





# AUTOMATED LIDAR FEATURE EXTRACTION



Tom van der Putte  
Senior Innovatiemanager KIXS

De technische ontwikkeling op het gebied van sensoren staat niet stil. Sensoren worden kleiner, beter, zuiniger en goedkoper. Daardoor hebben we binnen Defensie inmiddels de beschikking over sensoren die voor gebruik te velde tot voor kort niet bruikbaar of beschikbaar waren. Eén voorbeeld hiervan is LiDAR. Een LiDAR sensor kan met behulp van infrarood licht een omgeving inscannen in 3D. Het resultaat geeft de gebruiker een ongeëvenaard inzicht in de omgeving. Grote nadelen zijn echter de Gigabytes aan data, en dat je een specialist moet zijn om met de data te kunnen werken. Om deze uitdagingen te overbruggen heeft KIXS samen met 11LMB het project Automated LiDAR Feature Extraction (ALFEX) opgezet. →



Gelabelde puntenwolk. (a) grond met begroeiing en overige objecten (b) alleen grond met overige objecten. Rood=daken, lichtgrijs=muren, lichtblauw=hekwerk, donkerblauw=voertuig, donkergrijs=overig object.

### LiDAR (Light Detection and Ranging)

LiDAR is een relatief oude techniek. Het concept bestaat al sinds 1960. De sensor bestaat in essentie uit een zender en een ontvanger, verpakt in één behuizing. De sensor zendt een lichtstraal uit in het infrarode spectrum. Nadat de lichtstraal weerkaatst op een object wordt deze weer opgevangen door de ontvanger. Op basis van het 'Time-of-Flight' principe kan uiteindelijk de afstand tot het object berekend worden. Dit, samen met de positie van de UAV, en de hoek van uitgezonden lichtstraal, leidt tot de juiste locatie van het aangestraalde object. De sensoren die Defensie op dit moment gebruikt kunnen zo'n 200.000 pulsen per seconde uitzenden.

Het uiteindelijke product wordt een puntenwolk (Engels: 'point cloud') genoemd, en kan vele miljoenen punten bevatten, meestal met zo'n 50-300 punten per m<sup>2</sup>. Een dergelijke puntenwolk geeft een volledig driedimensionaal beeld van een omgeving, wat enorm kan helpen bij het creëren van *situational awareness*. Daarnaast heeft LiDAR een aantal unieke voordelen waar het zich mee onderscheidt van bijvoorbeeld reguliere camera's. Omdat het een actieve sensor is (het zendt licht uit in plaats van dat het alleen beschikbaar licht ontvangt), kan deze ook 's nachts ingezet worden. Daarnaast kan het ook door hele kleine gaatjes in het bladerdek van bomen penetreren. Dat maakt dat het ook (beperkt) objecten in beeld kan brengen die onder bomen verscholen staan. Maar zoals alles heeft ook het gebruik van LiDAR nadelen. Omdat het een actieve sensor is, maakt dit de kans op onderkenning mogelijk groter. Daarnaast levert het een hele grote dataset op: een paar km<sup>2</sup> levert al gauw een bestand op van een aantal gigabytes. Het belangrijkste nadeel van LiDAR is dat het specialistische kennis vergt om de uiteindelijk data te benutten. Kennis die niet bij elke eenheid beschikbaar is, terwijl de behoefte aan het gebruik van dergelijke data er wel degelijk is.

### Probleem

Een aantal jaar geleden kreeg 11 Luchtmobiele Brigade de beschikking over een *ISR drone* (Trinity F90+) waar verschillende sensoren ('payloads') aan gekoppeld konden worden, waaronder

een LiDAR sensor (Qbase 240). 11LMB zag de potentie van de opgeleverde data. In elk vorm van militaire optreden zijn terrein, het type obstakels, de vorm en de hoogte ervan erg belangrijk. Maar dat geldt zeker voor het luchtmobiele optreden, waarbij operaties regelmatig vlak boven het terrein plaatsvinden. KIXS heeft gekeken naar de wensen van 11LMB en is vervolgens samen aan de slag gegaan. Het doel was om een puntenwolk om te zetten in data die door elke militair geïnterpreteerd en gebruikt kan worden zonder inzet van een specialist of ingewikkelde software. Daarnaast moet dit in de CP, maar ook te veld kunnen worden uitgevoerd. Samen met collega's van het Datalab zijn we op zoek gegaan naar oplossingen. Het probleem hebben we onderverdeeld in twee stukken: enerzijds het herkennen van objecten in een puntenwolk (ook wel classificatie genoemd), anderzijds deze op een bruikbare manier beschikbaar maken voor de eindgebruiker.

