Precisietechnologie Tuinbouw: PPS Autonoom onkruid verwijderen

D2.4 Literatuurstudie spectrale reflectie-eigenschappen van planten en onkruiden

D2.5 Lab en veldexperimenten spectrale reflectie-eigenschappen van planten en onkruiden

Pieter Blok, Jochen Hemming, Henk-Jan Holterman, Jean-Marie Michielsens
en Jos Ruizendaal

Rapport WPR-751

Referaat

Dit rapport omvat de twee deliverables van het onderzoeksproject "autonoom onkruid verwijderen" die horen bij het thema hyper- en multispectrale onkruiddetectie. In de literatuur van de 10 tot 15 jaar zijn voldoende aanwijzingen te vinden dat er op basis van spectrale karakteristieken een goed onderscheid in diverse plantensoorten te maken is. Voor de hyperspectrale labmetingen zijn er verschillende gewassen en onkruiden opgekweekt. Van alle planten is op verschillende dagen in het lab het reflectiespectrum beeldvormend gemeten tussen 400 en 1000 nm en tussen 900 en 1700 nm. Met name de reflectie in het chlorofyl gebied (650 – 670 nm) en de reflectie van golflengtes in het groene gebied (rond 550 nm), red-edge (700 nm) en nabij-infrarood (800 nm) tonen een onderscheidend vermogen aan tussen de onderzochte gewassen en onkruiden. Met veldmetingen is onderzocht of het mogelijk is om met hyperspectrale camerabeelden groene onkruiden in een groen slagewas te kunnen detecteren. De nauwkeurigheid van een juiste classificatie was op beide meetdagen respectievelijk 6.9% en 9.9% onder de eerder vastgestelde streefwaarde van 90%. Om het effect van het gebruik van verschillende camera's op het proefresultaat uit te kunnen sluiten wordt een vergelijkingsonderzoek aanbevolen.

Abstract

This report contains the two deliverables of the research project "autonomous weed removal" that deal with the topic hyper- and multispectral weed detection. In the literature of the past 10 to 15 years, there are sufficient indications that a good distinction on the basis of spectral characteristics can be made between various plant species. For the hyperspectral lab measurements, various crops and weeds have been cultivated. The reflection spectrum of all plants was measured between 400 and 1000 nm and between 900 and 1700 nm on different growing stages in the laboratory. In particular the reflection in the chlorophyll range (650-670 nm) and in the green range (around 550 nm), red-edge (700 nm) and near-infrared (800 nm) show a distinctive power between the crops and weeds studied. With field measurements it was investigated whether it is possible to detect green weeds in a green lettuce crop using hyperspectral camera images. The accuracy of a correct classification on both measurement days was 6.9% and 9.9%, respectively, below the previously set target value of 90%. In order to exclude the effect of the use of different cameras on the test result, a comparative follow-up study is recommended.

Rapportgegevens

Rapport WPR-751

Projectnummer: 3742187700

DOI nummer: 10.18174/442084

Dit project is mede tot stand gekomen door de bijdrage van de Topsector Tuinbouw & Uitgangsmaterialen en het Ministerie van Landbouw, Natuur en Voedselkwaliteit (LNV).

Disclaimer

© 2018 Wageningen, Stichting Wageningen Research, Wageningen Plant Research, Business unit Glastuinbouw, Postbus 20, 2665 MV Bleiswijk T 0317 48 56 06, www.wur.nl/plant-research.

Kamer van Koophandel nr.: 09098104

BTW nr.: NL 8113.83.696.B07

Stichting Wageningen Research. Alle rechten voorbehouden. Niets uit deze uitgave mag worden verveelvoudigd, opgeslagen in een geautomatiseerd gegevensbestand, of openbaar gemaakt, in enige vorm of op enige wijze, hetzij elektronisch, mechanisch, door fotokopieën, opnamen of enige andere manier zonder voorafgaande schriftelijke toestemming van Stichting Wageningen Research.

Stichting Wageningen Research aanvaardt geen aansprakelijkheid voor eventuele schade voortvloeiend uit het gebruik van de resultaten van dit onderzoek of de toepassing van de adviezen.

Adresgegevens

Wageningen University & Research, BU Glastuinbouw

Postbus 20, 2665 ZG Bleiswijk

Violierenweg 1, 2665 MV Bleiswijk

T +31 (0)317 48 56 06

Inhoud

	Samenvatting	5
1	Inleiding	7
2	Literatuurstudie spectrale reflectie-eigenschappen van planten en onkruiden (D2.4)	9
	2.1 Inleiding	9
	2.2 Review-artikelen	10
	2.3 Detectie van onkruiden tussen ander gewas	11
	2.4 Fluorescentietechnieken	14
	2.5 Spinazie en sla	14
	2.6 Conclusie	15
3	Lab en veldexperimenten spectrale reflectie-eigenschappen van planten en onkruiden (D2.5)	17
	3.1 Introductie	17
	3.2 Materialen en methoden lab experimenten	17
	3.3 Resultaten lab experimenten	22
	3.3.1 Spectrale reflectiecurves	22
	3.3.1.1 Eerste meetdag 10/11/2016	22
	3.3.1.2 Tweede meetdag 15/11/2016	23
	3.3.1.3 Derde meetdag 21/11/2016	25
	3.3.1.4 Vierde meetdag 25/11/2016	26
	3.3.2 Classificatie VNIR - 400 t/m 1000 nm	28
	3.3.2.1 Classificeren van plantpixels voor het vinden van onderscheidende golflengtes	28
	3.3.2.2 Meest onderscheidende golflengtes in het onderscheid tussen gewassen en onkruiden	30
	3.3.2.3 Algemene scheidingsfunctie tussen een gewas en alle onkruiden samen geclusterd	32
	3.3.2.4 Tarwe versus alle onkruiden	32
	3.3.2.5 Rucola versus alle onkruiden	35
	3.3.2.6 Landkers versus alle onkruiden	38
	3.3.2.7 Scheidingsfunctie tussen een gewas en alle onkruiden gereduceerd naar de meestonderscheidende golflengte	40
	3.3.2.8 Tarwe versus alle onkruiden	40
	3.3.2.9 Rucola versus alle onkruiden	43
	3.3.2.10 Landkers versus alle onkruiden	44
	3.3.3 Classificatie NIR - 900 t/m 1700 nm	46
	3.3.3.1 Tarwe versus alle onkruiden	46
	3.3.3.2 Rucola versus alle onkruiden	49
	3.3.3.3 Landkers versus alle onkruiden	51
	3.4 Discussie en aanbevelingen lab experimenten	53
	3.5 Conclusies lab experimenten	53
	3.6 Materialen en methoden veldexperimenten	54
	3.7 Resultaten veld experimenten	62
	3.7.1 Resultaten meetdag 1 - MLP classifier	63
	3.7.2 Resultaten meetdag 2 - MLP classifier	65
	3.8 Discussie en conclusie veldexperimenten	66

4	Conclusies en discussie	69
	Literatuur	71
	Bijlage 1 Alle spectrale analyses tussen gewas en onkruid (VNIR) lab experimenten	73
	B1.1 Meetdag 1	73
	B1.2 Meetdag 2	77
	B1.3 Meetdag 3	100
	B1.4 Meetdag 4	106
	Bijlage 2 Beelden veld experimenten	111
	B2.1 Beeldanalyse van hyperspectrale beelden 30 augustus 2017	111
	B2.2 Beeldanalyse van hyperspectrale beelden 7 september 2017	115

Samenvatting

Dit rapport omvat twee deliverables van het onderzoeksproject "autonoom onkruid verwijderen". Dit project is als privaat publieke samenwerking (PPS) tussen Steketee machinefabriek BV en Wageningen University & Research binnen het programma Precisie technologie Tuinbouw uitgevoerd. De twee deliverables horen bij het thema hyper- en multispectrale onkruiddetectie. Het zijn deliverable D2.4 Literatuurstudie spectrale reflectie-eigenschappen van planten en onkruiden en D2.5 Lab- en veldexperimenten spectrale reflectie-eigenschappen van planten en onkruiden.

Er is een overvloed aan literatuur te vinden over spectrale metingen aan plantmateriaal van de laatste 10 tot 15 jaar. Veel onderzoek maakt gebruik van dezelfde methoden, zoals discriminant analysis om uit een 'trainingsset' de significante reflectantiecures te bepalen en een statistisch beoordelingsmodel. Dit model wordt vervolgens toegepast op een 'testset' van onafhankelijke metingen. Er zijn voldoende aanwijzingen te vinden dat er op basis van spectrale karakteristieken een goed onderscheid in diverse plantensoorten te maken is. Uit de gemeten spectra kunnen een beperkt aantal (bijv. 6 tot 20) golflengtes geselecteerd worden die voldoende bepalend zijn. Welke golflengtes dat precies zijn, hangt van de plantensoort af, ook al liggen ze meestal wel in overeenkomstige golflengtebanden (groen (rond 550nm), rood-edge (rond 700 nm) en nabij infrarood tot 800 nm).

Voor de hyperspectrale labmetingen zijn er verschillende gewassen (tarwe, rucola en landkers babysla) en onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, kweek, melganzenvoet) opgekweekt. Van alle planten is op verschillende dagen in het lab het reflectiespectrum beeldvormend gemeten tussen 400 en 1000 nm (VNIR camera) en tussen 900 en 1700 nm (NIR camera). Met een Fisher Lineaire Discriminant Analyse (LDA) is vervolgens een scheidingsfunctie berekend tussen de beeldpixels behorend bij de gewassen en de onkruiden. Vervolgens zijn de meest onderscheidende golflengtes bepaald en is de classificatie geëvalueerd. Ondanks dat de resultaten als indicatief moeten worden beschouwd, zijn er wel interessante trends zichtbaar, met name in de reflectie in het chlorofyl gebied (650 – 670 nm). Ook de reflectie van golflengtes in het groene gebied (rond 550 nm), red-edge (700 nm) en nabij-infrarood (800 nm) tonen in minder mate een onderscheidend effect tussen de onderzochte gewassen en onkruiden.

In het vervolg zijn er veldmetingen uitgevoerd met de vraag of het mogelijk is om met hyperspectrale camerabeelden en beeldanalyse (groene) onkruiden in een groen slagewas te kunnen detecteren. Hiervoor is op twee dagen met een mobiele opstelling met een hyperspectrale line-scan camera beelddata tussen de 400nm en 1000 nm verzameld. Voor de classificatie is er gekozen voor een neurale netwerk dat niet-lineaire classificatie mogelijk maakt. Ook is er post-processing stap toegevoegd om pixels tot planten te clusteren om zo een resultaat per plant te kunnen bepalen. De nauwkeurigheid van een juiste classificatie op de hele dataset ligt op beide meetdagen respectievelijk 6.9% en 9.9% onder de eerder vastgestelde streefwaarde van 90%. De performance bij het detecteren van onkruiden in het open veld was, zoals door de grotere variatie in ook verwacht, lager dan bij de lab metingen. Voor de veldexperimenten is een andere camera gebruikt dan voor de labmetingen. Om het effect van het gebruik van verschillende camera's (en bijbehorende hardware zoals belichting) op het proefresultaat uit te kunnen sluiten wordt een vergelijkingsonderzoek aanbevolen.

1 Inleiding

Binnen de uitvoeringsagenda van de topsector tuinbouw en uitgangsmaterialen (T&U) is één van de speerpunten onderzoek naar arbeid en arbeidsomstandigheden door automatisering en robotisering. In dit kader is in 2014 het programma precisietechnologie tuinbouw van start gegaan. Werkpakket 2 binnen dit programma richt zich op autonoom onkruid verwijderen. Dit werkpakket is als privaat publieke samenwerking (PPS) tussen Steketee machinefabriek BV en Wageningen University & Research uitgevoerd. Recente hardware en software ontwikkelingen op het gebied van hyper- en multispectrale camera's bieden nieuwe kansen voor een nog betere detectie van onkruiden tussen gewasplanten. Dit is met name belangrijk voor het wieden in volvelds gewassen omdat hier geen gebruik kan worden gemaakt van de bekende geometrie van de gewasplantpositie. Dit rapport omvat de twee deliverables die bij het thema hyper- en multispectrale onkruiddetectie horen. Deliverable D2.4 Literatuurstudie spectrale reflectie-eigenschappen van planten en onkruiden en D2.5 Lab en veldexperimenten spectrale reflectie-eigenschappen van planten en onkruiden. De overige deliverables van het autonoom onkruid wieden project zijn in een apart rapport beschreven.

2 Literatuurstudie spectrale reflectie-eigenschappen van planten en onkruiden (D2.4)

2.1 Inleiding

Licht dat in contact komt met een plant of gewas kan worden geabsorbeerd, gereflecteerd of getransmitteerd. Per plantensoort of toestand van de plant (groeistadium, beschikbaarheid van water en nutriënten, ziektes) kunnen deze eigenschappen verschillen. Omdat licht van de golflengte 500-600 nm voor een groot deel wordt gereflecteerd hebben planten voornamelijk voor ons een zichtbare groene kleur. Er is veel literatuur over multispectrale en hyperspectrale reflectie-eigenschappen van plantmateriaal. Spectrale metingen kunnen plaats vinden op verschillende schalen. 'Proximal sensing' gebeurt op korte afstand van het gewas ('ground based'), zodat individuele bladeren en planten gedetecteerd kunnen worden. Deze methode is geschikt om individuele onkruidplanten te herkennen waarop dan eventueel actie kan worden ondernomen. Onder 'remote sensing' wordt meestal verstaan de detectie op grotere hoogte: vanuit drones, vliegtuigen of satellieten. Dit geeft informatie op grotere schaal: 'patches' van meerdere planten op zelfs complete akkers. De opgenomen beelden bevatten geen individuele planten meer, zodat allen pleksgewijze behandelingen plaats kunnen vinden. Overigens wordt soms de proximal sensing ook als remote sensing aangeduid, als overkoepelende term. De metingen kunnen verschillende doelen hebben: bijv. onkruiddetectie tussen een gewas of ziekteherkenning. Detectie kan bovendien gebruikt worden voor diagnose of ook kwantificering van de omvang (van onkruiden of ziekte), om te beslissen of actie nodig is of niet.

Het domein van optische waarnemingen reikt van 400 nm in het zichtbare gebied van het elektromagnetische spectrum tot 2500 nm in het short-wave infraroodgebied (Figuur 1). De sterke absorptie van licht door de fotosynthetische pigmenten (voornamelijk chlorofyl) in een blad domineert de eigenschappen in het zichtbare spectrum (VIS, 400 nm - 700 nm). Het nabije infrarood plateau (NIR, 700 nm - 1100 nm) is een regio waar biochemische absorpties worden beperkt door de aanwezige stoffen in bladeren, vooral cellulose, lignine en andere structurele koolhydraten. Echter, blad-reflectie in dit gebied kan ook beïnvloed worden door meervoudige verstrooiing van fotonen in het blad, gerelateerd aan de interne structuur, en lucht-water grensvlaktes die licht breken in bladeren. De reflectie en transmissie in het midden-infrarood ook short-wave-infrarood genoemd (SWIR, 1100 nm - 2500 nm) is ook een gebied van sterke absorptie, voornamelijk door het aanwezige water in groene bladeren. De absorptie door water in het blad zijn het grootst in spectrale banden rond 1450, 1940 en 2500 nm, met belangrijke secundaire absorpties bij 980 nm en 1240 nm (Carter, 1991).

Figuur 1 Typische spectra voor reflectie en transmissie van een blad (Jacquemoud and Ustin, 2008).

De reflectie-eigenschappen van een plant zijn aan verandering onderhevig, zowel in zichtbare deel (VIS, 400-700 nm) als het nabij infrarood (NIR, 700-1100 nm). Gedurende de groei kan deze veranderen, maar ook onder invloed van externe omstandigheden zoals hoeveelheid zonlicht, aanwezigheid van water en nutriënten. In een aantal artikelen komt dit naar voren.

