

Pontfelhőszűrési és -szegmentálási módszerek

HRUTKA Bence Péter

DOI: 10.30921/GK.75.2023.5.2

Absztrakt: A napjainkban széles körben terjedő pontfelhőt alkotó eszközöket, mint például a földi és légi lézerszenkennereket, különböző mobil térképező rendszereket, illetve pilóta nélküli légi járműveket rutinszerűen használjuk a földmérésben és számos kapcsolódó mérnöki területen. A felmérések eredményeként előállított, több száz millió pontból álló pontfelhők feldolgozása viszont nem mindig egyszerű feladat. A sokszor idő- és hardverigényesnek tűnő manuális feldolgozás mellett ma már lehetőségünk van különböző korszerű matematikai módszereken (pl. iteratív robusztus becslésen), gépi tanuláson (pl.: sűrűség alapú klaszterezésen, neurális hálózatokon) alapuló pontfelhő-szegmentáló, -osztályozó eljárások alkalmazására is. Ezek a megoldások a pontfelhőből közvetett módon meghatározható információkat használnak fel, mint például a pontsűrűség, a normálvektorok iránya, vagy a különböző saját értékeken alapuló jellemzők. A cikkben a különböző – attribútumalapú, élalapú, modellalapú, régió növelésen, és gépi tanuláson alapuló – szegmentációs módszereket mutatom be, emellett kitérek ezek gyakorlati alkalmazására is. Több példán keresztül mutatom be, hogy a nyers pontfelhőből meghatározható jellemzők hogyan hasznosíthatóak különböző feladatok elvégzésénél, mint például a tető- és falpontok elhatárolása, talajpontok szűrése vagy pontthalmazok automatizált elkülönítése. A bemutatott módszerek az adott feladattól függően számos esetben kínálhatnak megoldást a pontfelhők hatékony feldolgozására.

Abstract: State-of-the-art instruments such as terrestrial and airborne laser scanners, various mobile mapping systems, and unmanned aerial vehicles are used daily in surveying and other related areas. However, processing point clouds consisting of hundreds of millions of points is complex. In addition to manual processing, which is more often than not rather time-consuming and hardware dependent, it is possible to apply point cloud segmentation and classification methods based on various advanced mathematical methods (e.g. sequential RANdom SAMple Concesus), Machine Learning (e.g. Density-Based Spatial Clustering of Applications with Noise, neural networks), which use hidden information derived from a point cloud, just to name but a few, point density, the direction of normal vectors, or features based on different eigenvalues. In addition to presenting different point cloud segmentation methods, such as attribute-based, edge-based, region growing-based, model fitting-based, and machine learning-based techniques, this paper discusses their practical applications too. Through a couple of examples, I show the different features that can be determined from the raw point clouds and how these can be used to perform various tasks, such as roof and wall point separation, ground point filtering, or point cloud clustering. The presented methods can offer solutions for efficient point cloud processing.

Kulcsszavak: pontfelhő, szegmentálás, osztályozás, RANSAC, gépi tanulás, automatizált feldolgozás

Keywords: point cloud, segmentation, classification, RANSAC, machine learning, automated processing

1. Bevezetés

A napjainkban végzett geodéziai tevékenység esetében, ha mérésekről beszélünk, akkor kétféle megközelítés létezik. A hagyományos esetben a geodéziai mérés során a feladat szempontjából releváns pontok koordinátáinak meghatározása történik, például felméréshez (Lovas et al. 2018), mozgásvizsgálathoz (Siki et al. 2013), próbaterheléshez (Joó et al. 2022). Ilyenkor a mérés során kell döntenünk, hogy melyek azok az adatok, pontok, amelyek az irodai feldolgozás, majd a későbbi végtermék előállítására szempontjából relevánsak. Az utóbbi évtizedekben ez a hagyományos szemléletmód egyre inkább átalakul, illetve kiegészül. A széles körben terjedő pontfelhőt alkotó technikák (Lovas et al. 2013), mint például a drón (Unmanned Aerial

Vehicle – UAV) fotogrammetria, földi lézerszenkennerek (Terrestrial Laser Scanner – TLS), vagy éppen mobil térképező rendszerek (Mobile Mapping System – MMS) miatt egy-egy terepi adatgyűjtés során nagy mennyiségű adatot tudunk előállítani viszonylag rövid idő alatt. A mérésekből a releváns pontok kiválasztása az irodában történik meg (Takács-Lovas 2023). Sok esetben tévesen úgy gondoljuk, hogy a pontfelhő egy-egy kiragadott pontja egyenértékű a hagyományos módszerekkel mért ponttal, de ez általában nem igaz. A pontfelhő pontjait együttesen kell értelmezni, majd felhasználni a különböző termékek előállítására során.

A pontfelhőtechnikák esetén az igazán kényes kérdések az irodai feldolgozás során dőlnek el. A felmérések során előállított nagy mennyiségű adat manuális feldolgozása idő-

és hardverigényes feladat, és sokszor a mérés eredményeként előállított pontfelhő pontjainak csak töredékét fogjuk végtermékként használni. Számos olyan félautomatizált, illetve teljesen automatizált megoldás létezik, amelyek nagyban segítik a pontfelhők előfeldolgozását és kiértékelését. A következőkben ezek közül mutatom be a legfontosabb módszereket néhány lehetséges alkalmazással együtt.

