii

Field:

Add

Calculate

Selection:

Select By Attributes

Zoom To

Switch

Clear

Delete

Copy

FID	Shape	LAYER	GM_TYPE	Numar_de_niveluri	Inaltime_constructie	Inaltime_etaj	Adresa
0	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	8	22	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. C 3
1	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	9	24.75	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. D5
2	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	10	27.5	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. D4
3	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	11	30.25	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. D3
4	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	8	22	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. C4, Sc. 1
5	Polygon	CONSTRUCTII_ACTIVE	Unknown Area Type	8	22	2.75	Loc. Bragadiru, Str Prelungirea Ghencea, Nr. 45, Bl. C4, Sc. 1

Click to add new row.

Figura 2.21. Tabelul de atribute al stratului cu amprente la sol ale construcțiilor

Pentru extrudarea geometriilor construcțiilor, am folosit funcția *Extrusion*, alegând câmpul *Înălțime_construcție*. Modificarea simbologiei a fost făcută alegând simbolul *stacked*, care împarte textura construcțiilor în funcție de înălțime la numărul de niveluri, iar rezultatul se poate vedea în *Figura 2.22*.




Figura 2.22. Rezultatul extrudării amprentelor la sol ale construcțiilor

ArcGIS Pro permite și adăugarea de marcaje, pentru a facilita navigarea pe hartă (*Figura 2.23*).




Figura 2.23. Marcaje în ArcGIS Pro

2.7. Utilizarea produselor software de tip CAD în modelarea spațială 3D

2.7.1. Produsul software Autodesk 3ds Max

Soluția Autodesk 3ds Max este un produs software de modelare ce se pretează atât realizării modelelor spațiale 3D ale construcțiilor (*Figura 2.24*), structurilor și elementelor interioare ale acestora, cât și realizării de modele 3D din animații sau jocuri video (*3ds Max Software | Get Prices & Buy Official 3ds Max 2022*).




Figura 2.24. Model 3D al unei construcții, realizat în produsul software Autodesk 3ds Max (Autodesk, 2008)

Pentru a modela diferite obiecte, se poate pleca de la primitive implementate în software, sau se pot folosi forme 2D, în general de tip *spline*, care pot fi extrudate pentru obținerea unor volume. (Autodesk, 2008)

Funcția *Building Object Style Editor* permite generarea modelelor 3D pornind de la amprente la sol ale construcțiilor. Se poate stabili un anumit stil al construcțiilor pentru o multitudine de construcții, prin asocierea unei etichete (*shape label masks*). Din fereastra *Edit Style Element* (*Figura 2.25*) se pot modifica atributele precum denumirea elementului creat, *Pick Shape Label* (alegerea unei primitive), *Building Height* (înălțimea construcției), *Number of Floors* (numărul de etaje), *Floor Height* (înălțimea fiecărui etaj), *Wall Mapping Style* (stabilește modul în care se aplică textura), *Wall Material ID* (stabilește identificatorul materialului asociat

pereților) (*3ds Max 2022 Help | Building Object Style Editor | Autodesk*).




Figura 2.25. Fereastra Edit Style Element în Autodesk 3ds Max (3ds Max 2022 Help | Building Object Style Editor | Autodesk)

2.7.2. Produsul software Autodesk Revit

Revit este un produs Autodesk BIM (Building Informational Model), folosit pentru generarea cu acuratețe a modelelor spațiale ale construcțiilor (*Figura 2.26*), în domenii precum design-ul arhitectural, inginerie civilă, instalații, etc. (*Revit Software | Get Prices & Buy Official Revit 2022 | Autodesk*).




Figura 2.26. Model 3D al unei construcții realizat în Autodesk Revit (Revit Software | Get Prices & Buy Official Revit 2022 | Autodesk)

Produsul software Autodesk Revit este specializat pe design-ul arhitectural și are implementate diferite opțiuni de design, care permit explorarea diferitelor posibile aspecte ale construcțiilor, în modelul 3D al acestora (*Revit Software | Get Prices & Buy Official Revit 2022 | Autodesk*).

2.7.3. Produsul software Autodesk Civil 3D

Autodesk Civil 3D este o soluție care permite crearea de BIM, având caracteristici ce facilitează design-ul și documentarea. Datele inițiale pot fi atât geometrii reprezentate de polilinii închise, cât și nori de puncte obținuți prin scanare laser. Rezultatele modelării pot fi exportate în formate compatibile cu ArcGIS.

