

Vegetatie in kaart brengen met AI & Remote Sensing in het stedelijk gebied van Ede



Eindverslag MSc Onderzoeksstage

Auteur: Frank Bouw

Juli 2025

Begeleider Aveco de Bondt: Dirk van Hout, Consultant Natuur & Duurzaamheid

Begeleider Wageningen University & Research: Thomas Janssen, Assistant Professor Plant Ecology and Nature Conservation



Voorwoord

Dit verlag en het bijbehorende onderzoek vormen onderdeel van mijn afstudeerstage bij Aveco de Bondt, die liep van half maart tot half juli. Dit was de laatste horde voor het afronden van mijn master Climate Studies aan de Wageningen Universiteit.

De stage begon met het idee vanuit Aveco de Bondt om te kijken naar de potentie van AI op het gebied van natuur in kaart brengen. Tijdens het vooronderzoek stuitte ik echter ook op interessante Remote Sensing bronnen, met name de puntenwolk van het AHN en de infraroodluchtfoto's. Hierdoor is de stage uiteindelijk een onderzoek geworden naar de potentie van AI en Remote Sensing voor het in kaart brengen van vegetatie in stedelijk gebied.

Gaandeweg is gekozen om het onderzoek toe te spitsen op heggen. Enerzijds omdat ze goed zichtbaar leken op de luchtfoto, anderzijds vanwege de ecologische relevantie van heggen. Daarnaast ontstond tijdens de stage ook het idee om het onderzoek uit te breiden naar groenmonitoring. Dit kwam door het zien van de infraroodluchtfoto's en het lezen van een interessant artikel over het in kaart brengen van groen in particulierentuinen. Omdat dit buiten een wetenschappelijk kader heeft plaatsgevonden is ervoor gekozen de resultaten hiervan in een apart hoofdstuk te verwerken.

Ik hoop dat met dit onderzoek voor Aveco de Bondt duidelijk is geworden wat mogelijk is op het gebied van vegetatie in kaart brengen met AI en Remote Sensing. Er zit in ieder geval veel potentie in het filteren van de puntenwolk van het AHN en het gebruik van objectherkenning AI op kaartbeelden of luchtfoto's.



Samenvatting

In de afgelopen eeuw is ongeveer 25% van de oorspronkelijke biodiversiteit verdwenen. Om dit tegen te gaan zijn er steeds meer kaders opgesteld, waaronder de Basiskwaliteit Natuur (BKN). Aveco de Bondt houdt zich hiermee bezig door te adviseren op het gebied van natuur-inclusief inrichten van het landelijk en stedelijk gebied. Dit doet Aveco de Bondt met onder andere de biodiversiteitsstresstest en de BioTwin tool. De huidige publiekelijk toegankelijke data voor het evalueren van de groenkwiteit is echter beperkt. Hierdoor ontstond de vraag om de potentie van AI voor het in kaart brengen van de groenkwiteit te onderzoeken. Uiteindelijk is het onderzoek gefocust op heggen in kaart brengen in het stedelijk gebied van Ede met Remote Sensing en AI.

Tijdens het onderzoek zijn twee methodes ontwikkeld en uitgewerkt. In de AI methode is getracht heggen in kaart te brengen met objectherkenning AI op kleurluchtfoto's. Dit is gedaan door een AI model te trainen op 1900 ingetekende heggen uit vijf trainingsgebieden in Ede. Dit model is eerst getest op het aantal iteraties in de training, waarna het beste model gebruikt is voor de validatie. Daarnaast is met de AHN methode getracht heggen in kaart te brengen door de puntenwolk van het AHN te filteren en te koppelen aan informatie uit de infraroodluchtfoto's. Dit is gedaan door informatie uit infrarood- en kleurluchtfoto's om te zetten naar de NDVI-index en door de relatieve hoogte van ieder punt te bepalen. Vervolgens is een drempelwaarde van 0.1 toegepast voor de NDVI-index om te bepalen of het vegetatie betreft en zijn de punten met een relatieve hoogte tussen de 0.5 en 2.5 meter behouden.

Tijdens veldwerk in twee gebieden, zijn twee datasets met de daadwerkelijk aanwezige heggen gecreëerd, voor het valideren en analyseren van beide methodes. Voor het gebied met veel bomen geldt dat 52% van de heggen gemist wordt, door alleen te kijken naar een luchtfoto, terwijl dit 27% is voor het gebied met weinig bomen. Om de prestatie van beide methodes te kwantificeren zijn de precisie (kwaliteit) en recall (volledigheid) bepaald. Beide bleken uiteindelijk onvoldoende om een precieze lokalisering van alle heggen te garanderen. Dit komt voornamelijk door de limitatie van de luchtfoto, die belangrijk is voor de objectherkenning en de NDVI-index. Toch was de volledigheid van de AHN methode vrij hoog en kwam de lage precisie vooral doordat ook struiken uit de puntenwolk meegenomen werden. Hierdoor lijkt deze methode wel geschikt om vegetatie te classificeren op basis van hoogte.

Naast het onderzoek naar heggen, is het onderzoek ook uitgebreid naar algemenere groenmonitoring met de NDVI-index kaarten. Met behulp van informatie uit de BAG en BRK zijn alle tuinen in het stedelijk gebied van Ede in kaart gebracht. Door dit te combineren met vegetatie informatie uit de NDVI-kaarten is uiteindelijk het groenpercentage van alle tuinen van 2016 t/m 2024 bepaald. Daarnaast is ook het groenpercentage van het hele stedelijke gebied bepaald. Over de jaren bleek veel fluctuatie aanwezig te zijn, doordat de NDVI-kaart afhankelijk is van omstandigheden, zoals het weer. Die fluctuatie bleek hetzelfde voor het hele stedelijke gebied en de tuinen, terwijl de trends anders zijn. Het percentage groen in de tuinen is namelijk met ongeveer 0.8% per jaar afgenomen, terwijl het percentage groen in het hele stedelijke gebied gelijk gebleven is.

Uit het onderzoek komt naar voren dat filtering van de AHN puntenwolk geschikt kan zijn om groen te classificeren op hoogte en dat AI geschikter is om eenvoudiger te herkennen objecten te detecteren. Daarnaast kan de groenmonitoring inzicht geven in de ontwikkeling van het aandeel groen in tuinen.



Begrippenlijst & Afkortingen

AI: Artificiële Intelligentie: In de context van dit onderzoek duidt AI op objectherkenning AI op kaartbeelden en/of luchtfoto's.

AHN: Actueel Hoogtebestand Nederland: Bronhouder van het hoogtebestand van Nederland. Zie [Hoofdstuk 2.2.1](#) voor meer informatie.

BAG: Basisregistratie Adressen en Gebouwen: Dataset met informatie over de ligging van panden.

Banden: Satellietbeelden en luchtfoto's zijn opgebouwd uit zogenaamde banden. Bij een kleurluchtfoto zijn dit de rode, groene en blauwe band die samen alle kleuren kunnen vormen. Bij een infraroodluchtfoto is de rode band vervangen voor de infrarode band, om zo vegetatie zichtbaar te maken.

BRK: Basisregistratie Kadaster: Dataset met informatie over de ligging van percelen.

DSM: Digitaal Oppervlakte Model: Raster met hoogtegegevens van alle objecten boven het maaiveld. Product van het AHN. Zie 2.2.1 voor meer informatie.

DTM: Digitaal Terrein Model: Raster met maaiveldgegevens. Product van het AHN. Zie 2.2.1 voor meer informatie.

GIS: Geografisch Informatiesysteem: Algemene benaming voor ruimtelijke data of het platform waarin de data wordt geanalyseerd. In dit onderzoek is het platform QGIS gebruikt.

Polygonen: Een dataformat in GIS voor vlakken. In GIS onderscheiden we punten, lijnen en vlakken. Vlakken worden ook wel polygonen genoemd. Dat komt van het Engelse 'polygons'

RS: Remote Sensing: In de context van dit onderzoek aardobservatie. Zie [Hoofdstuk 1.6](#) voor meer uitleg.

WFS: Web Feature Service: Een service die je in GIS kan toevoegen waardoor je online kaarten kan bekijken én kan bewerken.

WMS: Web Map Service: Een service die je in GIS kan toevoegen waardoor je online kaarten kan bekijken, maar niet kan bewerken.



Inhoudsopgave

Voorwoord	2
Samenvatting	3
Begrippenlijst & Afkortingen	4
Inhoudsopgave	5
1 Inleiding	7
1.1 Achtergrond	7
1.2 Aanleiding	7
1.3 Doelstelling	9
1.4 Hoofdvraag	9
1.5 Uitbreiding onderzoek	10
1.6 Remote Sensing	10
1.7 Artificiële Intelligentie	10
2 Methode	11
2.1 AI Methode: Objectherkenning AI op kleurluchtfoto's	11
2.1.1 AI objectherkenning model	11
2.1.2 AI objectherkenning model maken met Tygron	13
2.1.3 AI heggen model	14
2.2 AHN Methode: Puntenwolk AHN & Infraroodluchtfoto's	20
2.2.1 Puntenwolk AHN	20
2.2.2 Kleur- en infraroodluchtfoto's	22
2.2.3 Data analyse	23
3 Resultaten	24
3.1 AI Heggen model	24
3.1.1 Aantal epochs	24
3.1.2 Validatie	25
3.2 Puntenwolk resultaten	27
3.2.1 Visualisatie	27
3.2.2 Effectiviteit	28
4 Uitbreiding onderzoek: Groenmonitoring	29
4.1 Groenpercentage bepalen	29
4.2 Groenpercentage in particulierentuin	30
4.3 Groenmonitoring	31
4.4 Boomkruinoppervlakte	34
5 Discussie	35
5.1 Limitaties	35
5.1.1 Limitatie luchtfoto	35
5.1.2 Limitaties AI methode	36



5.1.3	Limitaties AHN methode	37
5.2	Methodes vergelijken	37
5.3	Discussie groenmonitoring resultaten	38
5.4	Potentiële andere toepassingen	39
6	Conclusies	40
7	Aanbevelingen	41
8	Dankwoord	42
9	Literatuur	43
10	Bijlagen	45
A:	Stappenplan: AI-model maken met Tygron en QGIS	45
B:	Belangrijke instellingen AI-model	47
C:	Stappenplan: Remote Sensing methode	47
D:	Stappenplan: NDVI kaart maken	48
E:	Stappenplan: Percentage groen berekenen voor een bepaald gebied	49
F:	Stappenplan: Groenpercentages in particulierentuin.	49



1 Inleiding

1.1 Achtergrond


De kwaliteit van de Nederlandse natuur en de bijbehorende biodiversiteit bevindt zich op een vrij laag niveau, vergeleken met een eeuw geleden [1], [2]. Onder druk van onder andere landbouwintensivering, verstedelijking en stikstofdepositie is in de afgelopen eeuw 25% van de oorspronkelijke biodiversiteit namelijk verdwenen [1]. Biodiversiteit is nauw verbonden met de gezondheid van de leefomgeving door zogenaamde ecosysteemdiensten [3]. Deze zijn onder andere bestuiving, plaagonderdrukking door natuurlijke vijanden, zuivering van water en lucht en het tegengaan van hittestress [3]. Door de achteruitgang van de biodiversiteit komen deze ecosysteemdiensten onder druk te staan, en gaat de kwaliteit en kwantiteit ervan achteruit [3].

Om het proces van biodiversiteitsverlies tegen te gaan, zijn steeds meer richtlijnen en kaders opgesteld, waaronder het Aanvalsplan Landschap en de Basiskwaliteit Natuur [2], [3]. Het Aanvalsplan Landschap bevat een richtlijn van 10% groen-blauwe dooradering van het landschap, wat overeenkomt met de Europese Biodiversiteitsstrategie [2]. Daarin staat dat minstens 10% van het landbouwareaal moet bestaan uit landschapselementen met grote diversiteit [2]. De Basiskwaliteit Natuur (BKN) is een initiatief van het voormalige Ministerie van Landbouw, Natuur en Voedselkwaliteit waarin de focus gelegd wordt op de verbetering van de kwaliteit van de natuur buiten natuurgebieden, dus in stedelijk en landelijk gebied [3]. In Nederland is lang de focus geweest op het beschermen en inrichten van Natura 2000 gebieden, terwijl de kwaliteit van de natuur buiten de natuurgebieden achteruit is gegaan. Daarom is de BKN specifiek gericht op de natuur in het landelijk en stedelijk gebied, door te kijken naar de condities die algemene soorten nodig hebben. Deze condities zijn abiotische factoren (bodem, water nutriënten), inrichting (habitat, groen-blauwe dooradering) en beheer (natuur-inclusieve landbouw) [3].

1.2 Aanleiding

Aveco de Bondt houdt zich ook bezig met de BKN door onder meer advisering op het gebied van natuur-inclusieve inrichting van stedelijk en landelijk gebied [4], [5]. Dit wordt gedaan door landschapstypen, natuurdoeltypen en de aanwezige flora en fauna te analyseren. Daarnaast wordt ook specifiek onderzoek gedaan naar de kwaliteit van de habitat voor bepaalde doelsoorten. Hiervoor gebruikt Aveco hun zelfontwikkelde biodiversiteitsstresstest waarin de geschiktheid van gebieden voor bepaalde doelsoorten wordt geanalyseerd, door te toetsen in hoeverre aan bepaalde habitatsvereisten, zoals voedselaanbod en nestelplekken, is voldaan. Hierdoor is het mogelijk om tekortkomingen in de habitat van een bepaalde doelsoort ruimtelijk in beeld te brengen.

In [Figuur 1](#) is een weergave van de biodiversiteitsstresstest zichtbaar. Dit is een GIS-tool die verschillende invoerlagen combineert om de habitatsgeschiktheid in kaart te brengen. Voor de verschillende invoerlagen wordt openbare data gebruikt. Voor waterelementen wordt de waterlegger van het waterschap gebruikt. Voor de groenkwaliteit wordt data uit het boomregister gebruikt. Voor lichtverstorend wordt data van de gemeente gebruikt over de locatie van lantaarnpalen. En voor geluidsverstorend een kaart vanuit Tygron. Tygron is een rekenplatform voor GIS-analyses, waar Aveco de Bondt een licentie voor heeft [6]. Dit wordt voornamelijk gebruikt voor water gerelateerde berekeningen. Echter zijn er ook nog meer functionaliteiten, waaronder de recentelijk toegevoegde AI-module, die in dit onderzoek gebruikt is.



Figuur 1: Visualisatie van de biodiversiteitsstress. Door de verschillende invoerlagen over elkaar heen te leggen in GIS ontstaat uiteindelijk een overzicht van de habitatschiktheid voor een bepaalde doelsoort.



Naast de biodiversiteitsstresstest, gebruikt Aveco ook hun BioTwin tool, waarmee ruimtelijk ontwerpen gecreëerd kunnen worden met real-time modelleren in Tygron. Daarbij kunnen habitatslementen toegevoegd worden om te onderzoeken wat dat met de geschiktheid van het gebied voor specifieke doelsoorten doet, door te evalueren of de inrichting voldoet aan de habitatseisen. De meeste habitatsvereisten zijn landschapselementen die nestelplekken of voedselvoorzieningen voor doelsoorten kunnen herbergen.