2. Pontfelhő-szegmentálás

A pontfelhők szegmentálása az automatizált feldolgozás építőköveként megkerülhetetlen témakörnek számít. A pontfelhők a pontok 3D-s koordinátáin kívül számos egyéb közvetlen (pl. szín) és közvetett (pl. pontsűrűség egy pont adott sugarú környezetében) módon meghatározható attribútummal, információval rendelkezhetnek.

A pontfelhő-szegmentálás lényegében ezeknek az információknak a felhasználásával történő csoportosításról, majd szétválogatásról szól. Egy adott ponthalmaznak azokat a pontjait keressük, amelyek tulajdonságai valamilyen módon összetartoznak. (Nguyen et al. 2013; Grilli et al. 2017).

Attól függően, hogy a részekre osztást milyen elven végezzük el, a szegmentálási módszereket a következőképpen csoportosíthatjuk:

- attribútumalapú módszerek,
 - élalapú módszerek,
 - régiönövelésen alapuló módszerek
 - modellalapú módszerek,
 - gépi tanuláson alapuló módszerek.
- A következő alfejezetekben ezeket a szegmentációs módszereket mutatom be. Az egyes módszerek átfogó ismertetése mellett kitérek egy-két módszer speciális alkalmazási lehetőségére is. Ezeket később esettanulmányok formájában, példákon keresztül is bemutatom.

2.1 Attribútumalapú szegmentáció

Az attribútumalapú (attribute-based) módszerek a pontfelhő pontjaihoz rendelt tulajdonságok hasonlósága alapján történő csoportosításán, más szóval klaszterezésén alapulnak. A szegmentáció alapvetően két fő lépésből áll. Először az attribútum

meghatározása történik. Ez lehet már meglévő adat is, mint például a pontokhoz rendelt színinformáció, vagy intenzitásértékek. De lehet akár számított érték is, mint például egy pont környezetében lévő pontokra illesztett sík normálisának iránya (1. ábra) vagy függőlegessel bezárt szöge (Grilli et al. 2017).


A pontfelhők esetében megkülönböztetünk geometriai, spektrális és sajátértékeken alapuló jellemzőket. A geometriai jellemzők lehetnek az egyes koordináták, lokális pontsűrűség, különböző görbületértékek. Spektrális jellemzőkhöz elsősorban a különböző szín- és intenzitásadatok tartozhatnak. Léteznek úgynevezett sajátértékeken alapuló pontfelhőjellemzők is, mint például az omnivariancia, linearitás, síklapúság, gömbszerűség (Feng-Guo 2018).

A pontfelhő egy pontjának saját értékei (λ_1, λ_2 és λ_3 , a továbbiakban csökkenő sorrendben $\lambda_1 > \lambda_2 > \lambda_3$) a Q mátrix saját értékei, amely az 1. képlettel számítható, ahol az A mátrix tartalmazza az adott pont R sugarú környezetében található pontok koordinátáit, a súlypont koordinátáival történő eltolása után (Mayre et al. 2017):

$$A = \begin{bmatrix} x_1 - \bar{x} & y_1 - \bar{y} & z_1 - \bar{z} \\ \vdots & \vdots & \vdots \\ x_m - \bar{x} & y_m - \bar{y} & z_m - \bar{z} \end{bmatrix}$$

$$Q = A^T A = \begin{bmatrix} \sum_{i=1}^m (x_i - \bar{x})^2 & \sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y}) & \sum_{i=1}^m (x_i - \bar{x})(z_i - \bar{z}) \\ \sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y}) & \sum_{i=1}^m (y_i - \bar{y})^2 & \sum_{i=1}^m (y_i - \bar{y})(z_i - \bar{z}) \\ \sum_{i=1}^m (x_i - \bar{x})(z_i - \bar{z}) & \sum_{i=1}^m (y_i - \bar{y})(z_i - \bar{z}) & \sum_{i=1}^m (z_i - \bar{z})^2 \end{bmatrix}$$

1. képlet.



1. ábra. Pontfelhő és egyes pontjaihoz tartozó normálisok

A saját értékek értékes információt tartalmaznak az adott pont és környezetébe eső pontok által alkotott ponthalmaz geometriájáról, amelyekhez további jellemzők vezethetők le (1. táblázat). Az így meghatározott tulajdonságok a feladat függvényében önmagukban is használhatóak a pontfelhők attribútumalapú szegmentálására.


1. táblázat. A saját értékeken alapuló főbb jellemzők és meghatározásuk (λ_1, λ_2 és λ_3 és csökkenő sorrendben a saját értékek)

Saját értékeken alapuló jellemzők	Meghatározás
Omnivariancia (omnivariance)	$\sqrt[3]{\lambda_1 \cdot \lambda_2 \cdot \lambda_3}$
Anizotropia (anisotropy)	$\frac{(\lambda_1 - \lambda_3)}{\lambda_1}$
Síklapúság (planarity)	$\frac{(\lambda_2 - \lambda_3)}{\lambda_1}$
Felületváltozás (surface variation)	$\frac{\lambda_3}{(\lambda_1 + \lambda_2 + \lambda_3)}$
Gömbszerűség (sphericity)	$\frac{\lambda_3}{\lambda_1}$

Az attribútum meghatározása után következik a csoportosítás, ami a pontok kategorizálását jelenti a kiválasztott attribútum alapján. Az attribútumokon alapuló szegmentálás hatékonysága nagymértékben függ a megválasztott tulajdonság minőségétől, illetve az általunk megválasztott küszöbértékektől. A módszerről elmondható, hogy alapvetően egy egyszerű szegmentálási módszer. A megválasztott tulajdonság függvényében lehet gyors és hatékony is. Hátránya, hogy az attribútumok eloszlására, valamint a zajra érzékeny. Bonyolultabban meghatározható attribútumok esetén a feldolgozás időigényes lehet (Grilli et al. 2017).

