




Kartering van oever- en waterplanten vanuit de lucht

Aquatische vegetatie karteren op basis van airborne remote sensing beelden door middel van multispectrale classificatie en objectherkenning

Dion van Deijl, Erwin Vonk, Gé van den Eertwegh,
Sandra Gaytan Aguilaren, Rowland de Roode en Ellis Penning

Definitief

Datum: 26-1-2021

Opdrachtgever:



Hoogheemraadschap van
Rijnland

Samenvatting

Aquatische vegetatieopnamen in het veld zijn arbeidsintensief en niet vlakdekkend voor een geheel gebied. Hierdoor kan het zijn dat knelpunten, zoals watergangen met bijvoorbeeld veel flab, en/of bijzondere vegetatie-soorten ontbreken in de opnamen. Ook is het daarmee steeds de vraag of de veldwaarnemingen een compleet beeld en daarmee oordeel opleveren voor het gehele watersysteem. Daarnaast zijn er kosten verbonden aan de opnamen, maar geldt ook voor andere manieren van gegevens inwinnen.

In dit onderzoek is verkend of en hoe remote sensing technieken kunnen worden ingezet voor de aquatische vegetatieopnamen i.c. herkenning van diverse groeivormen en Krabbenscheer. Dit is gedaan met volgende doelen:

1. Verkennen of de kwaliteit van de kartering met remote sensing technieken vergelijkbaar is met de huidige handmatige inventarisaties in het veld.
2. Verkennen of karteren met remote sensing goedkoper en minder arbeidsintensief is dan de huidige gebiedsdekkende inventarisaties van oever- en waterplanten, dan wel een meerwaarde heeft die tot (redelijke) meerkosten leidt.

De verkenning is gedaan in Polder Stein. In deze polder zijn beelden ingewonnen en twee technieken gebruikt voor de karteringen:

1. De multispectrale classificatie is gedaan voor het hele onderzoeksgebied. Met deze classificatie wordt er onderscheid gemaakt in Krabbenscheer, emers, submers, drijvend, flab en kroos. Deze techniek gebruikt de spectrale informatie per pixel om onderscheid te maken tussen de klassen, simpel gezegd op basis van 'kleur'.
2. Classificatie door objectherkenning. De objecten die hier worden herkend zijn velden van Krabbenscheer. Deze techniek kan onderscheid maken in patronen en vormen van de vegetatie en richt zich niet zozeer op de 'kleur' per pixel.

Uit de resultaten blijkt dat de verschillende groeivormen goed kunnen worden herkend met de multispectrale classificatie en dat het mogelijk is om plantensoorten in velden te detecteren met objectherkenning (Krabbenscheer-velden). Afzonderlijke planten konden niet worden gedetecteerd.

Remote sensing kan deels de handmatige vegetatie inventarisaties vervangen. Daarnaast kan met remote sensing een vlakdekkende classificatie worden uitgevoerd. Deze geeft meer inzicht in ruimtelijke variatie van groeivormen binnen een gebied.

De kosten van een KRW-beoordeling met airborne remote sensing kunnen nog niet worden ingeschat, omdat nog niet is onderzocht hoe robuust de huidige methode is. Er is nog niet bekend of nieuwe veldwaarnemingen in 2021 of later noodzakelijk zijn voor een nieuwe groeivormenkaart op basis van remote sensing. Mogelijk kan het getrainde neurale netwerk zonder veel aanpassingen direct worden gebruikt om nieuw in te winnen beelden in 2021 te classificeren.

Inhoudsopgave

Samenvatting.....	1
Inhoudsopgave	3
1 Inleiding.....	5
1.1 Kader	5
1.2 Doelen.....	5
1.3 Uitvoerend team.....	6
2 Onderzoeksgebied.....	7
3 Methode	9
3.1 Inwinning	9
3.1.1 Airborne remote sensing	9
3.1.2 Veldmetingen.....	10
3.2 Voorbewerking	11
3.3 Classificatie	12
3.3.1 Multispectrale classificatie.....	12
3.3.2 Objectherkenning.....	13
3.4 Validatie van de algoritmes.....	14
3.4.1 Validatie multispectrale classificatie	14
3.4.2 Validatie objectherkenning.....	15
3.5 Toetsing classificatie kaart.....	17
3.5.1 KRW transecten.....	17
3.5.2 Krabbenscheer-detectie	17
4 Resultaten	19
4.1 Veldmetingen	19
4.2 Beelden.....	20
4.3 Uitsnede.....	20
4.4 Classificatie	21
4.4.1 Groeivormen	21
4.4.2 Objectherkenning Krabbenscheer	26
4.5 Toetsing	30
4.5.1 KRW transecten.....	30
4.5.2 KRW-maatlatten	32
4.5.3 Vergelijking Krabbenscheer-detectie	32
5 Conclusies.....	35
6 Discussie.....	39
7 Aanbevelingen	41
8 Bibliografie	43
Bijlage A – Informatie airborne remote sensing.....	45
Bijlage B - Sloottransecten en interpretatie	53
Bijlage C – KRW deelmaatlatten groeivormen.....	65
Bijlage D – Diverse digitale bestanden.....	67
Bijlage E – Beeldenboek Rijnland	69

1 Inleiding

1.1 Kader

Deze rapportage is tot stand gekomen op basis van een verkenning naar de mogelijkheden om oever- en waterplanten vanuit de lucht te karteren. De basis hiervoor wordt gevormd door remote sensing technieken toe te passen. Het kader voor de verkenning betreft:

- Oever- en waterplanten: karteringen voor KRW-waterlichamen verbeteren.
- Veldkarteringen van oever- en waterplanten verbeteren en/of (deels) vervangen.
- In de tijd gezien kan dynamiek (ontwikkeling-groei-afsterven-...) gevolgd worden.
- Veldkarteringen zijn arbeidsintensief en niet (geheel) vlakdekkend.

De probleemstelling is als volgt:

'Aquatische vegetatieopnamen zijn arbeidsintensief en niet vlakdekkend. Hierdoor kan het zijn dat knelpunten, bijvoorbeeld watergangen met bijvoorbeeld veel flab, en/of bijzondere vegetatie-soorten ontbreken missen in de opnamen. Daarnaast zijn er kosten verbonden aan de opnamen.'

1.2 Doelen

De doelen van dit onderzoek zijn:

- Verkennen of de kwaliteit van de kartering met remote sensing technieken vergelijkbaar is met de huidige handmatige inventarisaties.
- Verkennen of karteren met remote sensing goedkoper en minder arbeidsintensief is dan de huidige gebiedsdekkende inventarisaties naar de aanwezigheid van oever- en waterplanten, dan wel een meerwaarde heeft die tot (redelijke) meerkosten leidt.

Het primaire karteringsdoel is om onderscheid te maken tussen verschillende groeivormen (submers, emers, drijvend, flab, kroos) en bedekkingsgraden van deze groeivormen. Het secundaire karteringsdoel is om specifieke vegetatiesoorten te karteren, met als voorbeeld Krabbenscheer. Krabbenscheer is een kenmerkende soort in het onderzoeksgebied.

De onderzoeksvragen zijn:

- Inwinning: resulteren de gekozen sensoren, platform, resolutie en opnamen moment in bruikbare beelden voor kartering van groeivormen en Krabbenscheer?
- Analyse: welke karteringsmethodes zijn geschikt voor het karteren van oever- en waterplanten en op welke schaal kan er onderscheid worden gemaakt tussen waterplanten qua groeivorm? Idem qua soort i.c. Krabbenscheer?
- Toepassing: hoe verhoudt de beschreven methode zich ten opzichte van traditionele/gangbare aquatische vegetatie opnamen op het gebied van kwaliteit en kosten?

1.3 Uitvoerend team

We hebben het project uitgevoerd met een team van deskundige mensen en innovators, werkend bij een kennisinstelling en adviesbureaus, die elkaar al kennen uit vergelijkbare eerdere en lopende projecten sinds 2016:

StellaSpark	Erwin Vonk
Deltares	Ellis Penning, Sandra Gaytan Aguilar, Christine Rogers & Gennadii Donchyts
DRO Remote Sensing	Rowland de Roode
KnowH2O	Dion van Deijl & Gé van den Eertwegh


DRO Remote Sensing heeft ons ondersteund met de inwinning en verwerking van airborne remote sensing informatie.

We hebben Roelf Pot als deskundig en ervaren aquatisch ecoloog in de arm genomen om de veldwaarnemingen van oever- en waterplanten uit te voeren en uit te werken.

2 Onderzoeksgebied

In het onderzoeksgebied Polder Stein liggen onder andere een Natura 2000-gebied en twee plassen (Kalverbroek en Vrijhoef). Het betreft een 'nat grasland' gebied.

