

AUTOMATISCHE CLASSIFICERING VAN LASERSCANDATA MET DEEP LEARNING VOOR LANDMEETKUNDIGE TOEPASSINGEN

XXXXX

HOGENT, Opleiding Vastgoed, Gent, België

SLEUTELWOORDEN: Deep learning, puntenwolk, artificiële intelligentie, laserscanning, landmeetkunde.

SAMENVATTING:

Deze bijdrage wil onderzoeken onder welke voorwaarden artificiële intelligentie en in het bijzonder deep learning een meerwaarde kan betekenen voor het classificeren van dataverzamelingen ingewonnen door LIDAR-apparatuur.

Het onderzoek vertrekt vanuit het classificatieprobleem bij puntenwolken en de uitdagingen die puntenwolken stellen aan lerende algoritmes. Daarbij wordt het begrip classificering gedefinieerd in de bredere context van verwerkingsprocessen van puntenwolken. Het begrip deep learning wordt ook onderscheiden van andere machine learning technieken zoals SVM en RF. Het meeste onderzoek rond geautomatiseerde classificering van puntenwolken focust vandaag op supervised deep learning. Het is dit type van deep learning dat verder wordt geëvalueerd.

Vervolgens wordt de werking besproken van deep learning modellen die gebruikt worden in marktrijpe softwaretoepassingen. Op basis van de inherente modeleigenschappen, de testresultaten en het marktaanbod worden afwegingscriteria geformuleerd voor de inzet van deep learning bij verwerking van puntenwolken. Het onderzoek hanteert hierbij het perspectief van de landmeetkundige eindgebruiker. Een belangrijke conclusie is dat deep learning een investering vraagt in het adequaat trainen van het model. Bovendien is een grote reken capaciteit noodzakelijk, net zoals een groot aanbod van geschikte trainingsdata. Herhaalbaarheid en schaalbaarheid zijn bijgevolg belangrijke criteria voor de landmeetkundige professional om af te wegen of deep learning een zinvol hulpmiddel is bij het classificeren van puntenwolken.

1. INTRODUCTIE

Deep learning is een methode van artificiële intelligentie die vandaag meer en meer ingezet wordt om gegevensverzamelingen te verwerken. Bekende toepassingen zijn gezichtsherkenning en tekstvoorspelling. Een deep learning model voorspelt bepaalde eigenschappen van ingevoerde data op basis van hun ervaring met vergelijkbare trainingsdata. Hoe meer een deep learning model getraind is, hoe accurater het voorspellingen kan doen over eigenschappen van nieuwe data. Het is een vorm van artificiële intelligentie en machine learning waar bij menselijke intelligentie nagebootst wordt door een neurale netwerk. De opbouw van zo'n netwerk bestaat uit verschillende lagen van neuronen of knopen die met elkaar verbonden zijn. Een klassieke manier van bewerking door zo'n model is het kruisen van gegevens door middel van convolutie.

De inzet van deze netwerken voor de automatische interpretatie van puntenwolken ingewonnen door LIDAR-hardware is een thema waar vandaag veel onderzoek rond gebeurt en nieuwe software wordt voor ontwikkeld. Deep learning kan worden ingezet om elk datapunt in een puntenwolk automatisch van een betekenisvol label te voorzien. Om dit proces van labeling aan te duiden worden de begrippen "classificatie" en "(semantische) segmentatie" in de literatuur door elkaar gebruikt. In deze bijdrage wordt het begrip classificatie gehanteerd om het semantisch labelen aan te duiden. (Kaveh et al., 2023) Een voorbeeld van classificatie is een dataset van een stuk autosnelweg waarbij elk datapunt een label krijgt "scheur" of "geen scheur". Essentieel voor deze modellen is dat ze in staat zijn labels toe te kennen als gevolg van een gericht trainingsproces dat ze ondergaan met gelijkaardige datacollecties. Het betreft een door de mens gecontroleerd trainingsproces of "supervised learning".