2.2 Élalapú szegmentálás

Az attribútumalapú szegmentációhoz hasonlóan az élalapú (edge-based) szegmentációs módszerek esetében is két fő lépésről beszélhetünk. Első lépés a határoló pontok meghatározása, kiválasztása. Ehhez a pontfelhő olyan tulajdonságait használják fel, mint például a gradiens, a normálisok irányának, vagy a görbületértékek változása (2. ábra) a pontok adott környezetében. A megadott küszöbértéket átlépő pontok alkotják a határoló pontok halmazát.



2. ábra. Normálisok irányváltása alapján meghatározott határoló pontok (zöld)

Egy-egy szegmens meghatározásának alapja a határokon belül lévő pontok alapján történik (Nguyen et al. 2013; Grilli et al. 2017).

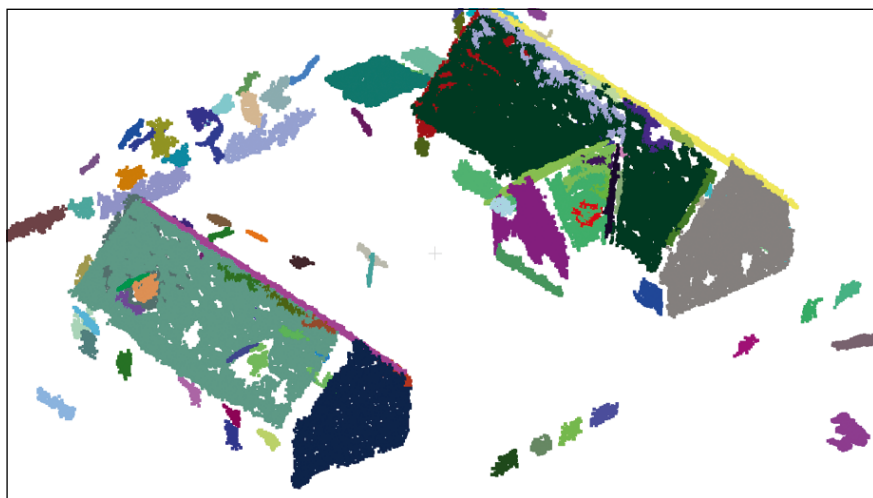
A módszerre jellemző, hogy alapvetően gyors, viszont nem a legpontosabb eljárás. Érzékeny a zajra, illetve a pontok egyenetlen eloszlására.

2.3 Régiónövelésen alapuló szegmentáció

A terület- vagy régiónövelésen alapuló (region-based) szegmentációs módszerek az egyes pontokat és az adott környezetükben lévő egyéb pontokat vizsgálják. Alapelve, hogy a szomszédos pontok tulajdonságainak vizsgálata segítségével próbálnak meg hasonló attribútumú pontokat megkeresni,

majd egy régióban eltávolítani. A módszer jellemzője, hogy zajra kevésbé érzékeny. Két fajtája van; a kicsiből nagyba (seeded, bottom-up) és nagyból kicsibe (unseeded, top-down) építkező eljárások (Nguyen et al. 2013; Grilli et al. 2017).

A kicsiből nagyba építkező módszer egy „magból” indul ki, és szomszédos pontok vizsgálatával próbálja növelni az egy szegmenshez tartozó pontok halmazát. Egy pont adott régióhoz tartozását a felhasználó által definiált kritériumok és küszöbértékek segítségével dönti el az algoritmus. Ilyen feltétel lehet a síklapúság, a normálisok párhuzamossága, vagy a görbületértékek vizsgálata (3. ábra). Hátránya, hogy érzékeny a megválasztott küszöbértékekre.



3. ábra. Normálisok iránya és Gauss-görbületi (Hyde et al. 1997) érték alapján történő régiónövelésen alapuló szegmentáció (a megtalált szegmensnek különböző színekkel jelölve)

A nagyból kicsibe építkező területalapú módszer az előző ellentéte. Itt első lépésben minden pont egy nagy területbe tartozik. Ezt követően kisebb területekre osztják azokat. Ez a felosztás addig tart, amíg a kiválasztott modellhez való illeszkedés nem lesz egy adott küszöbértéken belül elfogadható. Egyik alapesete a síkhoz való illeszkedésnek a vizsgálata, amit például épületek azonosítására használnak. A módszer alapvetően érzékeny a növényzetre. Alkalmazása során nehézséget okoz annak eldöntése, hogyan bontsuk fel részekre a pontfelhőt.