Het in kaart brengen van landschapselementen voor de biodiversiteitsstresstest en de BioTwin tool is echter uitdagend, omdat de beschikbare open data beperkt is. Voor bomen kan het boomregister geraadpleegd worden. Daarnaast heeft de gemeente meestal data beschikbaar van vegetatie in haar eigen beheer [7]. Echter is er dan nog veel vegetatie, met name op particulier terrein, buiten beeld.

1.3 Doelstelling

Daarom is het doel van dit onderzoek om te kijken in hoeverre landschapselementen in het stedelijke gebied, die een nestelplek of voedselvoorziening voor doelsoorten kunnen herbergen, versneld en geautomatiseerd in kaart gebracht kunnen worden. De focus ligt op het analyseren van de potentie van Remote Sensing en Artificiële Intelligentie (AI) voor het in kaart brengen van deze landschapselementen. Naast de kansen die AI en RS bieden voor de automatisering en versnelling van het in kaart brengen van landschapselementen, biedt het ook kansen op het gebied van het in kaart brengen van privaat groen. Ook biedt het geautomatiseerd en versneld in kaart brengen monitoringskansen.

Het landschapselement waar in dit onderzoek de focus op ligt is bepaald aan de hand van de habitatseisen die bepaalde doelsoorten stellen voor hun leefgebied, nestelgelegenheid en voedselvoorziening. Vanuit de expertise en kennis binnen Aveco de Bondt is gekozen om specifiek te onderzoeken in hoeverre het lukt om heggen in kaart te brengen. Heggen zijn namelijk belangrijk voor doelsoorten als de huismus en egel. Daarnaast zijn heggen zichtbaar op luchtfoto's en andere Remote Sensing bronnen, zoals infraroodbeelden en het Actueel Hoogtebestand Nederland (AHN).

Het onderzoek is gefocust op het stedelijk gebied van Ede. Dit onderzoek is namelijk in samenwerking met de gemeente Ede. Daarnaast is gekozen voor stedelijk gebied, omdat hier veel privaat groen aanwezig is en omdat de biodiversiteitsstresstest en de BioTwin tool voornamelijk toegepast worden op het stedelijk gebied.

1.4 Hoofdvraag

Met dit specifieke doel is uiteindelijk de volgende hoofdvraag voor het onderzoek opgesteld:
In hoeverre kunnen Remote Sensing (RS) data en objectherkenning Artificiële Intelligentie (AI) heggen in kaart brengen in het stedelijk gebied van de gemeente Ede?

Om het landschapselement heggen duidelijk ingekaderd te hebben, zijn heggen in dit onderzoek als volgt gedefinieerd: Heggen zijn een lijnvormige rij van aaneengesloten struiken van minimaal een halve meter en maximaal twee en een halve meter hoog. In dit onderzoek worden heggen en hagen beide aangeduid als heggen. In de werkelijkheid wordt een haag strak en frequent gesnoeid en een heg wordt minder frequent gesnoeid, en is daardoor ruiger.



1.5 Uitbreiding onderzoek

Naast het onderzoek om heggen in kaart te brengen, ontstond in de loop van de stage ook het idee om de potentie van Remote Sensing voor het in kaart brengen en monitoren van algemener groen te onderzoeken. Omdat dit een uitbreiding is op het onderzoek naar het in kaart brengen van heggen, is dit in een apart hoofdstuk verwerkt. Ook omdat dit deel van het onderzoek niet in een wetenschappelijk kader heeft plaatsgevonden. Dus de hoofdstukken: Methode en Resultaten gaan over het in kaart brengen van heggen. Daarna volgt het hoofdstuk: 'Uitbreiding onderzoek: Groenmonitoring', die verder ingaat op de uitbreiding van het onderzoek. Daarna komen de bevindingen over heggen en de bevindingen over groenmonitoring allebei aan bod in de Discussie, Conclusie en Aanbevelingen. Maar eerst worden de niet-alledaagse begrippen Remote Sensing en Artificiële Intelligentie in de volgende alinea's geïntroduceerd in het kader van dit onderzoek.

1.6 Remote Sensing

Remote Sensing (RS) is een term die gebruikt wordt voor technieken om informatie te verkrijgen over voorwerpen zonder rechtstreeks contact te hebben [8]. Het begrip wordt vooral gebruikt om aardobservatie aan te duiden. RS-technieken gebruiken actieve of passieve meetsystemen. Een passief meetsysteem detecteert met een sensor elektromagnetische straling, waaronder ook het zichtbare licht. Met passieve meetsystemen worden bijvoorbeeld satellietbeelden en luchtfoto's gemaakt. Een actief meetsysteem zendt daarentegen zelf signalen uit en detecteert die weer met een sensor. Twee voorbeelden hiervan zijn RADAR en LIDAR, waarmee met LIDAR bijvoorbeeld het hoogtebestand (AHN) gemaakt wordt [8], [9]. Een belangrijke eigenschap van een RS-beeld is de resolutie, wat het niveau van detail aanduidt. In dit onderzoek wordt de term uitsluitend gebruikt voor ruimtelijke resolutie, wat een maatstaf is voor het kleinste object wat gedetecteerd kan worden.

1.7 Artificiële Intelligentie

"Artificiële Intelligentie is een verzamelterm voor algoritmes en methodes die taken uitvoeren, waarvan werd geacht dat er menselijke intelligentie voor nodig is" [10]. Naast bekende vormen van AI, zoals ChatGPT, zijn er ook veel ontwikkelingen op het gebied van objectherkenning AI [11]. Dit is het type AI wat vanaf verschillende soorten beelden objecten kan herkennen, dus ook vanaf kaartbeelden of luchtfoto's [12]. Dit wordt al toegepast om vegetatie, bosbranden en andere zaken in kaart te brengen vanaf luchtfoto's [13]. Voor het maken van zo'n objectherkenning AI-model is veel trainingsdata nodig. Het type AI-model en de toepassing ervan wordt verder toegelicht in de Methode.



2 Methode

Het doel van het onderzoek is dus het in kaart brengen van heggen met RS en AI. In dit hoofdstuk wordt de methodiek hiervoor verder toegelicht. In dit onderzoek zijn twee methodes ontwikkeld en onderzocht. In de eerste methode wordt gebruik gemaakt van objectherkenning AI op hoge resolutie kleurluchtfoto's van Beeldmateriaal Nederland [14]. Deze methode wordt in het vervolg de 'AI Methode' genoemd. In de tweede methode wordt gebruik gemaakt van de puntenwolk data van het AHN in combinatie met infrarood- en kleurluchtfoto's van Beeldmateriaal Nederland [14], [15]. Deze methode wordt in het vervolg de 'AHN Methode' genoemd.

2.1 AI Methode: Objectherkenning AI op kleurluchtfoto's

De eerste methode tracht heggen te herkennen op hoge resolutie kleurluchtfoto's door middel van objectherkenning AI. In deze methode wordt uitgelegd hoe een AI-model getraind is met behulp van het Tygron platform. Onlangs heeft Tygron een nieuwe AI-functionaliteit toegevoegd, waardoor relatief gebruiksvriendelijk een objectherkenning AI-model gemaakt kan worden op basis van kaartbeelden, zoals luchtfoto's [12]. Hieronder wordt eerst uitgelegd wat een AI objectherkenning model inhoudt. Vervolgens wordt het algemene proces van het maken van een objectherkenning AI-model in Tygron beschreven. Daarna wordt de methodiek voor een AI heggen model in het stedelijk gebied van Ede verder toegelicht.

2.1.1 AI objectherkenning model

Een AI objectherkenning model is een model dat vanaf beelden objecten kan herkennen. In dit onderzoek is een AI-model gemaakt dat heggen kan herkennen vanaf hoge resolutie luchtfoto's. Het type AI-model dat hiervoor gebruikt wordt is een Mask R-CNN model [16]. Met dit type AI-model kan je individuele objecten detecteren én omlijnen. Bij objectdetectie wordt een selectiekader om het object geplaatst, waardoor het gedetecteerd is. Bij de omlijning van objecten, wordt een vlak getekend over het object waarbij de randen gevolgd worden. Dit heeft als voordeel dat de precieze locatie en de oppervlakte van het object bepaald kan worden. Een visualisatie van de omlijning en detectie is weergegeven in [Figuur 2](#).



Figuur 2: Visualisatie van omlijning en objectdetectie voor gebouwen. De gekleurde vlakken zijn het resultaat van de omlijning en de gestippelde vierkanten zijn de objectdetectie selectiekaders.

Mask R-CNN staat voor Mask Region-Based Convolutional Neural Network [16]. Dit is een state-of-the-art Convolutional Neural Network (CNN). Een CNN is een artificieel neurale netwerk voor beeldherkenning op pixel data [17]. Dit wordt in het model gebruikt om visuele patronen te leren herkennen. R-CNN is een type CNN waar de afbeelding in verschillende gebieden wordt opgedeeld en waar voor al die deelgebieden een CNN wordt toegepast om die visuele patronen te leren herkennen. 'Mask' in Mask R-CNN staat voor het vermogen van het model om de objecten precies te omlijnen [17].

Voor een goedwerkend Mask R-CNN model is veel data nodig. Dit is nodig om het model te trainen op het herkennen van bepaalde objecten. De trainingsdata voor het model zijn afbeeldingen met omlinnde objecten. In het voorbeeld van [Figuur 2](#) heb je een dataset nodig met afbeeldingen van luchtfoto's met omlinnde gebouwen. In het geval van heggen heb je dus afbeeldingen nodig van luchtfoto's met omlinnde heggen. Omdat geen pasklare dataset van luchtfoto's met de omlijning van heggen beschikbaar zijn, in dit onderzoek de trainingsdata met de hand gemaakt, maar eerst worden de stappen voor het maken van een AI-model in Tygron in het volgende hoofdstuk toegelicht.



2.1.2 AI objectherkenning model maken met Tygron

In Tygron is het dus mogelijk om relatief gebruiksvriendelijk AI-modellen te maken. Dat proces gaat in drie stappen. De eerste stap is het maken van trainingsdata, de tweede stap het maken van het AI-model en de derde stap het toepassen van het AI-model. In het verslag worden de stappen in hoofdlijnen beschreven. Voor een gedetailleerd stappenplan voor het maken van een AI-model met Tygron kan [Bijlage A](#) geraadpleegd worden. Dit hoofdstuk is bedoeld om het algemene proces te beschrijven. In het volgende hoofdstuk wordt de methode voor het maken, toepassen en valideren van het AI Heggen model beschreven.

2.1.2.1 Trainingsdata maken

Voor het maken van trainingsdata wordt gebruik gemaakt van QGIS. In QGIS wordt een kaartbeeld, luchtfoto of satellietbeeld ingevoegd dat gebruikt gaat worden. Belangrijk hierbij is dat het beeld waarop het model getraind wordt, ook het beeld is waarop het model het best kan toegepast worden. Vervolgens wordt een gebied uitgekozen waar de objecten ingetekend gaan worden. Belangrijk hierbij is dat alle objecten in dat bepaalde gebied ingetekend worden. Als input voor het maken van het AI-model is trainings- en testdata nodig. Ongeveer twee derde van de ingetekende objecten wordt gebruikt voor trainingsdata en één derde voor testdata. De trainingsdata wordt tijdens de training van het model gebruikt om het model te verbeteren en de testdata om het model na iedere iteratie te evalueren. Vervolgens worden de ingetekende objecten ingeladen in Tygron. Hier wordt dan hetzelfde kaartbeeld ingeladen wat gebruikt is voor het intekenen van de objecten in QGIS. In Tygron wordt vervolgens de 'AI Trainingsdata' exporteer functie gebruikt om van de ingetekende objecten en het kaartbeeld bruikbare input data te maken voor het creëren van het AI-model.

2.1.2.2 AI-model maken

Met de bruikbare inputdata vanuit Tygron kan vervolgens met behulp van de open-source Python repository van Tygron een AI-model gemaakt worden [18]. In deze repository zit een JupyterLab bestand waarmee stapsgewijs de instellingen voor het creëren van een AI-model ingesteld kunnen worden. Hierin wordt de inputdata geselecteerd en worden de instellingen aangepast op de eigenschappen van de inputdata. Een lijst met de belangrijkste instellingen en uitleg daarover is te vinden in [Bijlage B](#). Vervolgens kan het aantal epochs van het AI-model ingesteld worden. Die epochs, ook wel iteraties genoemd, zijn de hoeveelheid herhalingen in de training, waarmee het model zichzelf verbetert. Met te weinig epochs is het model te soepel en met te veel kan het model te streng worden. Hoelang het trainen duurt is afhankelijk van het aantal epochs en de hoeveelheid inputdata. Wanneer het hele proces doorlopen is wordt een ONNX bestand gecreëerd waar het AI-model in opgeslagen zit.

2.1.2.3 AI-model toepassen

Het ONNX bestand kan vervolgens in Tygron toegepast worden op een bepaald gebied. In Tygron moet het kaartbeeld ingeladen worden, waar het model op getraind is. Op dit kaartbeeld kan vervolgens het model toegepast worden en is de output een data laag met vlakken. Met een goedwerkend AI-model bevatten die vlakken voornamelijk het object in kwestie. Deze data laag kan vervolgens gebruikt worden in Tygron of geëxporteerd worden in een bruikbaar GIS format voor verdere analyse.

2.1.3 AI heggen model

Nu uitgelegd is hoe het model werkt en hoe het model gemaakt kan worden met behulp van Tygron, kan de methodiek voor het maken van een AI heggen model in Ede verder toegelicht worden. Eerst wordt toegelicht op welk bronbeeld het AI heggen model gebaseerd is en waarom. Vervolgens wordt uitgelegd hoe de trainingsdata gemaakt is. Daarna worden de verschillende modelinstellingen toegelicht. Hierna wordt uitgelegd hoe het model getest is op het aantal epochs. En als laatste wordt de methodiek voor het valideren van het model toegelicht.

2.1.3.1 Bronbeeld

Het AI heggen model is gebaseerd op de hoge resolutie kleurluchtfoto van 2024. Ieder jaar worden hoge resolutie kleurluchtfoto's gemaakt met een grondpixel resolutie van 8cm. Dit gebeurt in principe in het bladloze seizoen, tussen medio februari en medio april, zodat objecten onder bomen goed zichtbaar zijn. Tijdens inspectie van de luchtfoto's bleek echter dat dit voor het jaar 2024 niet het geval is en dat de vegetatie groen is. Door weersomstandigheden in het voorjaar van 2024 is de foto uiteindelijk pas richting de zomer genomen toen er blad aan de bomen zat. Doordat heggen op deze luchtfoto duidelijk zichtbaar zijn, is ervoor gekozen om het AI-model daarop te trainen. De hoge resolutie kleurluchtfoto kan met een Web Map Service (WMS) van het PDOK toegevoegd worden aan QGIS en Tygron [19].

2.1.3.2 Trainingsdata



Figuur 3: Kaart van de trainings- en validatiegebieden in het stedelijk gebied van Ede die gebruikt zijn voor het respectievelijk trainen en valideren van het AI-model. De validatiegebieden zijn ook gebruikt om de AHN methode te analyseren.

Na het bepalen van het kaartbeeld waar het AI-model op gebaseerd wordt, zijn vijf trainingsgebieden in Ede geselecteerd voor het maken van trainingsdata. De vijf trainingsgebieden zijn 500x500 meter en zijn weergegeven in [Figuur 3](#). De namen van de trainingsgebieden zijn gebaseerd op de wijken waar de trainingsgebieden in vallen. Bij de selectie van de trainingsgebieden is geprobeerd gevarieerde gebieden uit te kiezen die samen representatief zijn voor het stedelijk gebied van Ede. Daarnaast zijn er ook twee validatiegebieden uitgekozen voor het valideren van het model, waarover meer in [Hoofdstuk 2.1.3.5](#).