Het Hoogheemraadschap van Rijnland heeft verschillende GIS-gegevens aangeleverd ter ondersteuning van het onderzoek. Hieronder vallen: afbakening van het onderzoeksgebied, karteringen van watergangen, KRW-meetpunten, macrofyten-meetpunten, waterdiepte metingen en een export van de Nationale Databank Flora en Fauna (NDFF), zie Figuur 1.



Figuur 1 Overzicht van onderzoeksgebied en beschikbare ruimtelijke data.

3 Methode

De methode bestaat uit vijf stappen. Eerst is de inwinning van de beelden en de velddata gedaan. Vervolgens zijn hier uit de gebruikte data geselecteerd en opgewerkt in de voorbereiding. Daarna zijn er twee aquatische vegetatie classificatie technieken toegepast (multispectrale classificatie en objectherkenning). Aansluitend zijn deze technieken gevalideerd en ten slotte zijn de resultaten i.c. de classificatie-kaarten getoetst aan elkaar en aan veldwaarnemingen.

3.1 Inwinning

Op 30 en 31 juli 2020 heeft de inwinning plaatsgevonden van de beelden en de veldwaarnemingen. De beelden zijn ingewonnen met een vliegtuig op 30 juli 2020; tegelijkertijd en de dag erna zijn de veldwaarnemingen gedaan aan de grond. Voor de timing van de inwinnen en grondwaarnemingen is nauw overleg geweest tussen de piloot en grondwaarnemers. De weercondities in de zomer van 2020 waren pas geschikt voor de inwinnen tegen eind juli 2020. Omdat er maar één inwinningsmoment is opgenomen in het onderzoek is er gewacht op de beste weercondities binnen het groeiseizoen van de aquatische vegetatie.

3.1.1 Airborne remote sensing


Inwinning van de beelden is gedaan met een vliegtuig op 30-07-2020. De vlucht is onder onbewolkte, zonnige (geen reflectie van wolken in het water) en bijna windstille condities (geen golven, vlakke waterspiegel) ingevlogen. Het vliegtuig is gekozen als platform met de volgende onderbouwing:

- Minimale verstoring van het natuurgebied.
- Studiegebied is aan de grote kant voor een drone. Daardoor is het voordeliger om het gebied in te vliegen met een vliegtuig.
- Inwinning is flexibel in de tijd inzetbaar: hierdoor kan de vlucht worden uitgevoerd wanneer de (weer-) condities geschikt zijn (hier: zo onbewolkt en windstil als mogelijk). Satellieten hebben vaak last van bewolking en vliegen alleen op vaste tijden over. Hierdoor kan timing en kwaliteit van satellietbeelden tegenvallen.
- Bij een vliegtuig als platform kan er een selectie van meerdere sensoren worden gemaakt die geschikt is voor de toepassing (classificeren van waterplanten).
- Met het platform kan de gevraagde resolutie van 15 cm (of fijner) worden behaald voor het hele onderzoeksgebied. Deze hoge resolutie kan niet worden behaald met een satellietbeeld. Daarnaast is het mogelijk om voor een geselecteerd gebied een extra hoge resolutie beeld in te winnen voor de Krabbenscheer-detectie (3 cm).
- Met een vliegtuig kan een gebied sneller worden ingewonnen vergeleken met een drone. Hierdoor zullen de opname condities tussen de losse beelden minder verschillen. Dit resulteert in een hogere kwaliteit van de zogenaamde orthomosaic: een geometrisch correct totaalbeeld van een gebied waarin alle losse foto's aan elkaar zijn geplakt.

De gebruikte sensoren en eigenschappen ervan staan in Tabel 1. Het hele onderzoeksgebied is ingewonnen met een resolutie van 14 tot 45 cm (afhankelijk van de sensor). Daarnaast is er een strook ingewonnen op een hogere resolutie (2,6 tot 45 cm - afhankelijk van de sensor). Van elk sensorbeeld is een orthomosaic gemaakt. Verder is er een hoogte-model ('digital elevation model' - DEM) gemaakt van de luchtfoto's. Een uitgebreide beschrijving van de sensoren en de inwinning is te vinden in Bijlage A. In de digitale Bijlage D zijn ook de beelden van de verschillende sensoren opgenomen.

Tabel 1 Sensoren en eigenschappen.

Sensor	Type	Wavelength Band [nm]
Warmtebeeld (TIR):	Temperature [C]	7500 – 13000
SWIR	reflection estimation	1475 – 1700
NIR-850	reflection estimation	850 – 970
NIR-735	reflection estimation	715 – 780
BP-695	reflection estimation	680 – 720
BN-660	reflection estimation	645 - 675
RED LIN	reflection estimation	580 – 700
GREEN LIN	reflection estimation	470 – 600
BLUE LIN	reflection estimation	400 – 500
Colour RGB	Colour	400 – 700



Figuur 2 Dekking ingewonnen beelden. Links het hele onderzoeksgebied en rechts strook met hoge-resolutie-beelden.

3.1.2 Veldmetingen

Tijdens de dag van de vlucht en de dag daaropvolgend zijn er vegetatieopnames gemaakt in het onderzoeksgebied. De veldkartering is gedaan volgens het KRW-protocol (Bijkerk, et al., 2014). Met de kartering zijn de volgende groeivormen opgenomen:

- Krabbenscheer;
- Emers;
- Drijvend;
- Submers;
- Flab;
- Kroos.

Daarnaast zijn de dominante soorten opgenomen. De opnamen zijn gedaan op drie verschillende schalen. Er is gemeten op een punt in de sloot, 1 m sloottransect en 100 m sloottransect. In het totaal zijn 114 punten, 114 m aan transecten en 11 stuks 100 m-transecten opgenomen. De opnamen zijn ingemeten met een GSM gecorrigeerde GPS (RTC). Van een groot deel van de veldopnamen zijn ook foto's gemaakt. De foto's zijn in de digitale Bijlage D opgenomen. In Figuur 3 zijn vier voorbeeldopnamen weergegeven.



Figuur 3 Een selectie van vier veldopnamen. Linksboven: Krabbenscheer. Rechtsboven: drijvende vegetatie (Gele Plomp). Links- en rechtsonder kroos.

3.2 Voorbewerking

Voordat de groeivormen en Krabbenscheer zijn gekarteerd zijn eerst de beelden uitgesneden met de watergangpolygonen (legger watersysteem) die zijn aangeleverd door het Hoogheemraadschap (Figuur 1). Om deze uitsnede te verbeteren, is er onderzocht of de oever kan worden gedetecteerd met de ingewonnen beelden. Na visuele controle is geconcludeerd dat de uitsnede geen verbetering nodig had en dat het mogelijk is om de watergangen te selecteren met de beelden. Voor dit onderzoeksgebied zijn de aangeleverde watergangen van voldoende kwaliteit voor de uitsnede. De uitsnede is verder verbeterd met het digitaal hoogte-model. Met het hoogte-model zijn de bomen uit de dataset verwijderd. De voorbewerking heeft de volgende datasets opgeleverd (deze datasets zijn in de digitale Bijlage D opgenomen):

1. **Waterwegen-masker op basis van aangeleverde vector bestand.** Uit de hoge-resolutie-luchtfoto's zijn door middel van het vectorbestand waterwegen alle watergangen 'uitgeknipt'. Doordat hiermee alleen de waterwegen overblijven op de luchtfoto reduceert de hoeveelheid data. Dit zorgt ervoor dat alleen de relevante waterwegen overblijven voor verdere classificatie.

2. **Waterwegen-masker op basis van remote sensing** (niet gebruikt voor de uitsnede). Waterpixels zijn geselecteerd aan de hand van de spectrale eigenschappen van water. Deze spectrale eigenschappen zijn afgeleid van de ingewonnen beelden. Dit bestand is niet gebruikt in de analyse.
3. **Bomen-masker.** Op basis van een DEM zijn bomen uit de dataset gefilterd. Pixels hoger gelegen dan 1 m+NAP zijn gebruikt voor het masker.

3.3 Classificatie

Tijdens de studie zijn er twee technieken gebruikt voor de karteringen. Hierdoor is er in deze studie kennis opgedaan over twee verschillende automatische karteringstechnieken.

1. De multispectrale classificatie is gedaan voor het hele onderzoeksgebied. Met deze classificatie wordt er onderscheid gemaakt in Krabbenscheer, emers, submers, drijvend, flab en kroos. Deze techniek gebruikt de spectrale informatie per pixel om onderscheid te maken tussen de klassen, simpel gezegd op basis van 'kleur'.
2. De objectherkenning. De objecten die hier worden herkend zijn Krabbenscheer-velden. Deze techniek kan onderscheid maken in patronen en vormen van de vegetatie en richt zich niet zozeer op de 'kleur' per pixel.