2.4 Modellalapú szegmentáció

A modellalapú (model-based) módszerek egyszerű, matematikailag definiálható geometriai alakzatok (pl.: sík, gömb, henger) megkeresésén alapulnak (4. ábra). Az alakzatokhoz legjobban illeszkedő pontok keresésére egy robusztus, legkisebb négyzetek módszerén alapuló iterációs paraméterbecslési eljárás, a RANdom SAMple Consensus (RANSAC) alkalmazható (Fischer-Bolles 1981). A RANSAC-módszer ismertetéséről, térinformatikai alkalmazásáról Varga et al. (2021) cikkében, míg egyik mérnökgeodéziai alkalmazásáról Takács (2023) cikkében olvashatunk.

2.5 Gépi tanuláson alapuló szegmentáció

Ha pontfelhőkhöz hasonló nagy méretű adathalmazok feldolgozásáról beszélünk, akkor a gépi tanuláson alapuló algoritmusok használatát nehezen tudjuk megkerülni. Az utóbbi évtizedekben a gépi tanuláson (machine learning), ezen belül is a mély tanuláson (deep learning) alapuló algoritmusok egyre inkább elterjedtek. Ma már számos alkalmazási területe van mesterséges intelligenciának. Szakmánkban az egyik ilyen terület a pontfelhő-szegmentálás, illetve -osztályozás (Grilli et al. 2017).

A gépi tanuláson alapuló algoritmusok alapvetően az adathalmazokban valamilyen tulajdonság (attribútum) alapján összefüggéseket, mintázatokat keresnek, ismernek fel. Pontfelhők esetében ilyen attribútumok lehetnek a 2.5 alfejezetben tárgyalt saját értékek és az ezeken alapuló különböző jellemzők (Poux-Billen 2019).



4. ábra. Sorozatos RANSAC-sikkesítés eredménye. Az egyes színek a megtalált síkokat jelképezik.

Annak függvényében, hogy a minták felismerése, illetve a csoportok elkülönítése milyen módon történik, megkülönböztetünk:

- felügyelt,
- felügyelet nélküli,
- megerősített gépi tanulási módszereket.

A felügyelt (supervised) gépi tanulási módszereknél a csoportosítás szabályát a felhasználónak kell megadnia egy tanító adathalmaz segítségével. Ilyenkor az adott algoritmus az ismert bemeneti és kimeneti értékek segítségével egy tanításnak nevezett folyamat során hoz létre egy modellt az adott feladat elvégzésére. Vannak olyan módszerek, mint például a Random Forest (RF), amely tanítás során döntési fák sorozatával alakít ki szegmenseket. A K-Nearest Neighbors (K-NN) módszer azt feltételezi, hogy a csoporthoz tartozó jellemzők értéke egy adott távolságon belül van, vagyis szomszédosan helyezkednek el. Ma már egyre inkább elterjedt a különböző neurális hálózatok (Neural Network) alkalmazása is. A neurális hálózatok több rétegbe rendezett úgynevezett „neuronokból” épülnek fel. A neuronok egy-egy aktivációs függvényt tartalmaznak, amelyeknek van egy-egy súlya és egy eltolási értéke. A neurális hálózat tanítása során az ismert bemenő és kimenő adatok függvényében ezeknek a súlyoknak, eltolási értékeknek a keresése történik meg oly módon, hogy az ismert és a neurális hálózatból kapott kimenet között az eltéréseket minimalizáljuk. A felügyelt gépi tanulási módszerek esetében az eredmény nagyban függ

a tanító adatok minőségétől, mennyiségétől. Később az előre létrehozott modellt lehet beépíteni az adott feladat (jelen esetben szegmentálás) elvégzésére (Bonaccorso 2018, Awange et al. 2020).

Felügyelet nélküli módszerek esetében a csoportosítás eredménye az adott algoritmus működtetéséhez szükséges paraméterek beállított értékétől függ. Az adatok közötti összefüggések megkeresését az alkalmazott program saját maga végzi el. A gépi tanuláson alapuló algoritmusok közül számos csoportképzésre, klaszterezésre alkalmazható algoritmusal találkozhatunk a szakirodalomban, például k-Means, hierarchikus, Density-Based Spatial Clustering of Applications with Noise (DBSCAN). Ezek között a módszerek között vannak olyanok, amiknél a keresett csoportok számát előre definiálni kell. A már említett k-Means módszer is egy ilyen klaszterező algoritmus. A működtetéséhez előre meg kell adni a keresett csoportszámot, majd ezt követően a véletlenszerűen felvett kezdőpontok és ponttávolságok alapján az algoritmus az iterációkon keresztül megpróbálja az optimális klaszterközéppontokat megkeresni úgy, hogy az adatok távolsága minimális legyen. A hierarchikus klaszterezésen alapuló algoritmusok

is ismert számú csoporttal operálnak, és a klaszterek megalkotása során egy fához hasonló adatszerkezetet használnak fel. Belátható, hogy a csoportok szám a pontfelhők esetében nem mindig ismert előre. Ezt küszöbölhetjük ki olyan algoritmusok használatával, mint a Density-Based Spatial Clustering of Applications with Noise (DBSCAN) (Bonaccorso 2018). A DBSCAN (Ester et al. 1996) algoritmus lényege, hogy klaszterek elválasztásához a sűrűségviszonyok változását használjuk fel úgy, hogy az alacsony sűrűségű területekkel körülvevett, nagy sűrűségű területeket keressük meg és különítjük el.

A DBSCAN algoritmus két paraméter segítségével működtethető:

- R - a klaszteren belüli a pontok közötti maximális távolság,
- n_{min} - a minimális pontszám, ami szükséges egy csoport létrehozásához.