Vervolgens zijn voor elk trainingsgebied alle heggen ingetekend. Om dit proces te structureren is een grid met hokken van 50x50 meter over elk trainingsgebied heen geplaatst. Vervolgens is elke raster van het grid stapsgewijs afgegaan en zijn alle heggen ingetekend. Als voorbeeld is een overzicht van trainingsgebied Kernhem weergegeven in [Figuur 4](#). Daarnaast zijn in [Figuur 5](#) een aantal ingetekende heggen te zien ter illustratie.



Figuur 4: Overzichtskaart trainingsgebied Kernhem met 10x10 grid en alle ingetekende heggen.



Figuur 5: Visualisatie van intekenen heggen. Links een afbeelding waar de heggen nog niet zijn ingetekend en rechts een afbeelding waar de heggen zijn ingetekend.

In [Tabel 1](#) is onder andere te zien dat er in totaal 1902 heggen ingetekend zijn om trainingsdata van te maken voor het AI-model. De variatie aan trainingsgebieden wordt ook weerspiegeld in het aantal ingetekende heggen. In het trainingsgebied Kernhem zijn bijvoorbeeld veel meer heggen ingetekend, doordat de wijk veel heggen heeft in de voortuinen als erfafscheiding.

Tabel 1: Aantal ingetekende heggen per trainingsgebied

Trainingsgebied	Aantal ingetekende heggen
Kernhem	673
Ede-Veldhuizen	194
Maandereng	318
Ede-West	464
Ede-Oost	253
Totaal	1902

Na het intekenen van alle heggen is voor ieder trainingsgebied de dataset opgedeeld in een testdataset en een trainingsdataset. Voor het trainingsproces van het model is namelijk trainings- en testdata nodig. De trainingsdata wordt tijdens de training van het model gebruikt om het model te verbeteren en de testdata om het model na iedere iteratie te evalueren. Het opdelen van de dataset is gedaan door ongeveer 25% van het gebied te selecteren en dat voor de testdataset te gebruiken en de overige 75% te gebruiken voor de trainingsdataset. De grens tussen het test- en traingebied is zo veel mogelijk geplaatst op een plek waar geen heggen ingetekend zijn. In trainingsgebied Ede-West is dit bijvoorbeeld gedaan door een weg te volgen die het gebied doorkruist en ongeveer in 25% en 75% opdeelt.

Na het onderscheiden van de test- en trainingsdata is voor elk trainingsgebied een apart Tygron project aangemaakt. In dit Tygron project is vervolgens de hoge resolutie luchtfoto van 2024 ingeladen. Omdat de maximale resolutie in Tygron 0.1m is, is het raster van de luchtfoto daarop aangepast. Daarna is de test- en trainingsdata ingeladen. Vervolgens is de AI trainingsdata exporteer functie gebruikt om bruikbare test- en trainingsdata te maken voor het AI-model.

2.1.3.3 Instellingen

De geëxporteerde test- en trainingsdata is vervolgens gebruikt als input voor het AI-model. In [Bijlage B](#) is een overzicht te vinden van alle instellingen met uitleg. De instellingen zijn aangepast naar de eigenschappen van de heggen test- en trainingsdata. Daarnaast is het aantal epochs (iteraties in training) ingesteld op dertig. Om te kunnen controleren bij hoeveel epochs het model het beste werkt wordt na elke vijf epochs een model opgeslagen, zodat er uiteindelijk zes modellen zijn om te vergelijken.

2.1.3.4 Testen

Om te testen welk aantal epochs het beste werkt, worden alle zes de AI-modellen eerst toegepast op de vijf trainingsgebieden. Het toepassen gebeurt in dezelfde Tygron projecten die gebruikt zijn voor het maken van de trainings- en testdata. Hierin is het AI-model toegepast op het bronbeeld waar het model op gebaseerd is. Per gebied worden vervolgens de modellen vergeleken door de model output te vergelijken met de input. Dit wordt gedaan door alle individuele heggen langs te gaan en te bepalen of een heg wel of niet goed voorspelt is. In [Figuur 6](#) is een voorbeeld van de model output weergegeven, om een beeld ervan te krijgen. Duidelijk is dat in dit geval de ingetekende heggen ook door het model gezien zijn, maar dat er daarnaast ook veel andere stukken groen voor heg aan worden gezien.



Figuur 6: Voorbeeld van de modeloutput in trainingsgebied Kernhem. Links een weergave van de model input, ofwel de ingetekende heggen. Rechts een weergave van de model output, waarin de blauwe vlakken de model output zijn.

Om te kwantificeren hoe het model presteert wordt de precisie en de recall van het model bepaald [20]. De precisie zegt iets over de kwaliteit van de modeloutput en de recall, ook wel het terugvindpercentage, zegt iets over de volledigheid van de modeloutput [21]. Om de precisie en recall te kunnen bepalen van een dataset met veel heggen is het handig om dit geautomatiseerd te doen. Dat is gedaan door de volgende formules toe te passen [20].




$$\text{Precision} = \frac{tp}{tp + fp}$$

$$\text{Recall} = \frac{tp}{tp + fn}$$

- 'tp' staat voor true positive, wat staat voor alle juiste model voorspellingen. Dus alle daadwerkelijke objecten die juist voorspeld worden door het model
- 'fp' staat voor false positive, wat staat voor alle foutieve model voorspellingen. Dus alle output die niet de daadwerkelijke objecten zijn.
- 'fn' staat voor false negative, wat staat voor alle objecten die gemist worden door het model. Dus alle objecten die niet in de output zitten, terwijl ze er in werkelijkheid wel zijn.

In dit onderzoek naar heggen is de precisie dus het percentage heggen van de input dat ook in de output zit, ten opzichte van de totale output. In het voorbeeld van [Figuur 6](#), is de precisie 33%, omdat er in totaal 6 heggen in de model output zitten, waarvan er 2 overeenkomen met de input. De recall is het percentage heggen van de input dat ook in de output zit, ten opzichte van de totale input. In het voorbeeld van [Figuur 6](#), is de recall 100%, omdat er in totaal 2 ingetekende heggen zijn, die beide ook in de output van het model zitten.

Om te kunnen bepalen of een ingetekende heg wel of niet overeenkomt met de modeloutput, wordt de zogeheten Intersection-over-Union (IoU) methode gebruikt. Dit is een methode waarbij de overlap gekwantificeerd kan worden. In [Figuur 7](#) zijn de concepten intersection en union visueel weergegeven. De IoU is dan uiteindelijk het intersection-oppervlak gedeeld door het union-oppervlak. Dus in het geval van de heggen resulteert de union in een vlak waar óf een heg is ingetekend óf een heg uit het model komt óf allebei. De intersection resulteert in een vlak waar zowel een heg is ingetekend én voorspelt door het model. De oppervlakte van de intersection wordt dan gedeeld door de union, om de hoeveelheid overlap te bepalen. Als de IoU 1 is, vallen beide vlakken precies samen. Als de IoU 0 is, is er geen sprake van overlap. Voor het testen het model is een IoU drempelwaarde van 0.5 toegepast, wat betekent dat de model output als juist wordt gezien als er 50% overlap is met de model input. Met de IoU drempelwaarde van 0.5 kan vervolgens voor de zes modellen in de vijf trainingsgebieden de precisie en recall bepaald worden. Het model met het aantal epochs dat de hoogste precisie en recall heeft, presteert het best. Dit model wordt vervolgens gebruikt voor de validatie.



Figuur 7: Visuele uitleg van de concepten intersection en union



2.1.3.5 Validatie

Om het model goed te kunnen valideren, zijn alle heggen in kaart gebracht in twee validatiegebieden het stedelijk gebied van Ede, waarvan de ligging in [Figuur 3](#) is weergegeven. Bij de selectie van de validatiegebieden is voornamelijk rekening gehouden met een variatie in boomkroonoppervlakte. Dit om iets te kunnen zeggen over de model prestatie in een wijk met relatief weinig bomen en een wijk met relatief veel bomen. Bomen zorgen ervoor dat veel heggen niet zichtbaar zijn vanaf een luchtfoto. “De Bergen” is het validatie gebied met relatief weinig bomen met 7% boomkroonoppervlak en “Burgemeester” het gebied met relatief veel bomen met 33% boomkroonoppervlak [22]. Omdat achtertuinen veelal niet zichtbaar zijn vanaf de openbare weg, is ervoor gekozen het model te valideren in de openbare ruimte en voortuinen.

Allereest zijn voor deze twee validatiegebieden de heggen in de openbare ruimte en voortuinen ingetekend vanaf de luchtfoto, zoals ook gebeurd is bij het maken van de trainingsdata. Daarna zijn de gebieden eind juni 2025 bezocht en zijn alle heggen ingetekend zoals aangetroffen in de wijk. Dit is gedaan met de “Field Maps” applicatie van ArcGIS. Deze applicatie is speciaal ontwikkeld voor veldwerk, zodat er op een gebruiksvriendelijke manier data in het veld verzameld kan worden. In deze applicatie is de kaart ingeladen met ingetekende heggen vanaf de luchtfoto. Vervolgens is deze kaart in het veld aangepast. Dit is gedaan door alle ingetekende heggen te beoordelen door aan te geven of het in werkelijkheid ook een heg is. Daarnaast zijn heggen toegevoegd die nog niet ingetekend waren vanaf de luchtfoto, door ze in te tekenen in de applicatie. Hierdoor is er uiteindelijk een kaart van beide gebieden met alle heggen. Door dit te combineren met de kaart met ingetekende heggen vanaf een luchtfoto, kan een indicatie gegeven worden van het aantal heggen die gemist zijn door te kijken naar een luchtfoto.

Nadat de limitatie van het gebruik van de luchtfoto is gekwantificeerd, zijn de kaart met alle heggen en de kaart met heggen ingetekend vanaf een luchtfoto gebruikt om het AI-model te valideren in beide gebieden. Om eerlijk het model te valideren moeten eerst de vlakken van de model output in achtertuinen handmatig verwijderd worden, omdat tijdens het veldwerk de heggen in achtertuinen niet in kaart zijn gebracht. Nadat dit gedaan is voor beide gebieden, is de precisie en recall bepaald, zoals ook gedaan is bij het testen van het beste aantal epochs. Naast de precisie en recall is er ook gekeken naar de totale oppervlaktes van heggen in beide gebieden, om te onderzoeken of die goed bepaald kan worden met het model.

Daarna is er nog onderzoek gedaan naar het effect van na-filtering op de output. De output is na-gefilterd op basis van oppervlakte, omdat de ruwe output veel kleine vlakken bevat die geen daadwerkelijke heggen zijn. Omdat de precisie en recall bepaald wordt door het aantal heggen en niet de oppervlakte, kan het de precisie en recall bevorderen door de na-filtering toe te passen. Er is uiteindelijk gefilterd op een minimale oppervlakte van 1 m², omdat er ook nagenoeg geen heggen zijn ingetekend onder de 1 m².


2.2 AHN Methode: Puntenwolk AHN & Infraroodluchtfoto's

Naast de 'AI methode' is ook de 'AHN methode' ontwikkeld. Deze methode tracht heggen in kaart te brengen met behulp van de puntenwolk van het AHN & kleur- en infraroodluchtfoto's van Beeldmateriaal Nederland [14], [15]. Dit zijn twee Remote Sensing bronnen waar veel informatie in zit. Uit de puntenwolk van het AHN is de hoogte van objecten af te leiden en met de kleur- en infraroodluchtfoto's kan bepaald worden waar vegetatie zich bevindt. Door informatie uit beide bronnen te combineren kan je dus in theorie vegetatie met bijbehorende hoogte, zoals heggen, in kaart brengen. Hieronder komt eerst een toelichting van de data bronnen en vervolgens wordt verder ingegaan op de methode.

2.2.1 Puntenwolk AHN

De puntenwolk is de meest gedetailleerde dataset van het Actueel Hoogtebestand Nederland (AHN). Het is een dataset met alle punten die gemeten zijn met informatie over onder andere de coördinaten (x, y) en de hoogte (z). Het AHN gebruikt de LIDAR techniek voor het inwinnen van de data [9]. Dit is een techniek waarmee laserpulsen vanuit een vliegtuig naar het aardoppervlak worden gestuurd, gereflecteerd worden en weer ontvangen. Vanuit de duur van de laserpuls kan dan de hoogte berekend worden. De laserpulsen kunnen op verschillende hoogtes gereflecteerd worden, mits het eerste object wat de laserpuls tegenkomt deels doorlaatbaar is, zoals bomen of struiken. Hierdoor kan op dezelfde locatie de hoogte van de boom, de onderliggende heg en het maaiveld bepaald worden.

Het AHN4, het meest actuele hoogtebestand dat beschikbaar is in Ede, bevat ongeveer 10-14 meetpunten per m². Vanuit de puntenwolk wordt vervolgens een Digitaal Terrein Model (DTM) en een Digitaal Oppervlakte Model (DSM) gecreëerd, wat allebei rasterbestanden zijn met resoluties van 0.5 of 5 meter. Het DTM is een rasterbestand berekend door interpolatie van de laagste punten in de puntenwolk en het DSM een rasterbestand met een gewogen gemiddelde van alle punten die in een rasterpixel vallen. Het AHN wordt altijd ingewonnen in het bladloze seizoen, zodat zoveel mogelijk metingen het maaiveld betreffen. Het belangrijkste product van het AHN is namelijk het DTM. Dit komt doordat het AHN initieel bedoeld is voor analyses met water, waarvoor de hoogte van het maaiveld het meest relevant is. Ondanks metingen in het bladloze seizoen, wordt ook vegetatie gemeten door de aanwezigheid van houtige elementen, zoals stammen en takken. Dit is duidelijk zichtbaar op beelden van het Digitaal Oppervlakte Model (DSM), zoals weergegeven in [Figuur 8](#).



Figuur 8: Rechts een visualisatie van het Digitaal Oppervlakte Model. Links een kleurluchtfoto ter vergelijking.



De puntenwolk van het AHN is verkrijgbaar in de data room van het AHN [23]. Hier zijn echter alleen puntenwolken beschikbaar op kaartbladen van 5 km x 6.25 km. Naast de dataroom van het AHN, zijn ook via GeoTiles puntenwolken beschikbaar op kleinere kaartbladen van 1 km x 1.25 km [24]. Daarom is voor dit onderzoek gebruik gemaakt van de puntenwolken die beschikbaar zijn via GeoTiles. De puntenwolk is een zwaar bestand en beschikbaar in LAZ formaat. Dit formaat kan ingeladen worden in QGIS, waar een aantal functionaliteiten beschikbaar om de data te verwerken. De mogelijkheden hiermee zijn echter beperkt, dus wordt voor de data analyse gebruikt gemaakt van de PDAL library [25]. Dit is een open source library die veel gebruikt wordt voor het analyseren van puntenwolk data. Verschillende analyse stappen kunnen in een 'pipeline script' opgeschreven worden en dan toegepast worden. In dit onderzoek zijn de PDAL functionaliteiten gebruikt via de Python plug-in [26]. De specifieke methode om een dataset met heggen uit de puntenwolk te verkrijgen wordt uitgelegd nadat de infraroodluchtfoto data verder is toegelicht.