De twee karteringstechnieken resulteren in twee vegetatiekaarten:

1. Eén kaart voor alle watergangen in het onderzoeksgebied. Deze kaart maakt onderscheid tussen de groeivormen, gebaseerd op de multispectrale classificatie.
2. Eén kaart voor een deel van de watergangen binnen het onderzoeksgebied (een selectie van watergangen met Krabbenscheer binnen het onderzoeksgebied). Deze kaart geeft aan waar in de watergangen Krabbenscheer aanwezig is op basis van de objectherkenning.

3.3.1 Multispectrale classificatie

Het herkennen van verschillende soorten waterplanten kan aan de hand van spectrale informatie geschieden, door onderscheid te maken tussen de delen van het lichtspectrum die geabsorbeerd worden door het blad (en eventueel de bloem) van een plant en door water. Een randvoorwaarde om met de methode robuust vegetatietypen te classificeren is dat de te onderscheiden planttypen ieder een uniek en kenmerkend deel van het lichtspectrum absorberen. Voorts dient de ruimtelijke resolutie van het ingewonnen beeldmateriaal dusdanig te zijn, dat redelijkerwijs de grootte van een pixel overeenkomt met de grootte van de te classificeren waterplant (met enige marge).

De beelden zijn geclassificeerd gebruikmakend van een combinatie van 'standaard' beschikbare indexen voor de analyse van multispectrale beelden: de Normalised Difference Vegetation Index (NDVI), de Enhanced Vegetation Index (EVI), de Normalised Difference Water Index (NDWI) en drie Red Edge indexen (REDE).

Voor de multispectrale classificatie van de beelden is een algoritme ontwikkeld. Dit algoritme kan met een neuraal netwerk onderscheid maken tussen de groeivormen. Een Artificial Neural Network (ANN) is gebruikt als classificatiemethode. Er is gebruik gemaakt van een neuraal netwerk met Multi Layer Perceptron (MLP). Deze methode wordt veel gebruikt om de niet-lineaire relatie tussen voorspeller en voorspellende waarden in kaart te brengen. De belangrijkste taak van het neurale netwerk is het verbeteren van de prestatiefunctie tussen de voorspelde en waargenomen waarden. Voor deze studie bestaat het neurale netwerk van MLP uit een invoerlaag (acht spectrale banden, NDVI, NDWI en EVI), een verborgen laag en een uitvoerlaag van neuronen (klassen: vegetatietypen en water)

Het algoritme is ontwikkeld in Python en maakt gebruik van Tensorflow voor het neurale netwerk en Rasterio voor het verwerken van de beelden (Barbosa, 2020). De workflow van het algoritme is hieronder beschreven:

1. Het inladen van de acht beelden (beschreven in Tabel 1).
2. Berekenen van zes vegetatie indexen per pixel.
3. Het inladen van de velddata voor de pixel waar een veldwaarneming is gedaan.
4. De beelden omzetten naar een tabel met alle pixel als rijen en met in de kolommen de locatie van de pixel (x, y), pixel waarden van de acht banden, de zes indexen en (als bekend) de veldwaarneming; zie Tabel 3.
5. De tabel opsplitsen in een trainings-, validatie- en testdeel.
6. Het neurale netwerkmodel trainen met het trainings- en validatiedeel; zie Figuur 4;
7. Het model testen/valideren met het testdeel; zie Figuur 5;
8. De rest van de tabel classificeren i.c. de pixels waar geen veldwaarnemingen zijn gedaan;
9. De tabel omzetten naar een classificatie-raster.

Tabel 2 Groeivormen en klassennummers.

Groeivorm	Klassennummer
Water	0
Krabbenscheer	1
Drijvend	2
Emers	3
Submers	4
Flab	5
Kroos	6

Tabel 3 Tabel na omzetting van beelden en velddata, x- en y-meter zijn de coördinaten van de pixel, x- en y-pixel zijn locaties van de pixels op het raster. Target is de groeivorm waargenomen in het veld (zie Tabel 2).

xmeters	ymeters	ypixel	xpixel	red	green	blue	rede	rede2	rede3	nir	swir	tir	ndvi	ndwi	evi	target
114048	447621	9353	27265	0.13	0.09	0.07	0.10	0.12	0.27	0.27	0.09	0.49	0.33	-0.48	0.21	5
114055	447602	9479	27311	0.08	0.06	0.04	0.08	0.11	0.27	0.24	0.08	0.47	0.49	-0.58	0.28	5
113994	447716	8689	26891	0.24	0.19	0.14	0.19	0.27	0.62	0.61	0.25	0.52	0.44	-0.52	0.46	6
111552	447688	8888	9962	0.05	0.03	0.02	0.04	0.03	0.05	0.07	0.03	0.44	0.20	-0.43	0.05	0
113420	448474	3439	22909	0.04	0.04	0.02	0.03	0.07	0.25	0.31	0.11	0.42	0.77	-0.79	0.49	1
111531	447663	9060	9816	0.06	0.03	0.03	0.05	0.05	0.07	0.09	0.04	0.49	0.25	-0.46	0.08	0

3.3.2 Objectherkenning

We hebben vervolgens een 'deep learning' algoritme ontwikkeld, genaamd AquaNet, om uit deze data Krabbenscheer te herkennen. Voor de eigenlijke detectie maakt AquaNet gebruik van het Mask-RCNN algoritme (He, Gkioxari, Dollár, & Girshick, 2017). Dit algoritme is in 2017 ontwikkeld door onder andere Cornell University en wordt inmiddels gebruikt voor allerlei toepassingen waarbij objectherkenning centraal staat, zoals in de medische wereld voor het lokaliseren van tumoren uit scans, in drones voor automatische detectie van obstakels in de lucht en voor het detecteren van gebouwen, schepen of auto's uit satellietbeelden (Ramani, Prabakaran, Kannadasan, & Rajkumar, 2019). In dit project is gebruik gemaakt van Mask-RCNN implementatie in Python, Tensorflow en Keras. Mask-RCC is een zogenaamd 'multi-stage' deep learning algoritme, waarbij foto's eerst door een generieke 'backbone' gaan en vervolgens door specifieke sub-algoritmes voor de lokalisatie, classificatie en segmentatie van objecten.

De 'backbone' richt zich met name op het detecteren van specifieke kenmerken op een foto, zoals onderscheid tussen organische, ronde, hoekige en rechte vormen, diverse texturen (glad, vezelachtig, bolletjes, etc.) en kleurtinten (donker, licht, gelig, groenig). In de backbone worden deze basiskenmerken stapsgewijs verder gecombineerd tot kenmerken met een hoger abstractieniveau, zoals 'dierlijke kenmerken' (staarten, beharingstypen, schubben), 'vervoersobjecten' (wielen, sturen, glanzende lak, gestroomlijnde vormen), et cetera. Met deze 'hogere orde' kenmerken kan het algoritme uiteindelijk een robuuste classificatie maken, zoals 'auto', 'paard', 'mens', 'banaan'. Voor AquaNet gekozen voor de zogenaamde Resnet50 backbone. Dit is een relatief compacte 'backbone' (50 lagen diep), die desondanks hoog scoort in nauwkeurigheid. Door de compactheid is deze backbone relatief robuust voor classificatie van objecten voor situaties waar relatief weinig trainingsdata beschikbaar is.

De 'backbone' is getraind op de zogenaamde COCO-dataset (Lin, et al., 2014) een publieke dataset met ruim 1,5 miljoen objecten uit meer dan 80 categorieën. Van elk object zijn in de dataset gelabelde foto's beschikbaar. Door hiervan gebruik te maken kunnen we het algoritme eerst generiek trainen in het herkennen van basale vormen en texturen, waardoor we voor de verdere specialisatie richting Krabbenscheer in verhouding veel minder data nodig hebben. Dit principe wordt 'transfer learning' genoemd.


Doorgaans neemt het trainen van dit soort deep learning algoritmes veel tijd in beslag (ordegrootte weken of maanden op 'gangbare' hardware). Daarom zijn de berekeningen uitgevoerd op een gespecialiseerd rekencluster met GPU's (Graphical Processing Units – processoren gespecialiseerd in grafische berekeningen). Om de berekeningen te versnellen zijn deze vergaand geparallelliseerd. De gehele luchtfoto wordt daarvoor opgeknipt in 'minitegels' van 512 bij 512 pixels, waardoor deze tegelijkertijd in het geheugen verwerkt kunnen worden. In totaal zijn er 64 minitegels met grondwaarnemingen, waarvan we 80% (51 minitegels) gebruiken voor het trainen van het algoritme, 10% (6) voor validatie en de resterende 10% (7) voor het testen. Deze splitsing is belangrijk, want met een onafhankelijke validatie- en testset kunnen we inzichtelijk maken hoe het algoritme presteert op data die het nog niet eerder gezien heeft. Dit is dus een goede indicatie voor de nauwkeurigheid die je kunt verwachten indien je het algoritme operationeel zou gebruiken.