A paraméterek megadása után az algoritmus a vizsgált adatokból (x) véletlenszerűen kiválaszt egy pontot (x_i), majd meghatározza a többi adathoz (x_j) viszonyított távolságát. Ha az előre megadott R távolságon belül a minimális mennyiségű pontnál több található, akkor a pontthalmazban találtunk egy magot (core):

$$N(d(\bar{x}_i, \bar{x}_j) \leq R) \geq n_{min}$$

Ezt követően a magot határoló pontoktól kezdi el vizsgálni a többi adat távolságát. Ha a magpontok és határoló pontok távolsága R értéken belül esik, akkor a magot bővíti az új tagokkal:

$$d(\bar{x}_i, \bar{x}_j) \leq R$$

Ha az adat kívül esik az R sugáron kívül, akkor az a pont nem lesz része az adott magnak (5. ábra).



5. ábra. DBSCAN működési elve

A magpontok halmaza addig bővíthető, amíg a mintaadatok megfelelnek a paraméterekkel megválasztott követelményeknek. Ha egy csoporthoz a határoló pontok mentén nem tudunk már több magpontot hozzárendelni, akkor a klasztert véglegesíthetjük, és kereshetünk további csoportokat (6. ábra). Azok a pontok, amelyek egyetlen klaszterhez sem tartoznak zajként különíthetők el.


Megerősített módszerek esetében a kimenet alapján valamilyen visszacsatolás történik. Ez általában eredmények értékelését jelenti valamilyen pontozási rendszer segítségével. Az így megszerzett információt használják fel az adott modell finomítására a modell alkalmazása során (Bonaccorso 2018).

A sokszor bonyolultnak tűnő matematikai háttér ellenére ezek a gépi tanulási módszerek könnyen alkalmazhatóak. A legtöbb esetben már kész függvények, programok állnak rendelkezésre, amelyeket az adott feladatra kell szabni és helyesen kell tudni alkalmazni. A kész algoritmusok közül számos használható pontfelhőszegmentációra is. A gépi tanuláson alapuló algoritmusokról általánosan elmondható, hogy hatékonyan, gyorsan működnek.

Az előző alfejezetekben tárgyalt pontfelhőszegmentációs módszerek előnyeit és hátrányait a következő táblázat foglalja össze (2. táblázat):

2. táblázat. A pontfelhőszegmentációs módszerek összehasonlítása

Szegmentációs módszerek	Előnyök	Hátrányok
Attribútumalapú	gyors szétválasztást tesz lehetővé, egyszerűen alkalmazható	zajra érzékeny, az attribútum meghatározásának függvényében időigényes lehet
Élalapú	gyors szétválasztást tesz lehetővé	zajra érzékeny
Régiónövelésen alapuló	zajra kevésbé érzékeny	megválasztott küszöbértékekre érzékeny, az attribútumok számának meghatározásának függvényében időigényes lehet
Modellalapú	gyors, robusztus szétválasztást tesz lehetővé	megválasztott küszöbértékekre érzékeny
Gépi tanuláson alapuló	gyors, robusztus szétválasztást tesz lehetővé	az eredmény nagyban függ a tanító adatok minőségétől, a jellemzők meghatározása időigényes lehet



6. ábra. Gépi tanuláson alapuló DBSCAN-klaszterezés eredménye (az egyes klaszterek különböző színekkel jelölve)

3. Pontfelhő-osztályozás


A pontfelhőszegmentálás egy alkalmazási területe a szemantikus szegmentáció, vagyis az osztályozás. A különböző szegmentációs módszerek segítségével alkotott csoportok címkézésével az adott pontfelhő részeit rendszerezhetjük.

A szegmentálás során meghatározott csoportok osztályba sorolása történhet interaktívan a felhasználó által, vagy valamilyen algoritmus segítségével. Utóbbi esetben már olyan (fél)automatizált megoldásokról beszélhetünk, amelyek a legtöbb esetben különböző gépi tanuláson alapuló, vagy egyéb specifikus feladatra kitalált hatékony algoritmusok végeznek el. Egy ilyen osztályozási

feladat megoldásaként született meg a Cloth Simulation Filter (CSF) módszer is.

A Cloth Simulation Filter, a nevéből adódóan, „lepedőszimuláció” segítségével végzi el a talaj- és nentalajpontok szétválogatását. Az algoritmus első lépésként veszi az adott pontfelhő magasság szerinti invertáltját, majd erre a ponthalmazra egy paraméterezett „lepedőt” illeszt rá (7. ábra). A paramétereket (pl.: szimulációk száma, rács mérete, rugalmassági paraméter) a felhasználó veheti fel.

Az osztályozás invertált pontfelhőn, a deformálódott lepedő segítségével történik. A kialakult felülethez képest, a megadott küszöbértéken belül eső pontok fogják alkotni a talajpontokat (Zhang et al. 2016).



7. ábra. A „lepedőszimuláción” alapuló algoritmus működési elve (Zhang et al. 2016)

4. Esettanulmányok szegmentálási módszerek alkalmazására


A pontfelhő-szegmentáló algoritmusok áttekintése után a következő részben a különböző szegmentálási módszerek egy-egy lehetséges alkalmazását mutatom be példákon keresztül.