Modelarea suprafețelor se poate face prin combinații de elemente de tip punct, linii și contururi, rezultând diferite tipuri de suprafețe precum suprafețe TIN - *Triangular Irregular Networks*, formate prin triangulație (*Figura 2.27-b.*) sau suprafețe GRID, formate din puncte ce alcătuiesc o rețea (*Figura 2.27-a.*) (*Civil 3D Features | 2022, 2021 Features | Autodesk*).

Se poate folosi și extensia *Autodesk Dynamo for Civil 3D*, care permite automatizarea procesului de modelare, prin crearea unui set de reguli ce vor fi scrise într-un limbaj de programare vizuală (VLS - *Visual Programming Language*) și aplicate (*About | The Dynamo Primer*).




Figura 2.27. Suprafețe de tip a. GRID și b. TIN (Rahman et al., 2010)

3. Modelarea spațială 3D pe baza imaginilor ortorectificate

3.1. Introducere

Clasificarea imaginilor (Figura 3.1) presupune împărțirea pe categorii și etichetarea grupurilor de pixeli sau vectori dintr-o imagine, pe baza unui set de reguli specifice. Regulile de clasificare pot fi concepute pe baza uneia sau mai multor caracteristici spectrale sau texturale. Metodele principale de clasificare sunt: clasificare supervizată și clasificare nesupervizată (Gavali & Banu, 2019).

Clasificarea nesupervizată este realizată într-un mod în totalitate automat, prin intermediul unor algoritmi specifici, în timp ce clasificarea supervizată presupune selectarea manuală a eșantioanelor (seturi de date de instruire) din imagine și atribuirea acestora unor categorii prestabilite, precum drumuri, clădiri, corpuri de apă, vegetație, etc., ducând la obținerea unor măsuri statistice ce se aplică imaginii în întregime (Gavali & Banu, 2019).

Există diferite tehnici de clasificare a imaginilor, precum clasificarea cu ajutorul rețelelor neuronale, algoritmi de tip *Support vector machine* sau *Random Forest*, logica Fuzzy, algoritmi genetici, etc. (Gavali & Banu, 2019).

Diferiți factori pot afecta rezultatele procesului de clasificare a imaginilor, precum alegerea metodei de clasificare, disponibilitatea produselor software specifice, dar și complexitatea terenului din zona de studiu. Un pas esențial în clasificarea imaginilor este preprocesarea datelor inițiale, ce poate include detectarea și recuperarea liniilor deformate, rectificarea geometrică, calibrarea radiometrică, aplicarea corecției atmosferice și a corecțiilor topografice (Lu, 2007).

În prezent, principalele metode de clasificare se bazează pe tehnici de învățare automată – *Machine learning*, o aplicație bazată pe inteligență artificială (AI - *Artificial Intelligence*), care cuprinde algoritmi ce analizează datele, învață din acestea și aplică ceea ce au învățat în luarea deciziilor (*Deep Learning vs. Machine Learning*, 2020).



Figura 3.1. Imagine ortorectificată (în partea stângă) și rezultatul clasificării imaginii (în partea dreaptă): roșu-construcție, verde închis-copac, verde deschis-vegetație joasă, gri-suprafață impermeabilă, galben-mașini (Höhle, 2017)

3.2. Extragerea elementelor din imagini utilizând tehnici de învățare automată (*Machine Learning*)

3.2.1. Algoritmul *Support-Vector Machine*

Support Vector machine (SVM) este unul dintre cei mai folosiți algoritmi de clasificare supervizată a imaginilor. Calitatea rezultatelor procesului de clasificare cu SVM depinde de acuratețea clasificării, derivată din eșantioanele alese în etapa de instruire și de acoperirea asigurată de acestea. Redundanța datelor poate încetini procesul de instruire, utilizând și o parte mai mare din memorie (Aslani & Seipel, 2020).

Metoda SVM presupune folosirea unui set de date de instruire, pe baza căruia algoritmi vor împărți setul de date în mai multe clase, în concordanță cu eșantioanele alese inițial. Datele vor fi separate astfel prin intermediul unor *hiperplane* de separare optime, care reprezintă, de fapt, limita de decizie dintre caracteristicile diferitelor clase (Maulik & Chakraborty, 2017).

În Figura 3.2, punctele albastre și triunghiurile roșii reprezintă două clase de elemente, reprezentate prin caracteristicile x și y , iar linia neagră reprezintă limita de decizie (un *hiperplan* reprezentat în spațiul 2D). Algoritmul SVM preia datele și creează limita cea mai potrivită care le separă pe acestea în două categorii distincte.




