

DER EINSATZ VON DROHNEN ZUR ERKENNUNG UND QUANTIFIZIERUNG VON REBERKRANKUNGEN (BAKTERIOSEN UND VIROSEN) IM WEINGARTEN

HELMUT GANGL¹, MARTIN TIEFENBRUNNER², GERHARD LEITNER¹, IRMGARD TIEFENBRUNNER¹
und WOLFGANG TIEFENBRUNNER¹

¹Bundesamt für Weinbau
A-7000 Eisenstadt, Gölbeszeile 1

²LMS-Data
A-8793 Trofaiach, Wiesengasse 5

Bois noir ist eine durch Phytoplasmen verursachte Erkrankung mit hohem Potential zur Rebschädigung, die in Österreich bereits weit verbreitet und wirtschaftlich relevant ist. Auch Virose, insbesondere solche, die durch Nepoviren bedingt sind, können sich verheerend auf die Vitalität befallener Reben auswirken. Es gibt keine Behandlung gegen diese Krankheiten, und daher ist die Erkennung erkrankter Reben in Weingärten und Jungrebanlagen sehr bedeutend; das Monitoring danach ist aber auch zeitintensiv. Wir haben daher auf Visual-Data-Exploration-Basis untersucht, inwieweit aus einer Serie von Photos, die mit über dem Weingarten fliegenden Drohnen im Spektralbereich des sichtbaren Lichts aufgenommen wurden, wichtige Informationen über das Ausmaß der Reberkrankung extrahiert werden können. Dazu wurde zunächst ein Verfahren entwickelt, das die rasche Erkennung erkrankter Reben ermöglicht und die Gefahr von Verwechslungen mit gesunden Weinpflanzen oder dem Hintergrund (z. B. Fahrgassenbegrünung) gering hält. Die Analysen fanden an zwei Weingärten mit massiver Bois Noir-Symptomatik statt ('Grüner Veltliner' und 'Blaufränkisch') und zwei weiteren, die herdförmige Stellen mit an Nepovirose erkrankten Reben aufwiesen. Blattverfärbungen können leicht erkannt und quantifiziert werden, besonders bei Rotwein-, aber durchaus auch bei Weißweinsorten. Es ist allerdings mit dem vorgestellten Untersuchungsansatz, der auf Einzelpixelanalyse basiert, nicht möglich, verschiedene Erkrankungen, die ähnliche Symptome verursachen, zu unterscheiden. Lokal unterschiedliche Wüchsigkeit innerhalb von Rebanlagen kann ebenfalls festgestellt werden, sofern sich die Reben vom Hintergrund trennen lassen, was bei begrünten Fahrgassen nicht ausreichend gelungen ist. Das bedeutendste Problem, das einer vollautomatisierten Erkennung im Wege steht, ist die farbliche Vielfalt des Hintergrundes (z. B. die Gestaltung der Fahrgassen), weshalb derzeit nur ein halbautomatischer Ansatz, der die Anschauung und das Eingreifen des Menschen ermöglicht, in Frage kommt, um erkrankungsbedingte Rebschäden zu lokalisieren und zu quantifizieren. Es wird diskutiert, inwieweit eine gestalterkennende Künstliche Intelligenz (KI) hier Abhilfe schaffen könnte. **Schlagwörter:** precision viticulture, Bois noir, Nepovirose, Drohnen, unmanned aerial vehicle (UAV), Data Mining, Visual Data Exploration (VDE)

The use of drones to detect and quantify grapevine diseases (bacterioses and viroses) in the vineyard. Bois noir is a grapevine disease with a high potential for damaging grapevines caused by phytoplasmas. In Austria it is already widespread and economically relevant. Also viroses, especially those caused by nepoviruses, can have a devastating effect on the vitality of infected vines. There is no treatment for these diseases and therefore the detection of diseased vines in vineyards and young vine plantations is very important; however, monitoring them is also time-consuming. We have therefore investigated, on the basis of visual data exploration, how important information about the extent of the vine disease can be extracted from a series of photos taken in the spectral range of visible light with drones flying over the vineyard. First, a process was developed that enables diseased vines to be identified quickly and minimizes the risk of confusion with sound vines or the background (e. g. interrow greencover). The analyses were carried out with two vineyards with massive Bois Noir symptoms (varieties: 'Grüner Veltliner' and 'Blaufränkisch') and two others that showed focal areas with vines suffering from nepoviruses. Leaf discolouration can easily be recognized and quantified, especially with red, but also with white varieties. With the research approach presented here, which is based on single-pixel analysis, however, it is not possible to differentiate between different diseases that cause similar symptoms. Locally differing growth rates within vineyards can also be determined, provided that the vines can be separated from the background, which is not sufficiently successful in the case of interrow greencover. The most important problem inhibiting a fully automated detection is the variety of colors in the background (e. g. interrow design), which is why currently only a semi-automatic approach, which enables human observation and intervention, is possible, to localize and quantify disease-related vine damage. It is discussed to what extent a shape-identifying Artificial Intelligence (AI) could help here. **Keywords:** precision viticulture, Bois noir, nepoviruses, drones, unmanned aerial vehicle (UAV), Data Mining, Visual Data Exploration (VDE)