Az ismertetett módszerek többségét a CloudCompare (CloudCompare 2023) pontfelhő és poligonháló (mesh) feldolgozására használható nyílt forráskódú szoftver segítségével mi magunk is kipróbálhatjuk, illetve tesztelhetjük. Olyan professzionális felhasználás esetén, mint például a különböző gépi tanuláson alapuló algoritmusok alkalmazása, szükség lehet a különböző programozási nyelvek (Python, C++) használatára is. Számos könyvtár érhető el, ahol már meglévő szegmentációs módszereket találhatunk meg és használhatunk. Egyik ilyen könyvtár a pontfelhőkezelésre is használható Open3D Python könyvtár (Zhou et al. 2018), ami beépített DBSCAN-nel rendelkezik.

4.1 Szegmentálás a normálisok függőlegessel bezárt szöge alapján

A pontfelhő pontjaihoz tartozó normálisok a különböző megjelenítési módok támogatása, illetve 3D-s modellek alkotása mellett szegmentálásra is felhasználhatók. A következőkben ennek szemléltetésére egy drónfotogrammetrián alapuló, a Magyar Mérnöki Kamara Feladat Alapú Pályázata (Holéczy et al. 2020) keretében, 2020-ban a Barnagon végzett felmérés eredményét; pontfelhőjét használtam fel (Hrutka et al. 2022).

A nyers pontfelhő a 3. fejezetben bemutatott Cloth Simulation Filter segítségével, talaj- és nementalajpontokra bontható. Ezt követően a normálisok irányultságán alapuló attribútumalapú szegmentáció (2.1-es alfejezet) segítségével lehetőség van a fal és tetőpontok közelítő szétválasztására (8. ábra). Erre a normálisok függőleges tengellyel bezárt szögértéke használható.



8. ábra. A normálisok függőlegessel bezárt szöge

A leválogatott tetőpontok normálvektorainak segítségével, akár a tetőpontokhoz tartozó fekvését, kitétségét is számszerűsíteni lehet.

4.2 Sajátértékeken alapuló szegmentáció alkalmazása talajpont-leválogatásra

A mai földmérési gyakorlatban a nagyobb területek digitális terepmodelljének előállítása egy gyakran előforduló feladat. Számos eszköz használható erre a feladatra. Egy alkalmazása lehet a 2.1-es alfejezetben ismertetett saját értékeken alapuló síklapúságértékek kombinálása attribútumalapú szegmentációval talajpont-detektálásra.


A módszert egy, a Zalaegerszegi Járműipari Tesztpálya (ZalaZone) mellett található teszterület drónfotogrammetria segítségével előállított pontfelhőjén teszteltem. A felmérést egy DJI Phantom 4 Pro kvadrokopter segítségével, 60 méteres repülési

magasságból, 1,6 cm/pixel terepi felbontás (GSD) mellett végeztük el. A repülést rácsban (grid mission), 80%-os átfedéssel, lombtalan időszakban végeztük. Az 1803 darab fényképet a nadíriránnyal 10°-ot bezáró ferde kameratengellyel készítettük. A georeferáláshoz 10 darab, RTK GNSS-technikával bemért terepi illesztőpontot használtunk fel. A feldolgozást 3Dsurvey szoftver segítségével végeztük el, aminek eredményeként a 19,1 ha méretű területről 169 millió pontból álló pontfelhőt állítottunk elő (9. ábra).

A drónfotogrammetria segítségével előállított pontfelhők esetében kihívást jelenthet a talajpontok elhatárolása az aljnövényzet pontjaitól. Erre nyújthat megoldást a síklapúságértékek előszűrésként való felhasználása (10. ábra). Egy-egy pont adott, pl. 0,5 m-es környezetébe eső pontjaiból levezetett saját értékekből meghatározható az adott pont síklapúságértéke (1. táblázat).



9. ábra. A teszterület pontfelhője



10. ábra. Saját értékeken alapuló síklapúságértékek a pontok 0,5 m-es környezeté alapján

A módszer zajsűrűségi és előszűrési eszközként használható a pontfelhő leképződött vegetációs pontok leválogatása során. Kiegészítve a 3. fejezetben található Cloth Simulation Filter (CSF) módszerrel, a talajpontok hatékony szegmentálását végeztem el. Az elválasztott talajpontokat digitális terepmodell (DTM) előállítására használtam fel (11. ábra).

4.3 Gépi tanuláson alapuló sűrűség alapú klaszterezés DBSCAN-algoritmussal

Egy másik, szintén gyakori feladat a pontfelhő pontjaiból az épületek tetőpontjainak kiválogatása, majd a tetők modellezése.

Ilyen feladatok esetében a 2.5-ös alfejezetben bemutatott gépi tanuláson alapuló szegmentációs módszerek jó kiegészítői lehetnek az egyéb szegmentáló algoritmusoknak. Számos esetben lehet szükség a pontfelhők felügyeletlen szétválogatására, hogy további elemzéseket lehessen azokon végrehajtani. Erre volt szükség a korábbiakban bemutatott barnagi

felmérés esetében is, ahol a normalizált felszínmodellen végrehajtott (voxeleken alapuló) sorozatos RANSAC-síkkereséssel (2.4. alfejezet), majd a megtalált síkok normálisainak függőlegesssel bezárt szögének vizsgálata alapján lehatárolt, feltételezett tetőpontokat épületenként kellett elkülöníteni (Hrutka et al. 2022).


