



## ERFASSUNG DER SCHWARZ-HOLZKRANKHEIT MIT DROHNEN – EINE ECHTE ALTERNATIVE?

Im Kontext des Klimawandels bilden Krankheiten wie Bois noir (Schwarzholzkrankheit, SHK) oder Flavescence dorée (Goldgelbe Vergilbung, GGV) neue Herausforderungen. Die Überwachung dieser Krankheiten ist komplex und kostenintensiv, deshalb braucht es effiziente Alternativen. Vielversprechend ist der Drohneneinsatz zur Detektion der SHK.

Derzeit erfolgt das Monitoring von SHK und GGV durch eine visuelle Kontrolle Rebe für Rebe, ein zeitaufwendiges Verfahren. Dabei besteht die Herausforderung, dass sich die beiden Krankheiten visuell nicht unterscheiden lassen und dafür molekularbiologische Methoden erforderlich sind. In Regionen, in denen die GGV bereits vorkommt (Tessin und in einigen Westschweizer Kantonen), ist der Überwachungsbedarf besonders hoch. Reben, die von GGV befallen sind, müssen unbedingt gerodet werden. Für Winzer und Winzerinnen sowie kantonale Behörden ist eine zuverlässige und kosteneffiziente Einschätzung der Krankheitsverbreitung ent-

scheidend, da diese beide Krankheiten erhebliche Schäden verursachen.

Bildgebende Methoden wie Multispektralsensoren sind räumlich hochauflösend und erlauben die Unterscheidung kleinster Farbnuancen. Daneben ermöglichen Drohnen eine schnelle Erfassung von Krankheitssymptomen auf grossen Flächen und sind daher eine vielversprechende Alternative zu Rebbegehungen. Wir präsentieren hier erste Ergebnisse des Drohneneinsatzes zur Detektion von SHK auf einer Versuchsparzelle im Kanton Zürich – durchgeführt mit einer handelsüblichen Drohne, ausgestattet mit einer Multispektralkamera.

### DROHNENEINSATZ IM REBBERG

Die eingesetzte Kamera kann gleichzeitig mehrere Spektralbänder erfassen, darunter Grün, Rot, Red Edge und Nahinfrarot. Diese Bänder wurden vom Hersteller gezielt ausgewählt, da sie generell für das Vegetationsmonitoring eingesetzt werden können. Eine frühere Studie belegt ihre Wirksamkeit bei der Erkennung von SHK-Symptomen (Huggel, 2024), zeigt aber auch auf, dass diese Kanäle Limitierungen aufweisen.

Die Versuchsparzelle umfasste rund 720 Zweigelt-Reben (ca. 1450 m<sup>2</sup>) mit deutlichen Symptomen und einer Infektionsrate von über





Abb. 1: Nahaufnahme der Reben, welche den Trainings für das «Machine Learning» dient.  
(© Jeremiah Huggel)



Abbildung 4: Studienparzelle mit Reihen von über 50 Metern Länge und etwa 60 Reben pro Reihe. In Blau die symptomatischen Flächen, in Gelb die nicht symptomatischen Flächen. Wie beschrieben, wurde nur die Blattoberfläche berücksichtigt. (© Jeremiah Huggel)

55%. Die Drohnenflüge fanden in der zweiten Septemberwoche 2024 statt, ein Zeitpunkt, an dem die Symptome gut sichtbar sind, das Laub jedoch noch grösstenteils grün ist. Die Flüge wurden entlang der Reihen mit vorprogrammierter Flugbahn durchgeführt. Die Kamera war in einem 45°-Winkel geneigt, um die Lauboberfläche seitlich optimal zu erfassen. Die Bilder wurden in einer Höhe von 20 Metern alle drei Meter aufgenommen, ein idealer Kompromiss zwischen Bildauflösung und Fluggeschwindigkeit.