Ursprünglich für militärische Zwecke (Aufklärung, Spionage, aber auch gezielte Tötung) (MA et al., 2013; CHEN et al., 2019) entwickelt, ist inzwischen auch die zivile Nutzung von Drohnen (unmanned aerial vehicles, UAVs) von überaus großer Bedeutung. Wildlife-Monitoring, geospatiale Erfassung nach Katastrophen und die Untersuchung von Lebensräumen, die für Menschen gefährlich sind – z. B. in Zusammenhang mit der Expansion einer Epidemie – sind hier zu nennen (FORNACE et al., 2014; BELOEV, 2016). Weite Verbreitung fanden Drohnen bei den abbildenden Medien, um komplizierte, dreidimensionale Kameraführung – z. B. bei Sportereignissen – zu ermöglichen. Seit den letzten zehn Jahren sind UAVs auch als Spielzeug erhältlich. Viele landwirtschaftliche Anwendungen sind noch in der Testphase, aber in einigen Bereichen werden UAVs bereits erfolgreich verwendet, nämlich bei der Feststellung der Bodenqualität, bei der Ausbringung von Saatgut, Herbiziden und Düngern, was die Bodenverdichtung minimiert, und beim Monitoring von Anbauflächen, z. B. um Bestandslücken oder Mängelstellen festzustellen und hier lokal erforderliche, notwendige Schritte zu ergreifen. Euphorisch wird von einer neuen Landbewirtschaftung, "precision agriculture", gespro-

chen, in der Maßnahmensetzungen viel zielgerichteter und teilweise auch schonender erfolgen können (ZHANG & KOVACS, 2012; Tsouros et al., 2019). Von einigen interessanten Anwendungen wird auch im deutschsprachigen Raum berichtet. So wurden in Baden-Württemberg Drohnen, ausgerüstet mit einer Wärmebildkamera, zur Detektion von Rehkitzen kurz vor der Mahd eingesetzt. Auf diese Weise konnten 80 Individuen gerettet werden (ORF, 2017). Im Hanság, dem östlichsten Teilgebiet des Nationalparks Neusiedler See-See Winkel, werden auf diese Weise Bodenbrüter geschützt. Mit Wärmebildkameras ausgerüstete Drohnen eignen sich auch, um Trockenstress bei Pflanzen zu erkennen. Das International Water Management Institute führte in Sri Lanka entsprechende Versuche durch und kam zum Schluss, dass sich Wassermangel in der Pflanze im nahen Infrarotbereich bereits zehn Tage, bevor sichtbare Symptome ausgeprägt werden, erkennen lässt (SIDDIQUI, 2016). Diese Einsichten werden von der Bayerischen Landesanstalt für Weinbau und Gartenbau (LWG) derzeit (2017 bis 2020) für den Weinbau genutzt bzw. wird die Effizienz in einem Projekt untersucht (HESSDÖRFER, 2020). Mithilfe der von UAVs gelieferten Informationen soll gezieltes Bewässern mög-

lich werden – eben nur dort, wo es wirklich nötig ist. Schon 2013 wurden Drohnen zur Schädlingsbekämpfung eingesetzt. Zur Eindämmung des Maiszünslers wurden Schlupfwespen dabei ferngesteuert über Maisfeldern abgeworfen (BERGMANN, 2014), und zur Vertreibung von Staren in Weinkulturen wurden am Westufer des Neusiedlersees Drohnen sehr erfolgreich eingesetzt, nachdem nach tödlichen Unfällen von Versuchsflugzeug-Piloten nach Alternativen gesucht worden war (KNOPF, 2014). Unsere eigenen Versuche fallen in den Bereich des Monitorings von landwirtschaftlichen Nutzflächen, um Erkrankungen festzustellen. In diesem Bereich gibt es noch nicht allzu viel Erfahrung. Die Southern Illinois University versucht mit einem zehnstufigen Bewertungssystem die Einschätzung der Nutzpflanzengesundheit bei der Bonitierung vor Ort und mittels Drohnenbildern zu vergleichen (ERICKSON, 2015). Es handelt sich hier aber eher um eine Vitalitätsfeststellung als um ein Diagnosetool. In Tomatenkulturen wurden supraaufgelöste UAV-Bilder zur Krankheitserkennung verwendet (YAMAMOTO et al., 2017). Verschiedene Arbeiten wurden auch im Weinbau durchgeführt (ALBETIS et al., 2017 und 2018; AL-SADDIK et al., 2016; GENARO et al., 2016; KERKECH et al., 2018). Bei den sehr aufwendigen Untersuchungen von ALBETIS et al. (2017 und 2018) standen die Bakteriose Flavescence dorée (FD) und Grapevine Trunk Diseases (GTD), ein von Pilzen verursachtes Krankheitskontinuum, im Fokus. Der für die Aufnahmen verwendete Spektralbereich ging dabei über den des sichtbaren Lichtes hinaus. Da dafür aber eine spezielle Ausrüstung erforderlich ist, die nicht überall verfügbar und darüber hinaus kostenintensiv ist, entschieden wir uns dafür, für unsere Untersuchungen nur den RGB-Bereich des Lichts zu nutzen. FD spielt in den österreichischen Weinbaugebieten noch kaum eine Rolle, aber Bois noir (BN), eine ebenfalls durch Phytoplasmen ausgelöste Erkrankung, ist mittlerweile weit verbreitet und ökonomisch bedeutend. BN verbreitet sich im Allgemeinen nicht so rasch wie FD, weil für den bedeutendsten Vektor von BN, *Hyalesthes obsoletus*, die Rebe *Vitis vinifera* nicht ins Wirtsspektrum fällt. Die Symptome, die hauptsächlich im späten Sommer erscheinen, sind aber ähnlich: Die Lignifizierung des Rebholzes ist mangelhaft, die Blätter verfärben sich früh gelblich bei Weiß-

wein- und rötlich bei Rotweinkulturen. Es kommt zum Eintrocknen von Infloreszenzen und Beeren. Falls sie sich nicht erholt, stirbt die Pflanze nach einigen Jahren. Zum Absterben der Rebe kommt es oft auch durch Nepoviren, die hauptsächlich im Süden Österreichs weit verbreitet sind und gravierende Schäden in Rebkulturen verursachen. Häufige Symptome sind Wuchsstörungen, die im späten Frühjahr oft sehr deutlich sind. Wir haben uns daher auf den Symptommachweis mittels UAVs für diese beiden Gruppen von Krankheitserregern beschränkt. Einen Überblick über die Verwendung von Drohnen in der Landwirtschaft gibt BARBEDO (2019).

