

Aardbei oogstvoorspelling met artificiële intelligentie en modellering (Aardboogst, Operationele groep EIP project, OG EIP 2023-20)

Technisch eindrapport

25/08/2026



Medegefinancierd door
de Europese Unie

AGENTSCHAP
LANDBOUW &
ZEEVISSERIJ

VLAAMS
RURAAL
NETWERK

Dit eindrapport werd opgesteld binnen het EIP Operationele Groep project Aardboogst (Aardbei oogstvoorspelling met artificiële intelligentie en modellering). Proefcentrum Fruitteelt is projectverantwoordelijke. Onderstaande partners werkten mee aan dit rapport.

Proefcentrum Fruitteelt

Yasmin Vanbrabant (yasmin.vanbrabant@pcfruit.be)

Serge Remy (serge.remy@pcfruit.be)



Vlaamse Instelling voor Technologisch Onderzoek (VITO)

Stephanie Delalieux (stephanie.delalieux@vito.be)

Nick Gutkin (nick.gutkin@vito.be)



Flanders Make

Walter Verdonck (walter.verdonck@flandersmake.be)

Bart Theys (bart.theys@flandersmake.be)



TAAK 1:

Om sterke neerwaartse wind van de propellers van de drone te minimaliseren want bewegende bloemen maken een betrouwbare detectie onmogelijk, zullen testen gebeuren met een minidrone (< 250 g). Vermits vliegen op GPS niet betrouwbaar is in een tunnel en er dicht bij de planten moet gevlogen worden, is in het dit jaar afgelopen Proeftuin Industrie 4.0 project 'Drones in de bouw en landbouw' reeds aangetoond dat nauwkeurig kan genavigeerd worden in een tunnel op constante hoogte boven de planten in vollegrond met een UWB (Ultra Wide Band) module op de drone en UWB ontvangers in de tunnel. In hetzelfde project werd ook vastgesteld dat vliegen met de camera onder een hoek (naar voor gekanteld) de bloemen goed in beeld brengt voordat ze beginnen te bewegen door het zog van de propellers. Omdat UWB technologie relatief duur is, zal in deze eerste taak van dit Aardboogst project eerst getest worden of de drone ook betrouwbaar op visie kan vliegen door een tunnel met aardbeien op stelling. Hiertoe zullen QR codes geplaatst worden in de buurt van de planten. Ten tweede zal nagegaan worden of hierbij de zichtbare bloemen ook goed in beeld gebracht worden. Hiertoe zal telkens een beperkte manuele telling gebeuren ter bevestiging. Deze testen zullen elk jaar tenminste bij 3 telers in minstens 3 tunnels met aardbeien op stelling op minstens 2 momenten uitgevoerd worden. Dus in totaal voor het hele project minstens 12 drone vluchten.

Activiteiten & resultaten Flanders Make


Testen zijn uitgevoerd met:

- DJI mini 3 pro: volledig geautomatiseerd
- DJI mini 4 pro: manueel gevlogen tijdens project, achteraf ook volledig geautomatiseerd
- DJI NEO: manueel gevlogen
- DJI Mavic 3M: volledig geautomatiseerd

Geautomatiseerde vluchten zijn succesvol getest in een testomgeving, maar nog niet op voldoende grote schaal in praktijktunnels met doordrager aardbeien in stellingteelt.

Voor het navigeren op visie zijn verschillende strategieën gebruikt:

- Visuele markers
- Plantenrij detectie in een serre (Figuur 1).



Figuur 1: Plantenrij detectie op visie door een drone in een serre met sierplanten.

- Visuele geleidingsdraad op basis van 2 fluo roze draden (Figuur 2):



Figuur 2: Visuele geleidingsdraden (fluo roze) voor een drone naast aardbeirijen op stelling. De blauwe lijnen tonen de vliegroute van de drone.

Activiteiten en resultaten VITO

De eerste testen toonden aan dat beelden die werden verzameld met een voorwaarts gekantelde camera, gericht op het vastleggen van aardbeienbloemen, zowel konden worden samengevoegd tot panoramische orthofoto's als afzonderlijk verwerkt. De beeldkwaliteit werd geëvalueerd om na te gaan of de luchtstroom veroorzaakt door de UAV-propellers zichtbaar was in de beelden onder de vorm van onscherpe bloemen of bladeren.

