

Bepaling van vers- en drooggewicht van sla op basis van RGB-camerabeelden met een convolutional neural network (CNN)

Brent BEYERS

Promotor: Prof. J. Ceusters
Copromotor: Ing. S. Daems
Dr. M. Frans
Dr. F. De Ridder

Masterproef ingediend tot het behalen van de
graad van Master of Science in de
biowetenschappen: *Land- en tuinbouwkunde*

Academiejahr 2025-2026

© Copyright KU Leuven

Zonder voorafgaande schriftelijke toestemming van zowel de promotor(en) als de auteur(s) is overnemen, kopiëren, gebruiken of realiseren van deze uitgave of gedeelten ervan verboden. Voor aanvragen i.v.m. het overnemen en/of gebruik en/of realisatie van gedeelten uit deze publicatie, kan u zich richten tot KU Leuven Campus Geel, Kleinhoefstraat 4, B-2440 Geel, +32 14 72 13 00 of via e-mail iiw.geel@kuleuven.be.

Voorafgaande schriftelijke toestemming van de promotor(en) is eveneens vereist voor het aanwenden van de in deze masterproef beschreven (originele) methoden, producten, schakelingen en programma's voor industrieel of commercieel nut, om te refereren naar dit werk in publicaties en voor de inzending van deze publicatie ter deelname aan wetenschappelijke prijzen of wedstrijden.



*Copyright informatie:
studiewerk van een student in het kader van de
academische opleiding en examenbeoordeling.
Na deze beoordeling vond geen correctie plaats
van het studiewerk.*

Voorwoord

Na een uitdagende maar leerrijke periode aan deze masteropleiding is het moment aangebroken om met deze masterproef dit academisch hoofdstuk af te sluiten. Hoewel de verantwoordelijkheid bij mijzelf lag om deze masterproef alsook deze boeiende opleiding tot een goed einde te brengen, wil ik hier toch nog de tijd nemen om een aantal personen te bedanken die mij tijdens dit traject gesteund en begeleid hebben.

In eerste instantie wil ik Rijk Zwaan bedanken voor het ter beschikking stellen van hun slazaden alsook het slabedrijf Goni voor hun slaplanten. Dit heeft mij de mogelijkheid gegeven om mijn proeven voor deze masterproef te kunnen uitbreiden, waarvoor dank!

Vervolgens wil ik ing. Stijn Daems bedanken voor de goede begeleiding, de waardevolle feedback alsook het voortdurend klaarstaan wanneer ik vragen had met betrekking tot mijn scriptie. Daarnaast wil ik mijn copromotoren Dr. Fjo De Ridder en Dr. Mario Frans hartelijk bedanken voor de begeleiding tijdens mijn onderzoeksstage, het beantwoorden op al mijn vragen en hun waardevolle feedback op mijn masterproef. Bovendien wil ik ook nog Dr. Jeroen van Roy en Jan Creylman bedanken voor hun tijd en constructieve feedback op mijn masterproef.

Verder wil ik mijn medestudenten bedanken voor alle steun, motivatie en toffe momenten tijdens de opleiding.

Tot slot wil ik mijn ouders en zus bedanken voor hun steun. Ondanks de stress en mijn minder aangename humeur dat ik af en toe mee naar huis nam bleven jullie mij onvoorwaardelijk steunen. Daarnaast gaven jullie mij alle kansen en ruimte om mij volledig te kunnen focussen op mijn studies. Bedankt hiervoor!

Brent Beyers

Mei 2026, Arendonk

Samenvatting

Sla (*Lactuca sativa* L.) is wereldwijd één van de belangrijkste bladgroenten met een jaarlijks stijgende productie. Slatelers zijn hierdoor genoodzaakt de productie van sla efficiënter te maken door onder andere het ontwikkelen van gewasmodellen op basis van groei-indicatoren zoals het vers- en drooggewicht. De traditionele methoden voor het meten van deze parameters zijn echter tijdrovend, arbeidsintensief en destructief, waardoor accurate niet-destructieve alternatieven noodzakelijk zijn. Hoewel niet-destructieve computervisie-gebaseerde methoden veelbelovende resultaten opleveren voor het schatten van groei-gerelateerde kenmerken, kampen deze met beperkingen zoals gevoeligheid voor ruis, beperkt generalisatievermogen en grote rekenkundige complexiteit. Het gebruik van RGB-camera's in combinatie met een convolutional neural network (CNN) biedt een potentieel alternatief, aangezien RGB-camera's breed toepasbaar zijn en CNN's visuele data accuraat en efficiënt kunnen verwerken en analyseren. Het doel van deze masterproef is dan ook om de mogelijkheden te onderzoeken voor het gebruik van CNN's met RGB-afbeeldingen voor de bepaling van het vers- en drooggewicht van sla gedurende een gehele teeltroonde onder praktijkomstandigheden.

Van verschillende sla-cultivars (Emeldia RZ, Limambo RZ en Volumia) werden RGB-afbeeldingen verzameld. De cultivars Emeldia RZ en Limambo RZ werden elks twee keer zelf opgekweekt om slaplanten afkomstig van twee verschillende teeltromdes te bekomen. Daarnaast waren de slaplanten van de cultivar Volumia afkomstig van een externe slateler en van éénzelfde teeltroonde. Van de slaplanten werden RGB-afbeeldingen verzameld onder een camerahoek van 0°, 45° en 90° ten opzichte van het grondoppervlak. Na verzameling van de RGB-afbeeldingen van de slaplanten werd een CNN-model ontworpen met het meest accurate schattingsvermogen. Tenslotte werd het schattings- en generalisatievermogen van het ontwikkelde CNN-model onderzocht.

De resultaten tonen aan dat het meest accurate CNN-model, afgestemd op een relatief kleine dataset, bestond uit 5 convolutielagen en volgende hyperparameters: een leersfrequentie van 0,001; een batchgrootte van 10 en 200 epochs. Het ontwikkelde model schat het vers- en drooggewicht van sla accuraat, met $R^2 \sim 0,92 - 0,97$ en NRMSE $\sim 0,19 - 0,34$, voor cultivars die in de trainingsdata aanwezig zijn en onder gelijkaardige omstandigheden werden geteeld, mits voldoende trainingsdata. De schattings- en generalisatieprestaties variëren echter sterk per cultivar, mogelijks door morfologische verschillen. Het model toont een zekere robuustheid voor variatie in camerahoeken, al resulteerden de beelden onder een camerahoek van 45° en 90° in de beste schattingen.

Dit onderzoek toont aan dat een CNN-model in combinatie met een RGB-camera als niet-destructieve meetmethode voor de bepaling van het vers- en drooggewicht van sla mogelijkheden biedt. Daarentegen blijft, onder andere door de wisselende generalisatieprestaties, de praktische toepasbaarheid voorlopig nog beperkt. Door verder onderzoek te doen naar CNN's in combinatie met RGB-camerabeelden voor de bepaling van het vers- en drooggewicht van sla en het vergroten van de trainingsdataset met camerabeelden van verschillende sla-cultivars onder diverse teeltomstandigheden, kan dit onderzoek een waardevolle bijdrage leveren aan de ontwikkeling van geautomatiseerde, niet-destructieve meetssystemen voor de precisieteelt van sla.

Summary

Lettuce (*Lactuca sativa* L.) is one of the world's most important leafy vegetables, with a yearly increase in production worldwide. As a result, lettuce growers are forced to make lettuce production more efficient, for example by developing crop models based on growth indicators such as fresh and dry weight. However, traditional methods for measuring these parameters are time-consuming, labour-intensive and destructive, making accurate non-destructive alternatives essential. Although non-destructive computer vision-based methods provide promising results for estimating growth-related characteristics, they suffer from limitations such as sensitivity to noise, limited generalization ability and high computational complexity. The use of RGB cameras in combination with a convolutional neural network (CNN) offers a potential alternative, as RGB cameras are widely applicable and CNNs can process and analyse visual data accurately and efficiently. The aim of this master's thesis is therefore to investigate the possibilities for using CNNs with RGB images to determine the fresh and dry weight of lettuce throughout an entire growing cycle under greenhouse conditions.

RGB images were collected from various lettuce cultivars (Emeldia RZ, Limambo RZ and Volumia). The cultivars Emeldia RZ and Limambo RZ were each grown twice to obtain lettuce plants from two different growing cycles. In addition, lettuce plants of the cultivar Volumia were obtained from an external lettuce grower and were all from the same growing cycle. From the lettuce plants of the relevant cultivars, RGB images were collected at camera angles of 0°, 45° and 90° relative to the ground surface. After collecting the RGB images of the lettuce plants, a CNN model with the most accurate estimation capability was developed. Finally, the estimation and generalization capabilities of the developed CNN model were investigated.

The results demonstrate that the most accurate CNN model, trained on a relatively small dataset, consisted of 5 convolutional layers and the following hyperparameters: a learning rate of 0,001; a batch size of 10; and 200 epochs. The model accurately estimates the fresh and dry weight of lettuce, with $R^2 \sim 0,92 - 0,97$ and NRMSE $\sim 0,19 - 0,34$, for cultivars present in the training data and grown under similar conditions, provided there is sufficient training data. However, the estimation and generalization performance vary greatly by cultivar, possibly due to morphological differences. The model shows a certain robustness to variations in camera angles, although images taken at camera angles of 45° and 90° appear to be the most suitable.

This study demonstrates that a CNN model combined with an RGB camera holds potential as a non-destructive measurement method for determining the fresh and dry weight of lettuce. However, due to factors such as varying generalization performance, its practical applicability remains limited. By conducting further research into CNNs in combination with RGB images for determining the fresh and dry weight of lettuce, and by expanding the training dataset with images of different lettuce cultivars under various growing conditions, this research can make a valuable contribution to the development of automated, non-destructive measurement systems for precision cultivation of lettuce.

Keywords: Lettuce (*Lactuca sativa* L.) – Convolutional neural network (CNN) – Fresh and dry weight – RGB images – Greenhouse conditions – Non-destructive measurement

INHOUD

Voorwoord	ii
Samenvatting.....	iii
Summary.....	iv
Symbolenlijst.....	viii
Lijst met afkortingen	ix
1 Inleiding	1
2 Literatuurstudie.....	3
2.1 <i>Algemene, economische, morfologische, en fysiologische aspecten van sla en de beschutte teelt in een mobiele gotensysteem (MGS).....</i>	3
2.1.1 Economisch belang van sla wereldwijd	3
2.1.2 Slateelt in België en Vlaanderen	5
2.1.3 Morfologie en fysiologie van sla	5
2.1.4 Beschutte teelt van sla in een mobiele gotensysteem (MGS)...	7
2.2 <i>Toepassing van de RGB-camera bij plantfenotypering.....</i>	9
2.2.1 Basisprincipes bij het gebruik van beeldvormingstechnieken ...	9
2.2.2 Werking en principes van een RGB-camera.....	10
2.2.3 Toepassingen van RGB-camera's in gewasmonitoring	11
2.3 <i>Convolutional Neural Networks (CNN's) en het gebruik ervan bij de monitoring van sla</i>	14
2.3.1 Basisprincipes van CNN.....	14
2.3.2 Het gebruik van CNN's voor de groeimonitoring van kassla ...	16
3 Materiaal en methoden.....	19
3.1 <i>Inleiding en doelstelling</i>	19
3.2 <i>Zaai en opkweek van slaplanten tot het oogstgewicht</i>	20
3.2.1 Irrigatie.....	21
3.2.2 Klimaatomstandigheden: temperatuur, relatieve vochtigheid, CO ₂ , belichting en ventilatie.....	21
3.3 <i>Sla afkomstig van een extern sla-teeltbedrijf</i>	22
3.4 <i>Verzamelen van de RGB-camerabeelden, vers- en drooggewichten van de slaplanten.....</i>	22
3.4.1 Verzamelen van de RGB-camerabeelden van de slaplanten onder een hoek van 0°, 45° en 90° ten opzichte van het grondoppervlak	22
3.4.2 Bepaling van vers- en drooggewicht	25

3.5	<i>Ontwikkeling en onderzoek van een CNN-model voor de bepaling van vers- en drooggewicht van sla op basis van RGB-camerabeelden.....</i>	25
3.5.1	Ontwerpen van een CNN-model met het meest accurate schattingsvermogen	25
3.5.2	Onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model.....	30
3.6	<i>Statistische analyse</i>	32
4	Resultaten en discussie.....	34
4.1	<i>Ontwerpen van een CNN-model met het meest accurate schattingsvermogen</i>	34
4.1.1	Bepaling van het optimaal aantal convolutielagen.....	34
4.1.2	Bepaling van de optimale hyperparameters	35
4.1.3	Discussie	38
4.2	<i>Onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model</i>	40
4.2.1	Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak.....	40
4.2.2	Onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak ...	43
4.2.3	Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een combinatie van camerahoeken van 0°, 45° en 90° t.o.v. het grondoppervlak	49
5	Besluit.....	53
	Referenties.....	55
	Bijlagen	67
Bijlage A	Overzicht van het onderzoeksproces	A. 1
Bijlage B	Overzicht van de datums met betrekking tot de zaai en opkweek van de slaplanten tot het bereiken van het oogstgewicht	B. 1
Bijlage C	Samenstelling van de voedingsoplossing en de bijhorende streefwaardes	C. 1
Bijlage D	Overzicht van het aantal afbeeldingen en de verschillende periodes waarbij de RGB-camerabeelden werden genomen van de slaplanten	D. 1
Bijlage E	Voorbeelden van RGB-camerabeelden genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivars Emeldia RZ, Limambo RZ, van zowel teeltronde 1 en 2, en Volumia.....	E. 1

Bijlage F	De onderzochte CNN-modellen met bijhorende specificaties en gebruikte hyperparameters voor de bepaling van het optimaal aantal convolutielagen.....	F. 1
Bijlage G	Schematische weergave van het ontwikkelde CNN-model met het meest accurate schattingsvermogen.....	G. 1
Bijlage H	Resultaten van het onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model weergegeven in de vorm van scatterplots met bijhorende R^2-, RMSE- en NRMSE-waarden en vergelijking van de regressielijnen.....	H. 1

Symbolenlijst

EC	Elektrische Conductiviteit	[mS/cm]
RV	Relatieve vochtigheid	[%]
R ²	Determinatiecoëfficiënt	[Dimensieloos]
∞	Oneindig	[Dimensieloos]

Lijst met afkortingen

1D	Eendimensionaal
2D	Tweedimensionaal
3D	Driedimensionaal
AI	Artificiële intelligentie
B	Blauw
BPK	Belgische plantenkwekerij
Ca ⁺⁺	Calcium
Cl ⁻	Chloor
CNN	Convolutional Neural Network
Cu ⁺⁺	Koper
f(x)	Functie
FAO	Food and Agriculture Organization
FC	Fully Connected
Fe	Ijzer
G	Groen
GPU	Graphics Processing Unit
ha	Hectare
H ₂ BO ₃ ⁻	Borium
HCO ₃ ⁻	Bicarbonaat
H ₂ PO ₄ ⁻	Fosfaat
ISP	Image Signal Processor
J/cm ²	Joule per vierkante centimeter
JPG	Joint Photographic experts Group
K ⁺	Kalium
MAE	Mean Absolute Error
Mg ⁺⁺	Magnesium
MGS	Mobiele gotensysteem
Mn ⁺⁺	Mangaan
MSE	Mean Squared Error
n	Aantal voorspellingen
Na ⁺	Natrium
NFT	Nutriëntenfilmtechniek
NH ₄ ⁺	Ammonium
NO ₃ ⁻	Nitraat

NRMSE	Normalized Root Mean Square Error
ppm	Parts per million
PAR	Photosynthetically Active Radiation
R	Rood
R-CNN	Region Based Convolutional Neural Network
ReLU	Rectified Linear Unit
RGB	Rood Groen Blauw
RGB-D	Rood Groen Blauw - Diepte
RMSE	Root mean square error
RZ	Rijk Zwaan
SO ₄ ²⁻	Sulfaat
t	Ton
UAV	Unmanned Aerial Vehicle
VS	Verenigde Staten
W/m ²	Watt per vierkante meter
X	Oorspronkelijke waarde
X _{max}	Maximum waarde
X _{min}	Minimum waarde
X _{norm}	Genormaliseerde waarde
y _i	Werkelijke waarde
y _{max}	Maximale werkelijke waarde
y _{min}	Minimale werkelijke waarde
$\hat{y}_i$	Voorspelde waarde
$\bar{y}$	Gemiddelde van de werkelijke waarden
Zn ⁺⁺	Zink

1 INLEIDING

Sla (*Lactuca sativa* L.) is wereldwijd één van de belangrijkste bladgroenten met een breed scala aan toepassingen, van salades tot medicinale producten (Das & Bhattacharjee, 2020; Shatilov et al., 2019). In het jaar 2023 bedroeg de wereldwijde productie van sla ongeveer 28,08 miljoen ton (FAO, 2025; Das & Bhattacharjee, 2020). De teelt van sla is een interessante teelt voor vele telers aangezien sla een relatief winstgevend gewas is omdat de teeltperiode kort is en de opbrengsten relatief hoog zijn. Sla is over het algemeen een belangrijke en veelzijdige groente die verschillende voordelen biedt en een belangrijke rol speelt in de voedselvoorziening en de gastronomische keuken (Gupta, 2023). Bovendien stijgt de wereldproductie van sla jaarlijks, met gemiddeld ca. 248.333 ton in de afgelopen jaren, wat onder andere te wijten is aan de toenemende vraag naar voedsel ten gevolge van de bevolkingstoename in de wereld (FAO, 2025; van Dijk et al., 2021).

Door de jaarlijkse toenemende vraag naar sla wereldwijd zijn slatelers genoodzaakt om de productie ervan efficiënter te maken. Dit kan behaald worden door het ontwikkelen van gewasmodellen die de sla-telers helpen voor het verbeteren van klimaat-, nutriënten- en irrigatiebeheerstrategieën om een optimale slaproductie te verkrijgen. Deze gewasmodellen kunnen onder andere bekomen worden door het meten van het vers- en drooggewicht van sla die fungeren als groei-indicatoren omdat deze nauw verband houden met de transpiratie en fotosynthese van de slaplant. Bovendien kunnen deze groei-indicatoren, vers- en drooggewicht van sla, de sla-telers helpen bij het bepalen van geschikte oogsttijden wat zorgt voor de verbetering van de economische status van de slatelers. De traditionele methoden, waarbij doorgaans plantenmonsters worden verzameld en analytische instrumenten in een laboratorium worden gebruikt, voor het meten van het vers- en drooggewicht van sla zijn tijdrovend, arbeidsintensief en destructief. Hierdoor is het gebruik van accurate en niet-destructieve meetmethodes voor het meten van het vers- en drooggewicht van sla noodzakelijk (Gang et al., 2022).

Vanwege de nood aan onder andere accurate en niet-destructieve meetmethodes voor het ontwikkelen van gewasmodellen kent de glastuinbouw, waar de teelt van sla onderdeel van uitmaakt, een stelselmatige verschuiving van de traditionele glastuinbouw naar precisietuinbouw onder glas (Jayasuriya et al., 2024). Momenteel wordt er al veel gebruik gemaakt van computervisie-gebaseerde methoden voor het schatten van groeigerelateerde kenmerken van land- en tuinbouwgewassen. Deze beeldgebaseerde methoden extraheren specifiek laag-niveau kenmerken, zoals kleur- en structuurgerelateerde kenmerken, uit digitale beelden en leggen een verband tussen deze lage-niveau kenmerken en handmatig gemeten groeigerelateerde eigenschappen. Ondanks dat verschillende computervisie-gebaseerde methoden veelbelovende resultaten opleveren voor het schatten van groeigerelateerde kenmerken kampen deze methoden met enkele problemen. Ten eerste zijn deze methoden gevoelig voor ruis wat de beeldsegmentatie en extractie van kenmerken beïnvloedt en de schattingsnauwkeurigheid mogelijks doet afnemen. Omdat het vastleggen van beelden in praktijkomstandigheden gepaard gaat met ongelijkmatige belichting en rommelige achtergronden is ruis onvermijdelijk. Daarnaast zijn computervisie-gebaseerde methoden sterk afhankelijk van handmatig ontworpen beeldkenmerken en zorgt hierdoor voor een grote rekenkundige complexiteit. Bovendien is het generalisatievermogen van de geëxtraheerde lage-niveau beeldkenmerken beperkt (Zhang et al., 2020).

Een potentieel alternatief voor de traditionele methoden alsook voor de computervisie-gebaseerde methoden is het gebruik van convolutional neural networks (CNN's), een techniek behorende tot het domein van artificiële intelligentie (AI). Een CNN is een artificieel model voor het verwerken van gegevens met een rasterpatroon, zoals afbeeldingen, en is ontworpen om automatisch en adaptief ruimtelijke hiërarchieën van kenmerken te leren (Yamashita et al., 2018). Het gebruik van RGB-camera's (waar RGB staat voor Rood Groen en Blauw), voor RGB-beeldvorming, in combinatie met een CNN, voor de verwerking van RGB-beelden, bieden voor het bepalen van het vers- en drooggewicht van sla op een accurate en niet-destructieve manier potentieel. Dit aangezien RGB-camera's breed toepasbaar zijn en CNN's visuele data, zoals RGB-afbeeldingen, met een accurate en hoge efficiëntie kunnen verwerken en analyseren (El Sakka et al., 2025; Guo et al., 2021; Kior et al., 2024). Het is dan ook nodig om de combinatie van deze twee zaken te onderzoeken en na te gaan of deze een accurate en efficiënte oplossing kunnen bieden voor het niet-destructief meten van het vers- en drooggewicht van sla in de praktijk.

Deze masterproef valt binnen het project "Intelligente klimaatoptimalisatie met en voor tuinders (KlimOp-AI)" van het Expertisecentrum Energie van Thomas More Geel, waarbij AI-technieken worden toegepast op klimaatgegevens om glastuinbouwbedrijven meer inzichten te geven in de klimaatregeling van serres (Thomas More, 2021). Gerelateerd aan dit project wordt in deze masterproef het bepalen van het vers- en drooggewicht van sla, gedurende een gehele teeltronde onder praktijkomstandigheden, op basis van RGB-afbeeldingen met behulp van een CNN onderzocht.

Het eerste deel van deze masterproef bestaat uit een literatuurstudie dat drie grote delen omvat. Bij het eerste gedeelte worden de algemene, economische, morfologische, en fysiologische aspecten van sla en de beschutte teelt ervan in een mobiele gotensysteem (MGS) besproken. Daaropvolgend wordt de toepassing van de RGB-camera bij plantfenotypering aangehaald. Tenslotte worden de basisprincipes van CNN's en het gebruik ervan bij de monitoring van sla besproken.

In het praktische deel van deze masterproef worden RGB-afbeeldingen verzameld van verschillende sla-cultivars. De cultivars worden elks twee keer zelf opgekweekt om slaplanten afkomstig van twee verschillende teeltrondes te bekomen. Daarnaast worden ook slaplanten van één bepaalde cultivar afkomstig van een externe slateler en van éénzelfde teeltronde gebruikt. Dit wordt gedaan om later te evalueren hoe het CNN-model presteert bij RGB-afbeeldingen van slaplanten afkomstig van verschillende cultivars en teeltrondes, alsook om na te gaan in welke mate het model robuust is bij variatie in sla-cultivars en teeltomstandigheden. Dit wordt gedaan omdat per bedrijf meerdere verschillende cultivars in diverse teeltrondes worden geteeld. Van de slaplanten van de desbetreffende cultivars worden RGB-afbeeldingen verzameld onder een camerahoek van 0°, 45° en 90° t.o.v. het grondoppervlak. Dit wordt uitgevoerd om later te evalueren hoe het CNN-model presteert bij RGB-afbeeldingen van slaplanten die onder verschillende camerahoeken worden genomen, en om na te gaan in welke mate het model robuust is bij variatie in camerahoeken zoals dit in de praktijk zou kunnen voorkomen. Na verzameling van de RGB-afbeeldingen van de slaplanten wordt zelf een CNN-model ontworpen met het meest accurate schattingsvermogen. Tenslotte wordt het schattings- en generalisatievermogen van het ontwikkelde CNN-model onderzocht.

2 LITERATUURSTUDIE


2.1 Algemene, economische, morfologische, en fysiologische aspecten van sla en de beschutte teelt in een mobiele gotensysteem (MGS)

Sla (*Lactuca sativa* L.) is een populair groentegewas dat wereldwijd wordt geteeld, met een hoge voedingswaarde en belangrijke economische waarde. De term “sla” omvat, botanisch gezien, alle planten behorende tot het geslacht *Lactuca*. Dit geslacht behoort tot de composietenfamilie (*Asteraceae*) wat de familie is van de samengesteldbloemigen (Benoit et al., 1989; Kraker et al., 1994; Křístková et al., 2008; Mou, 2008). Op basis van morfologische kenmerken worden de verschillende moderne commerciële slasoorten ingedeeld (Yang et al., 2022; Zhang et al., 2017). De indeling van de verschillende slasoorten is voornamelijk gebaseerd op kropvorming, stengeltype, bladvorm, -grootte en -textuur (Mou, 2008). Over het algemeen kunnen de verschillende slasoorten als volgt worden ingedeeld: ijssla (“Crisphead”; waarvan ijsbergsla de meeste bekende), botersla (“Butterhead”; ook bekend als kropsla), romeinse sla (Cos), bladsla (ook bekend als snijsla) en stengelsla (ook bekend als aspergesla) (Kraker et al., 1994; Mou, 2008; Shi et al., 2022; Zhang et al., 2017). De commerciële productie van sla in kassen, ten gevolge van zijn belangrijke economische waarde wereldwijd, is hierdoor al reeds sterk geautomatiseerd (Petropoulou et al., 2023). Het gebruik van onder andere zaai-, oogst- en reinigingsmachines, transportbanden, draaitafels, en liften aangestuurd door een geavanceerd besturingssysteem maken de geautomatiseerde productie van sla mogelijk waardoor besmettingsrisico's en arbeidskosten worden verlaagd terwijl de productie van sla wordt verhoogd (Bennett-Ciaglia, 2017). Het gebruik van moderne camerasystemen en AI-technologieën zorgen voor de verbetering van precisietuinbouwtoepassingen bij de teelt en dus ook de automatisering van sla onder glas (Javaid et al., 2023). Vele onderzoeken worden dan ook uitgevoerd rond het gebruik van moderne camerasystemen en AI-technologieën om sla met een hoge kwaliteit snel en in grote hoeveelheden te produceren (Hou et al., 2024). In de volgende subhoofdstukken wordt dieper ingegaan op de verschillende aspecten van het groentegewas sla (economische belang van sla, slateelt in België en Vlaanderen, morfologie en fysiologie van sla) en de teelt (beschutte teelt van sla in een mobiele gotensysteem) ervan.

2.1.1 Economisch belang van sla wereldwijd


Sla is wereldwijd één van de economisch belangrijkste bladgroenten met een breed scala aan toepassingen, gaande van salades tot medicinale producten (Das & Bhattacharjee, 2020; Shatilov et al., 2019). Sla is een populair groentegewas dat het hele jaar door, onder andere door de beschutte teelt, op de markt verkrijgbaar is (Gupta, 2023). Wereldwijd worden miljoenen tonnen sla per jaar geteeld. In het jaar 2023 bedroeg de wereldwijde productie van sla 28,08 miljoen ton (FAO, 2025; Das & Bhattacharjee, 2020). Volgens Shatilov et al. (2019) en cijfermateriaal afkomstig van de “Food and Agriculture Organization” (FAO) zijn China, India en de Verenigde Staten (VS) wereldwijd verantwoordelijk voor het grootste aandeel aan de productie en het teeltgebied van sla. China (14,73 miljoen ton in 2023) is het land met de grootste slaproductie per jaar met daaropvolgend de VS (4,67 miljoen ton in 2023) en India

(1,17 miljoen ton in 2023). Andere sla-producerende landen zijn onder andere België, Frankrijk, Italië, Japan, Mexico en Spanje (FAO, 2025; Das & Bhattacharjee, 2020). Figuur 2-1 geeft een overzicht van de verschillende sla-producerende landen wereldwijd. De wereldwijde teelt van sla kent momenteel een jaarlijks gemiddelde opbrengst van 22,20 ton per ha. Het land met wereldwijd de grootste sla-opbrengst is Puerto Rico (95,55 ton/ha in 2023), door het sterke gebruik van hydroponische teeltsystemen die hogere opbrengsten op een beperkte teeltoppervlakte mogelijk maken, gevolgd door Koeweit (48,70 ton/ha in 2023), Bahrein (47,31 ton/ha in 2023) en België (44,17 ton/ha in 2023). Wereldwijd heeft de teelt van sla een geregistreerd teeltgebied van ongeveer 1 miljoen ha met in 2023 een teeltgebied van 1,26 miljoen ha (Ag-Con, 2024; FAO, 2025; Shugrue, 2024).