MATERIAL UND METHODEN

STANDORTE UND ERKRANKUNGSZUSTAND

Vier Weingärten in drei nordburgenländischen Gemeinden wurden aufgrund einer in den vergangenen Jahren beobachteten Häufung von erkrankten Reben ausgewählt. In Eisenstadt, Ortsteil St. Georgen, waren dies zwei Weingärten am Hang des Leithagebirges, unmittelbar an den Niederwald angrenzend und von Südost nach Nordwest verlaufend. Einer davon, 100 m lang und 33 m breit, enthielt Reben einer Rotwein- ('Blaufränkisch'), der andere, westlicher gelegen und 112 m lang und 20 m breit, solche einer Weißweinsorte ('Grüner Veltliner'). Die Fahrgassen waren begrünt, wobei sich, wohl unbeabsichtigt, hauptsächlich Beifußblättriges Traubenkraut (*Ambrosia artemisiifolia*) ausgebreitet hatte, daneben auch noch Gräser und Ackerwinde (*Convolvulus arvensis*) sowie Feinstrahl (*Erigeron annuus*). In beiden Anlagen waren Reben, die BN-Symptome aufwiesen, 2017 in großer Zahl festgestellt worden. Auch der bedeutendste Überträger, *Hyalesthes obsoletus*, wurde 2017 und 2019 an Gelbfällen im Blaufränkisch-Weingarten nachgewiesen, ebenfalls *Reptalus panzeri*, ein BN-Vektor von geringerer Wichtigkeit. Im Untersuchungsjahr 2018 wurden im Blaufränkisch-Weingarten bereits Ende Juni vereinzelt Blattverfärbungen wahrgenommen, weshalb bereits am 26.06.2018 die erste Untersuchung mittels Drohne erfolgte. Am 31.08.2018 wurden zum zweiten Mal Luftaufnahmen der Weingärten angefertigt, und die Symptome Blattverfärbung und Einrollen des Blattrandes waren bereits sehr deutlich zu erkennen, während

die Blätter gesunder Reben noch keine Herbstverfärbungen aufwiesen. Zu diesem Zeitpunkt wurde auch die Weingartenbegehung und visuelle Erhebung des Rebrkrankheitszustandes durchgeführt, die 2019 wiederholt wurde.

Ein sehr lang gestreckter (453 m), schmaler, etwas gekrümmt von Südwest nach Nordost verlaufender Zweigelt/St. Laurent-Weingarten nahe Gols (östlich des Neusiedlersees) war in vergangenen Jahren durch herdförmig verteilte Bereiche aufgefallen, in denen die Reben im Wuchs zurückblieben, kurzknötig waren und auch andere Symptome aufwiesen, die man gemeinhin mit Virose in Verbindung bringt. Die Untersuchung mittels ELISA lieferte den Nachweis des Reisingkrankheitsvirus (GFLV), eines wegen des Schädigungspotentials gefürchteten Nepovirus. Aus dem Weingartenboden konnten Individuen der Nematodenart *Xiphinema index* isoliert werden. Die Art kann GFLV von Rebe zu Rebe übertragen. Da sie sich nur langsam im Erdreich bewegen kann, verursacht sie in Weinkulturen herdförmige Schadstellen. Viele der befallenen Reben sterben ab.

Der Weingarten liegt nordöstlich einige Meter höher als südwestlich, ist zum Neusiedlersee hin stufenartig abfallend und hat einen lockeren, lößhaltigen Untergrund. Die Fahrgassen wurden 2018 von Bewuchs freigehalten, was das automatische Erkennen der Reben auf Photos stark vereinfacht. Luftaufnahmen mittels Drohne wurden am 19.05.2018 aufgenommen, also zu jenem Zeitpunkt, zu dem das verzögerte Wachstum am deutlichsten zu sehen war. Auch die Begehung und visuelle Bonitierung erfolgte zum Zeitpunkt der deutlichsten Symptomausprägung.

Ebenfalls sehr langgestreckt (238 m) und schmal (etwa 10 m) verläuft der Teil eines nördlich von Tadten gelegenen Zweigelt-Weingartens, dessen Reben ähnliche Symptome aufwiesen wie jene in Gols. Die Untersuchung mit ELISA erbrachte ebenfalls den Nachweis des Reisingkrankheitsvirus. Der Weingarten verläuft ohne erkennbare Neigung, den Untergrund bildet Tschernosem auf Schotter. Jede zweite Fahrgasse war begrünt, hauptsächlich mit Weißklee (*Trifolium repens*) und diversen Gräsern. Photos im sichtbaren Spektralbereich wurden mittels Drohne zu jener Zeit aufgenommen, in der die Wachstumsverzögerung am deutlichsten zu erkennen war, nämlich am 19.05.2018. Begehung und visuelle Bonitierung erfolgten ebenfalls zur Zeit der eindeutigsten Symptomausprägung.

DATENERHEBUNG

Der Drohnenflug über die Weingärten wurde von UAV-Piloten der Firma Skyability (Siegendorf, Österreich) durchgeführt. Verwendet wurde ein Multikopter DJI M600 (6 Rotoren, 3x2 Akkopakete, 16kf max. Abfluggewicht, Einsatzgewicht beim Auftrag etwa 13 kg). Die Photos wurden mit einer Sony A7R2 (42MP Vollformat-Kamera mit Zeiss-Objektiv) im sichtbaren Bereich des Spektrums (RGB) aufgenommen, die Auflösung pro Bild umfasste 7952 x 5304 Pixel.