Uit de analyses bleek dat een vliegrichting onder een hoek van 45° ten opzichte van de aardbeistellingen de meest geschikte methode was om scherpe beelden te verkrijgen. Deze configuratie maakte het mogelijk om de aardbeienbloemen duidelijk in beeld te brengen en tegelijkertijd de invloed van de propellerluchtstroom tot een minimum te beperken. Bij bepaalde rassen en tunnelomstandigheden dienden de vlieghoek en de afstand tot de teeltrijen echter te worden aangepast om ook bloemen aan overhangende bloemtakken correct te kunnen registreren.

Daarnaast werd tijdens de georeferentie van de beelden in Taak 4 een belangrijke uitdaging vastgesteld. Door variaties in de vliegsnelheid van de UAV bleek het moeilijk om over de volledige lengte van de aardbeistellingen een gelijkmatige spreiding van de beeldopnames te realiseren. Dit leidde vooral aan het begin en einde van de teeltrijen tot een ongelijke verdeling van de bemonsteringsbeelden. Deze uitdaging kon binnen de looptijd van het project niet volledig worden opgelost, aangezien de noodzakelijke automatisering (met constante vliegsnelheid) voor een verdere optimalisatie van de gegevensverzameling uiteindelijk niet kon worden ontwikkeld.

Activiteiten en resultaten pcfruit

Pcfruit heeft de datacollectie voor drie locaties (twee stellingteelten en één vollegrondsteelt in tunnel) gepland, gecoördineerd en uitgevoerd, met manuele tellingen op minimaal twee tijdstippen per jaar in 2024 en 2025. Een overzicht van alle datacollectie momenten is weergegeven in Tabel 1. Dit omvatte de selectie van te vliegen rijen (steekproef) per perceel, het uitzetten van plots voor manuele bloemtellingen, de nummering en markering van de te meten rijen, en het inmeten met RTK-GPS van de begin- en eindpunten van alle teeltrijen (pcfruit). Daarnaast onderhielden we nauw contact met de telers om ervoor te zorgen dat er op de dagen van de datacollectie door Flanders Make geen oogst-, spuit- of andere teelthandelingen plaatsvonden die de metingen konden hinderen. VITO werd eveneens steeds tijdig geïnformeerd, zodat de verwerking van de dronegegevens onmiddellijk na de datacaptatie kon worden opgestart.

Tabel 1: Overzicht van datacollectie moment met minidrone in 2024 en 2025

Nr	Locatie	Cultivar(s)	Teeltmethode	Data dronevluchten
1	Sint-truiden (pcfruit)	Lady Emma, Karima, Malling Ace	Stellingteelt in tunnel	17/05/2024
				22/05/2024
				19/06/2024
				26/08/2024
2	Borgloon (teler)	Karima	Stellingteelt in tunnel	4/07/2024
				14/08/2024
				08/07/2025
				11/08/2025
3	Zammelen (teler)	Verity	Volle grond in tunnel	4/07/2024
				8/08/2024
				07/07/2025
				12/08/2025
4	Borgloon (teler)	Lady Emma	Stellingteelt in tunnel	8/07/2025
				13/08/2025

TAAK 2:


Als alternatieve aanpak om bruikbare camera beelden te bekomen van de aardbeibloemen van planten op stelling zal in deze activiteit een RGB camera (DJI OSMO Zenmuse X3) met Gimbal op een rechtopstaande staaf gemonteerd worden (met instelbare hoogte van de camera) die op een (voorlopig) handmatige voort te duwen wielentkar is geplaatst (mobiel camera platform). Hierdoor wordt negatieve interferentie door windbeweging uitgesloten en gaat de camera recht vooruit ter hoogte van de planten kijken naar de bloemen terwijl die zijdelings langs de rijen planten wordt voortbewogen. Ook in dit systeem zal eerst getest worden of hiermee de bloemen goed in beeld gebracht kunnen worden en zal een beperkte manuele telling gebeuren ter bevestiging. Vervolgens moeten de beelden die een andere resolutie hebben dan de dronebeelden goed aan elkaar te plakken zijn tot één orthofoto. Net zoals taak 1 zullen deze testen bij aardbeien op stelling elk jaar in minstens in 3 tunnels op minstens 2 momenten gebeuren. Dus ook bij deze aanpak minstens 12 testen in totaal voor het hele project. Bij voorkeur zijn

dit dezelfde tunnels als in Taak 1 om oogstvoorspelling met beide types camerabeelden te kunnen vergelijken.