A feladat elvégzésére a korábbiakban bemutatott DBSCAN-algoritmust

használtam fel. A klaszterek létrehozása során a pontok 3D-s koordinátáit vizsgáltam $R = 0,4$ m és $n_{\min} = 100$ paraméterekkel. Így a pontok sűrűségviszonyának változásdetektálásával sikerült épületenként elkülöníteni a leképződött tetőpontokat (12. ábra).

Az épületenként szegmentált tetőpontthalmazok elkülönítése fontos az épületekhez tartozó falpontok elkülönítése, illetve későbbi 3D-s modellek levezetése szempontjából.

5. Összefoglalás

Az elmúlt években rohamosan fejlődő, pontfelhőt alkotó technikákkal előállított adatok feldolgozása során a 3D-s koordináták mellett számos, egyéb közvetlen, illetve közvetett módon rendelkezésre álló információ használható. Ezeknek az információknak a felhasználásával foglalkoznak a különböző automatizált pontfelhőfeldolgozást támogató, szegmentáló és osztályozó algoritmusok.



12. ábra. Példa a DBSCAN alkalmazására az épületek tetőpontjainak elkülönítésére (szürkével a kiinduló állomány, a különböző színekkel pedig az eredmény látható)



11. ábra. A leválogatott talajpontok pontfelhője és az ezekből levezett digitális terepmodell

A cikkben átfogóan ismerttettem ezeket a módszereket az egyszerűbben használható attribútum- és élalapú, illetve a bonyolultabb (már gyakran programozási ismereteket is megkövetelő) régió növelésen, különböző matematikai modelleken és gépi tanuláson alapuló algoritmusokig. Kitértem a szegmentálási módszerek egy specifikus alkalmazására, a pontfelhő-osztályozásra. A különböző szemantikus szegmentációra használható algoritmusok közül bemutattam egy talaj- és nemtalajpontok osztályozására használható módszert a Cloth Simulation Filtert.

Három gyakorlati példán keresztül bemutattam a szegmentáló algoritmusok lehetséges alkalmazásait. Mindhárom esetben egy-egy drónfotogrammetria segítségével előállított pontfelhőt használtam fel. Első lehetséges alkalmazásként a felmérés során leképződött épületek fal- és tetőpontjainak elkülönítésére, a pontokra meghatározott normálvektorok függőlegesssel bezárt szöge lapján végzett attribútumalapú szegmentációt használtam fel. Második alkalmazásként a talajpontok előzetes szűrésére egy úgynevezett saját értékeken alapuló jellemzőt, a síklapúság értékét vezettem le. Kombinálva a síklapúságértékre vonatkozó attribútumalapú szegmentációt és a Cloth Simulation Filter módszert, a drónfelvételeken leképződött vegetáció, elsősorban az aljnövényzet hatékony szűrését végeztem el. Végül harmadik példaként a napjainkban egyre inkább teret nyerő gépi tanulási módszerek egy geodéziai alkalmazását, a tetőpontok épületenként történő automatizált szétválogatását mutattam be egy DBSCAN-algoritmus segítségével.

A bemutatott, gyakran korszerű matematikai és gépi tanulási módszereket is felhasználó eszköztárak számos lehetőséget nyújthatnak a korszerű felmérési módszerek eredményeként előállított pontfelhők hatékony, automatizált feldolgozására.

6. Köszönetnyilvánítás

A tanulmány a Kulturális és Innovációs és Minisztérium ÚNKP-22-3-I-BME-38 kódszámú Új Nemzeti Kiválóság

Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alap anyagi támogatásával készült.

