

Stefanie Reim<sup>1\*</sup>, Virginia Maß<sup>2</sup>, Pendar Alirezazadeh<sup>2</sup>, Johannes Seidl-Schulz<sup>3</sup>,  
Matthias Leipnitz<sup>3</sup>, Eric Fritzsche<sup>1</sup>, Martin Geyer<sup>2</sup>, Michael Pflanz<sup>2</sup>

## Entwicklung einer Hochdurchsatz-Phänotypisierungsmethode für den europäischen Birnengitterrost unter Verwendung von UAV-basierten RGB-Bildern

---

<sup>1</sup> Julius Kühn-Institut, Bundesforschungsinstitut für Kulturpflanzen, Institut für Züchtungsforschung an Obst, Dresden-Pillnitz, Pillnitzer Platz 3a, 01326 Dresden, Deutschland; stefanie.reim@julius-kuehn.de, eric.fritzsche@julius-kuehn.de

<sup>2</sup> Leibniz Institut für Agrartechnik und Bioökonomie, Abteilung für Agromechatronik, Max-Eyth-Allee 100, 14469 Potsdam, Deutschland; vmass@atb-potsdam.de, palirezazadeh@atb-potsdam.de, mgeyer@atb-potsdam.de, mpflanz@atb-potsdam.de

<sup>3</sup> geo-konzept Gesellschaft für Umweltplanungssysteme mbH, Wittenfelder Str. 28, 85111 Adelschlag, Deutschland; jseidl-schulz@geo-konzept.de, mleipnitz@geo-konzept.de

\* Korrespondenz: stefanie.reim@julius-kuehn.de



**DGG-Proceedings 2023, Vol. 11**

Short Communications – Peer Reviewed, Open Access

Deutsche Gartenbauwissenschaftliche Gesellschaft e. V. (DGG)

German Society for Horticultural Science

[www.dgg-online.org](http://www.dgg-online.org)

Annual Conference DGG and BHGL

01.-04.03.2023, Osnabrück, Germany

# Entwicklung einer Hochdurchsatz-Phänotypisierungsmethode für den europäischen Birnengitterrost unter Verwendung von UAV-basierten RGB-Bildern

Stefanie Reim<sup>1</sup>, Virginia Maß<sup>2</sup>, Pendar Alirezazadeh<sup>2</sup>, Johannes Seidl-Schulz<sup>3</sup>,  
Matthias Leipnitz<sup>3</sup>, Eric Fritzsche<sup>1</sup>, Martin Geyer<sup>2</sup>, Michael Pflanz<sup>2</sup>

<sup>1</sup>Julius Kühn-Institut, Deutschland

<sup>2</sup>Leibniz Institut für Agrartechnik und Bioökonomie, Deutschland

<sup>3</sup>geo-konzept Gesellschaft für Umweltplanungssysteme mbH, Deutschland

## Abstract

In der Obstzüchtung wird die Phänotypisierung häufig noch manuell durchgeführt, was jedoch sehr arbeits- und kostenintensiv ist. Daher wurde im Rahmen des MONIQUA-Projekts eine UAV-basierte, digitale Hochdurchsatzmethode für die Phänotypisierung von Krankheitserregern am Modell des Europäischen Birnengitterrostes entwickelt.

Auf Grundlage eines Trainingsdatensatzes, der 324 Bilder mit Birnengitterrostsymptomen umfasste, wurde im Rahmen des maschinellen Lernens ein Objektdetektor unter Verwendung eines vortrainierten YOLOv5-Algorithmus implementiert, der eine eindeutige Identifizierung jedes Symptoms in einem Bild ermöglicht. Im weiteren Verlauf des Projektes soll die genaue Lokalisierung von Krankheitssymptomen innerhalb der Obstanlage durch einen neuartigen Photogrammetrieansatz ermöglicht und der Gesamtbefall am Baum quantifiziert werden. In Zukunft soll dieses digitale Phänotypisierungssystem als Hochdurchsatzmethode zur Bewertung der genetischen Ressourcen von Birnen und zur anschließenden Bereitstellung von resistenten oder toleranten Genotypen für die Birnenzüchtung eingesetzt werden.