### Machine Learning

Het classificeren van een puntenwolk is niet eenvoudig. Traditionele algoritmes komen vaak niet verder dan het onderscheiden van grond, vegetatie en soms bebouwing. Daarnaast zijn deze traag en vaak onnauwkeurig. Daarom is vanaf het begin gekeken naar manieren om AI (Artificial Intelligence) te gebruiken. We hebben gekeken naar het zelf trainen en implementeren van *Deep Learning* modellen (een vorm van *Machine Learning*), maar ook naar de huidige stand van zaken op de markt.

Het voordeel van het gebruik van *Deep Learning* is dat je de computer kan leren om zaken te herkennen: een beetje op de manier zoals een mens dat ook doet. Het grote nadeel is dat je het wel heel veel voorbeelden moet voorschotelen, zogenoemde trainingsdata. Hiervoor hebben we handmatig bestaande puntenwolken geïnterpreteerd, om deze vervolgens te gebruiken om de *machine learning* modellen mee te trainen.

Collega's van het Datalab hebben verschillende methoden geprobeerd op basis van onze zelf geproduceerde trainingsdata. Daarnaast is er in het commerciële domein een aantal oplossin-



## OPERATIONEEL

gen getest met diezelfde trainingsdata. Al deze tests leverden dezelfde conclusie: er is op dit moment simpelweg te weinig data om goed te kunnen trainen.

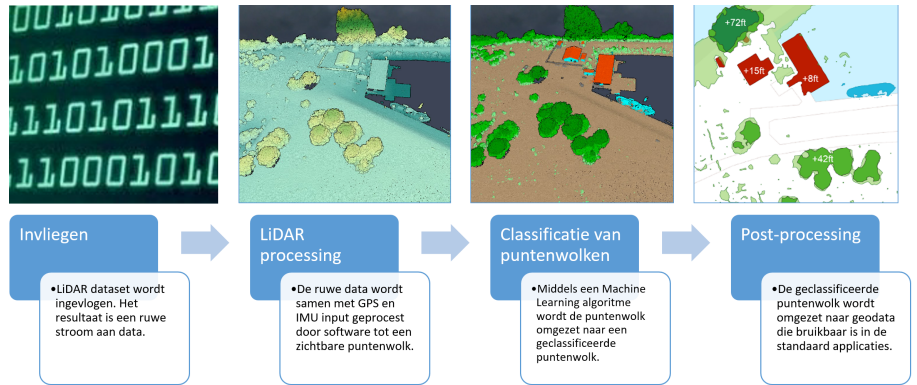
Dat gaf ons drie opties om het einddoel te bereiken:

1. Zelf heel veel trainingsdata invliegen en handmatig classificeren, wat een investering van honderden en wellicht duizenden uren vergt.
2. Synthetische trainingsdata gebruiken om modellen te trainen. Synthetische LiDAR data wordt gemaakt door een virtuele LiDAR sensor door een virtuele 3D wereld te laten vliegen. Omdat al bekend is wat voor een objecten er in de virtuele wereld zijn, is de resulterende puntenwolk meteen geïnclassificeerd. Hiermee kun je ontzettend snel opschalen. Maar omdat de data nooit 100% gelijk is aan 'real-world' data, is alleen synthetische data niet genoeg. Het model moet getraind worden met echte data.
3. Een model zoeken wat al door een ander getraind is, en wat goede resultaten oplevert.

Het zelf maken van trainingsdata viel ver buiten scope en planning van het project. Datzelfde gold voor optie 2: het inkopen van synthetische data. Uiteindelijk is het gelukt om een commerciële partij te vinden die een voorgetraind model had. De resultaten hiervan waren buitengewoon goed. Zelfs gedetailleerde objecten als hekwerken en schoorstenen werden juist herkend. Daarnaast is dit model erg robuust: het schaalte heel goed met verschillende LiDAR-sensoren en verschillende punt dichtheden. Gebruik van dit model geeft Defensie meteen een voorsprong van jaren. Tegelijkertijd is dit model ook beschikbaar voor anderen. Hoe we die voorsprong kunnen uitbouwen, daar kom ik later op terug.

### Verder processen

Aleen met succesvolle objectherkenning zijn we er nog niet. De objecten moeten vervolgens ook aan de eindgebruiker worden geleverd op zo'n manier dat deze zonder extra opleiding gebruikt kunnen worden. Hiervoor hebben we bij KIXS een zogeheten *pipeline* gemaakt: een set aan scripts en instructies die data volgens een bepaald recept kan processen. Dit is gemaakt met *Open Source* software, in combinatie met commerciële software: FME Forms. Dit is een *Extract Transform Load* (ETL) tool met een sterke focus op geo-data. Deze *pipeline* stelt ons in staat om geïnclassificeerde puntenwolken om te zetten naar regulier kaartmateriaal (punten, lijnen en vlakken), met daaraan extra informatie toegevoegd. Denk hierbij aan informatie als type object, grondhoogte en hoogte van het object t.o.v. de grond. Dit kaartmateriaal kan vervolgens op zo'n manier geëxporteerd worden, dat het in te lezen is in alle applicaties die kunnen omgaan met geo-data, zoals ArcGIS, WinTAK/ATAK en andere generieke of specialistische software.