Onder segmentatie wordt in deze bijdrage verstaan: het verdelen van de puntenwolken in deelverzamelingen op basis van clustering van de attributen van elk datapunt. Attributen omvatten minstens het x, y en z-coördinaat, maar kan aangevuld worden met een reflectiewaarde, RGB-waarde of andere. Voor segmentatie worden "unsupervised learning" processen ingezet. Dit type model evalueert zichzelf enkel op basis van ervaringen met nieuwe data. Belangrijke methodes zijn de k-gemiddeld clusteranalyse en hiërarchische clusteranalyse.

Het classificatieproces is ook te onderscheiden van de registratie van de puntenwolk. Registratie betekent de integratie van verschillende scans in een gecoördineerd geheel door op zoek te gaan naar gemeenschappelijke datapunten. Klassieke registratie gebeurt door algoritmes zoals het iterative closest point (ICP) algoritme. Algoritmes met het oog op registratie worden niet beschouwd als een vorm van artificiële intelligentie. Het betreft geen lerend model, maar een reeks van op regels gebaseerde calculaties die telkens dezelfde operaties uitvoert.

2. HOOFDTEKST

2.1 Het probleem van de ongestructureerde puntenwolk

Ruwe dataverzamelingen die zijn ingewonnen met LIDAR-apparatuur zijn omvangrijk en ongestructureerd. Zonder verwerking zijn de datapunten niet bruikbaar voor verdere toepassingen. De punten hebben geen onderlinge relaties, hiërarchie of een semantisch attribuut. Een puntenwolk moet aan een aantal verwerkingen onderworpen worden om bruikbaar te zijn voor bijvoorbeeld 3D-modeleringssoftware of BIM-software. Deze verwerking is een arbeidsintensief proces. Dit betekent dat automatische verwerking met behulp deep learning modellen potentieel een grote tijds winst kan opleveren.

Automatische interpretatie van tweedimensionale beelden met behulp van deep learning levert al accurate resultaten op en is efficiënt in gebruik. De interpretatie van 3d puntenwolken is minder vergoederd. Als een van de oorzaken kan worden op de eigenschappen van een puntenwolk die haar onderscheiden van andere driedimensionale weergaven. Zo kan de dichtheid van de punten variëren in een dataset. Een deel van de oppervlakte van het gescande object valt weg aangezien een laserscanner nooit een volledig object kan dekken. Bovendien bevat een puntenwolk vaak ongewenste datapunten (“ruis”). Tijdens de data-inwinning zijn niet alle elementen te vermijden die de dataset kunnen verstoren zoals bijvoorbeeld reflecties of passanten in het studiegebied. (Changyu et al. 2024). Deze eigenschappen maken het moeilijk om de strategieën die succesvol zijn toegepast bij tweedimensionale beeldverwerking te hergebruiken om puntenwolken te classificeren.

2.2 Direct en indirecte deep learning types

Om het probleem van de ongestructureerde puntenwolk te verhelpen kan een voorverwerking op de data worden toegepast. Door een puntenwolk eerst in te delen in voxels zijn deze eenvoudiger te interpreteren door klassieke modellen die hun nut bewezen hebben voor 2D beeldverwerking. (Huang et al., 2023) Het voxeliseren van puntenwolken vraagt echter heel wat rekenkracht en opslagruimte. Wanneer een puntenwolk in een voxelrooster wordt “geduwd” gaat steeds een deel van de geometrische informatie van de originele data verloren. Ten slotte is het moeilijk om een juiste roosterdichtheid of voxelgrootte te bepalen wanneer de puntenwolk geen homogene puntichtheid kent.

Een tweede strategie om de “lastige” eigenschappen van puntenwolken te omzeilen is de puntenwolk om te zetten naar een reeks 2d beelden vanuit verschillende perspectieven. Elk beeld wordt dan door het model aan classificatie onderworpen waarna de resultaten van elk gezichtspunt worden samengevoegd. Ook deze methode heeft als nadeel dat er veel rekenkracht nodig is aangezien het model elk perspectief apart moet gaan classificeren. Bovendien is deze methode gevoelig voor overfitting waarbij het model niet generiek genoeg werkt. (Huang et al., 2023) Het voorspelt enkel de juiste eigenschappen bij data die zeer gelijkaardig zijn als de trainingsdata.