Figuur 2-1 Noof. Wereldkaart met de verschillende sla-producerende landen in het jaar 2023. De verschillende kleuren van de sla-producerende landen zijn gelinkt aan de opbrengsten uitgedrukt in ton (t). Uit *Production of lettuce, 2023* door Food and Agriculture Organization of the United Nations. Food and Agriculture Organization of the United Nations, 2025. Copyright 2025 van Food and Agriculture Organization of the United Nations. Food and Agriculture Organization of the United Nations.

De teelt van sla is een interessante teelt voor vele telers aangezien sla een relatief winstgevend gewas is omdat de teeltperiode kort is en de opbrengsten relatief hoog zijn. Door de toenemende populariteit en vraag naar biologisch geteelde gewassen stijgt ook de vraag naar sla (Lal, 2024). Bovendien is sla over het algemeen een belangrijke en veelzijdige groente die verschillende voordelen biedt zoals het grote aanbod aan verschillende variëteiten, laag caloriegehalte en goede bron van essentiële voedingsstoffen zoals vitamines, mineralen en voedingsvezels, en een belangrijke rol speelt in de voedselvoorziening en de gastronomische keuken (Gupta, 2023; Lal, 2024). Daarnaast wijzen recente studies aan dat de vraag naar voedsel in de periode 2010-2050 met 35-56% zal toenemen als gevolg van onder andere de bevolkingstoename, economische ontwikkeling en verstedelijking in de wereld (van Dijk et al., 2021). Al deze zaken verklaren dan ook deels de jaarlijkse toename van de wereldproductie van sla doorheen de jaren (Figuur 2-2).



Figuur 2-2 Noot. De jaarlijkse wereldproductie van sla uitgedrukt in ton (t) uitgezet overheen een tijdsperiode van 1961 tot en met 2023. Uit *Production of lettuce, 2023* door Food and Agriculture Organization of the United Nations. Food and Agriculture Organization of the United Nations, 2025. Copyright 2025 van Food and Agriculture Organization of the United Nations. Food and Agriculture Organization of the United Nations.

2.1.2 Slateelt in België en Vlaanderen

Sla, met voornamelijk de kropsla, is op de tomaat (gemiddeld 276.383 ton per jaar) na de meest vermarktbare groente in België met een gemiddelde vermarktbare productie van 34.757 ton per jaar. De gemiddelde vermarktbare productie van de slateelt in openlucht bedraagt in België gemiddeld 6.680 ton per jaar terwijl deze van de beschutte teelt van sla gemiddeld 28.077 ton per jaar bedraagt. Dit betekent dat de beschutte teelt van sla in België voor het grootste deel verantwoordelijk is voor de vermarktbare productie van sla (80,8%) en de teelt van sla in open lucht slechts voor een kleiner gedeelte (19,2%) verantwoordelijk is. Jaarlijks wordt in België voor de teelt van sla in openlucht gebruik gemaakt van gemiddeld 220 ha teeltareaal en voor de beschutte teelt van sla jaarlijks een teeltareaal van gemiddeld 569,1 ha (VLAM, 2025). Volgens Derden et al. (2005) is 99,6% van het totale glasgroenteareaal van België gelegen in Vlaanderen. Dit betekent dat de beschutte teelt van sla in Vlaanderen naar schatting een gemiddeld teeltareaal van 566,8 ha heeft met een gemiddelde vermarktbare productie van 27.965 ton per jaar (Derden et al., 2005; VLAM, 2025).

2.1.3 Morfologie en fysiologie van sla

In deze paragraaf wordt dieper ingegaan op de morfologie en fysiologie van sla. Het wortelstelsel alsook de blad- en kropvorming van de slaplant met bijhorende invloedfactoren wordt besproken.

Het wortelstelsel van sla bestaat uit een centrale penwortel met korte horizontale zijwortels die het meest geconcentreerd liggen tegen het grondoppervlak voor water- en nutriëntopname (Kraker et al., 1994; Mou, 2008). De beworteling vindt hoofdzakelijk plaats in de zone 0-45 cm en daarbij vooral in de bovenste 15 cm (Kraker et al., 1994). Bij intensieve teelt onder glas overschrijdt de worteldiepte zelden deze van de bouwvoor (25-30 cm) aangezien meestal voldoende water en nutriënten zijn voorzien zodat diepere wortelgroei niet noodzakelijk is voor de slaplant. Voor voldoende wortelgroei is voldoende vocht en een voldoende hoge bodemtemperatuur (vanaf 4°C) vereist (Benoit et al., 1989).

In de vegetatieve fase van de slaplant zijn de bladeren spiraalvormig gerangschikt in een dichte rozet aan de voet van een vaak verkorte vlezige stengel (Kraker et al., 1994; Mou, 2008). De slabladeren zijn gekenmerkt door een sterke ontwikkeling van de bladschijf in verhouding tot het nerfsysteem, in het bijzonder de middennerf (Benoit et al., 1989). Tussen de verschillende slasoorten is een grote diversiteit in kleur, vorm, oppervlak, rand en textuur van de bladeren aanwezig. De bladranden van de slaplant kunnen gaaf, gelobd, ingesneden, ingekeept of golvend zijn wat vaak soortafhankelijk is. De kleur van de slabladeren varieert van geelgroen tot donkergroen met verschillende mate van glanzendheid (Benoit et al., 1989; Mou, 2008). Bovendien kan de aanwezigheid van het in wateroplosbare niet-fotosynthetische pigment anthocyaan, verantwoordelijk voor de rode, blauwe en paarse kleuring in planten, ervoor zorgen dat alle slabladeren of een deel ervan, of in een vlekkenpatroon of alleen langs de randen rood(groen) tot paars gekleurd worden. De anthocyaanvorming en -concentratie in het blad is afhankelijk van de slasoort en omgevingsomstandigheden, zoals licht (kwaliteit en intensiteit) en temperatuur (meestal bij lage temperaturen) (Benoit et al., 1989; Kraker et al., 1994; Mou, 2008; Owen & Lopez, 2015; Palsha et al., 2024). Onderzoek uitgevoerd door Soufi et al. (2023) toonde aan dat een combinatie van rood en blauw licht (rood/blauw-verhouding van 3:1) resulteerde in een toename van de anthocyaanvorming en -concentratie bij sla, dezelfde conclusie werd getrokken door Sng et al. (2021). Song et al. (2020) alsook Y. Zhang et al. (2018) toonden aan dat hogere lichtintensiteiten konden leiden tot hogere anthocyaangehaltes. Daarnaast concludeerde Boo et al., (2011) dat de teelt van sla bij lagere temperaturen gepaard ging met hogere anthocyaangehaltes.

Naast het feit dat bij bepaalde slasoorten, zoals eikenbladsla, de bladeren rozetvormig staan ingeplant zijn er ook slasoorten, zoals ijsbergsla, waarbij na rozetvorming nog een kropvorming plaatsvindt. De rozetbladeren van kropvormende slasoorten zijn meestal plat uitgespreid en functioneren als fotosynthetische organen. Wanneer de slaplant 10-12 bladeren heeft geproduceerd, vouwen de nieuwe bladeren naar binnen om een bladkrop te vormen (Yu et al., 2020). Een goede kropvorming bij sla geschiedt enkel wanneer een ideaal aantal brede bladeren gevormd worden op een vegetatieve stengel waarvan het volume beperkt is en wanneer de middennerf van deze bladeren voldoende naar binnen buigt. Bepalende groeifactoren voor kropvorming zijn licht, temperatuur en CO₂. De kropvorming van sla vindt plaats in 3 fases: aanlooperperiode, opbouwperiode en afrijpingsperiode (Benoit et al., 1989). Bij de aanlooperperiode gaat de bladvorm van de eerste 10-15 bladeren geleidelijk over van smal ovaal naar breed rond, met een lengte dat ongeveer gelijk is aan de hoogte. Bij deze periode is het van belang dat deze buitenste bladeren zo groot mogelijk uitgroeien en zo lang mogelijk een horizontale stand behouden om, vooral in periodes met weinig licht, zoveel mogelijk licht op te vangen. De invloeden van deze lichtcaptatie worden doorgegeven aan de binnenste bladschijven en -hoofdnerven. In de opbouwperiode gebeurt de vorming van de kropvormende bladeren. Vooral in deze periode is de invloed van de groeifactoren licht, temperatuur en CO₂ op de kropvorming het grootst. Een te lage lichtintensiteit veroorzaakt smalle en lange bladeren. Daarenboven zal de stengel van de sla te lang worden en door een vertraagde bladaanleg zullen op deze al reeds te lange stengel te weinig bladeren ontwikkelen met een losse krop als gevolg. Bij onvoldoende lichthoeveelheid zal de bladbreedte worden beperkt terwijl voor een ideale krop de bladbreedte minstens gelijk moet zijn aan de bladlengte. Een lage temperatuur, vooral tijdens de nacht, beperkt de uitgroei van de middennerf van het blad en daarmee ook van de bladlengte. Bij een te hoge gemiddelde temperatuur (> 20°C) kan een te lage lichtintensiteit de oorzaak zijn dat de middennerven van de buitenste bladeren onvoldoende naar binnen toe krommen. Anderzijds kan een te hoge lichtintensiteit een te

snelle bladaanleg veroorzaken zodat een te groot aantal bladeren elkaar verdringen op het beperkte stengelvolume en dus eveneens een te losse krop ontstaat. Een hoge CO₂-concentratie gaat in hoofdzaak zorgen voor brede bladeren, maar zal ook het aantal bladeren verhogen. Als laatste vindt de afrijpingsperiode plaats waarbij de sla op gewicht komt door het strekken van de vele bladeren (kropbladeren) die in aanleg aanwezig waren in de groeipunt (Benoit et al., 1989).


2.1.4 Beschutte teelt van sla in een mobiele gotensysteem (MGS)

Bij deze masterproef worden de slaplanten onder glas opgekweekt in een hydroponisch mobiele gotensysteem (MGS). Het MGS is een teeltsysteem dat courant wordt toegepast voor de beschutte teelt van sla. In 2018 werd MGS in Vlaanderen al reeds toegepast op 15 slateeltbedrijven (Nawara et al., 2019). De werking van het MGS is gelijkaardig aan deze van het hydroponische nutriëntenfilmtechniek (NFT)-systeem. Bij NFT circuleert een voedingsoplossing door het gehele teeltsysteem doormiddel van een constante ondiepe waterstroom met opgeloste voedingsstoffen dat in waterdichte goten over de wortels van de planten stroomt (Domingues et al., 2012; Majid et al., 2021; Petropoulou et al., 2023). Zuurstofrijke omstandigheden worden gecreëerd door de waterstroming en -diepte van het systeem te regelen (Benton Jones Jr, 2016). De voedingsoplossing wordt aanvankelijk opgeslagen in een reservoir waarna het onder een hoek in de goten wordt gepompt en vervolgens constant rond de wortels van de planten stroomt (Domingues et al., 2012; Petropoulou et al., 2023). Uiteindelijk wordt de voedingsoplossing afgevoerd (drainwater) naar een tank voor filtering voordat het wordt teruggepompt naar het reservoir voor hergebruik. Bij NFT staan de goten, en dus ook de slaplanten, op een vaste afstand van elkaar waardoor bij dit teeltsysteem de teeltoppervlakte alsook het beschikbare licht minder efficiënt wordt gebruikt voor de teelt van sla. Dit probleem komt niet voor bij MGS waarbij gedurende het ontwikkelingsstadia van de slaplant de gootafstand geleidelijk aan wordt verruimd, waardoor de slaplanten meer groeiruimte verkrijgen om groeibelemming en morfologische belemmering van de slaplant te voorkomen (Nawara et al., 2019). Hierdoor wordt bij MGS de beschikbare teeltoppervlakte en licht efficiënter gebruikt waardoor MGS kan gezien worden als een verbeterde versie van het NFT-systeem.

De meeste MGS-bedrijven besteden de opkweek van slaplantgoed, vaak perspotplanten, uit aan gespecialiseerde opkweekbedrijven (Nawara et al., 2019). Wanneer de slaplanten, voorzien van een perspot, toekomen bij de slateler worden deze eerst gedurende 1-2 weken geplaatst op de voor-opkweek, dit geeft de planten de tijd om te acclimatiseren (Nawara et al., 2019; Snoeck et al., 1985). Bijkomend worden de slaplanten van water en gewasbeschermingsmiddelen voorzien via sproeijs van bovenaf. Tijdens de voor-opkweekfase bedraagt de plantdichtheid 100 planten per vierkante meter (m²). Bij de voor-opkweek staan de slaplanten nog niet in goten, dit gebeurt wanneer de voor-opkweek fase afgelopen is. Wanneer de voor-opkweekfase voorbij is worden de planten manueel of via een planrobot in de goten van het MGS geplaatst aan een dichtheid van 40 planten per m². Vanaf de plaatsing op de goten worden de slaplanten van water en nutriënten voorzien via een dunne voedingsfilm dat doorheen het gehele teeltsysteem circuleert (cfr. het NFT-systeem). De goten bewegen verder uit elkaar naarmate de slaplanten verder ontwikkelen. De slaplanten bewegen automatisch van de plantzone naar de oogstzone met een finale plantdichtheid van 14 planten per m². Naarmate de plant groeit verandert de samenstelling van de voedingsoplossing, maar ook het irrigatieschema. Hierdoor is het MGS-systeem opgesplitst in 5 secties, de

zogenaamde kraanvakken. Bij het opplanten starten de jonge slaplanten op kraanvak één en schuiven door naar kraanvak vijf op het einde van de teeltcyclus. Het drainwater van kraanvakken één tot drie wordt samen opgevangen omwille van de specifieke samenstelling van de voedingsoplossing. Hetzelfde geldt voor kraanvakken vier tot vijf. Dit wordt schematisch weergegeven in Figuur 2-3a. De goten voor de teelt van sla op het MGS staan onder een helling van meer dan $0,5^\circ$ waarvan de hellingsgraad kan variëren. Hierdoor stroomt de voedingsoplossing langs één kant van de goot binnen en vervolgens gravitair naar het andere uiteinde van de goot (Figuur 2-3b). Standaard bedraagt de drain ongeveer 95% van het inkomende water waardoor de volumes water die gerecirculeerd en gezuiverd moeten worden groot zijn. De zuivering gebeurt standaard door een snelle zandfilter en een actieve kool filter die samen terug zuiver drainwater creëren dat opnieuw naar de slaplanten wordt gepompt. De snelle zandfilter zorgt voor de verwijdering van partikels aanwezig in het vuile drainwater en de actieve kool filter voor de verwijdering van wortellexudaten en gewasbeschermingsmiddelen. Dit zuiveringssysteem is bij MGS tweemaal aanwezig: één systeem om de vuile drain van kraanvak één tot en met drie te zuiveren en één systeem om de vuile drain van kraanvak vier en vijf te zuiveren. Standaard zit nog geen ontsmetting bij in het zuiveringssysteem (Nawara et al., 2019).

Wanneer de slakroppen volgroeid zijn worden deze naar de oogst ruimte gebracht. Daar worden de slaplanten, machinaal of handmatig, uit de goten gehaald en verplaatst naar de verpakkingsafdeling. Ondertussen worden de goten gereinigd, waarna het teeltproces opnieuw begint (Petropoulou et al., 2023). Het oogstgewicht van de slaplant is afhankelijk van de slasoort dat wordt geteeld, zo wordt kropsla geoogst bij een kropgewicht van ca. 350 gram terwijl ijssla eerder wordt geoogst bij een kropgewicht van ca. 600 gram (Snoeck et al., 1985). Daarnaast is het oogstgewicht niet alleen cultivarafhankelijk, maar ook verschillend per land. Zo wordt in België onder glas de zwaarste sla op water geteeld waarbij het oogstgewicht van kropsla kan oplopen tot 500 gram per krop en bij rossa, bionda en eikenblad tot ongeveer 350 gram per krop. Terwijl in Noord- en Midden Amerika kropsla van 250 gram per krop eerder populair is (Rijk Zwaan, 2009; Stijger, 2022; Visser, 2022).




Figuur 2-3 Noot. Schematische weergaven van de werking van het mobiele gotensysteem (MGS) met (a) de algemene werking van het MGS dat is opgedeeld in de voor-opkweek en de vijf verschillende kraanvakken; (b) de voedingsfilmstroming bij de teelt van sla op het MGS. (Aangepast) uit *OUTPUT 5.2A: "TWEELIJSTEN MET SELECTIECRITERIA VOOR DE VERSCHILLENDE ZUIVERINGSSTAPPEN SPECIFIEK VOOR DE WATERZUIVERING VAN I.) TRAYVELDEN VOOR AARDBEI EN II.) MOBIELE GOTENSYSTEEM VOOR SLA"* door S. Nawara et al.. Nawara et al., 2019. 1(1), 7-8. Copyright 2019 van S. Nawara et al.. Nawara et al..

2.2 Toepassing van de RGB-camera bij plantfenotypering

2.2.1 Basisprincipes bij het gebruik van beeldvormingstechnieken

Beeldvormingstechnieken worden gebruikt om complexe eigenschappen van planten te kwantificeren voor plantfenotypering in gecontroleerde teeltsystemen (in groeikamers of kassen) of in open lucht. Op basis van afbeeldingen, die bekomen kunnen worden via verschillende beeldvormingstechnieken, van het fenotype van de plant vertrouwen kwantitatieve metingen voor complexe eigenschappen voornamelijk op algoritmen voor beeldverwerking. Bij het gebruik van beeldvormingstechnieken worden elektromagnetische golven als detectie-informatiedragers beschouwd (L. Li et al., 2014). Elk onderdeel van plantencellen en -weefsels heeft golflengte-specifieke absorptie-, reflectie- en transmissie-eigenschappen. Het effect van de kwalitatieve verandering van het lichtspectra, ten gevolge van interactie met de plant, is gerelateerd aan de absorptie van zichtbaar licht (400-700 nm) door plantpigmenten (voornamelijk fotosynthetische pigmenten zoals chlorofyl a, chlorofyl b en carotenoïden), de absorptie van kortgolvig infraroodlicht (1200-2400 nm) door water, eiwitten en andere koolstofbestanddelen en de verstrooiing van nabij-infraroodlicht (700-1200 nm) door de interne structuren van de bladeren (Figuur 2-4) (Jayasuriya et al., 2024; Kior et al., 2024; Li et al., 2014). Zichtbare beeldvorming, waar RGB-beeldvorming onder valt, wordt voornamelijk gebruikt om verschillende aspecten van de plantarchitectuur te meten zoals de scheutbiomassa, bladoppervlak, kleur en beoordelingen van de ernst van bladziekten (L. Li et al., 2014).



Figuur 2-4 Noot. De spectrale reflectiecurve van planten. De belangrijkste absorptie- en reflectie-eigenschappen zijn aangegeven. Uit *LANDSCAPE ARCHAEOLOGY ON THE NORTHERN FRONTIER OF THE ROMAN EMPIRE AT POROLISSUM*, door A. Roman & T. Ursu, 2016. Copyright 2016 van A. Roman & T. Ursu.

2.2.2 Werking en principes van een RGB-camera

De populairste en meest gebruikte methode voor het meten van morfologische kenmerken van planten of plantorganen, biomassa en plantengroei is RGB-beeldvorming, ook bekend als beeldvorming met zichtbaar licht (Jayasuriya et al., 2024). Het veelzijdige gebruik van deze beeldvormingstechniek is te danken aan de technische eenvoud en brede toegankelijkheid ervan alsook de lage kosten en hoge resolutie van RGB-camera's, ook wel gekend als de alledaagse normale camera's (Guo et al., 2021; Jang et al., 2020; Jayasuriya et al., 2024; Kior et al., 2021; Kior et al., 2024). RGB-beeldvorming is gebaseerd op de meting van reflectie in rode (R), groene (G) en blauwe (B) spectrale banden wat de beeldvorming bij plantfenotypering technisch eenvoudig en breed toegankelijk maakt (Kior et al., 2024). De beeldvormingsapparatuur dat wordt gebruikt voor RGB-beeldvorming zijn RGB-camera's die het RGB-bereik van het elektromagnetische spectrum (400-700nm) vastleggen dat met het blote oog zichtbaar is (Jayasuriya et al., 2024). Deze RGB-camera's bieden een hoge ruimtelijke resolutie van stralingswaarden in de rode (~600 nm), groene (~550 nm) en blauwe (~450 nm) spectrale banden (Jang et al., 2020; Kior et al., 2021; Li et al., 2014).


Een RGB-camera is opgebouwd uit vijf basiscomponenten: lens, behuizing, Bayer-filter, beeldsensor en "Image Signal Processor" (ISP) (Figuur 2-5). Deze vijf componenten maken de beeldvorming van de RGB-camera mogelijk. De lens, ook wel fotografische lens genoemd, is een apparaat dat in staat om een beeld te verzamelen en te reproduceren (Ceccarelli & Secci, 2023). De behuizing van de RGB-camera is de plaats waar de elektronica van de camera namelijk de Bayer-filter, beeldsensor en de ISP in aanwezig zijn. De functie van de behuizing is het beveiligen van het apparaat en het beschermen van de interne componenten (Bayer-filter, beeldfilter en ISP) tegen blootstelling aan en contact met de buitenwereld (Ceccarelli & Secci, 2023).

De beeldsensor van de RGB-camera is als het ware de omvormer die het beeld omzet in een representatieve of elektrische codering. De beeldsensor is een siliciumchip die het licht kan opvangen en meten, namelijk het aantal fotonen dat de chip bereikt. Het sensoroppervlak van de beeldsensor bestaat uit miljoenen kleine ontvangers die in een regelmatig rooster zijn gerangschikt. Deze ontvangers, ook wel fotosites of fotodiodes (af en toe ook wel pixelsites) genoemd, zijn de microsensoren die de omzetting van fotonen naar elektronen uitvoeren (Ceccarelli & Secci, 2023; Damon, 2025). Elke fotosite kan een elektrische lading leveren evenredig met het aantal fotonen dat erop valt. Vervolgens wordt de gedetecteerde lading door een speciale analoog-digitaal conversiecircuit omgezet in numerieke waarden. Elk van de waarden verkregen uit de fotosites vormt een pixel van het verkregen beeld bekomen door de RGB-camera (Ceccarelli & Secci, 2023).

De Bayer-filter, ook wel Bayer-patroon genoemd, wordt gebruikt voor het verkrijgen van (gekleurde) digitale beelden. De fotodiodes aanwezig in de beeldsensor zijn als het ware van nature kleurenblind. Dit is omdat de fotodiodes enkel lichtenergie (fotonen) omzetten in elektrische energie (elektronen), dit betekent dat ongeacht welke lichtkleur een bepaalde fotodiode bereikt het alleen de lichtintensiteit zal kunnen waarnemen en niet de kleur. Hierdoor zal zonder een Bayer-filter alleen een grijs getint beeld bekomen worden zoals bij monochrome camera's (die geen kleurenfilter hebben) (Ceccarelli & Secci, 2023; Supertrek, 2024; TechNexion, 2025). Om de kleur in het beeld te verkrijgen worden de fotodiodes bedekt met verschillende kleurfilters: rood, groen, en blauw (RGB) volgens het model dat wordt aangegeven door de Bayer-filter (Figuur 2-5). Deze filter groepeerde de sensoren voor de drie fundamentele kleuren RGB in cellen van 2x2 fotosites: elke bevat twee groene elementen

(50% groen), één rood element (25% rood) en één blauw element (25% blauw) (Ceccarelli & Secci, 2023; Kior et al., 2021). De groene elementen (pixels) komen vaker voor (50% groen) vanwege de gevoeligheid van het menselijk oog voor groen licht, wat resulteert in meer zichtbare 'beelden' (TechNexion, 2025).

De "Image Signal Processor" (ISP) is een gespecialiseerde mediaprocessor die wordt gebruikt voor beeldverwerking in digitale camera's. De ISP produceert het uiteindelijke digitale beeld en heeft vele functies zoals correctie van de beeldscherpte, correctie van de beeldsensor, formaatwijziging van het beeld en correctie van de lensvorming (Ceccarelli & Secci, 2023).



Figuur 2-5 Noot. Weergave van het verloop van de RGB-beeldvorming via de vijf verschillende basiscomponenten van een RGB-camera: lens, behuizing ("camerabody"), Bayer filter, beeldsensor ("Image sensor") en ISP ("Image Signal Processor"). Daarnaast is een weergave aanwezig van het model van de Bayer filter met een uitvergroting van een 2x2 fotosite met twee groene elementen (50% groen), één rood element (25% rood) en één blauw element (25% blauw). Aangepast uit "RGB Cameras Failures and Their Effects in Autonomous Driving Applications" door A. Ceccarelli en F. Secci, 2023, *IEEE TRANSACTIONS ON DEPENDABLE AND SECURE COMPUTING*, 20(4), 2731-2745. Copyright 2023 van A. Ceccarelli en F. Secci. Ceccarelli en Secci.

2.2.3 Toepassingen van RGB-camera's in gewasmonitoring

Binnen de plantkunde kennen RGB-camera's een breed toepassingsgebied. Zoals eerder aangehaald (zie 2.2.2) is het veelzijdige gebruik te danken aan de technische eenvoud en brede toegankelijkheid alsook de lage kosten en hoge resolutie van deze camera's (Guo et al., 2021; Jang et al., 2020; Kior et al., 2021; Kior et al., 2024). Voor RGB-beeldverzameling worden zowel conventionele camera's (verschillende modellen van Canon, zoals EOS Rebel; Liu et al., 2024), industriële camera's (zoals de HW500 van Shenzhen Huawang Technology; Y. Li et al., 2024), en smartphonecamera's op grote schaal gebruikt met goede prestaties (Rui et al., 2024).

De (technische) eenvoud van de RGB-camera maakt dat verschillende meetopstellingen kunnen worden gebruikt voor RGB-beeldvorming bij plantfenotypering. Onder meetopstelling kan het volgende worden verstaan: draagbare apparaten (zoals fotocamera's of mobiele telefoons) voor korte en middelgrote afstanden tot de plant, voertuigen op land (zoals tractoren) voor middelgrote afstanden, onbemande luchtvaartuigen ("unmanned aerial vehicle", UAV) (zoals drones) die worden gebruikt voor gemiddelde en grote afstanden, vliegtuigen voor grote afstanden en satellieten voor extreem grote afstanden tot de plant (Guo et al., 2021; Kior et al., 2024). Daarnaast kan het type meetopstelling verschillen afhankelijk van de toepassing van de RGB-camera in gecontroleerde (serre of groeikamer) of ongecontroleerde (open lucht) omstandigheden (Araus & Cairns, 2014). Voor fenotypering in een gecontroleerde omgeving zoals kassen, kunnen nauwkeurigere RGB-camerabeelden verkregen worden in vergelijking bij veldfenotypering. Fenotypering doormiddel van RGB-camera's in gecontroleerde omgevingen maakt meer gedetailleerde metingen mogelijk dan bij veldfenotypering door de beperking van extrinsieke factoren zoals wind of neerslag (Shafiekhani et al., 2017).

Bovendien maken RGB-camera's toepassingen in nauwkeurige en snelle morfologische fenotypering mogelijk, zoals ziekte- en plantoppervlakedetectie, kleurenanalyse en 3D-modellering (Deery et al., 2014; Kim & Chung, 2021; Kuska & Mahlein, 2018; Liu et al., 2017). Over het algemeen kunnen RGB-camera's ingezet worden voor volgende fenotypische kenmerken van de plant: vorm, kleur, grootte, biomassa, pigmentgehalte, ziekten en plagen, abiotische stressreacties, nutriëntengebreken en vegetatie-indices. Samen met de vele voordelen kennen RGB-camera's vele mogelijke toepassingen binnen gewasmonitoring: groeibewaking, detectie van stress bij planten, schatting van de rijpheid, classificatie en sorteren, kwaliteits- en opbrengstbeoordeling, 3D-modellering, gewasbeheer en robotoogst (Abebe et al., 2023). Verschillende toepassingen van RGB-camera's in gewasmonitoring worden weergegeven in Tabel 2-1.

Voor de gewasmonitoring van sla bestaan momenteel ook al enkele toepassingen van RGB-camera's. Bij een onderzoek uitgevoerd door Seki & Toda (2022) werd een neurale netwerk (Mask R-CNN) ontwikkeld voor de kwantificering van morfologische parameters, zoals breedte, lengte en oppervlakte, van slazaden waarbij een digitale camera werd gebruikt voor het vastleggen van de beelden van de slazaden. De combinatie van het neurale netwerk met een digitale camera voor beeldverzameling maakte het mogelijk om fenotypische gegevens van 42.036 slazaden te verkrijgen, wat handmatig onmogelijk zou zijn. De studie van Seki & Toda (2022) toonde aan dat nauwkeurige fenotypering door automatisering met behulp van deep learning, zelfs bij kleine plantgroottes, toegepast zou kunnen worden op analyses met behulp van RGB-camerabeelden gemaakt door microscopen of drones. Zhang et al. (2020) stelde een methode voor om de groei van kassla te monitoren met behulp van digitale beelden en een convolutional neural network (CNN). Er werd een CNN-model ontwikkeld voor het schatten van groeigerelateerde kenmerken, namelijk de bladoppervlakte en vers- en drooggewicht, van meerdere sla-cultivars met behulp van digitale camerabeelden. Uit het onderzoek bleek dat de geschatte groeigerelateerde kenmerken een goede overeenkomst vertoonden met de werkelijke groeigerelateerde kenmerken. Uit het onderzoek van Zhang et al. (2020) werd geconcludeerd dat het gebruik van een digitale camera in combinatie met een CNN een betrouwbare methode is voor het schatten van groeigerelateerde kenmerken van kassla en potentieel heeft als toepassing voor groeimonitoring.