Figura 3.2. Clasificarea prin algoritmul SVM (Support Vector Machines (SVM) Algorithm Explained, 2017)

În algoritmul SVM, hiperplanul optim este considerat cel care ia în considerare distanța maximă față de caracteristicile claselor, adică limita cea mai mare (Support Vector Machines (SVM) Algorithm Explained, 2017).




Figura 3.3. Clasificarea unei imagini (partea stângă) prin algoritmul SVM, obținându-se amprente la sol ale construcțiilor (partea dreaptă) (Aslani & Seipel, 2020)

Datele inițiale folosite pentru obținerea geometriilor construcțiilor prin clasificarea imaginilor cu algoritmul SVM (Figura 3.3) pot fi imagini ortorectificate, date LiDAR, amprente la sol ale construcțiilor, nori de puncte derivați pe baza imaginilor fotogrammetrice oblice prin *Dense Image Matching*, etc. (Aslani & Seipel, 2020).

3.2.2. Algoritmul *Random Forest*

Algoritmul de clasificare *Random Forest* este un algoritm de clasificare supervizată ce se bazează pe o combinație de arbori de decizie. Acesta selectează date aleatorii din setul de date inițiale, generează un arbore de decizie pentru fiecare eșantion, iar fiecare arbore acordă un vot unitar pentru cea mai populară clasă (Breiman, 1999). În final, pentru alocarea unui pixel într-o anumită clasă, algoritmul selectează cel mai votat rezultat ca predicție finală (Figura 3.4).

În procesul de instruire, arborii sunt creați prin extragerea unui subset de date de instruire, prin înlocuire; astfel, un eșantion poate fi selectat de mai multe ori, iar altele pot să nu fie selectate deloc. În jur de două treimi din eșantioane sunt folosite în procesul de instruire, iar restul sunt utilizate pentru estimarea performanței clasificării (Belgiu & Drăguț, 2016).

Sunt necesari doi parametri pentru a genera arborii: numărul de arbori de decizie (*Ntree*) și numărul de variabile ce vor fi selectate și testate pentru generarea arborilor (*Mtry*). Numărul de arbori poate fi oricât de mare este necesar, însă studiile au arătat că în jurul valorii de 500, erorile de clasificare se vor stabiliza. Numărul de variabile se stabilește, de regulă, ca radical din numărul de variabile de intrare (Belgiu & Drăguț, 2016).




Figura 3.4. Clasificarea cu algoritmul *Random Forest* (Chauhan, 2021)

În clasificarea semantică a imaginilor pentru extragerea geometriei construcțiilor (Figura 3.5), algoritmul *Random Forest* se remarcă prin capacitatea de a utiliza un volum ridicat de date de eșantionare.




Figura 3.5. Rezultatele unei clasificări cu algoritmul Random Forest (Du et al., 2015)

3.3. Extragerea elementelor din imagini utilizând rețelele neuronale artificiale

3.3.1. Introducere

Rețelele neuronale au numeroase aplicații în diferite domenii precum matematică, fizică, statistică, sau inginerie, fiind utilizate pentru modelarea fenomenelor. O rețea neuronală artificială este un sistem de procesare a informației, similară rețelei neuronale biologice, care are ca și componentă de bază un neuron artificial asemănător unui neuron biologic și are următoarele caracteristici (Yadav, 2015):

- Procesarea informației se realizează prin conexiuni simple numite neuroni (*Figura 3.6*);
- Semnalele sunt transferate între neuroni prin legături de conexiune;
- Fiecărei legături de conexiune îi este asociată o anumită putere, care multiplică semnalul transmis;
- O funcție de activare este aplicată semnalului de intrare net de către fiecare neuron, pentru a-i determina semnalul de ieșire.

Fiecare neuron primește unul sau mai multe semnale de intrare prin conexiunile denumite și sinapse și produce un singur semnal de ieșire (Yadav, 2015).




Figura 3.6. Structura unui neuron artificial (Yadav, 2015)

3.3.2. Arhitectura rețelelor neuronale

Structura rețelelor neuronale este dată de algoritmul folosit în procesul de instruire. Există trei tipuri de arhitecturi ale rețelelor neuronale (Haykin, 2008):

- *Rețele Feedforward uni-strat (Figura 3.7.a)*: reprezintă cea mai simplă formă de rețea neuronală și presupune un strat de intrare de noduri-sursă, care este proiectat într-un strat de ieșire de neuroni, dar nu și invers;
- *Rețele Feedforward multi-strat (Figura 3.7.b)*: sunt caracterizate de prezența unuia sau mai multor straturi ascunse, ale căror noduri de calcul sunt denumite neuroni ascunși sau unități ascunse;
- *Rețele recurente (Figura 3.7.c)*: spre deosebire de rețelele *Feedforward*, acestea sunt caracterizate de cel puțin o buclă de feedback.