Activiteiten en resultaten pcfruit

Door pcfruit werd een mobiel platform ontwikkeld waarop de DJI Osmo Zenmuse X3 camera kon worden gemonteerd (Figuur 1). Verschillende kijkhoeken werden getest, waarbij zowel de hoogte als de hoek van de sensor konden worden aangepast. De sensor werd op een hoogte van ongeveer 2 meter geplaatst en ingesteld onder de maximaal haalbare neerwaartse hoek binnen de opstelling.

De dataverzameling op pcfruit gebeurde in drie rijen met de rassen Lady Emma, Karima en Maling Ace op 24/06/2024, 20/08/2024 en 27/08/2024. Daarnaast werden dezelfde rijen die in 2024 met de drone werden gemeten bij teler-Karima, ook opgenomen met de DJI-opstelling op 05/07/2024 en 14/08/2024. In alle gevallen werden zowel de oost- als westzijde van de rijen gemeten. Deze metingen werden echter niet herhaald in 2025 omdat ze niet tot kwalitatieve beelden konden verwerkt worden (zie hieronder).



Figuur 3: Mobiel platform (hadnmatig voortduwen) met DJI OSMO Zenmuse X3 camera met gimbal stabilisatiesysteem bovenaan gemonteerd op de staaf.

Activiteiten en resultaten VITO :

De RGB-beelden verzameld met het DJI OSMO-gimbalsysteem werden verwerkt volgens vergelijkbare methodieken als de UAV-beelden. Zowel beeldstitching als panoramische verwerking werden geëvalueerd. Uit deze analyses bleek echter dat de beelden afkomstig van het gimbalsysteem te veel verticale instabiliteit vertoonden om met bestaande stitching-algoritmes betrouwbare en geometrisch correcte samengestelde beelden te genereren.

In vergelijking met de UAV-beelden die op dezelfde tijdstippen en in dezelfde tunnels werden verzameld, bleek de beeldkwaliteit van het DJI OSMO-systeem onvoldoende voor een nauwkeurige detectie en telling van aardbeienbloemen. Op basis van deze resultaten werd geconcludeerd dat deze benadering niet geschikt was voor de beoogde toepassing binnen het project.

TAAK 3:


Het gebruikte convolutioneel neurale netwerk (CNN) in het huidige oogstvoorspellingsmodel voor doordrager aardbeien in openlucht en vollegrond is getraind op hoge resolutie camerabeelden genomen met een drone loodrecht boven de bloeiende planten op 9 m hoogte en nadien aangeplakt in een orthofoto. De beelden genomen in een tunnel zullen een lagere resolutie hebben gezien de gebruikte RGB camera's. In deze taak beperken we ons tot de orthofoto's bekomen uit Taak 2 waarbij de camera zijdelings naar de bloeiende planten is gericht en niet loodrecht naar beneden naar de planten kijkt. Het bestaande CNN voor open bloemen detectie bij aardbeien van projectpartner Flanders Make FM dat een bloemdensiteitskaart oplevert en daarin het aantal bloemen telt, zal daarom vergeleken worden met het CNN model van projectpartners VITO dat de afzonderlijke bloemen detecteert en telt. Beide CNN modellen presteerden gelijkaardig voor orthofoto's van openlucht vollegrond doordrager aardbei percelen. Voor orthofoto's van stellingenteelt onder tunnel willen we dat ook nagaan.

Activiteiten en resultaten Flanders Make

Bloemdetecties overheen de rij werden uitgevoerd op nieuwe data van testvluchten en gedeeld met VITO.