2.2.2 Kleur- en infraroodluchtfoto's

Landsdekkende kleur- en infraroodluchtfoto's worden jaarlijks gemaakt in opdracht van Beeldmateriaal Nederland [14]. Deze zijn onder andere beschikbaar via het PDOK met een Web Map Service (WMS) [19]. In het bladloze seizoen worden ieder jaar de hoge resolutie kleurluchtfoto's gemaakt, met een grondpixelresolutie van 8 cm. Dit gebeurt in het bladloze seizoen, zodat objecten onder bomen goed zichtbaar zijn. Daarnaast worden in de zomer 25cm resolutie kleur- en infraroodluchtfoto's gemaakt. Deze foto's laten de begroeiing van Nederland zien en zijn dus nuttig voor het in kaart brengen van vegetatie [14]. In [Figuur 9](#), is duidelijk zichtbaar dat vegetatie gedetecteerd wordt op de infraroodluchtfoto. Dit komt doordat het chlorofyl in de vegetatie infrarood licht reflecteert [27]. Infrarood- en kleurluchtfoto's zijn opgebouwd uit verschillende zogenaamde banden. Bij een kleurluchtfoto zijn dit de rode, groene en blauwe band die samen alle kleuren kunnen vormen. Daarom wordt de kleurluchtfoto ook wel de RGB luchtfoto genoemd. Bij een infraroodluchtfoto is de rode band vervangen voor de nabij-infrarode band, om zo vegetatie zichtbaar te maken. Nabij-infrarood is het infrarood met een golflengte die dicht bij het spectrum van zichtbaar licht zit.



Figuur 9: Links een visualisatie van de luchtfoto met nabij-infrarode band. Rechts de RGB luchtfoto zonder de infrarode band ter vergelijking.

De Web Map Service (WMS) van het PDOK is een online kaart waar je geen individuele banden uit kan halen. Dit is wel mogelijk wanneer de infrarood- en kleurluchtfoto's gedownload worden. Dat is voor dit onderzoek gedaan via GeoTiles, omdat je daar kaartbladen van 5km x 6.25km kan downloaden [24]. GeoTiles heeft daarnaast de puntenwolk van het AHN gekoppeld aan de infrarood- en kleurluchtfoto's. Daardoor is de puntenwolk verrijkt met de rode, groene, blauwe en infrarode band uit de luchtfoto's. Doordat dit een stap in de data-analyse scheelt is ervoor gekozen om de puntenwolk van het AHN via GeoTiles te downloaden, zodat de informatie over de hoogte gelijk gekoppeld is aan informatie van de kleur- en infraroodluchtfoto's.



2.2.3 Data analyse

Voor de data analyse is dus uiteindelijk de puntenwolk van het AHN gedownload via GeoTiles [24]. De data analyse bestaat uit 3 stappen. De eerste stap is om vanuit de puntenwolk de relatieve hoogte te berekenen, om de hoogte van objecten ten opzichte van het maaiveld te bepalen. De tweede stap is om de informatie uit de infraroodluchtfoto om ze zetten naar een bruikbaar dataformat, om te kunnen bepalen of iets vegetatie is of niet. De derde stap is om vervolgens de data te filteren op relatieve hoogte en op of iets vegetatie is of niet. Voor een gedetailleerd stappenplan kan [Bijlage C](#) geraadpleegd worden.

De hoogte in de puntenwolk is de hoogte boven NAP, en dat is in Ede ongeveer tussen de 9 en 45 meter [28]. Om de relatieve hoogte te bepalen wordt de hoogte van de punten in de puntenwolk van de hoogte van het maaiveld model afgehaald. Dit is gedaan door naast de puntenwolk ook het rasterbestand met de maaiveldhoogte in te laden. Dit rasterbestand heeft veel rasterpixels zonder data, die eerst zijn opgevuld door middel van interpolatie. Daarna is voor elk punt van de puntenwolk bepaald in welke rasterpixel het punt valt. Vervolgens is de hoogte van het punt afgetrokken van de hoogte van het maaiveld, om zo de relatieve hoogte te verkrijgen.

Om vanuit de infraroodluchtfoto te bepalen of iets vegetatie is of niet, is in dit onderzoek de zogeheten Normalized Difference Vegetation Index (NDVI) gebruikt. Deze index wordt berekend met de formule: $NDVI = (NIR - R) / (NIR + R)$, waarbij NIR de infrarode band aanduidt en R de rode band [29]. Met de NDVI kan de informatie over vegetatie uit de luchtfoto's gestandaardiseerd worden. De NDVI heeft waarden tussen de -1 en 1. Een NDVI dichtbij of gelijk aan -1 duidt water aan en een NDVI van 1 duidt op zeer dichte bebossing. Bij een NDVI hoger dan 0.1 wordt over het algemeen uitgegaan van vegetatie [30], [31], [32].

Nu de relatieve hoogte en de NDVI-index bepaald is wordt de data gefilterd. Er is gekozen om de data te filteren op een hoogte tussen de 0.5m en 2.5m. Daarnaast is de drempelwaarde van de NDVI voor vegetatie toegepast ($NDVI > 0.1$). Dit resulteert in een puntenwolk met alle punten waar vegetatie is tussen de 0.5 en 2.5 meter.

De methode is toegepast in de validatiegebieden die gebruikt zijn voor het AI heggen model. Dit is gedaan, omdat daar datasets zijn van alle aanwezige heggen. Dat maakt het mogelijk om ook deze methode te evalueren en te kijken hoeveel heggen in kaart gebracht kunnen worden. Vanwege tijdsgebrek is de methode niet verder ontwikkeld dan het filteren van de puntenwolk. Dit betekent dat de huidige output een bestand is met heel veel punten. Om van al die punten iets te kunnen zeggen is het aantal punten dat samenvalt met een heg bepaald. Dit is een maatstaf voor de precisie van de methode. Dus de precisie is het aantal punten dat samenvalt met een heg gedeeld door het totaal aantal punten. Daarnaast is ook gekeken hoeveel heggen in de validatiegebieden minimaal tien punten uit de puntenwolk bevatten. Dit is een maatstaf voor de recall (het terugvindpercentage) van de methode. Dus de recall is het aantal heggen met minimaal tien punten gedeeld door het totaal aantal heggen.



3 Resultaten

In dit hoofdstuk worden de resultaten van de twee methodes om heggen in kaart te brengen beschreven. Allereerst worden de resultaten van de AI methode beschreven, waar een AI-model voor heggen is gecreëerd. Daaropvolgend worden de resultaten van de Remote Sensing methode beschreven, waar de data uit puntenwolk van het AHN is gebruikt.


3.1 AI Heggen model

In dit hoofdstuk worden de resultaten van het AI Heggen model beschreven. Als eerste komen de resultaten van het testen van het best aantal epochs aan bod. Daarna worden de resultaten van de validatie gepresenteerd.

3.1.1 Aantal epochs

Zoals beschreven in de methode is het AI-model getraind met dertig epochs, waarbij elke vijf epochs een model is opgeslagen. Deze zes modellen zijn vervolgens toegepast op de vijf trainingsgebieden, om te bepalen welk aantal epochs het beste werkt. In [Figuur 10](#) is de precisie en recall voor de verschillende AI-modellen weergegeven. Hieruit blijkt dat de precisie relatief laag is en de recall relatief hoog. Dit betekent dat veel van de ingetekende heggen herkend worden, maar dat ook veel vlakken in de output zitten die geen ingetekende heg zijn. Dit terwijl de verwachting is dat ze allebei vrij hoog zijn, omdat het model toegepast is op hetzelfde gebied waarop het getraind is.

In [Figuur 10](#) is ook duidelijk zichtbaar dat het model met tien epochs over het algemeen het best presteert. De precisie en recall pieken beide bij tien epochs waarna beide waarden na vijftien epochs gelijk blijven. Dat geldt alleen niet voor de recall in trainingsgebied Ede-Oost, maar dat is de enige uitzondering. Daarom is het model met tien epochs verder gebruikt om te valideren. Ook voor de twee validatiegebieden is het model nog getest, waaruit bleek dat ook hier het model het best presteert bij tien epochs.



Figuur 10: Precisie en recall voor de zes modellen in de vijf trainingsgebieden. De legenda rechts geeft de kleur van een trainingsgebied aan.



3.1.2 Validatie

Om het model te kunnen valideren is veldwerk gedaan. Door het veldwerk kunnen de ingetekende heggen van de luchtfoto vergeleken worden met alle daadwerkelijk aanwezige heggen. De resultaten hiervan zijn weergegeven in [Tabel 2](#). Hieruit komt duidelijk naar voren dat in het validatiegebied met veel overhangende bomen (33% boomkruinoppervlak), slechts de helft van de heggen zichtbaar is op de luchtfoto. In het validatiegebied met relatief weinig overhangende bomen (7% boomkruinoppervlak), wordt 27% van de heggen gemist.

Tabel 2: Aantal heggen op de luchtfoto en het aantal heggen dat daadwerkelijk aanwezig was tijdens het veldwerk. Daarnaast ook de totale oppervlakte van beide heggen datasets. Ook is het percentage heggen op de luchtfoto t.o.v. het totaal weergegeven. Dat percentage is bepaald voor het aantal heggen en de oppervlakte.

Validatiegebied	Luchtfoto of veldwerk	Aantal heggen	Oppervlakte heg [m ²]
De Bergen (weinig bomen)	Luchtfoto	125	1730
	Veldwerk	172	2147
Percentage heggen gemist op luchtfoto		27%	19%
Burgemeester (veel bomen)	Luchtfoto	90	886
	Veldwerk	188	1854
Percentage heggen gemist op luchtfoto		52%	52%

Voor het valideren zijn de datasets met ingetekende heggen van de luchtfoto en ingetekende heggen tijdens veldwerk beide gebruikt. Dit om iets te kunnen zeggen over de modelprestatie op een luchtfoto én de algemene prestatie van de methode om heggen in kaart te brengen. Voor de validatie zijn heggen in achtertuinten eerst uit de model output van tien epochs gehaald. Daarna is gekeken naar de precisie en recall van het model. Dat is op dezelfde manier gebeurd als het testen van de verschillende epochs. In [Tabel 3](#) zijn hiervan de resultaten weergegeven. De precisie en recall zijn hoger voor het validatiegebied met minder bomen, wat ook de verwachting was. Daarnaast is een verrassend resultaat dat de precisie in validatiegebied Burgemeester hoger is voor veldwerk t.o.v. alleen de luchtfoto. Dit kan komen doordat een aantal heggen wel herkend is door het AI-model, terwijl die niet herkend zijn met het blote oog op luchtfoto's. Dit gaat dan veelal om randgevallen waar je van een luchtfoto niet goed kan beoordelen of iets wel of niet een heg is.

Tabel 3: Precisie en recall voor de twee validatiegebieden. Dit is bepaald voor de modelprestatie voor het in kaart brengen van heggen op een luchtfoto en voor het in kaart brengen van heggen tijdens veldwerk. De precisie en recall in de rijen met veldwerk geven dus de prestatie van de totale methode aan.

Validatiegebied	Luchtfoto of Veldwerk	Precisie	Recall
Burgemeester	Luchtfoto	20%	46%
	Veldwerk	22%	24%
De Bergen	Luchtfoto	50%	59%
	Veldwerk	50%	46%

In [Figuur 11](#) is de model output weergegeven voor de twee validatiegebieden, om een beeld van de output te kunnen krijgen. Voor validatiegebied Burgemeester is bijvoorbeeld duidelijk zichtbaar dat twee heggen onder bomen niet in de modeloutput zitten. Voor validatiegebied Bergen is zichtbaar dat er minder bomen zijn en daardoor ook meer heggen in de model output. Ook hier is een deel van de heggen gemist, omdat het rode beuk heggen zijn, waar het model niet op getraind is.

De Bergen



Burgemeester



Figuur 11: Visualisatie van de model output t.o.v. de heggen die in kaart gebracht zijn tijdens het veldwerk. De blauwe vlakken zijn de model output en de groene omlijnningen de ingetekende heggen.

Naast het valideren van alle individuele heggen zijn ook de totale oppervlaktes van de heggen datasets onderzocht. Dit om te kijken of naast het in kaart brengen van heggen de totale oppervlakte heggen bepaald kan worden aan de hand van het AI-model. De resultaten hiervan zijn weergegeven in [Tabel 4](#). Opvallend hierbij is dat de oppervlaktes heg van het veldwerk best in de buurt komen van de oppervlaktes uit de model output, terwijl de precisie en recall van beide modellen niet heel hoog zijn.

Tabel 4: Totaal oppervlakte heggen van de heggen ingetekend op de luchtfoto, heggen ingetekend tijdens veldwerk en heggen in de model output.

Validatiegebied	Oppervlakte luchtfoto of totaal [m ²]		Oppervlakte Model output [m ²]
Burgemeester	Luchtfoto	886	2134
	Totaal	1854	2134
De Bergen	Luchtfoto	1730	2028
	Totaal	2147	2028

Daarna is ook nog onderzocht wat het na-filteren van de ruwe modeloutput doet met de precisie en recall, waarvan het resultaat in [Tabel 5](#) zichtbaar is. De recall bleef hierbij gelijk, omdat bij het na-filteren alleen alle vlakken onder 1 m² eruit zijn gehaald. De precisie is daarentegen wel omhoog gegaan, omdat er minder onjuiste model voorspellingen zijn na het filteren.

Tabel 5: Precisie en recall na het filteren op vlakken > 1m2 in de modeloutput

Validatiegebied	Luchtfoto of totale methode	Precisie	Recall
Burgemeester	Luchtfoto	20% > 25%	46%
	Totale methode	22% > 28%	24%
De Bergen	Luchtfoto	50% > 60%	59%
	Totale methode	50% > 61%	46%

3.2 Puntenwolk resultaten

In dit hoofdstuk worden de resultaten van de AHN methode beschreven. De heggen data uit de 2 validatiegebieden wordt ook gebruikt om de AHN methode te analyseren. Hieronder volgt eerst een visualisatie van de gefilterde puntenwolk. Daarna wordt de effectiviteit van de methode beschreven. Vanwege tijdsgebrek in de stage is het niet gelukt om de gefilterde puntenwolk om te zetten in bruikbaarere vlakken data. Dit is een vervolgstap die vooralsnog mogelijk lijkt, maar nog tijd kost om verder uit te werken.

3.2.1 Visualisatie

In [Figuur 12](#) is een visualisatie van de gefilterde puntenwolk van het AHN voor delen uit de twee validatiegebieden. Voor validatiegebied De Bergen is duidelijk zichtbaar dat de puntenwolk in dit voorbeeld de meeste heggen eruit kan filteren. Omdat de methode de puntenwolk filtert op de relatieve hoogte en de NDVI-index worden echter ook andere groenelementen tussen de 0.5 en 2.5 meter meegenomen. In het voorbeeld van validatiegebied Burgemeester betreft dit een aantal punten die eigenlijk een boom of struik zijn ([Figuur 12](#)). In het geval van de boom kan dit komen doordat de NDVI-index aangeeft dat het groen is, en dat een object tussen de 0.5 en 2.5 meter onder de boom aanwezig is. Omdat de NDVI bepaald wordt op basis van de luchtfoto kan dit een vertekend beeld geven voor objecten onder bomen. Geparkeerde auto's onder bomen zitten bijvoorbeeld ook in de gefilterde puntenwolk. Daarnaast zijn ook plekken gevonden waar schuttingen in de gefilterde puntenwolk zitten. Naast ongewenste objecten onder bomen, zijn heggen onder bomen ook detecteerbaar. Dit is zichtbaar in validatiegebied Burgemeester, waar ook heggen onder bomen in de gefilterde puntenwolk zitten.