Deze literatuurstudie is een eerste verkenning van recente publicaties op het gebied van plantherkenning op basis van reflectiemetingen. Review-artikelen bieden beknopte overzichten van recente ontwikkelingen. Onderzoeksartikelen daarentegen geven meer diepgang in resultaten. De studie is verre van volledig, want er is de laatste jaren enorm veel gepubliceerd hierover.

Een gebruikelijke aanpak in onderzoek naar plantherkenning op basis van het meten van de reflectie is door eerst spectrale metingen te doen dicht bij een blad van een plant. Door een groot aantal van dergelijke metingen te doen, wordt een 'training set' opgebouwd, waar met behulp van statistische analyse (discriminant analysis) een model van de karakteristieke kenmerken gemaakt wordt. Een tweede, onafhankelijke set metingen dient vervolgens om het model te testen.

2.2 Review-artikelen

Goede review-artikelen die algemene informatie geven en ook verwijzen naar andere literatuur zijn (Noble *et al.* 2002, Heege and Thiessen 2013, Bradley 2014, Peteinatos *et al.* 2014, Martinelli *et al.* 2015). Allerlei nuttige informatie komt daarin naar voren. Zo is bijv. in onderstaande Figuur 2 uit Heege en Thiesen (2013) te zien hoe leaf area index (LAI) en chlorofylconcentratie van invloed kunnen zijn op de reflectie-eigenschappen.

Fig. 6.3 Reflectance of plants depending on either the leaf-area-index (*top*) or on the chlorophyll concentration in the leaves (*bottom*). The curves are based on simulation models. For the *top* graph, the chlorophyll mass per unit leaf area is constant. Vice versa, for the *bottom* graph, the leaf-area-index is constant (From Reusch 1997, altered)

Figuur 2 Invloed van de Leaf area index (LAI) en chlorofylconcentratie op de reflectie-eigenschappen (Heege en Thiesen, 2013).

De review van (Singh *et al.* 2016) bespreekt 'machine learning' voor apparatuur dat gebruikt maakt van imaging technieken. De review artikel van (Noble *et al.* 2002) heeft speciale aandacht voor het toepassen van spectrale technieken voor onkruiddetectie onder real-world omstandigheden. Door o.a. de grote variatie in de natuurlijke lichtcondities wordt de correcte classificatie namelijk behoorlijk bemoeilijkt.

2.3 Detectie van onkruiden tussen ander gewas

Peña *et al.* (Peña *et al.* 2015) onderzochten de herkenning van enkele onkruiden (*Chenopodium album*, *Convolvulus arvensis*) tussen zonnebloemen in Zuid-Spanje aan de hand van opnamen met een drone. Diverse vlieghoogtes zijn getest in verschillende groeistadia van de jonge gewassen (4-8 bladeren per plant). Multispectrale opnamen tussen 450 en 780 nm werden ingedeeld in zes spectrale banden (blauw B, groen G, rood R, rood-edge R-edge en nabij infrarood NIR). Hoewel in potentie meer mogelijk zou moeten zijn, gezien deze spectrale metingen, is toch slechts gebruik gemaakt van off-row detectie van groen tegen een achtergrond van zand. Alles wat in de rij stond, werd geacht zonnebloem te zijn.

Slaughter *et al.* (Slaughter *et al.* 2008) bekeken de detectie van onkruiden in enkel cultivars van jonge ijsbergsla en bladsla (*Lactuca sativa capitata* en *crispa*) in Californië (USA). De te detecteren onkruiden waren klein kruiskruid (*Senecio vulgaris*) herderstasje (*Capsella bursa-pastoris*) en melkdistel (*Sonchus spp.*). Voor de trainingsset werden opnames van zeer nabij gemaakt; een pixel equivalent met een spot van 3 mm op het blad. Zo kan elke opname slechts één blad bevatten. Ook randeffecten kunnen worden uitgesloten. Het opgenomen spectrum liep van 384 tot 810 nm. Twee indices werden bepaald: RVI, red ratio vegetation index en NDVI, normalized difference vegetation index. Daarnaast werd het gehele spectrum gelijkmatig over 21 banden verdeeld, zonder vooraf bepaalde golflengtes meer gewicht te geven. Onderstaande Figuur 3 toont absorptiespectra van de sla en onkruiden.

Figure 2. Average absorbance spectra of lettuce crops and annual weed seedlings.

Figuur 3 Absorptiespectra van de sla en onkruiden (Slaughter *et al.* 2008).

De herkenning op basis van 21 banden bleek beter te presteren dan RVI of NDVI. Gemiddeld werd in 90% van de gevallen het juiste onderscheid tussen sla en onkruid gemaakt.

Feyaerts and Van Gool (Feyaerts and Van Gool 2001) onderzochten de detectie van verschillende onkruiden (waaronder *Poa annua*, *Stellaria media*, *Chenopodium album*) in suikerbieten. De uiteindelijk gekozen spectrale signatuur voor de discriminatie gebruikte de volgende golflengtes: 441nm, 446nm, 459nm, 883nm, 924nm, 988nm. Met een neuronale netwerk classifier konden in open veld omstandigheden 80% van de gewasplanten en gemiddeld 91% van de onkruidplanten correct herkend worden.

Yang *et al.* (Yang *et al.* 2004) onderzochten detectie van onkruiden in mais en soja aan de hand van foto's vanuit een Piper Seneca vliegtuig. Daarvoor werden plots (3x3 m²) aangelegd met verschillende combinaties van mais, soja en diverse onkruiden. Het spectrum VIS-NIR werd opgedeeld in 24 banden. Hieruit werden ook 12 vegetation indices (VI's) afgeleid, in feite verhouding van reflectanties bij verschillende golflengtes (rood vs NIR). NDVI's werden bepaald voor verschillende golflengteparen; 65 indices op basis van 5 rode en 13 NIR banden. Een volledige classificatie (herkenning van beide gewassen en alle onkruiden), was mogelijk met 85% nauwkeurigheid op basis van de 65 NDVI-waarden.

Mirik *et al.* (Mirik *et al.* 2013) onderzocht de detectie van het onkruid knikkende distel (*Carduus nutans*) in grasland (diverse C3- en C4-gewassen), zowel voor als tijdens de bloei (resp. april en juni). De metingen vonden plaats in Texas, met behulp van een Cessna vliegtuigje. Het spectrale meetbereik was 505-900 nm. Daarvan werd uiteindelijk alleen het deel 500-710 nm gebruikt, verdeeld over 25 golflengtebanden. Onderstaande Figuur 4 toont de spectrale reflectie eigenschappen van de onderzochte gewassen. Ook de kale grond werd daaraan toegevoegd, om deze te kunnen herkennen als de planten nog jong zijn en de bodem niet geheel bedekken. Er zijn duidelijke verschillen in de spectra van april en juni, die terug te voeren zijn op de verschillende groeistadia. De grootste verschillen werden gezien in NIR, daarom lag de focus op NIR-banden (764-885 nm). Er zijn significante verschillen in de spectra van april en juni. Gemiddelde nauwkeurigheid van een juiste classificatie lag tussen 79 en 91% voor de detectie van distel in grasland, in resolutie van 1 m².

Figure 2. Spectral profile of training samples for musk thistle (N = 200), tansy mustard (N = 91), bromo grass (N = 30), wheat (N = 200), senescent grass (N = 35) and bare ground (N = 200) in April (a) and musk thistle (N = 200), Russian thistle (N = 72), Johnsongrass (N = 84), senescent grass (N = 35) and bare ground (N = 200) in June (b) 2006.

Figuur 4 Spectrale reflectie eigenschappen van verschillende gewassen (Mirik *et al.* 2013).

Shapira *et al.* (Shapira *et al.* 2013) onderzochten detectie van onkruiden in tarwe en kikkererwt in Zuid-Israël. 'Ground based' opnames werden gemaakt. Het totale meetbereik bedroeg 400-2400 nm, maar de water-absorptiebanden (rond 1400 en 1800-2000 nm) moesten worden uitgesloten. De band 675-1100 nm bleek het belangrijkste voor het onderscheid tussen de plantsoorten. Er werden zowel opnames gemaakt van zeer dichtbij (bladniveau; voor de trainingsset) als vanaf ca. 1.4 m hoogte (plantniveau). De classificatie van opnames op plantniveau was in ca. 95% van de gevallen juist. Voor tarwe was detectie op basis van 11 banden mogelijk; voor kikkererwt waren 8 banden significant. In beide gevallen lagen diverse banden in het 'red-edge' bereik.

Uit dezelfde onderzoeksgroep is het onderzoek van Herrmann *et al.* (Herrmann *et al.* 2013) naar onkruid (gras en breedbladig) in tarwe. Het meetbereik van 400-850 nm werd opgedeeld in 91 banden. Uit de opnames werden at random pixels geselecteerd voor de analyse, waarbij de helft van de pixels een zonverlicht deel betrof en de andere helft in de schaduw lag. Op basis van reflectie-eigenschappen bij 470, 555 en 670 nm kon onderscheid gemaakt worden in zon of schaduw, grond of vegetatie en 'specular' reflectie op de vegetatie. Met behulp van discriminant analysis konden gras, breedbladig onkruid, tarwe en grond onderscheiden worden. Een VIP analyse (variable importance in projection) daarbij leverde de belangrijkste onderscheidende golflengtes: 730 nm (red-edge) voor de vegetaties, 685 nm voor grond, 550 nm voor gras, 440 nm voor tarwe. Overall nauwkeurigheid van herkenbaarheid bedroeg 72%.

Gómez-Casero *et al.* (Gómez-Casero *et al.* 2010) beschrijven detectie van wilde haver en kanariegras in wintertarwe, in Zuid-Spanje. Grondgebonden opnames (op plantniveau) vonden plaats laat in het groeiseizoen (april-mei), wanneer eerst de tarwe en daarna ook de onkruiden langzaam geel beginnen te worden. Aanvankelijk werden 50 golflengtebanden geselecteerd in het bereik 325-1075 nm. Dit werd later teruggebracht tot 13 banden over 400-900 nm. De indices RVI en NDVI werden ook bepaald. Tussen eind april en begin mei bleek golflengte 420 nm het belangrijkste; golflengtes tussen 800-900 nm bleken weinig onderscheidend. Eind mei waren de diverse plantensoorten al behoorlijk geel en de typische reflectantiepatronen voor groene gewassen werden dan ook behoorlijk vlak. Dit maakte een juiste classificatie een flink stuk onnauwkeuriger.

Hadoux *et al.* (Hadoux *et al.* 2012) bestudeerden de detectie van dicotyl onkruid in tarwe, in Zuid-Frankrijk, in de maand maart. Er werden opnames gemaakt met het spectrale bereik 400-1000 nm, verdeeld over 160 banden. De auteurs zeggen echter niet welke banden zijn gebruikt in de analyse.

Zhang *et al.* (2012) onderzochten onkruiden tussen tomatenplanten. Verschillende aspecten werden daarbij meegenomen. Zo werden tomaten geteeld waarbij de nachttemperatuur op verschillend niveau werd gebracht. Dit werd zichtbaar in verschillende spectra, zoals te zien in onderstaande Figuur 5 (Zhang and Slaughter 2011a). De grootste effecten traden op rond 480-670 nm (VIS) en 720-810 nm (NIR). Voor onkruiden waren soortgelijke effecten zichtbaar.

Fig. 2. Average reflectance spectra for tomato under four nighttime temperatures.

Figuur 5 Gemiddelde reflectie spectra voor tomaat bij vier nachttemperaturen (Zhang *et al.* 2012).

Ook werd gekeken naar het effect van de hoeveelheid zonlicht die planten ontvangen (Zhang and Slaughter 2011b), zie onderstaande Figuur 6. Kleine maar significante verschillen traden op rond 550 nm en 750 nm.

Fig. 2 – Average relative reflectance spectra measured for tomato seedlings grown under high and low sunlight intensity conditions.

Figuur 6 Gemiddelde reflectie spectra gemeten bij zaailingen van tomaat gecultiveerd bij hoge en lage lichtintensiteit (Zhang and Slaughter 2011b).

Dergelijke multispectrale detectietechnieken werden met succes toegepast in de behandeling van in-rij onkruiden tussen jonge tomatenplanten (Zhang *et al.* 2012). De onkruiden werden na detectie bespoten met hete olie met behulp van een gepulseerd micro-doseringssysteem. Op deze manier was de controle van onkruid 95% succesvol. De schade aan tomatenplanten door de olie was ca. 2.4%

De Castro *et al.* (de Castro *et al.* 2012, de Castro *et al.* 2013) onderzochten detectie van breedbladig kruisbloemig onkruid (*Diploaxis* spp. en *Sinapis* spp.) wintergewassen (tarwe, tuinbonen en erwten), in Spanje. Er werden met behulp van een Cessna opnamen gemaakt rond het middaguur op een zonnige dag in april, met een spectraal bereik van 400-1100 nm. Onkruiden werden het best gedetecteerd (85%) op basis van de R/B ratio en B/G ratio. Een opmerkelijk goed onderscheid van nagenoeg 100% was mogelijk tussen onkruiden en tuinbonen.

2.4 Fluorescentietechnieken

Sommige onderzoekers maken gebruik van fluorescentiemethoden. Hoewel in sommige gevallen de herkenning van ziekten of onkruiden daarmee eenvoudiger wordt, is het belangrijkste nadeel dat er een UV-lichtbron nodig is. Bijv. grassen en onkruiden in graan werden zo met succes gedetecteerd (Longchamps *et al.* 2010).

2.5 Spinazie en sla

Literatuur over onkruiden in spinazie is niet gevonden. Wel is er onderzoek gedaan naar reflectie-eigenschappen van spinazie, bijv. als indicatoren van stikstofhoeveelheden en chlorofylgehalte (Jones *et al.* 2007a); de NDVI (GreenSeeker) bleek een goede indicator. Er kon ook een verband met biomassa worden gelegd (Jones *et al.* 2007b).

Een ander type onderzoek omvat de detectie van mestdeeltjes op planten als spinazie en sla. Dit blijkt zeer goed mogelijk met fluorescente technieken (Everard *et al.* 2014). In dit onderzoek werd overigens niet gewerkt met spinazie op het land, maar verkregen uit de groentewinkel. Mestdruppels werden in het laboratorium aangebracht. Detectie van mest op spinazie en sla werd ook onderzocht door Lee *et al.* (Lee *et al.* 2014). Ook zij maakten van fluorescente methoden gebruik.

Hierboven werd al onderzoek beschreven van detectie van onkruid tussen jonge bladsla (Slaughter *et al.* 2008). Ander onderzoek aan sla beschrijft effect van stressfactoren op reflectantiespectra, zoals bijvoorbeeld een watertekort (Gao *et al.* 2010). Onderstaande Figuur 7 laat zien dat met name bij grotere golflengtes in SWIR (short-wave infrared) duidelijke verschillen zichtbaar zijn.

Fig. 2. Lettuce canopy reflectance spectra under different water stress

Figuur 7 Reflectie-eigenschappen van een sla gewas bij verschillende niveaus van water stress (Gao et al. 2010).

De meest gevoelige golflengtes voor waterstress in sla bleken 1267nm, 1443nm, 1661nm, 1921nm. Maar ook in NIR waren effecten aantoonbaar: de reflectie bij golflengtes 810 en 940 nm correleerden significant met water stress.

2.6 Conclusie

Er is een overvloed aan literatuur te vinden over spectrale metingen aan plantmateriaal van de laatste 10 tot 15 jaar. Deze beknopte studie is daarom zonder twijfel niet volledig.

Veel onderzoek maakt gebruik van dezelfde methoden, zoals discriminant analysis om uit een 'trainingsset' de significante reflectantiecures te bepalen en een statistisch beoordelingsmodel. Dit model wordt vervolgens toegepast op een 'testset' van onafhankelijke metingen.

Ook al worden in de artikelen steeds andere gewassen en onkruiden besproken, in grote lijnen komen de resultaten wel op hetzelfde neer. Zo worden vaak dezelfde spectrale gebieden als relevant beschreven (wat ook niet zo gek is, want chlorofyl is vaak de belangrijkste factor).