Activiteiten en resultaten VITO

Een deep-learningmodel voor objectdetectie (Cascade R-CNN) werd getraind op basis van 2185 gelabelde beelden van aardbeienbloemen, verzameld in verschillende tunnels gedurende de twee projectseizoenen. De beelden werden opgedeeld in tegels van 512×512 pixels, waarna individuele aardbeienbloemen werden geannoteerd met behulp van een bounding-boxbenadering, waarbij rond elke afzonderlijke bloem een begrenzkader werd geplaatst (Figuur 4). Gesloten of onvoldoende ontwikkelde bloemen, evenals bloemen waarvan de kroonbladeren reeds gedeeltelijk waren afgevallen, werden niet meegenomen in de annotaties. Er werd geen onderscheid gemaakt tussen verschillende aardbeirassen, aangezien uit voorlopige analyses bleek dat de bloemen van de verschillende rassen visueel sterk op elkaar leken en rasspecifieke modellen geen meerwaarde boden t.o.v. één algemeen detectiemodel.



Figuur 4: Voorbeeld van een beeldtegel afkomstig van UAV-opnames, met aanduiding van de labels of bounding boxes/detectiekaders (rode streepjeslijnen) van de aardbeienbloemen die werden gebruikt voor het trainen van het Cascade R-CNN-detectiemodel.

Na het trainen van het objectdetectiemodel werd inferentie uitgevoerd op gegeorefereerde beeldfragmenten, waardoor gegeorefereerde detecties van individuele bloemen konden worden verkregen. De modelperformantie werd in eerste instantie kwalitatief geëvalueerd, waarbij gedurende het project bijkomende trainingsdata werden toegevoegd naarmate meer UAV-vluchten beschikbaar kwamen.

Na het eerste dataverzamelingsseizoen werden enkele belangrijke uitdagingen geïdentificeerd. Een eerste uitdaging betrof de lichtomstandigheden tijdens de beeldopnames. Bij zonnig weer veroorzaakten reflecties op de bladranden saturatie effecten, die door het model regelmatig foutief als bloemblaadjes werden gedetecteerd. De meest effectieve oplossing hiervoor bleek het uitvoeren van beeldopnames onder bewolkte omstandigheden en het vermijden van opnames rond het middaguur. In de praktijk is dit echter niet altijd haalbaar gezien de operationele beperkingen van telers.

Een tweede uitdaging werd veroorzaakt door de variabele vliegsnelheid van de UAV. Omdat de vluchten manueel werden uitgevoerd, was het moeilijk om over de volledige lengte van een stelling een constante snelheid aan te houden. Aangezien de videobeelden automatisch werden bemonsterd aan een vaste frequentie (één beeld per twaalf videoframes), leidde een lagere vliegsnelheid lokaal tot een grotere overlap tussen opeenvolgende beelden. Hierdoor ontstond een verhoogd risico dat dezelfde bloemen meerdere keren werden gedetecteerd en geteld. Binnen de looptijd van het project kon hiervoor geen volledige oplossing worden ontwikkeld, aangezien hiervoor een verdere automatisering van de drone voor dataverzameling noodzakelijk was. Tijdens het tweede projectjaar verbeterde de kwaliteit van de gegevensverzameling wel merkbaar dankzij de toegenomen ervaring van de UAV-piloot.


TAAK 4:

De beelden genomen door een drone onder een hoek en schuin vooruit (Taak 1) maakt dat ze niet geschikt zijn voor de huidige aanpak van stitchen van alle beelden. Om een oplossing te bieden die toelaat om beelden die onder een hoek genomen te zijn te gebruiken en te vermijden dat de foto's tot

een grote orthofoto gestitcht moet worden, willen we hier eerst de bloemen tellen in de afzonderlijke camerabeelden. Hier stelt zich al een uitdaging vermits de bloemen van de planten vooraan in beeld duidelijker en groter zullen zijn in het beeld dan de bloemen van de daarachter gelegen planten die ook in beeld zijn. Vervolgens moet de bloemdensiteit op het grondvlak geprojecteerd worden, maar hiertoe moeten de beelden wel geordend kunnen worden in de juiste volgorde en dit kan niet via GPS positie gebeuren in een tunnel. Daarom zullen hiervoor andere methoden worden getest worden (vb. herkennen planten en beelden o.b.v. plantafstanden, bloemtrossen, geplaatste QR codes, ...). Tenslotte moet de bloemdensiteit uitgemiddeld worden om een densiteitskaart te bekomen. Deze benadering lijkt op een reeds bestaande VITO techniek van ‘drone sampling’ waarbij slechts de beelden van een beperkte oppervlakte van een groter perceel wordt geanalyseerd om een uitspraak te kunnen doen over het hele perceel.