Die Weingärten von St. Georgen wurden in einer Höhe von nur 15 m überflogen, die Aufnahmen erfolgten schräg, d. h. in seitlicher Kameraposition, zunächst spitzwinkelig, anfangs nicht über dem, sondern östlich des Weingartens. Danach wurde die Rebanlage dem Rebzeilenverlauf entlang überflogen und der Aufnahmewinkel entsprechend steiler. Beim fünften Überflug in Weingartenlängserstreckung zeigte die Kamera beinahe senkrecht nach unten. Die Prozedur wurde dann von Westen beginnend wiederholt, so dass bei der Blaufränkisch-Rebanlage zehn Überflüge auszuwerten waren, bei der Grüner Veltliner-Anlage hingegen nur sechs, da er etwas schmaler war. Die Überlappung der Einzelbilder war groß, von Bild zu Bild bewegte sich der aufgenommene Ausschnitt um etwa zwei Reben weiter. Der Weingarten bei Gols wurde zweimal überflogen, einmal mit seitlicher Kameraposition in 25 m Höhe, danach mit senkrecht nach unten aufnehmender Kamera aus einer Höhe von 50 m. Die Überlappung der Bilder ist hier je nach Aufnahmehöhe viel geringer, bei 50 m Höhe zeigt jedes dritte Bild einen nicht mehr überschneidenden Bereich.

In Tadten wurde eine geringere Flughöhe gewählt, 15 m und 25 m bei seitlicher Kameraposition und nur 7 m bei nach unten zeigender Kamera.

DATENANALYSE

Das Ziel der Untersuchung, BN betreffend, ist die Unterscheidung von gesunden und kranken Reben oder zumindest von kranken Rebpflanzen und allem anderen. Im Falle der Nepoviren ist es wichtig, Reben von allem anderen zu trennen. Es bedarf also eines Diskriminanzfaktors. Als Ausgangsdaten dienen hunderte Bilder mit jeweils 42.177.408 Pixel, wobei pro Pixel 256 Helligkeitswerte für die drei Grundfarben rot, grün und blau möglich sind.

Bei der Untersuchung der Bildhelligkeit ergibt sich, dass diese nicht über die gesamte Bildfläche gleichmäßig ist (nicht dargestellt). Der Bildrand ist weniger hell als die Bildmitte. Nimmt man an unterschiedlichen Tagen mit verschiedener Witterung oder zu unterschiedlichen Tageszeiten auf, ändert das ebenfalls die Bildhelligkeit. Auch genügt eine sich vor die Sonne schiebende Wolke, um die Helligkeit drastisch zu senken. Aus all dem folgt, dass die absolute Helligkeit vermutlich kein geeignetes Diskriminanzkriterium sein dürfte. Die relative Helligkeit der drei Farben zueinander ist ein zweckmäßigeres, weil von den Aufnahmebedingungen weniger abhängiges Maß, und es kann untersucht werden, wie sich die Pixel in dieser Hinsicht verteilen. Das kann auf verschiedene Weise geschehen, etwa indem man im Farbkubus Pfeile (Vektoren) von schwarz: RGB(0,0,0) zum Pixel:

RGB(x,y,z) zieht und den Winkel vergleicht, den die Vektoren zweier Pixel einnehmen. Einfacher ist eine Skalierung. Wir stellen fest, dass für die skalierten Farben stets gelten soll: $Rot' + Grün' + Blau' = \text{Maximalwert}$. Wenn der Farbkubus für jede Koordinate Werte zwischen null und eins erlaubt, folgt also:

$$1) \quad Rot' + Grün' + Blau' = 1.$$

Rot, Grün und Blau sind dabei die Helligkeitswerte der drei Grundfarben. Diese Bedingung lässt sich durch folgende Transformationen erfüllen:

$$2) \quad Rot' = Rot / (Rot + Grün + Blau),$$

$$3) \quad Grün' = Grün / (Rot + Grün + Blau),$$

$$4) \quad Blau' = Blau / (Rot + Grün + Blau),$$

wie man leicht überprüfen kann, indem man die transformierten (Gl. 2 bis 4) in Gl. 1 einsetzt.

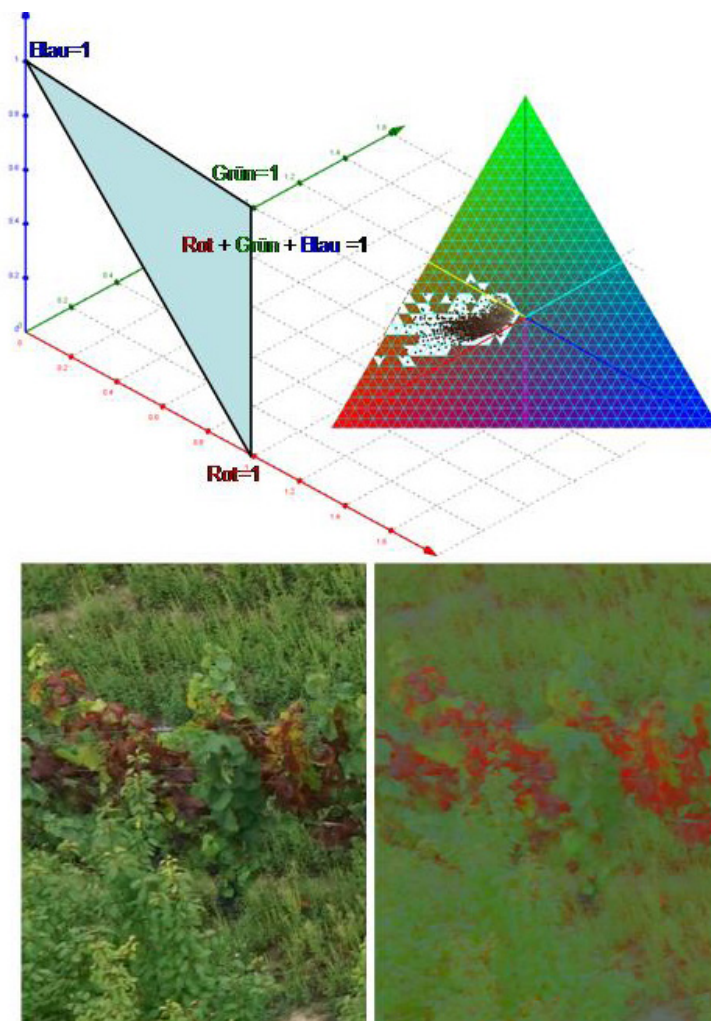


Abb. 1: Darstellung des Einheitssimplex, der die Bedingung Gl. 1 erfüllt, dass die Summe der drei Farbwerte konstant ist, wobei die Konstante für alle Pixel die gleiche ist. Die Farbwerte aller Pixel werden so transformiert, dass sie auf dem Simplex liegen, damit Helligkeitsunterschiede, wie sie durch verschiedene Belichtung zustandekommen, keine Rolle spielen. Wie die transformierte Welt aussieht, lässt sich in der Grafik unten rechts erkennen (verglichen mit dem Original unten links).