De verschillen in de reflectantiecures lijken weliswaar klein (op het eerste gezicht), toch kunnen met de statistische modellen goede classificaties gemaakt worden. Daar staat tegenover dat slechts in beperkte mate rekening gehouden is met verschillen die een andere oorzaak hebben, zoals stressfactoren. Ook hoeveelheid zon of de (voldoende) aanwezigheid van nutriënten zijn van invloed op de groei dus op de spectrale karakteristieken van de planten.

De belangrijkste constatering is in ieder geval dat er voldoende aanwijzingen in de literatuur te vinden zijn dat er op basis van spectrale karakteristieken een goed onderscheid in diverse plantensoorten te maken is. Dat wil zeggen, zelfs alleen op basis van spectra, zonder rekening te houden met andere aspecten zoals vorm van blad of plant. Uit de gemeten spectra kunnen een beperkt aantal (bijv. 6 tot 20) golflengtes geselecteerd worden die voldoende bepalend zijn. Welke golflengtes dat precies zijn, hangt van de plantensoort af, ook al liggen ze meestal wel in overeenkomstige golflengtebanden (groen (rond 550nm), rood-edge (rond 700 nm) en nabij infrarood tot 800 nm).

3 Lab en veldexperimenten spectrale reflectie-eigenschappen van planten en onkruiden (D2.5)

3.1 Introductie

Er is veel wetenschappelijke literatuur over multispectrale en hyperspectrale reflecties van plantmateriaal voor het detecteren van onkruid tussen een gewas. Ook al worden in de diverse wetenschappelijke artikelen steeds andere gewassen en onkruiden besproken, in grote lijnen komen de resultaten wel op hetzelfde neer: zo wordt vaak de reflectie van het chlorofyl (650-670 nm) als meest relevant beschouwd in het onderscheid tussen onkruid en gewas.

De belangrijkste constatering uit het literatuuronderzoek in hoofdstuk 1 is in ieder geval dat er voldoende aanwijzingen in de literatuur te vinden zijn dat er op basis van spectrale karakteristieken een goed onderscheid in diverse plantensoorten te maken is. Dat wil zeggen, zelfs alleen op basis van spectra, zonder rekening te houden met andere aspecten zoals vorm en structuur van blad of plant.

De hieronder beschreven aanpak is, dat uit de gemeten spectra een beperkt aantal (bijv. 6 tot 20) golflengtes geselecteerd kunnen worden die voldoende bepalend zijn om onderscheid te kunnen maken tussen plantensoorten. Welke golflengtes dat precies zijn, hangt van de plantensoort af, ook al liggen ze meestal wel in overeenkomstige golflengtebanden:

- Groen - rond 550nm.
- Chlorofyl - tussen 640 - 670 nm.
- Rood-edge - rond 700 nm.
- Nabij infrarood - tot 800 nm.

3.2 Materialen en methoden lab experimenten

Voor de hyperspectrale metingen zijn er verschillende gewassen en onkruiden opgekweekt, door de opdrachtgever, Machinefabriek Steketee BV, is bepaald welke gewassen en onkruiden in de proef meegenomen zouden worden:

Gewassen:

- Tarwe.
- Rucola.
- Landkers babysla.

Onkruiden:

- Vogelmuur.
- Zandraket.
- Hanenpoot.
- Straatgras.
- Kweek.
- Melganzenvoet.

Alle gewassen en onkruiden zijn opgekweekt in individuele kweekbakken op een gemixt substraat van potgrond en zandgrond om een werkelijke teeltsituatie te simuleren. De planten zijn gezaaid in november en opgekweekt in een kasruimte met een geregelde temperatuur van 20°C en een relatieve luchtvochtigheid van 80%. Gedurende 8 uur per dag is er bijgelicht door Son-T assimilatielampen om de natuurlijke groeiomstandigheden zo goed mogelijk te benaderen.

Vogelmuur (chickweed)

Zandraket (arabidopsis)

Hanenpoot (cockspur)

Tarwe (wheat)

Straatgras (annual meadow grass)

Melganzenvoet (Lamb's quarters)

Kweek (couch grass)

Rucola (Rucola)

Landkers San Maria (salad leaves 'land cress')

Figuur 8 Kweekbakken met onkruiden en gewassen.

De meetopstelling was zo ingericht dat twee spectrale camera's via een instelbare stappentafel boven over de planten bewogen werd om de planten van de bovenkant te scannen.

In Tabel 1 staat een overzicht van de verschillende plantenbakken met de meetdagen per bak. De meeste bakken zijn meer dan één keer gemeten om de planten in verschillende stadia te kunnen meten. In totaal zijn de planten over vier verschillende dagen gemeten vanwege het verschil in opkomst.

Tabel 1

Meetschema van kweekbakken.

Naam	NL	EN	Zaai-datum	Gemeten 10/11/2016	Gemeten 15/11/2016	Gemeten 21/11/2016	Gemeten 25/11/2016
Stellaria media	Vogelmuur	chickweed	1/11/2016	x	x		
Arabidopsis thaliana	Zandraket	arabidopsis	3/11/2016	x	x	x	
Echinochloa crus-galli	Hanenpoot	cockspur	1/11/2016		x	x	
Triticum aestivum	Tarwe	common wheat	1/11/2016	x	x		
Poa annua	Straatgras	annual meadow grass	1/11/2016		x		
Elymus Repens	Kweek	couch grass	1/09/2016	x			
Chenopodium album	Melganzen-voet	Lambs quarters	1/11/2016		x		x
Eruca sativa	Rucola	Rucola	1/11/2016		x	x	x
Barbarea verna	Landkers san maria	Salad Leaves 'Land Cress' san maria	1/11/2016		x	x	x

Van alle planten is het reflectiespectrum beeldvormend gemeten tussen 400 en 1000 nm (VNIR camera) en tussen 900 en 1700 nm (NIR camera). Het spectrumgebied bevat het zichtbare licht (400 tot 700 nm), het nabij-infrarode licht (700 tot 1000 nm) en het infrarode licht (1000 tot 1700 nm). De laatste twee gebieden liggen buiten de menselijke perceptie. Elke beeldpixel van de VNIR camera bestaat uit een spectrum van 192 waarden met een golflengteverschil tussen opeenvolgende waarden van 3 nm (spectrale resolutie). De beeldpixels van de NIR camera bestaan uit een spectrum van 254 waarden met een spectrale resolutie van 3 nm. De opnames van de camera bestaan daarmee uit een beeldenstack van respectievelijk 192 beelden voor de VNIR en 254 beelden voor de NIR camera. In Figuur 9 staat een voorbeeldweergave van de beeldenstack die ontstaat.

Figuur 9 Voorbeeld van een beeldenstack van een hyperspectrale opname.

Alle spectrale reflectiewaarden van de twee camera's zijn geanalyseerd in het softwarepakket Matlab met classificatie plug-in PerClass. Door de kleine spectrale resolutie (3 nm) en dus grote dataset, zijn de reflectiewaarden uitgemiddeld in een stapgrootte van 5 (overeenkomend met 15 nm spectraal verschil) met een voorwaartse "moving average" filter. De hoeveelheid ruis en de mogelijke verstorende invloed hiervan op het resultaat wordt met dit filter aanzienlijk verminderd. De totale dataset wordt hierdoor ook ingekrimpt, omdat er nu in stappen van 15 nm naar onderscheidende golflengtes wordt gezocht. Dit betekent dat de VNIR meetdata in plaats van 192 verschillende golflengtes wordt teruggebracht naar 38 "uitgemiddelde" golflengtes en de NIR meetdata van 254 naar 50 golflengtes. Voor het uiteindelijke resultaat heeft deze inkrimping geen nadelige gevolgen aangezien naastgelegen reflectiewaarden sterk gecorreleerd zijn.

Allereerst zijn er 50-100 beeldpixels uit elke plantenbak van het gewas geselecteerd om een indruk te krijgen van de spectrale reflectie lopend tussen 400 t/m 1000 nm (VNIR) en 900 t/m 1700 nm (NIR). De reflectiecurve toont aan wat de verschillen in reflectie zijn tussen de gewassen en onkruiden.

Een gebruikelijke aanpak in onderzoek naar plantherkenning op basis van het meten van reflecties is door eerst spectrale metingen te doen dicht bij een blad van een plant. Door een groot aantal van dergelijke metingen te doen, wordt een 'training set' opgebouwd, waar met behulp van statistische analyse (discriminant analysis) een model van de karakteristieke kenmerken gemaakt wordt, ook wel "scheidingsfunctie" genoemd. Een tweede, onafhankelijke set metingen dient vervolgens om het model te testen. Zodoende zijn de beeldpixels geanalyseerd met een Fisher Lineaire Discriminant Analyse (LDA). Deze methode is een vorm van "supervised" classificeren, welke een scheidingsfunctie berekent tussen een aantal bekende beeldklassen. Allereerst is met de "supervised" Fisher LDA een scheidingsfunctie gemaakt om alle plantdelen (een combinatie van zowel onkruiden als gewasdelen) te scheiden van de grond/teeltsubstraat. Dit om ervoor te zorgen dat alleen de plantdelen worden meegenomen in de spectrale analyse voor het onderscheid tussen gewas en onkruid.

Met de Fisher LDA is vervolgens een scheidingsfunctie berekent tussen de gewassen en de onkruiden op basis van een kleine selectie bladpixels die handmatig zijn ingetekend op het beeld ("supervised" classificatie). Vervolgens wordt de scheidingsfunctie getoetst op het gehele "plantbeeld".

Deze toets levert een beeldvullende pixelclassificatie op van de door de LDA geclassificeerde labels. Hierna is visueel bepaald of de classificatie een goed onderscheid levert tussen het gewas en een onkruid door bijvoorbeeld te bepalen of de werkelijke "tarwe" pixels ook worden aangemerkt als "tarwe" door de LDA scheidingsfunctie. Dezelfde visuele beoordeling geldt natuurlijk ook voor de overige gewassen en onkruiden.

Ook is door middel van een 'confusion matrix' de classificatie geëvalueerd. In deze matrix wordt de werkelijke label van een pixel ('True labels') uitgezet tegenover de door de software geschatte label van de spectra ('Decisions'). De LDA scheidingsfunctie kan als 'succesvol' worden aangemerkt, wanneer het overgrote deel van de planten correct wordt geclassificeerd/gelabeld en een hoge nauwkeurigheid heeft in de 'confusion matrix'. Deze nauwkeurigheid wordt als volgt berekend:

		Predicted Class	
		Yes	No
Actual Class	Yes	TP	FN
	No	FP	TN

$$\text{nauwkeurigheid}(\%) = \frac{P + N}{P + N + P + N} \times 100$$

Figuur 10 Confusion matrix en berekening van de nauwkeurigheid.

Als laatste worden uit de scheidingsfunctie de meest onderscheidende golflengtes gekozen, door middel van "discriminant weighting". Dit om te kunnen bepalen welke golflengtes de meeste invloed hebben in de scheidingsfunctie. Dit is noodzakelijk om de hyperspectrale meetdata (bestaande uit 192 en 254 spectrale banden) te reduceren naar een multispectrale set met maximaal 5-10 hoog-onderscheidende golflengtes. Dit kan uiteindelijk leiden tot een toegepaste multispectrale camera, met maximaal 5-10 golflengte-gevoelige banden, die adequaat de gewassen kan onderscheiden van de onkruiden.

3.3 Resultaten lab experimenten

3.3.1 Spectrale reflectiecurves

De gemiddelde spectrale reflectiewaarden van 50-100 willekeurig gekozen plantpixels zijn per meetdag uitgezet in grafieken.

3.3.1.1 Eerste meetdag 10/11/2016

Op de eerste meetdag is er met name in het nabij-infrarode gebied (700-1000 nm) een duidelijk onderscheid tussen de tarwe en de 3 onkruiden (Figuur 11); vogelmuur, zandraket, kweek. Ook zijn er duidelijke verschillen in de reflectie van groen licht (550 nm) en de zogenaamde "red-edge" bij circa 650-670 nm.

Figuur 11 Reflectie gewassen meting 10-11-2016.

In het NIR gebied (900 – 1700 nm, Figuur 12) laat de tarwe een verlaagde reflectie laat zien in vergelijking met de 3 onkruiden.

Figuur 12 Reflectie gewassen NIR meting 10-11-2016.

3.3.1.2 Tweede meetdag 15/11/2016

Op de tweede meetdag zijn er soortgelijke verschillen zichtbaar (Figuur 14). In het nabij-infrarode gebied en de reflectie in het groene gebied (550 nm) zijn er duidelijke verschillen tussen de gewassen rucola en babysla en de onkruiden.

Figuur 13 De Principale Component Analyse toont de maximale variatie in twee nieuwe componenten (PC1 en PC2) tussen de gecombineerde klasse van rucola en babysla (blauwe plusjes) en de gecombineerde klasse van 5 onkruiden (vogelmuur, zandraket, hanenpoot, straatgras en melganzenvoet) (rode plusjes).

Een Principale Componenten Analyse (PCA) is uitgevoerd om de variatie in de dataset samen te vatten en samenhang tussen de twee klassen (klasse met rucola en babysla en klasse met 5 onkruiden) inzichtelijk te maken is gedaan. Met een PCA is het mogelijk om de maximale variatie weer te geven tussen de zogenaamde twee belangrijkste Principale Componenten (PC1 en PC2). Figuur 13 geeft aan dat er een duidelijk spectraal onderscheid te vinden is tussen de klasse "onkruid" en klasse "sla".

De spectrale verschillen tussen tarwe en de onkruiden zijn veel kleiner dan op de eerste meetdag. Dit kan komen doordat de absolute reflectie van tarwe in het nabij-infrarode gebied is gestegen ten aanzien van de eerste meetdag waardoor de verschillen met de onkruiden kleiner wordt.

Figuur 14 Reflectie gewassen meting 15-11-2016.

In het NIR gebied (900 – 1700 nm, Figuur 15) zijn de verschillen tussen de gewassen en de onkruiden minder duidelijk. Opmerkelijk is dat de tarwe een sterk verlaagde reflectie laat zien in vergelijking met de slasoorten en de onkruiden.

Figuur 15 Reflectie gewassen NIR meting 15-11-2016.

3.3.1.3 Derde meetdag 21/11/2016

De reflectieverschillen tussen de slasoorten en onkruid op de derde meetdag zijn in zowel het VNIR als het NIR gebied kleiner (Figuur 16 & Figuur 17). Bij 1400 nm ligt de reflectie van hanenpoot beduidend hoger dan de twee slasoorten en zandraket.

Figuur 16 Reflectie gewassen VNIR meting 21-11-2016.

Figuur 17 Reflectie gewassen NIR meting 21-11-2016.

3.3.1.4 Vierde meetdag 25/11/2016

De reflectie van melganzenvoet op de vierde meetdag is in het VNIR gebied lager en in het NIR gebied hoger dan de slasoorten (Figuur 18 & Figuur 19). Met name in het NIR gebied tussen 1000 en 1300 nm zijn de verschillen duidelijker. In het VNIR gebied ligt de reflectie van melganzenvoet met name in de groene band (550 nm) en in de red-edge (650-670 nm) lager.

Figuur 18 Reflectie gewassen VNIR meting 25-11-2016.

Figuur 19 Reflectie gewassen NIR meting 25-11-2016.

3.3.2 Classificatie VNIR - 400 t/m 1000 nm

3.3.2.1 Classificeren van plantpixels voor het vinden van onderscheidende golflengtes

Met een zogenaamd classifier op alle plantdelen (zowel gewassen als onkruiden) is er een plantfilter gemaakt die van elk beeld de plantpixels selecteert (groene pixels). Met deze classifier kan de achtergrond uit het beeld worden gescheiden (Figuur 20). Als tweede stap wordt er dan een classifier getraind voor een onderscheid tussen gewassen en onkruiden, de verstoring van de achtergrond is hiermee uitgesloten.

Vogelmuur

Zandraket

Hanenpoot

Tarwe

Straatgras

Melganzenvoet

Kweek

Rucola

Landkers

Figuur 20 Classifieer pixels groene plantdelen.