#### ENTWICKLUNG DES KLASSTIFIKATIONS-ALGORITHMUS

Um die Klassifizierung von symptomatischen und asymptomatischen Pflanzen durchzuführen, musste ein Erkennungsalgorithmus trainiert werden. Dafür wurden am Tag des Drohnenflugs zehn symptomatische und asymptotische Reben am Boden fotografiert (Abb. 1). Sowohl Blätter mit erkennbaren Symptomen (rote Blätter) als auch die gesunden, grünen Blätter wurden manuell, pixelgenau markiert, etwa neun Millionen Pixel

wurden so gesammelt. Diese Daten bilden die Grundlage für ein auf «Machine Learning» gestütztes System, das lernt, jeden Pixel automatisch zu klassifizieren. 60% der Daten dienten dem Training, 40% der Validierung des Algorithmus.

#### OPTIMIERUNG DES ALGORITHMUS

Um die Erkennung robuster zu machen, wurden zusätzliche Vegetationsindizes aus den



Foto aufgenommen mit der Drohne. (© Jeremiah Huggel)




Abb. 2: Klassifizierung mit berechneten Vegetationsindizes.

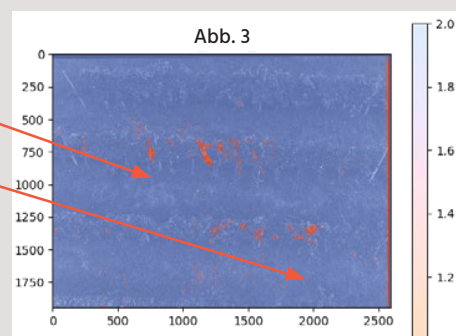


Abb. 3: Klassifizierung nach Filterung und Glättung der Daten.





Abbildung 5a: Magnesiummangel-Symptome bei roten Sorten mit normaler Holzverholzung.

(© Agroscope)



Abbildung 5b: Symptome des Blattrollvirus bei roten Sorten mit normaler Holzverholzung.

(© siehe Link unten)



Abbildung 5c: Symptom der Büffelizekade mit dem typischen schwarzen Kreis an der Einstichstelle.

(© Agroscope)



Abbildung 5d: Symptom von SHK und fehlende Verholzung des Holzes. (© Agroscope)

Spektraldaten berechnet. Diese halfen, symptomatische von gesunden Bereichen besser zu unterscheiden (siehe Abb. 2). Eine Schwellwertanalyse diente der Klassifikation: Überschreitet ein Pixel diesen Wert, gilt er als symptomatisch.

Allerdings entstehen bei dieser Methode oft fehlerhafte Einzelpixel, die keine realen Symptome repräsentieren und häufig im Hintergrund im trockenen Gras sind. Um dies zu korrigieren, wurde ein Bildverarbeitungsverfahren getestet (siehe Abb. 3). Dieses glättet das Bild, entfernt isolierte Pixel und verstärkt zusammenhängende, krankheitstypische Muster. Die Genauigkeit erreichte über 80%, bedarf aber menschlicher Hilfe, um die Gruppen von symptomatischen Pixeln vom Hintergrund zu unterscheiden.

#### EINBEZUG DER HÖHENINFORMATION

Bis zu diesem Punkt lagen nur 2D-Bilder mit (x,y)-Koordinaten vor. Zur Unterscheidung von Rebe, Boden oder Gras wurde ein 3D-Modell anhand von einem «Structure from Motion Ansatz» erstellt. Dieser erlaubt es, den Boden anhand von einem digitalen Oberflächenmodell zu subtrahieren und nur die 3D-Pixel zwischen 0.7 und 2.0 Metern – also in der Laubzone der Reben – zu berücksichtigen (siehe Abb. 4). Dadurch fallen die Probleme der Falschklassifikation im Hintergrund (Boden) weg. Es werden jedoch immer noch einzelne Pixel falsch klassifiziert, welche danach ähnlich wie bei den 2D-Bildern mit einem Glättungsalgorithmus reduziert werden. Dadurch sieht man nur noch grössere Ansammlungen von symptomatisch-klassifizierten Pixeln, welche ganze Reben repräsentieren.