3.4 Validatie van de algoritmes

De twee classificatie algoritmes valideren de classificatie door een deel van de data niet te gebruiken tijdens de training. Dit niet gebruikte deel van de data voor training vormt de 'validatiedataset'. De resultaten van deze validatie staan hieronder beschreven:


3.4.1 Validatie multispectrale classificatie

Tijdens de training van het multispectrale-classificatie neurale netwerk wordt de nauwkeurigheid ('accuracy') en zekerheid ('loss') uitgerekend. Tijdens 100 trainingsronden ('epoch') is te zien dat het model stopt op een optimum van zowel de nauwkeurigheid als zekerheid. Dit laat zien dat het netwerk succesvol heeft geleerd.



Figuur 4 Link de training van het neurale netwerk. Te zien is dat het model nauwkeuriger wordt (slimmer) na meerdere trainingsronden ('epoch'). Recht is te zien dat het model met meer zekerheid de correcte voorspelling doet ('loss').

Vervolgens wordt het netwerk gevalideerd met een test dataset. De test data is niet gebruikt bij het trainen van het neurale netwerk. De resultaten van de validatie zijn te zien in de 'confusion matrix' in Figuur 5. De groeivormen (0, 4, 5, 6) worden bijna volledig correct geïdentificeerd. Ook de groeivormen 1, 2 en 3 worden zeer goed geïdentificeerd. Een zeer klein deel van de pixels met groeivormen van 1, 2 en 3 worden soms verwisseld. De hoge nauwkeurigheid van de testset laat zien dat het model correct is gefit op de trainingsdata en dat er geen 'overfitting' plaats vindt.




Figuur 5 Validatie van het neurale netwerk met een confusion matrix. Hierin is te zien welke aandeel van de pixels in de verkeerde klasse (groeivorm) wordt ingedeeld.

3.4.2 Validatie objectherkenning

Na visuele inspectie bepalen we de statistische betrouwbaarheid van het model door een zogenaamde 'Average Precision at 50% Intersection over Union'-score (afgekort AP_{50}). Dit is een standaardscore die gebruikt wordt om de kwaliteit van objectherkenningsmethoden in één getal uit te drukken. De AP_{50} score heeft altijd een waarde tussen 0 en 100%, waarbij 0% een rondt

onbetrouwbaar model is, en 100% een model met perfecte voorspellingen (geen vals-positieven en geen vals-negatieven). De beste neurale netten van dit moment halen doorgaans AP₅₀ scores rond 50-60% op generieke datasets met dagelijkse objecten, zoals de COCO-dataset (Redmon & Farhadi, 2018).

Voor de berekening van de AP₅₀-score wordt gekeken naar de overlap tussen modelvoorspelling en de werkelijke locatie van een gedetecteerd object, zoals vastgesteld bij de grondwaarnemingen. Het overlappende oppervlak tussen waar het model een object meent te herkennen en het 'ware' object wordt de 'Intersection over Union' (IoU) genoemd. Voor de AP₅₀-score wordt een voorspelling als 'correct' aangemerkt als de overlap groter dan 50% is.



Figuur 6 Illustratief voorbeeld van de definitie van de Intersection-over-Union. In de AP₅₀-berekening wordt een voorspelling als 'juist' aangemerkt als de overlap (IoU) groter dan 50% is.

Vervolgens worden voor elke voorspelling de precisie ('precision') en gevoeligheid ('recall') berekend. De precisie geeft de verhouding aan tussen de juiste detecties ten opzichte van alle detecties (inclusief de onjuiste). Gevoeligheid is gedefinieerd als de verhouding tussen juiste detecties ten opzichte van het totaal aan grondwaarnemingen waar daadwerkelijk Krabbenscheer was vastgesteld. Alle modelvoorspellingen worden gerangschikt op hun precisie en gevoeligheid, waarna daarover de integraal wordt berekend (oppervlak onder de curve).

Na de volledige training (50 'epochs') vinden we de volgende AP₅₀ scores:

- Training: 54%.
- Validatie: 67%.
- Test: 56%.

Gemiddeld komen we uit op een score van 60%. In de context van scores op benchmark datasets, en gegeven dat de hoeveelheid grondwaarnemingen relatief klein is, lijkt dit op zijn minst een acceptabele score. Wel laat deze score zien dat er nog de nodige ruimte voor verdere verbetering zit. Opvallend is dat zowel de validatie als test minstens zo goed scoren als de training. Dit geeft aan dat er geen sprake is van overfitting. Dit geeft vertrouwen in de robuustheid van het model, aangezien de presentaties op niet eerder 'geziene' data vergelijkbaar zijn met de trainingsdata. De verwachting is dat de score met meer grondwaarnemingen flink hoger kan worden, omdat het algoritme daardoor beter leert generaliseren en 'edge cases' kan herkennen.

3.5 Toetsing classificatie kaart

In de voorgaande paragraaf zijn de algoritmes op pixel- en objectschaal gevalideerd. Om de toepasbaarheid van de classificatie kaarten verder te toetsen zijn de kaarten toegepast en getoetst. Daarnaast is de Krabbenscheer-detectie vergeleken tussen de twee methodes vergeleken, te weten de multispectrale classificatie en de objectherkenning.

3.5.1 KRW transecten

3.5.1.1 Bedekkingsgraad

Op elf sloot-transecten van 100 m lengte elk is de bedekkingsgraad van de groeivorm geschat via een KRW-beoordeling. De waarden van deze geschatte bedekking zijn vergeleken met een bedekking berekend aan de hand van de classificatiekaart. In het veld kan de bedekking meer dan 100% zijn doordat verschillende groeivormen boven elkaar kunnen groeien (gelaagde vegetatie). Bijvoorbeeld submerse vegetatie onder drijvende vegetatie. Deze gelaagdheid van groeivormen is niet waar te nemen met remote sensing, daarom zijn de veldschattingen omgerekend naar een maximale bedekking van 100%.

Voor elk transect is een kaart gemaakt met daarop de verdeling van de groeivormen in een cirkeldiagram van de veldwaarneming en de remote sensing methode.

3.5.1.2 KRW-deelmaatlaten

Met de bedekking van de verschillende groeivormen is per sloot de deelmaatlat-score berekend van het watertype M8 (Gebufferde Laagveensloten). Deze scores zijn beschreven in STOWA 2018-49 'Omschrijving MEP en maatlaten voor sloten en kanalen voor de Kaderrichtlijn Water 2021-2027' (STOWA). Met deze scores kunnen de groeivormen worden ingedeeld in de klassen, slecht, ontoereikend, matig en goed.


3.5.2 Krabbenscheer-detectie

De twee classificatie methoden detecteren beide Krabbenscheer met een andere techniek. Om de twee methodes te toetsen is er een kaart gemaakt waar de resultaten van beide detectiemethodes over elkaar heen zijn gelegd (zie paragraaf 4.5.3).

4 Resultaten

4.1 Veldmetingen

Op 30-07-2020 en 31-07-2020 zijn er 114 punten en 11 sloot-transecten opgenomen in het onderzoeksgebied. De waarneming zijn opgenomen de digitale Bijlage D. In Figuur 7 zijn de locaties van de veldwaarnemingen weergegeven. Van elke groeivorm zijn minimaal tien waarnemingen gedaan in het gebied. De verdeling van de groeivormen is te zien in Tabel 4.




Figuur 7 Ligging veldwaarnemingen.

Tabel 4 Aantal waarnemingen en groeivormen.

Groeivorm	Aantal waarnemingen
Krabbenscheer	15
Submers	17
Drijvend	19
Emers	24
Flab	10
Kroos	23

4.2 Beelden

Een overzicht van alle ingewonnen beelden is weergegeven in Figuur 8. Op de beelden is duidelijk te zien dat verschillende sensors (i.c. spectrale golflengtes) een ander beeld opleveren. Het verschil in reflectie kan worden gebruikt voor de classificatie van de verschillende groeivormen.




Figuur 8 Overzicht ingewonnen beelden.

Op de stroken die zijn ingewonnen met een extra hoge resolutie zijn duidelijk Krabbenscheer-velden te zien. Losse planten zijn lastig te onderscheiden op de beelden.

4.3 Uitsnede

Met de voorbewerking van de beelden is er een uitsnede gemaakt. Met deze uitsnede zijn alleen de relevante pixels voor de classificatie geselecteerd. In het totaal zijn er drie maskers gemaakt. De methode van de uitsnede is beschreven in paragraaf 3.2. In Figuur 9 zijn de verschillende uitsnede weergegeven. Beide watermaskers zijn bruikbaar voor de uitsnede. In deze studie is ervoor gekozen de uitsnede van de legger te gebruiken. Verder is een deel van het bomenmasker niet gebruikt. Dit

komt omdat de randen van de DEM opkrullen. Het bomenmasker is hier handmatig verwijderd. Ten slotte zijn ook drooggevallen meren handmatig verwijderd uit de dataset.