## 1. Einleitung

Pflanzenkrankheiten sind eines der größten wirtschaftlichen Risiken im Obstbau und für ihre Bekämpfung ist die Anwendung verschiedener Pflanzenschutzmittel während der Vegetationsperiode notwendig. Allerdings wird die Anwendung von Pflanzenschutzmitteln zunehmend durch gesetzliche Vorschriften eingeschränkt (BMEL 2023) weshalb die Bereitstellung von toleranten oder resistenten Sorten eine der wichtigsten Herausforderungen in der Züchtung darstellt. Voraussetzung für resistente Neuzüchtungen von Sorten ist allerdings die Evaluierung der genetischen Ressourcen, die es erlaubt, resistente Genotypen als Ausgangsmaterial für die Züchtung zu identifizieren. Zu diesem Zweck stehen verschiedene Forschungsinstrumente zur Verfügung, wobei die Phänotypisierung ein wichtiges Instrument für die Bestimmung der Interaktion des jeweiligen Genotyps mit der Umwelt ist (Pieruschka und Schurr 2019).

Die Phänotypisierung von Pflanzen, insbesondere in der Obstzüchtung, erfolgt bis heute noch überwiegend manuell durch eine visuelle Beurteilung (Reim et al. 2023). Dies hat mehrere Nachteile: die manuelle Phänotypisierung ist sehr arbeitsintensiv, kann nur für

ausgewählte Pflanzen und für eine begrenzte Zeit durchgeführt werden und ist oft subjektiv und damit nicht immer zuverlässig, vor allem wenn verschiedene Personen die Phänotypisierung vornehmen.

Die Entwicklung von Phänotypisierungstechniken mit hohem Durchsatz ist daher essentiell, um eine effektive und objektive Bewertung eines breiten Spektrums genetischer Ressourcen zu ermöglichen. Gleichzeitig erfordert die Bewertung obstgenetischer Ressourcen eine hochauflösende räumliche Kartierung der gewonnenen Daten. Obstgenetische Ressourcen, die für Evaluierungszwecke verwendet werden, befinden sich hauptsächlich in sogenannten "aktiven" Genbanksammlungen, in denen einzelne Akzessionen als Einzelbäume erhalten werden (Flachowsky und Höfer 2010). Daher muss sichergestellt werden, dass die erhobenen phänotypischen Daten einzelnen Bäumen zugeordnet werden können.

In den letzten Jahren wurden Hochdurchsatz-Phänotypisierungsverfahren auf der Grundlage nicht-destruktiver Bildgebungs- und Erfassungssysteme für verschiedene Kulturpflanzen entwickelt, z. B. für Weizen (Genaev et al. 2021) und Oliven (Caruso et al. 2021). Es gibt auch Studien zur Phänotypisierung von Obstkrankheiten mit Hilfe von optischen spektrometrischen bzw. bildgebenden Verfahren (Di und Li 2022).

Die Entwicklungen im Bereich der unbemannten Luftfahrzeuge (UAVs) haben eine umfassende und konsistente Phänotypisierung vorangetrieben, da im Vergleich zu bodengestützten Technologien UAV-Bilder größere Gebiete abdeckt werden können und damit die Kosten niedriger sind (Johansen et al. 2019). Durch die Weiterentwicklung der UAVs ist es nun auch möglich, UAV-Bilder mit hoher räumlicher und zeitlicher Auflösung zu erhalten, die eine klare Differenzierung der Pflanzenmerkmale auf individueller Ebene ermöglichen. Infolgedessen wird das UAV zunehmend für die Phänotypisierung von Obstbäumen eingesetzt, z. B. für die Erfassung von Blühmerkmalen (López-Granados et al. 2019), die Zählung von Früchten (Aitelkadi et al. 2021) oder die Erkennung von Krankheiten (Ayaz et al. 2021).

Das Ziel der Studie war daher, eine Hochdurchsatz-Phänotypisierungsmethode für den Europäischen Birnengitterrost (*Gymnosporangium sabinae*) unter Verwendung von UAV-basierten RGB-Bildern zu entwickeln, die eine effektive und objektive Phänotypisierung in Obstanlagen zukünftig ermöglicht.