3.3.2.2 Meest onderscheidende golflengtes in het onderscheid tussen gewassen en onkruiden

In Tabel 2 wordt het vergelijkend onderscheid gegeven tussen een gewas en een onkruid. De bijhorende resultaten zijn te vinden in de appendix (Bijlage 1). In dit vergelijk wordt een individuele classifieer getraind en getoetst op het gewas én het onkruid beeld.

Het spectrale onderscheid tussen tarwe en vogelmuur levert bijvoorbeeld een nauwkeurigheid van 91.0% op de eerste meetdag en (10-11-2016) en een nauwkeurigheid van 99.8% op de tweede meetdag (15-11-2016, zie de meettabel op pagina 8). De volledig uitgewerkt resultaten staan in de appendix.

In het geval van twee meetdagen wordt door middel van een rankingsmethode de 5 meest onderscheidende golflengtes gekozen op basis van onderstaande formule:

Tabel 2

Samenvatting van meest onderscheidende golflengtes en nauwkeurigheid.

Gewas	Onkruid	Nauwkeurigheid		5 meest onderscheidende golflengtes		
		Meting 1	Meting 2	Meting 1	Meting 2	Ranking *
Tarwe	Vogelmuur	91.0%	99.8%	675 nm	722 nm	722 nm
				660 nm	738 nm	675 nm
				691 nm	675 nm	660 nm
				707 nm	660 nm	691 nm
				722 nm	598 nm	598 nm
	Zandraket	100.0%	99.5%	660 nm	675 nm	675 nm
				675 nm	644 nm	644 nm
				552 nm	691 nm	660 nm
				644 nm	722 nm	552 nm
				583 nm	738 nm	583 nm
	Hanenpoot	96.8%	-	660 nm	-	660 nm
				707 nm		707 nm
				722 nm		722 nm
				691 nm		691 nm
				598 nm		598 nm
	Straatgras	95.0%	-	644 nm	-	644 nm
				583 nm		583 nm
				675 nm		675 nm
				660 nm		660 nm
				629 nm		629 nm
	Kweek	97.2%	-	660 nm	-	660 nm
				675 nm		675 nm
				722 nm		722 nm
				644 nm		644 nm
				614 nm		614 nm
	Melganzenvoet	99.0%	-	691 nm	-	691 nm
				644 nm		644 nm
				722 nm		722 nm
				675 nm		675 nm
				598 nm		598 nm

Gewas	Onkruid	Nauwkeurigheid		5 meest onderscheidende golflengtes		
		Meting 1	Meting 2	Meting 1	Meting 2	Ranking *
Rucola	Vogelmuur	96.4%	-	660 nm	-	660 nm
				675 nm		675 nm
				598 nm		598 nm
				707 nm		707 nm
				722 nm		722 nm
	Zandraket	88.0%	91.1%	598 nm 675 nm 722 nm 707 nm 583 nm	660 nm 675 nm 644 nm 552 nm 598 nm	675 nm 598 nm 552 nm 644 nm 660 nm
	Hanenpoot	96.5%	99.7%	707 nm 660 nm 598 nm 644 nm 691 nm	629 nm 675 nm 707 nm 552 nm 614 nm	707 nm 675 nm 629 nm 660 nm 598 nm
	Straatgras	96.7%	-	675 nm 644 nm 660 nm 707 nm 691 nm	-	675 nm 644 nm 660 nm 707 nm 691 nm
	Melganzenvoet	83.5%	96.7%	614 nm 644 nm 849 nm 675 nm 881 nm	675 nm 660 nm 707 nm 644 nm 629 nm	675 nm 644 nm 614 nm 660 nm 707 nm
Landkers	Vogelmuur	99.7%	-	675 nm 769 nm 598 nm 629 nm 738 nm	-	675 nm 769 nm 598 nm 629 nm 738 nm
				675 nm 644 nm 629 nm 691 nm 881 nm	660 nm 722 nm 552 nm 707 nm 583 nm	675 nm 644 nm 660 nm 552 nm 629 nm
				691 nm 660 nm 707 nm 644 nm 629 nm	691 nm 660 nm 707 nm 552 nm 722 nm	691 nm 660 nm 707 nm 675 nm 722 nm
				691 nm 722 nm 614 nm 754 nm 675 nm	-	691 nm 722 nm 614 nm 754 nm 675 nm
				675 nm 644 nm 660 nm 769 nm 629 nm	675 nm 660 nm 644 nm 738 nm 785 nm	675 nm 660 nm 644 nm 769 nm 629 nm
	Straatgras	80.0%	-			
	Melganzenvoet	97.2%	96.5%			

3.3.2.3 Algemene scheidingsfunctie tussen een gewas en alle onkruiden samen geclusterd

De resultaten uit de vorige paragraaf geven het spectrale onderscheid tussen een gewas en één onkruid (bijv. tarwe versus vogelmuur). Voor een uiteindelijke praktische toepassing is het interessant om na te gaan of de spectrale reflectie van een gewas significant afwijkt van een combinatie van verschillende onkruiden. Onderstaande paragrafen geven dit onderscheid. Er is in één LDA-scheidingsfunctie gemaakt per vergelijking, dus in totaal 3 vergelijkingen (en 3 scheidingsfuncties):

1. Spectrale verschillen tussen tarwe en 6 onkruiden.
2. Spectrale verschillen tussen rucola en 5 onkruiden.
3. Spectrale verschillen tussen landkers en 5 onkruiden.

3.3.2.4 Tarwe versus alle onkruiden

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, kweek, melganzenvoet). Uit onderstaande figuren (Figuur 21) blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen tarwe en alle onkruiden, met een nauwkeurigheid van 96.0% op deze 7 beelden, zie Tabel 3 voor de confusion matrix. De classifier maakt met name op het straatgras en het kweek beeld de meeste fouten. Ook op het tarwe beeld worden een aantal foute pixels aangemerkt (ipv tarwe klasse krijgen deze pixels een onkruid classificatie).

Tarwe

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Kweek

Melganzenvoet

Figuur 21 Beeld onkruiden en gewassen na scheidingsfunctie op tarwe.

De onderscheidende golflengtes “discriminant weights” tussen tarwe en alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, kweek, melganzenvoet) staan in Figuur 22. Een hoge waarde geeft aan dat de golflengte een groot onderscheidend vermogen heeft. In Tabel 4 staan de 10 meest onderscheidende golflengtes met bijbehorend gewicht.

Figuur 22 Onderscheidende golflengte tussen tarwe en onkruiden.

Tabel 3

Confusion matrix van de classifier tussen tarwe en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Wheat	Weed	Sum
True labels	Wheat	8582	1145	9727
	Weed	4053	116038	120091
Sum		12635	117183	96.0%

Tabel 4

De 10 meest onderscheidende golflengtes tussen tarwe en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
675	0.1968
614	0.1161
660	0.0823
722	0.0535
754	0.0515
598	0.0490
801	0.0441
567	0.0436
537	0.0405
629	0.0345

3.3.2.5 Rucola versus alle onkruiden

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet). Uit onderstaande figuren (Figuur 23) blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen rucola en alle onkruiden, met een nauwkeurigheid van 94.7% op deze 6 beelden, zie Tabel 5 voor de confusion matrix. De classifier maakt met name op het zandraket en het straatgras beeld de meeste fouten. Op het rucola beeld worden met name aan de bladranden de meeste foute pixels aangemerkt (i.p.v. rucola klasse krijgen deze pixels een onkruid classificatie).

Rucola

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Melganzenvoet

Figuur 23 Beeld onkruiden en gewassen na scheidingsfunctie op rucola.

Tabel 5

Confusion matrix van de classifier tussen rucola en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Weed	Sum
True labels	Rucola	14782	3798	18580
	Weed	1314	76168	77482
Sum		16096	79966	94.7%

De onderscheidende golflengtes “discriminant weights” tussen rucola en alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet) staan in Figuur 24. Een hoge waarde geeft aan dat de golflengte een groot onderscheidend vermogen heeft. In Tabel 6 staan de 10 meest onderscheidende golflengtes met bijbehorend gewicht.

Figuur 24 Onderscheidende golflengte tussen rucola en onkruiden.

Tabel 6

De 10 meest onderscheidende golflengtes tussen rucola en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
675	0.1617
629	0.1227
660	0.1217
598	0.0642
707	0.0535
614	0.0460
691	0.0441
865	0.0368
769	0.0355
722	0.0341

3.3.2.6 Landkers versus alle onkruiden

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet). Uit onderstaande figuren (Figuur 25) blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen landkers en alle onkruiden, met een nauwkeurigheid van 98.9% op deze 6 beelden, zie Tabel 7 voor de confusion matrix. De classifier maakt alleen op het straatgras beeld significante fouten.

Landkers

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Melganzenvoet

Figuur 25 Beeld onkruiden en gewassen na scheidingsfunctie op landkers.

Tabel 7

Confusion matrix van de classifier tussen landkers en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Land cress	Weed	Sum
True labels	Land cress	12048	544	12592
	Weed	447	77035	77482
Sum		12495	77579	98.9%

De onderscheidende golflengtes "discriminant weights" tussen landkers en alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet) staan in Figuur 24 en 26. Een hoge waarde geeft aan dat de golflengte een groot onderscheidend vermogen heeft. In Tabel 6, 8 en 4 staan de 10 meest onderscheidende golflengtes met bijbehorend gewicht.

Figuur 26 Onderscheidende golflengte tussen landkers en onkruiden.

Tabel 8

De 10 meest onderscheidende golflengtes tussen landkers en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
675	0.1571
769	0.1107
629	0.0772
644	0.0715
691	0.0712
738	0.0595
881	0.0562
722	0.0544
754	0.0467
865	0.0426

3.3.2.7 Scheidingsfunctie tussen een gewas en alle onkruiden gereduceerd naar de meest onderscheidende golflengte

De resultaten uit de vorige paragraaf zijn hoopgevend als het gaat om het vinden van een algemeen spectraal onderscheid tussen een gewas en een combinatie van onkruiden. De bijhorende scheidingsfuncties zijn gebaseerd op een hyperspectraal beeld van 38 verschillende golflengtes. Voor een praktische toepassing is een camera met 38 spectrale banden echter vaak te duur en zoals blijkt uit de vorige paragraaf totaal overbodig in het vinden van een spectraal onderscheid tussen een gewas en een combinatie van onkruiden. Dit komt omdat slechts een beperkt aantal spectrale banden voor het onderscheid zorgen tussen een gewas en de onkruiden.

In de volgende paragrafen wordt het hyperspectrale beeld, bestaande uit 38 banden, gereduceerd naar een combinatie van hoog onderscheidende spectrale banden (tussen 5 en 10 banden) gebaseerd op de resultaten van de vorige paragraaf. Een nieuwe LDA classifier wordt vervolgens gemaakt op het gereduceerde (multi) spectrale beeld. Hierdoor is het mogelijk om te zien hoe goed de classifier zal werken op een combinatie van alleen hoog onderscheidende golflengtes. We maken zodoende een "simulatie" van een multispectrale camera met bijhorende classifier welke in praktijk gebruikt kan worden.

3.3.2.8 Tarwe versus alle onkruiden

Er is een Fisher LDA-scheidingsfunctie gemaakt op een gereduceerd multispectraal beeld. In plaats van 32 spectrale banden zijn alle beelden teruggebracht naar de 9 meest onderscheidende spectrale banden (zie paragraaf 3.2.3.1). Deze 9 banden bleken de meeste impact te hebben in het onderscheid tussen tarwe en alle onkruiden: 675, 614, 660, 722, 754, 598, 801, 567, 537 nm. Ondanks het inkrimpen van het hyperspectrale beeld wordt er nog een nauwkeurigheid van 94.2% gehaald. Onderstaande beeldclassificaties (Figuur 27) tonen aan dat er een acceptabele classificatie op pixelniveau heerst. Het criterium is dat op het beeld minimaal 50% van de pixels juist geïdentificeerd moeten zijn, zie ook de confusion matrix in Tabel 9 en Tabel 10.

Tabel 9

Confusion matrix van de classifier tussen tarwe en onkruiden op 9 spectrale banden.

Confusion matrix		Decision labels		
(pixel based)		Wheat	Weed	Sum
True labels	Wheat	8096	1105	9201
	Weed*	6375*	114421*	120796*
Sum		14471	115526	94.2%

* Deze data is afkomstig van een sommatie van alle beelden, zie data hieronder

Tabel 10

Confusion matrix van de classificatie tussen tarwe en onkruiden, gespecificeerd per onkruid.

		Decision labels		
		Wheat	Weed	Sum
True labels	Vogelmuur	239	65922	66161
	Zandraket	329	10545	10874
	Hanenpoot	334	533	867
	Straatgras	209	421	630
	Kweek	4969	35286	40255
	Melganzenvoet	295	1714	2009
	Sum	6375	114421	120796

Tarwe

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Kweek

Melganzenvoet

Figuur 27 Beeld onkruiden na scheiding van tarwe op 9 banden.

3.3.2.9 Rucola versus alle onkruiden

Deze 9 banden bleken de meeste impact te hebben in het onderscheid tussen rucola en alle onkruiden: 675, 629, 660, 598, 707, 614, 691, 865, 769 nm. Het inkrimpen van het hyperspectrale beeld naar deze 9 banden levert nog steeds een nauwkeurigheid van 94.4%. Onderstaande beeldclassificaties (Figuur 28) tonen aan dat er nog steeds een acceptabele classificatie op pixelniveau heerst, waarbij per beeld minimaal 50% van de pixels juist geïdentificeerd worden, zie ook de confusion matrix in Tabel 11 en Tabel 12.

Rucola

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Melganzenvoet

Figuur 28 Beeld onkruiden na scheiding van rucola op 9 banden.

Tabel 11

Confusion matrix van de classifier tussen rucola en onkruiden op 9 spectrale banden.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Weed	Sum
True labels	Rucola	13241	3280	16521
	Weed	1731	71905	73169
Sum		14972	75185	94.4%

Tabel 12

Confusion matrix van de classificatie tussen rucola en onkruiden, gespecificeerd per onkruid.

		Decision labels		
		Rucola	Weed	Sum
True labels	Vogelmuur	431	61829	62260
	Zandraket	334	7138	7472
	Hanenpoot	63	876	939
	Straatgras	179	448	705
	Melganzenvoet	724	1614	1793
	Sum	1731	71905	73169

3.3.2.10 Landkers versus alle onkruiden

Deze 7 banden bleken de meeste impact te hebben in het onderscheid tussen landkers en alle onkruiden: 675, 769, 629, 644, 691, 738, 881 nm. Het inkrimpen van het hyperspectrale beeld naar deze 7 banden levert nog steeds een nauwkeurigheid van 97.9%. Onderstaande beeldclassificaties (Figuur 29) tonen aan dat er nog steeds een acceptabele classificatie op pixelniveau heerst, waarbij per beeld minimaal 50% van de pixels juist geclassificeerd worden, zie ook de confusion matrix in Tabel 12 en Tabel 13.

Figuur 29 Beeld onkruiden na scheiding van landkers op 7 banden.

Tabel 13

Confusion matrix van de classifier tussen landkers en onkruiden op 9 spectrale banden.

Confusion matrix		Decision labels		
(pixel based)		Land cress	Weed	Sum
True labels	Land cress	11785	852	12637
	Weed	1120	79647	80770
Sum		12905	80499	97.9%

Tabel 14

Confusion matrix van de classificatie tussen landkers en onkruiden, gespecificeerd per onkruid.

		Decision labels		
		Land cress	Weed	Sum
True labels	Vogelmuur	342	66410	66752
	Zandraket	68	9847	9915
	Hanenpoot	193	860	1053
	Straatgras	363	554	917
	Melganzenvoet	154	1976	2133
	Sum	1120	79647	80770

3.3.3 Classificatie NIR – 900 t/m 1700 nm

In deze paragraaf worden de resultaten gepresenteerd van het spectrale onderscheid tussen de gewassen en de onkruiden in het NIR gebied lopend tussen 900 en 1700 nm.