In 2017 kende het onderzoek rond deep learning voor puntenwolken een doorbraak. Een onderzoeksteam aan Stanford University ontwikkelde een model genaamd PointNet (Qi et al., 2017) dat adequaat classificaties uitvoerde met ongestructureerde puntenwolk als invoer. Het netwerk haalt gelijkaardige resultaten als bij het vooraf voxeliseren of renderen van de puntenwolk, maar doordat er geen omzettingen nodig zijn en de modelarchitectuur compacter gebeurt de classificatie efficiënter en sneller. Sinds de ontwikkeling van PointNet spitst het grootste deel van het onderzoek zich toe op modellen die de puntenwolk rechtstreeks als input nemen.

State-of-the-art deep learning modellen halen een gemiddelde accuraatheid tussen de 91% en 94%. (Huang et al., 2023) Met andere woorden genereren goed getrainde modellen gemiddeld tussen 91% en 95% correcte labels. Belangrijk om te vermelden is dat er een trade-off lijkt te bestaan tussen accuraatheid en efficiëntie. Een model dat iets correcter nieuwe data classificeert heeft vaak meer verwerkingstijd en rekenkracht nodig.

2.3 Trainingsdata

Om supervised deep learning veronderstelt dat een model getraind moet worden. Hoe meer een model traint met geschikte data, hoe correcter het nieuwe data zal classificeren. Dit houdt in dat er een grote hoeveelheid aan gelijkaardige datasets ter beschikking moet zijn. De trainingsdata is best gelijkaardig, maar dan ook weer niet te specifiek zodat het model nog in staat is om te generaliseren met nieuwe data. Onderzoekinstellingen en bedrijven bieden intussen al uitgebreide publieke bibliotheken van puntenwolken aan. De publieke datasets zijn belangrijk om de prestaties van de verschillende modellen met elkaar te kunnen vergelijken.

Om een model te trainen is er een grote hoeveelheid aan trainingsdata nodig die op een correct manier gelabeld zijn, met zogenaamde “ground truth” labels. Het voorzien van deze waarheidsgetrouwe labels is een tijdsintensief werk en vraagt de inzet van een professionele annotator. Nadat een deep learning model labels heeft voorspeld worden deze vergeleken met de ground truth labels. Door deze vergelijking leert het model bij en corrigeert de machine zichzelf. Deze techniek wordt ook backpropagation genoemd. De opmaak van geschikte datasets voor training kan ook versneld worden door puntenwolken op een artificiële of synthetische manier aan te maken. Op die manier kan het manuele classificeringswerk deels geautomatiseerd worden.

Sydney Urban Objects (Quadros et al., 2013) en ScanObjectNN (Uy et al., 2019) zijn voorbeelden van verzamelingen met reëel ingewonnen data die ingedeeld zijn in 14 à 15 verschillende klassen met ground truth labels. ScanObjects NN is een verzameling met 2902 verschillende scans. Wat opvalt is dat er grote verschillen bestaan in de gemiddelde accuraatheid afhankelijk welk object wordt geclassificeerd. Het voorspellen van het label “stoel” of “deur” gebeurt veel preciezer dan het correct toekennen van het label “tas” of “doos”.

2.4 Trainen van het model in de landmeetpraktijk

De mate waarin deep learning specifieke kenmerken kan extraheren is dus sterk verschillend van de objecteigenschappen. Dit aspect is belangrijk om af te wegen of deep learning nuttig is in een bepaalde landmeetcontext. Zijn de eigenschappen van de objecten die men wil classificeren voldoende distinctief? Wegmarkeringen en verkeersborden automatisch classificeren zal bijvoorbeeld eenvoudiger verlopen dan verschillende types verharding onderscheiden.