Figuur 9 Water- en bomenmasker.

4.4 Classificatie


Voor de Krabbenscheer-detectie en de groeivormen-classificatie zijn twee methodes gebruikt.

4.4.1 Groeivormen

De multispectrale classificatie resulteert in een kaart met daarop de gedetecteerde groeivormen. Elke pixel is geclassificeerd als water of als één van de zes groeivormen. De groeivormen-kaart is toegevoegd in de digitale Bijlage D. In Figuur 10 is een voorbeeld gegeven van de groeivormenkaart. In het figuur is te zien dat de groeivormen op de veldwaarnemingen correct worden voorspeld. Dit blijkt ook uit de 'confusion matrix' in Figuur 10 en Figuur 11.




Figuur 10 Voorbeeld van de groeivormenkaart.




Figuur 11 Voorbeeld van de groeivormenkaart in de plas.


Na een visuele controle met de luchtfoto (i.c. het RGB-beeld) blijkt dat de groeivormen meestal correct worden voorspeld. In enkele gevallen classificeert het algoritme niet goed. Voorbeelden van mis-classificatie zijn hieronder weergegeven en beschreven.




Figuur 12 De brug staat niet op het watergangen masker. Hierdoor is de brug geclassificeerd als kroos.



Figuur 13 De bladeren van de drijvende vegetatie krullen omhoog; hierdoor worden stukken van de drijvende vegetatie geclassificeerd als emerse vegetatie.



Figuur 14 Op de overgang tussen twee groeivormen wordt vaak een andere groeivorm geassocieerd. Het gaat vaak om smalle stroken rondom de groeivorm. Deze overgang groeivormen zijn meestal niet waargenomen in het veld.



Figuur 15 Krabbenscheer wordt vaak onterecht gedetecteerd bij submerse of emerse vegetatie.

4.4.2 Objectherkenning Krabbenscheer

Tijdens het trainen convergeert het algoritme duidelijk naar een optimum; met elke trainingsstap wordt het algoritme beter in het herkennen van Krabbenscheer. We stoppen de training na 50 stappen (epochs) om overfitting te voorkomen. Visuele inspectie van het classificatie-resultaat naderhand laat zien dat het algoritme succesvol de meeste gebieden met Krabbenscheer weet te herkennen. De begrenzing van elk veld van Krabbenscheer wordt vaak perfect door het algoritme aangewezen, zelfs lastige gebieden waar ook andere vegetatie tussendoor groeit. We laten hierbij een selectie zien van de succesvolle detecties die door het algoritme gedaan zijn (Figuur 16 en Figuur 17). Het valt op dat AquaNet accuraat de omlijning van een Krabbenscheer-veld weet vast te stellen. Voor elke detectie geeft AquaNet ook een zekerheid aan; deze is ook hoog voor dergelijke situaties (>90%).



Figuur 16 Voorbeeld van een Krabbenscheer-veld dat succesvol herkend is door AquaNet. De zwarte pixels zijn stukken boom of land, die door het 'masken' in een eerder stadium reeds uit de foto zijn verwijderd. Het Krabbenscheer-veld aan de rechterkant grenst direct aan andere begroeiing; AquaNet kan precies de grens tussen beide vegetatietypen herkennen.



Figuur 17 Situatie waarbij Krabbenscheer op twee plekken voorkomt. Het veld links wordt correct herkend door AquaNet. Rechts ligt een veld dat aan de rechterkant dicht begroeid is met Krabbenscheer, maar dat geleidelijk overgaat in een meer gemixte samenstelling, waarbij ook kroos voorkomt tussen de individuele Krabbenscheer planten. Het algoritme kan geen individuele planten herkennen en kapt daarom het 'Krabbenscheer-veld' af op het punt waar de begroeiing minder intensief wordt.

Naast succesvolle detectie zijn er ook situaties waarbij Krabbenscheer niet (geheel) juist herkend wordt. We laten daar ook een paar voorbeelden van zien. Figuur 18 en Figuur 19 laten situaties zien die voor AquaNet lastig zijn. Kennelijk kan vanuit de lucht onder bepaalde omstandigheden submerse vegetatie erg lijken op Krabbenscheer. Bij deze studie hebben we enkele plekken aangetroffen waarbij de submerse vegetatie zodanig leek op Krabbenscheer, dat deze door AquaNet onjuist als Krabbenscheer werd aangemerkt (Figuur 18). Verder kunnen er situaties zijn waarbij de Krabbenscheer niet, zoals typisch, in een aaneengesloten 'veld' groeit, maar bestaat uit een losse verzameling van individuele planten met daartussen relatief veel ruimte waar kroos groeit. Hier is het algoritme wel in staat om bepaalde stukken te herkennen, maar doorgaans lukt het niet om individuele planten te detecteren, waardoor het lastig is om de correcte begrenzing aan te geven (Figuur 19).



Figuur 18 – Voorbeeld van een zogenaamde vals-positief. Dit is een stuk sloot waar geen Krabbenscheer groeide, maar waar AquaNet wel Krabbenscheer meende te herkennen. De vegetatie in deze sloot is bij het veldwerk vastgesteld als 'submers'. Qua structuur en kleur lijkt dit vanuit de lucht wel op Krabbenscheer. Kennelijk is het voor het algoritme lastig om het correcte onderscheid te maken.




Figuur 19 – Voorbeeld van een 'twijfelgeval'. Dit stuk sloot bevat inderdaad Krabbenscheer op de plek waar het algoritme dit ook gedetecteerd heeft. Echter groeit de Krabbenscheer hier niet in een aaneengesloten veld, maar zijn het allemaal individuele planten met daartussen veel kroos. Het algoritme kan niet goed individuele planten herkennen, omdat deze qua pixelgrootte niet duidelijk te onderscheiden zijn. Dat maakt het correct herkennen van de hoeveelheid Krabbenscheer in dergelijke situaties uitdagend.

We kunnen ook een vergelijking maken tussen de grondwaarnemingen en de AquaNet Krabbenscheer-detecties. Ook hierbij zien we dat veel vlakken netjes over elkaar liggen, hoewel er ook duidelijk vals-positieven en vals-negatieven zijn. Het is belangrijk op te merken dat handmatig ingetekende vlakken ook niet foutloos zijn; er zijn voorbeelden waarbij het algoritme beter was in het afbakenen van een Krabbenscheer-veld dan de (door mensenhanden ingetekende) grondwaarnemingen. Dit komt ook omdat het enigszins arbitrair is waar precies een Krabbenscheer-veld op houdt en overgaat op wateroppervlak of een ander type vegetatie. Enkele vals-negatieven zijn simpelweg model-fouten, maar er is ook in ieder geval één plek waar het waterwegen- en bomenmasker een deel van de Krabbenscheer pixels maskeerde, waardoor het algoritme die gemist heeft. Dit is een aandachtspunt voor toekomstige studies.



Figuur 20 Een deel van watergang in het onderzoeksgebied met in grijs de grondwaarneming en in blauw de modelvoorspelling.




Figuur 21 Een deel van watergang waar slechts een deel van de grondwaarnemingen als Krabbenscheer zijn herkend. Mogelijk komt dit omdat het bomen-en waterwegenmasker (zwarte pixels) een deel de waarnemingen deels maskeerde.



Figuur 22 Een voorbeeld waarbij de zuidelijke watergang correct herkend is als Krabbenscheer, maar waarbij in de noordelijke watergang sprake is van een vals-positief. Grijze vlakken zijn grondwaarnemingen, blauw de object-detecties. In werkelijkheid was daar sprake van submerse vegetatie in de noordelijke watergang, maar AquaNet herkende Krabbenscheer.

Het eindresultaat is te zien in Figuur 23. We kunnen constateren dat het overgrote deel van de grondwaarnemingen ook door AquaNet worden herkend. Wel zijn er een aantal plekken waarvoor geen Krabbenscheer-grondwaarnemingen zijn, maar AquaNet wel Krabbenscheer herkend. Na visuele inspectie kan geconcludeerd worden dat worden dit deels toch mogelijk terechte detecties zijn, die simpelweg niet bij het veldwerk naar voren zijn gekomen. Deels betreft het ook daadwerkelijk incorrecte detecties, waarbij het algoritme zich 'vergist' tussen submerse vegetatie en Krabbenscheer.