## 2. Material und Methoden

Für die Erfassung der Symptome des Birnengitterrostes wurden RGB-Bilder in drei Versuchsquartieren mit einer Gesamtgröße von etwa 1 ha des Julius Kühn-Instituts in Dresden-Pillnitz, Deutschland, aufgenommen. In den Quartieren waren insgesamt 828 verschiedene Birnengenotypen aus Kreuzungsnachkommenschaften, Sorten bzw. Wildarten gepflanzt, was die Erkennung von Birnengitterrostsymptomen an einer Vielzahl von morphologisch unterschiedlichen Birnenblättern gewährleisten sollte. Die Birnenbäume wurden in den Jahren 2021 bis 2022 nicht mit Fungiziden behandelt, so dass eine natürliche Infektion möglich war. Die RGB-Bilder wurden zu Beginn des Auftretens früher Birnenrostsymptome im Mai bis zum Auftreten fortgeschrittener Birnenrostsymptome im August aufgenommen, um ein breites Spektrum von Birnenrostsymptomen zu erfassen. Für die Bilderfassung wurden insgesamt neun Drohnenflüge durchgeführt. Als Drohne wurde die Phantom 4 Pro (DJI, Shenzhen, China) eingesetzt. Diese arbeitet vollautomatisch, wenn die Flugparameter an der Bodenkontrollstation voreingestellt sind. Die Phantom 4 Pro verfügt über eine RGB-

Kamera mit einem 1-Zoll-Sensor mit 20 Megapixeln (5 472x3 648 Pixel/Bild). Die Brennweite beträgt 8,8 mm, was einer Brennweite von 24 mm im Kleinbildformat entspricht. Die UAV-Bilder wurden alle 3 s bei einer Fluggeschwindigkeit von 1 m/s aufgenommen. Mit einer angepassten Flughöhe von etwa 8-10 m über dem Boden wurde eine geringe Kameradistanz zu den Blattsymptomen erreicht. Eine Vorwärts- und Seitenüberlappung von etwa 75-80 % soll eine optimale photogrammetrische Verarbeitung garantieren.

Zur Bewertung von Birnenrostsymptomen wurde ein objektbasierter Bildanalyseansatz verwendet (Object Detection). Alle UAV-Bilder wurden auf eine Größe von 768 x 768 Pixel geschnitten, um die Anzahl der Bilder für das Training zu erhöhen und die Bildgröße für die computergestützte Weiterverarbeitung zu optimieren. Das Zuschneiden erfolgte mit der OpenCV-Grafikbibliothek für Bildverarbeitung in Python. Die Symptomkennzeichnung wurde manuell von Fruchtexperten mit dem Computer Vision Annotation Tool (CVAT, Sekachev et al. 2020) vorgenommen (Abbildung 1). Zu diesem Zweck wurden rechteckige ‚Bounding Boxes‘ um den gesamten Blattbereich mit Birnenrostsymptomen (GYMNSA) und gesunden Blättern (HEALTH) gezeichnet. Nach Abschluss der Beschriftung wurde für jeden Bilddatensatz eine Beschriftungsdatei (TXT) im YOLO 1.1-Format erstellt und für das anschließende Modelltraining verwendet.

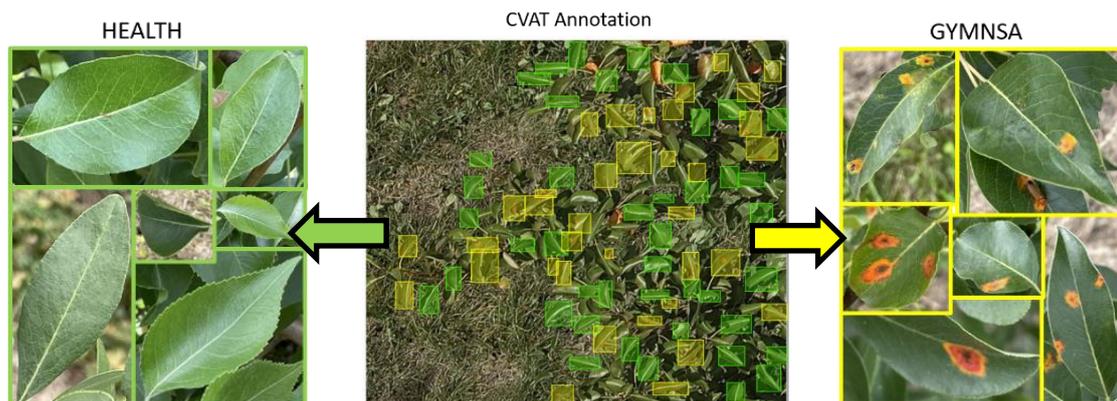


Abbildung 1: Ausschnitt aus einem Luftbild der Versuchsanlage am JKI Dresden-Pillnitz mit gelabelten Blättern mit Birnenrostsymptomen (gelbe Boxen, Label: GYMNSA) und Blättern ohne Symptome (grüne Boxen, Label: HEALTH).