Figura 3.7. Tipuri de arhitecturi ale rețelelor neuronale (Haykin, 2008)

3.3.3. Rețelele neuronale convoluționale

Termenul de *Deep learning* (învățare profundă) se referă la rețelele neuronale artificiale multi-strat. Una dintre cele mai folosite rețele neuronale artificiale profunde este Rețeaua neuronală convoluțională (*Convolutional Neural Network* – CNN). O caracteristică importantă a acestui tip de rețea este faptul că determinările făcute nu sunt dependente de poziția în spațiu a obiectelor, adică acestea pot fi identificate indiferent de poziția lor în imagine (Albawi et al., 2017).

Metodele *Deep learning* s-au dovedit a fi foarte eficiente în procesul de segmentare semantică a imaginilor, odată cu apariția rețelelor neuronale FCN (*Fully Convolutional Networks*), caracterizate de un număr redus de parametri ce permite reducerea timpului necesar procesului de instruire (Long et al., 2015).

SegNet este o rețea neuronală de tip FCN, bazată pe o arhitectură de tip codare-decodare (*Figura 3.8*) care generează date de ieșire având aceeași rezoluție ca datele de intrare.




Figura 3.8. Arhitectura rețelei neuronale SegNet (Audebert et al., 2017)

În *Figura 3.9* este prezentat un exemplu de clasificare utilizând rețeaua neuronală SegNet, în care cu alb sunt reprezentate drumurile, cu albastru – clădirile, cu cyan – vegetația joasă, cu verde – copacii și cu galben – mașinile.




Figura 3.9. Imagine (stânga-fals color) clasificată (dreapta) utilizând rețeaua neuronală SegNet (Audebert et al., 2017)

3.4. Obținerea modelelor 3D ale construcțiilor prin extragerea amprentelor la sol ale acestora cu algoritmul de învățare profundă implementat în ArcGIS Pro – Studiu de caz

Produsul software ArcGIS Pro include instrumente ce utilizează Inteligența Artificială și metode de învățare profundă (*Deep Learning*) pentru extragerea caracteristicilor din imagini. Pentru aceasta, este necesară instalarea în ArcGIS Pro a bibliotecilor de învățare profundă (*Deep Learning Libraries Installers for ArcGIS*, 2020/2022).

În Living Atlas există, de asemenea, diferite modele de extragere a amprentelor la sol ale construcțiilor pe baza imaginilor satelitare. În cazul de față, am folosit modelul *Building Footprint Extraction – USA*, bazat pe o rețea neuronală convoluțională cu o arhitectură de tip Mask R-CNN (*Building Footprint Extraction - USA - Overview*).

Zona de studiu este un cartier rezidențial din Municipiul Craiova (*Figura 3.10*).




Figura 3.10. Zona de studiu

Instrumentul de geoprocesare *Detect Objects Using Deep Learning* aplică asupra unei imagini raster un model de învățare profundă indicat, având ca rezultat o nouă clasă de caracteristici ce conține obiectele identificate în imagine.

Pentru setarea parametrilor (*Figura 3.11*), ca strat de intrare am ales stratul cu imaginea raster, iar stratul de ieșire va fi stratul ce conține amprentele la sol ale construcțiilor extrase din imagine. Sistemul de coordonate a fost setat să fie preluat din Scena creată, adică sistemul Stereo 70, iar pentru zona de lucru am ales extinderea curentă a ecranului. De asemenea, funcția permite alegerea tipului de procesor utilizat pentru segmentarea imaginii și anume: CPU (*central processing unit* – procesorul) sau GPU (*graphics processing unit* – placa video).




Figura 3.11. Setarea parametrilor pentru funcția Detect Objects Using Deep Learning




Figura 3.12. Rezultatul segmentării imaginilor cu funcția Detect Objects Using Deep Learning în ArcGIS Pro

Rezultatul segmentării imaginii se poate observa în Figura 3.12. Ampretele la sol ale construcțiilor extrase din imagine nu sunt drepte, iar pentru le îndrepta am folosit instrumentul

de geoprocesare *Regularize* (Figura 3.13), alegând ca strat de intrare stratul obținut anterior, ca strat de ieșire noul strat cu amprente la sol ale construcțiilor îndreptate, iar ca metodă *Right Angles*, pentru a obține geometrii cu unghiuri drepte.