Tabel 2-1 Toepassingen van RGB-camera's voor gewasmonitoring van verschillende land- en tuinbouwgewassen. Onbemande luchtvaartuigen worden weergegeven onder de term UAV ("unmanned aerial vehicle") en artificiële intelligentie onder de term AI.

Gewas	Toepassing	Meetomgeving	Meetopstelling	Beeldverwerking	Referentie
Sla	Zaadmorphologie	Laboratorium	Digitale camera zonder statief	AI-model	Seki & Toda, 2022
	Plantengroei	Serre	Digitale camera met statief	AI-model	Zhang et al., 2020
Appel	Zaadmorphologie	Laboratorium	Flatbedscanner	Discriminantanalyse	Ropelewska & Rutkowski, 2021
	Plantengroei	Open lucht	UAV	AI-model	Wu et al., 2020
	Detectie van vruchten	Open lucht	Voertuig op land	AI-model	Fu et al., 2020
	Opbrengstvoorspelling	Open lucht	Digitale camera zonder statief	AI-model	Ge et al., 2022
	Detectie en in kaart brengen echte meeldauw-besmetting	Open lucht	UAV	Vegetatie-index	Chandel et al., 2021
Banaan	Vruchtrijpheid	Laboratorium	Digitale camera met statief	Classificatiealgoritme	Surya Prabha & Satheesh Kumar, 2015
	Monitoring bananenziekten	Open lucht	UAV	AI-model	Calou et al., 2020; Gomez Selvaraj et al., 2020
Druif	Vruchten telling ter ondersteuning van opbrengstschatting	Open lucht	Mobiele telefoon zonder statief	Telalgoritme	Liu et al., 2020
	Vruchtrijpheid	Laboratorium	Digitale camera met statief	AI-model	Ramos et al., 2021
	Opbrengstvoorspelling	Open lucht	Voertuig op land	AI-model	Olenskyj et al., 2022
Mango	Vruchtdetectie	Open lucht	UAV	AI-model	Xiong et al., 2020
Peer	Plantengroei	Open lucht	UAV	Vegetatie-index	Guo et al., 2021
Aardbei	Vruchtmorfologie	Laboratorium	Digitale camera met statief	AI-model	Feldmann et al., 2020
	Scheutbiomassa	Open lucht	Voertuig op land	AI-model	Zheng et al., 2022
	Opbrengstvoorspelling	Open lucht	UAV	AI-model	Chen et al., 2019
Kool	Zaadmorphologie	Laboratorium	Digitale camera met statief	AI-model	Huang & Cheng, 2017
	Plantengroei	Open lucht	UAV	Wiskundig model + Vegetatie-index	Kim et al., 2018
Cassave	Carotenoïdegehalte	Laboratorium	Digitale camera met statief	AI-model	Carvalho et al., 2022
	Plantengroei	Serre	Digitale camera met statief	Regressiemodel + Vegetatie-index	Wasonga et al., 2021
	Monitoring bacteriële bladplekkenziekte	Laboratorium	Digitale camera zonder statief	AI-model	Elliott et al., 2022
Aardappel	Gewasopkomst	Open lucht	UAV	Beeldanalyse-algoritme	Li et al., 2019
	Knolgrootte	Laboratorium	Digitale camera met statief	Beeldanalyse-algoritme	Si et al., 2017
	Stikstofgehalte	Open lucht	UAV	Schattingsmodel + Vegetatie-index	Fan et al., 2022
	Monitoring aardappelziekte (<i>Solanum tuberosum</i> L.)	Open lucht	UAV	Beeldanalyse-algoritme	Sugiura et al., 2016
Tomaat	Voorspelling gewasopbrengst en scheutbiomassa	Open lucht	UAV	AI-model	Johansen et al., 2020
	Vruchtmorfologie	Laboratorium	Digitale camera met statief	AI-model	Zhu et al., 2022
	Opbrengstvoorspelling	Open lucht	UAV	Lineair regressiemodel	Chang et al., 2021

2.3 Convolutional Neural Networks (CNN's) en het gebruik ervan bij de monitoring van sla

2.3.1 Basisprincipes van CNN

Een convolutional neural network (CNN) is een artificieel model voor het verwerken van gegevens met een rasterpatroon, zoals afbeeldingen, en is ontworpen om automatisch en adaptief ruimtelijke hiërarchieën van kenmerken te leren. Een CNN is over het algemeen samengesteld uit een opeenstapeling van drie soorten lagen (of bouwstenen): convolutie-, pooling- en volledig verbonden (ook wel *fully connected* of kortweg FC) lagen. De convolutie- en poolinglagen voeren kenmerkenextracties uit, van bijvoorbeeld een afbeelding van een slapant, terwijl een volledig verbonden laag de, door convolutie- en poolinglagen, geëxtraheerde kenmerken in kaart brengt aan de uiteindelijke uitgang (of output) van het CNN. Een typische CNN-opbouw bestaat uit het herhalen van een opeenstapeling van meerdere convolutielagen en een poolinglaag, gevolgd door één of meer FC-lagen (Figuur 2-6). Van de beschreven convolutie- en poolingbewerkingen voor tweedimensionale (2D) CNN's, die hier verder worden uitgelegd, kunnen soortgelijke bewerkingen ook worden uitgevoerd voor driedimensionale (3D) CNN's (Yamashita et al., 2018).


Om verdere uitleg over de (2D-) CNN-architectuur beter te begrijpen is het handig om te weten dat in digitale beelden de pixelwaarden worden opgeslagen in een 2D-raster, dat wil zeggen een matrix van getallen. Een computer ziet namelijk een afbeelding als een matrix van getallen die elk overeenkomen met een bepaalde pixelhelderheid (Yamashita et al., 2018).

Een convolutielaag is een fundamenteel onderdeel van de CNN-architectuur dat kenmerkenextractie uitvoert. Deze laag bestaat doorgaans uit een combinatie van lineaire bewerkingen (convolutiebewerking) en niet-lineaire bewerkingen (activeringsfunctie). Convolutiebewerking is een gespecialiseerd type lineaire bewerking dat wordt gebruikt voor kenmerkextractie, waarbij een kleine matrix van getallen (*kernel*) wordt toegepast op de *input* (ingevoerde data) dat ook een matrix van getallen is (*tensor*). De kernel schuift stapsgewijs over de invoertensor. Op elke positie van de invoertensor wordt een elementgewijs product berekend tussen elk element van de kernel en de invoertensor. De resultaten van deze elementgewijze producten worden vervolgens opgeteld om de uitvoerwaarde op de corresponderende positie in de uitvoertensor te verkrijgen, de zogenaamde kenmerkenkaart (*feature map*). Deze procedure wordt herhaald door het toepassen van meerdere kernels om een willekeurig aantal kenmerkkaarten te vormen die verschillende kenmerken van de invoertensoren vertegenwoordigen zoals randen, kleuren of bepaalde structuren. De verschillende kernels kunnen dus worden beschouwd als verschillende kenmerkextractors (of simpelweg filters) die over de input (afbeelding of ook wel invoertensor genoemd) worden geschoven en de kenmerken van die input "extraheren" (Figuur 2-6) (Ketkar & Moolayil, 2021; Rathor et al., 2025; Yamashita et al., 2018). In de convolutielaag worden de *outputs* (kenmerkextracties) afkomstig van de convolutiebewerking verder geleid door een niet-lineaire activeringsfunctie. Deze niet-lineaire activeringsfunctie wordt gebruikt om een niet-lineariteit in het CNN te introduceren. De niet-lineaire activeringsfunctie dat momenteel het meeste wordt toegepast is de gelijkgerichte lineaire eenheid (*Rectified Linear Unit* - ReLU) die de functie $f(x) = \max(0, x)$ berekent (Indolia et al., 2018; Yamashita et al., 2018).

De laag die de convolutielaag opvolgt is de poolinglaag (Figuur 2-6). De poolinglaag biedt een typische downsamplingbewerking waarbij de afmetingen van de kenmerkkaarten wordt

verkleind. Bij dit proces wordt een verzameling aan waarden samengevoegd tot een kleiner aantal waarden, wat leidt tot een reductie van de afmetingen van de kenmerkenmap. *Pooling* transformeert de gecombineerde representatie aan kenmerken, afkomstig van de convolutielaag, in waardevolle informatie door nuttige informatie te behouden en irrelevante informatie te verwijderen (Gholamalinezhad & Khosravi, 2020). Hierdoor vermindert pooling de rekenkundige complexiteit en de geheugenvereisten aangezien het de resolutie van de kenmerkenmappen vermindert terwijl de belangrijke kenmerken die nodig zijn voor verwerking in de volgende lagen behouden blijven (Nirthika et al., 2022). Daarnaast zorgt pooling voor het introduceren van translatie-invariantie, dit is het vermogen van een netwerk om een object correct te herkennen zelfs wanneer het object verplaatst is op de afbeelding, in kleine verschuivingen en vervormingen. Bovendien zorgt pooling voor het beheersen van *overfitting*, dit wil zeggen dat het model de irrelevante informatie onthoudt in plaats van de relevante informatie te leren. Hierdoor zal het model minder goed presteren op een volgende nieuwe dataset (Yamashita et al., 2018).

De laatste laag dat in een CNN voorkomt is de volledig verbonden laag. De kenmerkkaarten afkomstig van de convolutie- en poolinglaag worden doorgaans afgeplat, dit betekent getransformeerd tot een ééndimensionale (1D) matrix met getallen (of vectoren), en zijn verbonden met één of meer volledig verbonden lagen waarin elke input via een leerbaar gewicht is verbonden met elke output. Zodra de door de convolutielagen geëxtraheerde en door de poolinglagen gedownsampledde kenmerken zijn gecreëerd, worden deze door een subset van volledig verbonden lagen toegewezen aan de uiteindelijke outputs van het netwerk, zoals bijvoorbeeld de waarschijnlijkheden voor elke klasse in classificatietaken. Elke volledig verbonden laag wordt gevolgd door een niet-lineaire activeringsfunctie, zoals ReLU, zoals hiervoor beschreven (Yamashita et al., 2018). De reeks convolutie- en poolinglagen genereren de kenmerken (van de afbeelding) en een volledig verbonden laag (of een reeks van verbonden lagen) leert de uiteindelijke classificatie-/regressiefunctie op basis van deze gegenereerde kenmerken. Dit wil dus zeggen dat één of meerdere verbonden lagen beslissingen nemen op basis van de gegenereerde kenmerken afkomstig van de convolutie- en poolinglagen (Ketkar & Moolayil, 2021). Visueel gezien bestaat een volledig verbonden laag uit verschillende knooppunten (neuronen) die rechtstreeks verbonden zijn met de knooppunten in de twee aangrenzende lagen, zonder dat deze knooppunten (van dezelfde laag) onderling verbonden zijn (Figuur 2-6) (O'Shea & Nash, 2015). Op de laatste volledig verbonden laag wordt een activeringsfunctie toegepast die meestal verschilt van de activeringsfuncties op de andere volledig verbonden lagen. Afhankelijk van de taak, zoals het voorspellen van een continu getal of het kiezen van een bepaalde klasse uit meerdere mogelijke klassen, dat een CNN moet uitvoeren moet een geschikte activeringsfunctie worden geselecteerd (Yamashita et al., 2018).



Figuur 2-6 Noof. Schematische weergave van de architectuur en werking van een convolutional neural network (CNN). Aangepast uit [CNN] Convolutional Neural Network, door L. Seok-young, 2021. Copyright 2021 van L. Seok-young.

2.3.2 Het gebruik van CNN's voor de groeimonitoring van kassla

In een studie van Zhang et al. (2020) werd een methode voorgesteld voor het monitoren van de groei van drie cultivars van kassla, namelijk Flandria, Tiberius en Locarno, met behulp van RGB-Diepte-beelden (RGB-D-beelden) en een CNN. Het doel van deze studie was om nauwkeurige schattingen te maken van groei-gerelateerde eigenschappen, namelijk vers- en drooggewicht en het bladoppervlak, van sla in de beschutte teelt. In deze studie werd een CNN gebruikt om de relatie te modelleren tussen een RGB-D-afbeelding van sla en de bijhorende groei-gerelateerde eigenschappen (vers- en drooggewicht en bladoppervlak). Voor de evaluatie van de prestaties van het CNN-model werden de determinatiecoëfficiënt (R^2) en de *normalized root mean square error* (NRMSE) gebruikt. De R^2 wordt weergegeven als de maat die aangeeft welk percentage van de variantie van de responsvariabelen wordt verklaard door de (lineaire) relatie met de verklarende variabelen (Chicco et al., 2021; Renaud & Victoria-Feser, 2010). De NRMSE is een maatstaf voor de verschillen tussen de voorspelde waarden en werkelijke waarden, genormaliseerd door het bereik, het gemiddelde of de standaardafwijking van de werkelijke waarden. De NRMSE wordt gebruikt als relatieve maatstaf voor vergelijking tussen verschillende variabelen of verschillende modellen (Kumar Sharma et al., 2022; *Normalized Root Mean Square Error (NRMSE) - Lifesight*, 2024; Yang et al., 2014). Er werd aangetoond dat de door een CNN geschatte groei-gerelateerde eigenschappen van sla overeenkomen met de destructieve metingen, met een R^2 -waarde van $\sim 0,9$ en NRMSE-waarde van $\sim 20\%$ (Tabel 2-2). Daarnaast werd door Zhang et al. (2020) aangetoond dat de voorgestelde schattingsmethode van het CNN een sterk generalisatievermogen had, evenals robuuste schattingsprestaties ondanks wisselende seizoensfactoren bij de beschutte teelt van sla. Dit werd getest door het voorgetrainde CNN-model rechtstreeks toe te passen op afbeeldingen van de sla-cultivar Tiberius dat in een ander groeiseizoen werd geteeld (Tabel 2-3). Bovendien werd aangetoond dat de voorspellingsnauwkeurigheid van een CNN-model verschillend is tussen de verschillende sla-cultivars (Tabel 2-3). Over het algemeen presteerde het CNN-model beter in het schatten van de groei-gerelateerde kenmerken van Flandria en Tiberius dan van Locarno. Volgens Zhang et al. (2020) is dit mogelijks te wijten aan de bladvorm van de cultivar. Afhankelijk van de bladstructuur kon het CNN-model meer of minder uitgebreide informatie verkrijgen bij het extraheren van de kenmerken uit de RGB-afbeelding.

Tabel 2-2 Schattingsresultaten van de groei-gerelateerde kenmerken van kassla op basis van het CNN-model (Zhang et al., 2020).

	Versgewicht (g)	Drooggewicht (g)	Bladoppervlakte (cm ²)
R ²	0,8983	0,8910	0,9156
NRMSE ¹	26,00%	22,07%	19,94%

¹NRMSE berekend volgens Vergelijking 3-6 (zie 3.6)

Tabel 2-3 Resultaten van de geschatte groei-gerelateerde eigenschappen voor de drie sla-cultivars door het CNN-model (Zhang et al., 2020).

Cultivar	Groeiseizoen	Versgewicht (g)		Drooggewicht (g)		Bladoppervlakte (cm ²)	
		R ²	NRMSE ¹	R ²	NRMSE ¹	R ²	NRMSE ¹
Flandria	1	0,9152	22,23%	0,9532	14,73%	0,9449	16,34%
Tiberius	1	0,9271	19,15%	0,8984	17,71%	0,9156	17,13%
Locarno	1	0,9040	31,05%	0,8476	31,45%	0,9044	25,81%
Tiberius	2	0,9277	22,96%	0,9126	37,92%	0,9251	27,60%

¹NRMSE berekend volgens Vergelijking 3-6 (zie 3.6)

Xu et al. (2023) voerden verder onderzoek uit op het CNN-model van Zhang et al. (2020) voor het schatten van het versgewicht van sla. Door meer data te gebruiken en de structuur van het model te verbeteren, kon bij dit onderzoek de R²-waarde verhoogd worden en de NMRSE-waarde verlaagd worden. De invloed van de datagrootte werd onderzocht door de dataset van Zhang et al. (2020) te verrijken met extra afbeeldingen zonder de oorspronkelijke modelstructuur te veranderen. Door hetzelfde model van Zhang et al. (2020) te gebruiken met de verrijkte dataset kon de R²-waarde met 0,0212 worden verhoogd tot R² = 0,9195 en de NMRSE-waarde worden verlaagd met 3,15% tot NRMSE = 22,85%. De schattingsprestatie van de modelstructuur werd onderzocht door het aanpassen van de oorspronkelijke modelstructuur van Zhang et al. (2020) en deze te beoordelen m.b.v. de verrijkte dataset. Hieruit bleek dat door een extra convolutie- en paddinglaag toe te voegen aan de vereenvoudigde modelvariant van Zhang et al. (2020), ontstaan door het padding-gedeelte van de oorspronkelijke CNN-architectuur van Zhang et al. (2020) te verwijderen, het voorspellingsvermogen werd verbeterd. Door toevoeging van een extra convolutie- en paddinglaag kon de R²-waarde met 0,0045 verhoogd worden (van R² = 0,9195 naar 0,9240) en de NMRSE-waarde met 0,61% verlaagd worden (van NRMSE = 22,85% naar 22,24%). Volgens Xu et al. (2023) is deze verbeterde prestatie te wijten aan de verrijkte dataset en de verbeterde kenmerken-extractie door de extra convolutielaag. Daarnaast werden de resultaten van zowel het oorspronkelijke en verbeterde model van Zhang et al. (2020) vergeleken met deze van meer geavanceerde modellen (VGG16, ResNet18, MobileNet en EfficientNet) o.b.v. de verrijkte dataset. Hieruit bleek dat het verbeterde model van Zhang et al. (2020) het beste presteerde terwijl de meer geavanceerde modellen het slechtste presteerde aangezien deze modellen kampten met overfitting. Xu et al. (2023) kon hieruit concluderen dat de modelstructuur van een CNN dient afgestemd te zijn op de omvang van de dataset en de complexiteit van de taak.

Een studie uitgevoerd door Gang et al. (2022) ontwikkelde een op CNN-gebaseerd model voor het schatten van het versgewicht, drooggewicht, hoogte, diameter en bladoppervlak van de sla-cultivars Aphyllion, Lugano, Satine en Salanova op basis van RGB-D-afbeeldingen. Deze studie toonde ook aan, o.b.v. een R²- en NMRSE-waarde, dat de op CNN gebaseerde model

geschatte groei-gerelateerde eigenschappen van sla overeenkwamen met de destructieve metingen. Volgens Gang et al. (2022) maakte het gebruik van RGB-D-afbeeldingen in het CNN-model de mogelijkheid om de nauwkeurigheid van de bepaling van de vijf onderzochte groei-indicatoren te verbeteren dankzij het verkrijgen van hoogte-informatie van de sla-cultivars. Daarnaast was het model in staat schattingsfouten in de late groeifase te verminderen, wanneer de groei-indicatoren sterk toenamen. Aangezien de late groeifase van gewassen nauw samenhangt met het optimale oogstgewicht en -moment, stelde Gang et al. (2022) dat het voorgestelde model kan helpen bij het voorspellen van het juiste oogstmoment en bij de ontwikkeling van beslissingsondersteunende systemen of oogstrobots die automatisch werken. De resultaten van het onderzoek worden weergegeven in Tabel 2-4 en Tabel 2-5.

Tabel 2-4 Algemene resultaten van de geschatte groei-gerelateerde eigenschappen voor de vier sla-cultivars door het CNN-model (Gang et al., 2022).

	Versgewicht (g)	Drooggewicht (g)	Hoogte (cm)	Diameter (cm)	Bladoppervlakte (cm ²)
R ²	0,95	0,95	0,95	0,89	0,96
NRMSE ¹	6,09%	6,30%	7,65%	7,92%	5,62%

¹NRMSE berekend volgens Vergelijking 3-7 (zie 3.6)

Tabel 2-5 Verschillende R²-waarden van de geschatte groei-gerelateerde eigenschappen voor de vier sla-cultivars door het CNN-model (Gang et al., 2022).

Cultivar	R ² Versgewicht (g)	R ² Drooggewicht (g)	R ² Hoogte (cm)	R ² Diameter (cm)	R ² Bladoppervlakte (cm ²)
Aphylion	0,96	0,96	0,96	0,92	0,96
Lugano	0,93	0,91	0,91	0,86	0,96
Satine	0,96	0,99	0,95	0,92	0,98
Salanova	0,95	0,95	0,91	0,96	0,97

3 MATERIAAL EN METHODEN

3.1 Inleiding en doelstelling

In deze masterproef werd het bepalen van het vers- en drooggewicht van sla op basis van RGB-afbeeldingen met behulp van een convolutional neural network (CNN) onderzocht. Een zelf ontworpen CNN-model werd gebruikt om een relatie te modelleren tussen een RGB-afbeelding van een slaplant en het bijhorende vers- en drooggewicht. Deze masterproef had als doel de mogelijkheden te onderzoeken voor het gebruik van CNN's met RGB-afbeeldingen voor de schatting van het vers- en drooggewicht van sla gedurende een gehele teeltronde onder praktijkomstandigheden.

RGB-afbeeldingen werden verzameld van drie verschillende sla-cultivars: Emeldia RZ (botersla), Limambo RZ (bladsla) en Volumia (botersla). De cultivars Emeldia RZ en Limambo RZ werden elks twee keer zelf opgekweekt om slaplanten afkomstig van twee verschillende teeltrondes (1 en 2) te bekomen. De slaplanten van de cultivar Volumia waren afkomstig van een externe slateler en van éénzelfde teeltronde. Dit werd gedaan om later te evalueren hoe het CNN-model presteerde bij RGB-afbeeldingen van slaplanten afkomstig van verschillende cultivars en teeltrondes, alsook om na te gaan in welke mate het model robuust was bij variatie in sla-cultivars en teeltomstandigheden aangezien per bedrijf meerdere verschillende cultivars in diverse teeltrondes worden geteeld. Van de slaplanten van de desbetreffende cultivars werden RGB-afbeeldingen verzameld onder een camerahoek van 0°, 45° en 90° t.o.v. het grondoppervlak. Dit werd uitgevoerd om later te evalueren hoe het CNN-model presteerde bij RGB-afbeeldingen van slaplanten die onder verschillende camerahoeken werden genomen, en om na te gaan in welke mate het model robuust was bij variatie in camerahoeken zoals dit in de praktijk zou kunnen voorkomen.

Na verzameling van de RGB-afbeeldingen van de slaplanten van de verschillende sla-cultivars werd zelf een CNN-model ontworpen met het meest accurate schattingsvermogen. Voor de ontwikkeling van het CNN-model werden het optimaal aantal convolutielagen en de optimale hyperparameters (leerfrequentie, aantal epochs en batchgrootte; zie later) bepaald. Voor de bepaling van het optimaal aantal convolutielagen werden verschillende CNN-modellen, met telkens een ander aantal convolutielagen, ontwikkeld waarbij de waarden van de hyperparameters constant bleven voor een correcte vergelijking van de verschillende modellen. Het CNN-model, met een welbepaald aantal convolutielagen, dat de meest accurate schattingen vertoonde werd verder gebruikt voor de bepaling van de optimale hyperparameters. Na bepaling van de optimale hyperparameters werd een CNN-model verkregen met een optimaal aantal convolutielagen en optimale hyperparameters om een zo accuraat mogelijke schatting van het vers- en drooggewicht van de slaplanten o.b.v. RGB-afbeeldingen te bekomen. Het CNN-model werd ontwikkeld m.b.v. de RGB-afbeeldingen genomen onder een camerahoek van 90° t.o.v. het grondoppervlak van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1.

Tenslotte werd het schattings- en generalisatievermogen van het ontwikkelde CNN-model onderzocht. Het schattingsvermogen geeft weer hoe goed het model het vers- en drooggewicht kan schatten voor data die gelijkaardig is aan de trainingsdata. M.a.w. werd het model getraind en getest op afbeeldingen van dezelfde cultivars en dezelfde

teeltomstandigheden, maar waarbij de testdata niet gebruikt werd tijdens het trainen (zie later). Het generalisatievermogen geeft weer hoe goed het model het vers- en drooggewicht kan schatten voor data die anders is dan de trainingsdata (m.a.w. RGB-afbeeldingen van slaplanten geteeld onder andere omstandigheden en/of van sla-cultivars die nog onbekend zijn voor het CNN). In een eerste proef werd het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak onderzocht. In een tweede proef werd het generalisatievermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak onderzocht. Tenslotte werd het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een combinatie van camerahoeken van 0°, 45° en 90° t.o.v. het grondoppervlak onderzocht. Hierbij werd nagegaan hoe het model presteerde wanneer alle RGB-afbeeldingen van de verschillende camerahoeken en sla-cultivars, afkomstig van zowel teeltronde 1 en 2, als trainingsdata werden gebruikt. Een overzicht van het onderzoeksproces voor deze masterproef wordt in bijlage A, Figuur A-1 weergegeven.

3.2 Zaai en opkweek van slaplanten tot het oogstgewicht

Voor de proeven werd gebruik gemaakt van slazaden (*Latuca sativa*) van het gewastype botersla cultivar Emeldia RZ (42-198) en van het gewastype bladsla cultivar Limambo RZ (86-LE2741) (Rijk Zwaan Belgium nv, Stabroek, België). In de serres van Thomas More campus Geel werden deze slazaden gekiemd en verder opgekweekt tot slaplanten met een oogstgewicht van respectievelijk ca. 400 gram en ca. 250 gram (de klimaatomstandigheden die aanwezig waren in de serre worden verder toegelicht bij 3.2.2). De slazaden werden gezaaid in de cellen van een zaaitray gevuld met potgrond (Agaris Professional Substraat, Agaris Horti, Gent, België). Per slazaad werd een aparte cel gebruikt. De aangebrachte slazaden werden in de cellen bedekt met dezelfde potgrond (Agaris Professional Substraat, Agaris Horti, Gent, België) waarna wit zand werd aangebracht op de gevulde cellen van de zaaitray om uitdroging en het te warm worden van de toekomstige zaailingen te vermijden. De zaaitray werd in een kunststoffen bak geplaatst waar een dunne laag water in werd aangebracht. De kunststoffen bak met zaaitray werd afgesloten doormiddel van een plastieken folie voor het bekomen van een voldoende hoge luchtvochtigheid om uitdroging van de toekomstige jonge zaailingen te vermijden. Na het kiemen van de slazaden tot zaailingen werden de zaailingen samen met de pluggen in perspotten, bestaande uit dezelfde potgrond gebruikt voor de inzaai van de slazaden, van ca. 5,5 cm bij 5,5 cm geplaatst. Uiteindelijk werden de perspotten met de zaailingen in goten gezet waar de slaplanten van het gewastype botersla cultivar Emeldia RZ verder ontwikkelden tot een oogstgewicht van ca. 400 gram en de slaplanten van het gewastype bladsla cultivar Limambo RZ tot een oogstgewicht van ca. 250 gram. Een overzicht van de datums met betrekking tot de zaai en opkweek van de slaplanten tot het bereiken van het oogstgewicht voor de twee sla-cultivars wordt in bijlage B, Tabel B-1 gegeven.

3.2.1 Irrigatie

Voor de irrigatie van de slapplanten werd gebruik gemaakt van een mobiele gotensysteem (MGS) (zie 2.1.4). Overdag (9u30 tot 18u00) stroomde de voedingsoplossing om de 45 minuten door de goten met slapplanten. Tijdens de nacht (18u00 tot 9u30) stroomde de voedingsoplossing om de 6 uur. De voedingsoplossing had een Elektrische Conductiviteit (EC) met een streefwaarde van 1,7 mS/cm en een pH met een streefwaarde van 5,5. De samenstelling van de voedingsoplossing en de bijhorende streefwaardes worden in bijlage C, Tabel C-1 gegeven.