Irodalom

- Awange, J. – Paláncz, B. – Völgyesi, L. 2020. *Hybrid Imaging and Visualization Employing Machine Learning with Mathematica – Python*. Springer, ISBN 978-3-030-26152-8 DOI: [10.1007/978-3-030-26153-5](https://doi.org/10.1007/978-3-030-26153-5)
- Bonaccorso, G. 2018. *Machine Learning Algorithms Second Edition*. Packt, ISBN 9781789347999. <https://www.packtpub.com/product/machine-learning-algorithms-second-edition/9781789347999> utolsó elérés: 2023. augusztus 23.
- CloudCompare 2023. *CloudCompare Software*, Version 2.12.4 Kyiv. <https://www.danielgm.net/cc/>, utolsó elérés: 2023. augusztus 23.
- Ester, M. – Kriegl, H. P. – Sander, J. – Xiaowei, Xu. 1996. *A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise*. <https://www.osti.gov/biblio/421283> utolsó elérés: 2023. augusztus 23.
- Feng, C. C. – Guo, Z. 2018. *Automating Parameter Learning for Classifying Terrestrial LiDAR Point Cloud Using 2D Land Cover Maps*. Remote Sensing, 10(8), pp. 1192. DOI: [10.3390/rs10081192](https://doi.org/10.3390/rs10081192)
- Fischler, M. A. – Bolles, R. C. 1981. *Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography*. Communications of the ACM, 24 (6), pp. 381–395. DOI: [10.1145/358669.358692](https://doi.org/10.1145/358669.358692)
- Grilli, E. – Menna, F. – Remondino, F. 2017. *A preview of point clouds segmentation and classification algorithms*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W3, 2017 3D Virtual Reconstruction and Visualization of Complex Architectures, 1–3 March 2017, Nafplio, Greece. DOI: [10.5194/isprs-archives-XLII-2-W3-339-2017](https://doi.org/10.5194/isprs-archives-XLII-2-W3-339-2017)
- Holéczy, E. – Oláh, R. – Siki, Z. – Takács, B. – Tóth, Z. – Varga, T. 2020. *Módszertani útmutató az elavult ingatlan-nyilvántartási térképek korszerű technológiákkal végzett felújításához*, Magyar Mérnöki Kamara Kiadványsorozata 63. 2020. pp. 1–83. http://mmk-ggt.hu/fap/FAP_105_2020_GGT.pdf utolsó elérés: 2023. augusztus 23.
- Hrutka, B. P. – Siki, Z. – Takács, B. 2022. *Voxel-based point cloud segmentation and building detection*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLVIII-4/W1-2022, pp. 209–215. DOI: [10.5194/isprs-archives-XLVIII-4-W1-2022-209-2022](https://doi.org/10.5194/isprs-archives-XLVIII-4-W1-2022-209-2022)
- Hyde, S. – Ninham, B.W. – Andersson, S. – Larsson, K. – Landh, T. – Blum, Z. – Lidin, S. 1997. *The Language of Shape. The Role of Curvature in Condensed Matter: Physics, Chemistry and Biology. Chapter 1 - The Mathematics of Curvature*. Elsevier Science B. V, pp. 1–42. ISBN 9780444815385. DOI: [10.1016/B978-0-444-81538-5/50002-2](https://doi.org/10.1016/B978-0-444-81538-5/50002-2)
- Jóó, A. L. – Völgyi, I. – Hegyi, P. – Kollár, D. – Takács, B. G. – Égető, Cs. 2022. *Speciális mérési feladatok a Monostori híd próbateljesítéskor*. MAGÉSZ Acélszerkezetek 19: különszám, pp. 47–57., p. 11.
- Lovas, T. – Berényi, A. – Barsi, Á. 2012. *Lézerszkennelés*. TERC Kereskedelmi és Szolgáltató Kft., Budapest. p. 166. ISBN: 9789639968
- Lovas, T. – Rehány, N. – Somogyi, J. Á. 2018. *Történelmi épületek rekonstrukciós munkálatainak támogatása pontfelhők segítségével*. Geodézia és Kartográfia, 70. évf. 1. sz. pp. 19–24. DOI: [10.30921/GK.70.2018.1.3](https://doi.org/10.30921/GK.70.2018.1.3)
- Mayr, A. – Rutzinger, M. – Bremer, M. – Elberink, S. O. – Stumpf, F. – Geitner, C. 2017. *Object-based classification of terrestrial laser scanning point clouds for landslide monitoring*. The Photogrammetric Record 32(160), pp. 377–397. DOI: [10.1111/phor.12215](https://doi.org/10.1111/phor.12215)
- Nguyen, A. – Le, B. 2013. *3D Point Cloud Segmentation: A survey*. Conference: 2013 6th International Conference on Robotics, Automation and Mechatronics (RAM) (2013) DOI: [10.1109/RAM.2013.6758588](https://doi.org/10.1109/RAM.2013.6758588)
- Poux, F. – Billen, R. 2019. *Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods*. ISPRS International Journal of Geo-Information. 8(5), pp. 213. DOI: [10.3390/ijgi8050213](https://doi.org/10.3390/ijgi8050213)
- Siki, Z. – Rózsa, Sz. – Takács, B. – Deák, O. – Égető, Cs. – Tuchband, T. 2013. *A Paksi Atomerőmű magassági alappont hálózat ellenőrzése, aktuális koordináták meghatározása, adatbázisba történő betöltése*. 2013. pp. 1–52., p. 52
- Takács, B. 2023. *A Robinson híd pylonjának alakváltozásai*. Geodézia és Kartográfia, 75. évf. 2. sz. pp. 17–21. DOI: [10.30921/GK.75.2023.2.3](https://doi.org/10.30921/GK.75.2023.2.3)
- Takács, B. – Lovas, T. 2023. *A pontfelhők készítésének és alkalmazásának helyes gyakorlatáról*. Mérnök Újság XXX, 4, pp. 52–55., p. 4.
- Varga, Á. – Szatmári, J. – Tobak, Z. – Boudewijn van, L. – Mucsi, L. 2021. *Épületek napenergia-potenciáljának számítása fotogrammetriai módszerekkel előállított adatok felhasználásával*. Geodézia és Kartográfia, 73. évf. 2. sz. pp. 4–9. DOI: [10.30921/GK.73.2021.2.1](https://doi.org/10.30921/GK.73.2021.2.1)
- Zhang, W. – Qi, J. – Wan, P. – Wang, H. – Xie, D. – Wang, X. – Yan, G. 2016. *An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation*. Remote Sensing, 8(6), pp. 1–22. DOI: [10.3390/rs8060501](https://doi.org/10.3390/rs8060501)
- Zhou, Q. Y. – Park, J. – Koltun, V. 2018. *Open3D: A Modern Library for 3D Data Processing*. DOI: [10.48550/arXiv.1801.09847](https://doi.org/10.48550/arXiv.1801.09847)



Hrutka Bence Péter
doktorandusz

BME, Építőmérnöki Kark
Általános- és Felsőgeodézia Tanszék
hrutka.bence@emk.bme.hu