Ein vorläufiger Bildsatz bestand aus 181 beschnittenen UAV-Bildern mit einer annähernd gleichen Anzahl von annotierten Birnengitterrostsymptomen und gesunden Blättern. Zusätzlich wurden 17 Hintergrundbilder ohne Objekte aufgenommen, um falsch-positive Ergebnisse zu reduzieren. Diese 198 Bilder wurden nach dem Zufallsprinzip mit Hilfe eines Python-Prozesscodes in Trainingsbilder und Validierungsbilder aufgeteilt. 95 % des gesamten Bildsatzes wurden als Trainingsbilder und 5 % als Validierungsbilder verwendet. Als Modell für das Machine Learning Training wurde das einstufige Modell ‚You Only Look Once‘ (YOLO v5x) gewählt, da es verschiedene Objekte in einem einzigen Bild erkennt und Objekte sehr schnell identifiziert (Jocher et al. 2022). Die Open-Source-Plattform PyTorch (Paszke et al. 2019) wurde als Deep-Learning-Framework verwendet.

### 3. Ergebnisse und Diskussion

Bei insgesamt neun UAV-Flügen, die während der Vegetationsperiode in den Jahren 2021 und 2022 durchgeführt wurden, konnten 705 Bilder mit Birnengitterrostsymptomen aufgenommen werden. Durch die geringe Flughöhe von 8-10 m wurde eine hohe räumliche Auflösung erreicht, die es ermöglichte, die Krankheitssymptome mit einer Größe von unter 5 cm gut im Bild zu erkennen. Flüge in geringer Höhe erfordern jedoch eine höhere Anzahl von Flügen und eine große Anzahl von Bildern, um ein bestimmtes Gebiet abzudecken, was den Zeit- und Arbeitsaufwand erhöht. Für die digitale Phänotypisierung von Obstzuchtmaterial ist dieser Ansatz jedoch gut geeignet, da in der Regel nur kleine Flächen erfasst werden müssen. Für den Einsatz dieser digitalen Phänotypisierungsmethode in größeren Obstanlagen wäre ein UAV-System mit einer hochauflösenden Kamera besser geeignet, da dieses größere Flughöhen ermöglicht und somit die Anzahl der Flüge/ Bilder reduziert.

Alle Bilder wurden im Feld unter komplexen Umweltbedingungen (unterschiedliche Tageszeiten, Jahreszeiten, Wetterbedingungen, Beleuchtung, Standorten usw.) aufgenommen. Zunächst wurden alle Bilder visuell auf ihre Qualität (z. B. Schärfe, Belichtung, Kontrast) geprüft und gegebenenfalls aus dem Datensatz gelöscht. Insgesamt wurden 324 Bilder mit Birnenrostsymptomen in den Bilddatensatz für den weiteren Workflow verwendet (Tabelle 1). Nach dem Zerschneiden standen 12 698 kleinere Bilder zur Verfügung, die nochmals visuell auf ihre Qualität und das Vorhandensein von Birnenblättern im Bild überprüft wurden. Als Ergebnis wurden 810 beschnittene Bilder für die anschließende Symptomkennzeichnung ausgewählt. Mit Stand Januar 2023 waren 181 der 810 beschnittenen Bilder annotiert und konnten für ein erstes Training (171 Bilder) und eine Validierung (10 Bilder) des Modells verwendet werden.

Tabelle 1: Anzahl der aufgenommenen Bilder, annotierte Trainingsbilder, Validierungs- und Testbilder und Anzahl der Gesamtannotationen für ein erstes Modelltraining für die Erkennung von Birnengitterrostsymptomen (Stand Januar 2023).