3.2.2 Klimaatomstandigheden: temperatuur, relatieve vochtigheid, CO₂, belichting en ventilatie

In de serres van Thomas More campus Geel werden de slazaden gekiemd en verder opgekweekt tot slapplanten. De klimaatfactoren, waaronder temperatuur, relatieve vochtigheid (RV), CO₂-gehalte, natuurlijke belichting (gebruikte straling, stralingssom en "Photosynthetically Active Radiation" (PAR)-som) en ventilatie, waren variabel en afhankelijk van het buitenklimaat. Tabel 3-1 geeft een overzicht van de gemiddelde waarden van de klimaatfactoren in de serre tijdens de verschillende maanden die de kieming en opkweek van de slapplanten omvatten. Overdag werd de serre verwarmd bij een kastemperatuur onder de 14 °C en s' nachts bij een temperatuur onder de 13 °C. Ventilatie gebeurde overdag bij een temperatuur groter dan 16 °C, tijdens de nacht gebeurde dit bij een temperatuur groter dan 17,5 °C. Dit maakte dat de gestreefde etmaaltemperatuur voor verwarming 12 °C was en voor ventilatie 14,2 °C, wat ervoor zorgde dat de etmaaltemperatuur in de kas tussen de 12 en 14 °C moest zijn. Wat overeenkwam met een gestreefde dagtemperatuur van 15 - 16,7 °C en een gestreefde nachttemperatuur van 13 - 15 °C. Vanaf 13 oktober werd naast natuurlijke belichting ook gebruik gemaakt van kunstmatige belichting. De gebruikte lichtintensiteit van de kunstmatige belichting bedroeg 120 µmol/m²/s met een lichtspectrum dat lag tussen blauw en dieprood licht (de exacte golflengtes waren niet bekend). De aan- en uitschakeling van de kunstmatige belichting gebeurde tussen 7u30 en 21u00, bij een gebruikte straling onder de 150 W/m² werd de kunstmatige belichting automatisch aangeschakeld. De kunstmatige belichting was in de avond niet meer actief als overdag een stralingssom van 700 J/cm² werd bereikt.

Tabel 3-1 Overzicht van de gemeten gemiddelde dag- en nachttemperatuur, gemiddelde RV tijdens de dag en nacht, gemiddelde CO₂-gehalte tijdens de dag en natuurlijke belichting (gemiddelde gebruikte straling, gemiddelde stralingssom en gemiddelde PAR-som) in de serre tijdens de verschillende maanden die de kieming en opkweek van de slapplanten omvatten. Onder dag wordt verstaan van 9u30 tot 18u00 en onder nacht van 18u00 tot 9u30.

Maand	Dagtemperatuur (°C)	Nachttemperatuur (°C)	RV dag (%)	RV nacht (%)	CO ₂ -gehalte dag (ppm)	Gebruikte straling (W/m ²)	Stralingssom (J/cm ²)	PAR-som (mol/m ²)
Augustus	22,96	22,91	53,89	54,44	354,69	201,16	805,82	16,79
September	18,51	18,49	65,43	65,60	354,95	133,33	543,28	11,32
Oktober	15,84	15,79	72,29	72,35	390,98	58,58	239,37	4,99
November	14,31	14,27	70,11	70,24	467,69	38,48	157,11	3,27
December	13,72	13,67	73,44	73,14	520,73	22,05	85,98	1,79

3.3 Sla afkomstig van een extern sla-teeltbedrijf

Slaplanten van het gewastype botersla cultivar Volumia waren afkomstig van het sla-teeltbedrijf Goni (Goni BV, Sint-Katelijne-Waver, België) (Rijk Zwaan, 2026). De jonge slaplanten waren afkomstig van de Belgische plantenkwekerij (BPK) (BPK, Duffel, België), een Belgische kweker van jonge groenteplanten. De camerabeelden van de slaplanten werden in de serres van Thomas More campus Geel, onder dezelfde omstandigheden als de zelf opgekweekte slaplanten, genomen. Tabel 3-2 geeft een overzicht van de teeltomstandigheden, teeltronde, aantal slaplanten en datum van afhaling van de slaplanten bij Goni.

Tabel 3-2 Overzicht van de teeltomstandigheden (irrigatie(techniek), belichting, temperatuur, gemiddelde relatieve vochtigheid (RV) en gemiddelde CO₂-gehalte), teeltronde, aantal slaplanten en datum van afhaling van de slaplanten bij het sla-teeltbedrijf Goni.

Cultivar	Teeltronde	Datum afhaling slaplanten	Aantal slaplanten	Irrigatie(techniek)	Belichting	Temperatuur	RV (%)	CO ₂ -gehalte (ppm)
Volumia	1	11/09/2025	52	Mobiele gotensysteem (MGS)	Natuurlijk daglicht	Gemiddeld onder 20 °C (weersafhankelijk)	85	1500

3.4 Verzamelen van de RGB-camerabeelden, vers- en drooggewichten van de slaplanten

3.4.1 Verzamelen van de RGB-camerabeelden van de slaplanten onder een hoek van 0°, 45° en 90° ten opzichte van het grondoppervlak

Het verzamelen van de RGB-camerabeelden voor het CNN vond plaats nadat de slaplanten een week in goten stonden. De beeldverzameling werd elke week van maandag tot en met vrijdag in de serres van Thomas More Geel, op dezelfde plaats waar de slaplanten werden opgekweekt, bij natuurlijk daglicht uitgevoerd. Elk dag werd van drie verschillende slaplanten van elke sla-cultivar één RGB-afbeelding genomen telkens onder hoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak. De camerabeelden werden verzameld tot het oogstgewicht werd bereikt. Omwille van praktische redenen werd van de sla-cultivar Limambo RZ van teeltronde 2 op 15/12/2025 RGB-afbeeldingen genomen van 7 verschillende slaplanten en op 16/12/2025 van 8 verschillende slaplanten, bijgevolg werd het oogstgewicht niet bereikt. Een overzicht van het aantal afbeeldingen en de verschillende periodes waarbij de RGB-camerabeelden werden genomen van de zelf opgekweekte kassla (Emeldia RZ en Limambo RZ) en de kassla (Volumia) afkomstig van het externe slabedrijf Goni wordt in bijlage D, Tabel D-1 gegeven.

De beeldverzameling werd uitgevoerd met behulp van een mobiele telefoon (iPhone 13 mini, Apple, Californië, Verenigde Staten), een praktijkgerichte keuze aangezien geen complexe camera werd gebruikt. Tijdens de beeldverzameling werd de telefoon op een (telefoon)statief (Studio ME Statief 179 cm, Avanta Group, Nederland) gemonteerd.


Bij de RGB-afbeeldingen genomen onder een hoek van 45° en 90° t.o.v. het grondoppervlak werd een vierkanten plaatje met een afmeting van 6,5 cm bij 6,5 cm op een willekeurige plaats in de buurt van de slaplant geplaatst. Voor de beeldverzameling van de RGB-afbeelding

genomen onder een hoek van 0° t.o.v. het grondoppervlak werd het vierkanten plaatje op een vaste afstand van 20 cm geplaatst ten opzichte van het middelpunt van de slaplant, de hoogte van het vierkanten plaatje t.o.v. de slaplant was willekeurig. Het vierkanten plaatje werd als schaalreferentie gebruikt voor het CNN.

Met behulp van een fysieke waterpas werd, voordat de telefoon onder een hoek van 45° of 90° werd gepositioneerd op het statief, het “waterpas” staan van de telefoon nagegaan. Voor het instellen van de telefoon onder een hoek van 45° en 90° werd ook gebruik gemaakt van de waterpasfunctie aanwezig in de standaard applicatie ‘Meten’ van de mobiele telefoon. Voor het nemen van de afbeeldingen werd de flits optie en de optie voor het maken van ‘live’ foto’s uitgeschakeld. De oorspronkelijke pixelresolutie van de RGB-camerabeelden was 3024 x 4032. Met een alcoholstift en tape werden, tijdens het nemen van de eerste foto’s van de kassla, de posities van het (telefoon)statief en de slaplanten vastgelegd waardoor de camerabeelden voor elke meting bij dezelfde positie werden genomen. De camerabeelden werden opgeslagen als JPG-bestanden. Voorbeelden van RGB-camerabeelden genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivars Emeldia RZ, Limambo RZ, van zowel teeltronde 1 en 2, en Volumia worden in bijlage E, Tabel E-1 gegeven.

3.4.1.1 Vastleggen van de RGB-afbeeldingen onder een hoek van 90° t.o.v. het grondoppervlak


Voor het vastleggen van de RGB-afbeeldingen, onder een hoek van 90° t.o.v. het grondoppervlak, stonden de lenzen van de telefoon op een afstand van 113 cm verwijderd van het grondoppervlak. Het middelpunt van het statief stond op een afstand van 39,5 cm van het middelpunt van de slaplant (Figuur 3-1). Voor het bekomen van de RGB-afbeeldingen van de zelf opgekweekte sla-cultivars (Emeldia RZ en Limambo RZ), genomen onder een hoek van 90° t.o.v. het grondoppervlak, werd vanaf dag 1 een vergroting van 2,5x toegepast, vanaf dag 26 werd een vergroting van 2x toegepast zodanig dat de gehele slaplant op de afbeelding bleef passen. Voor het verzamelen van de RGB-afbeeldingen van de slaplanten (Volumia) afkomstig van het externe slabedrijf Goni werd voor alle afbeeldingen een vergroting van 2,5x toegepast.



Figuur 3-1 Schematisch zijaanzicht van de opstelling voor het vastleggen van de RGB-afbeeldingen van de kassla onder een hoek van 90° t.o.v. het grondoppervlak met bijhorende legende en afmetingen.

3.4.1.2 Vastleggen van de RGB-afbeeldingen onder een hoek van 45° t.o.v. het grondoppervlak

Voor het verzamelen van de camerabeelden onder een hoek van 45° t.o.v. het grondoppervlak werden de lenzen van de telefoon op een afstand van 107 cm verwijderd van het grondoppervlak terwijl het middelpunt van het statief op een afstand van 154,5 cm van het middelpunt van de slaplant stond. Bij het instellen van de camera onder een hoek van 45° werd gebruik gemaakt van twee elastieken voor extra ondersteuning van de camera in de camerahouder (Figuur 3-2). Voor het verzamelen van de RGB-afbeeldingen van de zelf opgekweekte sla-cultivars (Emeldia RZ en Limambo RZ) werd een vergroting van 2,5x toegepast. Dezelfde vergroting werd ook toegepast voor het bekomen van alle RGB-afbeeldingen van de slaplanten (Volumia) afkomstig van het externe slabedrijf Goni.




Figuur 3-2 Schematisch zijaanzicht van de opstelling voor het vastleggen van de RGB-afbeeldingen van de kassla onder een hoek van 45° t.o.v. het grondoppervlak met bijhorende legende en afmetingen.

3.4.1.3 Vastleggen van de RGB-afbeeldingen onder een hoek van 0° t.o.v. het grondoppervlak

Voor het verzamelen van de camerabeelden onder een hoek van 0° t.o.v. het grondoppervlak werd de telefoon langs de zijkant van de slaplant gepositioneerd. Een opstelling van twee grijze kunststoffen bakken werd gebruikt om een consistente achtergrond te verkrijgen voor de RGB-afbeelding (Figuur 3-3a). Net zoals bij het nemen van de camerabeelden onder een hoek van 45° en 90° t.o.v. het bodemoppervlak werd voor het nemen van de camerabeelden onder een camerahoek van 0° de waterpasfunctie aanwezig in de standaard applicatie 'Meten' van de telefoon gebruikt. Voor het verzamelen van de RGB-afbeeldingen van de zelf opgekweekte sla-cultivars (Emeldia RZ en Limambo RZ) werd vanaf dag 1 een vergroting van 1x toegepast en was de afstand tussen de telefoon en het middelpunt van de slaplant 20 cm. Om te verzekeren dat de gehele plant op de afbeelding bleef passen werd vanaf dag 4 een vergroting van 0,7x toegepast, vanaf dag 9 een vergroting van 1,7x en werd de afstand tussen de telefoon en het middelpunt van de plant vergroot naar 60 cm met behulp van een extra grijze kunststoffen bak, vanaf dag 16 werd een vergroting van 1,3x toegepast (Figuur 3-3b). Vanaf dag 25 werd een vergroting van 1x toegepast en werd als consistente achtergrond de kunststoffen bak vervangen door een isolatieplaat met een groter oppervlak dan de kunststoffen bak (Figuur 3-3c). Voor het verzamelen van de RGB-afbeeldingen van de slaplanten (Volumia) afkomstig van het externe slabedrijf Goni werd voor alle afbeeldingen

een vergroting van 1,3x toegepast en was de afstand tussen de telefoon en het middelpunt van de plant 60 cm.



Figuur 3-3 Schematisch zijaanzicht van de opstelling voor het vastleggen van de RGB-afbeeldingen van de slaplanten onder een hoek van 0° t.o.v. het grondoppervlak met bijhorende legende en afmetingen. (a) Opstelling van twee grijze kunststoffen bakken bij dag 1 van de beeldverzameling voor het bekomen van een consistente achtergrond voor de RGB-afbeelding van de slaplant onder een hoek van 0° t.o.v. het grondoppervlak. (b) Opstelling van twee grijze kunststoffen bakken met een extra kunststoffen bak bij dag 9 van de beeldverzameling voor het bekomen van een consistente achtergrond voor de RGB-afbeelding van de slaplant onder een hoek van 0° t.o.v. het grondoppervlak. (c) Opstelling van twee grijze kunststoffen bakken met een isolatieplaat in plaats van een kunststoffen bak als achtergrond bij dag 25 van de beeldverzameling voor het bekomen van een consistente achtergrond voor de RGB-afbeelding van de slaplant onder een hoek van 0° t.o.v. het grondoppervlak.

3.4.2 Bepaling van vers- en drooggewicht

Na de beeldverzameling werd telkens het vers- en drooggewicht van het bovengronds plantgedeelte bepaald. Voor de bepaling van het versgewicht werd het bovengrondse plantgedeelte direct na de beeldverzameling op een balans (PRACTUM2102-1S, Sartorius Lab Instruments, Göttingen, Duitsland) met een nauwkeurigheid van 10 mg gewogen. Voor de bepaling van het drooggewicht werden de planten voor minstens 72 uur bij 70°C in een droogoven geplaatst waarna het drooggewicht op de balans werd gewogen.

3.5 Ontwikkeling en onderzoek van een CNN-model voor de bepaling van vers- en drooggewicht van sla op basis van RGB-camerabeelden

3.5.1 Ontwerpen van een CNN-model met het meest accurate schattingsvermogen

Verschillende CNN-modellen werden ontworpen om na te gaan welk model het vers- en drooggewicht van sla het meest accuraat kon schatten. Voor de ontwikkeling van het CNN-model werd eerst het optimale aantal convolutielagen nagegaan (zie 3.5.1.2). Na bepaling van

het optimale aantal convolutielagen werden volgende optimale hyperparameters bepaald: leerfrequentie, aantal epochs en batchgrootte (zie 3.5.1.3). Het CNN-model met het meest accurate schattingsvermogen werd verder onderzocht (zie 3.5.2). Het model werd ontwikkeld o.b.v. de RGB-afbeeldingen genomen onder een hoek van 90° t.o.v. het grondoppervlak van de sla-cultivar Emeldia RZ (99 afbeeldingen) en de sla-cultivar Limambo RZ (99 afbeeldingen), beide afkomstig van teeltronde 1. Het ontwikkelen van het CNN-model gebeurde met behulp van Google Colab-software waarbij een runtimetype Python 3 en hardware-versnelling T4 GPU gebruikt werd.

3.5.1.1 Voorbewerking data

Voordat het CNN-model werd ontwikkeld, werd de originele dataset met RGB-afbeeldingen verdeeld in drie datasets. Eén dataset werd gebruikt voor training (trainingsdataset), één voor validatie (validatiedataset) en één voor het testen van het model (testdataset), de data werd respectievelijk verdeeld in een verhouding van 7:1,5:1,5. In totaal werden 198 afbeeldingen voor de ontwikkeling van het CNN-model gebruikt. Waardoor de trainingsset bestond uit 138 afbeeldingen en zowel de validatiedataset alsook de testset uit 30 afbeeldingen bestonden. De trainingsset werd gebruikt om het model te trainen terwijl de validatieset werd gebruikt om het model tijdens het trainingsproces te evalueren. Tijdens het trainingsproces werden de optimaal aantal convolutielagen en de optimale hyperparameters bepaald met de trainings- en validatieset. De testset werd op het einde van de modelontwikkeling toegepast om de schattingsprestatie van het CNN-model te evalueren (Yamashita et al., 2018).

Aangezien de trainingsdataset een relatief kleine hoeveelheid data bevatte, 138 RGB-afbeeldingen, werd data-augmentatie toegepast om de datadiversiteit te vergroten en overfitting te vermijden. De RGB-afbeeldingen werden willekeurig geroteerd binnen een bereik van -15 tot +15 graden en de helderheid van de afbeeldingen werd willekeurig aangepast, dit om de verandering in daglicht te simuleren, binnen een bereik van 0,8 tot 1,2 keer de helderheid van de originele afbeeldingen. Deze vormen van data-augmentatie werden gekozen om realistische variaties van afbeeldingen in de dataset te bekomen.

De pixelresolutie van de RGB-afbeeldingen van de slaplanten werd herschaald van 3024 x 4032 naar 128 x 128 pixels. Dit werd gedaan omwille van verschillende redenen. Ten eerste vereist een CNN een input van een vaste grootte, waardoor alle afbeeldingen moeten worden herschaald naar één vaste pixelresolutie voordat deze als input worden aangeboden. Ten tweede maken afbeeldingen met een lagere pixelresolutie het eenvoudiger en sneller om een CNN te trainen en is er minder geheugenruimte vereist. Ten slotte kan het gebruiken van afbeeldingen met een lagere resolutie leiden tot een grotere generaliseerbaarheid, of minder overfitting, van CNN's. Dit gebeurt doordat de lagere pixelresolutie het CNN-model dwingt te focussen op de essentiële visuele kenmerken van de slaplant zonder rekening te houden met irrelevante details. Echter dient de resolutie voldoende hoog te blijven om de relevante morfologische kenmerken van de slaplant te behouden (Lakhani, 2020; Saponara & Elhanashi, 2022).

Feature scaling werd toegepast om de data te standaardiseren aangezien de waarden van het vers- en drooggewicht verschillende bereiken hadden. Als feature scaler techniek werd Min-Max normalisatie toegepast. Met Min-Max normalisatie werd de data geschaald naar een vast bereik [0, 1] aangezien geen negatieve waarden in de dataset aanwezig waren. Bovendien bleven de onderlinge relaties tussen de oorspronkelijke invoergegevens, de oorspronkelijke gegevens van de vers- en drooggewichten van de slaplanten, bij Min-Max normalisatie behouden (Pinheiro et al., 2025; Waema et al., 2025). Na het schatten van de gewichten door

het CNN-model werden de voorspelde waarden via de inverse transformatie teruggebracht naar de originele schaal voor verdere interpretatie en evaluatie van de resultaten. De transformatie van de gegevens bij Min-Max normalisatie wordt gegeven door Vergelijking 3-1.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad \text{Vergelijking 3-1}$$

Met:

X_{norm} = genormaliseerde waarde

X = oorspronkelijke waarde

X_{min} = minimum waarde

X_{max} = maximum waarde

3.5.1.2 Bepaling van het optimaal aantal convolutielagen

Als eerste stap, voor de ontwikkeling van een CNN-model met het meest accurate schattingsvermogen, werd het optimale aantal convolutielagen bepaald tijdens training en validatie van het CNN-model. De input voor de CNN-modellen waren RGB-afbeeldingen van de slapplanten met afmetingen van 128 x 128 x 3 (breedte x hoogte x aantal kanalen). Meerdere CNN-modellen werden met verschillende aantal convolutielagen ontworpen, waarbij het eerste model één convolutielaag had met 16 filters, een kernel met een grootte van 3 x 3 en een stapgrootte (*stride*) van 1. Het hierop volgende ontwikkelde model kreeg een extra convolutielaag met het dubbele aantal filters van de voorgaande convolutielaag, dit werd telkens herhaald. De toename van het aantal convolutielagen werd stopgezet wanneer de schattingsprestatie van het model niet meer systematisch verbeterde. De kernelgrootte en stapgrootte was voor elke convolutielaag hetzelfde. Om de grootte van de kenmerkaarten te behouden, zodat deze niet kleiner werden na elke convolutieoperatie, werd nulopvulling in elke convolutielaag toegepast. Op elke convolutielaag werd ook de niet-lineaire activeringsfunctie Rectified Linear Unit (ReLU) toegepast. Elke convolutielaag werd gevolgd door een poolinglaag met een grootte van 2 x 2 en stapgrootte van 2 waardoor de grootte van de kenmerkenkaarten met een factor 2 werden gereduceerd. In de poolinglagen werd de maximale poolingfunctie (*Max Pooling*) gebruikt. Het aantal verborgen neuronen in de volledig verbonden laag was twee, overeenkomend met de twee outputs, vers- en drooggewicht van de slapplant, van het model. Hierdoor kon het model de twee groei-gerelateerde kenmerken gelijktijdig schatten. Om als output een numerieke waarde te bekomen werd op deze laatste laag de activeringsfunctie *linear* toegepast. Dezelfde hyperparameters werden aangehouden voor de bepaling van het optimaal aantal convolutielagen: leerfrequentie van 0,001; een maximum van 100 epochs met *early stopping* (*patience* 10) en een batchgrootte van 10. Early stopping met een *patience* van 10 werd toegepast om tijd te besparen bij de ontwikkeling van het CNN-model. Early stopping was een methode die de prestaties van het model op de validatieset tijdens training monitorde. De training van het model werd beëindigd wanneer de validatiefout, namelijk de validatie *loss* (MSE) (zie later), niet meer afnam. Het doel van early stopping was om het model vast te leggen op het punt waar het de beste prestatie had op onbekende data, namelijk data afkomstig van de validatieset (GeeksforGeeks, 2025; Miseta et al., 2024). Een *patience* van 10 werd toegepast om na de effectieve stopzetting van de training door early stopping de validatiefout bij nog 10 extra epochs te monitoren om er zeker van te zijn dat de validatiefout niet meer verder afnam.

De prestaties van de verschillende modellen werden tijdens training- en validatie geëvalueerd doormiddel van de *mean squared error* (MSE) en de *mean absolute error* (MAE). De MSE is

het gemiddelde van de kwadraten van het verschil tussen de voorspelde waarden en werkelijke waarden (Vergelijking 3-2). Omdat bij de MSE een kwadratische bewerking wordt gebruikt is deze gevoelig voor grote fouten en kan deze snel bestraffen, alsook kan het effecten van kleine fouten versterken (H. Zhao et al., 2017; Yin et al., 2025). De MAE is het gemiddelde van de absolute waarde van het verschil tussen de voorspelde waarden en de werkelijke waarden (Vergelijking 3-3) (Barron, 2019; Yin et al., 2025).

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad \text{Vergelijking 3-2}$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad \text{Vergelijking 3-3}$$

Met:

n = aantal voorspellingen


y_i = werkelijke waarde

$\hat{y}_i$ = voorspelde waarde

Elk model werd vijf keer achter elkaar getraind ($n = 5$) en bij elke training werd zowel de MSE voor de training- en validatieset alsook de MAE voor de training- en validatieset bijgehouden. Uiteindelijk werd de gemiddelde validatie MAE met bijhorende standaardafwijking bepaald om de verschillende modellen te vergelijken. Dit werd gedaan omdat bij elke training van het model de MSE voor de training- en validatieset alsook de MAE voor de training- en validatieset varieerde. Het CNN-model met de laagste gemiddelde validatie MAE werd geselecteerd om verder te verbeteren door middel van de optimale hyperparameters te bepalen. In totaal werden zeven CNN-modellen (Model A - G), met een verschillend aantal convolutielagen, ontwikkeld en onderling vergeleken om een CNN-model met een optimaal aantal convolutielagen te bekomen. De onderzochte CNN-modellen met bijhorende specificaties en gebruikte hyperparameters voor de bepaling van het optimaal aantal convolutielagen worden in bijlage F, Figuur F-1 gegeven.

3.5.1.3 Bepaling van de optimale hyperparameters

Bij training van een CNN-model werden de kernels in de convolutielagen en de gewichten in de volledig verbonden lagen gevonden die de verschillen tussen de voorspelde waarden en de werkelijke waarden op een trainingsdataset minimaliseren. De prestaties van het model werden berekend met een verliesfunctie (de *loss function* MSE) doormiddel van *forward propagation* op de trainingsdataset. De leerbare parameters, de kernels en gewichten, werden vervolgens bijgewerkt doormiddel van *back propagation* (Figuur 3-4) (Yamashita et al., 2018).



Figuur 3-4 Noot. Schematische weergave van de architectuur en werking van een convolutional neural network (CNN). Uit “Convolutional neural networks: an overview and application in radiology” door R. Yamashita et al.. Yamashita et al., 2018, *Insights into Imaging* (2018) 9:611–629, 9(4), 613, Copyright 2018 van R. Yamashita et al.. Yamashita et al..

Het leerproces van het CNN-model moet zodanig worden gestuurd zodat het model het beste leert van de aangeleverde trainingsdata. Dit werd gedaan door het afstemmen van volgende hyperparameters: batchgrootte, leersfrequentie en het aantal epochs. Deze hyperparameters werden aan het model toegekend voordat het werd getraind. De batchgrootte was het aantal trainingsbeelden dat in één keer door het model werd gestuurd, waarop tijdens het trainen forward propagation en back propagation werd uitgevoerd. Het uitvoeren van forward propagation en back propagation op één batch, waarbij de leerbare parameters werden bijgewerkt, werd een iteratie genoemd. De leersfrequentie was de stapgrootte dat het optimalisatiealgoritme in elke iteratie zette, m.a.w. bepaalde dit hoe groot de gewichtsaanpassing was tijdens back propagation per iteratie. Het aantal epochs waren het aantal keren dat het CNN-model de volledige trainingsdataset had doorlopen (Shafi & Assad, 2023).

Na bepaling van het optimale aantal convolutielagen werd in deze stap de optimale hyperparameters bepaald: leersfrequentie, aantal epochs en batchgrootte. De onderzochte leersfrequenties waren: 0,1; 0,01; 0,001 en 0,0001. Voor de bepaling van de optimale leersfrequentie werd een vaste batchgrootte van 10 en een maximum van 100 epochs met early stopping (patience 10) genomen.

De optimale batchgrootte werd bepaald met de optimale leersfrequentie die al bepaald werd en een maximum van 100 epochs met early stopping (patience 10). De onderzochte batchgroottes waren: 5, 10, 15 en 20. De prestaties van het model, met de hiervoor bepaalde optimale aantal convolutielagen, met de verschillende hyperparameters werden op dezelfde manier geëvalueerd als bij de bepaling van het optimaal aantal convolutielagen (zie 3.5.1.2).

Voor de bepaling van het aantal epochs werd het model getraind over respectievelijk 1000, 500, 300, 200, 100 en 50 epochs en werd een training- en validatie loss (MSE)-curve en een training- en validatie MAE-curve opgesteld. Deze curves gaven inzicht in hoe goed het model had geleerd van de trainingsdata en hoe goed het model generaliseerde naar de validatiedata in de loop van meerdere epochs. Bij de training- en validatie loss (MSE)-curve werd de MSE-waarde, van zowel training en validatie, uitgezet op het aantal epochs en bij de training- en validatie MAE-curve werd de MAE-waarde, van zowel training en validatie, uitgezet

op het aantal epochs. Doordat het model werd getraind bij telkens een verschillend aantal epochs kon nagegaan worden, door analyse van de verschillende curves, wat de optimale aantal epochs waren voor het trainingsproces van het CNN-model.

3.5.2 Onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model

Het schattings- en generalisatievermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak werden onderzocht (zie 3.5.2.1 en 3.5.2.2). Ten slotte werd nagegaan hoe het model presteerde wanneer alle RGB-afbeeldingen van de verschillende camerahoeken en sla-cultivars, afkomstig van zowel teeltronde 1 en 2, als trainingsdata werden gebruikt (zie 3.5.2.3). De voorbewerking van de data werd telkens op dezelfde manier uitgevoerd zoals beschreven in 3.5.1.1.

3.5.2.1 Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak

Het schattingsvermogen van het CNN-model werd onderzocht doordat het model werd getraind met de RGB-afbeeldingen van de sla-cultivar Emeldia RZ en de sla- cultivar Limambo RZ, beide afkomstig van teeltronde 1. De bepaling van het schattingsvermogen gebeurde m.b.v. een testset bestaande uit 30 RGB-afbeeldingen van de sla-cultivar Emeldia RZ en de sla-cultivar Limambo RZ, beide afkomstig van teeltronde 1. Deze onderzoeksmethode werd telkens toegepast voor RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak. Tabel 3-3 geeft een overzicht van de verschillende testsets met bijhorende kenmerken die werden gebruikt voor het onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model.

Tabel 3-3 Overzicht van de verschillende testsets kenmerkend voor een bepaalde sla-cultivar, teeltronde en camerahoek t.o.v. het grondoppervlak. Bijkomend wordt het aantal RGB-afbeeldingen, gebruikt per testset, vermeld.