Figuur 12: Visualisatie van de gefilterde puntenwolk van het AHN in beide validatiegebieden.



3.2.2 Effectiviteit

Om iets te kunnen zeggen over de effectiviteit van de methode zijn de ingetekende heggen van het veldwerk gebruikt. Voor deze heggen is gekeken hoeveel punten van de gefilterde puntenwolk in de vlakken van de heggen vallen. Dit kan iets zeggen over de precisie van de methode. Daarnaast kan ook iets gezegd worden over de recall (het terugvindpercentage) door te kijken hoeveel ingetekende heggen punten uit de puntenwolk bevatten. Er is gekozen om het minimum hiervan op tien te zetten, zodat geen heggen worden meegenomen waar maar een paar meetpunten inzitten. In [Tabel 6](#) is de precisie en de recall van de methode zichtbaar voor beide gebieden.

Tabel 6: Precisie en Recall van de AHN methode

Validatiegebied	Precisie	Recall
Burgemeester	27%	72%
De Bergen	57%	87%

Bij deze methode is aardig wat ruis aanwezig. Dit is ook een observatie die gedaan is bij de visuele inspectie van de puntenwolk. Dit komt met name door alle andere vegetatie tussen de 0.5 en 2.5 meter die met de methode ook in de puntenwolk zitten. Dat zijn struiken, struwelen, kleine bomen en andere groenelementen. In validatiegebied De Bergen zit bijvoorbeeld een houtwal met struweel eronder waar 16% van de punten in vallen.



4 Uitbreiding onderzoek: Groenmonitoring

Tijdens de stage ontstond ook het idee om te kijken naar de kansen van Remote Sensing op het gebied van groenmonitoring. Dit kwam idee voort uit het zien van de NDVI-beelden in het stedelijk gebied in Ede. Daarnaast is het idee gevoed na het lezen van een artikel tijdens het vooronderzoek over het in kaart brengen van groen in particulierentuinen met behulp van de NDVI-index [33]. Dit is een artikel waarin het percentage groen in particulierentuinen voor heel Nederland berekend is, met als voornaamste doel de vergroeningspotentiaal te bepalen.

Met deze ideeën zijn een aantal kaarten gecreëerd. Dit betreft een kaart met het groenpercentage per buurt voor 2024, een kaart met het gemiddelde groenpercentage van particulierentuinen per buurt in 2024, en een kaart met het verschil in gemiddelde groenpercentages van particulierentuinen per buurt tussen 2016 en 2024. Daarna ontstond ook nog het idee om iets te doen met het monitoren van de 3-30-300 regel. Hiervoor wordt een voorbeeld gegeven voor het bepalen van de boomkruinoppervlakte met behulp van Tygron en het boomregister.

In dit hoofdstuk wordt eerst uitgelegd hoe het groenpercentage in een gebied bepaald kan worden. Daarna wordt de casus van groenpercentages in particulierentuinen behandeld. Vervolgens worden de groenpercentages van verschillende jaren vergeleken, om zo het groen te monitoren. Als laatste wordt nog een kort uitstapje gedaan naar het berekenen van de boomkruinoppervlakte per buurt, om de minimale 30% boomkruinoppervlakte in de 3-30-300 regel te kunnen kwantificeren.


4.1 Groenpercentage bepalen

Het groen in kaart brengen kan relatief eenvoudig met de NDVI-index die al voor een ander deel van het onderzoek uitgelegd is, maar hier volgt nog een beknopte uitleg. De NDVI is een index waarmee je de informatie over vegetatie vanuit de infraroodluchtfoto's standaardiseert. Dit gebeurt met de formule: $NDVI = (NIR - R) / (NIR + R)$, waarbij NIR de nabij-infrarode band aanduidt en R de rode band [29]. De NDVI heeft waardes tussen de -1 en 1. Een NDVI dichtbij of gelijk aan -1 duidt water aan en een NDVI van 1 duidt op zeer dichte bebossing. Een NDVI hoger dan 0.1 wordt gezien als drempelwaarde voor vegetatie [30], [31], [32]. In [Bijlage D](#) is een gedetailleerd stappenplan voor QGIS beschreven voor het maken van een NDVI kaart.

Naast het stappenplan is ook een geautomatiseerd python script voor in QGIS gemaakt. Als dit script gerund wordt, kan een jaartal, interessegebied en map waarin je de documenten wilt hebben geselecteerd worden. Het script downloadt vervolgens de benodigde kaartbladen, doet de hele analyse en laadt de NDVI-kaart van het gekozen jaartal in QGIS. Dit script is ook bijgevoegd bij het inleveren van dit verslag. Dit script doet precies hetzelfde als het volgen van alle stappen.

Het groenpercentage in een bepaald gebied kan dan bepaald worden door een binair rasterbestand te maken voor een NDVI hoger van 0.1. Dit wil zeggen dat alle rasterpixels met een NDVI groter dan 0.1 de waarde 1 krijgen en rasterpixels met een NDVI lager dan 0.1 de waarde 0 krijgen. Vervolgens kan je met het binaire raster en het gewenste gebied het aantal rastercellen met 1 en 0 binnen een bepaald gebied optellen. Het gemiddelde van alle nullen en enen resulteert dan in een groenfractie die gebruikt kan worden om het groenpercentage te berekenen. In [Bijlage E](#) is een gedetailleerd stappenplan voor QGIS beschreven voor het berekenen van het groenpercentage in een bepaald gebied.

Als voorbeeld is voor het stedelijk gebied van Ede het groenpercentage per buurt bepaald voor het 2024. De kaart hiervan is weergegeven in [Figuur 13](#). Hierin is een duidelijke ruimtelijke variatie in buurten zichtbaar. De Frankeneng buurt heeft bijvoorbeeld een laag groenpercentage, wat komt doordat het een industrieterrein is. De Burgemeester buurt juist weer een hoog groenpercentage, door dat er veel bomen zijn en relatief grote groene tuinen.




Figuur 13: Percentage groen in alle buurten in het stedelijk gebied van Ede in 2024.

4.2 Groenpercentage in particulierentuin

Met het binaire NDVI raster wat gecreëerd is, kan ook een analyse gedaan worden om het percentage groen in tuinen te bepalen. Hiervoor is alleen nog een polygoon laag nodig waarin alle tuinen staan. Hiervoor is de methode uit het artikel gebruikt [33]. Met de gegevens over panden, verblijfsobjecten en percelen kan uiteindelijk een polygoon laag gemaakt worden met alle particulierentuinen. Voor percelen kan geput worden uit de Basisregistratie Kadaster en voor panden en verblijfsobjecten uit de Basisregistratie Adressen en Gebouwen (BAG) van het PDOK. Met de polygoon laag voor tuinen kan het groenpercentage per tuin bepaald worden op dezelfde manier waarop het gedaan is voor alle buurten in het stedelijk gebied. Een compleet stappenplan hiervoor staat in [Bijlage F](#)

Als voorbeeld is deze analyse gedaan voor alle particulierentuinen in het stedelijk gebied van Ede. De analyse van de BAG resulteerde uiteindelijk in 36,000 tuinen. Voor al deze tuinen is het groenpercentage berekend en is het gemiddelde genomen voor een hele buurt. Een kaart van deze analyse is weergegeven in [Figuur 14](#). Op deze kaart zie je bijvoorbeeld dat in de Enka buurt het groenpercentage niet heel hoog is in de particulierentuin, terwijl uit [Figuur 13](#) bleek dat het groenpercentage van de hele buurt vrij hoog is. Dit zijn extra inzichten die gedaan kunnen worden door alleen de particulierentuin te analyseren.




Figuur 14: Gemiddeld percentage groen in particulierentuinen voor buurten in het stedelijk gebied van Ede in 2024.

4.3 Groenmonitoring

Naast een kaart met groen percentages voor een bepaald jaar, kan met de methodiek ook het percentage groen van meerdere jaren bepaald worden, om zo het aandeel groen te kunnen monitoren. Ter illustratie is dit gedaan voor het algemene groenpercentage in buurten met het verschil in tussen 2024 en 2016 ([Figuur 15](#)). Daarnaast is deze analyse ook uitgevoerd voor het verschil in oppervlakte groen in particulierentuinen tussen 2024 en 2016 ([Figuur 16](#)). Hierin valt op dat de meeste buurten over het algemeen groener geworden zijn, terwijl het groenpercentage in particulierentuinen achteruit lijkt te zijn gegaan. Hiervoor moeten een aantal wijken aan de rand van het stedelijk gebied even buiten beschouwing gelaten, omdat hier in de tussentijd ontwikkeling heeft plaatsgevonden.

Omdat de NDVI-beelden van elk jaar een momentopname zijn, is ervoor gekozen om de analyse te doen voor alle jaren van 2016 t/m 2024 om zo te kijken of en trend zichtbaar is. Voor 2021 kon het percentage groen niet bepaald worden, omdat geen luchtfoto's van de zomervlucht beschikbaar waren. In [Figuur 17](#) zijn twee grafieken weergegeven met het gemiddelde groenpercentages in tuinen en het gemiddelde groenpercentage van het hele stedelijke gebied. Uit deze grafieken blijkt dat behoorlijk wat fluctuatie in de data aanwezig is. Omdat een daadwerkelijke fluctuatie van het percentage groen ieder jaar onwaarschijnlijk lijkt, komt het waarschijnlijk door de methodiek. Het percentage groen is namelijk gebaseerd op de NDVI-index, die weer afhankelijk is van de infraroodluchtfoto. Hierin is de hoeveelheid chlorofyl in de vegetatie bepalend. Dit is weer afhankelijk van het moment waarop de luchtfoto is genomen.



Legenda

Vershil percentage groen 2024 t.o.v 2016

-20 tot -10

-10 tot -5

-5 tot 0


0 tot 5

5 tot 10

10 tot 15

ESRI Satellite

Figuur 15: Vershil in percentage groen per buurt tussen 2024 en 2016. Positieve waarden betekenen een toename in groen van 2016 naar 2024 en negatieve waarden betekenen een afname in groen van 2016 naar 2024. In bepaalde randbuurten kan de afname met name verklaard worden door bouw van nieuwe woningen en uitbreidingen op het industrieterrein.



Legenda

Vershil percentage groen 2024 t.o.v 2016

-20 tot -15

-15 tot -10


-10 tot -5

-5 tot 0

0 tot 5

ESRI Satellite

Figuur 16: Vershil in gemiddeld percentage groen in particulierentuinen per buurt tussen 2024 en 2016. Positieve waarden betekenen een toename in groen van 2016 naar 2024 en negatieve waarden betekenen een afname in groen van 2016 naar 2024. Er is dus over het algemeen minder groen in particulierentuinen in 2024 ten opzichte van 2016.




Figuur 17: Gemiddeld percentage groen in particulierentuinen in het stedelijk gebied van Ede (boven) t.o.v. het gemiddeld percentage groen in het hele stedelijke gebied (onder).

Ondanks de fluctuatie lijkt een trend zichtbaar voor het percentage groen in tuinen. Waar in de jaren 2016 t/m 2020 het groenpercentage nog 36% was is die in de jaren 2022-2024 nog 28%. De trendlijn in de grafiek geeft dit ook weer en komt overeen met een afname van 0.8% per jaar. Het percentage groen in het hele stedelijk gebied is daarentegen gelijk gebleven, zoals te zien is aan de vlakke trendlijn. Dit wekt zelfs de suggestie dat het groen in het openbare gebied is toegenomen, om te kunnen compenseren voor de afname in particulierentuinen. Deze bevinden zijn dus in lijn met de kaarten die gemaakt zijn voor het verschil in groen tussen 2024 en 2016. Echter moet bij het maken van dit soort kaarten rekening gehouden worden met de fluctuatie, om zo niet een verkeerd beeld te schetsen. Het maken van een trendlijn is daarom noodzakelijk.

4.4 Boomkruinoppervlakte

De 3-30-300 regel is ontwikkeld om een duidelijke vuistregel te hebben voor het groen in de stad [34]. De regel houdt in dat je 3 bomen moet kunnen zien vanuit ieder huis, dat je 30% boomkruinoppervlakte hebt en binnen 300 meter een park of andere groene plek. Om een deel van deze regel te kunnen analyseren is het percentage boomkruinoppervlakte per buurt in het stedelijk gebied van de gemeente Ede bepaald.

Voor het bepalen van de boomkruinoppervlakte is gekeken naar twee mogelijkheden. Enerzijds de data uit het boomregister [22], anderzijds naar het 'Foliage' AI-model van Tygron dat boomvlakken kan herkennen. De data uit het boomregister is gebaseerd op de puntenwolk van het AHN4, wat data uit 2022 is. Het Tygron model kan toegepast worden het standaard satellietbeeld dat in Tygron wordt ingeladen. Dit is een recent satellietbeeld. Na een korte visuele inspectie leek de data uit het boomregister meer overeen te komen met de boomkruinen en is ervoor gekozen die te gebruiken. In [Figuur 18](#) is het percentage boomkruinoppervlak per buurt in het stedelijk gebied van Ede weergegeven. Hieruit komt duidelijk naar voren dat veel buurten nog niet aan de regel voldoen en dat er dus werk aan de winkel is.



Figuur 18: Percentage boomkruinoppervlakte voor verschillende buurten in het stedelijk gebied van Ede

Naast dit voorbeeld zijn is door Tygron ook een methode ontwikkeld om de hele 3-30-300 regel kunnen analyseren, wie een aantal bedrijven al toepassen [35], [36]. Tygron heeft hier zelf een hele handleiding voor beschikbaar waarmee voor een gebied naar keuze de regel geanalyseerd kan worden [37].

5 Discussie

In dit hoofdstuk worden de Methode en Resultaten van het in kaart brengen van heggen met het AHN en met AI ter discussie gesteld. Daarnaast worden ook de resultaten van de uitbreiding van het onderzoek behandeld. Allereerst wordt de limitatie van een luchtfoto beschreven. Daarna worden de limitaties van beide methodes uiteen gezet. Daarna worden de voor- en nadelen van beide methodes aan bod komen. Hierna worden de groenmonitoring resultaten ter discussie gesteld. Als laatste worden andere potentiële toepassingen van AI en Remote Sensing voor het in kaart brengen van groen behandeld.

5.1 Limitaties

5.1.1 Limitatie luchtfoto

De eerste limitatie is dat je met een luchtfoto niet alles in beeld hebt. Die limitatie geldt voor beide methodes, omdat de luchtfoto voor de AI methode is gebruikt als bronbeeld en voor de AHN methode om de NDVI-index te bepalen. Daarin zijn drie factoren te onderscheiden. In [Figuur 19](#) zijn de drie factoren weergegeven, om een beeld ervan te kunnen krijgen. Als eerste het hellend effect van hoge objecten vanwege de hoek waarin de luchtfoto is genomen. Hierdoor is een deel van de omgeving rondom hoge objecten niet zichtbaar. Als tweede het schaduw effect, waardoor de slagschaduw van hoge objecten die valt op een deel van de omgeving, waardoor die niet tot nauwelijks zichtbaar is. Als derde het effect van overhangende objecten, voornamelijk bomen. Daaronder is ook niets zichtbaar, omdat een luchtfoto logischerwijs het bovenaanzicht geeft.