Figura 3.13. Setarea parametrilor pentru funcția *Regularize*

Rezultatul final al extragerii amprentelor la sol ale construcțiilor pe baza imaginilor satelitare prin algoritmul de învățare profundă implementat în ArcGIS Pro se poate observa în Figura 3.14.




Figura 3.14. Rezultatul extragerii amprentelor la sol ale construcțiilor pe baza imaginilor satelitare prin algoritmul de învățare profundă implementat în ArcGIS Pro

Pe baza numărului de niveluri ale construcțiilor, s-a estimat înălțimea acestora (Figura 3.15).

Craiova_V2_Clip_DetectObject6_REG										
Field: Add Calculate Selection: Select By Attributes Zoom To Switch Clear Delete Copy										
	OID *	Class	Confidence	Shape *	ORIG_OID	STATUS	Shape_Length	Shape_Area	Numar_niveluri	Inaltime_constructie
2	2	1	98.450643	Polygon	2	0	50.204581	146.25	3	7.5
3	3	1	97.37879	Polygon	3	0	50.204581	147	3	7.5
4	4	1	96.599132	Polygon	4	0	49.497475	145	3	7.5
5	5	1	98.201215	Polygon	5	0	52.325902	163	3	7.5
6	6	1	97.797024	Polygon	6	0	50.911688	154.875	3	7.5
7	7	1	97.222275	Polygon	7	0	50.204581	147.5	3	7.5

Figura 3.15. Tabelul de atribute ale stratului de construcții

Cu funcția *Extrusion* au fost extrudate amprentele la sol ale construcțiilor, în funcție de înălțimea acestora, iar rezultatul se poate observa în Figura 3.16.




Figura 3.16. Extrudarea amprentelor la sol ale construcțiilor

4. Concluzii

Scopul acestui raport de cercetare a fost analiza principalelor metode și produse software de modelare spațială 3D a imobilelor, în contextul creșterii necesității pentru dezvoltarea modelelor spațiale 3D ale orașelor.

Sursele de date necesare în generarea modelelor 3D ale orașelor sunt variate și pot fi nori de puncte, imagini ortorectificate, amprente la sol ale construcțiilor, date de elevație etc. În funcție de disponibilitatea acestor date, putem alege o metodă și un produs software de modelare optime. Din imaginile fotogrammetrice se pot obține geometriile construcțiilor prin diferite procedee de *machine learning* și *deep learning*, iar norii de puncte, amprente la sol ale construcțiilor, datele de elevație pot reprezenta baza unor modele 3D realizate cu produse software de tip GIS sau CAD.

Standardele CityGML creează o bază pentru numeroase aplicații de modelare 3D, asigurând interoperabilitatea dintre acestea. CityGML cuprinde cinci grade de detaliere, care definesc completitudinea datelor din alcătuirea modelului 3D. Modelul propus de Esri – 3DCIM (3D City Information Model) este o bază de date geospațiale ce asigură posibilitatea de gestionare a datelor și permite schimbul de date între acesta și modelul CityGML, cele două fiind interoperabile. Datelor geospațiale le sunt asociate atribute, împreună alcătuind un model semantic al orașului.

Produsele software precum Autodesk 3ds Max, Revit și Civil 3D se pretează, în general, aplicațiilor de design, sau de BIM, însă rezultatele acestora pot fi folosite pentru completarea datelor existente și îmbunătățirea modelelor 3D ale orașelor.

Formatul datelor suportat este, de asemenea, un factor important, ce asigură integrarea datelor în mai multe tipuri de aplicații. Astfel, metodele și produsele software descrise permit importul și exportul de date în mai multe tipuri de formate, precum .dxf, .shp, .ascii, .xml, .gdb, .tiff, etc.

Automatizarea procesului de modelare este un factor foarte important, în special dacă se lucrează cu un volum mare de date. În cazul metodelor de generare a modelelor spațiale 3D pe baza norilor de puncte, putem vorbi despre metode bazate pe modele, care folosesc primitivele descrise într-o bibliotecă, sau metode bazate pe date, care analizează norul de puncte în întregime, fără a descompune construcția în primitive. În cazul generării modelelor 3D pe baza imaginilor ortorectificate, am identificat diferiți algoritmi de învățare automată, precum algoritmul *Support Vector Machine* sau algoritmul *Random Forest*, folosiți pentru clasificarea imaginilor. Pe lângă aceștia, o altă metodă de actualitate folosită pentru clasificarea imaginilor este utilizarea rețelelor neuronale artificiale, care reduc timpul necesar întregului proces.