Alle Punkte, die diese Bedingung erfüllen, liegen auf dem Einheitssimplex (Abb. 1), einer Ebene, die insbesondere die Punkte $RGB(1,0,0)$, $RGB(0,1,0)$ und $RGB(0,0,1)$ inkludiert. Alle möglichen Werte bilden ein gleichseitiges Dreieck, das in der Folge die Operationsbasis darstellt. Abbildung 1 zeigt rechts oben, wie dieser Simplex eingefärbt aussieht und wie er als Analyseinstrument dienen kann: Die hier aufgetragenen Punkte sind die transformierten Pixel eines Blattes mit BN-Symptomen. Rechts unten zeigt Abbildung 1 zudem, wie eine Weingarten-Szene aussehen würde, gäbe es lediglich Farbkombinationen, die durch die Transformationen Gl. 2 bis 4 entstehen.

Wir haben uns hier dazu entschieden, dass es beim derzeitigen Stand der Kenntnis möglicherweise sinnvoller ist, ein einfaches, aber auch sehr flexibles Werkzeug zu erstellen, das mit einiger Kreativität an die jeweils im untersuchten Weingarten vorliegende Situation angepasst werden kann statt einer sorgfältigen statistischen Analyse und dem Vergleich vieler Diskriminatoren zur vollautomatischen Unterscheidung (ALBETIS et al., 2017 und 2018). Data Mining (Visual Data Exploration, VDE) ist eine Alternative zur klassischen Statistik, die in man-

chen Situationen überlegen ist. Warum wir der Meinung sind, dass das auch hier der Fall ist, wird aus späteren Erläuterungen folgen. Auf Basis von VDE ist es möglich, Erfahrung zu sammeln und das Geschehen vom Faktor Mensch noch nicht ganz zu entkoppeln. Die Software, die dieses Werkzeug darstellt, wurde mit der IDE Delphi 7 Aurora (Borland, Austin, TX, USA) bzw. Delphi CE (Embacadero, Austin, TX, USA) erstellt.

Bevor die Art und Weise beschrieben wird, mit der dieses Tool verwendet werden kann, soll noch eine sehr grobe Analyse durchgeführt werden, die für das Erstellen des Lernprotokolls aber wesentlich ist.

ERGEBNISSE UND DISKUSSION

VERTEILUNG DER FARBEN IM WEINGARTEN

Der Farbsimplex lässt sich grob in vier Bereiche einteilen, nämlich jene, wo eine der Grundfarben dominiert, und einen, wo das nicht der Fall ist. In Abbildung 2 sind jene Pixel eines Weingartens ('Blaufränkisch'; St. Georgen), die in den bezeichneten Bereich fallen, gelb hervorgehoben. Bei allen anderen Pixel sind die Farbwerte halbiert, sie erscheinen daher sehr dunkel.




Abb. 2: Verteilung der Pixel eines Weingartenbildes auf dem Farbsimplex. Mit Ausnahme der Grundfarbe Grün spielen die farbdominierten Bereiche kaum eine Rolle, während der graue Bereich, in dem keine Grundfarbe besonders dominiert, die bei weitem meisten Pixel enthält.

LERNPROTOKOLL

Man erkennt, dass kaum blau oder rot dominierte Pixel vorhanden sind, selbst jene, bei denen die Grundfarbe grün ist, überwiegen in einem dem menschlichen Auge durchaus grün erscheinenden Rebanlagenbild nicht. Unser optischer Sinn täuscht uns also. Fast alle Pixel sind grau, d. h. es überwiegt keine Farbe deutlich. Dass die Verteilung der Pixel über den Simplex nicht einheitlich ist, sondern sich fast alle Pixel in Zentrumsnähe sammeln, muss beim Lernprotokoll berücksichtigt werden.

Gemäß den Grundprinzipien der VDE wurde die Software so gestaltet, dass jeder Schritt durch unmittelbare Ansicht überwachbar ist und der Nutzer eine Eingriffsmöglichkeit hat. Es ist der Mensch, der in die Lage gesetzt werden soll, zu lernen, nicht die Maschine, die einem Lernalgorithmus folgt. Das Lernziel ist, Pixel zu erkennen, die z. B. symptomatische Rebteile abbilden bzw. Teil dieser Abbildung sind, und sie von allen anderen zu unterscheiden. Allgemeiner gesprochen, wird die Erkennung eines „Targets“ angestrebt.