De vermelde scanbibliotheken zijn belangrijk voor wetenschappelijk onderzoek, maar zijn niet onmiddellijk inzetbaar om een model te trainen voor landmeetkundige toepassingen. De voorziene ground truth labels zijn generiek en weinig aangepast aan de specifieke context van een landmeetkundige opdracht. Wanneer men bijvoorbeeld deep learning gebruikt om airborne laserscandata te voorzien van labels volgens de indeling van Grootchalig Referentiebestand (GRB) moet men beschikken over kwaliteitsvolle en grootchalige datasets die voorzien zijn van de ground truth labels volgens die GRB-indeling. Het is duidelijk dat deze niet zomaar publiek beschikbaar zijn. Bovendien zullen de resultaten verbeteren als de trainingsdata veel scans bevatten die qua kwaliteit en dichtheid overeenkomen met de nieuwe data. Ook consistentie van de attributen is gewenst. Het mixen van airborne laserscanning datasets met terrestrial laserscanningdata is te vermijden.

Landmeetbedrijven die al beschikken over een grote collectie data van opgeleverde projecten hebben het voordeel dat ze die meteen kunnen aanwenden als geschikte trainingsdata.

2.5 Toepassingen in de landmeetkunde

Automatische classificering kan een meerwaarde betekenen voor het bijhouden van grootschalige referentiebestanden. Het inventariseren van het landgebruik van grote gebieden met airborne laserscanning is een voorbeeld. Zo bestaat er onderzoek naar het inventariseren van bosbestanden. Grootschalige monitoringtaken zoals rotsmassa's, schade-opmeting, landverlies, oppervlaktewaterlichamen zijn andere taken die gebaat kunnen zijn met een automatische classificering.

Zoals eerder beschreven vraagt een model heel wat training vooraleer het klaar is voor een specifieke landmeetcontext. Zo zal een model voor architectuurscanning heel anders moeten getraind worden dan een model voor landgebruik. De investering in een deep-learning model zal zich terugbetalen wanneer het model veel gelijkaardig classificeringswerk moet verrichten. Zo bestaat er een markt voor op maat gemaakte softwaremodules voor specifieke sectoren zoals wegenbouw en spoorwegbeheer.

Voor de professionele praktijk dient de classificering echter een zo goed als volledige accuraatheid te halen. Indien er te veel punten fout geïdentificeerd worden wordt de tijdswinst door automatisering teniet gedaan door manuele controlewerkzaamheden. Dit vormt nog een grote uitdaging om deep-learning efficiënt te kunnen inzetten.

Marktleiders in de geo-ict sector zoals Esri, Trimble en Leica bieden plugins of gespecialiseerde softwarepakketten aan voor automatische classificering die gebaseerd is een op een deep-learning modelarchitectuur. De modellen hebben vaak al een pretraining ondergaan zodat er vrij snel een resultaat mee kan geboekt worden. Een voorwaarde is wel dat nieuwe of aanvullende trainingsdata gelijkaardige kenmerken vertoont dan diegene waarmee het model al werd getraind.

Daarnaast ontwikkelen start-ups gespecialiseerde dienstverlening voor deep-learning puntenwolkeverwerking. Zo wil Pointly.ai (Pointly GmbH, 2020) ontzorgen in het trainingsproces. Het traint deep-learning modelen op maat van de projecten van de klant. Een ander voorbeeld is Point Cloud Technology (Point Cloud Technology GmbH, 2021) dat een platform is voor puntenwolkeverwerking dat volledig op machine learning is gebaseerd. Scantobim.ai (nCircle Tech Pvt. Ltd., 2020) ten slotte is een applicatie dat deep learning inzet om het proces versnellen van ruwe scans naar een BIM-model (Kaveh M et al., 2022).

3. CONCLUSIE

Het onderzoek naar automatische classificering van puntenwolken is sinds 2017 in een stroomversnelling geraakt dankzij het eerste model dat een puntenwolk zonder omzetting kon verwerken. De inherente karakteristieken van een puntenwolk zorgen ervoor dat succesvolle strategieën uit de beeldverwerking en 2D moeilijk te kopiëren zijn. De beschikbaarheid van uitgebreide trainingsdatasets om de prestaties van de verschillende modellen te vergelijken waren daarbij van belang.