Produsul software ArcGIS Pro s-a remarcat prin faptul că înglobează o serie de posibilități de modelare 3D pornind de la diferite surse de date, inclusiv norii de puncte 3D și imaginile fotogrammetrice.

Din studiile de caz se remarcă faptul că pentru a obține un grad de detaliere mai ridicat, este necesară achiziția datelor spațiale prin tehnici de scanare laser, norul de puncte oferind posibilitatea de modelare a detaliilor precum acoperișurile și terasele. Datele despre construcții existente în aplicația eTerra3 pot contribui la obținerea unor modele 3D având un nivel de detaliere mai scăzut, însă acestea nu oferă o acoperire suficientă.

În urma studiului realizat, propun să se aibă în vedere crearea la nivel național a unei baze de date deschise care să conțină diferite tipuri de atribute referitoare la construcții precum anul construirii, numărul de niveluri, înălțimea, destinația construcției, suprafață, adresă, sau alte date relevante la care publicul larg poate avea acces. Această bază de date poate fi utilă în domenii precum estimarea radiației solare, estimarea necesarului de energie, poziționare, clasificarea clădirilor, îmbunătățirea metodelor de vizualizare, analize de vizibilitate, estimarea zonelor de umbră produse de clădiri, estimarea propagării zgomotului, planificare urbană, răspunsul în situațiile de urgență, estimarea populației, anticiparea dezastrelor, arheologie etc.

În concluzie, având în vedere datele inițiale de care dispunem, sau posibilitățile de achiziție a acestora, gradul de detaliere impus de scopul proiectului, dar și tipul de aplicație ce necesită modelarea 3D a imobilelor, pot fi alese metode și produse software optime, pentru obținerea unor modele spațiale 3D ale imobilelor în concordanță cu cerințele de acuratețe ale proiectului.

Bibliografie

1. *2D, 3D & 4D GIS Mapping Software | ArcGIS Pro*. Preluat în 9 martie 2022, din <https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview>
2. *3ds Max 2022 Help | Building Object Style Editor | Autodesk*. Preluat în 29 martie 2022, din <https://help.autodesk.com/view/3DSMAX/2022/ENU/?guid=GUID-6D823C77-D233-4FD4-89BC-FAE2F7EAA785>
3. *3ds Max Software | Get Prices & Buy Official 3ds Max 2022*. Preluat în 29 martie 2022, din <https://www.autodesk.com/products/3ds-max/overview>
4. *About | The Dynamo Primer*. Preluat în 4 aprilie 2022, din <https://primer.dynamobim.org/en/>
5. *About CityEngine—ArcGIS CityEngine Resources | Documentation*. Preluat în 22 februarie 2022, din <https://doc.arcgis.com/en/cityengine/latest/get-started/get-started-about-cityengine.htm>
6. *Advanced 3D City Design Software | ArcGIS CityEngine*. Preluat în 22 februarie 2022, din <https://www.esri.com/en-us/arcgis/products/arcgis-cityengine/overview>
7. *ArcGIS Pro Resources | Tutorials, Documentation, Videos & More*. Preluat în 9 martie 2022, din <https://www.esri.com/en-us/arcgis/products/arcgis-pro/resources>
8. Aslani, M., & Seipel, S. (2020). A fast instance selection method for support vector machines in building extraction. *Applied Soft Computing*, 97, 106716. <https://doi.org/10.1016/j.asoc.2020.106716>
9. Audebert, N., Saux, B., & Lefèvre, S. (2017). Beyond RGB: Very High Resolution Urban Remote Sensing With Multimodal Deep Networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140. <https://doi.org/10.1016/j.isprsjprs.2017.11.011>
10. Autodesk. (2008). Understanding 3ds Max. În Autodesk (Ed.), *Learning Autodesk 3ds Max 2008 Foundation* (pp. 13–37). Focal Press. <https://doi.org/10.1016/B978-0-240-80927-4.50010-0>
11. Badea, A. C. (2020). *Note de curs, disciplina "Sisteme Informatice Geografice"*. Universitatea Tehnică de Construcții București, Școala Doctorală.
12. Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
13. 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>