Activiteiten en resultaten Flanders Make

Het algoritme voor het tellen van bloemen in een plantenrij bij Flanders Make werd verbeterd zodat niet enkel een densiteit geschat wordt, maar dat ook het exacte aantal bloemen en hun preciese locatie in de plantenrij weergegeven kan worden. Een SLAM (Simultaneous Localization and Mapping) algoritme werd gecombineerd met een bloemdetectiealgoritme met als input de videobeelden van een drone of smartphone camera die door de plantenrij gaat en deze volledig in beeld brengt. Hierbij werd in “vertical mode / portrait” gefilmd, wat ook mogelijk was met de DJI mini 3 en 4. Doordat in video opgenomen werd, was elke bloem zichtbaar in soms 10-tallen beelden. Daarom werd een filter toegepast die een zelfde bloem die op meerdere beelden voorkwam kon labelen als dezelfde bloem (Figuur 5). De hoek waaronder de beelden gemaakt worden is hierbij van weinig belang. Dit algoritme werd als POC ontwikkeld. Nauwkeurigheid en robuustheid zijn echter nog lag.



Figuur 5: Combinatie van een SLAM algoritme en een bloemdetectiealgoritme om bloemen te detecteren in videobeelden van aardbeirijen bekomen met een drone.

Activiteiten en resultaten VITO

Binnen deze taak werden verschillende methoden onderzocht om UAV-beelden te verwerken en zo scherpe en bruikbare inputgegevens te verkrijgen voor het trainen van het Cascade R-CNN-bloemdetectiemodel. In eerste instantie werden afzonderlijke foto's genomen met behulp van de ingebouwde foto-opnamefunctie van de UAV. Omdat de drone manueel werd bestuurd, bleek deze aanpak echter weinig geschikt. Variaties in vliegsnelheid en vliegrichting zorgden ervoor dat opeenvolgende beelden niet op een consistente onderlinge afstand werden opgenomen.

Daarom werd verder gewerkt met continue video-opnames. Deze aanpak bleek efficiënter, aangezien individuele videoframes achteraf konden worden geëxtraheerd en gebruikt voor verdere verwerking en analyse.

Tijdens het testen van verschillende methoden voor beeldprojectie en beeldstitching werden meerdere uitdagingen vastgesteld. De vliegsnelheid van de UAV bleek een belangrijke invloed te hebben op zowel de beeldkwaliteit als de mogelijkheid om op een gestandaardiseerde manier videoframes te selecteren. Een snelheid van ongeveer 1 m/s werd als optimaal beschouwd. Deze snelheid liet de piloot toe om tijdig en veilig te reageren op obstakels, terwijl de volledige lengte van een stelling binnen een aanvaardbare tijd kon worden opgenomen. Bovendien werd bewegingsonscherpte bij deze snelheid beperkt.

Ook de oriëntatie van de camera werd geëvalueerd. Een verticale beeldoriëntatie bleek gunstiger dan een horizontale oriëntatie, omdat hierdoor vervormingen aan de beeldranden als gevolg van de groothoeklens van de UAV-camera werden verminderd. Daarnaast bleken de lichtomstandigheden een belangrijke factor. Op zonnige dagen zorgden sterke contrasten en reflecties voor vergelijkbare detectieproblemen als beschreven in Taak 3. Verder vormde occlusie van bloemen door bladeren en andere plantendelen een uitdaging, waardoor verschillende vlieghoeken ten opzichte van de aardbeistellingen werden getest.

Tijdens het eerste projectjaar werden vijf verschillende verwerkingsmethoden getest en geëvalueerd:

1. Stitchen van videoframes tot panoramische orthofoto's. Hierbij werden zowel opeenvolgende beelden als beelden met tussenstappen van drie en vijf frames getest. Deze methode bleek weinig succesvol omdat, door de beperkte afstand tussen de UAV en de planten, onvoldoende overeenkomstige beeldkenmerken (matching points) aanwezig waren om de beelden betrouwbaar samen te voegen.
2. Bloemtelling op afzonderlijke videoframes. Hierbij werden bloemen geteld op geselecteerde frames uit de videobeelden. De beste resultaten werden bekomen wanneer één beeld per twaalf videoframes werd geanalyseerd.
3. Tracking van individuele bloemen in videobeelden. Hiervoor werd gebruik gemaakt van een Python-gebaseerd video-tracking package. Hoewel de detectienauwkeurigheid hoog was (meer dan 80% ten opzichte van manuele tellingen op UAV-beelden), traden veel dubbeltellingen op doordat bloemen tussen opeenvolgende beelden sterk van positie en uitzicht veranderden of tijdelijk door planten werden verborgen.
4. Combinatie van ORB-SLAM en Cascade R-CNN. In deze aanpak werden bloemen in een driedimensionale ruimte gelokaliseerd en vervolgens geprojecteerd op een tweedimensionaal vlak. Deze methode vereiste bijkomende ruimtelijke referenties, was computationeel traag en detecteerde slechts ongeveer 51% van de manueel getelde bloemen.
5. Objectdetectie op gegeorefereerde beeldframes. Hierbij werd één beeld per twaalf videoframes geselecteerd en gegeorefereerd mbv GPS metingen op vaste punten in de tunnel. Op deze manier konden de detecties ruimtelijk worden weergegeven binnen de tunnelomgeving. Deze methode behaalde een detectienauwkeurigheid van 76% ten opzichte van manuele tellingen en werd daarom geselecteerd voor verdere toepassing tijdens het tweede projectjaar (Figuur 6).

De gekozen aanpak sluit bovendien nauw aan bij de door VITO ontwikkelde en gepatenteerde methode voor "drone sampling", waarbij een representatieve steekproef van beelden wordt gebruikt om uitspraken te doen over een groter teeltoppervlak. De resultaten binnen dit project bevestigen de toepasbaarheid van deze methode voor nieuwe toepassingen zoals bloemtelling in aardbeiteelten onder tunnels.



Figuur 6: Gegeorefereerde UAV-beelden uit de serre van teler-Karima met door het detectiemodel geïdentificeerde aardbeienbloemen, weergegeven als rode detectiekaders rond individuele bloemen.

TAAK 5:

Afhankelijk van de morfologie van de plant (meer open plant of heel compacte plant met veel bladeren) en de bloemtrossen en het specifieke teeltsysteem gaat een camera meer of minder van het werkelijke aantal bloemen in beeld kunnen brengen. Dus het neurale netwerk kan ook maar het aantal bloemen tellen die de camera in beeld kan brengen. Indien vervolgens het oogstvoorspellingsmodel wordt toegepast zal er een onderschatting van de werkelijke oogst gebeuren. Om hiervoor te corrigeren moet er bepaald worden wat de fractie bloemen is die de camera niet kan zien (i.e. de occlusiefactor). Hiervoor zal een camera in dezelfde positie geplaatst worden als de camera van de minidrone (Taak 1) en als de camera op het mobiele platform (Taak 2). Gedurende 4 weken in de productiefase zal er elke week op minstens 2 momenten per week een foto genomen worden en het werkelijke aantal bloemen manueel geteld worden die zichtbaar zijn in het camerabeeld voor beide camera opstellingen telkens in één tunnel. Deze oefening moet voor elk getest ras gedaan worden. Nadien wordt voor elk moment ook het aantal bloemen geteld die zichtbaar zijn in het camerabeeld. Vergelijking van het werkelijk aantal bloemen met het aantal bloemen zichtbaar in het beeld zal toelaten om te berekenen wat het gemiddeld percentage bloemen is dat niet zichtbaar is voor de camera (en dus ook niet voor het neurale netwerk). Dit percentage bloemen moet opgeteld worden bij het aantal bloemen dat het neurale netwerk heeft geteld om een accurate oogstvoorspelling toe te laten.

Activiteiten en resultaten pcfruit

Er is een test uitgevoerd met camera's op statieven in de doordrager aardbei stellingtunnel van pcfruit, waarbij boven elke cultivar beelden werden genomen (Figuur 7). Hierbij bleek echter dat het field of view (FOV) te sterk verschilde van het FOV dat gerealiseerd wordt met respectievelijk het droneplatform en/of het mobiele platform. Dit verschil was het gevolg van variaties in lens, afstand en opnamehoek die met deze opstelling haalbaar waren. Aangezien het de bedoeling was dat het FOV en dus het aantal zichtbare bloemen op de beelden zo goed mogelijk aansloot bij de beelden die met de drone en/of het mobiele platform werden gecapteerd, werd beslist om de occlusiefactor voor elke cultivar en elk perspectief te bepalen met hetzelfde platform (drone of mobiel platform). Dit gebeurde zowel op pcfruit als bij de telers, en op dezelfde dag waarop ook de beelden met het mobiele platform