3.3.3.1 Tarwe versus alle onkruiden

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, kweek, melganzenvoet). Uit onderstaande figuren (Figuur 30) blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en alle onkruiden, met een nauwkeurigheid van 98.4% op deze 7 beelden, zie Tabel 15 voor de confusion matrix. Op het tarwe beeld worden een aantal foute pixels aangemerkt, maar over het algemeen is deze scheidingsfunctie erg accuraat in het vinden van een onderscheid tussen tarwe en alle onkruiden op de NIR beelden.

Tarwe

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Kweek

Melganzenvoet

Figuur 30 Beeld onkruiden na scheiding van tarwe.

Tabel 15

Confusion matrix van de classifier tussen tarwe en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Wheat	Weed	Sum
True labels	Wheat	4167	1301	5468
	Weed	447	106549	106996
Sum		4614	107850	98.4%

Figuur 31 Onderscheidende golflengte tussen tarwe en onkruiden.

Tabel 16

De 10 meest onderscheidende golflengtes tussen tarwe en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
1633	0.1224
1584	0.0736
1600	0.0623
1617	0.0476
1502	0.0443
1470	0.0438
1567	0.0417
1091	0.0401
1309	0.0368
1325	0.0356

3.3.3.2 Rucola versus alle onkruiden

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet). Uit onderstaande figuren blijkt dat de scheidingsfunctie een spectraal onderscheid vindt tussen rucola en alle onkruiden, met een nauwkeurigheid van 91.7% op deze 6 beelden, zie Tabel 17 voor de confusion matrix. Op het rucola en het zandraket beeld worden een aantal foute pixels aangemerkt, toch is het onderscheid goed te noemen met relatief weinig fouten.

Rucola

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Melganzenvoet

Figuur 32 Beeld onkruiden na scheiding van rucola.

Tabel 17

Confusion matrix van de classifier tussen rucola en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Weed	Sum
True labels	Rucola	8399	4607	13006
	Weed	120	44168	44288
Sum		8519	48775	91.7%

Figuur 33 Onderscheidende golflengte tussen rucola en onkruiden.

Tabel 18

De 10 meest onderscheidende golflengtes tussen rucola en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
1633	0.0937
1584	0.0617
1600	0.0561
1325	0.0546
1215	0.0525
1309	0.0491
1373	0.0451
1518	0.0442
1567	0.0353
1184	0.0321

3.3.3.3 Landkers versus alle onkruiden

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA-scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van alle onkruiden (vogelmuur, zandraket, hanenpoot, straatgras, melganzenvoet). Uit onderstaande figuren (Figuur 34) blijkt dat de scheidingsfunctie met name op het landkers beeld een zeer slecht spectraal onderscheid vindt tussen landkers en alle onkruiden. 85% van het landkers beeld wordt fout geclassificeerd als onkruid. De nauwkeurigheid op deze 6 beelden is 83.7%, zie Tabel 19 voor de confusion matrix. De classifier maakt op zowel het zandraket als melganzenvoet beeld ook nogal wat fouten. Er kan geconcludeerd worden dat op het NIR beeld een minder duidelijk spectraal onderscheid heerst tussen landkers en alle onkruiden in vergelijking met het VNIR beeld (zie paragraaf 3.2.4.3).

Landkers

Vogelmuur

Zandraket

Hanenpoot

Straatgras

Melganzenvoet

Figuur 34 Beeld onkruiden na scheiding van landkers.

Tabel 19

Confusion matrix van de classifier tussen landkers en onkruiden.

Confusion matrix		Decision labels		
(pixel based)		Land cress	Weed	Sum
True labels	Land cress	1413	8093	9506
	Weed	683	43605	44288
Sum		2096	51698	83.7%

Figuur 35 Onderscheidende golflengte tussen landkers en onkruiden.

Tabel 20

De 10 meest onderscheidende golflengtes tussen landkers en onkruiden.

Wavelengths [nm]	Discriminative weights [-]
1617	0.0864
1373	0.0659
1470	0.0612
1309	0.0572
1153	0.0562
1091	0.0549
1405	0.0497
1357	0.0462
1262	0.0437
1246	0.0387

3.4 Discussie en aanbevelingen lab experimenten

Een discussiepunt ten aanzien van de resultaten uit hoofdstuk 2.3 en de appendix (vanaf p. 58) is dat de spectrale metingen 'slechts' op één plantenbak per gewas/onkruid zijn uitgevoerd. Er bestaat hierdoor een risico dat biologische- en/of groei gerelateerde omstandigheden uit de kweekkas een invloed hebben op het proefresultaat en de gevonden golflengtes. Dit leidt eerlijkheidshalve tot een broos statistisch verantwoord resultaat.

Daarom moeten de gevonden onderscheidende golflengtes als "indicatief" beschouwd worden. Het is aan te raden om een soortgelijk experiment te herhalen in een groter praktijkperceel bestaande uit de betreffende gewassen en onkruiden met een grotere biologische en teelt gerelateerde variëteit. Deze metingen zullen gedurende het gehele teeltseizoen op meerdere momenten moeten worden uitgevoerd, zodat verschillende groeistadia worden meegenomen in een algemene scheidingsfunctie.

3.5 Conclusies lab experimenten

Dit inventariserende onderzoek is opgezet om uit te zoeken of er spectrale reflectieverschillen heersen tussen een gewas en een onkruid. Wanneer dit het geval is, is het mogelijk om met een spectrale camera gewassen te onderscheiden van onkruiden, waarop dan eventueel actie ondernomen kan worden.

In dit onderzoek is getracht reflectieverschillen te vinden tussen de gewassen tarwe, rucola en landkers en een zestal onkruiden, namelijk vogelmuur, zandraket, hanenpoot, straatgras, kweek en melganzenvoet. Het onderzoek is uitgevoerd met twee hyperspectrale camera's:

- VNIR camera lopend tussen 400 en 1000 nm (spectrale resolutie 3 nm).
- NIR camera lopend tussen 900 en 1700 nm (spectrale resolutie 3 nm).

Met de kanttekening dat de resultaten uit hoofdstuk 2.3 als "indicatief" moeten worden beschouwd, blijkt dat het VNIR gebied een duidelijker onderscheid levert tussen een gewas en een onkruid dan het NIR gebied. Met name het onderscheid tussen landkers en de 6 onkruiden is bij NIR erg slecht te noemen.

Zodoende is door middel van verschillende Fisher LDA classificatietechnieken het spectrale onderscheid tussen een gewas en alle onkruiden stapsgewijs teruggebracht naar een beperkt aantal hoog onderscheidende spectrale banden. Dit is enkel gedaan op de VNIR beelden, omdat deze een sterker onderscheid leveren. De volgende spectrale banden zijn interessant voor een uiteindelijke multispectrale camera voor het herkennen van onkruiden in een gewas (gesorteerd op aflopende importantie):

- 9 onderscheidende golflengtes voor het verschil tussen **tarwe** en alle **6 onkruiden**:
 - 675 nm.
 - 614 nm.
 - 660 nm.
 - 722 nm.
 - 754 nm.
 - 598 nm.
 - 801 nm.
 - 567 nm.
 - 537 nm.

- 9 onderscheidende golflengtes voor het verschil tussen **rucola** en **5 onkruiden** (m.u.v. kweek):
 - 675 nm.
 - 629 nm.
 - 660 nm.
 - 598 nm.
 - 707 nm.
 - 614 nm.
 - 691 nm.
 - 865 nm.
 - 769 nm.
- 7 onderscheidende golflengtes voor het verschil tussen **landkers** en **5 onkruiden** (m.u.v. kweek):
 - 675 nm.
 - 769 nm.
 - 629 nm.
 - 644 nm.
 - 691 nm.
 - 738 nm.
 - 881 nm.

Gezien de beperkte dataset (slechts 1 kweekbak per teeltobject), bevelen wij een uitgebreidere praktijkproef aan om deze hoopgevende resultaten onder praktijkomstandigheden te valideren. Ondanks dat de resultaten als indicatief moeten worden beschouwd, zijn er wel interessante trends zichtbaar, met name in de reflectie in het chlorofyl gebied (650 – 670 nm). Ook de reflectie van golflengtes in het groene gebied (rond 550 nm), red-edge (700 nm) en nabij-infrarood (800 nm) tonen in minder mate een onderscheidend effect tussen de onderzochte gewassen en onkruiden.

Deze specifieke golflengtegebieden werden in het literatuuronderzoek (hoofdstuk 1) ook als interessant aangemerkt. Dit in combinatie met bovenstaande indicatieve resultaten tonen aan dat er multispectrale reflectieverschillen heersen tussen de gekozen gewassen en onkruiden in deze dataset.

3.6 Materialen en methoden veldexperimenten

De veld metingen zijn in augustus en september 2017 uitgevoerd op het bedrijf Green Specialties (<http://www.greenspecialties.nl/>) van A. van de Einden in Lierop. Dit bedrijf is gespecialiseerd in bladgroenten die het jaar rond worden geteeld. De verschillende sla soorten worden op bedden geteeld (1,8 m breed, in 24 rijen) die in een betrekkelijk korte periode een gesloten gewas geeft. Ongeveer 4 weken na het zaaien wordt de sla mechanisch geoogst met behulp van een lintzaag. De teler zoekt momenteel naar innovatieve en technische mogelijkheden om het bedrijf geheel biologisch te maken. Voor niet-chemische onkruidbeheersing ziet de teler veel in een selectieve wiedzmachine die de onkruiden tussen de sla, ongeacht de positie, verwijdert op basis van camerabeelden.

Met inachtneming van de resultaten van de lab experimenten, rijst de vraag of het mogelijk is om met hyperspectrale camerabeelden en beeldanalyse (groene) onkruiden in een groen slagewas te detecteren. In overleg met Steketee zijn de functionele eisen bepaald waaraan deze detectie minimaal moet voldoen. De streefwaarden zijn bepaald op basis van de huidige kosten aan handmatig onkruid wieden en wat teler belangrijk acht waaraan een nieuwe machine moet voldoen. Uit gesprekken bleek dat het sparen van groene sla planten belangrijker wordt geacht dan het mechanisch wieden van alle onkruiden. Zodoende zijn de volgende minimale streefwaarden bepaald:

- Nauwkeurigheid, accuracy – **90 %**
Percentage van een juiste classificatie (voor beide klassen) over de totale set.
- Sensitivity, true positive rate - **95 %**
Percentage werkelijke groene sla planten die ook als groene sla worden geclassificeerd door de beeldanalyse.

- Specificity, true negative rate - **80 %**

Percentage werkelijke onkruid planten die ook als onkruid worden geclassificeerd door de beeldanalyse.

- Precision - **95 %**

In het geval de beeldanalyse een classificatie uitgeeft voor groene sla, in hoeveel procent van de gevallen moet dat minimaal overeenkomen met een werkelijke groene sla plant

- Negative predictive value - **80 %**

In het geval de beeldanalyse een classificatie uitgeeft voor onkruid, in hoeveel procent van de gevallen moet dat minimaal overeenkomen met een werkelijke onkruid plant

Om de onderzoeksvraag te kunnen beantwoorden, zijn twee veldexperimenten uitgevoerd met een mobiele opstelling. Met deze opstelling zijn hyperspectrale beelden opgenomen van sla en onkruiden bij de teler in Lierop.

Figuur 36 Specim yperspectrale FX-10 line-scan camera welke gebruikt is in de veldexperimenten.

Een schematische weergave van de camera en belichtingsopstelling in de bak staat weergegeven in Figuur 37. In de bak zijn twee rijen met halogeenlampen gemonteerd, een rij met 12 lampen voor de camera en een rij met 13 lampen achter de camera. De rijen met lampen zijn versprongen van elkaar gemonteerd om een egaal lichtbeeld op het gewas te creëren. De halogeenlampen zijn 12 V 14W halogeenspots met een openingshoek van 10° (Osram DECOSTAR 51 PRO). De Specim FX10 camera was ingesteld op een sluitertijd van 30ms en een framerate van 32 Hz. Er is een spectrale binning van 2 toegepast en geen spatiele binning. Door de rijsnelheid van 160m/u en de framerate van 32Hz zijn de beelden opgenomen met een spatiele resolutie van 1.4mm/pixel. Om een volledig teeltbed op te kunnen nemen, werd met de mobiele cameraopstelling heen en weer gereden. Bij het begin en het eind van de strook waar de opnames werden gemaakt was rood-wit afzetlint aangebracht zodat het begin en eind van de rij ook zichtbaar werd in de beelden.

Figuur 37 Schematische weergave van camera en belichting in de meetbak.

Figuur 38 Mobiele hyperspectraal cameraopstelling bezig met een meting in het veld.

Eerst werden twee gangen in rode sla (Lola Rossa) gereden over 10 m lengte en daarna twee gangen in groene snijsla (Tango) over 5 m lengte. De rijsnelheid van de trekker was ingesteld op 160 m/h (4,4 cm/s). In de rode sla stond veel onkruid, in de groene sla stond minder onkruid en daarom werd besloten om voor de meting onkruid uit naastliggende bedden over te planten in de groene sla, om beide plant-objecten met 1 werkgang van de meetopstelling te kunnen opnemen (Figuur 39).

Figuur 39 In de rode sla stond veel onkruid, terwijl in de groene sla onkruiden getransplanteerd moesten worden uit naastgelegen rijen en paden.

De meest voorkomende onkruiden op het perceel waren kleine brandnetel, knopkruid en vogelmuur (Figuur 40).

Figuur 40 Foto van de meest voorkomende onkruiden op het perceel; brandnetel, knopkruid en vogelmuur.

Verder werd nog kamille, straatgras, klein kruiskruid, ganzerveet, akkermelkdistel, wikke en ooievaarsbek aangetroffen. Op het eind van het meetbed in de groene sla is ook een kweekbak met onkruiden ingegraven (in Wageningen opgekweekt), ter ondersteuning van het leeralgoritme (Figuur 41). Deze kweekbak is op dezelfde manier met de meetopstelling gescand.

Onkruidsoort - nr							
1	4	5	6		9	10	11
	4	5	6	7	9	10	11
2	4	5	6		9	10	11
	4	5	6	8	9	10	11
3	4	5	6	8	9	10	11

Figuur 41 Ingegraven tablet met opgekweekte onkruiden.

Tabel 21

Naamgeving opgekweekte onkruiden.

nr	Onkruidsoort in tablet	
1	Zwarte nachtschade	Solanum nigrum
2	Grote weegbree	Plantago major
3	Paarse dovenetel	Lamium purpureum
4	Vogelmuur	Stellaria media
5	Kamille	Matricaria chamomilla
6	Klein kruiskruid	Senecia vulgaris
7	Perzikkruid	Polygonum persicaria
8	Herderstasje	Capsella bursa-pastoris
9	Melganzerveet	Chenopodium album
10	Hanenpoot	Echinochloa crus-galli
11	Knopkruid	Galinsoga parviflora

Van alle planten in het open veld is het reflectiespectrum beeldvormend gemeten tussen 400 en 1000 nm met de Specim FX10 camera op twee verschillende meetdagen (30 augustus en 7 september 2017). Het spectrumgebied van de FX10 bevat het zichtbare licht (400 tot 700 nm) en het nabij-infrarode licht (700 tot 1000 nm) welke buiten de menselijke perceptie valt. Elke beeldpixel van de FX10 camera bestaat uit een spectrum van 224 waarden met een golflengteverschil tussen opeenvolgende waarden van 2.7 nm (spectrale resolutie). De opnames van de FX10 camera bestaan daarmee uit een beeldenstack van respectievelijk 224 beelden met reflectiewaarden (refereer naar Figuur 9). Voordat begonnen kon worden met de beeldanalyse, zijn alle hyperspectrale beelden genormaliseerd met de zwart- en witreferentie van de camera, om te corrigeren voor verschillen in belichting.

Om de variatie in de dataset samen te vatten en samenhang tussen de twee klassen (groene sla en onkruid) inzichtelijk te maken is een Principale Componenten Analyse (PCA) gedaan. Met een PCA is het mogelijk om de maximale variatie weer te geven tussen de zogenaamde twee belangrijkste Principale Componenten (PC1 en PC2). Een PCA kan ondersteunen in de keuze voor een classifier en biedt ook mogelijkheden om een dataset terug te brengen naar de meest belangrijke Principale Componenten om zo de rekentijd te verminderen.