14. 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>
15. Biljecki, F., Lim, J., Crawford, J., Moraru, D., Tauscher, H., Konde, A., Adouane, K., Lawrence, S., Janssen, P., & Stouffs, R. (2021). Extending CityGML for IFC-sourced 3D city models. *Automation in Construction*, 121, 103440. <https://doi.org/10.1016/j.autcon.2020.103440>
16. 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(4), 2842–2889. <https://doi.org/10.3390/ijgi4042842>
17. Billen, R., Cutting-Decelle, A., Marina, O., Almeida, J.-P., Cagliioni, 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*. <https://doi.org/10.1051/TU0801/201400001>
18. Breiman, L. (1999). *1 RANDOM FORESTS--RANDOM FEATURES*. <http://citeseerx.ist.psu.edu/viewdoc/citations;jsessionid=0822AD486441F0148CAFA1C643FF8F20?doi=10.1.1.367.9714>
19. *Building Footprint Extraction—USA - Overview*. Preluat în 12 aprilie 2022, din <https://sd-utcb.maps.arcgis.com/home/item.html?id=a6857359a1cd44839781a4f113cd5934>
20. Chauhan, A. (2021, februarie 23). Random Forest Classifier and its Hyperparameters. *Analytics Vidhya*. <https://medium.com/analytics-vidhya/random-forest-classifier-and-its-hyperparameters-8467bec755f6>
21. *CityEngine Web Viewer—Kisumu3D*. Preluat în 22 februarie 2022, din <https://www.arcgis.com/apps/CEWebViewer/viewer.html?&3dWebScene=e2981d2427eb4be28ecb7270adb6fcb3&view=694978.69,6.1,-9988257,694117.5,899.59,-9987554,0.5&lyr=1,1,1,1,0,0,1,1,1,1,1,0,0,0,0,0&wkid=32736&v=2>
22. *CityGML | OGC*. Preluat în 18 februarie 2022, din <https://www.ogc.org/standards/citygml>
23. *Civil 3D Features | 2022, 2021 Features | Autodesk*. Preluat în 29 martie 2022, din <https://www.autodesk.com/products/civil-3d/features>
24. *Deep Learning Libraries Installers for ArcGIS*. (2022). Esri. https://github.com/Esri/deep-learning-frameworks/blob/f7c3d45b195e42bead5eba0caf41d7507abbf511/README.md?rmedium=links_esri_com_b_d&rsource=https%3A%2F%2Flinks.esri.com%2Fdeep-learning-framework-install (Original work published 2020)
25. *Deep learning vs. machine learning: What's the difference?* (2020, ianuarie 23). Zendesk. <https://www.zendesk.com/blog/machine-learning-and-deep-learning/>

26. Du, S., Zhang, F., & Zhang, X. (2015). Semantic classification of urban buildings combining VHR image and GIS data: An improved random forest approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 107–119. <https://doi.org/10.1016/j.isprsjprs.2015.03.011>
27. *Essential shape operations overview—ArcGIS CityEngine Resources | Documentation*. Preluat în 22 februarie 2022, din <https://doc.arcgis.com/en/cityengine/latest/help/help-essential-shape-operations-overview.htm>
28. Gavali, P., & Banu, J. S. (2019). Chapter 6—Deep Convolutional Neural Network for Image Classification on CUDA Platform. În A. K. Sangaiah (Ed.), *Deep Learning and Parallel Computing Environment for Bioengineering Systems* (pp. 99–122). Academic Press. <https://doi.org/10.1016/B978-0-12-816718-2.00013-0>
29. *Generation of street networks—ArcGIS CityEngine Resources | Documentation*. Preluat în 22 februarie 2022, din <https://doc.arcgis.com/en/cityengine/latest/help/help-grow-a-street.htm>
30. Gröger, G., Kolbe, T., Czerwinski, A., & Nagel, C. (2008). *OpenGIS® City Geography Markup Language (CityGML) Encoding Standard*. Open Geospatial Consortium Inc.
31. Gröger, G., Kolbe, T. H., & Czerwinski, A. (2006). *Candidate OpenGIS® CityGML Implementation Specification (City Geography Markup Language)*. Open Geospatial Consortium Inc.
32. Gröger, G., & Plümer, L. (2012). CityGML – Interoperable semantic 3D city models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 71, 12–33. <https://doi.org/10.1016/j.isprsjprs.2012.04.004>
33. Haykin, S. (2008). *Neural Networks and Learning Machines*. Prentice Hall.
34. Höhle, J. (2017). Generating Topographic Map Data from Classification Results. *Remote Sensing*, 9, 224. <https://doi.org/10.3390/rs9030224>
35. Kolbe, T., Gröger, G., & Plümer, L. (2005). CityGML - Interoperable access to 3D city models. *Geo-information for Disaster Management*. https://doi.org/10.1007/3-540-27468-5_63
36. 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(1), 43–61. <https://doi.org/10.1007/s41064-020-00095-z>
37. Ledoux, H., Biljecki, F., Dukai, B., Kumar, K., Peters, R., Stoter, J., & Commandeur, T. (2021). 3dfier: Automatic reconstruction of 3D city models. *Journal of Open Source Software*, 6(57), 2866. <https://doi.org/10.21105/joss.02866>
38. Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431–3440. <https://doi.org/10.1109/CVPR.2015.7298965>