Fotos mit UAV erstellt <sup>1</sup>	Geschnittene Bilder <sup>1</sup>	Trainingsbilder <sup>2</sup>	Validierungsbilder <sup>2</sup>	Backgroundbilder	Anzahl Annotationen <sup>2</sup>	Testbilder <sup>2</sup>
324	810	171	10	17	11 000	12

<sup>1</sup>nach Qualitätscheck, <sup>2</sup>Stand Januar 2023

In einer ersten Trainings- und Validierungsphase eines YOLOv5-Standardmodells auf der Grundlage von 198 Bildern wurden 84 % der infizierten und 85 % der gesunden Blätter korrekt erkannt, während die Falsch-Positiv-Rate (FP) für beide Klassen gering war (Abbildung 2). Allerdings wurden einige Objekte als Hintergrund-Falsch-Positive klassifiziert. So wurden z. B. in der Bodenvegetation *Taraxacum*-Blätter als gesund oder *Taraxacum*-Blüten als infizierte Birnengitterrostblätter erkannt, obwohl *Taraxacum*-Blätter und -Blüten eine andere Form als Birnenblätter haben. Möglicherweise war das Modell nicht in der Lage, *Taraxacum*-Blätter auszuschließen, weil sehr viele verschiedene Birnenblattformen durch

die Aufnahme von verschiedenen Birnensorten und -arten im Trainingsdatensatz enthalten waren.




Abbildung 2: Konfusionsmatrix nach dem ersten Modelltraining mit YOLOv5 für die Klassen ‚HEALTH‘ (gesund) und ‚GYMNSA‘ (Birngitterrostsymptom). Die Farbintensität und der Wert in jeder Zelle zeigt den Anteil der Vorhersage für jede Klasse an.

Darüber hinaus wurde ein hoher Anteil an falsch-negativen (FN) Hintergrundwerten beobachtet, was bedeutet, dass mehrere gesunde und infizierte Blätter nicht erkannt wurden. Diese Ergebnisse lassen sich durch das Vorhandensein von verdeckten oder sich überlappenden Blättern in den Bäumen erklären. Dies kann zu Problemen bei der Erkennungsgenauigkeit und einer hohen Fehlerkennungsrate führen (Wang et al. 2021). Ein weiterer Grund könnte sein, dass Blätter nicht erkannt wurden, wenn sie im Schatten lagen oder an den Baumkronen überbelichtet waren. Alle Bilder in dieser Studie wurden bei verschiedenen natürlichen Tageslichtbedingungen mit wechselnder Beleuchtung aufgenommen. Dies kann eine Herausforderung darstellen, da die Bilder bemerkenswerte Schwankungen bei Belichtung, Kontrast und Schattenwurf aufweisen können (Liu et al. 2020). In einer Studie zu Schneebruch in Wäldern wurde berichtet, dass eine größere Schattenkomponente aufgrund der Bildaufnahme bei Sonneneinstrahlung den Grad der Baumdetails im Bild verringern kann (Puliti und Astrup 2022). In einigen Studien wurde jedoch auch erwähnt, dass die Genauigkeit nicht durch sonnige oder bewölkte Bedingungen während der Bildaufnahme beeinträchtigt wurde. Dies wurde hauptsächlich auf die große Anzahl von

Bildern mit unterschiedlichen Lichtverhältnissen zurückgeführt, die dem Modell zur Verfügung standen und seine Robustheit erhöhten (Liu et al. 2020; Puliti und Astrup 2022). Für diese Studie wurden alle Bilder im Feld mit einer großen Bandbreite an unterschiedlichen Lichtverhältnissen aufgenommen, was sehr variable Bilder für die Annotation und das anschließende Training des Modells lieferte.

Vorläufige Ergebnisse des Modelltrainings mit YOLOv5 zeigten eine Genauigkeit von 84 % bei der Erkennung von Birnengitterrostsymptomen. Im Vergleich zu anderen Studien zur deep-learning basierten Erkennung von Blattkrankheiten war die Erkennungsrate in unserer Studie damit schon sehr hoch. Beispielsweise wurden in einer Studie zur Erkennung typischer Apfelblattkrankheiten zwischen 92 % und 96 % der Symptome richtig erkannt (Tian et al. 2021). Diese Studie umfasste allerdings einen Trainingsdatensatz mit über 1 000 Bildern je Krankheit (Tian et al. 2021). Außerdem wurden keine UAV-Bilder, sondern Bilder von Einzelblättern verwendet. Die Erkennung mittels UAV-Bilder kann etwas geringer sein, da die Bilder nicht so hoch aufgelöst sind wie bei Handkamera-Bildern. Zum Beispiel wurden bei der UAV-basierten Erkennung der Braunfäule bei Tee nur 77 % (Bao et al. 2023) und der bakteriellen Fleckenkrankheit bei Paprikapflanzen 90 % der infizierten Blätter richtig erkannt (Mathew und Mahesh 2022). Im Projekt sind jedoch weitere Tests und Validierungen erforderlich, um ein endgültiges Erkennungsmodell mit ausreichender Genauigkeit zu trainieren. Da der erste Trainingsatz in unserer Studie nur 188 Bilder enthielt, ist es wahrscheinlich, dass die Genauigkeit des endgültigen Modells, das viel mehr Trainingsbilder enthalten wird, deutlich besser sein wird.