Figuur 19: Visualisatie van het hellende effect, het schaduw effect en het effect van overhangende bomen op de luchtfoto van 2024 (links, bewolkt) en 2023 (rechts, zonnig). De rode vlakken geven de BAG registratie van panden aan, wat de locatie van het pand op het maaiveld aangeeft. Daardoor is duidelijk zichtbaar dat een deel van de omgeving van het pand wegvalt door de hoek waarin de luchtfoto is genomen. Ook is er veel niet zichtbaar door de overhangende bomen en geeft de luchtfoto rechts ook een duidelijk beeld van het schaduw effect.



Het hellende effect viel mee, omdat er geen hoge gebouwen stonden. Wel bleek tijdens het veldwerk dat een aantal heggen die strak langs panden stonden, niet tot nauwelijks ingetekend waren vanaf de luchtfoto. Dus voor de AI methode is het effect minimaal. Voor de AHN methode zorgt het hellend effect hier en daar wel voor problemen, omdat er een locatieverschil tussen de luchtfoto en de puntenwolk van het AHN ontstaat. De puntenwolk heeft namelijk niet het hellende effect, waardoor sommige heggen in de puntenwolk ‘naast’ de heggen vanuit de luchtfoto liggen. Hierdoor kan de filtering van de NDVI-index ervoor zorgen dat sommige heggen (deels) onterecht eruit gefilterd worden. En ook voor deze methode geldt dat sommige heggen dichtbij gebouwen niet gezien worden.

Het schaduw-effect was voor de AI methode afwezig, omdat de 8cm resolutiebeelden van 2024 in Ede onder bewolkte omstandigheden opgenomen zijn. Voor de AHN methode is die limitatie wel aanwezig, omdat slagschaduwen zichtbaar zijn op de 25cm resolutiebeelden van 2024, waarop de NDVI-index gebaseerd is. Tijdens visuele inspectie bleek dat hierdoor delen van heggen wegvielen uit de gefilterde puntenwolk.

Het effect van overhangende objecten, met name bomen, is vooral merkbaar bij het validatiegebied met meer overhangende bomen. Hier was namelijk maar 48% van de ingetekende heggen tijdens het veldwerk zichtbaar vanaf de luchtfoto terwijl dat 72% was in het validatiegebied met minder bomen. Voor de AI methode zorgen overhangende bomen ervoor dat het AI-model de heggen eronder niet kan zien. Voor de AHN methode betekent het dat de filtering op basis van de NDVI gebeurt voor de boom in plaats van het object daaronder. Hierdoor worden alle objecten onder bomen aangezien voor heg, terwijl dat in veel gevallen ook auto's blijken te zijn.

5.1.2 Limitaties AI methode

Naast de limitatie van de luchtfoto zijn er ook nog andere limitaties voor de AI methode. De eerste limitatie is dat het AI-model alleen goed toepasbaar is op het bronbeeld waarop het getraind is. In dit geval is het model gebaseerd op de hoge resolutie luchtfoto van 2024, omdat dit jaar toevallig de vegetatie al in het blad was, terwijl dat normaal niet zo is. Dit betekent dat het model dus momenteel alleen goed toepasbaar is op dat beeld. Dit is ook getest, door te kijken hoe het model werkt op de luchtfoto van 2023 en dat bleek na een visuele inspectie niet goed te werken.

De tweede limitatie is de hoeveelheid trainingsdata. Na een gesprek met Tygron bleek dat hun zelfontwikkelde ‘Foliage’ AI-model waarmee ze onder andere loof- en naaldbomen proberen te detecteren gebaseerd is op 10.000 ingetekende bomen. Dat is een stuk meer dan de 1900 heggen die zijn ingetekend voor dit onderzoek.

De derde limitatie is de maximale pixelgrootte in Tygron. Die is namelijk 10cm, terwijl de hoge resolutie luchtfoto een pixelgrootte van 8cm heeft. Tijdens het inladen van de luchtfoto in Tygron wordt pixelgrootte aangepast naar 10cm, waardoor een deel van de precisie verloren gaat.

De vierde limitatie is dat het AI-model toegepast is op de luchtfoto van 2024, terwijl het veldwerk in 2025 heeft plaatsgevonden. Dit kan ervoor zorgen dat in de tussentijd heggen erbij zijn gekomen of verdwenen. Dit effect is deels onderdrukt, door een aantal net nieuw aangeplante heggen niet in te tekenen tijdens het veldwerk.



5.1.3 Limitaties AHN methode

Ook voor de AHN methode zijn nog een aantal limitaties te noemen naast de luchtfoto limitatie. De eerste limitatie is dat veel andere groenelementen tussen de 0.5 en 2.5 meter meegenomen worden. Dit betekent dat lage bomen, struiken en struwelen ook in de gefilterde puntenwolk zitten, wat nadelig is voor het in kaart brengen van heggen. Hierdoor is de precisie vrij laag.

De tweede limitatie is dat het huidige resultaat een gefilterde puntenwolk is, wat minder bruikbaar is dan vlakken. Dit is kort onderzocht, maar bleek niet zo eenvoudig als vooraf gehoopt. Dus vanwege tijdsgebrek is ervoor gekozen dat achterwege te laten.

De derde limitatie is dat de AHN puntenwolk dateert uit 2022. De informatie uit de luchtfoto die nodig is voor de NDVI-index is ook uit dat jaar. Dit kan ervoor dat sommige heggen niet in kaart zijn gebracht, doordat ze na 2022 aangeplant zijn. Dit geldt ook andersom voor heggen die in de tussentijd verdwenen zijn.

5.2 Methodes vergelijken

Met de resultaten en limitaties van beide methodes is het mogelijk ze te vergelijken. Als eerste worden de recall en precisie van beide methodes vergeleken, wat weergegeven is in [Tabel 7](#). Hieruit komt naar voren dat de AHN methode een hogere recall en precisie heeft. Dit betekent dat de kwaliteit én de volledigheid beter is als de AI methode. Dit geldt voor het validatiegebied met veel en met weinig bomen. Over het algemeen is de combinatie van precisie en recall van beide methodes te laag om een precisie lokalisering van individuele heggen te realiseren.

Tabel 7: Precisie en recall vergelijking van de AHN en AI methode

Validatiegebied	Precisie		Recall	
	AHN methode	AI methode	AHN methode	AI methode
Burgemeester	27%	22%	72%	24%
De Bergen	57%	50%	87%	46%

Naast het vergelijken van de prestatie van beide methodes om heggen in kaart te brengen is ook gekeken naar de voor- en nadelen van de AI en AHN methode. Er zitten ook wat algemenere voor- en nadelen van 'Objectherkenning AI met Tygron' en het 'filteren van de AHN puntenwolk' tussen. De voor- en nadelen zijn weergegeven in [Tabel 8](#).



Tabel 8: Voor- en nadelen van de AI en AHN methode

Voordelen AI	Bruikbaar format output data
	In theorie met elke jaarlijkse luchtfoto weer nieuwe data, mits je een goedwerkend model hebt.
	Een bestaand model kan in Tygron eenvoudig toegepast worden
Nadelen AI	Trainingsdata maken kost veel tijd, omdat het intekenen een tijdrovend proces is.
	Veel computer kracht nodig voor de analyse, vandaar dat het in Tygron plaatsvindt.
	Model is gebaseerd op trainingsbeelden waar die het beste op werkt, daarom moet er telkens nieuwe trainingsdata toegevoegd worden om het model up-to-date te houden.
	Huidig heggende model is gebaseerd op luchtfoto van 2024 en werkt alleen daar op.
Voordelen AHN	Hogere recall en precisie
	Minder computerkracht nodig voor de analyse
	De data-analyse blijft voor iedere nieuwe puntenwolk hetzelfde, dus het hoeft niet zoals het AI-model telkens verbeterd worden door trainingsdata toe te voegen
Nadelen AHN	AHN heeft om de ~3 jaar een nieuwe puntenwolk. Lagere frequentie t.o.v. luchtfoto's
	Het is nu ontwikkeld voor het toepassen op kleine gebieden. Voor opschalen moet het nog wat aangepast worden en zal het ook wat tijd kosten om de hele data analyse te doen.
	Neemt naast heggende ook ander groen tussen de 0.5 en 2.5 meter mee, kan ook een voordeel zijn als dit het doel is.

5.3 Discussie groenmonitoring resultaten

In deze paragraaf worden de groenmonitoring resultaten ter discussie te gesteld. Het eerste discussiepunt is dat de luchtfoto limitaties ook gelden voor de NDVI-kaart. Voor het berekenen van het groenpercentage geldt dat het bovenaanzicht het groenpercentage weergeeft. Dus in een verharde tuin met een grote boom kan het groenpercentage (berekend met de NDVI) 100% zijn. Daarnaast zorgen het hellende effect en slagschaduw ervoor dat delen van tuinen niet zichtbaar zijn. Voor kleinere tuinen is dit effect een groter probleem dan voor grotere. Het voordeel van het vergelijken van meerdere jaren is dat deze limitatie voor alle beelden het geval is. Door te kijken naar trends over jaren, kan dit verschil dus geminimaliseerd worden. Het kwantitatieve effect van de limitaties is moeilijk te bepalen, omdat de methode niet gevalideerd is. Er is ook geen validatie gedaan in het artikel over groen in particulierentuinen [33].

Een tweede limitatie is dat voor beide analyses gebruik is gemaakt van de huidige begrenzings van tuinen en buurten. Echter is tussen 2016 en 2024 de ligging en het aantal tuinen veranderd. Er zijn vooral huizen bijgebouwd in de buurten 'De Venen en Zanden' en 'Enka'. Hierdoor klopt de analyse met particulierentuinen niet in deze buurten. Dit zou verbeterd kunnen worden door de BAG en BRK gegevens uit 2016 te gebruiken. De historische percelen uit het BRK zijn echter niet openbaar toegankelijk, waardoor dat nog wat extra moeite en geld kost. Dit is iets waar in het vervolg rekening mee gehouden moet worden. In dit geval is er uiteindelijk rekening mee gehouden door te testen of de trendlijnen in de grafieken verschillen als een aantal wijken waar ontwikkeling heeft plaatsgevonden buiten beschouwing worden gelaten. Dit was niet het geval, waardoor de limitatie geen invloed heeft op de trendlijnen.



Een derde limitatie is dat in de verschilkaarten alleen gekeken is naar het verschil tussen 2 jaren, wat alleen het verschil tussen twee momentopnames weergeeft. Tijdens inspecties van de NDVI-beelden van de verschillende jaren zijn duidelijke verschillen zichtbaar. Daarom is ook gekeken naar alle jaren tussen 2016 en 2024 waar luchtfoto data van beschikbaar is, om zo toch te kunnen kijken of een trend zichtbaar is. Hieruit kwam naar voren dat veel fluctuatie in de data aanwezig is, maar toch trends zichtbaar zijn. Het percentage groen in particulierentuinen lijkt achteruit te gaan met ongeveer 0.8% per jaar, terwijl het gemiddeld percentage groen in alle buurten juist gelijk is gebleven.

In een onderzoek van het 'Compendium voor de Leefomgeving' komt echter duidelijk naar voren waarom monitoring op basis van de NDVI-beelden niet gedaan is: "Monitoring van groen in de stad is niet uitgevoerd, omdat de seizoens- en weereffecten per jaar te groot zijn voor nauwkeurige en betrouwbare ontwikkelingen in de tijd." [38]. Door het vergelijken van de grafieken voor het totale groen en de percentages in de tuinen is duidelijk dat die variatie inderdaad aanwezig is. Echter is er tussen de trend van het totale groen en het groen in de tuin een duidelijk verschil zichtbaar, terwijl de variatie in beide grafieken beide vergelijkbaar is.

5.4 Potentiële andere toepassingen

In deze paragraaf staan wat potentiële toepassingen van Remote Sensing en AI opgesomd. De potentiële toepassingen komen voort uit eigen ideeën, literatuuronderzoek en gesprekken met collega's. Dit is ter inspiratie voor eventuele vervolgonderzoeken.

- Vanuit de puntenwolk zijn houtwallen te onderscheiden van houtsingels. In een houtwal in het stedelijk gebied zijn duidelijk heel veel meetpunten tussen de 0.5 en 2.5 meter zichtbaar, terwijl bij een park met een lijn bomen (meer een houtsingel) nauwelijks meetpunten zijn tussen de 0.5 en 2.5m. Hierdoor zou je met informatie over de aanwezigheid van bomen iets kunnen zeggen over de aanwezigheid van ondergroei.
- In Tygron kunnen ook andere AI-modellen toegepast worden die openbaar beschikbaar zijn. Tygron heeft bijvoorbeeld zelf het 'Foliage' model dat best goed naald- en loofbomen kan intekenen op luchtfoto's.
- In Tygron is ook een uitleg over hoe je een gebied kan analyseren op de 3-30-300 regel met behulp van het Tygron platform. Hier gebruiken ze allerlei berekeningen voor om uiteindelijk ruimtelijke analyses te doen en te kijken of een bepaald gebied wel of niet aan de regel voldoet.
- Met de objectherkenning AI in Tygron zouden ook andere AI-modellen gemaakt kunnen worden met andere toepassingen:
 - Een AI-model die informatie uit topografische kaarten automatisch naar GIS data vertaald. Dit kan met het objectherkenning model, door te trainen op de verschillende 'objecten' die op de topografische kaart staan.
 - Een AI-model dat zonnepanelen kan detecteren. Er is ook een voorbeeld gevonden van een bedrijf dat zo'n AI model al in gebruik heeft [39]. Daarnaast heeft Tygron ook zelf een model dat zonnepanelen kan detecteren. Dit model is nog in ontwikkeling.



6 Conclusies

Na de uitvoering van dit onderzoek kunnen de volgende conclusies getrokken worden. Het onderzoek had de hoofdvraag: “In hoeverre kunnen Remote Sensing (RS) data en objectherkenning Artificial Intelligence (AI) heggen in kaart brengen in het stedelijk gebied van de gemeente Ede?”. Daarnaast is het onderzoek nog uitgebreid naar meer algemenere groenmonitoring.