en de drone werden verzameld. Op die manier werd een meer accurate occlusiefactor bekomen per cultivar, aangezien deze werd berekend op het perceel waarvan men ook effectief de oogst wenste te voorspellen. Bovendien werd hiermee gecorrigeerd voor bijkomende verschillen in occlusie tussen pefruit en de telers, zoals verschillen in het moment van opkuis van (ver)oude(rde) bladeren of het ontbreken ervan, en variaties in plantdichtheid. Hierdoor kan de morfologie van de plant, ondanks het feit dat het om dezelfde cultivar gaat namelijk alsnog verschillen tussen tunnels en bedrijven/telers.



Figuur 7: Vaste camera opstelling op pefruit voor bepaling van de occlusiefactor in camerabeelden van doordrager aardbeien op stelling in een tunnel.


TAAK 6:

Het bestaande opbrengstvoorspellingsmodel dat werkt met voorspellingen voor groepen van 30 planten en uitgaat van het aantal planten, aantal open bloemen en plantdatum zal toegepast en getraind worden met de getelde bloemen (Taken 3 en 4) voor beide camera opstellingen (Taken 1 en 2).

Activiteiten en resultaten pefruit

Bij de vollegrondsteelt in tunnel wordt er een dronevlucht uitgevoerd loodrecht (nadir) boven de doordrager aardbeien met een minidrone. Een steekproef van 10% van de rijen overvliegen is voldoende om tot een accurate oogstvoorspelling te komen. Simulaties hebben uitgewezen dat zelfs een goed gekozen steekproef van 0,5% van de rijen voldoende is om tot een accurate oogstvoorspelling te komen. Vervolgens worden deze beelden verder verwerkt in Mapeo voor de beeldverwerking van de foto's tot één groot samengesteld beeld (orthofoto) waarop een AI detectie algoritme de geopende bloemen detecteert. Per plot van 21 of 30 planten wordt het aantal bloemen geteld. Deze bloemaantallen worden in combinatie met de datum van de dronevlucht en plantdatum gebruikt om de oogst in kg 3 weken later te voorspellen d.m.v. een generalized additive model (GAM). Dit resulteert dan in een oogstvoorspelling voor het totale perceel door de steekproef te extrapoleren naar het volledige oppervlakte van het perceel. Na een dronevlucht en oogstvoorspelling kan er ook een spatiale oogstkaart geleverd worden waarbij per plot (van 21 of 30 planten) de oogst (in kg) wordt weergegeven volgens verschillende kleurklassen

(Figuur 8). Voor Verity (vollegrondteelt in tunnel) lagen de oogstvoorspellingen in juli en augustus 2024 en 2025 tussen 91% en 121% accuraatheid (Tabel 2). Gebruik van een correctiefactor (of occlusiefactor, zie Taak 5, om verborgen, gemiste of dubbel getelde bloemen te corrigeren) was niet altijd beter dan de oogst voorspellen zonder toepassing van een correctiefactor.



Figuur 8: Spatiale oogstkaart van Verity in 2025 met per plot van 30 planten de voorspelde oogst (in g) die wordt weergegeven met verschillende kleurklassen.

Tabel 2: Oogstvoorspelling Verity voor 2024 en 2025

GAM – kg vruchten		
Data	Jaar	% van de werkelijke oogst (kg)
Verity augustus - nadir (geen correctiefactor)	2024	91
Verity augustus - nadir (met correctiefactor)	2024	105
Verity juli - nadir (geen correctiefactor)	2025	107
Verity juli - nadir (met correctiefactor)	2025	121
Verity augustus - nadir (geen correctiefactor)	2025	91
Verity augustus - nadir (met correctiefactor)	2025	108