#### **4. Ausblick**

Die Arbeiten zur genauen Lokalisierung und der Quantifizierung der Krankheitssymptome am Baum werden weitergeführt. Dazu werden die UAV-Bilder mit der Photogrammetrie-Software Agisoft Metashape Professional (Agisoft, St. Petersburg, Russland) verarbeitet. Um die Symptome eindeutig den Einzelbäumen zuordnen zu können, ist es notwendig RTK-Genauigkeit des 3D-Modells zu erzielen. Da die Drohne keine RTK-Möglichkeit besitzt, soll auf die Nutzung von Bodenkontrollpunkten zurückgegriffen werden. Die Arbeit mit GCPs führt im Allgemeinen zu einer genaueren Datenausgabe im Vergleich zu UAV-Geotags, hat aber einen geringeren Automatisierungsgrad zur Folge. Mithilfe der 3D-Punktwolke ist es dann möglich, die Lage der Krankheitssymptome aus den einzelnen 2D-Bildern in 3D-Koordinaten zu projizieren und die genaue Lage der Symptome innerhalb der einzelnen Bäume zu bestimmen. Erkannte Symptome, die in der Regel eine Größe von weniger als 5 cm haben, können dem einzelnen Baum zugeordnet werden. Auf der Grundlage eines verbesserten Erkennungsmodells und der genauen Lokalisierung der Symptome auf Baumebene soll zu Projektende ein digitales Phänotypisierungsverfahren zur Verfügung stehen. Dies soll die Erkennung des Europäischen Birnengitterrostes im Hochdurchsatzverfahren und die räumliche Lokalisierung der Symptome im Feld ermöglichen. Diese Methode soll auch auf andere Krankheitssymptome übertragbar sein.

#### **Danksagung**

Die Autoren bedanken sich für die Förderung des Projekts MONIQUA durch das Bundesministerium für Ernährung und Landwirtschaft (Förderkennzeichen 2818712A19, 2818712B19, 2818712C19). Die Autoren danken Dr. Andreas Peil und Dr. Monika Höfer, die es uns ermöglicht haben, die Symptome des Europäischen Birnenrostes in der Versuchsanlage des JKI zu erfassen.

## Literatur

Aitelkadi K, Outmghoust H, laarab S, Moumayiz K, Sebari I (2021) Detection and Counting of Fruit Trees from RGB UAV Images by Convolutional Neural Networks Approach. *Advances in Science, Technology and Engineering Systems Journal* 6, 887-893, <https://doi.org/10.25046/aj0602101>

Ayaz H, Rodríguez-Esparza E, Ahmad M, Oliva D, Pérez-Cisneros M, Sarkar R (2021) Classification of Apple Disease Based on Non-Linear Deep Features. *Applied Sciences* 14, 6422, <https://doi.org/ARTN>

Bao W, Zhu Z, Hu G, Zhou X, Zhang D, Yang X (2023) UAV remote sensing detection of tea leaf blight based on DDMA-YOLO. *Comput Electron Agr* 205, 107637, <https://doi.org/10.1016/j.compag.2023.107637>

BMEL - Bundesministerium für Ernährung und Landwirtschaft (2023) FAQ: EU-Kommissions-Entwurf einer neuen Verordnung zur nachhaltigen Verwendung von Pflanzenschutzmitteln. <https://www.bmel.de/SharedDocs/FAQs/DE/faq-pflanzenschutzmittel-sur/FAQList.html>, zuletzt abgerufen am 07.02.2023

