

Virginia Maß^{1*}, Stefanie Reim², Pendar Alirezazadeh¹, Johannes Seidl-Schulz³,
Matthias Leinritz³, Eric Fritzsche², Martin Geyer¹, Michael Pflanz¹

Entwicklung eines digitalen Überwachungssystems zur Erkennung der Krankheitssymptome von Feuerbrand in Obstanlagen

¹ 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

² 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

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

* Korrespondenz: vmass@atb-potsdam.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

Annual Conference DGG and BHGL

01.-04.03.2023, Osnabrück, Germany

Entwicklung eines digitalen Überwachungssystems zur Erkennung der Krankheitssymptome von Feuerbrand in Obstanlagen

Virginia Maß^{1*}, Stefanie Reim², Pendar Alirezazadeh¹, Johannes Seidl-Schulz³,
Matthias Leipnitz³, Eric Fritzsche², Martin Geyer¹, Michael Pflanz¹

¹Leibniz Institut für Agrartechnik und Bioökonomie, Deutschland

²Julius Kühn-Institut, Deutschland

geo-konzept Gesellschaft für Umweltplanungssysteme mbH, Deutschland

Abstract

Der Feuerbrand (*Erwinia amylovora*) gehört zu den gefährlichsten Krankheiten im Obstbau. Regelmäßige Kontrollen sind unerlässlich, um einen Befall im frühen Stadium zu erkennen und eine Ausbreitung des Erregers zu verhindern. Dafür wird in dieser Studie ein digitales Monitoring-System zur Erkennung und Lokalisierung von Feuerbrandinfektionen in Obstanlagen auf Grundlage von RGB-Bildern entwickelt.

Voraussetzung für die digitale Symptomerkenkung ist die Erstellung eines RGB-Bilddatensatzes mit typischen Feuerbrand-Symptomen an Trieben, Blüten und Blättern. Dieser wurde nach künstlicher Inokulation in Versuchsanlagen generiert. Über 1.000 Kameraaufnahmen dienten als Trainingsdatensatz für den Machine Learning-Algorithmus und wurden manuell mit dem Computer Vision Annotation Tool (CVAT) gelabelt. Für die Erkennung und Position der Krankheitssymptome wurde die 2-Punkt Annotation (Bounding Box) angewandt. Mit Hilfe eines photogrammetrischen Ansatzes auf georeferenzierten Bilddaten soll in Zukunft eine kontinuierliche räumliche Erfassung und Dokumentation des Feuerbrands ermöglicht werden.

1. Einleitung

Das Monitoring von Pflanzenkrankheiten in Vermehrungs- und Züchtungsbetrieben sowie in kommerziell wirtschaftenden Obstbaubetrieben ist für die Gesunderhaltung der Anlage unerlässlich. Durch veränderte klimatische Bedingungen und global wachsende Warenströme erhöht sich der Etablierungserfolg einwandernder Schädlinge und Krankheiten nach Europa. Der Feuerbrand (*Erwinia amylovora*) wurde in den 1950er Jahren nach Europa eingeschleppt und ist seit etwa 2006 fast in ganz Europa verbreitet (Billing and Berrie 2002; van der Zwet 2006). Bei ungehinderter Ausbreitung kann Feuerbrand erhebliche wirtschaftliche Schäden in Obstanbaugebieten verursachen. Ein Befall kann zwar durch den Einsatz von Antibiotika, wie Streptomycin, bekämpft werden, allerdings unterliegt der Einsatz in den meisten europäischen Ländern einem Verbot oder strenger Regulierung (Peil et al. 2021). Daher zielen alle Maßnahmen darauf ab, die Ausbreitung des Erregers im Bestand zu verhindern und eine Infektion frühzeitig einzudämmen. Die frühe Erkennung erster Feuerbrand-Symptome sowie räumlich hochaufgelöste Informationen über erkrankte Bäume im Bestand sind entscheidend, um Maßnahmen zur Eindämmung gezielt und zeitnah anwen-

den zu können. Bislang wird die Krankheitsüberwachung überwiegend noch manuell durchgeführt (Norelli et al. 2007). Die Entwicklung einer digitalen Methode zur Erfassung von Feuerbrand-Symptomen im Obstbestand kann eine effektive Methode zur Überwachung dieses Schaderregers sein.

Mehrere Studien befassten sich bereits mit der Entwicklung digitaler Sensortechnologien zur Erkennung von Feuerbrand (Jarolmasjed et al. 2019; Skoneczny et al. 2020). Die einfache Handhabung, kostengünstige Verfügbarkeit von systemisch integrierten hochauflösenden RGB-Kameras sind entscheidende Vorteile gegenüber Kameras mit anderen Bildgebungsverfahren (Mahlein 2016). Für eine weitere photogrammetrische Verarbeitung der RGB-Daten war eine Überlappung der Bilder von etwa 80 % nötig. Durch die Nutzung von RGB-Kameras wurden komplexe Daten in einer überschaubaren Menge weiterverarbeitet.