Figuur 23 Eindresultaat van de Krabbenscheer-detectie via objectherkenning. Groen zijn alle grondwaarnemingen met Krabbenscheer en blauw alle detecties door AquaNet. Het overgrote deel van de grondwaarnemingen wordt ook door AquaNet herkend. Daarnaast heeft AquaNet enkele plekken gedetecteerd waarvoor geen grondwaarnemingen waren. Grofweg zijn drie clusters aan te wijzen waar sprake is van vals-positieven: A, B en C. Na aanvullende visuele inspectie van het fotomateriaal kan geconstateerd worden dat de vals-positieven in cluster A hoogstwaarschijnlijk oprecht vals-positieven zijn. Van cluster B is het niet uit te sluiten dat hier inderdaad Krabbenscheer aanwezig is, wat niet tijdens het veldwerk gekarteerd is. Cluster C betreft voor een groot deel vals-positieven, doordat hier submerse vegetatie aanwezig is die qua vorm en structuur sterk lijkt op Krabbenscheer.

4.5 Toetsing

4.5.1 KRW transecten


Op 11 sloot-transecten is de geschatte bedekking in het veld vergeleken met de groeivormenkaart. Transect 136-137 is weergegeven in Figuur 24. Onder de figuur is de interpretatie beschreven van de toetsing van het transect. De overige transecten en interpretatie zijn toegevoegd in Bijlage B.

Interpretatie toetsing transect 136-137:

- De Krabbenscheer-velden worden goed geclassificeerd. De bedekkingsgraad wordt lager geclassificeerd dan de veldschatting. Ook wordt er een zeer smalle strook Krabbenscheer gedetecteerd langs de zuidoever. Dit is niet waargenomen in het veld.
- De groeivormenkaart laat stroken zien met de submerse groeivorm. Deze is niet waargenomen in het veld.
- De dominante groeivorm is bij zowel de veldwaarneming als bij de groeivormen-kaart Krabbenscheer.

4.5.2 KRW-maatlatten

Met de groeivormenkaart zijn de deelmaatlatten voor elke watergang in het gebied berekend. In Figuur 25 staan de berekende deelmaatlatten voor de groeivorm 'Flab en Kroos' van het watertype M8 (Gebufferde Laagveensloten). De andere deelmaatlatten zijn toegevoegd in Bijlage C



Figuur 25 Deelmaatlatten-kaart 'Flab en Kroos'.

Op de deelmaatlattenkaart 'Flab en Kroos' zijn duidelijk de sloten te zien waar veel flab en kroos aanwezig. Veel van deze sloten liggen in agrarisch gebied (zuidoost). Dit is ook gezien bij de veldwaarnemingen.

4.5.3 Vergelijking Krabbenscheer-detectie

Krabbenscheer is zowel met multispectrale classificatie als met objectherkenning gedetecteerd. In Figuur 26, Figuur 27 en Figuur 28 zijn de twee methodes visueel met elkaar vergeleken. Daarnaast zijn de twee methoden kwantitatief met elkaar vergeleken door de geclassificeerde pixels binnen de objectherkenning vlakken bij elkaar op te tellen voor alle groeivormen. Hieruit blijkt dat ongeveer 50% van het gedetecteerde oppervlakte met de objectherkenning overeenkomt met de multispectrale classificatie, zie Tabel 5.

Tabel 5 Aantal geclassificeerde pixels binnen de Krabbenscheer-velden gedetecteerd met objectherkenning.


	Aantal pixels (-)	Percentage (%)
Water	3531	15
Krabbenscheer	11314	48
Drijvend	504	2
Emers	2939	12
Submers	4989	21
Flab	392	2
Kroos	31	0
Totaal	23700	100



Figuur 26 Multispectrale classificatie en objectherkenning voor Krabbenscheer in een sloot met grondwaarnemingen.



Figuur 27 Multispectrale classificatie en objectherkenning voor Krabbenscheer in een watergang zonder grondwaarnemingen.



Figuur 28 Misclassificatie van multispectrale classificatie en objectherkenning voor Krabbenscheer in een sloot zonder grondwaarnemingen.

5 Conclusies

De centrale inhoudelijke vraag van dit project was: 'Met welke kwaliteit kunnen verschillende groeivormen en Krabbenscheer worden gedetecteerd en geclassificeerd met airborne remote sensing informatie?'

We komen op basis van de resultaten tot de volgende conclusies:

- Krabbenscheer kan goed worden herkend door zowel objectherkenning toe te passen als ook multispectrale classificatie. Voor een goede detectie moet de Krabbenscheer in velden groeien. Afzonderlijke planten zijn met de beschikbare informatie en resolutie niet te herkennen. Daarnaast wordt Krabbenscheer ook vaak vals-positief herkend doordat de groeivorm erg lijkt op (een mix van) de groeivormen emers en submers. Krabbenscheer groeit deels onder water (submers) met heeft deels bladeren boven water (emers).
- Emerse vegetatie wordt goed multispectraal geclassificeerd. Alleen is de classificatie van de groeivorm gevoelig voor de ingetekende of gedetecteerde oever. Als de watergangen ruim zijn ingetekend, dan zal er meer emerse vegetatie worden geclassificeerd. Bij een zeer ruime ingetekende watergang wordt de vegetatie op het aanliggende land ook als emerse vegetatie geclassificeerd.
- Submerse vegetatie wordt alleen herkend als deze ook goed zichtbaar is vanuit de lucht. Submerse vegetatie wordt soms niet herkend doordat de vegetatie niet zichtbaar is door troebel water, de vegetatie onder een andere groeivorm groeit (gelaagde vegetatie) of doordat er te weinig trainingsdata is van diepe submerse vegetatie. Dit laatste punt is relatief eenvoudig te verbeteren
- Drijvende vegetatie wordt goed herkend. In enkele gevallen wordt drijvende vegetatie verkeerd geclassificeerd als emerse vegetatie, doordat bladeren boven water steken.
- Kroos wordt goed herkend als er sprake is van een gesloten kroosdek. Los kroos tussen andere vegetatie of open kroosdekken worden meestal niet als kroos geclassificeerd.
- Flab wordt goed herkend als deze aaneengesloten aan het wateroppervlak aanwezig is.

Een andere vraag was: 'Is de kwaliteit van de groeivormen kaart voldoende om de gangbare KRW-beoordeling te verbeteren of te vervangen?'

Onze conclusies luiden als volgt:

- Op basis van de ingewonnen beelden kunnen alleen vegetatie-velden (Krabbenscheer-velden) en groeivormen worden herkend. Het is waarschijnlijk niet haalbaar om afzonderlijke planten van een soort te herkennen op de beelden. Dit is overigens niet verder onderzocht.
- De bedekkingsgraad van de verschillende groeivormen kan worden berekend aan de hand van de groeivormenkaart. Deze zijn niet zuiver/hard te valideren, omdat er alleen veldschattingen zijn van de bedekkingsgraad. De dominante groeivorm is meestal wel gelijk tussen de veldschattingen en de groeivormenkaart.
- De KRW-deelmaatlatten op transect-niveau laten duidelijke ruimtelijke gradiënten in de polder zien.

Een volgende vraag was: 'Is een KRW-beoordeling op basis van remote sensing informatie goedkoper dan op basis van een gangbare kartering?'

We komen tot de volgende conclusies:

- De huidige methode kan geen afzonderlijke vegetatiesoorten herkennen. Hierdoor is het nog niet mogelijk om een volledige KRW-beoordeling te doen met remote sensing.
- De kosten van een KRW-beoordeling met airborne remote sensing kunnen nog niet compleet worden ingeschat omdat niet is onderzocht hoe robuust de huidige methode is. Daarom is nu niet bekend of nieuwe veldwaarnemingen noodzakelijk zijn voor de groeivormenkaart op basis van remote sensing in 2021. Mogelijk kan het getrainde neurale netwerk ook worden gebruikt om nieuw ingewonnen beelden (2021) te classificeren.

Een vraag luidde ook: 'Welke bijproducten en voordelen leveren vegetatieopnamen op basis van remote sensing informatie op?'