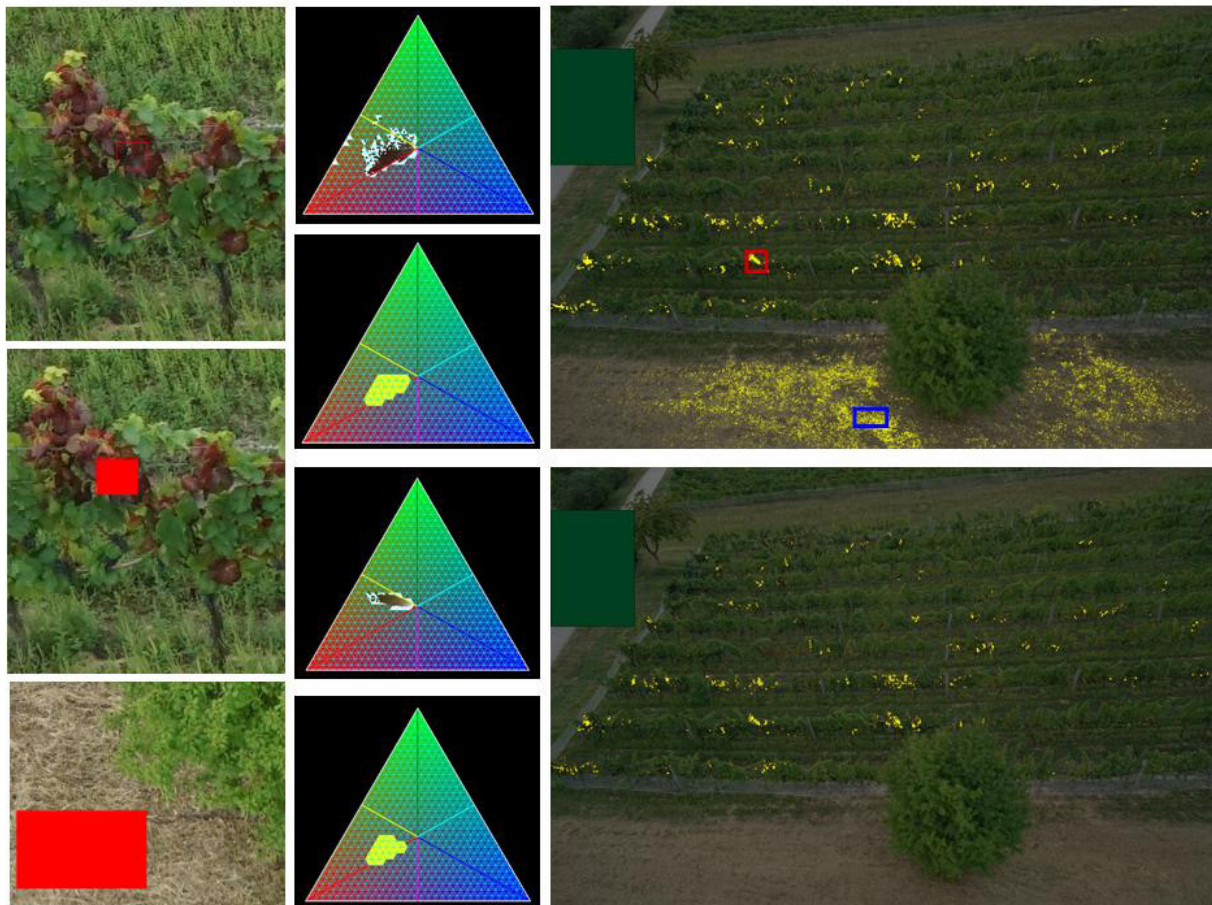


Abb. 3: Grundlegende Vorgehensweise beim Erlernen des Diskriminanzbereichs, der die Zuordnung der Pixel regelt; links: Quellansicht zur Symptomatikerkennung; Mitte: interaktiver Farbsimplex zur Erkennung und Auswahl der symptomtypischen Pixelfarbkombination; rechts: Targetansicht, in der die selektierten Pixel hervorgehoben und gezählt werden; Das Tool wird verwendet, um den Fehler erster und zweiter Art zu minimieren.

Dies ist in der Regel nicht fehlerfrei möglich, wobei zwei Fehlerarten zu berücksichtigen sind:

- 1) Ein das Target abbildendes Pixel wird nicht erkannt (Fehler erster Art).
- 2) Ein nicht das Target abbildendes Pixel wird falsch klassifiziert, also als das Target repräsentierend befunden (Fehler zweiter Art).

Die beiden Fehler sind in der Regel nicht unabhängig, minimiert man die eine Art, erhöht man die andere.

Die Software stellt drei Ansichten zur Verfügung, zwei davon sind interaktiv (Abb. 3). Die erste ist die „Quelle“ ("Source"). Hier wird das zu klassifizierende Objekt abgebildet, in Abbildung 3 (linke Spalte, oben und Mitte) ist das eine Rebe mit sehr deutlicher BN-Symptomatik. Indem man eine symptomausprägende Stelle markiert (rotes Rechteck), werden die Pixel skaliert, auf den Farbsimplex (mittlere Spalte in Abb. 3, oben) übertragen und als kleine Kreise an der richtigen Position abgebildet. Im vorliegenden Beispiel liegen die meisten Pixel entlang der roten Linie, die rotgrün von rotblau trennt, überwiegend auf der rotgrünen Seite. Der Simplex kann in unterschiedlicher Auflösung dargestellt werden, Abbildung 2 zeigt eine sehr grobe Rasterung, Abbildung 1 und Abbildung 3 eine feine. Auch die Simplexoberfläche ist interaktiv, man kann damit eine Fläche auszeichnen (gelber Fleck auf dem Simplex in Abbildung 3, mittlere Spalte, zweitoberste Abbildung), die als Diskriminator fungiert.

Die Targetansicht (rechte Spalte in Abb. 3) zeigt an einem Bild des zu untersuchenden Weingartens den Erfolg der Auswahl (obere Grafik). Man kann in die Abbildung zoomen und so den Fehler erster Art abschätzen. Nicht alle Blätter mit BN-Symptomatik werden erkannt, aber im Beispiel die meisten. Der Fehler erster Art ist also niedrig. Problematisch ist allerdings, dass im Vordergrund der Abbildung nackter Boden und Heu falsch klassifiziert und daher ebenfalls hervorgehoben werden (Der rote Farbanteil ist in Erde recht hoch.). Der Fehler zweiter Art ist also gravierend (Der rot markierte Bereich in der Targetansicht entspricht übrigens der in der Quellansicht dargestellten Rebe.).