Testset	Camerahoek	Cultivar	Teeltronde	Aantal RGB-afbeeldingen
1	0°	Emeldia RZ en Limambo RZ	1	30
2	45°	Emeldia RZ en Limambo RZ	1	30
3	90°	Emeldia RZ en Limambo RZ	1	30

3.5.2.2 Onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak

Het generalisatievermogen van het ontwikkelde CNN-model werd onderzocht door het vers- en drooggewicht van de sla-cultivar Emeldia RZ en de sla- cultivar Limambo RZ, beide afkomstig van teeltronde 2, alsook van de sla-cultivar Volumia (afkomstig van de externe

slateler) te schatten. De generalisatietest werd uitgevoerd door het ontwikkelde CNN-model, dat werd voorgetraind op de RGB-afbeeldingen van de sla-cultivar Emeldia RZ en de sla-cultivar Limambo RZ beide afkomstig van teeltronde 1, rechtstreeks toe te passen op de afbeeldingen van de sla-cultivar Emeldia RZ en de sla-cultivar Limambo RZ, beide afkomstig van teeltronde 2, alsook van de sla-cultivar Volumbia (afkomstig van de externe slateler). Voor elke sla-cultivar werd een aparte testset aangemaakt om het generalisatievermogen van het model te onderzoeken. De testset van de sla-cultivar Emeldia RZ bestond uit 114 afbeeldingen, van de sla-cultivar Limambo RZ uit 99 afbeeldingen en van de sla-cultivar Volumbia uit 52 afbeeldingen. Deze onderzoeksmethode werd telkens toegepast voor RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak. Tabel 3-4 geeft een overzicht van de verschillende testsets met bijhorende kenmerken die werden gebruikt voor het onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model.

Tabel 3-4 Overzicht van de verschillende testsets kenmerkend voor een bepaalde sla-cultivar, teeltronde en camerahoek t.o.v. het grondoppervlak. Bijkomend wordt het aantal RGB-afbeeldingen, gebruikt per testset, vermeld.

Testset	Camerahoek	Cultivar	Teeltronde	Aantal RGB-afbeeldingen
1	0°	Emeldia RZ	2	114
2		Limambo RZ	2	99
3		Volumbia	1	52
4	45°	Emeldia RZ	2	114
5		Limambo RZ	2	99
6		Volumbia	1	52
7	90°	Emeldia RZ	2	114
8		Limambo RZ	2	99
9		Volumbia	1	52

3.5.2.3 Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een combinatie van camerahoeken van 0°, 45° en 90° t.o.v. het grondoppervlak

Bij deze proef werd nagegaan hoe het ontwikkelde CNN-model presteerde wanneer alle RGB-afbeeldingen van de verschillende camerahoeken en sla-cultivars, afkomstig van zowel teeltronde 1 en 2, als trainingsdata werden gebruikt. Het model werd getraind met RGB-afbeeldingen genomen onder een camerahoek van 0°, 45° en 90° van de sla-cultivar Emeldia RZ en de sla-cultivar Limambo RZ, beide afkomstig van zowel teeltronde 1 als teeltronde 2. De RGB-afbeeldingen genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivar Volumbia werden ook gebruikt voor training van het model. De trainingsset bestond uit 814 afbeeldingen en zowel de validatie- als testset bestonden uit 175 afbeeldingen. Daarnaast werden verschillende testsets, telkens kenmerkend voor een bepaalde sla-cultivar, teeltronde en camerahoek t.o.v. het grondoppervlak, handmatig aangemaakt waarbij elke testset bestond uit 15 RGB-afbeeldingen van de kassla. Een overzicht van de verschillende testsets met bijhorende kenmerken wordt in Tabel 3-5 gegeven.

Tabel 3-5 Overzicht van de verschillende aangemaakte testsets kenmerkend voor een bepaalde sla-cultivar, teeltronde en camerahoek t.o.v. het grondoppervlak. Bijkomend wordt het aantal RGB-afbeeldingen, gebruikt per testset, vermeld.

Testset	Camerahoek	Cultivar	Teeltronde	Aantal RGB-afbeeldingen
1	0°, 45° en 90°	Emeldia RZ, Limambo RZ en Volumia	1 en 2	175
2	0°	Limambo RZ	1	15
3	45°	Limambo RZ	1	15
4	90°	Limambo RZ	1	15
5	0°	Emeldia RZ	1	15
6	45°	Emeldia RZ	1	15
7	90°	Emeldia RZ	1	15
8	0°	Limambo RZ	2	15
9	45°	Limambo RZ	2	15
10	90°	Limambo RZ	2	15
11	0°	Emeldia RZ	2	15
12	45°	Emeldia RZ	2	15
13	90°	Emeldia RZ	2	15
14	0°	Volumia	1	15
15	45°	Volumia	1	15
16	90°	Volumia	1	15

3.6 Statistische analyse

Voor de evaluatie van de prestaties van het ontwikkelde CNN-model werd bij elke testset een scatterplot met bijhorende vergelijking van de regressielijn, determinatiecoëfficiënt (R^2), *root mean square error* (RMSE) uitgedrukt in gram en *normalized root mean square error* (NRMSE) opgesteld. Bij het creëren van de scatterplots werden telkens de voorspelde gewichten (y-as) uitgezet t.o.v. de werkelijke gewichten (x-as). De scatterplots met bijhorende vergelijkingen van de regressielijnen werden verkregen met behulp van de Google Colab-software waarbij een runtime-type Python 3 en hardware-versnelling T4 GPU gebruikt werd. De R^2 , RMSE en NRMSE werden bepaald met behulp van Rstudio (R version 4.4.3, Posit Software, Boston, Verenigde Staten).

De R^2 wordt weergegeven als de maat die aangeeft welk percentage van de variantie van de responsvariabelen wordt verklaard door de (lineaire) relatie met de verklarende variabelen (Vergelijking 3-4) (Chicco et al., 2021; Renaud & Victoria-Feser, 2010).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{Vergelijking 3-4}$$

Met:

R^2 = determinatiecoëfficiënt

n = aantal voorspellingen

y_i = werkelijke waarde

$\hat{y}_i$ = voorspelde waarde

$\bar{y}$ = gemiddelde van de werkelijke waarden

De RMSE wordt gedefinieerd als de maatstaf voor de verschillen tussen de voorspelde waarden en de werkelijke waarden (Vergelijking 3-5). Het wordt gebruikt om de prestaties van een model weer te geven door de voorspelde en werkelijke waarden met elkaar te vergelijken. Omdat de RMSE de absolute fout meet is deze moeilijker interpreteerbaar en vergelijkbaar tussen verschillende datasets (Jamil & Akhtar, 2017; Kumar Sharma et al., 2022; *Normalized Root Mean Square Error (NRMSE)* - Lifesight, 2024; Yang et al., 2014). Daarom wordt voor de evaluatie van de prestaties van het ontwikkelde CNN-model ook de NRMSE mee in rekening gebracht.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad \text{Vergelijking 3-5}$$

Met:

RMSE = root mean square error (g)

n = aantal voorspellingen

y_i = werkelijke waarde

$\hat{y}_i$ = voorspelde waarde

De NRMSE is een maatstaf voor de verschillen tussen de voorspelde waarden en werkelijke waarden, genormaliseerd door het gemiddelde (Vergelijking 3-6), het bereik (Vergelijking 3-7) of de standaardafwijking van de werkelijke waarden. De NRMSE wordt gebruikt als relatieve maatstaf voor vergelijking tussen verschillende variabelen of verschillende modellen. Bovendien vult het de metrieken R^2 en RMSE aan door een genormaliseerd beeld te geven van de nauwkeurigheid van het CNN-model (Gang et al., 2022; Kumar Sharma et al., 2022; *Normalized Root Mean Square Error (NRMSE)* - Lifesight, 2024; Yang et al., 2014). Voor de evaluatie van de prestaties van het ontwikkelde CNN-model werd gebruik gemaakt van de NRMSE die bekomen werd door de verschillen tussen de voorspelde waarden en werkelijke waarden te normaliseren door het gemiddelde van de werkelijke waarden (Vergelijking 3-6).

$$\begin{aligned} NRMSE &= \frac{RMSE}{\bar{y}} \\ &= \frac{\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}}{\bar{y}} \end{aligned} \quad \text{Vergelijking 3-6}$$

$$\begin{aligned} NRMSE &= \frac{RMSE}{y_{\max} - y_{\min}} \\ &= \frac{\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}}{y_{\max} - y_{\min}} \end{aligned} \quad \text{Vergelijking 3-7}$$

Met:

NRMSE = normalized root mean square error

RMSE = root mean square error (g)

n = aantal voorspellingen

y_i = werkelijke waarde

$\hat{y}_i$ = voorspelde waarde

$\bar{y}$ = gemiddelde van de werkelijke waarden

$y_{\max}$ = maximale werkelijke waarde

$y_{\min}$ = minimale werkelijke waarde

4 RESULTATEN EN DISCUSSIE

In dit hoofdstuk worden de resultaten besproken voor de ontwikkeling en het onderzoeken van een CNN-model voor de bepaling van het vers- en drooggewicht van sla op basis van RGB-camerabeelden. Eerst worden de resultaten besproken met betrekking tot het ontwerpen van een CNN-model met het meest accurate schattingsvermogen. Op basis van deze resultaten worden het optimaal aantal convolutielagen en de optimale hyperparameters (leerfrequentie, batchgrootte en aantal epochs) geselecteerd voor het CNN-model. Vervolgens worden de schattings- en generalisatieprestaties van het ontwikkelde CNN-model bij RGB-camerabeelden, van de verschillende sla-cultivars en teeltrondes, genomen onder verschillende camerahoeken (0°, 45° en 90° t.o.v. het grondoppervlak) geëvalueerd.

4.1 Ontwerpen van een CNN-model met het meest accurate schattingsvermogen

4.1.1 Bepaling van het optimaal aantal convolutielagen

Voor de ontwikkeling van een CNN-model met het meest accurate schattingsvermogen werd eerst het optimale aantal convolutielagen bepaald. Meerdere CNN-modellen (Model A - G) werden met verschillende aantal convolutielagen ontworpen. Elk model werd vijf keer achter elkaar getraind ($n = 5$) en de validatie MAE bij elke training werd gebruikt voor het bekomen van de gemiddelde validatie MAE met bijhorende standaardafwijking. De gemiddelde validatie MAE's met bijhorende standaardafwijkingen werden gebruikt om de verschillende modellen te vergelijken en hieruit het optimaal aantal convolutielagen te bekomen. Tabel 4-1 toont de gemiddelde validatie MAE van elk model met bijhorende standaardafwijking. Hieruit kan afgeleid worden dat de gemiddelde validatie MAE systematisch afneemt bij toename van het aantal convolutielagen tot het model met vijf convolutielagen. Bij verdere toename in het aantal convolutielagen is geen verdere afname van de gemiddelde validatie MAE waar te nemen. Het model met vijf convolutielagen (model E) heeft naast de laagste gemiddelde validatie MAE ook de laagste standaardafwijking.

Tabel 4-1 Gemiddelde validatie MAE-waarden van de vijf aparte trainingsprocessen (n = 5) bij elk CNN-model (Model A - G). Data wordt voorgesteld als gemiddelde $\pm$ standaardafwijking.

Model	Aantal convolutielagen	Validatie MAE
A	1	0,0794 $\pm$ 0,0068
B	2	0,0707 $\pm$ 0,0103
C	3	0,0575 $\pm$ 0,0031
D	4	0,0489 $\pm$ 0,0045
E	5	0,0424 $\pm$ 0,0011
F	6	0,0460 $\pm$ 0,0050
G	7	0,0453 $\pm$ 0,0066

4.1.2 Bepaling van de optimale hyperparameters

4.1.2.1 Bepaling van de optimale leersfrequentie

Na bepaling van het optimale aantal convolutielagen werd de optimale leersfrequentie bepaald. De onderzochte leersfrequenties waren: 0,1; 0,01; 0,001 en 0,0001. De evaluatie voor de bepaling van de optimale leersfrequentie gebeurde op dezelfde manier als bij de bepaling van het optimale aantal convolutielagen. Volgens Tabel 4-2 neemt de gemiddelde validatie MAE systematisch af bij het kleiner worden van de leersfrequentie tot aan de leersfrequentie van 0,001. Verdere verkleining van de leersfrequentie zorgt niet meer voor een lagere gemiddelde validatie MAE. Bovendien valt ook hier op te merken dat de laagste validatie MAE gepaard gaat met de laagste standaardafwijking.

Tabel 4-2 Gemiddelde validatie MAE-waarden van de vijf aparte trainingsprocessen (n = 5) bij elke toegepaste leersfrequentie. Data wordt voorgesteld als gemiddelde $\pm$ standaardafwijking.

Leersfrequentie	Validatie MAE
0,1	0,2119 $\pm$ 0,0519
0,01	0,1121 $\pm$ 0,0579
0,001	0,0471 $\pm$ 0,0097
0,0001	0,0579 $\pm$ 0,0109

4.1.2.2 Bepaling van de optimale batchgrootte

De bepaling van de optimale batchgrootte gebeurde na bepaling van het optimaal aantal convolutielagen en de optimale leersfrequentie. De onderzochte batchgroottes waren: 5, 10, 15 en 20. De evaluatie voor de bepaling van de optimale batchgrootte gebeurde op dezelfde manier als bij de bepaling van het optimaal aantal convolutielagen en de optimale leersfrequentie. Uit Tabel 4-3 kan afgeleid worden dat een batchgrootte van 10 gepaard gaat met de laagste gemiddelde validatie MAE alsook met de laagste standaardafwijking. Verdere toename van de batchgrootte resulteert niet in een verdere daling van de gemiddelde validatie MAE.


Tabel 4-3 Gemiddelde validatie MAE-waarden van de vijf aparte trainingsprocessen (n = 5) bij elke toegepaste batchgrootte. Data wordt voorgesteld als gemiddelde $\pm$ standaardafwijking.

Batchgrootte	Validatie MAE
5	0,0476 $\pm$ 0,0051
10	0,0414 $\pm$ 0,0033
15	0,0526 $\pm$ 0,0059
20	0,0450 $\pm$ 0,0056

4.1.2.3 Bepaling van het optimale aantal epochs

Voor de bepaling van het optimale aantal epochs werd een training- en validatie loss (MSE)-curve en een training- en validatie MAE-curve opgesteld. Dit gebeurde telkens bij training en validatie van het model, bij respectievelijk 1000 (Figuur 4-1(a-b)), 500 (Figuur 4-1(c-d)), 300 (Figuur 4-1(e-f)), 200 (Figuur 4-1(g-h)), 100 (Figuur 4-1(i-j)) en 50 (Figuur 4-1(k-l)) epochs.

De training- en validatie loss (MSE)-curves en de training- en validatie MAE-curves volgen, onafhankelijk van het aantal epochs, over het algemeen dezelfde trend. Zowel bij de training- en validatie loss (MSE)-curves als bij de training- en validatie MAE-curves zijn schommelingen in de curves waar te nemen. Bij de training- en validatie loss (MSE)-curves daalt zowel de training- alsook validatiecurve aan het begin van het trainingsproces tot ca. 50 epochs, daarna stabiliseren beide curves. Bovendien stabiliseert de trainingscurve bij een lagere MSE-waarde dan de validatiecurve. Bij de training- en validatie MAE-curves is dezelfde trend waar te nemen. Bij de validatie loss (MSE)-curves en validatie MAE-curves van respectievelijk 1000 (Figuur 4-1(a-b)), 500 (Figuur 4-1(c-d)), 300 (Figuur 4-1(e-f)) en 200 (Figuur 4-1(g-h)) epochs is waar te nemen dat de curves niet meer dalen bij toename van het aantal epochs. Bij de validatie loss (MSE)-curves en validatie MAE-curves van 100 (Figuur 4-1(i-j)) en 50 (Figuur 4-1(k-l)) epochs is een zekere stabilisatie waar te nemen maar is niet met grote zekerheid te zeggen dat de curves nog verder zullen dalen zoals bij de validatie loss (MSE)-curves en validatie MAE-curves van respectievelijk 1000 (Figuur 4-1(a-b)), 500 (Figuur 4-1(c-d)), 300 (Figuur 4-1(e-f)) en 200 (Figuur 4-1(g-h)) epochs.



Figuur 4-1 Training- en validatie loss (MSE)-curve en training- en validatie MAE-curve bij respectievelijk 1000 (a-b), 500 (c-d), 300 (e-f), 200 (g-h), 100 (i-j) en 50 (k-l) epochs.

4.1.3 Discussie

Bij de bepaling van het optimale aantal convolutielagen bleek het model met een aantal van 5 convolutielagen de laagste gemiddelde validatie MAE te hebben. Naarmate het aantal convolutielagen toenam tot 5 convolutielagen was er een systematische afname van de gemiddelde validatie MAE waar te nemen. Dit betekent dat de schattingsprestatie van het model, aangezien het verschil tussen de voorspelde waarden en de werkelijke waarden afnam, verbeterde bij toename van het aantal convolutielagen. Deze verbetering is te verklaren doordat de eerste convolutielagen kenmerken op laag niveau, zoals kleurgradiënten, randen van bladeren en de textuur van het bladoppervlak, gaan vastleggen. Terwijl het toevoegen van extra convolutielagen ervoor zorgt dat het model zich gaat aanpassen aan kenmerken op hogere niveaus, zoals de vorm en structuur van de volledige krop of overlapping van de bladeren, waardoor het CNN de afbeeldingen in de dataset beter kan begrijpen en betere schattingsprestaties mogelijk zijn (Bhatt et al., 2021). Bij het gebruik van meer dan 5 convolutielagen nam de gemiddelde MAE niet meer af. Dit betekent dat bij het toevoegen van nog meer convolutielagen het model kampte met overfitting (Xu et al., 2023).

Uit de resultaten blijkt dat de optimale leersnelheid 0,001 is. Wanneer de leersnelheid groter was dan 0,001 nam de gemiddelde validatie MAE toe met als gevolg dat de schattingsprestatie van het CNN afnam. Dit is te verklaren doordat bij een te grote leersnelheid de gewichtsaanpassingen van de leerbare parameters tijdens het trainen van het model te groot zijn waardoor het minimale verschil tussen de voorspelde waarden en de werkelijke waarden wordt overgeslagen of mogelijk zelfs niet wordt gevonden (X. Zhao et al., 2024). Bij een leersnelheid kleiner dan 0,001 werd ook waargenomen, aangezien de gemiddelde validatie MAE terug toenam, dat de schattingsprestatie niet meer verbeterde. Doordat de leersnelheid te klein is, met als gevolg ook de gewichtsaanpassing bij elke iteratie, zijn er veel iteraties nodig voordat het minimale verschil tussen de voorspelde waarden en de werkelijke waarden gevonden wordt, wat tijdrovend is (X. Zhao et al., 2024). Aangezien gebruik werd gemaakt van early stopping bij het trainen van het model kan mogelijk de combinatie van een te lage leersnelheid en early stopping ervoor hebben gezorgd dat het minimale verschil tussen de voorspelde waarden en de werkelijke waarden niet werd bereikt. Dit komt doordat bij early stopping de training van het model vroegtijdig wordt stopgezet wanneer de validatiefout (validatie loss (MSE)) niet meer afneemt (GeeksforGeeks, 2025; Miseta et al., 2024).

Voor de bepaling van de optimale batchgrootte blijkt uit de resultaten dat een batchgrootte van 10 gepaard gaat met de laagste gemiddelde MAE en dus met het minimale verschil tussen de voorspelde waarden en de werkelijke waarden. Zowel kleinere als grotere batchgroottes resulteerden in waarden met een hogere gemiddelde MAE. De slechtere schattingsprestaties bij te kleine batchgroottes kunnen te wijten zijn aan het feit dat er een grote variabiliteit aanwezig is tussen de batches van de trainingsbeelden die telkens in één keer door het model worden gestuurd. Deze grote variabiliteit kan ervoor zorgen dat de aanpassingen op de leerbare parameters per iteratie sterk fluctueren waardoor het model minder stabiel convergeert naar het minimale verschil tussen de voorspelde waarden en de werkelijke waarden op de trainingsdata. Bij grotere batchgroottes is de variabiliteit tussen de batches van trainingsbeelden die telkens in één keer door het model worden gestuurd lager, wat ervoor zorgt dat de aanpassingen op de leerbare parameters per iteratie minder fluctueren. Dit betekent dat het model beter kan convergeren naar het minimale verschil tussen de

voorspelde waarden en de werkelijke waarden op de trainingsdata. Daarentegen is het model minder goed generaliseerbaar voor ongeziene data, zoals data afkomstig van de validatieset (Kandel & Castelli, 2020; Lin, 2022). De batchgrootte van 10, rekening houdende met de hoeveelheid data en complexiteit van de taak, zorgt voor een optimaal evenwicht tussen enerzijds voldoende variabiliteit om generalisatie te bevorderen maar niet te veel zodat bijwerkingen van de leerbare parameters instabiel worden.

Bij de analyse van de training- en validatie loss (MSE)-curves en de training- en validatie MAE-curves werd, onafhankelijk van het aantal epochs, over het algemeen dezelfde trend waargenomen. Het waarnemen van dezelfde trend is te verklaren doordat de MAE het gemiddelde is van de absolute waarde van het verschil tussen de voorspelde waarden en de werkelijke waarden terwijl de MSE het gemiddelde is van de kwadraten van het verschil tussen de voorspelde waarden en werkelijke waarden (Barron, 2019; Zhao et al., 2017). Zowel de MSE als de MAE geven over het algemeen het verschil tussen de voorspelde waarden en de werkelijke waarden weer, maar op een andere manier, dit verklaart waarom de trend van de curves gelijkaardig is maar de MSE-waarden verschillend zijn t.o.v. de MAE-waarden. De daling van de training- en validatie loss (MSE)-curves en de training- en validatie MAE-curves aan het begin van het trainingsproces betekent dat het model tijdens training het verschil tussen de voorspelde waarden en de werkelijke waarden, berekend via forward propagation, minimaliseert door het bijwerken van de leerbare parameters via back propagation alsook beter begint te presteren op de validatieset. Echter is de daling van de training loss (MSE)- en MAE-curves sterker dan bij de validatie loss (MSE)- en MAE-curves. Dit zorgt bij stabilisatie van de curves ervoor dat de training loss (MSE)- en MAE-curves lager liggen dan de validatie loss (MSE)- en MAE-curves bij toename van het aantal epochs wat resulteert in lichte overfitting van het model. Volgens Yamashita et al. (2018) overfit een model op de trainingsdata wanneer het goed presteert op de trainingsset in vergelijking met de validatieset. Dit betekent dat het model statistische regelmatigheden leert die specifiek zijn voor de trainingsset en presteert hierdoor minder goed op een volgende nieuwe dataset, namelijk de validatieset. De beste oplossing om overfitting te verminderen is het verkrijgen van meer trainingsdata (Yamashita et al., 2018). Aangezien het aantal RGB-afbeeldingen van de kassla, 198 afbeeldingen en rekening houdend met de uitbreiding van de dataset via data-augmentatie (zie 3.5.1.1), relatief beperkt was voor ontwikkeling van het model kan dit de verklaring zijn waarom lichte overfitting aanwezig is. Er wordt in dit geval gesproken over lichte overfitting aangezien de validatie loss (MSE)- en MAE-curves zelfs bij veel epochs, zoals bij 1000 epochs, niet meer terug beginnen te stijgen (geen stijgende validatiefout) en het model dus stabiel blijft generaliseren. Aangezien het gebruik van meer epochs bij het trainen meer rekentijd vereist en de toename van het aantal epochs het model niet slechter maakt in het schatten van het vers- en drooggewicht, doordat de validatie loss (MSE)- en MAE-curves stabiel blijven en niet terug beginnen te stijgen bij toename van het aantal epochs, wordt voor training van het model gebruik gemaakt van 200 epochs. Het gebruik van 200 epochs zorgt voor een goed evenwicht tussen de benodigde rekentijd en het stabiel trainen van het CNN-model zonder verdere overfitting.

Uit de resultaten kan geconcludeerd worden dat het CNN-model met het meest accurate schattingsvermogen bestaat uit 5 convolutielagen en volgende hyperparameters: een leersnelheid van 0,001; een batchgrootte van 10 en een aantal epochs van 200. Het ontwikkelde CNN-model met het meest accurate schattingsvermogen wordt in bijlage G, Figuur G-1 schematisch weergegeven. Opvallend was dat de gemiddelde validatie MAE van de optimale parameters van het model telkens gepaard gingen met de laagste

standaardafwijking. De standaardafwijking beschrijft namelijk in welke mate de waarden in een dataset afwijken van het gemiddelde, m.a.w. is het de mate waarin de waarden van een dataset onderling van elkaar verschillen (H.-Y. Kim, 2013). Dit kan betekenen dat de optimale parameters niet toevallig de laagste gemiddelde validatie MAE hadden in vergelijking met de andere gemiddelde validatie MAE waardes, gepaard gaande met grotere standaardafwijkingen, van de desbetreffende parameters. Bovendien is het ook opvallend dat de waardes van de optimale hyperparameters, uitgezonderd het aantal epochs, overeenkomen met de parameters die werden gebruikt voor bepaling van het aantal convolutielagen. Indien dit al of niet toevallig is zou de bepaling van het aantal convolutielagen opnieuw moeten gebeuren, maar met andere hyperparameters, alsook de bepaling van de optimale hyperparameters. Vervolgens dient opgemerkt te worden dat bij het ontwikkelen van het model een “trade off” gemaakt werd tussen het nemen van een voldoende aantal convolutielagen, zodat het model kenmerkenextractie op een redelijk niveau kon uitvoeren, en overfitting. Doordat bij de analyse van de training- en validatie loss (MSE)-curves en de training- en validatie MAE-curves voor bepaling van het optimale aantal epochs lichte overfitting werd waargenomen kan dit een invloed hebben bij de verdere analyses m.b.t. het onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model (zie 4.2). Daarentegen werd in eerder onderzoek uitgevoerd door Xu et al. (2023) aangetoond dat de modelstructuur van een CNN dient afgestemd te zijn op de omvang van de dataset en de complexiteit van de taak. Dit betekent dat het ontwikkelde CNN-model, waarvan de schattings- en generalisatieprestaties verder worden onderzocht, is afgestemd op een relatief kleine dataset, 198 afbeeldingen en rekening houdend met data-augmentatie (zie 3.5.1.1), en de bepaling van het vers- en drooggewicht (complexiteit van de taak) van sla.

4.2 Onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model

4.2.1 Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak

4.2.1.1 Resultaten


De resultaten voor het onderzoeken van het schattingsvermogen van het CNN-model voor het vers- en drooggewicht van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak worden weergegeven in Tabel 4-4. De bijhorende scatterplots zijn in Bijlage H, Figuur H-1(a-b) tot en met Figuur H-3(a-b) terug te vinden.

Het ontwikkelde CNN-model toont voor de voorspellingen van het versgewicht van de sla-cultivars Emeldia RZ en Limambo RZ nagenoeg gelijke R^2 - alsook NRMSE-waarden bij zowel de RGB-camerabeelden genomen onder een camerahoek van 45° als onder een camerahoek van 90°. De voorspellingen bij beide camerahoeken vertonen dezelfde R^2 -waarde van 0,97. Bovendien vertonen de camerahoeken nagenoeg gelijke NRMSE-waarden met respectievelijk 0,20 en 0,19. Voor de voorspellingen van het drooggewicht is hetzelfde waar te nemen waarbij respectievelijk de R^2 -waarden (ca. 0,94 – 0,95) en de NRMSE-waarden (ca. 0,23 – 0,27) van

beide cultivars nagenoeg gelijk zijn. De voorspellingen van het vers- en drooggewicht bij de RGB-camerabeelden genomen onder een camerahoek van 0° vertonen echter lagere R²-waarden (0,86) en hogere NRMSE-waarden (~ 0,39). Dit is ook zichtbaar op de scatterplots van de voorspellingen voor zowel het vers- als drooggewicht bij de RGB-camerabeelden genomen onder een camerahoek van 0° (Figuur 4-2 (a-b); Bijlage H, Figuur H-1(a-b)). Op elke scatterplot is namelijk bij de geschatte gewichten een overschatting waar te nemen dat verder toeneemt naarmate het werkelijke gewicht toeneemt. Bovendien zijn de schattingsprestaties voor de bepaling van zowel het vers- als drooggewicht bij de verschillende camerahoeken (0°, 45° en 90°) nagenoeg gelijk aangezien de R²- en NRMSE-waarden telkens binnen een zelfde bereik liggen.

Tabel 4-4 De resultaten voor het onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model voor het vers- en drooggewicht van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak.

Camerahoek	Cultivar	Teeltronde	Vergewicht (g)			Drooggewicht (g)		
			R ²	RMSE (g)	NRMSE	R ²	RMSE (g)	NRMSE
0°	Emeldia RZ en Limambo RZ	1	0,86	37,64	0,41	0,86	1,56	0,38
45°	Emeldia RZ en Limambo RZ	1	0,97	24,22	0,20	0,94	1,36	0,27
90°	Emeldia RZ en Limambo RZ	1	0,97	15,88	0,19	0,95	0,87	0,23



Figuur 4-2 Scatterplot met het voorspelde vergewicht uitgezet t.o.v. het werkelijke vergewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een camerahoek van 0° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R², RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.