We komen tot de volgende conclusies:

- Een groot voordeel is dat de groeivormen vlakdekkend worden gekarteerd. Deze vlakdekkende informatie geeft de volgende voordelen:
 - Nieuwe locaties voor KRW-opnamen kunnen worden bepaald aan de hand van de groeivormen kaart.
 - Ruimtelijke gradiënten en patronen van de groeivormen worden inzichtelijk gemaakt.
 - Locaties met waardevolle vegetaties zoals Krabbenscheer die buiten de standaard meetpunten liggen kunnen worden opgespoord.
 - Er kan worden nagegaan of perceel- en slootbeheer invloed heeft op de status van de gehele sloot of delen van een poldergebied; zijn er patronen in de groeivormenkaarten terug te vinden die te relateren zijn aan bijvoorbeeld een specifiek type beheer?
 - Lokale afwijkingen, zowel in positieve als in negatieve zin, ten opzichte van de totale polder kunnen worden opgespoord.
 - Vlakdekkende kaarten geven meer inzicht in begrip over het totale poldersysteem dan op basis van enkele puntwaarnemingen wordt verkregen.
 - Naast de KRW-monitoring kan ook informatie voor andere type vragen worden verkregen: bijv. hoe zijn de sloten geschoond, hoe gaat het met de graslanden in weidevogel-beheergebied? Hiermee zijn de beelden ook voor andere delen van het waterschap en voor externe organisaties zoals SBB bruikbaar.
- Diverse actuele remote sensing producten en bijproducten die ook kunnen worden gebruikt voor andere toepassingen zijn:
 - Hoge resolutie kleurenluchtfoto's.
 - Diverse andere beelden bijvoorbeeld infrarood.
 - Digitaal hoogte model.
 - Watermasker.
 - Bomenmasker voor watergangen.
- Het objectherkenning algoritme kan worden getraind op andere vegetatie-soorten zoals Gele Plomp en kroos.

Inzake de inwinning komen we tot de volgende conclusies:

- De inwinning was later in het groeiseizoen, eind juli 2020. Toch stond de vegetatie in het gebied er goed bij. Bij sommige drijfblad-vegetatiesoorten waren er al wat verkleurde bladeren aanwezig. Nog later in het groeiseizoen vliegen en data inwinnen wordt afgeraden, omdat de verkleuring dan naar verwachting te veel invloed op de classificatie kan krijgen.
- De exacte timing van de vlucht (dag en tijdstip) is belangrijk en blijft een kwestie van aandacht, als de weercondities moeilijk te voorspellen zijn. Het beste is te streven naar een wolkenloze zonnige dag met weinig tot geen wind. Geen of weinig wind tijdens de inwinning zorgt voor een betere detectie van de bedoelde vegetatie, doordat golfwerking kan zorgen voor verstoringen van het spectrale beeld.

Ten aanzien van de voorbewerking van de data komen we tot de volgende conclusies:

- Uitsnede van bomen als masker is voor een groot deel bruikbaar. De hoeken van het beeld moeten goed op hoogte gerefereerd worden (geo-referentie).
- Uitsnede van water (legger) als masker is van goede kwaliteit.
- Waterdetectie is mogelijk op basis van remote sensing beelden.

Met betrekking tot de classificatie op puntschaal per pixel komen we tot de volgende conclusie:

- De classificatie is zeer goed, waarschijnlijk doordat meer spectrale banden opgenomen zijn ten opzichte van een gewoon RGB-beeld of een RGB-beeld samen met een NIR-beeld. Het was zinvol de inwinning te doen met de geselecteerde sensoren.

Met betrekking tot de classificatie op sloot-transect-schaal komen we tot de volgende conclusie:

- Classificatie op transect-schaal is moeilijk hard/zuiver te toetsen, omdat de veldwaarnemingen (weliswaar 'deskundige') schattingen zijn.
- De aanwezigheid van Krabbenscheer binnen een transect wordt meestal onterecht gedetecteerd.
- De bedekking van submerse vegetatie wordt vaak onderschat wanneer deze niet zichtbaar is door troebel water, gelaagde vegetatie, of te weinige trainingspunten met diepe submerse vegetatie.

6 Discussie

Een aantal punten wordt benoemd omdat deze voor discussie vatbaar zijn:

- De analyse is gedaan op basis van één beeld in de tijd: meerdere opnames in de tijd geven de mogelijkheid om de robuustheid van de gevolgde methodiek te testen.
- Het is wellicht beter om de pixels ruimtelijk apart valideren, omdat het vóórkomen van vegetatie(vormen) en daarmee pixels ruimtelijk gecorreleerd zijn.
- Watermaskers combineren: maskers op basis van leggerinformatie en op basis van airborne remote sensing informatie.
- Het is de vraag of er in 2021 of later opnieuw geclassificeerd kan worden met dezelfde trainingsdata uit 2020.

7 Aanbevelingen

We hebben de volgende aanbevelingen:

- Een tweede keer data van het gebied inwinnen in 2021 en dan het algoritme toepassen dat getraind is met de 'oude' data van 2020; idem trainen met extra en nieuwe data van 2021.
- De inwinning van beelden combineren met de reguliere opnames van Rijnland. Hiervoor dienen de reguliere inwinning en vegetatie inwinning op elkaar worden afgestemd (timing veldwerk, vlieghoogte, type sensoren en benodigde weercondities). Door middel van een combinatie van de inwinning kan benodigde informatie voor het gehele beheergebied van Rijnland vlakdekkend worden ingewonnen.
- Vanaf 2021 elk jaar een beeld inwinnen van Polder Stein of het gehele beheergebied van Rijnland om patronen in de ruimte en trends de in tijd te monitoren. Waar gaat het beter met het watersysteem, waar gaat het slechter en waarom? (op basis van een hypothese).
- KRW-(deel)maatlatten geschikt maken om remote sensing data erin te kunnen (en mogen) verwerken en deze data geschikt maken voor toepassing in de (deel)maatlatten.
- Naast de KRW-(deel)maatlatten classificatie beschikt het Hoogheemraadschap van Rijnland ook over een (concept)beeldenboek, zie Bijlage E. In dit beeldenboek worden vier verschillende ecologische stadia beschreven. Met de verkregen groeivormenkaart en vertalingsregels afgeleid van het beeldenboek kan er een kaart worden gemaakt van de verschillende ecologische stadia in het gebied op slootniveau.





8 Bibliografie

- Barbosa, C. M. (2020). *User guide Neural Network in Python*.
- Bijkerk, R., Beers, M., Bonhof, G., Brans, B., Buskens, R., Coops, H., et al. (2014). *Handboek Hydrobiologie: biologisch onderzoek voor de ecologische beoordeling van Nederlandse zoete en brakke oppervlaktewateren*. STOWA.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017, 3 20). Mask R-CNN.
- Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., . . . Dollár, P. (2014, 5 1). Microsoft COCO: Common Objects in Context.
- Ramani, S., Prabakaran, N., Kannadasan, R., & Rajkumar, S. (2019). Real Time Detection And Segmentation Of Ships In Satellite Images. *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH*.
- Redmon, J., & Farhadi, A. (2018, 4 8). YOLOv3: An Incremental Improvement.
- STOWA (2018). Omschrijving MEP en maatlatten voor sloten en kanalen voor de KaderRichtlijn Water 2021-2027. STOWA-rapport 2018-49.

Bijlage A – Informatie airborne remote sensing



Remote Sensing Data Documentation



Flight Date : 2020-07-30



Remote Sensing Data Specification:

The Rijnland Remote Sensing dataset was captured at 2020-07-30 between 13:03 and 13:47 (UTC) under sunny conditions. The dataset contains 2 multispectral maps and point clouds: the full map, which contains the agreed section to scanned captured at an altitude of approximately 366 meters, and a LowAlt stip which was captured from an altitude of 155 meters. An additional high resolution colour image strip was captured directly after the multispectral LowAlt stip.



Full map



LowAlt Strip

Each multispectral map contains 9 spectral bands: Red, Green, Blue, BN660, BP695, BP735, BP850, BP1475 and TIR. A colour map, created from the RGB bands, is also added for the purpose of visual inspection.

Full Map Specifications:

Sensor	Type	Wavelength Band [nm]	Resolution [m/pix]	data format
Warmtebeeld (TIR):	Temperature [C]	7500 – 13000	0.43	16 bit
SWIR	reflection estimation	1475 – 1700	0.45	16 bit
NIR-850	reflection estimation	850 – 970	0.14	12 bit
NIR-735	reflection estimation	715 – 780	0.14	12 bit
BP-695	reflection estimation	680 – 720	0.14	12 bit
BN-660	reflection estimation	645 – 675	0.14	12 bit
RED LIN	reflection estimation	580 – 700	0.14	12 bit
GREEN LIN	reflection estimation	470 – 600	0.14	12 bit
BLUE LIN	reflection estimation	400 – 500	0.14	12 bit
Colour RGB	Colour	400 – 700	0.14	3x8 bit

LowAlt Map Specifications:

Sensor	Type	Wavelength Band [nm]	Resolution [m/pix]	data format
Warmtebeeld (TIR):	Temperature [C]	7500 – 13000	0.43	16 bit
SWIR	reflection estimation	1475 – 1700	0.45	16 bit
NIR-850	reflection estimation	850 – 970	0.057	12 bit
NIR-735	reflection estimation	715 – 780	0.057	12 bit
BP-695	reflection estimation	680 – 720	0.057	12 bit
BN-660	reflection estimation	645 – 675	0.057	12 bit
RED LIN	reflection estimation	580 – 700	0.057	12 bit
GREEN LIN	reflection estimation	470 – 600	0.057	12 bit
BLUE LIN	reflection estimation	400 – 500	0.057	12 bit
Colour RGB	Colour	400 – 700	0.057	3x8 bit




Additional LowAlt stip by Canon:

Sensor	Type	Wavelength Band [nm]	Resolution [m/pix]	data format
RED LIN	reflection estimation	580 – 700	0.026	10 bit
GREEN LIN	reflection estimation	470 – 600	0.026	10 bit
BLUE LIN	reflection estimation	400 – 500	0.026	10 bit
Colour RGB	Colour	400 – 700	0.026	3x8 bit



Multispectral Map Properties:

The overall spectral range of the multispectral dataset spans from 400 to 18000nm. Four different sensor types were used to accomplish this: cmos color (vis), cmos monochrome (nir), an InGaAs (swir) and a microbolometer (flir tir)





Weather conditions

Remote sensing data was acquired under sunny weather conditions with slow wind coming from east south-east and QNH of 1020 hPa. Some thin altostratus clouds were coming in from the west but did not reach the projected area during image acquisition.