Na de PCA is met beeldanalyse een classifier gemaakt van al het plantmateriaal (zowel sla als onkruiden) door middel van een Fisher Lineaire Discriminant Analyse (LDA). Met deze classifier kan de achtergrond uit het beeld worden gescheiden. Vervolgens is er een classifier getraind voor een onderscheid tussen gewassen en onkruiden, waarbij de achtergrond is weggefilterd door de eerste classifier.

"Machine learning" vision software is ontwikkeld met behulp van het softwarepakket MVTec Halcon (v13). Er is gekozen voor een neurale netwerk leeralgoritme genaamd "multi-layer perceptron" (MLP). Een MLP neurale netwerk maakt niet-lineaire classificatie mogelijk. Bij lineaire classificatie wordt de populatie gescheiden door een lijn (in geval van twee kenmerken), een vlak (drie kenmerken) of een hypervlak (meer dan drie kenmerken). Bij niet-lineaire classificatie kan de informatie gescheiden worden door ingewikkeldere vormen, zoals ellipsen, cirkels of grillige vormen. Dit maakt een preciezere classificatie mogelijk.

Een neurale netwerk wordt opgebouwd uit 3 lagen (Figuur 42); een input laag (de beeldinformatie), een tussenlaag met zeer uitgebreide onderlinge connecties en een output laag (de beslissing). Doordat de connecties in de tussenlaag niet standaard dezelfde blijven, maar kunnen worden verzwakt, versterkt, aangemaakt of verbroken, kan dit kunstmatig neurale netwerk zichzelf 'trainen'. Helaas is een neurale netwerk niet in staat om de gegeven uitvoer (de classificatie) te verklaren, omdat het werkt via een Black Box-principe. Dit komt doordat de tussenlaag getraind wordt via meerdere recursieve stappen met ontraceerbare configuraties en gewichtsaanpassingen.

Figuur 42 Neuraal netwerk werkingsprincipe.

Het MLP netwerk is opgebouwd uit 224 features in de input laag, welke overeenkomen met elke spectrale band die door de FX10 camera is gemeten. Als "pre-processing" is gekozen voor een PCA met 44 componenten, om de rekentijd van training te verminderen. De keuze van 44 componenten resulteerde uit een pre-analyse van het MLP netwerk, waarbij aangetoond werd dat 99% van de variatie verklaard kon worden door 44 principale componenten. Er is gekozen voor 300 perceptrons in de tussenlaag, gebaseerd op de grootte van de input laag.

Door de lage onkruiddruk in de groene sla, is ervoor gekozen om het MLP netwerk te trainen op basis van 945365 pixels van onkruiden die in de rode sla stonden, welke met een groene kleur filter ("threshold") verkregen waren. De klasse "groene sla" is getraind met 1014134 pixels afkomstig uit hyperspectrale beelden van groene sla buiten de afzetlinten. Op deze manier kunnen alle beelden binnen de afzetlinten onafhankelijk geëvalueerd worden in de test set. De ratio van onkruid en groene sla pixels in de training, was respectievelijk 48.2% en 51.8%.

Figuur 43 Trainingsdata van de klasse "onkruid" is verkregen door de groene onkruiden met een kleur threshold uit de rode sla te filteren. De groene pixels zijn trainingspixels voor de klasse onkruid, de rode pixels welke overeenkomen met rode sla zijn uitgefilterd.

Om de performance van de MLP classifier te toetsen, zijn alle test beelden voorzien van een waarheidslabel ("ground truth"), waarbij alle pixels in het test beeld een label "groene sla" of "onkruid" krijgen (Figuur 44). Bepaling van de "ground truth" labels is uitgevoerd door onkruidspecialist Jean-Marie Michiels.

Figuur 44 Ground truth labels op pixel-niveau in de test beelden, welke gebruikt worden voor de onafhankelijke evaluatie van de classifier. De groene pixels zijn werkelijke groene sla planten (ras Tango) en de rode pixels zijn werkelijke onkruiden.

De MLP classifier levert een classificatie per beeldpixel (Figuur 45). Omdat een plant-object in een hyperspectraal beeld een cluster is van aan elkaar grenzende beeldpixels (Figuur 46), is een post-processing stap nodig om een classificatie van een object te kunnen leveren. Dit vormt namelijk de input voor een selectieve wiedzmachine, welke volledige onkruiden moet verwijderen.

Figuur 45 De MLP classifier levert een classificatie per beeldpixel. De rode pixels zijn onkruid geclassificeerde pixels en groen betreft de classificatie van groene sla.

Figuur 46 De classificatie in de test set is uitgevoerd op plant-clusters. Dit zijn gebieden van aan elkaar grenzende beeldpixels, zoals aangeven met verschillende kleuren.

Er is gekozen voor "majority voting" als post-processing stap. Hierbij wordt van elk cluster ("connected component") bepaald waar het meerendeel (>50%) van de pixels, na classificatie, uit bestaat (Figuur 47). Een plant-cluster verkregen op de eerste meetdag wordt gekenmerkt als onkruid wanneer meer dan 50% van de pixels de classificatie "onkruid" heeft gekregen. Een "groene sla" cluster ontstaat wanneer meer dan 50% van de pixels de classificatie "groene sla" heeft gekregen. Door de grootte van de plant clusters en de mogelijkheid tot overlap op de twee meetdag is gekozen om de "majority voting" hier te verlagen naar 10% (voor het aanmerken van een onkruid cluster).

Figuur 47 Majority-voting wordt toegepast om een classificatie op plant-niveau te leveren. In dit voorbeeld wordt een cluster aangemerkt als onkruid wanneer minimaal 50% van de pixels binnen het cluster worden geclassificeerd als onkruid.

De totale test set bestond uit hyperspectrale beelden binnen de afzetlinten van de groene sla met daarin onkruiden. Deze beeld data kwam niet voor in de train set om zo de classifier onafhankelijk te toetsen op "niet geziene pixel-data". De testset op de eerste meetdag bestond uit 1348 groene sla plant-clusters (6190013 pixels totaal) en 180 clusters met onkruiden (53780 pixels totaal). Op de tweede meetdag waren dit respectievelijk 342 plant-clusters voor groene sla (10172162 pixels totaal) en 96 clusters voor onkruid (36488 pixels totaal). Door de lage onkruiddruk in de groene sla is de test ratio op de eerste meetdag 88.2% voor groene sla clusters en 11.8% voor onkruid clusters. Omdat de planten op de tweede meetdag elkaar gingen overlappen en dus samengevoegd werden onder minder maar grotere plant-clusters is de ratio respectievelijk 78.1% en 21.9% voor groene sla en onkruid.

De classificatieresultaten zijn samengevat in een "confusion matrix" waarbij per plant-cluster het werkelijke label is vergeleken met de door de beeldanalyse bepaalde classificatie. Hierbij worden de volgende parameters gehanteerd:

- True Positive (TP)
 werkelijkheid: groene sla.
 classificatie beeldanalyse: groene sla.
- True Negative (TN)
 werkelijkheid: onkruid.
 classificatie beeldanalyse: onkruid.
- False Positive (FP)
 werkelijkheid: onkruid.
 classificatie beeldanalyse: groene sla.
- False Negative (FN)
 werkelijkheid: groene sla.
 classificatie beeldanalyse: onkruid.

De volgende performance indicators voor de classifier zijn te herleiden met bovenstaande parameters:

$$\text{sensitivity}(\%) = \frac{P}{P + N} \times 100$$

$$\text{specificity}(\%) = \frac{N}{N + P} \times 100$$

$$\text{precision}(\%) = \frac{P}{P + P} \times 100$$

$$\text{negative_predictive_value}(\%) = \frac{N}{N + N} \times 100$$

$$\text{accuracy}(\%) = \frac{P + N}{P + N + P + N} \times 100$$

3.7 Resultaten veld experimenten

De keuze voor de MLP classifier is mede bepaald op de resultaten van de PCA. In Figuur 48 en Figuur 49 worden de twee belangrijkste principale componenten uit de PCA dimensie-reductie weergegeven. Uit de figuren blijkt dat beide klassen (de onkruid klasse en de groene sla klasse) niet makkelijk te scheiden zijn in twee afzonderlijke puntenwolken, omdat ze als het ware onderdeel van elkaar zijn (dit in tegenstelling tot de lab experimenten, Figuur 13). Het toepassen van een lineaire scheidingsfunctie (zoals Fisher LDA) zal bij deze dataset leiden tot foute classificaties, waarbij onkruid-pixels worden aangemerkt als groene sla en omgekeerd. Daarom is gekozen voor de niet-lineaire MLP classifier.

Figuur 48 De PCA van meetdag 1 toont de maximale variatie in twee nieuwe componenten (PC1 en PC2) tussen de klasse "groene sla" (blauwe plusjes) en de klasse "onkruid" (rode kruisjes).

Figuur 49 De PCA van meetdag 2 tussen de klasse "groene sla" (blauwe plusjes) en de klasse "onkruid" (rode kruisjes).

3.7.1 Resultaten meetdag 1 – MLP classifier

Uit de confusion matrix en bijhorende evaluatie parameters (Tabel 22 en Tabel 23) blijkt dat de classifier een nauwkeurigheid heeft van 83.1% op 1528 plant-clusters. 66.1% van de 180 onkruiden wordt gedetecteerd, terwijl de beslissing "onkruid" door de MLP classifier in 37.7% een terechte bleek. Dit getal is de verhouding van 119 terechte beslissingen op een totaal van 316 onkruid beslissingen. Daarentegen staat een 95% precision score voor de klasse groene sla, wat betekent dat de classifier in 95% van de gevallen een groene sla terecht aanmerkt. 85.4% van de 1348 groene planten wordt gedetecteerd door de classifier.

Wanneer de classificatie-resultaten worden geplot op de hyperspectrale beelden (Figuur 50) valt op het algoritme de middelmatig tot grotere onkruiden beter detecteert dan de kleine onkruiden (zie de blauw gekleurde gebieden).

Tabel 22

Confusion matrix van de MLP classifier op plant-cluster niveau tussen groene sla en onkruid van meetdag 1.

Confusion matrix		Decision labels		
(object based)		Groene sla	Onkruid	Sum
True labels	Groene sla	1151	197	1348
	Onkruid	61	119	180
Sum		1212	316	1528

Tabel 23

Evaluatie parameters van de MLP classifier op plant-cluster niveau van meetdag 1.

Accuracy	83.1%
Sensitivity	85.4%
Specificity	66.1%
Precision	95.0%
Negative predictive value	37.7%

Figuur 50 Enkele voorbeelden van detectie van onkruiden in sla op de eerste meetdag. Correcte classificaties zijn aangegeven met groene pixels ("true positives") en de rode pixels ("true negatives"). De gele pixels zijn werkelijke sla planten geclassificeerd als onkruid en de blauwe pixels vice versa (overige classificaties staan in de bijlage, sectie 2.1).

3.7.2 Resultaten meetdag 2 - MLP classifier

Uit de confusion matrix en bijhorende evaluatie parameters (Tabel 24 en Tabel 25) blijkt dat de classifier op de tweede meetdag een nauwkeurigheid heeft van 80.1% op 342 plant-clusters. 37.5% van de 96 onkruiden wordt gedetecteerd, terwijl de beslissing "onkruid" door de MLP classifier in 57.1% een terechte bleek. Dit getal is de verhouding van 36 terechte beslissingen op een totaal van 63 onkruid beslissingen. De precision score is 84.0% voor de klasse groene sla, wat betekent dat de classifier in 84% van de gevallen een groene sla terecht aanmerkt. 92.1% van de 342 sla-clusters van groene sla wordt gedetecteerd door de classifier.

Wanneer de classificatie-resultaten worden geplott op de hyperspectrale beelden (Figuur 51) valt op het algoritme sommige "gras-soortige" onkruiden aanmerkt als groene sla.

Tabel 24

Confusion matrix van de MLP classifier op plant-cluster niveau tussen groene sla en onkruid van meetdag 2.

Confusion matrix		Decision labels		
(object based)		Groene sla	Onkruid	Sum
True labels	Groene sla	315	27	342
	Onkruid	60	36	96
Sum		375	63	438

Tabel 25

Evaluatie parameters van de MLP classifier op plant-cluster niveau van meetdag 2.

Accuracy	80.1%
Sensitivity	92.1%
Specificity	37.5%
Precision	84.0%
Negative predictive value	57.1%

Figuur 51 enkele voorbeelden van detectie van onkruiden in sla op de tweede meetdag. Correcte classificaties zijn aangegeven met groene pixels ("true positives") en de rode pixels ("true negatives"). De gele pixels zijn werkelijke sla planten geclassificeerd als onkruid en de blauwe pixels vice versa (overige classificaties staan in de bijlage, sectie 2.2).

3.8 Discussie en conclusie veldexperimenten

Er kan geconcludeerd worden dat het mogelijk is om met (hyperspectrale) camerabeelden onkruiden in een groen slagewas te detecteren, echter tonen de resultaten dat de MLP classifier nog niet de gestelde streefwaarden haalt op deze dataset.

De nauwkeurigheid, een maat voor de ratio van een juiste classificatie op de hele dataset, ligt op beide meetdagen respectievelijk 6.9% en 9.9% onder de streefwaarde van 90%. Alhoewel de classifier een betere performance heeft op de groene sla klasse in vergelijking met de onkruid klasse, wordt de streefwaarde precision slechts eenmaal gehaald (op de eerste meetdag). Op de tweede meetdag ligt de precision 11.0% onder de streefwaarde, terwijl de sensitivity respectievelijk 9.6% en 2.9% onder de streefwaarde ligt. Het algoritme laat de laagste classificatie performance zien op de onkruid clusters die respectievelijk 13.9% en 42.5% onder de 80% streefwaarde liggen voor de eerste en tweede meetdag (specificity). Negative predictive value ligt 42.3% en 22.9% onder streefwaarde. De classifier mist vooral kleine onkruid clusters en gras-soortige onkruiden (aangemerkt als groene sla).

Doordat het algoritme is getest in een gewas met overlappende planten (met name op de tweede meetdag) zijn door het plant-clustering algoritme minder maar grotere plant-clusters aan de classifier aangeboden. Kleine plant-clusters die gemist worden door het algoritme wegen in de classificatie performance even zwaar mee als grote juist geïdentificeerde plant-clusters. Wanneer de beeldanalyse wordt geëvalueerd op pixel-niveau is het de verwachting dat de classificatie accurater wordt en een minder groot negatief verschil levert ten aanzien van de gestelde streefwaarden (refereer naar Figuur 50, Figuur 51 en bijlage 2.1 en 2.2).

4 Conclusies en discussie

Wanneer de resultaten uit 2016 vergeleken worden met de data-analyse van 2017, blijkt dat de MLP classifieer een lagere performance heeft bij het detecteren van onkruiden in het open veld. Door meer variatie in de omstandigheden was een lagere performance in het open veld t.o.v. lab metingen ook te verwachten. Ook tonen de Principale Component Analyses een lagere variatie tussen de sla en onkruid klasse in de hyperspectrale beelddata van 2017. Dit in tegenstelling tot de data van 2016, waarbij er meer variatie in de hyperspectrale beelddata tussen de twee klassen te vinden was. Dit heeft mogelijk geleid tot een betere (lineaire) classifieer in 2016 met hogere classificatieresultaten.

In 2017 is een andere camera gebruikt voor de veldmetingen dan bij de 2016 proef, wat het lastig maakt om de data en de classifieer 1-op-1 te kunnen vergelijken. Om het effect van het gebruik van verschillende camera's (en bijhorende hardware zoals belichting) op het proefresultaat uit te kunnen sluiten wordt een vergelijkingsonderzoek aanbevolen waarbij met beide camera's kweekbakken met zowel sla als onkruid doorgemeten worden. Vervolgens kan met een PCA gecontroleerd worden of de variatieverschillen in hyperspectrale data tussen beide klassen vergelijkbaar is. Mogelijk zelfs uitgebreid met het trainen van een nieuwe classifieer om de beelddata te classificeren.