Im Rahmen des MONIQUA-Projekts sollen Feuerbrand-spezifische Krankheitssymptome durch bildgebende Verfahren digital erfasst, mithilfe von Machine Learning ausgewertet und kartiert werden. Langfristig soll mit dieser Methode ein kostengünstiges und Hochdurchsatz-Überwachungssystem für die Obstproduktion und -zucht bereitgestellt werden.

2. Material und Methoden

Erstellung eines RGB-Bilddatensatzes und Annotation von Feuerbrandsymptomen

In den Jahren 2021 und 2022 wurden 5.087 RGB-Bilder als Grundlage für die Symptomererkennung gesammelt. An fünf Terminen wurden nach künstlicher Inokulation die RGB-Bilder sowohl im Versuchsquartier des Julius Kühn-Instituts (JKI), Institut für Pflanzenschutz in Obst- und Weinbau in Dossenheim, Deutschland, als auch im Versuchsgewächshaus des Julius Kühn-Instituts für Resistenzforschung und Stresstoleranz in Quedlinburg, Deutschland, aufgenommen. Im Versuchsgewächshaus am JKI-Quedlinburg wurden in jedem Jahr etwa 2.000 unterschiedliche Apfelgenotypen künstlich mit Feuerbrand inokuliert, die für die Fotoaufnahmen von Schadsymptomen des Feuerbrands genutzt werden konnten. Das Versuchsquartier des JKI-Dossenheim verfügt über einen heterogenen Apfelbestand mit unterschiedlichen Apfelsorten und Apfelwildarten, die ebenfalls jedes Jahr künstlich mit Feuerbrand inokuliert wurden. Diese Bestände mit insgesamt 701 Apfelbäumen wurden für Fotografien von Feuerbrand-Symptomen im Freiland verwendet. Für die Aufnahmen der typischen Symptome von Feuerbrandinfektionen an Trieben, Blättern und Blüten wurden verschiedene Kamerasysteme verwendet, um ein robustes Machine Learning-Modell zu erzeugen: Canon EOS 90D, Sony Alpha 6000, Sony ILCE- 20197RM2, Samsung Galaxy Tablet SM-T590 sowie unterschiedlichen Smartphones.

Von 5.087 gesammelten RGB-Bildern wurden 1.077 aus den Jahren 2021 und 2022 manuell durch Bounding Boxes mit dem Computer Vision Annotation Tool (CVAT (Sekachev et al. 2020)) annotiert. Dafür wurden die Klassen SHOOT, LEAF und FLOWER festgelegt (Abb. 1). Darüber hinaus wurden Symptome anderer Pflanzenkrankheiten ebenfalls erfasst und als eigene Klasse in den Bilddatensatz integriert (Abb. 1).

Insgesamt wurden 8.728 Annotationen von den 4 Klassen als Datensatz für den Trainings-, Validierungs- und Testprozess verwendet und für die Bildklassifikation herangezogen. Das Trainingsset beinhaltete 6.545 Bilder, das Validierungsset 435 Bilder und das Testset 1.748 Bilder.