4.2.1.2 Discussie

De hoge R^2 -waarden (ca. 0,94 – 0,97) bij de RGB-afbeeldingen genomen onder een camerahoek van 45° en 90° tonen aan dat het CNN-model een groot deel van de variatie in vers- en drooggewicht o.b.v. de desbetreffende camerabeelden kan verklaren. Dit betekent dat het CNN-model goed het onderscheid kan maken tussen slaplanten met lagere en hogere vers- en drooggewichten o.b.v. de RGB-afbeeldingen genomen onder een camerahoek van respectievelijk 45° en 90°. Bovendien tonen de bijhorende relatief lage NRMSE-waarden (ca. 0,19 – 0,27) aan dat de vers- en drooggewichten met een zekere nauwkeurigheid kunnen worden geschat. Gelijkaardige resultaten werden ook door Zhang et al. (2020) bekomen voor de bepaling van het vers- en drooggewicht van sla m.b.v. RGB-D-camerabeelden genomen onder een camerahoek van 90° t.o.v. het grondoppervlak. In deze studie werden voor de voorspellingen van het vers- en drooggewicht R^2 -waarden van respectievelijk 0,8983 en 0,8910 met NRMSE-waarden van respectievelijk 0,26 en 0,2207 bekomen. Onderzoek uitgevoerd door Xu et al. (2023) toont ook gelijkaardige resultaten voor de bepaling van het versgewicht van sla bij RGB-camerabeelden genomen onder een camerahoek van 90° met $R^2 = 0,9137$ en NRMSE = 0,2367. Daarnaast ontwikkelde Gang et al. (2022) een op CNN-gebaseerd model voor onder andere de bepaling van het vers- en drooggewicht van sla o.b.v. RGB-D-afbeeldingen. In dit onderzoek bedroegen de R^2 -waarden voor de bepaling van het vers- en drooggewicht allebei 0,95 en de NRMSE-waarden bedroegen (in het onderzoek bekomen volgens Vergelijking 3-7; zie 3.6) respectievelijk 0,0609 en 0,0630. Deze resultaten komen ook nagenoeg overeen met de resultaten verkregen bij het zelf ontwikkelde CNN-model in combinatie met RGB-camerabeelden genomen onder een camerahoek van 90°. Waar dat voor de bepaling van het vers- en drooggewicht van sla R^2 -waarden van respectievelijk 0,97 en 0,95 met NRMSE-waarden (verkregen volgens Vergelijking 3-7; zie 3.6) van respectievelijk 0,0462 en 0,0606 werden bekomen. Resultaten van onderzoek voor de bepaling van het vers- en drooggewicht van sla d.m.v. een CNN bij RGB-(D)-camerabeelden genomen onder een camerahoek van 0° en 45° t.o.v. het grondoppervlak ontbreken.

De relatief goede schattingsprestaties, hoge R^2 -waarden en relatief lage NRMSE-waarden, van het ontwikkelde CNN-model in combinatie met RGB-afbeeldingen onder een camerahoek van respectievelijk 45° en 90° waren te verwachten. Dit omdat de slaplanten waarvan de vers- en drooggewichten werden geschat afkomstig zijn van dezelfde teeltronde, en dus dezelfde teeltomstandigheden, alsook behoren tot dezelfde sla-cultivars van de slaplanten gebruikt voor training en validatie van het model. Ondanks dat lichte overfitting werd waargenomen bij de ontwikkeling van het CNN-model zijn er sterke schattingsprestaties onder een camerahoek van respectievelijk 45° en 90° aanwezig. Bij eventuele afwezigheid van deze lichte overfitting zouden de schattingsprestaties zelfs nog hoger kunnen gelegen hebben.

Ondanks de verwachting dat goede schattingsprestaties bij de RGB-afbeeldingen onder een camerahoek van zowel 0°, 45° en 90° zouden voorvallen wast dit echter minder het geval bij de camerahoek van 0°. Aangezien de schattingsprestaties van het CNN-model, met $R^2 \sim 0,87$ en NRMSE $\sim 0,38$ -0,41, bij RGB-camerabeelden van 0° lager waren dan deze onder een camerahoek van respectievelijk 45° en 90°. Het verschil tussen de schattingsprestaties is mogelijks te verklaren doordat bij de camerahoeken van 90° alsook van 45° een groter geheel van de slaplant te analyseren is terwijl dit bij de camerahoek van 0° minder is. Dit betekent dat bij de beeldanalyse van RGB-afbeeldingen genomen onder een hoek van 0° een zekere vorm van occlusie optreedt. Dit verwijst naar het fenomeen wanneer een deel van een 3D-beeld (in dit geval de slaplant) niet zichtbaar is voor de camera of een andere sensor (Sinha, 2021). Bij de camerabeelden genomen onder een camerahoek van 0° is dit het geval aangezien hierbij

bepaalde delen van de slaplant andere delen van het zicht van de camera onttrekken. Dit heeft als gevolg dat de kenmerkenextractie door het CNN-model groter en beter is bij RGB-camerabeelden genomen onder een camerahoek van 90° en 45° dan bij de beelden genomen onder een camerahoek van 0°. Hetzelfde probleem met betrekking tot occlusie trede op bij Kliman et al. (2025) waarbij een geautomatiseerd systeem werd ontwikkeld voor het schatten van de biomassa van wortels en scheuten gedurende de levenscyclus van een plant in hydrocultuursystemen. Hier trede occlusie op wanneer delen van de wortelstructuur andere delen aan het zicht van de camera onttrokken, wat leidde tot onvolledige of minder nauwkeurige reconstructies. Bovendien toonde ook Tan et al. (2023), die de schatting van het versgewicht van sla op basis van schuine afbeeldingen onderzochten, aan dat extreem hoge of lage opnamehoeken (in dit geval de camerahoek van 0°) tot sterke occlusie van de sla-afbeeldingen kunnen leiden. Wat ook de systematische overschattingen van zowel het vers- als drooggewicht bij toenemend werkelijk gewicht op de scatterplots (Figuur 4-2) bij een camerahoek van 0° kan verklaren. Ten slotte zou bij de afwezigheid van lichte overfitting door het model, net zoals bij de camerahoeken van 45° en 90°, de schattingsprestaties eventueel nog hoger kunnen gelegen hebben.

4.2.2 Onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak

4.2.2.1 Resultaten

Om na te gaan hoe het CNN-model presteerde bij het schatten van het vers- en drooggewicht van sla geteeld bij een andere teeltronde, alsook hoe het model presteerde per sla-cultivar, werd het vers- en drooggewicht van de sla-cultivars Emeldia RZ teeltronde 2, Limambo RZ teeltronde 2 en Volumia bepaald. Dit gebeurde bij RGB-camerabeelden genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak. De resultaten worden weergegeven in Tabel 4-5. De bijhorende scatterplots zijn in Bijlage H, Figuur H-4(a-f) tot en met Figuur H-6(a-f) terug te vinden.


Bij elke camerahoek zijn de hoogste R^2 -waarden met de laagste NRMSE-waarden waar te nemen bij de sla-cultivar Limambo RZ ($R^2 \sim 0,90 - 0,96$ en $NRMSE \sim 0,20 - 0,33$) met daarop volgend deze van Emeldia RZ ($R^2 \sim 0,78 - 0,89$ en $NRMSE \sim 0,31 - 0,47$) en ten slotte van de cultivar Volumia ($R^2 \sim 0,45 - 0,69$ en $NRMSE \sim 0,45 - 0,71$). Bij analyse van de scatterplots zijn over het algemeen, onafhankelijk van de camerahoek, systematische onderschattingen van zowel het vers- als drooggewicht bij Limambo RZ waar te nemen. Terwijl bij de sla-cultivars Emeldia RZ en Volumia zekere krommingspatronen van de puntenwolken waar te nemen zijn. Dit ten gevolge van overschattingen bij de lagere gewichtssegmenten en onderschattingen bij de hogere gewichtssegmenten. Bovendien werden bij de voorspellingen van de vers- en drooggewichten van de sla-cultivars Emeldia RZ en Limambo RZ onder sommige camerahoeken negatieve waarden, wat fysisch onmogelijk is, bij de laagste werkelijke gewichten geschat. Daarentegen was dit niet het geval, ongeacht de camerahoek, bij de cultivar Volumia. Figuur 4-3(a-f) geeft een algemeen voorbeeld van de patronen die op de scatterplots van de verschillende camerahoeken en sla-cultivars worden waargenomen. De individuele scatterplots m.b.t. de bepaling van het vers- en drooggewicht per camerahoek en cultivar kunnen in Bijlage H, Figuur H-4(a-f) tot en met Figuur H-6(a-f) geraadpleegd worden.

Voor de bepaling van het vers- en drooggewicht van de sla-cultivar Emeldia RZ alsook van Limambo RZ bij de camerahoeken van 0° en 45° zijn de R^2 - en NRMSE-waarden nagenoeg gelijk. Bij de sla-cultivar Emeldia RZ liggen de R^2 - en NRMSE-waarden respectievelijk in een bereik van ca. 0,86 – 0,89 en ca. 0,31 – 0,38. Voor Limambo RZ is dit respectievelijk ca. 0,95 – 0,96 en ca. 0,20 – 0,24. Bij de camerahoek van 90° liggen de R^2 -waarden lager en de NRMSE-waarden hoger bij deze cultivars. Met $R^2 \sim 0,78 - 0,81$ en NRMSE $\sim 0,40 - 0,47$ voor Emeldia RZ en bij Limambo RZ $R^2 \sim 0,90 - 0,91$ met NRMSE $\sim 0,29 - 0,33$. Deze resultaten zijn ook waarneembaar op de bijhorende scatterplots. Waarbij de puntenwolken van de cultivar Emeldia RZ bij bepaling van vers- en drooggewicht een meer uitgesproken krommingspatroon hebben (Figuur 4-3(a-b); Bijlage H, Figuur H-6(a-b)). En bij Limambo RZ de onderschatting toeneemt naarmate het werkelijke gewicht toeneemt (Figuur 4-3(c-d); Bijlage H, Figuur H-6(c-d)) terwijl dit bij de camerahoeken van 0° en 45° (Bijlage H, Figuur H-4(c-d) en Figuur H-5(c-d)) minder het geval is.

In tegenstelling tot bij de sla-cultivars Emeldia RZ en Limambo RZ zijn voor Volumia, bij zowel bepaling van het vers- als drooggewicht, de R^2 -waarden ($\sim 0,64 - 0,69$) het grootst en de NRMSE-waarden ($\sim 0,45 - 0,57$) het laagst bij de camerahoek van 90°. Ondanks dat bij elke camerahoek de R^2 - en NRMSE-waarden voor zowel bepaling van het vers- als drooggewicht bij Emeldia RZ en Limambo RZ nagenoeg gelijk waren is er bij Volumia toch een zeker verschil waar te nemen. Bij elke camerahoek liggen de R^2 -waarden voor bepaling van het drooggewicht met ca. 0,05 hoger dan bij de bepaling van het versgewicht. Daarbij horend liggen de NRMSE-waarden voor de bepaling van het drooggewicht met ca. 0,14 lager dan bij de bepaling van het versgewicht. Daarentegen zijn de R^2 - en NRMSE-waarden voor de bepaling van het versgewicht van de sla-cultivar Volumia bij de camerahoeken van 0° en 45° nagenoeg gelijk. Hierbij is $R^2 \sim 0,45 - 0,48$ met NRMSE $\sim 0,69 - 0,71$. Hetzelfde geldt bij de bepaling van het drooggewicht met $R^2 \sim 0,50 - 0,55$ en NRMSE $\sim 0,54 - 0,57$.

Tabel 4-5 Resultaten voor het voorspellen van het vers- en drooggewicht van de sla-cultivar Emeldia RZ teeltronde 2, de sla-cultivar Limambo RZ teeltronde 2 en de sla-cultivar Volumia met RGB-camerabeelden genomen onder een afzonderlijke camerahoek van respectievelijk 0°, 45° en 90° t.o.v. het grondoppervlak voor het onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model.

Camerahoek	Cultivar	Teeltronde	Versgewicht (g)			Drooggewicht (g)		
			R^2	RMSE (g)	NRMSE	R^2	RMSE (g)	NRMSE
0°	Emeldia RZ	2	0,88	50,36	0,34	0,89	1,89	0,31
	Limambo RZ	2	0,95	10,35	0,24	0,96	0,43	0,20
	Volumia	1	0,45	105,67	0,71	0,50	3,43	0,57
45°	Emeldia RZ	2	0,86	55,30	0,38	0,86	2,08	0,34
	Limambo RZ	2	0,96	8,54	0,20	0,96	0,43	0,20
	Volumia	1	0,48	102,89	0,69	0,55	3,25	0,54
90°	Emeldia RZ	2	0,78	69,39	0,47	0,81	2,48	0,40
	Limambo RZ	2	0,90	14,21	0,33	0,91	0,62	0,29
	Volumia	1	0,64	85,30	0,57	0,69	2,72	0,45



Figuur 4-3 Algemeen voorbeeld van de patronen die op de scatterplots van de verschillende camerahoeken en sla-cultivars worden waargenomen: scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor de sla-cultivar Emeldia RZ teeltronde 2 (a-b), de sla-cultivar Limambo RZ teeltronde 2 (c-d) en de sla-cultivar Volumbia (e-f) met RGB-camerabeelden genomen onder een camerahoek van 90° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.

4.2.2.2 Discussie

Globaal gezien vertoonde het ontwikkelde CNN-model de beste schattingsprestaties bij de sla-cultivars Emeldia RZ en Limambo RZ (hogere R^2 -waarden met lagere NRMSE-waarden) in vergelijking met deze bij de cultivar Volumia (lagere R^2 -waarden met hogere NRMSE-waarden). Idealiter zouden de schattingsprestaties voldoende hoog en gelijkaardig moeten zijn, ongeacht de cultivar en teeltronde, om te kunnen spreken over een algemeen sterk generalisatievermogen van het model. Dit was echter niet het geval. Daarentegen waren de betere schattingsprestaties bij Emeldia RZ en Limambo RZ in vergelijking met deze bij de cultivar Volumia wel te verwachten. Dit aangezien RGB-afbeeldingen van de cultivars Emeldia RZ en Limambo RZ, enkel afkomstig van een andere teeltronde (teeltronde 1), al te zien waren door het model tijdens het trainingsproces. In tegenstelling tot bij Volumia was dit niet het geval waardoor deze cultivar volledig onbekend was voor het ontwikkelde CNN-model. Bovendien zijn de verschillen in generalisatievermogen van het model groter tussen de sla-cultivars dan tussen de camerahoeken. Dit betekent dat de invloed van de verschillende camerahoeken op het generalisatievermogen van het CNN-model minder groot is dan bij het verschil in sla-cultivar.

Tussen de verschillende sla-cultivars, onafhankelijk van de camerahoek, zijn duidelijke verschillen in generalisatievermogen waar te nemen. Het CNN-model vertoonde het sterkste generalisatievermogen bij de cultivar Limambo RZ ($R^2 \sim 0,90 - 0,96$ en $NRMSE \sim 0,20 - 0,33$). Aangezien Limambo RZ een cultivar van het sla-type bladsla is, kan dit morfologisch verklaard worden doordat bladsla een meer uniforme vegetatieve groei vertoont zonder duidelijke groeifasen, wat leidt tot consistentere visuele kenmerken die het model beter kan leren. Bovendien waren op de scatterplots, onafhankelijk van de camerahoek, systematische onderschattingen van de vers- en drooggewichten waar te nemen. Mogelijks heeft dit te maken met de gekrulde bladeren die ongelijkmatige krullingen vertonen. Volgens Zhang et al. (2020) zorgen deze krullingen van de bladeren ervoor dat de geleerde kenmerken door het model niet uitgebreid genoeg waren om rekening te houden met de, t.g.v. de krullingen, bedekte en verborgen bladgedeeltes. Dit verklaart mogelijks de systematische onderschattingen op de scatterplots waarbij het model minder rekening houdt met de bedekte en verborgen bladgedeeltes die ook zorgen voor bijkomend werkelijk vers- en drooggewicht.

Het CNN-model vertoonde bij de sla-cultivar Emeldia RZ een lager generalisatievermogen ($R^2 \sim 0,78 - 0,89$ en $NRMSE \sim 0,31 - 0,47$) dan bij Limambo RZ. Dit was over het algemeen ook waar te nemen op de scatterplots bij de voorspellingen van zowel het vers- als drooggewicht van Emeldia RZ. Hierbij werden zekere krommingspatronen van de puntenwolken ten gevolge van overschattingen bij de lagere gewichtssegmenten en onderschattingen bij de hogere gewichtssegmenten waargenomen. Dit patroon kan, aangezien Emeldia RZ tot het sla-type botersla behoort, mogelijks verklaard worden door de drie groeifases bij de kropvorming van botersla (zie 2.1.3). Bij de kleinere slaplanten is het ontwikkelde CNN-model in zekere mate nog in staat zowel het vers- als drooggewicht van de planten te voorspellen. Dit is ook in de groeifase (aanlooperperiode) waar de bladeren van de slaplanten nog afzonderlijk herkenbaar zijn. Naarmate het werkelijke gewicht toenam vonden er overschattingen plaats, mogelijks zaten de slaplanten in de opbouwperiode waarbij de vorming van de kropvormende bladeren plaatsvond. Daardoor verandert de verhouding tussen de zichtbare structuur en werkelijke biomassa van de slaplant, wat gedeeltelijk kan bijdragen aan de geobserveerde overschattingen. Bij de zwaarste werkelijke vers- en drooggewichten vonden onderschattingen plaats, dit kan gekoppeld worden aan het feit dat de slaplanten in de afrijpingsperiode zaten. In deze periode zullen de planten op gewicht komen door strekking van de kropbladeren

waardoor de visuele grootte van de plant in mindere mate correleert met het werkelijke vers- en drooggewicht (Benoit et al., 1989). Een toenemende overlap van de slabladeren tijdens de ontwikkeling van het sla-type botersla kan mogelijks ook leiden tot moeilijkere inschattingen van het vers- en drooggewicht door het CNN-model. Bovendien kwamen ook bij Tan et al. (2023), die de schatting van het versgewicht van sla op basis van schuine afbeeldingen onderzochten, overschattingen van het versgewicht bij rode botersla in het late groeistadium voor. Volgens Tan et al. (2023) kunnen deze onderschattingen worden toegeschreven aan de dikkere bladeren aan de randen van de botersla. Waardoor de kans op occlusie toeneemt en beeldkenmerken van de slaplant in het geoccludeerde gebied verloren gaan. Bovendien werd ook gesteld dat de onderschattingen, en de bijhorende schattingsfouten, door het model ook verklaard kunnen worden doordat de trainingsset van het model minder gegevens bevatte die overeenkwamen met het late groeistadium. Daarentegen ontbreken resultaten van onderzoek naar het generalisatievermogen bij de bepaling van het vers- en drooggewicht van sla doormiddel van een CNN-model o.b.v. RGB-camerabeelden voor meerdere verschillende cultivartypes. De bevindingen van deze masterproef kunnen een eerste aanzet bieden voor verder onderzoek hierover.

Het generalisatievermogen van het CNN-model is het laagste bij de sla-cultivar Volumia ($R^2 \sim 0,45 - 0,69$ en $NRMSE \sim 0,45 - 0,71$). Dit is te verklaren doordat deze cultivar afkomstig was van andere teeltomstandigheden (externe slateler) in combinatie met dat het CNN-model nooit in aanraking is gekomen met RGB-afbeeldingen van deze specifieke cultivar. Net zoals bij de sla-cultivar Emeldia RZ zijn op de scatterplots, onafhankelijk van de camerahoek, bij zowel het schatten van het vers- als drooggewicht zekere krommingspatronen waar te nemen. Aangezien Volumia ook tot het sla-type botersla behoort kan mogelijks dezelfde verklaring worden gegeven als bij Emeldia RZ.

Het generalisatievermogen van het model voor de bepaling van het vers- en drooggewicht bij de sla-cultivars Emeldia RZ (botersla) en Limambo RZ (bladsla) is het grootste bij de camerahoeken van 0° en 45° . Terwijl dit bij de RGB-afbeeldingen genomen onder een camerahoek van 90° minder was. Deze bevindingen zijn tegenstrijdig met de resultaten bij het onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model (zie 4.2.1). Hierbij waren de schattingsprestaties van het model sterker bij een camerahoek van zowel 45° en 90° dan bij 0° . Een mogelijke verklaring is dat de RGB-afbeeldingen bij de camerahoek van 0° een robuustere 3D-informatie, zoals compactheid, verticale plantstructuur en zichtbaarheid van interne bladlagen, bevatten. Waardoor een algemene generaliseerbaarheid van het model bij cultivars afkomstig van verschillende teeltrondes mogelijk is. Daarentegen treedt bij deze camerahoek occlusie op (zie 4.2.1) wat maakt dat de schattingsnauwkeurigheden van het model bij deze hoek beperkt blijven. Het goede schattingsvermogen van het ontwikkelde CNN-model bij de camerahoek van 90° is mogelijks te verklaren doordat het model tijdens het trainingsproces voornamelijk de correlatie heeft gemaakt tussen de bladoppervlakte (ofwel het aantal groene pixels) en het vers- en drooggewicht van de slaplant. Dit maakt dat de schattingsprestaties bij slaplanten van dezelfde teeltronde, die ook aanwezig waren bij het trainingsproces van het model, accuraat zijn aangezien een gelijkaardige plantmorfologie van de slaplanten aanwezig is ten gevolge van dezelfde teeltomstandigheden. Bij dezelfde cultivar, maar geteeld onder andere teeltomstandigheden, kan er een verschil zijn in plantmorfologie, en dus ook in bladoppervlakte. Dit kan leiden tot verkeerde inschattingen van het vers- en drooggewicht van de slaplanten door het CNN-model. Daarentegen werden gelijkaardige resultaten bekomen door Zhang et al. (2020) die een generalisatietest hadden uitgevoerd door ook een voorgetraind CNN-model rechtstreeks toe te passen op afbeeldingen, genomen langs

boven (cfr. camerahoek van 90°) van Tiberius (gewastype Cos) die in een ander groeiseizoen (seizoen 2) zijn geteeld. Hierbij waren de schattingsprestaties voor bepaling van het vers- en drooggewicht gekenmerkt met R^2 -waarden van respectievelijk 0,9277 en 0,9126 met bijhorende NRMSE-waarden van respectievelijk 0,2269 en 0,3792. Bovendien werd door Zhang et al. (2020) opgemerkt dat het verkrijgen van beelden van de slaplanten van bovenaf een beperking geven aangezien de schattingsfout kan toenemen als er te veel overlappingen tussen de bladeren zijn. Dit kan eventueel ook een verklaring zijn voor het lagere generalisatievermogen bij RGB-afbeeldingen genomen onder een camerahoek van 90°.

Ten slotte vertoonde het ontwikkelde CNN-model bij, de sla-cultivars Emeldia RZ en Limambo RZ, zowel een sterk schattings (zie 4.2.1)- als generalisatievermogen bij RGB-camerabeelden benomen onder een camerahoek van 45° ten opzichte van het grondoppervlak. Dit is te verklaren doordat het CNN-model een groter gedeelte van de plant kan analyseren terwijl dit bij de camerahoek van 0° (enkel zijkant slaplant) en 90° (enkel bovenzijde slaplant) meer beperkt is. Khun et al. (2021) voerde onderzoek naar het gebruik van schuine RGB-beelden en het schijnbare oppervlak van planten voor een vroege schatting van de bovengrondse biomassa van maïs. Hieruit werd ook geconcludeerd dat het gebruik van schuine camerabeelden, meer specifiek bij een hoek van 30° t.o.v. de verticale as voor het schatten van de maïsbiomassa, de beste resultaten opleverden. Volgens Khun et al. (2021) zou het gebruik van schuine fotografie meer flexibiliteit bieden bij data-acquisitie met minder logistieke beperkingen, en deze aanpak een efficiënte manier kan zijn om de gewasbiomassa van planten te monitoren. Daarnaast toonden ook Tan et al. (2023) aan dat schuine beeldvorming voor de groeimonitoring, meer specifiek voor de bepaling van het versgewicht, van sla potentieel biedt.

In tegenstelling tot bij de sla-cultivars Emeldia RZ en Limambo RZ waren de resultaten van het generalisatievermogen bij Volumia, bij zowel bepaling van het vers- als drooggewicht, net omgekeerd. De R^2 -waarden (~ 0,64 – 0,69) waren het grootst en de NRMSE-waarden (~ 0,45 - 0,57) het laagst bij de camerahoek van 90°. Dit is opvallend aangezien eerder verwacht zou worden dat het laagste generalisatievermogen bij Volumia ook bij de camerahoek van 90° zou vallen, zoals vastgesteld werd bij Emeldia RZ en Limambo RZ. Daarentegen ligt dit wel in lijn met de goede schattingsresultaten bij RGB-camerabeelden genomen onder een hoek van 90° bij het onderzoeken van het schattingsvermogen van het CNN (zie 4.2.1). Een eenduidige verklaring voor dit omgekeerde patroon is moeilijk te geven, aangezien bij Volumia de combinatie optrad van een volledig ongeziene cultivar en andere teeltomstandigheden ten opzichte van de trainingsdata, waardoor de invloed van beide factoren afzonderlijk moeilijk te beoordelen is. Toekomstig onderzoek waarbij deze factoren afzonderlijk onderzocht worden, zou meer inzicht kunnen bieden in de relatieve bijdrage van cultivar-specificiteit en teeltomstandigheden op het generalisatievermogen van het CNN-model. Daarnaast tonen deze resultaten wel aan dat RGB-afbeeldingen genomen onder een camerahoek van 90° ook een potentiële bijdrage kunnen leveren aan het generalisatievermogen van het ontwikkelde CNN-model. Resultaten van onderzoek voor de bepaling van het vers- en drooggewicht van sla doormiddel van een CNN o.b.v. RGB-camerabeelden op volledig onbekende data (onbekende sla-cultivar geteeld bij andere teeltomstandigheden) ontbreekt. De bevindingen van deze masterproef kunnen een eerste aanzet bieden voor verder onderzoek hierover.

Bovendien werden bij de voorspellingen van de vers- en drooggewichten van de sla-cultivars Emeldia RZ en Limambo RZ onder sommige camerahoeken negatieve waarden, wat fysisch onmogelijk is, bij de laagste werkelijke gewichten geschat. Dit is het gevolg van het gebruik van de activatiefunctie “linear” in de uitvoerlaag dat standaard wordt toegepast bij

regressieproblemen om numerieke waarden, zoals het vers- en drooggewicht van sla, te kunnen voorspellen. Deze activatiefunctie zorgt ervoor dat de output in het volgende bereik ligt: $-\infty$ tot $+\infty$. Waardoor het CNN-model bij zeer lage vers- en drooggewichten, waarbij beperkte visuele informatie van de slaplanten op RGB-camerabeelden beschikbaar is, kan extrapoleren buiten het geobserveerde trainingsdomein en daarbij fysisch onmogelijke negatieve waarden gaat voorspellen (GeeksforGeeks, 2026; Lederer, 2021; Moez, 2025).

Daarentegen dient opgemerkt te worden dat CNN's, net zoals andere AI-modellen, een typisch black-box-karakter hebben. Dit betekent dat de ontwikkelaars van het model niet met grote zekerheid kunnen zeggen hoe CNN-modellen redeneren om tot bepaalde outputs te komen (Haar et al., 2023). Volgens Mostafa et al. (2023) beperkt dit black-box-karakter het vermogen voor plantwetenschappers om de relatie tussen de resultaten van het CNN-model en de planteigenschappen te begrijpen. Dit betekent dat de hiervoor besproken morfologische verklaringen van de resultaten m.b.t. het generalisatievermogen van het ontwikkelde CNN-model met zekere voorzichtigheid geïnterpreteerd moeten worden. Verdere onderzoeken, alsook het gebruik van *explainable AI* (XAI)-technieken, kunnen meer inzicht geven op de beslissingen van CNN's voor de bepaling van het vers- en drooggewicht van sla o.b.v. RGB-camerabeelden. De verklaringen van deze beslissingen kunnen worden gebruikt om het ontwikkelde CNN-model beter te begrijpen en de door het model gedetecteerde kenmerken te relateren aan de planteigenschappen. Op deze manier kan de generaliseerbaarheid van het model ook verder verbeterd worden (Mostafa et al., 2023).

Ten slotte is in deze masterproef slechts gebruikt gemaakt van een beperkt aantal sla-cultivars (Emeldia RZ en Limambo RZ) en een kleine hoeveelheid data (198 RGB-camerabeelden) voor de ontwikkeling van het CNN-model. Mogelijks bevatte het ontwikkelde CNN-model onvoldoende convolutielagen om kenmerkextracties op hogere niveaus, zoals overlapping van de slabladeren, uit te voeren. Dit verklaart dan ook mogelijks, samen met de overfitting door het model dat werd waargenomen bij de ontwikkeling ervan (zie 4.1.3), de fluctuerende generalisatieprestaties. Door in de toekomst een grotere hoeveelheid data te gebruiken kan het model uitgebreid worden (meer convolutielagen) waardoor kenmerkextracties op hogere niveaus mogelijk worden alsook overfitting kan vermeden worden. Hierdoor kunnen de generalisatieprestaties verbeterd worden. Daarnaast kan het gebruik van meer verschillende sla-cultivars, al of niet geteeld onder andere teeltomstandigheden, de variabiliteit in de dataset verhogen wat mogelijks ook de generaliseerbaarheid van het model kan verbeteren.