Literatuur

- Bradley, B.A., 2014.
Remote detection of invasive plants: A review of spectral, textural and phenological approaches. *Biological Invasions* 16 (7), 1411-1425.
- Carter G.A. (1991),
Primary and secondary effects of water content on the spectral reflectance of leaves, *American Journal of Botany*, 78(7):916-924.
- De Castro, A.I., Jurado-Expósito, M., Peña-Barragán, J.M., López-Granados, F., 2012.
Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. *Precision Agriculture* 13 (3), 302-321.
- De Castro, A.I., López-Granados, F., Jurado-Expósito, M., 2013.
Broad-scale cruciferous weed patch classification in winter wheat using quickbird imagery for in-season site-specific control. *Precision Agriculture* 14 (4), 392-413.
- Everard, C.D., Kim, M.S., Lee, H., 2014.
A comparison of hyperspectral reflectance and fluorescence imaging techniques for detection of contaminants on spinach leaves. *Journal of Food Engineering* 143, 139-145.
- Feyaerts, F., Van Gool, L., 2001.
Multi-spectral vision system for weed detection. *Pattern Recognition Letters* 22 (6), 667-674.
- Gao, H., Mao, H., Zhang, X., Year.
Inspection of lettuce water stress based on multi-sensor information fusion technology. In: *Proceedings of the International Conference on Computer and Computing Technologies in Agriculture*, pp. 53-60.
- Gómez-Casero, M.T., Castillejo-González, I., García-Ferrer, A., Peña-Barragán, J.M., Jurado-Expósito, M., García-Torres, L., López-Granados, F., 2010.
Spectral discrimination of wild oat and canary grass in wheat fields for less herbicide application. *Agronomy for Sustainable Development* 30 (3), 689-699.
- Hadoux, X., Gorretta, N., Rabatel, G., Year.
Weeds-wheat discrimination using hyperspectral imagery. In: *Proceedings of the CIGR-Ageng 2012, International Conference on Agricultural Engineering*, pp. 6 p.
- Heege, H.J., Thiessen, E., 2013.
Sensing of crop properties. *Precision in crop farming*. Springer, pp. 103-141.
- Herrmann, I., Shapira, U., Kinast, S., Karnieli, A., Bonfil, D.J., 2013.
Ground-level hyperspectral imagery for detecting weeds in wheat fields. *Precision Agriculture* 14 (6), 637-659.
- Jacquemoud, S., & Ustin, S. L. (2008).
Modeling leaf optical properties. *Photobiological sciences online*. *Environmental Photobiology*. <http://photobiology.info/#Environ>.
- Jones, C.L., Maness, N.O., Stone, M.L., Jayasekara, R., 2007a.
Chlorophyll estimation using multispectral reflectance and height sensing. *Transactions of the ASABE* 50 (5), 1867-1872.
- Jones, C.L., Weckler, P., Maness, N.O., Jayasekara, R., Stone, M., Chrz, D., 2007b.
Remote sensing to estimate chlorophyll concentration in spinach using multi-spectral plant reflectance. *Transactions of the ASABE* 50 (6), 2267-2273.
- Lee, H., Everard, C.D., Kang, S., Cho, B.-K., Chao, K., Chan, D.E., Kim, M.S., 2014.
Multispectral fluorescence imaging for detection of bovine faeces on romaine lettuce and baby spinach leaves. *Biosystems Engineering* 127, 125-134.
- Longchamps, L., Panneton, B., Samson, G., Leroux, G.D., Thériault, R., 2010.
Discrimination of corn, grasses and dicot weeds by their uv-induced fluorescence spectral signature. *Precision Agriculture* 11 (2), 181-197.
- Martinelli, F., Scalenghe, R., Davino, S., Panno, S., Scuderi, G., Ruisi, P., Villa, P., Stroppiana, D., Boschetti, M., Goulart, L.R., 2015.
Advanced methods of plant disease detection. A review. *Agronomy for Sustainable Development* 35 (1), 1-25.

- Mirik, M., Ansley, R.J., Steddom, K., Jones, D.C., Rush, C.M., Michels, G.J., Elliott, N.C., 2013.
Remote distinction of a noxious weed (musk thistle: *Carduus nutans*) using airborne hyperspectral imagery and the support vector machine classifier. *Remote Sensing* 5 (2), 612-630.
- Noble, S., Brown, B.R., Crowe, T.G., 2002.
The use of spectral properties for weed detection and identification – a review. AIC 2002 Meeting CSAE/ SCGR. nSaskatoon, Saskatchewan, .
- Peña, J.M., Torres-Sánchez, J., Serrano-Pérez, A., De Castro, A.I., López-Granados, F., 2015.
Quantifying efficacy and limits of unmanned aerial vehicle (uav) technology for weed seedling detection as affected by sensor resolution. *Sensors* 15 (3), 5609-5626.
- Peteinatos, G.G., Weis, M., Andújar, D., Rueda Ayala, V., Gerhards, R., 2014.
Potential use of ground-based sensor technologies for weed detection. *Pest management science* 70 (2), 190-199.
- Shapira, U., Herrmann, I., Karnieli, A., Bonfil, D.J., 2013.
Field spectroscopy for weed detection in wheat and chickpea fields. *International journal of remote sensing* 34 (17), 6094-6108.
- Singh, A., Ganapathysubramanian, B., Singh, A.K., Sarkar, S., 2016.
Machine learning for high-throughput stress phenotyping in plants. *Trends in plant science* 21 (2), 110-124.
- Slaughter, D.C., Giles, D.K., Fennimore, S.A., Smith, R.F., 2008.
Multispectral machine vision identification of lettuce and weed seedlings for automated weed control. *Weed Technology* 22 (2), 378-384.
- Yang, C.-C., Prasher, S.O., Goel, P., 2004.
Differentiation of crop and weeds by decision-tree analysis of multi-spectral data. *Transactions of the ASAE* 47 (3), 873.
- Zhang, Y., Slaughter, D.C., 2011a.
Hyperspectral species mapping for automatic weed control in tomato under thermal environmental stress. *Computers and Electronics in Agriculture* 77 (1), 95-104.
- Zhang, Y., Slaughter, D.C., 2011b.
Influence of solar irradiance on hyperspectral imaging-based plant recognition for autonomous weed control. *Biosystems Engineering* 110 (3), 330-339.
- Zhang, Y., Staab, E.S., Slaughter, D.C., Giles, D.K., Downey, D., 2012.
Automated weed control in organic row crops using hyperspectral species identification and thermal micro-dosing. *Crop Protection* 41, 96-105.

Bijlage 1 Alle spectrale analyses tussen gewas en onkruid (VNIR) lab experimenten

B1.1 Meetdag 1

Spectrale verschil tussen tarwe en vogelmuur

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de paarse pixels de LDA's geclassificeerde pixels van vogelmuur. Uit onderstaande figuren (Figuur 52, Figuur 53) blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en vogelmuur, met een nauwkeurigheid van 91.0% op deze twee beelden.

Figuur 52 Spectraal verschil tussen tarwe en vogelmuur.

Tabel 26

Confusion matrix scheiding tarwe en vogelmuur.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Vogelmuur	Sum
True labels	Tarwe	1431	8	1439
	Vogelmuur	1659	15501	17160
Sum		3090	15509	91.0%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen tarwe en vogelmuur:

Figuur 53 Verschil spectra tussen tarwe en vogelmuur.

Tabel 27

De 10 meest onderscheidende golflengtes tussen tarwe en vogelmuur.

Wavelengths [nm]	Discriminative weights [-]
675	0.102
660	0.094
691	0.086
707	0.086
722	0.075
754	0.066
598	0.052
785	0.047
849	0.044
769	0.036

Spectrale verschil tussen tarwe en zandraket

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren (Figuur 54, Figuur 55) blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en zandraket, met een nauwkeurigheid van 100.0% op deze twee beelden.

Figuur 54 Spectraal verschil tussen tarwe en zandraket.

Tabel 28

Confusion matrix scheiding tarwe en zandraket.

Confusion matrix		Decision labels		
		Tarwe	Zandraket	Sum
True labels	Tarwe	1438	1	1439
	Zandraket	0	3281	3281
Sum		1438	3282	100.0%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en zandraket:

Figuur 55 Verschil spectra tussen tarwe en zandraket.

Tabel 29

De 10 meest onderscheidende golflengtes tussen tarwe en zandraket.

Wavelengths [nm]	Discriminative weights [-]
660	0.155
675	0.113
552	0.079
644	0.079
583	0.073
707	0.058
506	0.044
522	0.031
801	0.031
598	0.029

Spectrale verschil tussen tarwe en kweek

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de gele pixels de LDA's geclassificeerde pixels van kweek. Uit onderstaande figuren (Figuur 56, Figuur 57) blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen tarwe en kweek, met een nauwkeurigheid van 97.2% op deze twee beelden. Met name op het tarwe beeld wordt ongeveer 50% van de pixels fout geclassificeerd (kweek classificatie i.p.v. tarwe label).

Figuur 56 Spectraal verschil tussen tarwe en kweek.

Tabel 30

Confusion matrix scheiding tarwe en kweek.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Kweek	Sum
True labels	Tarwe	751	688	1439
	Kweek	1186	64318	65504
Sum		1937	65006	97.2%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en kweek:

Figuur 57 Verschil spectra tussen tarwe en kweek.

Tabel 31

De 10 meest onderscheidende golflengtes tussen tarwe en kweek.

Wavelengths [nm]	Discriminative weights [-]
660	0.18
675	0.176
722	0.086
644	0.083
614	0.074
598	0.07
691	0.047
769	0.043
707	0.035
629	0.027

B1.2 Meetdag 2

Spectrale verschil tussen tarwe en vogelmuur

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van vogelmuur. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en vogelmuur, met een nauwkeurigheid van 99.8% op deze twee beelden.

Figuur 58 Spectraal verschil tussen tarwe en vogelmuur.

Tabel 32

Confusion matrix scheiding tarwe en vogelmuur.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Vogelmuur	Sum
True labels	Tarwe	9627	100	9727
	Vogelmuur	55	64792	64847
Sum		9682	64892	99.8%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en vogelmuur:

Figuur 59 Verschil spectra tussen tarwe en vogelmuur.

Tabel 33

De 10 meest onderscheidende golflengtes tussen tarwe en vogelmuur.

Wavelengths [nm]	Discriminative weights [-]
722	0.1333
738	0.0968
675	0.0823
660	0.0780
598	0.0624
644	0.0584
849	0.0547
785	0.0468
691	0.0464
522	0.0421

Spectrale verschil tussen tarwe en zandraket

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de blauwe pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en zandraket, met een nauwkeurigheid van 99.5% op deze twee beelden.

Figuur 60 Spectraal verschil tussen tarwe en zandraket.

Tabel 34

Confusion matrix scheiding tarwe en zandraket.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Zandraket	Sum
True labels	Tarwe	9635	92	9727
	Zandraket	1	9281	9282
Sum		9636	9373	99.5%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en zandraket:

Figuur 61 Verschil spectra tussen tarwe en zandraket.

Tabel 35

De 10 meest onderscheidende golflengtes tussen tarwe en zandraket.

Wavelengths [nm]	Discriminative weights [-]
675	0.1682
644	0.1506
691	0.1193
722	0.0805
738	0.0677
583	0.0520
552	0.0517
707	0.0510
598	0.0339
537	0.0262

Spectrale verschil tussen tarwe en hanenpoot

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van hanenpoot. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en hanenpoot, met een nauwkeurigheid van 96.8% op deze twee beelden.

Figuur 62 Spectraal verschil tussen tarwe en hanenpoot.

Tabel 36

Confusion matrix scheiding tarwe en hanenpoot.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Hanenpoot	Sum
True labels	Tarwe	9426	301	9727
	Hanenpoot	31	771	802
Sum		9457	1072	96.8%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en hanenpoot:

Figuur 63 Verschil spectra tussen tarwe en hanenpoot.

Tabel 37

De 10 meest onderscheidende golflengtes tussen tarwe en hanenpoot.

Wavelengths [nm]	Discriminative weights [-]
660	0.1649
707	0.1201
722	0.0958
691	0.0675
598	0.0649
552	0.0495
644	0.0492
675	0.0461
738	0.0408
754	0.0367

Spectrale verschil tussen tarwe en straatgras

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van straatgras. Uit onderstaande figuren blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen tarwe en straatgras, met een nauwkeurigheid van 95.0% op deze twee beelden. Door de slechte groei van de straatgras zijn er logischerwijs ook minder te trainen beeldpixels wat de kans op foute classificaties doet toenemen en de nauwkeurigheid doet afnemen. Het onderscheid tussen tarwe en straatgras op het straatgras beeld is niet erg accuraat met een score van 66% (479/726).

Figuur 64 Spectraal verschil tussen tarwe en straatgras.

Tabel 38

Confusion matrix scheiding tarwe en straatgras.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Straatgras	Sum
True labels	Tarwe	9451	276	9727
	Straatgras	247	479	726
Sum		9698	755	95.0%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen tarwe en straatgras:

Figuur 65 Verschil spectra tussen tarwe en straatgras.

Tabel 39

De 10 meest onderscheidende golflengtes tussen tarwe en straatgras.

Wavelengths [nm]	Discriminative weights [-]
644	0.1508
583	0.1068
675	0.0881
660	0.0819
629	0.0808
691	0.0673
769	0.0670
707	0.0632
552	0.0457
817	0.0376

Spectrale verschil tussen tarwe en melganzenvoet

De groene pixels geven de tarwe geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van melganzenvoet. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen tarwe en melganzenvoet, met een nauwkeurigheid van 99.0% op deze twee beelden.

Figuur 66 Spectraal verschil tussen tarwe en melganzenvoet.

Tabel 40

Confusion matrix scheiding tarwe en melganzenvoet.

Confusion matrix		Decision labels		
(pixel based)		Tarwe	Melganzenvoet	Sum
True labels	Tarwe	9647	80	9727
	Melganzenvoet	37	1788	1825
Sum		9684	1868	99.0%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen tarwe en melganzenvoet:

Figuur 67 Verschil spectra tussen tarwe en melganzenvoet.

Tabel 41

De 9 meest onderscheidende golflengtes tussen melganzenvoet.

Wavelengths [nm]	Discriminative weights [-]
691	0.1521
644	0.1181
722	0.0854
675	0.0665
598	0.0663
707	0.0640
660	0.0601
552	0.0505
738	0.0363

Spectrale verschil tussen rucola en vogelmuur

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van vogelmuur. Uit onderstaande figuren blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen rucola en vogelmuur, met een nauwkeurigheid van 96.4% op deze twee beelden.

Figuur 68 Spectraal verschil tussen rucola en vogelmuur.

Tabel 42

Confusion matrix scheiding rucola en vogelmuur.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Vogelmuur	Sum
True labels	Rucola	16010	2570	18580
	Vogelmuur	403	64444	64847
Sum		16413	67014	96.4%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en vogelmuur:

Figuur 69 Verschil spectra tussen rucola en vogelmuur.

Tabel 43

De 10 meest onderscheidende golflengtes tussen rucola en vogelmuur.

Wavelengths [nm]	Discriminative weights [-]
660	0.1506
675	0.1396
598	0.0661
707	0.0653
722	0.0651
522	0.0555
817	0.0410
769	0.0357
583	0.0348
865	0.0266

Spectrale verschil tussen rucola en zandraket

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de blauwe pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen rucola en zandraket, met een nauwkeurigheid van 88.0% op deze twee beelden.

Figuur 70 Spectraal verschil tussen rucola en zandraket.

Tabel 44

Confusion matrix scheiding rucola en zandraket.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Zandraket	Sum
True labels	Rucola	15240	3340	18580
	Zandraket	1	9281	9282
Sum		15241	12621	88.0%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en zandraket:

Figuur 71 Verschil spectra tussen rucola en zandraket.

Tabel 45

De 10 meest onderscheidende golflengtes tussen rucola en zandraket.