- Met de AI methode kan momenteel niet precies de locatie van heggen bepaald worden. De precisie (kwaliteit) en recall (volledigheid) zijn beide laag, waarvan een groot deel verklaard kan worden doordat een deel van de heggen niet zichtbaar is op de luchtfoto. Daarnaast heeft het model moeite met het onderscheiden van heggen en ziet het soms ook stukken struik, boom of gras aan voor heg.
- Ook met de AHN methode kan momenteel niet precies de locatie van heggen bepaald worden. Hier bleek de recall voor een wijk met weinig bomen wel goed (87%). De voornaamste oorzaak voor de lage precisie hier is dat veel struiken en ander groen tussen de 0.5 en 2.5 ook meegenomen worden.
- Beide methodes werken minder goed in het lokaliseren van heggen in een gebied met veel bomen t.o.v. een gebied met weinig bomen.
- AI objectherkenning op luchtfoto's is geschikter voor het detecteren van objecten die eenvoudiger te herkennen zijn, zoals bomen en zonnepanelen. Voor bomen heeft Tygron bijvoorbeeld zelf al een AI-model ontwikkeld [40]. Er is wel een bedrijf die specifieke plantensoorten in kaart brengt met objectherkenning AI, maar die doen dat met zelf ingewonnen hoge resolutie luchtfoto's met drones [41].
- De AHN methode is geschikter om heggen én struiken te lokaliseren, in plaats van alleen heggen. Daarnaast kan het filteren van de AHN puntenwolk goed gebruikt worden om meerdere groenelementen in kaart te brengen op basis van hoogte. Dus niet uitsluitend heggen, maar dat groen gecategoriseerd wordt op basis van de hoogte. Het boomregister gebruikt bijvoorbeeld de puntenwolk om de locatie van bomen te bepalen [22].
- Het monitoren van groen met de NDVI-index heeft potentie. Met name het monitoren van het groen in particulierentuinen is een mooie toepassing. Echter moet hierbij uitsluitend naar trends gekeken worden, omdat de NDVI-index veel varieert door omstandigheden, zoals nattere of drogere periodes. In Ede bleek uiteindelijk het percentage groen tussen 2016 en 2024 in tuinen met 0.8% per jaar af te nemen, terwijl het percentage groen in het hele stedelijke gebied gelijk gebleven is (zie [Figuur 17](#)).



7 Aanbevelingen

- **AI Heggen model:** Verdere ontwikkeling van het huidige model wordt afgeraden. Je mist namelijk ongeveer 50% van de heggen in een wijk met veel bomen en 25% in een wijk met weinig bomen. Echter lijken er wel kansen te liggen voor het ontwikkelen van een AI heggen model met de AHN puntenwolk als extra input naast de hoge resolutie luchtfoto. Het is namelijk ook mogelijk om Deeplearning AI modellen te maken met meerdere input datalagen.
 - **AI objectherkenning:** Er wordt aangeraden om AI objectherkenning op luchtfoto's in het vervolg toe te passen op eenvoudiger te detecteren objecten, zoals bomen of zonnepanelen. Daarnaast wordt aangeraden om dan te kijken naar het toepassen van meerdere datalagen als input voor het AI model.
- **AHN puntenwolk:** Het wordt afgeraden de huidige methode te gebruiken om alleen heggen in kaart te brengen. Echter lijkt de methode wel geschikt om gecombineerd heggen en struiken in kaart te brengen. Daarnaast kan de methode uitgebreid worden naar het categoriseren van groen op basis van hoogte, door naast de 'heggen/struiken' klasse ook nog de 'gras/kruiden' klasse en 'bomen' klasse toe te voegen. Wel moet er dan nog gekeken worden naar het vertalen van punten data naar bruikbaardere vlakken data.
- **Groenmonitoring:** Het wordt aangeraden om de groenmonitoring methode te gebruiken om percentages groen over de tijd te monitoren. Met name de groenmonitoring van particulierentuinen kan helpen om cijfers te hebben over de vooruitgang of achteruitgang van het aandeel groen in tuinen. Voor de groenmonitoring wordt aangeraden om uitsluitend naar trends te kijken en niet naar losse jaren. Door de trend van groen in het hele stedelijke gebied te vergelijken met de trend in achtertuinen kan gecorrigeerd worden voor fluctuaties in de NDVI-index.
 - **3-30-300 regel:** Het wordt aangeraden om naar de handleiding voor een analyse van de 3-30-300 regel van Tygron te kijken [37]. Deze analyse kan inzichtelijk maken waar wel en waar niet voldaan wordt aan de regel. Dit kan helpen om concreter advies te geven voor vergroening van bepaalde gebieden. Er zijn ook voorbeelden van twee bedrijven die dit al doen met behulp van Tygron [35], [36].



8 Dankwoord

Ik ben dankbaar voor alle inzichten en kennis die ik op heb kunnen doen tijdens mijn stage. Voor de vaardigheden die ik mocht leren op sociaal en technisch vlak en de ervaring van het werken voor een adviesbureau. Dit alles had ik niet kunnen doen zonder de hulp van iedereen. Allereerst wil ik daarvoor Dirk van Hout bedanken voor het begeleiden van de stage. Ook wil ik Thomas Janssen van de WUR bedanken voor het begeleiden vanuit de Wageningen Universiteit. Verder ben ik dank verschuldigd aan Victor Beumer, Bart Berlee, Gijs Aarts en alle andere collega's voor hun hulp, inzichten en interessante gesprekken. Ook wil ik nog Frank Baars van Tygron bedanken voor de hulp met AI. Daarnaast ook Adriaan van Natijne voor de hulp met de puntenwolk van het AHN. Ik kijk terug op een leerzame en mooie tijd.

Daarnaast wil ik nog het gebruik van ChatGPT en Copilot erkennen. Ik heb het gebruikt voor het maken van scripts en hulp bij het werken met QGIS. Ook heb ik het gebruikt om een aantal concepten uitgelegd te krijgen en daar bronnen bij te geven, die ik dan vervolgens kon raadplegen.



9 Literatuur

- [1] 'Verlies natuurlijkheid in Nederland, Europa en de wereld | Compendium voor de Leefomgeving'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.clo.nl/indicatoren/nl144003-verlies-natuurlijkheid-in-nederland-europa-en-de-wereld>
- [2] 'Raamwerk Aanvalsplan versterking landschappelijke identiteit via landschapselementen', 2021.
- [3] 'Kennisdocument Basiskwaliteit natuur'.
- [4] 'Aveco de Bondt | Natuurinclusief bouwen en ontwikkelen'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.avecodebondt.nl/diensten/natuurinclusief-bouwen-en-ontwikkelen>
- [5] 'Aveco de Bondt | Biodiversiteit'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.avecodebondt.nl/maatschappelijke-opgaven/biodiversiteit>
- [6] 'Tygron Platform – Accelerated Simulations for Engineers'. Geraadpleegd: 18 juni 2025. [Online]. Beschikbaar op: <https://www.tygron.com/nl/>
- [7] 'Download bomen uit het Boomregister'. Geraadpleegd: 17 juni 2025. [Online]. Beschikbaar op: <https://gisfme.vwinfra.nl/fmeserver/apps/BoomregisterDownload>
- [8] J. M. Read en M. Torrado, 'Remote Sensing', *International Encyclopedia of Human Geography: Volume 1-12*, vol. 1–12, pp. 335–346, jan. 2009, doi: 10.1016/B978-008044910-4.00508-3.
- [9] 'AHN: The making of | AHN'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.ahn.nl/ahn-the-making-of>
- [10] 'Wat is kunstmatige intelligentie (AI)? | Kunstmatige intelligentie (AI) | Rijksinspectie Digitale Infrastructuur (RDI)'. Geraadpleegd: 26 mei 2025. [Online]. Beschikbaar op: <https://www.rdi.nl/onderwerpen/kunstmatige-intelligentie/wat-is-kunstmatige-intelligentie>
- [11] 'Object Detection: The Definitive Guide - viso.ai'. Geraadpleegd: 26 mei 2025. [Online]. Beschikbaar op: <https://viso.ai/deep-learning/object-detection/>
- [12] 'Get started with AI yourself: Open source and accessibility on the Tygron Platform – Tygron Platform'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.tygron.com/nl/blog/2025/03/05/get-started-with-ai-yourself-open-source-and-accessibility-on-the-tygron-platform/>
- [13] 'satellite-image-deep-learning'. Geraadpleegd: 5 juni 2025. [Online]. Beschikbaar op: <https://www.satellite-image-deep-learning.com/>
- [14] 'Beeldmateriaal Nederland'. Geraadpleegd: 5 juni 2025. [Online]. Beschikbaar op: <https://www.beeldmateriaal.nl/>
- [15] 'AHN'. Geraadpleegd: 5 juni 2025. [Online]. Beschikbaar op: <https://www.ahn.nl/>
- [16] K. He, G. Gkioxari, P. Dollár, en R. Girshick, 'Mask R-CNN', *IEEE Trans Pattern Anal Mach Intell*, vol. 42, nr. 2, pp. 386–397, mrt. 2017, doi: 10.1109/TPAMI.2018.2844175.
- [17] 'Everything About Mask R-CNN: A Beginner's Guide - viso.ai'. Geraadpleegd: 18 juni 2025. [Online]. Beschikbaar op: <https://viso.ai/deep-learning/mask-r-cnn/>
- [18] 'GitHub - Tygron/tygron-ai-suite'. Geraadpleegd: 18 juni 2025. [Online]. Beschikbaar op: <https://github.com/Tygron/tygron-ai-suite>
- [19] 'Home - PDOK'. Geraadpleegd: 18 juni 2025. [Online]. Beschikbaar op: <https://www.pdok.nl/>
- [20] Y. Xiao *e.a.*, 'A review of object detection based on deep learning', doi: 10.1007/s11042-020-08976-6.
- [21] 'The Confusing Metrics of AP and mAP for Object Detection / Instance Segmentation | by Yanfeng Liu | Medium'. Geraadpleegd: 1 juli 2025. [Online]. Beschikbaar op: <https://yanfengliux.medium.com/the-confusing-metrics-of-ap-and-map-for-object-detection-3113ba0386ef>
- [22] 'Boomregister'. Geraadpleegd: 27 juni 2025. [Online]. Beschikbaar op: <https://boomregister.nl/overzichtskaart-van-de-bomen-in-nederland/>
- [23] 'Dataroom | AHN'. Geraadpleegd: 11 juni 2025. [Online]. Beschikbaar op: <https://www.ahn.nl/dataroom>
- [24] 'GeoTiles: readymade geodata with a focus on the Netherlands'. Geraadpleegd: 11 juni 2025. [Online]. Beschikbaar op: <https://geotiles.citg.tudelft.nl/>



- [25] 'PDAL - Point Data Abstraction Library — Point Data Abstraction Library (PDAL)'. Geraadpleegd: 5 juni 2025. [Online]. Beschikbaar op: <https://pdal.io/en/stable/>
- [26] 'Python — Point Data Abstraction Library (PDAL)'. Geraadpleegd: 6 juni 2025. [Online]. Beschikbaar op: <https://pdal.io/en/stable/python.html>
- [27] 'Reflected Near-Infrared Waves - NASA Science'. Geraadpleegd: 6 juni 2025. [Online]. Beschikbaar op: https://science.nasa.gov/ems/08_nearinfraredwaves/
- [28] 'AHN Viewer | AHN'. Geraadpleegd: 18 juni 2025. [Online]. Beschikbaar op: <https://www.ahn.nl/ahn-viewer>
- [29] S. Huang, L. Tang, J. P. Hupy, Y. Wang, en G. Shao, 'A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing', *J For Res (Harbin)*, vol. 32, nr. 1, pp. 1–6, feb. 2021, doi: 10.1007/S11676-020-01155-1/FIGURES/2.
- [30] 'NDVI beelden: Ultieme gids in 3 stappen om ze te begrijpen en te gebruiken'. Geraadpleegd: 28 april 2025. [Online]. Beschikbaar op: <https://www.farm21.com/nl/ndvi-beelden-ultimate-3-stappengids/>
- [31] 'Gemiddelde groenmaat (NDVI) over het groeiseizoen | Atlas Natuurlijk Kapitaal'. Geraadpleegd: 28 april 2025. [Online]. Beschikbaar op: <https://www.atlasnatuurlijkkapitaal.nl/gemiddelde-groenmaat-ndvi-over-groeiseizoen>
- [32] J. Aryal, C. Sitaula, en S. Aryal, 'NDVI Threshold-Based Urban Green Space Mapping from Sentinel-2A at the Local Governmental Area (LGA) Level of Victoria, Australia', *Land (Basel)*, vol. 11, nr. 3, p. 351, mrt. 2022, doi: 10.3390/LAND11030351/S1.
- [33] 'Nederlandse tuin kan bijna drie keer groener'. Geraadpleegd: 9 april 2025. [Online]. Beschikbaar op: <https://www.climateadaptationservices.com/wp-content/uploads/2019/10/Nederlandse-tuin-kan-veel-groener.pdf>
- [34] C. C. Konijnendijk, 'Evidence-based guidelines for greener, healthier, more resilient neighbourhoods: Introducing the 3–30–300 rule', *J For Res (Harbin)*, vol. 34, nr. 3, pp. 821–830, jun. 2023, doi: 10.1007/S11676-022-01523-Z/FIGURES/1.
- [35] 'NL Greenlabel › Webinar "The 3-30-300-rule"'. Geraadpleegd: 4 juli 2025. [Online]. Beschikbaar op: <https://nlgreenlabel.nl/blog/nieuws/webinar-the-3-30-300-rule/>
- [36] M. J. Nieuwenhuijsen *e.a.*, 'The evaluation of the 3-30-300 green space rule and mental health', *Environ Res*, vol. 215, dec. 2022, doi: 10.1016/j.envres.2022.114387.
- [37] 'Demo 3-30-300 Project - Tygron Support wiki'. Geraadpleegd: 4 juli 2025. [Online]. Beschikbaar op: https://support.tygron.com/wiki/Demo_3-30-300_Project
- [38] 'Groen in de stad, 2022 | Compendium voor de Leefomgeving'. Geraadpleegd: 10 juli 2025. [Online]. Beschikbaar op: <https://www.clo.nl/indicatoren/nl300801-groen-in-de-stad-2022#technische-toelichting>
- [39] 'Zonnepanelen Archives - READAR'. Geraadpleegd: 10 juli 2025. [Online]. Beschikbaar op: <https://readar.com/tag/zonnepanelen/>
- [40] 'How to detect foliage using an Inference Overlay - Tygron Preview Support Wiki'. Geraadpleegd: 16 juli 2025. [Online]. Beschikbaar op: https://previewsupport.tygron.com/wiki/How_to_detect_foliage_using_an_Inference_Overlay
- [41] 'ecogoggle'. Geraadpleegd: 4 juli 2025. [Online]. Beschikbaar op: <https://www.ecogoggle.nl/>



10 Bijlagen

A: Stappenplan: AI-model maken met Tygron en QGIS

Algemeen stappenplan voor het maken van een AI-model. Voor het stappenplan wordt uitgegaan van basisvaardigheden in QGIS en Tygron. Met een basisvaardigheid GIS zijn de basisvaardigheden in Tygron vrij eenvoudig aan te leren. ([Handout Quickstart - Tygron Support wiki](#))

Vorbereidende stappen:

- Downloaden van de map “tygron-ai-suite” uit de GitHub: [GitHub - Tygron/tygron-ai-suite](#)
 - Anaconda installeren als dat nog niet het geval is.
 - QGIS installeren
1. Maken van trainings- en testdata in QGIS
 - o Teken van vlakken op een kaart van de gewenste objecten (bijv. Heggen)
 - De ‘Snapping tool’ kan helpen bij het goed laten aansluiten van aangrenzende vlakken. (Rechtermuisklik toolbar en dan snapping tool aanzetten)
 - o Ruimtelijke scheiding maken tussen de trainings- en testdata
 - Polygoonlaag maken voor het test gebied en voor het train gebied (ook opslaan als GEOSJON bestand voor importeren naar Tygron)
 - o Velden toevoegen aan attribuuttabel met de namen “Train_object” en “Test_object” (vul vooral het object in kwestie in, bijvoorbeeld Heggen)
 - ‘Select by Location’ tool uit de processing toolbox om objecten uit test of train gebied te selecteren.
 - Fieldcalculator gebruiken om:
 - Velden die bij de trainingsdataset horen waarde 1 geven in “Train_object” veld en 0 in “Test_object” veld.
 - Velden die bij de testdataset horen waarde 1 geven in “Test_object” veld en 0 in “Train_object” veld.
 - o Polygoon laag exporteren als een GEOSJON bestand
 2. Trainings- en testdataset importeren in Tygron
 - o Areas > Import Geo Data > In de Geo Data Wizard die dan opent:
 - Step 3: Filter based on Attribute name: Filteren op basis van naam en waarde 1 of 0 (dus alleen training- of testdata)
 - Step 7: Select Attributes: alleen test of train attribuut selecteren waar net op gefilterd is, zodat je alleen die attribuutnaam hebt
 - Group by Attribute gebruiken: 2 groepen aanmaken op basis van “Train_object” en “Test_object” attribuut.
 3. Training en Test gebied importeren in Tygron
 - o Areas > Import Geo Data > In de Geo Data Wizard die dan opent
 - Test of Train bestand selecteren en toevoegen
 - Voor beide areas een attribuut maken met ‘Train_Area’ of ‘Test_Area’
 4. Passende Overlay maken waarop getraind gaat worden
 - o Overlays > Geo data > WMS > Configuration Wizard > een WMS toevoegen in de WMS Wizard die dan opent. Bijvoorbeeld luchtfoto’s van het kadaster.
 - o Grid cell size aanpassen aan de resolutie van de luchtfoto.