Acquisitie en Geautomatiseerde objectherkenning opgedeeld in verschillende stappen voor het experiment


### Praktijktesten

Voor een techneut is het natuurlijk heerlijk om met dit soort zaken bezig te zijn, maar uiteindelijk doen we dit om de militair te ondersteunen. Daarom is het uitgewerkte concept bij Falcon Autumn in november 2023 uitvoerig getest. Hierbij is de hele cyclus van voor tot achter getest: van invliegen en scannen, tot aan het gebruik van de resulterende data in het reguliere proces. De uitkomsten waren overwegend positief:

- Het is niet alleen mogelijk, maar zelfs eenvoudig om het AL-FEX proces uit te voeren en in te passen in de huidige processen van informatieverzameling en verwerking. Dat betekent dat de impact op de procedures, en de O&T beperkt is, terwijl de toegevoegde waarde groot is.
- De informatie is nauwkeurig en precies, en makkelijk te begrijpen voor de eindgebruiker.
- De resulterende data is veel eenvoudiger te delen dan de ruwe puntenwolken: in plaats van Gigabytes, gaat het hier om een paar MB aan data.
- De data is ook 's nachts in te winnen.
- De data is in te winnen met een bepaalde *stand-off*. Dat maakt het in beginsel veiliger.

Uiteraard zijn er ook een aantal aandachtspunten en beperking gebleken. Dat begint bij het vliegen met de UAV, wat bepaalde kaders aan weersomstandigheden stelt. Hoe harder het waait, hoe slechter de resulterende data. Ook is de sensor niet te gebruiken in mist en regen. Daarnaast is het zo dat de huidige UAV (Trinity F90+) niet hoorbaar boven het omgevingsgeluid uitkomt als deze rechtuit vliegt, op een hoogte van ongeveer 100m boven de grond. Totdat deze een bocht maakt: dan is het geluid wel hoorbaar. Dat is dus ook een aandachtspunt voor aanschaf van toekomstige UAV. De zichtbaarheid van de LiDAR sensor met Night-Vision Goggles (NVG's) is niet getest in dit experiment.

Bovenstaande conclusies laten zien dat nieuwe techniek een *gamechanger* kan zijn zonder dat het andere zaken of procedures helemaal vervangt. Het kan ook een extra stuk gereedschap zijn in de gereedschapskist van de militair, dat ingezet kan worden op het moment dat het toegevoegde waarde heeft.



➤ 2D-kaart gegenereerd uit gelabelde puntenwolken. (a) objecten uit gegeveerd puntenwolken. (b) Open Street Map (c) Overlay van (a) op (b) ter referentie.

➤ 2D-kaart, met hoogte informatie van objecten, met daaronder de OpenStreet-Map kaart.

## Vervolg

Al met al heeft deze uitkomst 11LMB en KIXS voldoende vertrouwen gegeven om het experiment naar een hoger niveau te tillen. Tijdens *Bold Quest 2024* gaan we ditzelfde experiment nogmaals doen, maar nu volledig offline, op de *edge* (te velde), waarbij het uitgangspunt is dat de eindgebruiker aan de knoppen zit.

Daarnaast is er een Kort Cyclisch Innovatie (KCI) project opgestart om dit platform binnen het Defensie netwerk werkend te krijgen. Hierbij moet het systeem centraal kunnen worden gebruikt, en worden bijgetraind, met behulp van clusters van krachtige *graphics processing units (GPU's)*. Daarnaast moet het ook op mobiele hardware in het veld te gebruiken zijn om lokaal data te processen.



Dit geeft Defensie natuurlijk een mooie extra *capability*, maar wel één die *off-the-shelf* ook voor anderen beschikbaar is. Om een voorsprong te kunnen opbouwen, gaan we in het KCI-project ook een grote hoeveelheid aan synthetische data laten maken om het bestaande model bij te trainen. Hiermee kunnen we nieuwe objecten trainen, de herkenning van getrainde objecten verbeteren, maar vooral: we kunnen de hoeveelheid trainingsdata snel opschalen zodat we in de toekomst onafhankelijk van leveranciers onze eigen AI modellen kunnen beheren. 🛡️