Wavelengths [nm]	Discriminative weights [-]
598	0.1325
675	0.1123
722	0.0916
707	0.0891
583	0.0754
552	0.0647
849	0.0510
567	0.0466
801	0.0457
644	0.0426

Spectrale verschil tussen rucola en hanenpoot

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van hanenpoot. Uit onderstaande figuren blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen rucola en hanenpoot, met een nauwkeurigheid van 96.5% op deze twee beelden.

Figuur 72 Spectraal verschil tussen rucola en hanenpoot.

Tabel 46

Confusion matrix scheiding rucola en hanenpoot.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Hanenpoot	Sum
True labels	Rucola	17899	681	18580
	Hanenpoot	0	802	802
Sum		17899	1483	96.5%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en hanenpoot:

Figuur 73 Verschil spectra tussen rucola en hanenpoot.

Tabel 47

De 10 meest onderscheidende golflengtes tussen rucola en hanenpoot.

Wavelengths [nm]	Discriminative weights [-]
707	0.1480
660	0.1375
598	0.1023
644	0.0895
691	0.0810
675	0.0643
722	0.0411
583	0.0402
614	0.0388
801	0.0362

Spectrale verschil tussen rucola en straatgras

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van straatgras. Uit onderstaande figuren blijkt dat de scheidingsfunctie een duidelijk spectraal onderscheid vindt tussen rucola en straatgras, met een nauwkeurigheid van 96.7% op deze twee beelden.

Figuur 74 Spectraal verschil tussen rucola en straatgras.

Tabel 48

Confusion matrix scheiding rucola en straatgras.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Straatgras	Sum
True labels	Rucola	17939	641	18580
	Straatgras	3	723	726
Sum		17942	1364	96.7%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en straatgras:

Figuur 75 Verschil spectra tussen rucola en straatgras.

Tabel 49

De 10 meest onderscheidende golflengtes tussen rucola en straatgras.

Wavelengths [nm]	Discriminative weights [-]
675	0.1661
644	0.1192
660	0.1067
707	0.0952
691	0.0851
598	0.0680
583	0.0546
801	0.0446
722	0.0399
769	0.0321

Spectrale verschil tussen rucola en melganzenvoet

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van melganzenvoet. Uit onderstaande figuren blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen rucola en melganzenvoet, met een nauwkeurigheid van 83.5% op deze twee beelden. Met name op het rucola beeld worden veel foute classificaties gegeven (melganzenvoet ipv rucola).

Figuur 76 Spectraal verschil tussen rucola en melganzenvoet.

Tabel 50

Confusion matrix scheiding rucola en melganzenvoet.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Melganzenvoet	Sum
True labels	Rucola	15262	3318	18580
	Melganzenvoet	59	1766	1825
Sum		15321	5084	83.5%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en melganzenvoet:

Figuur 77 Verschil spectra tussen rucola en melganzenvoet.

Tabel 51

De 10 meest onderscheidende golflengtes tussen rucola en melganzenvoet.

Wavelengths [nm]	Discriminative weights [-]
614	0.1485
644	0.1240
849	0.0663
675	0.0654
881	0.0653
865	0.0562
583	0.0533
754	0.0490
801	0.0461
785	0.0435

Spectrale verschil tussen landkers en vogelmuur

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van vogelmuur. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen landkers en vogelmuur, met een nauwkeurigheid van 99.7% op deze twee beelden.

Figuur 78 Spectraal verschil tussen landkers en vogelmuur.

Tabel 52

Confusion matrix scheiding landkers en vogelmuur.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Vogelmuur	Sum
True labels	Landkers	12421	171	12592
	Vogelmuur	63	64784	64847
Sum		12484	64955	99.7%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen landkers en vogelmuur:

Figuur 79 Verschil spectra tussen landkers en vogelmuur.

Tabel 53

De 10 meest onderscheidende golflengtes tussen landkers en vogelmuur.

Wavelengths [nm]	Discriminative weights [-]
675	0.1609
769	0.1112
598	0.0889
629	0.0804
738	0.0684
881	0.0561
567	0.0485
660	0.0475
722	0.0414
785	0.0346

Spectrale verschil tussen landkers en zandraket

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de blauwe pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen landkers en zandraket, met een nauwkeurigheid van 99.7% op deze twee beelden.

Figuur 80 Spectraal verschil tussen landkers en zandraket.

Tabel 54

Confusion matrix scheiding landkers en zandraket.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Zandraket	Sum
True labels	Landkers	12142	450	12592
	Zandraket	3	9279	9282
Sum		12145	9729	97.9%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen landkers en zandraket:

Figuur 81 Verschil spectra tussen landkers en zandraket.

Tabel 55

De 10 meest onderscheidende golflengtes tussen landkers en zandraket.

Wavelengths [nm]	Discriminative weights [-]
675	0.2174
644	0.1016
629	0.0957
691	0.0525
881	0.0502
769	0.0421
522	0.0415
785	0.0395
552	0.0368
738	0.0358

Spectrale verschil tussen landkers en hanenpoot

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van hanenpoot. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen landkers en hanenpoot, met een nauwkeurigheid van 99.7% op deze twee beelden.

Figuur 82 Spectraal verschil tussen landkers en hanenpoot.

Tabel 56

Confusion matrix scheiding landkers en hanenpoot.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Hanenpoot	Sum
True labels	Landkers	12059	533	12592
	Hanenpoot	0	802	802
Sum		12059	1335	96.0%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen landkers en hanenpoot:

Figuur 83 Verschil spectra tussen landkers en hanenpoot.

Tabel 57

De 10 meest onderscheidende golflengtes tussen landkers en hanenpoot.

Wavelengths [nm]	Discriminative weights [-]
691	0.1859
660	0.1520
707	0.1310
644	0.0641
629	0.0517
675	0.0501
722	0.0399
754	0.0361
881	0.0259
785	0.0252

Spectrale verschil tussen landkers en straatgras

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van straatgras. Uit onderstaande figuren blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen landkers en straatgras, met een nauwkeurigheid van 80.0% op deze twee beelden. Met name op het landkers beeld worden veel foute classificaties gegeven (straatgras ipv landkers).

Figuur 84 Spectraal verschil tussen landkers en straatgras.

Tabel 58

Confusion matrix scheiding landkers en straatgras.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Hanenpoot	Sum
True labels	Landkers	9930	2662	12592
	Hanenpoot	1	725	726
Sum		9931	3387	80.0%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen landkers en straatgras:

Figuur 85 Verschil spectra tussen landkers en straatgras.

Tabel 59

De 10 meest onderscheidende golflengtes tussen landkers en straatgras.

Wavelengths [nm]	Discriminative weights [-]
691	0.1672
722	0.0737
614	0.0688
754	0.0633
675	0.0631
644	0.0586
552	0.0549
537	0.0429
629	0.0424
738	0.0391

Spectrale verschil tussen landkers en melganzenvoet

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de magenta pixels de LDA's geclassificeerde pixels van melganzenvoet. Uit onderstaande figuren blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen landkers en melganzenvoet, met een nauwkeurigheid van 97.2% op deze twee beelden.

Figuur 86 Spectraal verschil tussen landkers en melganzenvoet.

Tabel 60

Confusion matrix scheiding landkers en melganzenvoet.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Melganzenvoet	Sum
True labels	Landkers	12209	383	12592
	Melganzenvoet	27	1798	1825
Sum		12236	2181	97.2%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen landkers en melganzenvoet:

Figuur 87 Verschil spectra tussen landkers en melganzenvoet.

Tabel 61

De 10 meest onderscheidende golflengtes tussen landkers en melganzenvoet.

Wavelengths [nm]	Discriminative weights [-]
675	0.1301
644	0.1141
660	0.0968
769	0.0819
629	0.0715
722	0.0667
754	0.0545
881	0.0529
865	0.0451
785	0.0413

B1.3 Meetdag 3

Spectrale verschil tussen rucola en zandraket

De cyan pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren blijkt dat de scheidingsfunctie een groot deel van de rucola en de zandraket juist classificeert, maar dat er bij beide ook nogal wat foute classificaties zijn. De scheidingsfunctie is minder accuraat bij het onderscheid tussen rucola en zandraket, de nauwkeurigheid op deze beelden is 91.1%.

Figuur 88 Spectraal verschil tussen rucola en zandraket.

Tabel 62

Confusion matrix scheiding rucola en zandraket.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Zandraket	Sum
True labels	Rucola	58344	5599	63943
	Zandraket	5697	56618	62315
Sum		64041	62217	91.1%

Deze minder succesvolle scheidingsfunctie levert toch nog een aantal “discriminant weights” op in het onderscheid tussen rucola en zandraket:

Figuur 89 Verschil spectra tussen rucola en zandraket.

Tabel 63

De 10 meest onderscheidende golflengtes tussen rucola en zandraket.

Wavelengths [nm]	Discriminative weights [-]
660	0.1166
675	0.1081
644	0.1003
552	0.0797
598	0.0565
583	0.0551
738	0.0517
722	0.0461
537	0.0440
707	0.0358

Spectrale verschil tussen rucola en hanenpoot

De cyaan pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van hanenpoot. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen rucola en hanenpoot, met een nauwkeurigheid van 99.7% op deze twee beelden.

Figuur 90 Spectraal verschil tussen rucola en hanenpoot.

Tabel 64

Confusion matrix scheiding rucola en hanenpoot.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Hanenpoot	Sum
True labels	Rucola	63871	72	63943
	Hanenpoot	159	5338	5497
Sum		64030	5410	99.7%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en hanenpoot:

Figuur 91 Verschil spectra tussen rucola en hanenpoot.

Spectrale verschil tussen landkers en zandraket

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van zandraket. Uit onderstaande figuren blijkt dat de scheidingsfunctie een groot deel van de landkers en de zandraket juist classificeert, maar dat er bij beide ook nogal wat foute classificaties zijn. De scheidingsfunctie is minder accuraat bij het onderscheid tussen landkers en zandraket, met een nauwkeurigheid van 92.7%.

Figuur 92 Spectraal verschil tussen landkers en zandraket.

Tabel 65

Confusion matrix scheiding landkers en zandraket.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Zandraket	Sum
True labels	Landkers	63871	72	63943
	Zandraket	9461	56328	65789
Sum		73332	56400	92.7%

Deze minder succesvolle scheidingsfunctie levert toch nog een aantal “discriminant weights” op in het onderscheid tussen landkers en zandraket:

Figuur 93 Verschil spectra tussen landkers en zandraket.

Tabel 66

De 10 meest onderscheidende golflengtes tussen landkers en zandraket.

Wavelengths [nm]	Discriminative weights [-]
660	0.1040
722	0.0812
552	0.0810
707	0.0797
583	0.0717
598	0.0554
675	0.0552
537	0.0514
691	0.0511
833	0.0463

Spectrale verschil tussen landkers en hanenpoot

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van hanenpoot. Uit onderstaande figuren blijkt dat de scheidingsfunctie een zeer duidelijk spectraal onderscheid vindt tussen landkers en hanenpoot, met een nauwkeurigheid van 99.7% op deze twee beelden.

Figuur 94 Spectraal verschil tussen landkress en hanenpoot.

Tabel 67

Confusion matrix scheiding landkress en hanenpoot.

Confusion matrix		Decision labels		
(pixel based)		Landkress	Hanenpoot	Sum
True labels	Landkress	65591	198	65789
	Hanenpoot	39	5458	5497
Sum		65630	5656	99.7%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen landkress en hanenpoot:

Figuur 95 Verschil spectra tussen landkress en hanenpoot.

Tabel 68

De 10 meest onderscheidende golflengtes tussen landkers en hanenpoot

Wavelengths [nm]	Discriminative weights [-]
691	0.1634
660	0.1268
707	0.1028
552	0.0715
722	0.0662
675	0.0613
614	0.0607
785	0.0371
769	0.0331
754	0.0327

B1.4 Meetdag 4

Spectrale verschil tussen rucola en melganzenvoet

De groene pixels geven de rucola geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van melganzenvoet. Uit onderstaande figuren blijkt dat de scheidingsfunctie op beide beelden een aantal plantdelen fout classificeert, de nauwkeurigheid was 96.7% op deze twee beelden.

Figuur 96 *Spectraal verschil tussen rucola en melganzenvoet.*

Tabel 69

Confusion matrix scheiding rucola en melganzenvoet.

Confusion matrix		Decision labels		
(pixel based)		Rucola	Melganzenvoet	Sum
True labels	Rucola	122122	3868	125990
	Melganzenvoet	627	8774	9401
Sum		122749	12642	96.7%

De scheidingsfunctie levert de volgende “discriminant weights” op in het onderscheid tussen rucola en melganzenvoet:

Figuur 97 Verschil spectra tussen rucola en melganzenvoet.

Tabel 70

De 10 meest onderscheidende golflengtes tussen rucola en melganzenvoet.

Wavelengths [nm]	Discriminative weights [-]
675	0.1738
660	0.1159
707	0.0975
644	0.0919
629	0.0557
785	0.0518
722	0.0475
583	0.0444
552	0.0402
614	0.0391

Spectrale verschil tussen landkers en melganzenvoet

De groene pixels geven de landkers geclassificeerde pixels weer van de LDA scheidingsfunctie en de rode pixels de LDA's geclassificeerde pixels van melganzenvoet. Uit onderstaande figuren blijkt dat de scheidingsfunctie een minder duidelijk spectraal onderscheid vindt tussen landkers en melganzenvoet, met een nauwkeurigheid van 97.2% op deze twee beelden.

Figuur 98 Spectraal verschil tussen landkers en melganzenvoet.

Tabel 71

Confusion matrix scheiding landkers en melganzenvoet.

Confusion matrix		Decision labels		
(pixel based)		Landkers	Melganzenvoet	Sum
True labels	Landkers	128383	4236	132619
	Melganzenvoet	703	8698	9401
Sum		129086	12934	96.5%

De scheidingsfunctie levert de volgende "discriminant weights" op in het onderscheid tussen landkers en melganzenvoet:

Figuur 99 Verschil spectra tussen landkers en melganzenvoet.

Tabel 72

De 10 meest onderscheidende golflengtes tussen landkers en melganzenvoet.

Wavelengths [nm]	Discriminative weights [-]
675	0.1855
660	0.1452
644	0.0901
738	0.0588
785	0.0514
769	0.0494
583	0.0479
629	0.0425
567	0.0374
754	0.0354

Bijlage 2 Beelden veld experimenten

B2.1 Beeldanalyse van hyperspectrale beelden 30 augustus 2017

Figuur 100 MLP classificatie van de hyperspectrale beelden op de eerste meetdag. Correcte classificaties zijn aangegeven met groene pixels ("true positives") en de rode pixels ("true negatives"). De gele pixels zijn werkelijke sla planten geclassificeerd als onkruid en de blauwe pixels vice versa.

B2.2 Beeldanalyse van hyperspectrale beelden 7 september 2017

Figuur 101 MLP classificatie van de hyperspectrale beelden op de tweede meetdag. Correcte classificaties zijn aangegeven met groene pixels ("true positives") en de rode pixels ("true negatives"). De gele pixels zijn werkelijke sla planten geclassificeerd als onkruid en de blauwe pixels vice versa.

To explore
the potential
of nature to
improve the
quality of life

Wageningen University & Research,
BU Glastuinbouw
Postbus 20
2665 ZG Bleiswijk
Violierenweg 1
2665 MV Bleiswijk
T +31 (0)317 48 56 06
F +31 (0) 10 522 51 93
www.wur.nl/glastuinbouw

Glastuinbouw Rapport WPR-751

De missie van Wageningen University & Research is 'To explore the potential of nature to improve the quality of life'. Binnen Wageningen University & Research bundelen Wageningen University en gespecialiseerde onderzoeksinstituten van Stichting Wageningen Research hun krachten om bij te dragen aan de oplossing van belangrijke vragen in het domein van gezonde voeding en leefomgeving. Met ongeveer 30 vestigingen, 5.000 medewerkers en 10.000 studenten behoort Wageningen University & Research wereldwijd tot de aansprekende kennisinstellingen binnen haar domein. De integrale benadering van de vraagstukken en de samenwerking tussen verschillende disciplines vormen het hart van de unieke Wageningen aanpak.