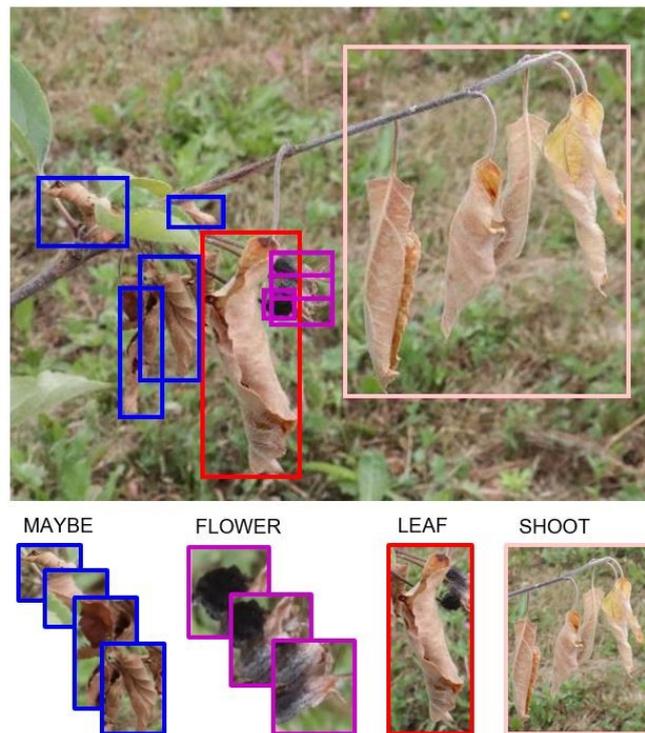


Abbildung 1: Annotation von Feuerbrand-Symptomen mit CVAT an Spross (SHOOT = rosa), Blatt (LEAF = rot) und Blüten (FLOWER = lila) sowie Symptome (z. B. trockene Blätter), die nicht eindeutig dem Feuerbrand zugeordnet werden konnten (MAYBE = blau).

Training des Machine Learning-Algorithmus

Um einen Klassifizierungsdatensatz für Feuerbrand-Symptome zu generieren, wurden die annotierten Bilder als Vorverarbeitungsschritt von Training, Validierung und Testung anhand der Bounding Box-Informationen zugeschnitten. Die Größe der Ausschnitte für das Modell betrug 224 Pixel x 224 Pixel. Die erstellten Trainings-, Validierungs- und Testdatensätze lagen als Modellformat für eine Musteranalyse, statistische Modellierung und Berechnungen (PASCAL) für visuelle Objektklassen (VOC) vor (Everingham et al. 2010). Für das Training des Algorithmus wurde das Convolutional Neural Network (CNN) „MobileNetV3-Large“ (Howard et al. 2019) mit 4.231.556 Parametern verwendet. Um eine Überanpassung des Modells zu verhindern und den Datensatz sowie die Annotationsarbeit in diesem ersten Modelltest abschätzen zu können, wurde das CNN zunächst 100 Epochen trainiert. Im Trainingsdurchlauf wurde eine Batch-Size von 16 und die Optimierungsmethode „Adam“ (Kingma and Ba 2015) mit einer Lernrate von 0,0001 verwendet.

GIS-gestützte Lokalisierung von Krankheitssymptomen

Die automatische Erkennung von Feuerbrand-Symptomen wurde durch den Machine Learning-Algorithmus realisiert. Durch RTK-genaue Positionsdaten von Einzelbildern auf dem Feld wurden die Feuerbrand-Symptome an einzelnen spezifischen Bäumen innerhalb der Obstanlage lokalisiert. Mit Hilfe eines neuartigen Photogrammetrieverfahrens durch die Photogrammetrie-Software Agisoft Metashape Professional (AgiSoft PhotoScan Professional 2016) wurden die 2D-Positionen von einzelnen Symptomen in 3D-Punktwolken projiziert und mit realen Koordinaten versehen.

3. Ergebnisse und Diskussion

Große Bilddatensätze sind von hoher Relevanz für ein erfolgreiches Training eines Machine Learning-Algorithmus (Iqbal et al. 2021). Vor allem Feuerbrand-Symptome an Blättern können leicht mit anderen Obstkrankheiten wie beispielsweise *Monilia* verwechselt werden. Um zu verhindern, dass mögliche Feuerbrand-Symptome bei einer Machine Learning-basierten Methode übersehen werden, wurden diese potenziellen Symptome mit in das Training integriert und als MAYBE gelabelt. Durch das Zuschneiden der Bilder anhand der Bounding Box-Informationen als Vorverarbeitungsschritt wurden 8.728 Ausschnitte generiert und für den ersten Testlauf mit dem Convolutional Neural Network (CNN) „MobileNetV3-Large“ verwendet. Durch den Einsatz verschiedener Kamerageräte bzw. Bildqualitäten konnte die Robustheit des Erkennungsmodells unterstützt werden, was eine wichtige Voraussetzung für die maschinelle Erkennung von Krankheiten auf der Grundlage von Deep Learning ist (Liu et al. 2020; Puliti and Astrup 2022). 78,13 % der Feuerbrand-Symptome wurden im ersten Testlauf richtig erkannt (Präzision). Dabei wurden 68,18 % der Symptome im Testdatensatz der richtigen Klasse zugeordnet (Sensitivität). Die Genauigkeit des Modells liegt mit 73,46 % ein wenig höher, was darauf hindeutete, dass der Datensatz relativ balanciert ist. Um die Erkennung und Aussagekraft des Algorithmus weiter zu verbessern, sollte in Zukunft eine Erweiterung des Datensatzes mit einer balancierten Anzahl von Annotationen je Klasse angestrebt werden.