39. Lu, D. (2007). A Survey of Image Classification Methods and Techniques for Improving Classification Performance. *International Journal of Remote Sensing*, 28, 823–870. <https://doi.org/10.1080/01431160600746456>
40. Maas, H.-G., & Vosselman, G. (1999). Two algorithms for extracting building models from raw laser altimetry data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2), 153–163. [https://doi.org/10.1016/S0924-2716\(99\)00004-0](https://doi.org/10.1016/S0924-2716(99)00004-0)
41. Maren, G. van. (2014, decembrie 16). Lossless CityGML support in ArcGIS. *ArcGIS Blog*. <https://www.esri.com/arcgis-blog/products/3d-gis/3d-gis/lossless-citygml-support-in-arcgis/>
42. Maulik, U., & Chakraborty, D. (2017). Remote Sensing Image Classification: A survey of support-vector-machine-based advanced techniques. *IEEE Geoscience and Remote Sensing Magazine*, 5, 33–52. <https://doi.org/10.1109/MGRS.2016.2641240>
43. Overview—3D BAG. Preluat în 9 februarie 2022, din <https://docs.3dbag.nl/en/>
44. Parish, Y. I. H., & Müller, P. (2001). Procedural modeling of cities. in *Proceedings of the 28th Annual Conference on Computer Graphics and Interactive Techniques*, 301–308.
45. Planificare și proiectare urbană—Planificare Urbană Inteligentă | ArcGIS Urban. Preluat în 6 aprilie 2022, din <https://www.esri.com/ro-ro/arcgis/products/arcgis-urban/overview>
46. Rahman, A., Sunar, M. S., Zamri, M. N., & Shaari, N. (2010). *Terrain Rendering on GPU*.
47. Reitz, T., McCabe, C., Morrish, S. W., & Sims, B. (2014). ArcGIS for 3D Cities: An Introduction. *An Introduction*, 56.
48. Reitz, T., & Schubiger-Banz, T. (2014). The Esri 3D city information model. *IOP Conference Series: Earth and Environmental Science*, 18.
49. Revit Software | Get Prices & Buy Official Revit 2022 | Autodesk. Preluat în 29 martie 2022, din <https://www.autodesk.com/products/revit/overview>
50. S. Albawi, T. A. Mohammed, & S. Al-Zawi. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
51. Stadler, A., & Kolbe, T. (2012). *Spatio-semantic coherence in the integration of 3D city models*. 36.
52. *Support Vector Machines (SVM) Algorithm Explained*. (2017, iunie 22). MonkeyLearn Blog. <https://monkeylearn.com/blog/introduction-to-support-vector-machines-svm/>
53. Takase, Y., Sho, N., Stone, A., & Shimiya, K. (2003). Automatic Generation of 3D City Models and Related Applications. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIV-5/W10.

54. 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.
55. Tarsha-Kurdi, F., Landes, T., Grussenmeyer, P., & Koehl, M. (2007). Model-driven and data-driven approaches using LIDAR data: Analysis and comparison. *ISPRS Workshop*, 87–92. <https://halshs.archives-ouvertes.fr/halshs-00264846>
56. *The ArcGIS Book | The ArcGIS Book*. Preluat în 9 martie 2022, din <https://learn.arcgis.com/en/arcgis-book/>
57. Turksever, S. (2015). *3D MODELING WITH CITY ENGINE*. <https://doi.org/10.13140/RG.2.2.30548.30085>
58. *Virtual Singapore*. Preluat în 9 februarie 2022, din <https://www.nrf.gov.sg/programmes/virtual-singapore>
59. *Virtual Singapore—Building a 3D-Empowered Smart Nation—GWPrime*. Preluat în 9 februarie 2022, din <https://www.gwprime.geospatialworld.net/case-study/virtual-singapore-building-a-3d-empowered-smart-nation/>
60. *Work with rules—ArcGIS CityEngine Resources | Documentation*. Preluat în 22 februarie 2022, din <https://doc.arcgis.com/en/cityengine/latest/help/help-working-with-rules.htm>
61. Yadav, N. (2015). *An Introduction to Neural Network Methods for Differential Equations*. <https://doi.org/10.1007/978-94-017-9816-7>