De belangrijkste drempel voor de inzet van deep learning voor de landmeetkundige professional is de training van een model

voordat het een accuraatheid kan garanderen die manueel controlewerk minimaliseert. Daartoe is veel data nodig van een homogene kwaliteit, een grote servercapaciteit en veel rekenkracht.

Het trainen van een model voor specifieke landmeetkundige opdrachten blijft in elk geval een omvangrijke tijdsinvestering. In die zin zou doorbraak in het onderzoek naar self supervised learning (SSL) modellen een gamechanger betekenen (Changyu et al., 2024). Wanneer een SSL-model succesvol een puntenwolk kan classificeren zonder dat de ervaring met trainingsdata noodzakelijk is wordt de inzet deep learning echt laagdrempelig en zal haar toepassingsgebied onvermijdelijk sterk uitbreiden.

4. REFERENTIES

- Changyu Zeng, Wei Wang, Anh Nguyen, Jimin Xiao, Yutao Yue. (2024). Self-supervised learning for point cloud data: A survey. *Expert Systems with Applications*, Volume 237, Part B, 121354, ISSN 0957-4174,
- Croce, V., Caroti, G., De Luca, L., Jacquot, K., Piemonte, A., & Véron, P. (2021). From the Semantic Point Cloud to Heritage-Building Information Modeling: A Semiautomatic Approach Exploiting Machine Learning. *Remote Sensing*, 13(3), 461.
- ESRI, 2022. ArcGISpro, Detect Objects From Point Cloud Using Trained Model (3D Analyst) <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/detect-objects-from-point-cloud-using-trained-model.html>. (2 november 2023).
- Grilli, E., Menna, F., Remondino, F. (2017). A Review of Point Clouds Segmentation and Classification Algorithms. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XLII-2/W3. 339-344. 10.5194/isprs-archives-XLII-2-W3-339-2017.
- Hexagon Geosystems AG, (2023). *How to Improve Reality Capture Field Workflows with AI-Based Software*, <https://blog.hexagongeosystems.com/how-to-improve-reality-capture-field-workflows-with-ai-based-software/> (2 november 2023)
- Huang Zhang, Changshuo Wang, Shengwei Tian, Baoli Lu, Liping Zhang, Xin Ning, Xiao Bai, Deep learning-based 3D point cloud classification: A systematic survey and outlook, *Displays*, Volume 79, 2023, 102456.
- Kaveh Mirzaei, Mehrdad Arashpour, Ehsan Asadi, Hossein Masoumi, Yu Bai, Ali Behnood, (2022). 3D point cloud data processing with machine learning for construction and infrastructure applications: A comprehensive review, *Advanced Engineering Informatics*, Volume 51, 101501.
- nCircle Tech Pvt. Ltd. (2020). Scantobim.ai, <https://scantobim.ai/> (2 november 2023).
- Point Cloud Technology GmbH, 2021. Point Cloud Technology, <https://www.pointcloudtechnology.com>. (2 november 2023).
- Pointly GmbH, 2020. Pointly.ai, <https://pointly.ai/> (2 november 2023).

Qi, C., R. Su, H., Mo, K., Guibas, L., J. (2017). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation.

Quadros, Underwood, Douillard, (2013) Sydney Urban Objects Dataset,
<https://www.acfr.usyd.edu.au/papers/SydneyUrbanObjectsDataset.shtml> (31 oktober 2023)

Uwe Stilla, Yusheng Xu, (2023). Change detection of urban objects using 3D point clouds: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 197, 228-255,

Uy, M., A., Pham, Q., Hua, B., Nguyen, D., Yeung S., (2019). Revisiting Point Cloud Classification: A New Benchmark Dataset and Classification Model on Real-World Data. *International Conference on Computer Vision (ICCV)*.

Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang and J. Xiao
3D ShapeNets: A Deep Representation for Volumetric Shapes
Proceedings of 28th IEEE Conference on Computer Vision and Pattern Recognition (CVPR2015)