Der Fehler zweiter Art lässt sich nun vermindern, indem man den falsch zugeordneten Bereich (blaue Umrandung in der Targetansicht bzw. rote Umrandung in der Source-Ansicht, unten) markiert und einer Analyse übergibt. Die Pixel erscheinen auf dem Simplex (dritte

Grafik in der mittleren Spalte), und man erkennt, dass die Boden und Heu repräsentierenden Pixel entlang der gelben Linie, die rot von grün trennt, erscheinen, überwiegend auf der roten Seite. Es ist also erforderlich, diesen Bereich aus der Markierung am Simplex auszusparen (unterste Grafik der mittleren Spalte von Abbildung 3). Wegen des in Abbildung 2 dargestellten Zusammenhangs ist es außerdem sinnvoll, den Zentralbereich des Simplex (den Dreiecksschwerpunkt) nicht zu markieren. Der gelbe Fleck auf dem Simplex ist nunmehr Basis einer neuen Zuordnung, die in der Targetansicht (rechte Spalte, unten) validiert werden kann. Ein Fehler zweiter Art tritt praktisch nicht mehr auf, dafür ist der Fehler erster Art größer geworden. Dennoch werden alle Reben mit BN-Symptomatik wenigstens an einigen Blättern oder Blattbereichen erkannt, was bedeutet, dass auf Rebebene die Zuordnung nun sehr gut ist. Man kann zudem das Resultat eventuell verbessern, indem man das Protokoll noch einige Male wiederholt. Ursprünglich hat die Vergrößerung der auf dem Simplex ausgewählten Fläche die Rechenzeit erhöht, was nach einer Verbesserung der Software nun nicht mehr der Fall ist. In dieser VDE-basierten Optimierung ist eine Validierung über die Targetansicht sehr rasch möglich. Man erkennt vor allem Fehler zweiter Art sehr schnell. Das Fehlerausmaß nicht nur abzuschätzen, sondern zu quantifizieren, ist allerdings bei einer auf der klassischen Statistik basierenden Optimierung leichter. Beispielsweise haben ALBETIS et al. (2018) mit Aufnahmen aus 150 m Höhe eine Auflösung von 8 cm x 8 cm pro Pixel erreicht und nach 25 verschiedenen Diskriminatorfunktionen, die als Variablen jeweils einige der fünf gemessenen Farbbereiche enthielten, die Pixel klassifiziert. Da von allen Reben das Erkrankungsniveau (vier Kategorien der Erkrankungsintensität) und von den erkrankten auch die GPS-Koordinaten erhoben worden waren, war die Güte der Diskriminatorfunktion und des ausgewählten Schwellenwertes validierbar und quantifizierbar. Dadurch, dass die GPS-Positionierung nicht exakt ist, die Zuordnung zu den Kategorien der Erkrankung einer gewissen Subjektivität unterliegt und die Symptomatik in der Intensität „fleckig“ ist, also an der Rebe lokal sehr unterschiedlich sein kann, ist die Quantifizierung allerdings mit einiger Unsicherheit behaftet und die Validierung damit vermutlich nicht so exakt, wie es den Anschein hat. Zudem ist die GPS-Positionierung nur

bei völlig ebener Lage der Weingärten in hoher Qualität durchführbar, wie auch die Darstellung einer Rebanlage in nur einem Bild. Das sind Voraussetzungen, die vielfach nicht gegeben sind, im konkreten Fall nur bei einem der vier Weingärten. Diese Vorgehensweise wäre für uns also nicht optimal gewesen.

Das hier vorgeschlagene Lernverfahren ließe sich vielleicht auch auf mehr Farbbereiche ausdehnen, indem man, falls möglich, z. B. durch eine Hauptkomponentenanalyse die Anzahl der Dimensionen auf drei reduziert. Damit ließen sich immer noch Bildbereiche auf dem Simplex darstellen, auch wenn die Anschaulichkeit der Farbzuoordnung verloren ginge. Das Lernprotokoll ließe sich auch in einen Lernalgorithmus überführen, indem man jenes Subdreieck auf der Simplexfläche bestimmt, das die meisten Targetpixel beinhaltet und dann von dort die Diskriminatorfläche am Simplex aufbaut. Das wäre vermutlich sinnvoller, als mehr oder weniger willkürlich eine Reihe von 25 Diskriminatorfunktionen, von denen vielleicht keine optimal ist, aus einer schier unendlichen Zahl von möglichen zu untersuchen (ALBETIS et al., 2017 und 2018).

STANDORT ST. GEORGEN – BLAUFRÄNKISCH- UND GRÜNER VELTLINER-WEINGARTEN MIT BN-SYMPTOMEN

Am Standort St. Georgen wurden an zwei Terminen (Ende Juni und Ende August) zwei Weingärten mit verschiedenen Sorten (die blaubeerige Sorte 'Blaufränkisch' und die grünbeerige Sorte 'Grüner Veltliner') analysiert. Zunächst wurden geeignete Analyseschlüssel entwickelt (Abb. 4). Ziel war es, erkrankte Reben zu erkennen bzw. die durch die Erkrankung verursachten Blattverfärbungen. Dabei schien es weniger wichtig, den Gesamtfehler zu minimieren, als vielmehr zu erreichen, dass der Fehler zweiter Art, die falschpositive Diagnostizierung, möglichst nicht auftritt. Da eine erkrankte Rebe durch sehr viele Pixel erfasst wird, wird sie auch dann sicher erkannt, wenn ein Teil der Pixel falschnegativ diagnostiziert wird. ALBETIS et al. (2017 und 2018) sind hier anders vorgegangen, weil in ihrer Untersuchung Reben nur durch wenige Pixel dargestellt sind. Sie haben daher mittels ROC (Receiver operating characteristic) Analysis die Unterscheidungsschwelle festgelegt und den Gesamtfehler minimiert.