4.2.3 Onderzoeken van het schattingsvermogen van het ontwikkelde CNN-model bij RGB-afbeeldingen genomen onder een combinatie van camerahoeken van 0°, 45° en 90° t.o.v. het grondoppervlak

4.2.3.1 Resultaten

Bij deze laatste proef werd nagegaan hoe het ontwikkelde CNN-model presteerde wanneer alle RGB-afbeeldingen van de verschillende camerahoeken en sla-cultivars, afkomstig van zowel teeltronde 1 en 2, als trainingsdata werden gebruikt. Het model werd getraind met RGB-afbeeldingen genomen onder een camerahoek van 0°, 45° en 90° van de sla-cultivar Emeldia RZ en de sla-cultivar Limambo RZ, beide afkomstig van zowel teeltronde 1 als teeltronde 2. De RGB-afbeeldingen genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivar Volumia werden ook gebruikt voor training van het model. De resultaten


worden weergegeven in Tabel 4-6. De bijhorende scatterplots zijn in Bijlage H, Figuur H-7(a-b) tot en met Figuur H-10(a-f) terug te vinden.

Wanneer, ongeacht de camerahoek, cultivar en teeltronde, wordt gekeken naar de schattingsprestaties van het ontwikkelde CNN-model is zowel voor de bepaling van het vers- als drooggewicht een hoge R^2 -waarde met een relatief lage NRMSE-waarde waar te nemen. Voor bepaling van het vers- en drooggewicht zijn de R^2 -waarden respectievelijk 0,92 en 0,93 met bijhorende NRMSE-waarden van respectievelijk 0,34 en 0,29. Daarnaast is op de bijhorende scatterplots (Figuur 4-4; Bijlage H, Figuur H-7(a-b)) waar te nemen dat de spreiding toeneemt naarmate het vers- en drooggewicht toeneemt vanaf respectievelijk ca. 240 g en ca. 9 g.

Bij analyse van de schattingsresultaten per camerahoek, cultivar en teeltronde is een bepaald patroon waar te nemen. Bij de sla-cultivar Limambo RZ behaalt het CNN-model consistent de beste resultaten over alle hoeken en teeltrondes. Voor de bepaling van het vers- en drooggewicht bij Limambo RZ worden R^2 -waarden van respectievelijk ca. 0,90 – 0,99 en ca. 0,86 – 0,98 met NRMSE-waarden van respectievelijk ca. 0,12 – 0,36 en ca. 0,15 – 0,33 waargenomen. Hierop volgend zijn consistent de beste schattingsresultaten voor Emeldia RZ waar te nemen over alle hoeken en teeltrondes. De resultaten geven voor de bepaling van het vers- en drooggewicht R^2 -waarden van respectievelijk ca. 0,80 – 0,92 en ca. 0,84 – 0,92 met bijhorende NRMSE-waarden van ca. 0,30 – 0,52 en ca. 0,27 – 0,42. Het schattingsvermogen bij de cultivar Volumia is het zwakst. Voor de bepaling van het vers- en drooggewicht zijn R^2 -waarden van respectievelijk ca. 0,67 – 0,88 en ca. 0,70 – 0,94 met NRMSE-waarden van respectievelijk ca. 0,30 – 0,58 en ca. 0,19 – 0,48 waar te nemen. Bovendien is het opmerkelijk dat bij het schatten van het vers- en drooggewicht, bij de cultivar Volumia, onder de camerahoek van 90° de beste schattingsresultaten ($R^2 \sim 0,88 - 0,94$ en $NRMSE \sim 0,19 - 0,30$) zijn waar te nemen. Dit komt overeen met de resultaten waargenomen bij het onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model (zie 4.2.2). Daarnaast worden op de bijhorende scatterplots voor de bepaling van het vers- en drooggewicht van Volumia onder de camerahoeken van respectievelijk 0°, 45° en 90° terug zekere krommingspatronen waargenomen (zie Bijlage H, Figuur H-10(a-f)). Deze patronen werden ook waargenomen bij het onderzoeken van het generalisatievermogen van het ontwikkelde CNN-model (zie 4.2.2). Bovendien werden bij de voorspellingen van de vers- en drooggewichten van bepaalde sla-cultivars, teeltrondes en camerahoeken negatieve waarden, wat fysisch onmogelijk is, bij de laagste werkelijke gewichten geschat.

Tabel 4-6 Schattingsresultaten van het ontwikkelde CNN-model bij de verschillende testsets telkens kenmerkend voor een bepaalde sla-variëteit, teeltronde en camerahoek t.o.v. het grondoppervlak.

Camerahoek	Cultivar	Teeltronde	Versgewicht (g)			Drooggewicht (g)		
			R ²	RMSE (g)	NRMSE	R ²	RMSE (g)	NRMSE
0°, 45° en 90°	Emeldia RZ, Limambo RZ en Volumbia	1 en 2	0,92	36,23	0,34	0,93	1,34	0,29
0°	Limambo RZ	1	0,91	26,62	0,24	0,92	0,96	0,21
45°	Limambo RZ	1	0,90	24,17	0,36	0,95	0,73	0,23
90°	Limambo RZ	1	0,90	27,52	0,31	0,86	1,26	0,33
0°	Emeldia RZ	1	0,92	56,59	0,30	0,92	2,04	0,27
45°	Emeldia RZ	1	0,80	61,00	0,43	0,88	1,96	0,32
90°	Emeldia RZ	1	0,92	43,55	0,31	0,90	1,94	0,31
0°	Limambo RZ	2	0,91	15,32	0,27	0,94	0,60	0,21
45°	Limambo RZ	2	0,96	9,18	0,22	0,95	0,51	0,24
90°	Limambo RZ	2	0,99	4,48	0,12	0,98	0,27	0,15
0°	Emeldia RZ	2	0,91	38,44	0,33	0,87	1,73	0,35
45°	Emeldia RZ	2	0,84	46,75	0,52	0,86	1,69	0,42
90°	Emeldia RZ	2	0,86	50,71	0,38	0,84	2,09	0,37
0°	Volumbia	1	0,67	93,09	0,58	0,70	3,05	0,48
45°	Volumbia	1	0,82	63,48	0,37	0,84	2,08	0,31
90°	Volumbia	1	0,88	55,78	0,30	0,94	1,34	0,19



Figuur 4-4 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivar Emeldia RZ, de sla-cultivar Limambo RZ, beide afkomstig van teeltronde 1 en 2, en de sla-cultivar Volumbia met RGB-camerabeelden genomen onder een camerahoek van 0°, 45° en 90° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R², RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.

4.2.3.2 Discussie

De schattingsresultaten tonen aan dat wanneer RGB-camerabeelden van de verschillende camerahoeken, cultivars en teeltrondes samen worden gebruikt bij het trainingsproces van het CNN-model een sterk algemeen schattingsvermogen wordt geleverd. Dit aangezien zowel voor de bepaling van het vers- als drooggewicht een hoge R^2 -waarde ($\sim 0,92 - 0,93$) met een relatief lage NRMSE-waarde ($\sim 0,29 - 0,34$) waar te nemen is, ongeacht de camerahoek, cultivar en teeltronde. Bovendien tonen de bijhorende scatterplots (Figuur 4-4) dat de spreiding toeneemt naarmate het vers- en drooggewicht toeneemt vanaf respectievelijk ca. 240 g en ca. 9 g. Aangezien Limambo RZ (sla-type bladsla) maar werd opgekweekt tot een versgewicht van ca. 250 g met bijhorend drooggewicht van ca. 10 g zullen deze spreidingen te wijten zijn aan de sla-cultivars Emeldia RZ en Volumia (beide van het sla-type botersla) aangezien deze cultivars werden opgekweekt tot een versgewicht van ca. 400 – 500 g met bijhorend drooggewicht van ca. 17 – 20 g. Dit toont mogelijks ook aan dat, net zoals bij het onderzoeken van het generalisatievermogen (zie 4.2.2), het ontwikkelde CNN-model het schatten van het vers- en drooggewicht relatief gezien moeilijker vindt bij Emeldia RZ en Volumia (beide sla-type botersla) dan bij Limambo RZ (sla-type bladsla). Bovendien werden ook hier bij de voorspellingen van de vers- en drooggewichten bij bepaalde sla-cultivars, teeltrondes en camerahoeken negatieve waarden, wat fysisch onmogelijk is, bij de laagste werkelijke gewichten geschat. Hiervoor kan dezelfde verklaring gegeven worden zoals bij 4.2.2.2.

Bij de analyse van de schattingsresultaten per camerahoek, cultivar en teeltronde kan hetzelfde patroon worden waargenomen zoals bij het onderzoeken van het generalisatievermogen. Ook hier vertoont het ontwikkelde CNN-model de beste schattingsprestaties bij Limambo RZ met daaropvolgend Emeldia RZ en ten slotte Volumia. Daarnaast dienen de lagere schattingsprestaties bij Volumia wel met enige voorzichtigheid te worden geïnterpreteerd. Aangezien van Volumia maar een beperkt aantal afbeeldingen beschikbaar waren (per camerahoek 52 RGB-camerabeelden), was de hoeveelheid trainingsdata voor het CNN-model van deze cultivar beperkt t.o.v. de andere cultivars (ongeveer 99 RGB-camerabeelden per camerahoek). Hierdoor heeft het model minder sterk de kans gehad om van de camerabeelden van deze cultivar te leren waardoor dit ook mogelijks de mindere schattingsprestaties kan verklaren (Shahinfar et al., 2020). Voor toekomstig onderzoek is het verder aangewezen om datasets van dezelfde grootte te verkrijgen tussen de verschillende cultivars. Op deze manier kunnen schattingsprestaties van het CNN-model tussen de verschillende cultivars, camerahoeken en teeltrondes beter met elkaar vergeleken worden. Bovendien waren de schattingsprestaties net zoals bij het onderzoeken van het generalisatievermogen (zie 4.2.2) bij Volumia het sterkst bij RGB-camerabeelden genomen onder een camerahoek van 90° t.o.v. het grondoppervlak. Dit laat zien dat het nemen van RGB-camerabeelden boven de slaplanten kan gebruikt worden voor de bepaling van het vers- en drooggewicht m.b.v. een CNN-model. Ten slotte werden op de bijhorende scatterplots voor de bepaling van het vers- en drooggewicht van Volumia onder de camerahoeken van 0° , 45° en 90° zekere krommingspatronen waargenomen. Deze patronen werden ook waargenomen bij het onderzoeken van het generalisatievermogen van het CNN-model (zie 4.2.2). Aangezien het CNN-model tijdens het trainingsproces al met RGB-afbeeldingen van deze cultivar in aanraking is gekomen kunnen de effecten van het verschil in cultivar en teeltronde verwaarloosd worden. Omdat Volumia net zoals Emeldia RZ van het sla-type botersla is kan het krommingspatroon mogelijks, rekening houdend met het black-box-karakter van CNN's, eerder te wijten zijn aan de drie groeifases, en de toenemende overlap van de slabladeren, bij de kropvorming van botersla (zie 4.2.2.2) dan aan het verschil in teeltomstandigheden.

5 BESLUIT

Sla (*Lactuca sativa* L.) is wereldwijd één van de belangrijkste bladgroenten met een breed scala aan toepassingen en kent wereldwijd een jaarlijkse stijging in productie. Slatelers zijn hierdoor genoodzaakt de productie van sla efficiënter te maken. Dit kan behaald worden door het ontwikkelen van gewasmodellen die onder andere bekomen worden door het meten van het vers- en drooggewicht van sla die fungeren als groei-indicatoren. De traditionele methoden, waarbij doorgaans plantenmonsters worden verzameld en analytische instrumenten in een laboratorium worden gebruikt, voor het meten van het vers- en drooggewicht van sla zijn tijdrovend, arbeidsintensief en destructief. Hierdoor is het gebruik van accurate en niet-destructieve meetmethodes voor het meten van het vers- en drooggewicht van sla noodzakelijk. Momenteel wordt er al veel gebruik gemaakt van computervisie-gebaseerde methoden voor het schatten van groei-gerelateerde kenmerken van land- en tuinbouwgewassen. Ondanks dat verschillende computervisie-gebaseerde methoden veelbelovende resultaten opleveren voor het schatten van groei-gerelateerde kenmerken kampen deze methoden met enkele problemen zoals de gevoeligheid voor ruis, het beperkte generalisatievermogen en de grote rekenkundige complexiteit. Een potentieel alternatief voor destructieve en computervisie-gebaseerde meetmethodes is het gebruik van RGB-camera's in combinatie met een CNN voor het bepalen van het vers- en drooggewicht van sla op een accurate en niet-destructieve manier. Dit aangezien RGB-camera's breed toepasbaar zijn en CNN's visuele data, zoals RGB-afbeeldingen, met een accurate en hoge efficiëntie kunnen verwerken en analyseren. Het doel van deze masterproef is om de mogelijkheden te onderzoeken voor het gebruik van CNN's met RGB-afbeeldingen voor de bepaling van het vers- en drooggewicht van sla gedurende een gehele teeltronde onder praktijkomstandigheden.

De resultaten geven aan dat het CNN-model met het meest accurate schattingsvermogen bestaat uit 5 convolutielagen en volgende hyperparameters: een leersnelheid van 0,001; een batchgrootte van 10 en een aantal epochs van 200. Daarnaast dient opgemerkt te worden dat bij het ontwikkelen van het model een "trade off" gemaakt werd tussen een voldoende aantal convolutielagen voor kenmerkextractie op een redelijk niveau en overfitting, waarbij lichte overfitting werd vastgesteld tijdens het trainingsproces. Dit kan een invloed hebben bij de verdere analyses m.b.t. het onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model. Tenslotte dient opgemerkt te worden dat het ontwikkelde CNN-model, is afgestemd op een relatief kleine dataset, 198 afbeeldingen en rekening houdend met de uitbreiding van de dataset via data-augmentatie, en de bepaling van het vers- en drooggewicht (complexiteit van de taak) van sla.

Het ontwikkelde CNN-model is in staat om accuraat het vers- en drooggewicht te schatten van slaplanten die behoren tot sla-cultivars die reeds aanwezig waren in de trainingsdata en geteeld werden onder gelijkaardige teeltomstandigheden, mits voldoende trainingsdata beschikbaar is. Dit toont aan dat de combinatie van CNN's met RGB-afbeeldingen potentieel bieden voor de bepaling van het vers- en drooggewicht van sla gedurende een gehele teeltronde. Echter vertoont het model fluctuerende generalisatieprestaties die sterk cultivar-afhankelijk zijn, wat aantoont dat de voorgestelde methode onvoldoende robuust is over alle cultivars en teeltomstandigheden voor een brede praktische toepassing. Daarnaast was er bij de schattingsprestaties ook een zeker verschil tussen de cultivars waar te nemen. Dit toont

aan dat de schattings- en generalisatieprestaties door het CNN mogelijks afhankelijk zijn van de verschillen in morfologie tussen de sla-cultivars. Bovendien tonen de relatief beperkte verschillen in generalisatievermogen tussen de camerahoeken aan dat het CNN-model een zekere robuustheid heeft bij variatie in camerahoeken, wat in de praktijk zou kunnen voorkomen wanneer RGB-afbeeldingen handmatig worden genomen. Daarentegen kan over het algemeen wel besloten worden dat RGB-camerabeelden genomen onder een camerahoek van respectievelijk 45° en 90° aangewezen zijn om te gebruiken voor het bepalen van het vers- en drooggewicht van sla met een CNN. Over het algemeen zijn deze camerahoeken in de praktijk ook de meest voor de hand liggende opties. Zo kunnen RGB-camerabeelden afkomstig van draagbare apparaten (zoals fotocamera's of mobiele telefoons), drones, tractoren of vaste cameraopstellingen gebruikt worden voor de bepaling van het vers- en drooggewicht van sla doormiddel van CNN's. Op basis van de bekomen resultaten kan over het algemeen geconcludeerd worden dat het gebruik van CNN's met RGB-afbeeldingen mogelijkheden biedt voor niet-destructieve schattingen van het vers- en drooggewicht van sla, maar dat de toepasbaarheid onder praktijkomstandigheden momenteel nog beperkt is.

In deze masterproef werd slechts gebruikt gemaakt van een beperkt aantal sla-cultivars (Emeldia RZ en Limambo RZ) en een kleine hoeveelheid data (195 RGB-camerabeelden) voor de ontwikkeling van het CNN-model. Mogelijks bevatte het ontwikkelde CNN-model onvoldoende convolutielagen om kenmerkextracties op hogere niveaus, zoals overlapping van de slabladeren, uit te voeren. Dit verklaart dan ook de fluctuerende cultivar-afhankelijke generalisatieprestaties. Door in de toekomst een grotere hoeveelheid data te gebruiken kan het model uitgebreid worden (meer convolutielagen) waardoor kenmerkextracties op hogere niveaus mogelijk worden alsook overfitting kan worden vermeden. Hierdoor kunnen de generalisatieprestaties verbeterd worden. Daarnaast kan het gebruik van meer verschillende sla-cultivars, al of niet geteeld onder andere teeltomstandigheden, de variabiliteit in de dataset verhogen wat mogelijks ook de generaliseerbaarheid van het model kan verbeteren.

Door het black-box-karakter van CNN's is het ook moeilijk om met grote zekerheid te kunnen zeggen hoe CNN-modellen redeneren om tot bepaalde outputs te komen. Verdere onderzoeken kunnen meer inzichten geven over de beslissingen van CNN's voor de bepaling van het vers- en drooggewicht van sla o.b.v. RGB-camerabeelden. De verklaringen van deze beslissingen kunnen dan worden gebruikt om het ontwikkelde CNN-model beter te begrijpen en de door het model gedetecteerde kenmerken te relateren aan de planteigenschappen. Op deze manier kan de generaliseerbaarheid van het model ook verder verbeterd worden.

Dit onderzoek heeft aangetoond dat het gebruik van een CNN-model in combinatie met een RGB-camera als niet-destructieve meetmethode voor de bepaling van het vers- en drooggewicht van sla mogelijkheden biedt als alternatief voor destructieve en computervisie-gebaseerde meetmethodes. Ondanks de beperkte hoeveelheid beschikbare trainingsdata konden door middel van een CNN met RGB-camerabeelden sterke schattingen van het vers- en drooggewicht worden verricht voor cultivars die aanwezig waren in de trainingsdata. Daarnaast focuste deze masterproef zich ook op de praktische toepassingen van een CNN in combinatie met een RGB-camera, waarbij complicaties werden ondervonden zoals het generalisatievermogen, occlusie bij bepaalde camerahoeken, overfitting en de beperkte trainingsdataset. Door verder onderzoek te doen naar CNN's in combinatie met RGB-camerabeelden voor de bepaling van het vers- en drooggewicht van sla en het vergroten van de trainingsdataset met camerabeelden van verschillende sla-cultivars onder diverse teeltomstandigheden, kan dit onderzoek een waardevolle bijdrage leveren aan de ontwikkeling van geautomatiseerde, niet-destructieve meetsystemen voor de precisieteelt van sla.

Referenties

- Abebe, A. M., Kim, Y., Kim, J., Kim, S. L., & Baek, J. (2023). Image-Based High-Throughput Phenotyping in Horticultural Crops. *Plants*, 12(10), 2061. <https://doi.org/10.3390/plants12102061>
- Araus, J. L., & Cairns, J. E. (2014). Field high-throughput phenotyping: The new crop breeding frontier. *Trends in Plant Science*, 19(1), 52-61. <https://doi.org/10.1016/j.tplants.2013.09.008>
- Barron, J. T. (2019). *A General and Adaptive Robust Loss Function*. 4331-4339. https://openaccess.thecvf.com/content_CVPR_2019/html/Barron_A_General_and_Adaptive_Robust_Loss_Function_CVPR_2019_paper.html
- Bennett-Ciaglia, A. (2017, november 10). *High Tech Growing Systems Help Improve Efficiencies, Meet Consumer Demand*. Greenhouse Product News. <https://gpnmag.com/article/automation-high-tech-growing-systems-help-improve-efficiencies-meet-consumer-demand/>
- Benoit, F., Pasture, E., Dejonckheere, W., Bleyaert, P., Van Der Elst, J., Baets, Th., D'Hoker, J., Pattou, M., Verstrynge, J., Baets, W., & Verhoyen, M. (1989). *De teelt van sla onder glas* (Eerste uitgave). Ministerie van Landbouw.
- Benton Jones Jr, J. (2016). *Hydroponics: A Practical Guide for the Soilless Grower* (2de dr.). CRC Press. <https://doi.org/10.1201/9780849331671>
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope. *Electronics*, 10(20). <https://doi.org/10.3390/electronics10202470>
- Boo, H.-O., Heo, B.-G., Gorinstein, S., & Chon, S.-U. (2011). Positive effects of temperature and growth conditions on enzymatic and antioxidant status in lettuce plants. *Plant Science*, 181(4), 479-484. <https://doi.org/10.1016/j.plantsci.2011.07.013>

- Calou, V. B. C., Teixeira, A. dos S., Moreira, L. C. J., Lima, C. S., de Oliveira, J. B., & de Oliveira, M. R. R. (2020). The use of UAVs in monitoring yellow sigatoka in banana. *Biosystems Engineering*, 193, 115-125. <https://doi.org/10.1016/j.biosystemseng.2020.02.016>
- Carvalho, R. R. B. de, Cortes, D. F. M., Sousa, M. B. e, Oliveira, L. A. de, & Oliveira, E. J. de. (2022). Image-based phenotyping of cassava roots for diversity studies and carotenoids prediction. *PLOS ONE*, 17(1), e0263326. <https://doi.org/10.1371/journal.pone.0263326>
- Ceccarelli, A., & Secci, F. (2023). RGB Cameras Failures and Their Effects in Autonomous Driving Applications. *IEEE Transactions on Dependable and Secure Computing*, 20(4), 2731-2745. <https://doi.org/10.1109/TDSC.2022.3156941>
- Chandel, A. K., Khot, L. R., & C, B. S. (2021). Apple powdery mildew infestation detection and mapping using high-resolution visible and multispectral aerial imaging technique. *Scientia Horticulturae*, 287, 110228. <https://doi.org/10.1016/j.scienta.2021.110228>
- Chang, A., Jung, J., Yeom, J., Maeda, M. M., Landivar, J. A., Enciso, J. M., Avila, C. A., & Anciso, J. R. (2021). Unmanned Aircraft System- (UAS-) Based High-Throughput Phenotyping (HTP) for Tomato Yield Estimation. *Journal of Sensors*, 2021(1), 8875606. <https://doi.org/10.1155/2021/8875606>
- Chen, Y., Lee, W. S., Gan, H., Peres, N., Fraise, C., Zhang, Y., & He, Y. (2019). Strawberry Yield Prediction Based on a Deep Neural Network Using High-Resolution Aerial Orthoimages. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131584>
- Damon, G. (2025). Definition: Photosite; Photosites; Photo-site; (occ. pixelsite). *Photokonnexion*. <https://www.photokonnexion.com/definition-photosite/>
- Das, R., & Bhattacharjee, C. (2020). Chapter 9—Lettuce. In A. K. Jaiswal (Red.), *Nutritional Composition and Antioxidant Properties of Fruits and Vegetables* (pp. 143-157). Academic Press. <https://doi.org/10.1016/B978-0-12-812780-3.00009-X>

- Deery, D., Jimenez-Berni, J., Jones, H., Sirault, X., & Furbank, R. (2014). Proximal Remote Sensing Buggies and Potential Applications for Field-Based Phenotyping. *Agronomy*, 4(3), 349-379. <https://doi.org/10.3390/agronomy4030349>
- Derden, A., Goovaerts, L., Vercaemst, P., & Vrancken, K. (2005). *Beste Beschikbare Technieken (BBT) voor de glastuinbouw*. <https://emis.vito.be/nl/bbt/publicaties/bbtbref-en-andere-publicaties/glastuinbouw>
- El Sakka, M., Ivanovici, M., Chaari, L., & Mothe, J. (2025). A Review of CNN Applications in Smart Agriculture Using Multimodal Data. *Sensors*, 25(2), Article 2. <https://doi.org/10.3390/s25020472>
- Elliott, K., Berry, J. C., Kim, H., & Bart, R. S. (2022). A comparison of ImageJ and machine learning based image analysis methods to measure cassava bacterial blight disease severity. *Plant Methods*, 18(1), 86. <https://doi.org/10.1186/s13007-022-00906-x>
- Fan, Y., Feng, H., Jin, X., Yue, J., Liu, Y., Li, Z., Feng, Z., Song, X., & Yang, G. (2022). Estimation of the nitrogen content of potato plants based on morphological parameters and visible light vegetation indices. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1012070>
- FAO. (2025). *FAO lettuce*. Our World in Data. <https://ourworldindata.org/search>
- Feldmann, M. J., Hardigan, M. A., Famula, R. A., López, C. M., Tabb, A., Cole, G. S., & Knapp, S. J. (2020). Multi-dimensional machine learning approaches for fruit shape phenotyping in strawberry. *GigaScience*, 9(5), giaa030. <https://doi.org/10.1093/gigascience/giaa030>
- Fu, L., Majeed, Y., Zhang, X., Karkee, M., & Zhang, Q. (2020). Faster R-CNN-based apple detection in dense-foliage fruiting-wall trees using RGB and depth features for robotic harvesting. *Biosystems Engineering*, 197, 245-256. <https://doi.org/10.1016/j.biosystemseng.2020.07.007>
- Gang, M.-S., Kim, H.-J., & Kim, D.-W. (2022). Estimation of Greenhouse Lettuce Growth Indices Based on a Two-Stage CNN Using RGB-D Images. *Sensors*, 22(15), Article 15. <https://doi.org/10.3390/s22155499>

- Ge, L., Zou, K., Zhou, H., Yu, X., Tan, Y., Zhang, C., & Li, W. (2022). Three dimensional apple tree organs classification and yield estimation algorithm based on multi-features fusion and support vector machine. *Information Processing in Agriculture*, 9(3), 431-442. <https://doi.org/10.1016/j.inpa.2021.04.011>
- GeeksforGeeks. (2025, juli 18). *Using Early Stopping to Reduce Overfitting in Neural Networks*. GeeksforGeeks. <https://www.geeksforgeeks.org/deep-learning/using-early-stopping-to-reduce-overfitting-in-neural-networks/>
- GeeksforGeeks. (2026, februari 20). *Activation functions in Neural Networks*. GeeksforGeeks. <https://www.geeksforgeeks.org/machine-learning/activation-functions-neural-networks/>
- Gomez Selvaraj, M., Vergara, A., Montenegro, F., Alonso Ruiz, H., Safari, N., Raymaekers, D., Ocimati, W., Ntamwira, J., Tits, L., Omondi, A. B., & Blomme, G. (2020). Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169, 110-124. <https://doi.org/10.1016/j.isprsjprs.2020.08.025>
- Guo, Y., Chen, S., Wu, Z., Wang, S., Bryant, C. R., Senthilnath, J., Cunha, M., & Fu, Y. H. (2021). Integrating Spectral and Textural Information for Monitoring the Growth of Pear Trees Using Optical Images from the UAV Platform. *Remote Sensing*, 13(9). <https://doi.org/10.3390/rs13091795>
- Gupta, D. (2023). *SECOND-NATIONAL-CONFERENCE-ON-NEW-OPPORTUNITIES-AND-CHALLENGES-IN-AGRICULTURE-AND-ALLIED-SECTORS-PROCEEDINGS*.
- Haar, L. V., Elvira, T., & Ochoa, O. (2023). An analysis of explainability methods for convolutional neural networks. *Engineering Applications of Artificial Intelligence*, 117, 105606. <https://doi.org/10.1016/j.engappai.2022.105606>
- Hou, L., Zhu, Y., Wei, N., Liu, Z., You, J., Zhou, J., & Zhang, J. (2024). Study on Utilizing Mask R-CNN for Phenotypic Estimation of Lettuce's Growth Status and Optimal Harvest Timing. *Agronomy*, 14(6), Article 6. <https://doi.org/10.3390/agronomy14061271>