- 'Update now' functie gebruiken met alleen deze overlay geselecteerd (zodat die niet alle andere overlays gaat berekenen)
- 5. Trainings- en testdataset exporteren vanuit Tygron als AI trainings- en testdata
 - Areas > Export Geo Data
 - Filter: juiste dataset ("Train_object" of "Test_object") of als je 1 dataset hebt met 2 attributen voor train en test daarop selecteren
 - Format: AI Training Data
 - Intersecting Areas optie aanvinken en attribuut selecteren dat de juiste intersecting area omschrijft ('Train_Area' of 'Test_Area' wat geïmporteerd is in stap 3)
 - Overlay selecteren die je wilt gebruiken
 - Image size and stride kunnen default blijven
- 6. ONNX-bestand creëren met Jupyterlab script van Tygron.
 - Anaconda openen > Environments > Import > "tygronai.yml" selecteren uit de tygron-ai-suite package van Tygron (dat laad alle benodigde packages)
 - Als de 'tygronai' environment er al is, hoef je het alleen aan te drukken om alle packages in het environment te 'activeren'
 - Jupyterlab openen > "example_config.ipynb" openen
 - Pad naar training en test data aanpassen
 - Model naam aanpassen
 - Instellingen model aanpassen aan de eigenschappen van de trainings- en testdata die zojuist is gecreëerd.
 - Aantal epochs (iteraties van de training) instellen.
 - Alle cellen in de volgorde van het script runnen. Uiteindelijk wordt een ONNX-bestand gecreëerd die automatisch wordt opgeslagen in de "tygron-ai-suite-main" folder.
- 7. ONNX-bestand (=AI-model) toepassen in Tygron: Tygron openen > ONNX bestand erin slepen > Inference AI overlay > alles instellen > Overlay layer met het toegepaste AI-model > Overlay exporteren en opslaan
- 8. Overlay met toegepast AI-model openen en analyseren in QGIS

De stap die het meeste tijd kost is stap 1: Het creëren van een training- en testdataset. Het hangt af van hoe groot die test- en trainingsdataset is, maar een beetje een goede dataset is vrij groot. De andere stappen kunnen in een dagdeel voltooid worden, afhankelijk van de grootte van de trainings- en testdataset en bepaalde instellingen voor het maken van het AI-model (aantal epochs). Dit stappenplan is deels gebaseerd op een Tygron Wiki pagina met uitleg over de Tygron AI module: [Demo Training Data Project - Tygron Preview Support Wiki](#)



B: Belangrijke instellingen AI-model

In deze bijlage staat een lijst met de belangrijkste instellingen voor het maken van een AI-model met het JupyterLab script wat in de Python repository van Tygron zit: [GitHub - Tygron/tygron-ai-suite](https://github.com/Tygron/tygron-ai-suite). Onderaan de uitleg staat ook een tabel met de instellingen voor het AI Heggen model.

- Resolutie: De resolutie van het kaartbeeld die vanuit Tygron geëxporteerd wordt als AI training data is de resolutie die ook ingesteld moet worden bij het maken van het AI-model: "setInputCellSize". Daar moet "cellSizeM" ingesteld worden op de resolutie van de input data.
- Afbeeldingsgrootte: vanuit Tygron kan je bij het exporteren de afbeeldingsgrootte instellen. Deze afbeeldingsgrootte moet in het script ook ingesteld worden. Dit kan gedaan worden bij de optie: "config.setInputSizes(inputWidth=200, inputHeight=200)". Als de afbeelding vanuit Tygron 200x200 is, moet dat hier ook ingesteld worden. Het is daarnaast van belang dat er niet meer dan 250 objecten per afbeelding in zitten.
- Epochs: aantal iteraties van het AI-model. Te weinig epochs zorgt voor een onnauwkeurig model en te veel kan zorgen voor een te strikt model. Dit is een beetje trial & error.
- scoreThreshold: drempelwaarde voor het meenemen van een object in het eind resultaat
- maskThreshold: drempelwaarde voor het meenemen van een pixel in een object.
- strideFraction: aantal overlap tussen de verschillende afbeeldingen.

Instelling	Waarde
cellSizeM in "setInputCellSize"	0.1
inputWidth & inputHeight in "config.setInputSizes"	200 & 200
Epochs	30

C: Stappenplan: AHN methode

1. Data downloaden:
 - a. Puntenwolk(en) die het projectgebied beslaan downloaden vanaf: [GeoTiles: readymade geodata with a focus on the Netherlands](https://geotiles.org/). Ver genoeg inzoomen voor kleinere kaartbladen, zodat het bestand niet te zwaar wordt: Voor meest recente AHN het LAZ bestand downloaden.
 - b. DTM raster (0.5m resolutie) downloaden die overlapt met de puntenwolk(en). Kan ook vanaf GeoTiles. Nu juist niet te ver inzoomen om de vanaf de grotere kaartbladen het DTM te kunnen downloaden.
2. Script gebruiken om met de puntenwolk en het DTM raster een CSV bestand te maken met alle punten die een NDVI>0.1 hebben en een relatieve hoogte tussen de 0.5 en 2.5 meter. Deze filtering kan ook nog naar behoefte aangepast worden. Zie het script zelf voor verdere details.
3. CSV bestand in QGIS inladen en resultaat bekijken (Layer > Add Layer > Add Delimited Text Layer)



D: Stappenplan: NDVI kaart maken

1. Zorg voor een polygoon laag met de omlijning van het interessegebied (in dit voorbeeld het stedelijk gebied van Ede)
 - a. Stedelijk gebied van Ede verkregen door het inladen van de Wijken kaart van het CBS ([PDOK - CBS Wijken&Buurten](#))
 - b. Inladen in QGIS via een Web Feature Service (WFS). Let op: niet te ver uitzoomen, zodat de WFS niet heel Nederland gaat inladen, dat kost meer data en tijd.
 - c. Buurten selecteren die in het stedelijk gebied vallen en die exporteren als een nieuwe polygoon laag. Oude WFS laag weer verwijderen
 - d. Deze laag samenvoegen. (Vector > Geoprocessing > Dissolve)
2. Kleur en infrarood luchtfoto's downloaden
 - a. Ga naar de volgende website: [GeoTiles](#).
 - b. RGB (kleur) en CIR (infrarood) kaartbladen downloaden die nodig zijn om het interessegebied te dekken (niet te ver inzoomen, dan krijg je kleinere vlakken waar je alleen AHN puntenwolken kan downloaden)
3. Verschillende RGB en CIR kaartbladen inladen en samenvoegen
 - a. Laad de RGB en CIR GeoTIFF bestanden in
 - b. Voeg alle RGB kaartbladen samen
 - i. Raster > Miscellaneous > Merge
 - ii. Alle RGB kaartbladen als input selecteren
 - iii. Let op: duurt best lang (paar minuten)
 - c. Doe hetzelfde voor alle CIR kaartbladen
 - d. Clip daarna beide kaartbladen naar het interessegebied.
 - i. Raster > Extraction > Clip raster by Mask layer
 - ii. Selecteer RGB raster en clip het naar de polygoon laag van het interessegebied en doe dat vervolgens ook voor het CIR raster
4. Haal uit het RGB kaartblad van interessegebied de rode band en uit het CIR kaartblad de infrarode band
 - a. "Rearrange bands" tool uit de toolbox (het is een GDAL tool)
 - b. Voor RGB: rode band (Band 1: red) eruit halen en rode band (R) noemen
 - c. Voor CIR: rode band (Band 1: red) eruit halen en infrarood (NIR) noemen
5. NDVI-raster laag maken
 - a. Raster calculator openen: Raster > Raster calculator
 - b. Input layers: Rode band (R) & Infrarode band (NIR)
 - c. Expression: $(NIR - R) / (NIR + R)$. (Op de plekken NIR en R de desbetreffende rasterlagen invoegen)
 - d. Output layer een naam geven en dan runnen

Naast het stappenplan is ook een geautomatiseerd python script voor in QGIS gemaakt. Als dit script gerund wordt, kan een jaartal, interessegebied en map waarin je de documenten wilt hebben geselecteerd worden. Het script downloadt vervolgens de benodigde kaartbladen, doet de hele analyse en laadt de NDVI-kaart van het gekozen jaartal in QGIS. Dit script is ook bijgevoegd bij het inleveren van dit verslag. Dit script doet precies hetzelfde als het volgen van alle stappen. Het script heeft daarnaast een shapefile nodig van alle kaartbladen in GeoTiles die te downloaden is vanaf deze website: ["Kaartbladen": map sheets | fwrite.org](#). Bij inleveren zit dit bestand ook bijgevoegd. Het is belangrijk dat in het script op de juiste manier naar dit bestand verwezen wordt.



E: Stappenplan: Percentage groen berekenen voor een bepaald gebied

1. Binair raster maken voor een bepaalde NDVI-waarde
 - a. Raster calculator openen (Raster > Raster calculator)
 - b. Input layer: huidige NDVI kaart
 - c. Expression: $NDVI > 0.1$ (of iets anders)

Dit resulteert in een binair raster, waar elke cel een waarde van 1 of 0 krijgt. De cellen met waarde 1, hebben een NDVI-waarde groter dan 0.1 en de cellen met waarde 0 hebben een NDVI waarde kleiner dan 0.1. Om nu het percentage groen te kunnen bepalen moet er nog een laatste stap gedaan worden.

2. Percentage groen toevoegen aan interessegebied polygoonlaag
 - a. "Zonal statistics" tool uit de toolbox
 - b. Input layer: interessegebied polygoonlaag
 - c. Raster layer: **Binaire** NDVI raster
 - d. Statistics to calculate: minstens 'Count, Sum, Mean'

Als nu de attributentabel van het interessegebied wordt geopend geeft het veld 'Mean' de groenfractie weer. Het veld 'Count' het totaal aantal cellen in het raster. Als dit vermenigvuldigd wordt met de resolutie (oppervlak van 1 cel), krijg je de totale oppervlakte van het interessegebied. Het veld 'Sum' heeft het aantal raster weer waar vegetatie aanwezig is. Als dit vermenigvuldigd wordt met de resolutie, krijg je de totale oppervlakte groen in het interessegebied. Dit kan je doen voor het hele interessegebied, maar ook voor bepaalde deelgebieden.

F: Stappenplan: Groenpercentages in particulierentuin.

Stappenplan polygoon laag tuinvlakken:

1. WFS van BAG (voor panden) en kadastrale kaart (voor percelen) toevoegen aan QGIS
 - a. [Home - PDOK](#) > Bekijk alle datasets > Zoek op BAG & percelen > WFS link van BAG en kadastrale kaart > WFS toevoegen aan QGIS via Data Source Manager
2. Datalagen pand, verblijfsobject & percelen openen
 - a. Zorgen dat het kaartvenster niet heel erg uitgezoomd is bij het inladen van de data
 - b. Vanuit de BAG WFS de data lagen 'pand' en 'verblijfsobject' openen
 - c. Vanuit de kadastrale kaart WFS de data laag 'perceel' openen
 - d. Alle drie de data lagen clippen naar het gebied van interesse (bijv gemeente grens) en opslaan als een GeoPackage (gpkg) bestand, omdat dat format de volgende stap beter ondersteunt.
3. Data-laag maken met alle percelen (polygoon) waar verblijfsobjecten (punten) inzitten
 - a. "Join attributes by location" tool in de toolbox
 - i. "Join to features in" : percelen
 - ii. "Features they" : contain
 - iii. "By comparing to" : verblijfsobjecten
 - iv. Optie "Discard records which could not be joined" aanvinken, zodat alleen percelen met een verblijfsobject overblijven.
4. Filteren op percelen met woonfunctie
 - a. "Extract by attribute tool" in de toolbox
 - i. Attribute: gebruiksdoel



- ii. Operator: “=”
 - iii. Value: “woonfunctie”
- 5. Laag met tuinen maken
 - a. “Difference” tool gebruiken: Vector > Geoprocessing tools > Difference
 - i. Input layer: percelen_met_woonfunctie
 - ii. Overlay layer: panden

Nu is er een polygoon laag gemaakt met alle tuinen als vlakken. Dit is net zoals met buurten in het stedelijk gebied een data laag om de vegetatie informatie die in het binaire raster zit aan toe te voegen.

- 6. Percentage groen toevoegen aan tuinen polygoonlaag
 - a. “Zonal statistics” tool uit de toolbox
 - b. Input layer: tuinen polygoonlaag
 - c. Raster layer: **Binaire** NDVI raster
 - d. Statistics to calculate: minstens ‘Count, Sum, Mean’

Dan geeft het veld ‘Mean’ weer de groenfractie aan. Door met de veldcalculator van de attribuuttabel een veld toe te voegen genaamd groen percentage waar de volgende expressie wordt toegepast: “_mean” * 100. Nu is dus van elke tuin (op een perceel met woonfunctie) in Ede het groenpercentage bekend, en dat zijn bijna 36000 tuinen. Om nu weer iets te kunnen zeggen over het percentage groen in tuinen in verschillende buurten, kan de volgende stap ondernomen worden.

- 7. Gemiddeld percentage groen in tuinen per buurt bepalen
 - a. “Join Attributes by location (Summary)” tool uit de toolbox
 - b. Join to features in: data laag met buurten (eventueel de data laag met ook het percentage groen in de hele buurt)
 - c. Where the features: ‘contain’
 - d. By comparing to: tuinen data laag met oppervlakte groen (uit de vorige stap)
 - e. Field to summarise:
 - i. Count: Dat is het veld wat iets zegt over de oppervlakte per tuin
 - ii. Sum: Dat is het veld wat iets zegt over de groenoppervlakte per tuin
 - iii. Mean: Dat is het veld wat iets zegt over het groenpercentage per tuin
 - f. Summaries to calculate: sum & mean. Dan kan je iets zeggen over de totale (groen)oppervlakte van tuinen en iets over het gemiddelde groen percentage per tuin.