4. Schlussfolgerung und Ausblick

Um die Einschleppung und Ausbreitung von *Erwinia amylovora* in einem frühen Stadium des Befalls zu erkennen und zu verhindern, sind regelmäßige Kontrollen notwendig. Damit Obstproduzenten und -züchtern eine schnelle Kontrolle, mit eindeutiger Identifizierung und Lokalisierung von Krankheitssymptomen, angeboten werden kann, soll eine maschinelle Erkennung auf der Grundlage eines „MobileNetV3-Large“-Algorithmus entwickelt werden. Mit über 78 % richtiger Erkennung der Feuerbrandsymptome, liegen erste Ergebnisse des Versuchs, einen Algorithmus zu trainieren, vor. Mit einer Erweiterung des Annotationsdatensatzes und der Verfeinerung der Annotationen können wahrscheinlich in Zukunft höhere Erkennungsraten von Feuerbrand-Symptomen erzielt werden. Durch die Verarbeitung der Ergebnisse des Erkennungsmodells und mithilfe von photogrammetrischen Verfahren auf georeferenzierten Bildern soll in Zukunft eine genaue Lokalisation der Krankheitssymptome möglich sein. Auf der Grundlage dieser Daten wird ein Überwachungsmodell entwickelt, das ein Kontrollsystem mit hohem Durchsatz für die Obstproduktion und -zucht ermöglicht.

Literatur

AgiSoft PhotoScan Professional (2016) Version 1.2.6 (Software).
<http://www.agisoft.com/downloads/installer/>

Billing E, Berrie AM (2002) A Re-examination of Fire Blight Epidemiology in England. *Acta Horticulturae* 590: 61-67, <https://doi.org/10.17660/ActaHortic.2002.590.6>

Everingham M, van Gool L, Williams CKI, Winn J, Zisserman A (2010) The Pascal Visual Object Classes (VOC) Challenge. *Int J Comput Vis* 88: 303-338, <https://doi.org/10.1007/s11263-009-0275-4>

Howard A, Sandler M, Chu G, Chen LC, Chen B, Tan M, Wang W, Zhu Y, Pang R, Vasudevan V et al. (2019) Searching for MobileNetV3. ICCV, Seoul, South Korea, <https://doi.org/10.48550/arXiv.1905.02244>

- Iqbal MS, Ali H, Tran SN, Iqbal T (2021) Coconut trees detection and segmentation in aerial imagery using mask region-based convolution neural network. *IET Computer Vision* 15, 428-439, <https://doi.org/10.1049/cvi2.12028>
- Jarolmasjed S, Sankaran S, Marzougui A, Kostick S, Si Y, Quirós Vargas JJ, Evans K (2019) High-Throughput Phenotyping of Fire Blight Disease Symptoms Using Sensing Techniques in Apple. *Frontiers in plant science* 10, <https://doi.org/10.3389/fpls.2019.00576>
- Kingma, DP, Ba J (2015) Adam: A Method for Stochastic Optimization. ICLR 2015, San Diego, USA, <https://doi.org/10.48550/arXiv.1412.6980>
- Liu G, Nouaze JC, Touko Mbouembe PL, Kim JH (2020) YOLO-Tomato: A Robust Algorithm for Tomato Detection Based on YOLOv3. *Sensors*, <https://doi.org/10.3390/s20072145>
- Mahlein AK (2016) Plant Disease Detection by Imaging Sensors - Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. *Plant disease* 100: 241-251, <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Norelli JL, Jones AL, Aldwinckle HS (2007) Fire Blight Management in the Twenty-first Century: Using New Technologies that Enhance Host Resistance in Apple. *Plant disease* 87 (7): 756-765, <https://doi.org/10.1094/PDIS.2003.87.7.756>
- Peil A, Emeriewen OF, Khan A, Kostick S, Malnoy M (2021) Status of fire blight resistance breeding in Malus. *J Plant Pathol* 103: 3-12, <https://doi.org/10.1007/s42161-020-00581-8>
- 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*, <https://doi.org/10.1016/j.jag.2022.102946>
- Sekachev B, Manovich N, Zhiltsov M, Zhavoronkov A, Kalinin D, Hoff B, Osmanov T, Kruchinin D, Zankevich A, Sidnev D et al. (2020) opencv/cvat: v1.1.0 (Zenodo)
- Skoneczny H, Kubiak K, Spiralski M, Kotlarz J, Mikiciński A, Puławska J (2020) Fire Blight Disease Detection for Apple Trees: Hyperspectral Analysis of Healthy, Infected and Dry Leaves. *Remote Sensing* 12 (13): 2101, <https://doi.org/10.3390/rs12132101>
- van der Zwet T (2006) Present Worldwide Distribution of Fire Blight and Closely Related Diseases. *Acta Horticulturae* 704: 35-36