- Huang, K.-Y., & Cheng, J.-F. (2017). A Novel Auto-Sorting System for Chinese Cabbage Seeds. *Sensors*, 17(4). <https://doi.org/10.3390/s17040886>
- Jamil, B., & Akhtar, N. (2017). Comparative analysis of diffuse solar radiation models based on sky-clearness index and sunshine period for humid-subtropical climatic region of India: A case study. *Renewable and Sustainable Energy Reviews*, 78, 329-355. <https://doi.org/10.1016/j.rser.2017.04.073>
- Jang, G., Kim, J., Yu, J.-K., Kim, H.-J., Kim, Y., Kim, D.-W., Kim, K.-H., Lee, C. W., & Chung, Y. S. (2020). Review: Cost-Effective Unmanned Aerial Vehicle (UAV) Platform for Field Plant Breeding Application. *Remote Sensing*, 12(6), Article 6. <https://doi.org/10.3390/rs12060998>
- Javaid, M., Haleem, A., Khan, I. H., & Suman, R. (2023). Understanding the potential applications of Artificial Intelligence in Agriculture Sector. *Advanced Agrochem*, 2(1), 15-30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Jayasuriya, N., Guo, Y., Hu, W., & Ghannoum, O. (2024). *Image based Crop Monitoring Technologies in Protected Horticulture: A Review* (arXiv:2401.13928). arXiv. <https://doi.org/10.48550/arXiv.2401.13928>
- Johansen, K., Morton, M. J. L., Malbeteau, Y., Aragon, B., Al-Mashharawi, S., Ziliani, M. G., Angel, Y., Fiene, G., Negrão, S., Mousa, M. A. A., Tester, M. A., & McCabe, M. F. (2020). Predicting Biomass and Yield in a Tomato Phenotyping Experiment Using UAV Imagery and Random Forest. *Frontiers in Artificial Intelligence*, 3. <https://doi.org/10.3389/frai.2020.00028>
- Ketkar, N., & Moolayil, J. (2021). Convolutional Neural Networks. In N. Ketkar & J. Moolayil (Red.), *Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch* (pp. 197-242). Apress. https://doi.org/10.1007/978-1-4842-5364-9_6
- Khun, K., Tremblay, N., Panneton, B., Vigneault, P., Lord, E., Cavayas, F., & Codjia, C. (2021). Use of Oblique RGB Imagery and Apparent Surface Area of Plants for Early Estimation of Above-Ground Corn Biomass. *Remote Sensing*, 13(20), 4032. <https://doi.org/10.3390/rs13204032>

- Kim, D.-W., Yun, H. S., Jeong, S.-J., Kwon, Y.-S., Kim, S.-G., Lee, W. S., & Kim, H.-J. (2018). Modeling and Testing of Growth Status for Chinese Cabbage and White Radish with UAV-Based RGB Imagery. *Remote Sensing*, 10(4). <https://doi.org/10.3390/rs10040563>
- Kim, H.-Y. (2013). Statistical notes for clinical researchers: Understanding standard deviations and standard errors. *Restorative Dentistry & Endodontics*, 38(4), 263-265. <https://doi.org/10.5395/rde.2013.38.4.263>
- Kior, A., Sukhov, V., & Sukhova, E. (2021). Application of Reflectance Indices for Remote Sensing of Plants and Revealing Actions of Stressors. *Photonics*, 8(12), Article 12. <https://doi.org/10.3390/photonics8120582>
- Kior, A., Yudina, L., Zolin, Y., Sukhov, V., & Sukhova, E. (2024). RGB Imaging as a Tool for Remote Sensing of Characteristics of Terrestrial Plants: A Review. *Plants*, 13(9), Article 9. <https://doi.org/10.3390/plants13091262>
- Kliman, R., Huang, Y., Zhao, Y., & Chen, Y. (2025). Toward an Automated System for Nondestructive Estimation of Plant Biomass. *Plant Direct*, 9(3), e70043. <https://doi.org/10.1002/pld3.70043>
- Kumar Sharma, D., Chatterjee, M., Kaur, G., & Vavilala, S. (2022). Deep learning applications for disease diagnosis. In *Deep Learning for Medical Applications with Unique Data* (pp. 31-51). Academic Press. <https://doi.org/10.1016/B978-0-12-824145-5.00005-8>
- Lakhani, P. (2020). The Importance of Image Resolution in Building Deep Learning Models for Medical Imaging. *Radiology. Artificial intelligence*, 2(1), e190177. <https://doi.org/10.1148/ryai.2019190177>
- Lal, B. (2024). *Lettuce: A dive into its nutritional value and economic significance*.
- Li, B., Xu, X., Han, J., Zhang, L., Bian, C., Jin, L., & Liu, J. (2019). The estimation of crop emergence in potatoes by UAV RGB imagery. *Plant Methods*, 15(1), 15. <https://doi.org/10.1186/s13007-019-0399-7>
- Li, L., Zhang, Q., & Huang, D. (2014). A Review of Imaging Techniques for Plant Phenotyping. *Sensors*, 14(11), Article 11. <https://doi.org/10.3390/s141120078>

- Li, Y., Zhang, Z., Azizi, A., Kabir, M. H., Igathinathane, C., Wang, X., Tahir, M. N., Han, X., & Zhang, M. (2024). Seeding detection and distribution evaluation using the developed automatic maize seeding machine. *Computers and Electronics in Agriculture*, 220, 108872. <https://doi.org/10.1016/j.compag.2024.108872>
- Lin, R. (2022). *Analysis on the Selection of the Appropriate Batch Size in CNN Neural Network*. <https://ieeexplore.ieee.org/document/9763653>
- Liu, S., Zeng, X., & Whitty, M. (2020). A vision-based robust grape berry counting algorithm for fast calibration-free bunch weight estimation in the field. *Computers and Electronics in Agriculture*, 173, 105360. <https://doi.org/10.1016/j.compag.2020.105360>
- Liu, X., Zhang, Z., Igathinathane, C., Flores, P., Zhang, M., Li, H., Han, X., Ha, T., Ampatzidis, Y., & Kim, H.-J. (2024). Infield corn kernel detection using image processing, machine learning, and deep learning methodologies under natural lighting. *Expert Systems with Applications*, 238, 122278. <https://doi.org/10.1016/j.eswa.2023.122278>
- Mostafa, S., Mondal, D., Panjvani, K., Kochian, L., & Stavness, I. (2023). Explainable deep learning in plant phenotyping. *Frontiers in Artificial Intelligence*, 6. <https://doi.org/10.3389/frai.2023.1203546>
- Mou, B. (2008). Lettuce. In J. Prohens & F. Nuez (Red.), *Vegetables I: Asteraceae, Brassicaceae, Chenopodiaceae, and Cucurbitaceae* (pp. 75-116). Springer. https://doi.org/10.1007/978-0-387-30443-4_3
- Nawara, S., Berckmoes, D., Baets, D., & Melis, P. (2019). *OUTPUT 5.2A: TWEE LIJSTEN MET SELECTIECRITERIA VOOR DE VERSCHILLENDE ZUIVERINGSSTAPPEN SPECIFIEK VOOR DE WATERZUIVERING VAN I.) TRAYVELDEN VOOR AARDBEI EN II .) MOBIELE GOTENSYSTEEM VOOR SLA*. Proefstation voor de Groenteteelt.
- Olenskyj, A. G., Sams, B. S., Fei, Z., Singh, V., Raja, P. V., Bornhorst, G. M., & Earles, J. M. (2022). End-to-end deep learning for directly estimating grape yield from ground-based imagery. *Computers and Electronics in Agriculture*, 198, 107081. <https://doi.org/10.1016/j.compag.2022.107081>

- Owen, W. G., & Lopez, R. G. (2015). *End-of-production Supplemental Lighting with Red and Blue Light-emitting Diodes (LEDs) Influences Red Pigmentation of Four Lettuce Varieties*. <https://doi.org/10.21273/HORTSCI.50.5.676>
- Petropoulou, A. S., van Marrewijk, B., de Zwart, F., Elings, A., Bijlaard, M., van Daalen, T., Jansen, G., & Hemming, S. (2023). Lettuce Production in Intelligent Greenhouses—3D Imaging and Computer Vision for Plant Spacing Decisions. *Sensors*, 23(6), Article 6. <https://doi.org/10.3390/s23062929>
- Pinheiro, J. M. H., Oliveira, S. V. B. de, Silva, T. H. S., Saraiva, P. A. R., Souza, E. F. de, Godoy, R. V., Ambrosio, L. A., & Becker, M. (2025). The Impact of Feature Scaling in Machine Learning: Effects on Regression and Classification Tasks. *IEEE Access*, 13, 199903-199931. <https://doi.org/10.1109/ACCESS.2025.3635541>
- Ramos, R. P., Gomes, J. S., Prates, R. M., Simas Filho, E. F., Teruel, B. J., & dos Santos Costa, D. (2021). Non-invasive setup for grape maturation classification using deep learning. *Journal of the Science of Food and Agriculture*, 101(5), 2042-2051. <https://doi.org/10.1002/jsfa.10824>
- Renaud, O., & Victoria-Feser, M.-P. (2010). A robust coefficient of determination for regression. *Journal of Statistical Planning and Inference*, 140(7), 1852-1862. <https://doi.org/10.1016/j.jspi.2010.01.008>
- Rijk Zwaan. (2009, juli 10). *Hydroteelt onder de loep*. <https://www.groentennieuws.nl/article/48725/hydroteelt-onder-de-loep/>
- Rijk Zwaan. (2026). *VOLUMIA RZ | Botersla | Groentezaden | Rijk Zwaan*. <https://www.rijkszwaan.nl/sla/VOLUMIA-RZ-prdLS11219-ctgCrops.lettuce>
- Roman, A., & Ursu, T. (2016). *Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks* (pp. 141-152).
- Ropelewska, E., & Rutkowski, K. P. (2021). Cultivar discrimination of stored apple seeds based on geometric features determined using image analysis. *Journal of Stored Products Research*, 92, 101804. <https://doi.org/10.1016/j.jspr.2021.101804>

- Rui, Z., Zhang, Z., Zhang, M., Azizi, A., Igathinathane, C., Cen, H., Vougioukas, S., Li, H., Zhang, J., Jiang, Y., Jiao, X., Wang, M., Ampatzidis, Y., Oladele, O. I., Ghasemi-Varnamkhasti, M., & Radi, R. (2024). High-throughput proximal ground crop phenotyping systems – A comprehensive review. *Computers and Electronics in Agriculture*, 224, 109108. <https://doi.org/10.1016/j.compag.2024.109108>
- Seki, K., & Toda, Y. (2022). QTL mapping for seed morphology using the instance segmentation neural network in *Lactuca* spp. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.949470>
- Shafi, S., & Assad, A. (2023). Exploring the Relationship Between Learning Rate, Batch Size, and Epochs in Deep Learning: An Experimental Study. In M. Thakur, S. Agnihotri, B. S. Rajpurohit, M. Pant, K. Deep, & A. K. Nagar (Red.), *Soft Computing for Problem Solving* (pp. 201-209). Springer Nature. https://doi.org/10.1007/978-981-19-6525-8_16
- Shafiekhani, A., Kadam, S., Fritschi, F. B., & DeSouza, G. N. (2017). Vinobot and Vinoculer: Two Robotic Platforms for High-Throughput Field Phenotyping. *Sensors*, 17(1), 214. <https://doi.org/10.3390/s17010214>
- Shahinfar, S., Meek, P., & Falzon, G. (2020). “How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring. *Ecological Informatics*, 57, 101085. <https://doi.org/10.1016/j.ecoinf.2020.101085>
- Si, Y., Sankaran, S., Knowles, N. R., & Pavek, M. J. (2017). Potato Tuber Length-Width Ratio Assessment Using Image Analysis. *American Journal of Potato Research*, 94(1), 88-93. <https://doi.org/10.1007/s12230-016-9545-1>
- Sinha, S. N. (2021). Occlusion. In *Computer Vision* (pp. 1-4). Springer, Cham. https://doi.org/10.1007/978-3-030-03243-2_806-1
- Sng, B. J. R., Mun, B., Mohanty, B., Kim, M., Phua, Z. W., Yang, H., Lee, D.-Y., & Jang, I.-C. (2021). Combination of red and blue light induces anthocyanin and other secondary metabolite biosynthesis pathways in an age-dependent manner in Batavia lettuce. *Plant Science*, 310, 110977. <https://doi.org/10.1016/j.plantsci.2021.110977>

- Snoeck, N. J., Dekkers, W., Lumkes, L., Titulaer, H. H. H., van der Zweep, F., van Kruistum, G., Jonkers, J., de Moel, C. P., Meier, R., van Kruistum, G., & van der Ham, G. (1985). *Teelt van sla* (Eerste oplage). Proefstation voor de Akkerbouw en Groenteteelt in de Vollegrond, Lelystad.
- Song, J., Huang, H., Hao, Y., Song, S., Zhang, Y., Su, W., & Liu, H. (2020). Nutritional quality, mineral and antioxidant content in lettuce affected by interaction of light intensity and nutrient solution concentration. *Scientific Reports*, 10(1), 2796. <https://doi.org/10.1038/s41598-020-59574-3>
- Soufi, H. R., Roosta, H. R., Stępień, P., Malekzadeh, K., & Hamidpour, M. (2023). Manipulation of light spectrum is an effective tool to regulate biochemical traits and gene expression in lettuce under different replacement methods of nutrient solution. *Scientific Reports*, 13(1), 8600. <https://doi.org/10.1038/s41598-023-35326-x>
- Sugiura, R., Tsuda, S., Tamiya, S., Itoh, A., Nishiwaki, K., Murakami, N., Shibuya, Y., Hirafuji, M., & Nuske, S. (2016). Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*, 148, 1-10. <https://doi.org/10.1016/j.biosystemseng.2016.04.010>
- Supertrek. (2024, december 20). *Wat is een RGB-camera?* <https://www.supertekmodule.com/what-is-rgb-camera/>
- Surya Prabha, D., & Satheesh Kumar, J. (2015). Assessment of banana fruit maturity by image processing technique. *Journal of Food Science and Technology*, 52(3), 1316-1327. <https://doi.org/10.1007/s13197-013-1188-3>
- Tan, J., Hou, J., Xu, W., Zheng, H., Gu, S., Zhou, Y., Qi, L., & Ma, R. (2023). PosNet: Estimating lettuce fresh weight in plant factory based on oblique image. *Computers and Electronics in Agriculture*, 213, 108263. <https://doi.org/10.1016/j.compag.2023.108263>
- TechNexion. (2025). RGB cameras: Definition, components, and integration. *TechNexion*. <https://www.technexion.com/resources/rgb-cameras/>
- Thomas More. (2021, september 1). *Exp-E Intelligente klimaatoptimalisatie met en voor tuinders (KlimOp-AI)* | Thomas More.


- <https://thomasmore.be/nl/onderzoek/projecten/exp-e-intelligente-klimaatoptimalisatie-met-en-voor-tuinders-klimop-ai>
- van Dijk, M., Morley, T., Rau, M. L., & Saghai, Y. (2021). A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. *Nature Food*, 2(7), 494-501. <https://doi.org/10.1038/s43016-021-00322-9>
- VLAM. (2025). *Knowledge base | Vlaams Centrum voor Agro- en Visserijmarketing*. <https://www.vlaanderen.be/vlam/kennisbank?page=0>
- Wasonga, D. O., Yaw, A., Kleemola, J., Alakukku, L., & Mäkelä, P. S. A. (2021). Red-Green-Blue and Multispectral Imaging as Potential Tools for Estimating Growth and Nutritional Performance of Cassava under Deficit Irrigation and Potassium Fertigation. *Remote Sensing*, 13(4). <https://doi.org/10.3390/rs13040598>
- Wu, J., Yang, G., Yang, H., Zhu, Y., Li, Z., Lei, L., & Zhao, C. (2020). Extracting apple tree crown information from remote imagery using deep learning. *Computers and Electronics in Agriculture*, 174, 105504. <https://doi.org/10.1016/j.compag.2020.105504>
- Xiong, J., Liu, Z., Chen, S., Liu, B., Zheng, Z., Zhong, Z., Yang, Z., & Peng, H. (2020). Visual detection of green mangoes by an unmanned aerial vehicle in orchards based on a deep learning method. *Biosystems Engineering*, 194, 261-272. <https://doi.org/10.1016/j.biosystemseng.2020.04.006>
- Xu, D., Chen, J., Li, B., & Ma, J. (2023). Improving Lettuce Fresh Weight Estimation Accuracy through RGB-D Fusion. *Agronomy*, 13(10), Article 10. <https://doi.org/10.3390/agronomy13102617>
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9(4), Article 4. <https://doi.org/10.1007/s13244-018-0639-9>
- Yu, C., Yan, C., Liu, Y., Liu, Y., Jia, Y., Lavelle, D., An, G., Zhang, W., Zhang, L., Han, R., Larkin, R. M., Chen, J., Michelmore, R. W., & Kuang, H. (2020). Upregulation of a KN1 homolog by transposon insertion promotes leafy head development in lettuce.

- Proceedings of the National Academy of Sciences*, 117(52), 33668-33678.
<https://doi.org/10.1073/pnas.2019698117>
- Zhang, L., Su, W., Tao, R., Zhang, W., Chen, J., Wu, P., Yan, C., Jia, Y., Larkin, R. M., Lavelle, D., Truco, M.-J., Chin-Wo, S. R., Michelmore, R. W., & Kuang, H. (2017). RNA sequencing provides insights into the evolution of lettuce and the regulation of flavonoid biosynthesis. *Nature Communications*, 8(1), 2264. <https://doi.org/10.1038/s41467-017-02445-9>
- Zhang, L., Xu, Z., Xu, D., Ma, J., Chen, Y., & Fu, Z. (2020). Growth monitoring of greenhouse lettuce based on a convolutional neural network. *Horticulture Research*, 7, 124. <https://doi.org/10.1038/s41438-020-00345-6>
- Zhang, Y., Xu, S., Cheng, Y., Peng, Z., & Han, J. (2018). Transcriptome profiling of anthocyanin-related genes reveals effects of light intensity on anthocyanin biosynthesis in red leaf lettuce. *PeerJ*, 6, e4607. <https://doi.org/10.7717/peerj.4607>
- Zhao, H., Gallo, O., Frosio, I., & Kautz, J. (2017). Loss Functions for Image Restoration With Neural Networks. *IEEE Transactions on Computational Imaging*, 3(1), 47-57. <https://doi.org/10.1109/TCI.2016.2644865>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 99. <https://doi.org/10.1007/s10462-024-10721-6>
- Zheng, C., Abd-Elrahman, A., Whitaker, V. M., & Dalid, C. (2022). Deep Learning for Strawberry Canopy Delineation and Biomass Prediction from High-Resolution Images. *Plant Phenomics*, 2022. <https://doi.org/10.34133/2022/9850486>
- Zhu, Y., Gu, Q., Zhao, Y., Wan, H., Wang, R., Zhang, X., & Cheng, Y. (2022). Quantitative Extraction and Evaluation of Tomato Fruit Phenotypes Based on Image Recognition. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.859290>

Bijlagen

- Bijlage A Overzicht van het onderzoeksproces
- Bijlage B Overzicht van de datums met betrekking tot de zaai en opkweek van de slapplanten tot het bereiken van het oogstgewicht
- Bijlage C Samenstelling van de voedingsoplossing en de bijhorende streefwaardes
- Bijlage D Overzicht van het aantal afbeeldingen en de verschillende periodes waarbij de RGB-camerabeelden werden genomen van de slapplanten
- Bijlage E Voorbeelden van RGB-camerabeelden genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivars Emeldia RZ, Limambo RZ, van zowel teeltronde 1 en 2, en Volumia
- Bijlage F De onderzochte CNN-modellen met bijhorende specificaties en gebruikte hyperparameters voor de bepaling van het optimaal aantal convolutielagen
- Bijlage G Schematische weergave van het ontwikkelde CNN-model met het meest accurate schattingsvermogen
- Bijlage H Resultaten van het onderzoeken van het schattings- en generalisatievermogen van het ontwikkelde CNN-model weergegeven in de vorm van scatterplots met bijhorende R^2 -, RMSE- en NRMSE-waarden en vergelijking van de regressielijnen

Bijlage A OVERZICHT VAN HET ONDERZOEKSPROCES



Figuur A-1 Overzicht van het onderzoeksproces voor de bepaling van het vers- en drooggewicht van sla m.b.v. RGB-afbeeldingen en een CNN. De afbeeldingen van de slaplanten van respectievelijk Emeldia RZ, Limambo RZ en Volumia zijn afkomstig van Rijk Zwaan België (2026). De afbeeldingen van de convolutielagen zijn afkomstig van Seok-young (2021).

Bijlage B OVERZICHT VAN DE DATUMS MET BETREKKING TOT DE ZAAI EN OPK WEEK VAN DE SLAPLANTEN TOT HET BEREIKEN VAN HET OOGSTGEWICHT

Tabel B-1 Overzicht van de datums met betrekking tot de zaai en opkweek van de slapplanten tot het bereiken van het oogstgewicht voor het gewastype botersla cultivar Emeldia RZ en het gewastype bladsla cultivar Limambo RZ.

Cultivar	Teeltronde	Datum inzaai slazaden	Periode kiemen van slazaden tot zaailingen	Datum overplaatsing in perspotten	Datum overplaatsing in goten	Periode groei sla tot bereiken oogstgewicht
Emeldia RZ	1	04/08/2025	04/08/2025 - 13/08/2025	13/08/2025	18/08/2025	18/08/2025 - 08/10/2025
	2	17/09/2025	17/09/2025 - 29/09/2025	29/09/2025	29/09/2025	29/09/2025 - 26/11/2025
Limambo RZ	1	03/09/2025	03/09/2025 - 15/09/2025	15/09/2025	15/09/2025	15/09/2025 - 06/11/2025
	2	17/10/2025	17/10/2025 - 29/10/2025	29/10/2025	29/10/2025	29/10/2025 - 16/12/2025

Bijlage C SAMENSTELLING VAN DE VOEDINGSOPLOSSING EN DE BIJHORENDE STREEFWAARDES

Tabel C-1 Samenstelling van de voedingsoplossing en de bijhorende streefwaardes.

Type component	Component	Concentratie (mmol/l)	Concentratie (μmol/l)
Anion	NO ₃ ⁻	10,00	
	Cl ⁻	< 1,00	
	SO ₄ ⁻	1,50	
	H ₂ PO ₄ ⁻	1,50	
	HCO ₃ ⁻	< 1,00	
Kation	NH ₄ ⁺	< 0,50	
	Na ⁺	< 2,00	
	K ⁺	4,00	
	Ca ⁺⁺	4,00	
	Mg ⁺⁺	1,50	
Spoorelement	Fe		30,00
	Mn ⁺⁺		5,00
	Zn ⁺⁺		5,00
	H ₂ BO ₃ ⁻		35,00
	Cu ⁺⁺		1,00


Bijlage D OVERZICHT VAN HET AANTAL AFBEELDINGEN EN DE VERSCHILLENDE PERIODES WAARBIJ DE RGB-CAMERABEELDEN WERDEN GENOMEN VAN DE SLAPLANTEN

Tabel D-1 Overzicht van het aantal afbeeldingen en de verschillende periodes waarbij de RGB-camerabeelden werden genomen van de zelf opgekweekte sla (Emeldia RZ en Limambo RZ) en de sla (Volumia) afkomstig van het externe slabedrijf Goni.


Cultivar	Teeltronde	Periode verzamelen camerabeelden	Aantal afbeeldingen verzameld per camerahoek t.o.v. het grondoppervlak (0°, 45° en 90°)
Emeldia RZ	1	25/08/2025 - 08/10/2025	99
	2	06/10/2025 - 26/11/2025	114
Limambo RZ	1	23/09/2025 - 06/11/2025	99
	2	05/11/2025 - 16/12/2025	99
Volumia	1	12/09/2025	52

Bijlage E VOORBEELDEN VAN RGB-CAMERABEELDEN GENOMEN ONDER EEN HOEK VAN 0°, 45° EN 90° T.O.V. HET GRONDOPPERVLAK VAN DE SLA-CULTIVARS EMELDIA RZ, LIMAMBO RZ, VAN ZOWEL TEELTRONDE 1 EN 2, EN VOLUMIA

Tabel E-1 Voorbeelden van RGB-camerabeelden genomen onder een hoek van 0°, 45° en 90° t.o.v. het grondoppervlak van de sla-cultivars Emeldia RZ, Limambo RZ, van zowel teeltronde 1 en 2, en Volumnia.


	Eigen teelt				Externe slateler
	Teeltronde 1		Teeltronde 2		
	Emeldia RZ	Limambo RZ	Emeldia RZ	Limambo RZ	Volumia
0°					
45°					
90°					

Bijlage F DE ONDERZOCHE CNN-MODELLEN MET BIJHORENDE SPECIFICATIES EN GEBRUIKTE HYPERPARAMETERS VOOR DE BEPALING VAN HET OPTIMAAL AANTAL CONVOLUTIELAGEN




Figuur F-1 Overzicht van de onderzochte modellen (Model A - G) met bijhorende convolutie- en poolinglagen. De bijhorende specificaties worden onder elke laag weergegeven, hetzelfde geldt voor de input en output. De modellformulering en gebruikte hyperparameters worden bovenaan in de figuur weergegeven. Voor elk model was de volledig verbonden laag met bijhorende outputs (vers- en drooggewicht sla) hetzelfde.

Bijlage G SCHEMATISCHE WEERGAVE VAN HET ONTWIKKELDE CNN-MODEL MET HET MEEST ACCURATE SCHATTINGSVERMOGEN




Figuur G-1 Schematische weergave van het ontwikkelde CNN-model met het meeste accurate schattingsvermogen met bijhorende convolutie- en poolinglagen. De bijhorende specificaties worden onder elke laag weergegeven, hetzelfde geldt voor de input en output. De optimale hyperparameters worden bovenaan in de figuur weergegeven.


Bijlage H RESULTATEN VAN HET ONDERZOEKEN VAN HET SCHATTINGS- EN GENERALISATIEVERMOGEN VAN HET ONTWIKKELDE CNN-MODEL WEERGEGEVEN IN DE VORM VAN SCATTERPLOTS MET BIJHORENDE R^2 -, RMSE- EN NRMSE-WAARDEN EN VERGELIJKING VAN DE REGRESSIELIJNEN




Figuur H-1 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een camerahoek van 0° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-2 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivars Emeldia RZ (42-198) en Limambo RZ (86-LE2741), beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een camerahoek van 45° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-3 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivars Emeldia RZ en Limambo RZ, beide afkomstig van teeltronde 1, met RGB-camerabeelden genomen onder een camerahoek van 90° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-4 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor de sla-cultivar Emeldia RZ van teeltronde 2 (a-b), de sla-cultivar Limambo RZ van teeltronde 2 (c-d) en de sla-cultivar Volumia (e-f) met RGB-camerabeelden genomen onder een camerahoek van 0° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-5 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor de sla-cultivar Emeldia RZ teeltronde 2 (a-b), de sla-cultivar Limambo RZ teeltronde 2 (c-d) en de sla-cultivar Volumia (e-f) met RGB-camerabeelden genomen onder een camerahoek van 45° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-6 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor de sla-cultivar Emeldia RZ teeltronde 2 (a-b), de sla-cultivar Limambo RZ teeltronde 2 (c-d) en de sla-cultivar Volumia (e-f) met RGB-camerabeelden genomen onder een camerahoek van 90° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.




Figuur H-7 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht (a) en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht (b) van de sla-cultivar Emeldia RZ, de sla-cultivar Limambo RZ, beide afkomstig van teeltronde 1 en 2, en de sla-cultivar Volumia met RGB-camerabeelden genomen onder een camerahoek van 0°, 45° en 90° t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.



Figuur H-8 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor Limambo RZ teeltronde 1 met RGB-camerabeelden genomen onder een camerahoek van 0° (a-b), 45° (c-d) of 90° (e-f) t.o.v. het grondoppervlak en Emeldia RZ teeltronde 1 met RGB-camerabeelden genomen onder een camerahoek van 0° (g-h), 45° (i-j) of 90° (k-l) t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.



Figuur H-9 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor Limambo RZ teeltronde 2 met RGB-camerabeelden genomen onder een camerahoek van 0° (a-b), 45° (c-d) of 90° (e-f) t.o.v. het grondoppervlak en Emeldia RZ teeltronde 2 met RGB-camerabeelden genomen onder een camerahoek van 0° (g-h), 45° (i-j) of 90° (k-l) t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.



Figuur H-10 Scatterplot met het voorspelde versgewicht uitgezet t.o.v. het werkelijke versgewicht en scatterplot met het voorspelde drooggewicht uitgezet t.o.v. het werkelijke drooggewicht voor Volumia teeltronde 1 met RGB-camerabeelden genomen onder een camerahoek van 0° (a-b), 45° (c-d) of 90° (e-f) t.o.v. het grondoppervlak. Op elke scatterplot is de bijhorende R^2 , RMSE (g), NRMSE en vergelijking van de regressielijn weergegeven. De regressielijn wordt weergegeven met een zwarte volle lijn, de stippellijn geeft de 1:1-lijn aan.

FACULTEIT INDUSTRIËLE INGENIEURSWETENSCHAPPEN
CAMPUS GEEL
Kleinhoefstraat 4
2440 GEEL, België
tel. + 32 14 72 13 00
iiw.geel@kuleuven.be
www.iw.kuleuven.be