#### VIELVERSPRECHENDE ERGEBNISSE


Abbildung 4 zeigt symptomatische Bereiche, eine exakte Zählung befallener Rebstöcke bleibt jedoch schwierig. Im Allgemeinen wurden stark befallene Reben durch den Algorithmus gut erkannt. In visuellen Tests wurden 80 % bis 90 % der Pixel korrekt klassifiziert. Der Anteil symptomatischer Pixel lag bei 30 %, die Infektionsrate der Reben bei ca. 55 %. Das ist immer noch eine gute Klassifikation: Die Unterschiede ergeben sich daraus, dass die Symptome sehr unterschiedlich ausgeprägt sind, da nicht jeder Trieb einer infizierten Rebe sichtbare Symptome aufweist und auch ein einzelner Trieb nicht vollständig symptomatisch sein muss.

#### ZUSÄTZLICHE HERAUSFORDERUNGEN

Obwohl die ersten Ergebnisse vielversprechend sind, erschweren weitere Faktoren den Prozess. Tatsächlich gibt es andere Krankheiten oder Mangelerscheinungen, die ähnliche Symptome wie SHK zeigen (Abb. 5 a bis d) und von unserem Algorithmus falsch erkannt werden könnten. In diesem Zusammenhang erscheint die fehlende Verholzung der Triebe (grüne Triebe im Spätsommer) ein vielversprechender zusätzlicher Indikator zu sein.

Im Jahr 2025 wurden daher drei weitere Parzellen mit Blauburgunder mit deutlich milderen Symptomen sowie drei Chardonnay-Parzellen zur Analyse beprobt, um damit die Erkennung auch auf weisse Sorten auszuweiten.

Da eine sichere Unterscheidung von SHK und GGV bislang nur im Labor mittels molekularer Analysen möglich ist, arbeitet das Projekt SmartGrape auch mit weiteren alternativen Methoden, darunter die Analyse der Duft-

stoffe, welche von infizierten Reben freigesetzt werden. Die Kombination aus Duftmolekülen und multispektraler Bildgebung kann in Zukunft ein leistungsstarkes Werkzeug für die Früherkennung und Unterscheidung von Vergilbungskrankheiten sein. Ein separater Artikel zu diesen Entwicklungen folgt in den nächsten Monaten. 

#### Dank

Wir danken den beteiligten Winzer/-innen, Mitgliedern des Smart-Grape-Projekts, namentlich: Linus Reichert (Universität Zürich), Stefano Minchev (ETH Zürich), Christophe Debonneville und Patrik Kehrli (Agroscope).

#### Autorenschaft

Lionel Christen, Agroscope Weinbau Deutschweiz, [lionel.christen@agroscope.admin.ch](mailto:lionel.christen@agroscope.admin.ch)  
Jeremiah Huggel, Universität Zürich, [jeremiah.huggel@uzh.ch](mailto:jeremiah.huggel@uzh.ch)  
Salome Schneider, Weinbauzentrum AG, [salome.schneider@weinbauzentrum.ch](mailto:salome.schneider@weinbauzentrum.ch)  
Meredith C. Schuman, Universität Zürich, [meredithchristine.schuman@uzh.ch](mailto:meredithchristine.schuman@uzh.ch)  
Kathleen Mackie-Haas, Agroscope Weinbau Deutschweiz, [kathleen.mackie-haas@agroscope.admin.ch](mailto:kathleen.mackie-haas@agroscope.admin.ch)

#### Weiterführende Literatur

Huggel, J., 2024: Assessing Machine Learning Methods to Detect Bois Noir in Vineyards – Towards a systematic monitoring approach with spectroradiometry and RPAS data to reduce farmers' manual detection time. University of Zurich. <http://dx.doi.org/10.13140/RG.2.2.35091.80163>