Caruso G, Palai G, Marra FP, Caruso T (2021) High-Resolution UAV Imagery for Field Olive (*Olea europaea* L.) Phenotyping. *Horticulturae* 8, 258, <https://doi.org/10.3390/horticulturae7080258>

Di J, Li Q (2022) A method of detecting apple leaf diseases based on improved convolutional neural network. *PLoS One* 17, e0262629, <https://doi.org/10.1371/journal.pone.0262629>

Flachowsky H, Höfer M (2010) The German Fruit Genebank, a decentral network for sustainable preservation of fruit genetic resources. Verlag Eugen Ulmer, Stuttgart 62, <https://doi.org/10.5073/JfK.2010.01.02>

Genaev MA, Skolotneva ES, Gulyaeva EI, Orlova EA, Bechtold NP, Afonnikov DA (2021) Image-Based Wheat Fungi Diseases Identification by Deep Learning. *Plants (Basel)* 10, <https://doi.org/10.3390/plants10081500>

Jocher G, Chaurasia A, Stoken A, Borovec J, NanoCode012, Kwon Y, Michael K, TaoXie, Fang J, imyhxy, et al. (2022) ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation (v7.0). Zenodo

Johansen K, Morton MJL, Malbeteau YM, Aragon B, Al-Mashharawi SK, Ziliani MG, Angel Y, Fiene GM, Negrão, SSC, Mousa, MAA, et al (2019) Unmanned Aerial Vehicle-Based Phenotyping Using Morphometric and Spectral Analysis Can Quantify Responses of Wild Tomato Plants to Salinity Stress. *Front Plant Sci* 10, 370, <https://doi.org/10.3389/fpls.2019.00370>

Liu G, Nouaze JC, Touko Mbouembe PL, Kim JH (2020) YOLO-Tomato: A Robust Algorithm for Tomato Detection Based on YOLOv3. *Sensors-Basel* 20, 2145

López-Granados F, Torres-Sánchez J, Jiménez-Brenes FM, Arquero O, Lovera M, Castro AI (2019) An efficient RGB-UAV-based platform for field almond tree phenotyping: 3-D architecture and flowering traits. *Plant Methods* 15, 160, <https://doi.org/10.1186/s13007-019-0547-0>

Mathew MP, Mahesh TY (2022) Leaf-based disease detection in bell pepper plant using YOLO v5. *Signal, Image and Video Processing* 16, 841-847, <https://doi.org/10.1007/s11760-021-02024-y>

Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G, Killeen T, Lin Z, Gimelshein N, Antiga L, et al (2019) PyTorch: An Imperative Style, High-Performance Deep Learning Library (Vancouver, BC, Canada)

Pieruschka R, Schurr U (2019) Plant Phenotyping: Past, Present, and Future. *Plant Phenomics* 2019, 1-6, <https://doi.org/10.34133/2019/7507131>

Puliti S, Astrup R (2022) Automatic detection of snow breakage at single tree level using YOLOv5 applied to UAV imagery. *International Journal of Applied Earth Observation and Geoinformation* 112, 102946, <https://doi.org/10.1016/j.jag.2022.102946>

Reim S, Mass V, Alirezazadeh P, Seidl-Schulz J, Leipnitz M, Fritzsche E, Geyer M, Pflanz M (2023) 77. Establishment of a UAV-based phenotyping method for European pear rust in fruit orchards. *Conference Proceedings: Precision agriculture '23*, 611-617, [https://doi.org/10.3920/978-90-8686-947-3\\_77](https://doi.org/10.3920/978-90-8686-947-3_77)

Sekachev B, Manovich N, Zhiltsov M, Zhavoronkov A, Kalinin D, Hoff B, Tosmanov Kruchinin D, Zankevich A, Dmitriy S, et al (2020) opencv/cvat: v1.1.0 (Zenodo)

Tian Y, Li E, Liang Z, Tan M, He X (2021) Diagnosis of Typical Apple Diseases: A Deep Learning Method Based on Multi-Scale Dense Classification Network. *Front Plant Sci* 12, <https://doi.org/10.3389/fpls.2021.698474>

Wang X, Liu J, Liu G (2021) Diseases Detection of Occlusion and Overlapping Tomato Leaves Based on Deep Learning. *Front Plant Sci* 12, <https://doi.org/10.3389/fpls.2021.792244>