 Koninklijk Nederlands
Meteorologisch Instituut
Ministerie van Infrastructuur en Waterstaat

[Home](#)
[KNMI.nl](#)

Klimatologie

Daggegevens van het weer in Nederland

Kies station, jaar, maand, dag en druk vervolgens op de knop "toon"

Cabauw Mast sinds 01/04/1986

 2020
 juli
 30
 [toon](#)

Daggegevens van het weer in Nederland

Het weer op donderdag 30 juli 2020 te Cabauw Mast © KNMI


Temperatuur		Normaal	Neerslag
Gemiddelde	19.2 °C	18.5 °C	Hoeveelheid
Maximum	25.2 °C	23.3 °C	Duur
Minimum	10.8 °C	13.5 °C	

Zon, bewolking & zicht		Wind	
Duur zonneschijn	12.7 uur	Gemiddelde snelheid	2.2 m/s (2 Bft)
Rel. zonneschijnduur	81 %	Maximale uurgemiddelde snelheid	4.0 m/s (3 Bft)
Gem. bedekkingsgraad	- octa's	Maximale stoot	6.0 m/s
Minimaal zicht	0.7 km	Overheersende richting	118 ° (020)

Relatieve luchtvochtigheid		Luchtdruk	
Gemiddelde	64 %	79 %	Gemiddelde luchtdruk
			1020.1 hPa

Voor meer elementen van deze stations, kies "Download" [Download](#)

Satellite images:





Aerial data collection.

All spectral bands were captured synchronously and were geo tagged in real time with GPS-GLONASS data. In order to cover the agreed area a pattern was flown capturing over 10.000 images in sequence.



Full map flight pattern




LowAlt flight pattern




Map and 3D point cloud processing

Images captured in the target area of the full map were exported to a 3d stitching program called Pix4D. Pix4D processes the geo-tagged images into a 3D point cloud. After additional georeferencing the dataset was processed into a densified point cloud. The densified point cloud is exported as a tab delimited file. Subsequently orthographic Geo-Tiff maps were exported.



Screenshot of 3D Point Cloud




Screenshot of 3D Point Cloud

3D Point Clouds of the full map and LowAlt Strips were exported in tab delimited text files. These files contain millions of xyz points.




Intensity to Reflection Estimation of VIS and NIR maps:

Two 1x1 meter calibration tiles containing 4 different grey levels were placed in the target area. Raw images containing these reflection tiles were used to determine linear conversion functions.



Four Greylevel Reftile

The reference tile that was used also has glare. This glare is direct reflection of incident light and is superposed onto the scattered light. The amount of glare in the image is dependent on the angle of incidence of the sun and the angle that. Therefore raw images containing the lowest amount of glare were used for this process and not the stitched map because Pix4D blends the different glared images together. Finally the GeoTiff maps exported by Pix4D were processed with the raster calculator from QGIS.




Band	A	B	C	D
BLUE	0.0096	0.125	0.289	0.451
GREEN	0.0087	0.129	0.293	0.459
RED	0.012	0.142	0.921	0.497
BN-660	0.0172	0.130	0.317	0.851
BP-695	0.0281	0.182	0.398	0.868
BP-735	0.0458	0.314	0.579	0.884
BP-850	0.148	0.635	0.921	0.950


Reflection values of the reference tile


NOTE 1: Spectral reflection of the SWIR band is not possible using this reference tile, SWIR was estimated by histogram fitting of comparable satellite data from Sentinel2.


NOTE 2: The TIR map is scaled in per pixel temperature data, not reflection data. The temperature map indicates estimated temperatures by FLIR. The measured temperatures are dependent on emissivity of the object's material and therefore should not be interpreted as absolute temperatures.


Bijlage B - Sloottransecten en interpretatie































Bijlage C – KRW deelmaatlatten groeivormen





Bijlage D – Diverse digitale bestanden

- Ingewonnen beelden (Rasters)
- Digitaal hoogte model (DEM - Raster)
- Bomenmasker (Raster)
- Watergangenmasker op basis van data Hoogheemraadschap
- Watergangenmasker op basis van remote sensing informatie
- Veldwaarnemingen:
 - Vegetatieopnamen (MS Excel)
 - Foto's van vegetatieopnamen

Bijlage E – Beeldenboek Rijnland

(NB: geciteerde tekst uit concept)

Ecologische stadia wateren


Om de verschillen te kunnen zien tussen slechte en goede waterkwaliteit hebben we vier beelden gemaakt die de stadia laten zien van het ecologische ideaalbeeld tot aan hoe een slechte waterkwaliteit er in die zelfde sloot uit zal zien en wat de bijbehorende kenmerken zijn. Deze beelden zijn generiek gemaakt, dus niet specifiek voor een bepaald type water. Naast de vier stadia staan rode en groene pijlen. De groene geven weer dat maatregelen bijdragen aan een beter ecologisch stadium, daar waar de rode weergeven dat er een verslechterde waterkwaliteit.

2.2.1 Ecologisch ideaalbeeld

- Helder water; weinig algengroei.
- Sterk begroeid: ondergedoken, drijvende en moerasplanten. Bedekking meer dan 60% (EKR: vegetatie ...).
- Lage biomassa vis: 100-350 kg/ha.
- Kenmerkende vissoorten: ruisvoorn, (jonge) snoek, zeelt, kroeskarper en de grote modderkruiper. (Rietvoorn-snoek visstandtype).
- Veel soorten waterdiertjes zoals kevers, wantsen, poelslakken, posthoornslakken, libellenlarven, waterpissebedden en ook muggenlarven.
- Zuurstofverzadiging: tussen 65 en 120%.
- Fosforgehalte 's zomers: maximaal 0,04 mg P/l. Range pm.

2.2.2 Voldoende kwaliteit

- Tamelijk helder water; enige groei van algen.
- Matig begroeid: bedekking 20-60% (EKR: vegetatie ...).
- Matige visbiomassa: 300-600 kg/ha.
- Kenmerkende vissoorten: snoek, blankvoorn, baars en kolblei (snoek-blankvoorn / blankvoorn brasem visstandtype).
- Vrij veel soorten waterdiertjes, zoals wantsen, poelslakken, waterpissebedden en muggenlarven.
- Zuurstofverzadiging: overdag tot 120%; 's nachts tot 35%.
- Fosforgehalte 's zomers: maximaal 0,22 mg P/l. Range pm.



2.2.3 Onvoldoende kwaliteit

Twee varianten:

- Weinig vegetatie; bedekking 10-20%, troebel en groei van algen (niet afgebeeld).
- Woekerende vegetatie: meer dan 80% bedekking één of enkele soorten; helder water (zie afbeelding) (EKR: vegetatie ...).

Overige kenmerken:

- Hoge visbiomassa (350-600 kg/ha).
- Dominantie door brasem, blankvoorn en snoekbaars (brasem snoekbaars visstandtype).
- Waterdiertjes tussen de vegetatie zoals poelslakken en posthoornslakken.
- Zuurstofverzadiging: 30-130 %.
- Fosforgehalte maximaal 0,44 mg P/l.

2.2.4 Slechte kwaliteit

- Zeer troebel.
- Vrijwel geen planten (EKR: vegetatie ...).
- Dikke sliblaag (soms vrijwel geen water meer).
- Sterke algengroei of flab, of bedekking met kroos.
- Hoge visbiomassa: 450-800 kg/ha.
- Dominantie door brasem, snoekbaars, karper.
- Waterdiertjes vooral in de bodem: muggenlarven en tubifex.
- Zuurstofverzadiging: 25-140% Fosforgehalte: meer dan 0,44 mg P/l.