Voor de stellingteelt werden beeldopnames met een minidrone gemaakt vanaf zowel de oost- als de westzijde van iedere plantenrij om te onderzoeken of meerdere perspectieven de betrouwbaarheid van de oogstvoorspellingen verbeteren. Daarnaast is getest of een correctiefactor (of oclusiefactor zie Taak 5), gebaseerd op een set handmatige bloemtellingen om verborgen, gemiste of dubbel getelde bloemen te corrigeren, de nauwkeurigheid kon verhogen. Verder is vergeleken welk model de hoogste voorspellingsnauwkeurigheid levert: een model dat eerst het aantal vruchten schat en dit vermenigvuldigt met het gemiddelde vruchtgewicht, versus een model dat direct het gewicht van de vruchten voorspelt. Op basis van resultaten van twee groeiseizoenen (2024 en 2025), met in totaal vijf stellingteelt voorspellingen, blijkt dat het model dat het aantal vruchten voorspelt, zonder correctiefactor en gebaseerd op slechts één perspectief (oost of west), in vier van de vijf voorspellingen, de meest consistente en nauwkeurige oogstvoorspellingen oplevert (Karima in Tabel 3 en Lady Emma in Tabel 4). De meeste voorspellingen lagen tussen 91 en 107% van de werkelijke oogst. Voor Lady Emma was er een uitschieter met een voorspelling die 28% lag boven de werkelijke oogst als beste voorspelling in juli. Waarschijnlijk was het voor deze cultivar te vroeg in het groeiseizoen om een betrouwbare voorspelling te doen, aangezien in juli gemiddeld slechts 20 bloemen per plot (21 planten) werden geteld, tegenover 60 bloemen in augustus. Verder kan er dan ook voor stellingteelt een oogstkaart (kg) gemaakt worden voor het perceel die de spatiale variabiliteit in oogst weergeeft (Figuur 9).

Tabel 3: Oogstvoorspellingen Karima voor 2024 en 2025

Data	Jaar	GAM - aantal vruchten	GAM - kg vruchten
		% van de werkelijke oogst (aantal vruchten)	% van de werkelijke oogst (kg)
Karima juli - O+W (geen correctiefactor)	2024	127	98
Karima juli - O+W (met correctiefactor)	2024	116	89
Karima juli - O (geen correctiefactor)	2024	106	80
Karima juli - O (met correctiefactor)	2024	132	101
Karima juli - W (geen correctiefactor)	2024	101	77
Karima juli - W (met correctiefactor)	2024	106	81
Karima juli - O+W (geen correctiefactor)	2025	134	115
Karima juli - O+W (met correctiefactor)	2025	115	118
Karima juli - O (geen correctiefactor)	2025	96	91
Karima juli - O (met correctiefactor)	2025	133	114
Karima juli - W (geen correctiefactor)	2025	110	96
Karima juli - W (met correctiefactor)	2025	144	123
Karima augustus - O+W (geen correctiefactor)	2025	137	138
Karima augustus - O+W (met correctiefactor)	2025	112	118
Karima augustus - O (geen correctiefactor)	2025	86	98
Karima augustus - O (met correctiefactor)	2025	100	109
Karima augustus - W (geen correctiefactor)	2025	100	110
Karima augustus - W (met correctiefactor)	2025	123	128

Tabel 4: Oogstvoorspellingen Lady Emma voor 2025

Data	Jaar	GAM - aantal vruchten	GAM - kg vruchten
		% van de werkelijke oogst (aantal vruchten)	% van de werkelijke oogst (kg)
Lady Emma juli - O+W (geen correctiefactor)	2025	161	140
Lady Emma juli - O+W (met correctiefactor)	2025	171	146
Lady Emma juli - O (geen correctiefactor)	2025	147	130
Lady Emma juli - O (met correctiefactor)	2025	164	140
Lady Emma juli - W (geen correctiefactor)	2025	145	128
Lady Emma juli - W (met correctiefactor)	2025	165	140
Lady Emma augustus - O+W (geen correctiefactor)	2025	96	56
Lady Emma augustus - O+W (met correctiefactor)	2025	96	56
Lady Emma augustus - O (geen correctiefactor)	2025	70	41
Lady Emma augustus - O (met correctiefactor)	2025	104	61
Lady Emma augustus - W (geen correctiefactor)	2025	66	38
Lady Emma augustus - W (met correctiefactor)	2025	88	51



Figuur 9: Spatiale oogstkaart van Karima in 2025 met per plot van 21 planten de voorspelde oogst (in kg) die wordt weergegeven met verschillende kleurklassen.

Datum: 25/08/2026

Handtekening:

Naam: Serge Remy