Abb. 4: Fehlererkennung und Analyseschlüssel für eine Rotwein- (oben) und eine Weißwein-Rebanlage (unten) zum Untersuchungstermin Ende August

In unserer VDE-orientierten Arbeit kann der Fehler nur abgeschätzt werden. Abbildung 4 zeigt, dass bei Rotweinsorten mit dem dargestellten Analyseschlüssel Ende August ungefähr die Hälfte der symptomtragenden Blattfläche erkannt wird. Das ist mehr als genug, um erkrankte Reben zu erkennen und um die Verbreitung von BN im Weingarten zu untersuchen. Wichtig ist insbesondere, dass es praktisch nicht zur fälschlichen Erkennung gesunden Rebmaterials kommt, und auch beim Hintergrund (Boden und Fahrgassenbegrünung) tritt kaum Falscherkennung auf. Rote Gläser bei Autoleuchten und auch menschliche Haut müssen allerdings vorab durch Bildbearbeitung entfernt werden. Die Erfüllung der Forderungen $\text{Rot} > 1,3 * \text{Grün}$ und $\text{Rot} > \text{Blau}$ genügen, damit Fehler der zweiten Art nur mehr in vernachlässigbarer Häufigkeit auftreten. Eine weitere Frage ist, ob andere Reberkrankungen mit ähnlicher Symptomatik von BN unterschieden werden können. Wir haben 2019 die Weingartenbegehung wiederholt, weil in manchen Jahren die Symptomatik der einzelnen Erkrankungen deutlicher zu erkennen ist als in anderen (Anhang 1). 2019 wies sie bei einigen Reben auf eine Doppelinfektion mit BN und Blattroll-Viren (GLRaV) hin bzw. auch auf ausschließlichen Virenbefall. Solange die Blattverfärbungen ähnlich sind, kann eine Trennung nicht vorgenommen werden. 2019 waren zudem die Folgen einer Schädigung der Reben durch Büffelzika-den (*Stictoccephala bisonia*) sehr häufig, die ganz ähnliche Blattverfärbungen verursachen wie BN und durch Farbspektrumanalyse der Einzelpixel sicherlich ebenfalls nicht von den BN-Blattsymptomen unterschieden werden können.

Bei der Weißweinsorte 'Grüner Veltliner' ist die Trennung zwischen gesunder und symptombehafteter Blattfläche wesentlich schwieriger. Nur ein Bereich $\text{Rot} \approx \text{Grün}$ bei geringem Blauanteil eignet sich dafür (Abb. 4, untere Reihe). Es wird weniger als ein Viertel der symptomtragenden Blattfläche erkannt – was völlig genügt, um kranke Reben zu identifizieren –, und auch der Anteil fälschlich positiv diagnostizierter Pixel ist höher, wobei es nicht die Reben sind, sondern der Hintergrund (Fahrgassenbegrünung), der etwas problematisch ist. Das Ergebnis ist dennoch vielversprechend. Einige der Reben zeigen Symptome einer anderen Erkrankung mit Blattverfärbung, nämlich Grapevine Trunk Diseases (GTD). Sie werden ebenso wie BN positiv diagnostiziert.

Für die Untersuchung des Blaufränkisch-Weingartens in St. Georgen wurden die Länge des Weingartens (100 m) fünfmal in der bereits besprochenen Weise abgeflogen und dabei jedes Mal zwischen 25 und 34 Bilder aufgenommen (es wurde also alle drei bis vier Meter fotografiert). Der Analyseschlüssel ist in Abbildung 4 gezeigt. Er umfasst den Rotbereich mit Ausnahme der gelbnahen Subdreiecke. Phytoplasmensymptome lassen sich bei der Rotweinsorte sehr gut erkennen und bonitieren (Abb. 5). In Straßennähe (links in der Abbildung), besonders östlich, finden sich sehr viele Reben mit BN-Symptomen, gehäuft aber auch etwas nördlich der Weingartenmitte, zumindest in den östlichen Reihen.

Zur Auswertung des Weingartens mittels Drohne wurden in jeder Aufnahme jene Pixel gezählt, die nach Analyseschlüssel die für erkrankte Reben typische Färbung aufwiesen ("Target-Pixel"). Nachdem die einzelnen Aufnahmen unterschiedliche Bereiche abbilden, ändert sich natürlich auch die Anzahl der gezählten Pixel (Abb. 5, unten). Zunächst wurden die Reihen beginnend vom Nordosten des Weingartens fotografiert; ein typisches Bild ist in den Abbildungen 2 und 3 zu sehen. Man beachte bei dieser Perspektive, dass eine Rebe aus doppelter Entfernung nur mehr durch ein Viertel der Pixel abgebildet wird. Der Vordergrund spielt also eine entsprechend größere Rolle. Beim Überfliegen des Weingartens aus der Distanz entsteht zunächst der Eindruck, dass von der Straße innerhalb des Weingartens hangaufwärts das Erkrankungsausmaß abnimmt (rote Linie in der Abb. 5, unten links). Kommt die Drohne dem Weingarten näher (gelbe Linie), wird eine zweigipfelige Verteilung sichtbar: Nicht nur in Straßennähe, sondern auch ab der Hälfte des Weingartens ist die Anzahl der erkannten Pixel hoch. Später, wenn die nordöstlichsten Reihen überflogen sind, ist der zweite Peak nicht mehr so ausgeprägt.

Beim Überfliegen der Reihen beginnend von Südwest entsteht ein ähnlicher Eindruck. Aus einiger Distanz zum Weingarten betrachtet, nimmt die Anzahl der Pixel hangaufwärts einigermaßen kontinuierlich ab (rote Linie). Aus der Nähe wird der Peak ab der Weingartenmitte wieder sehr auffällig und verschwindet erst, nachdem der größte Teil der Rebanlage überflogen worden ist (blaue Linie) und später als beim Überfliegen von Nordost.

Bei der Untersuchung einiger orthogonaler Photos des

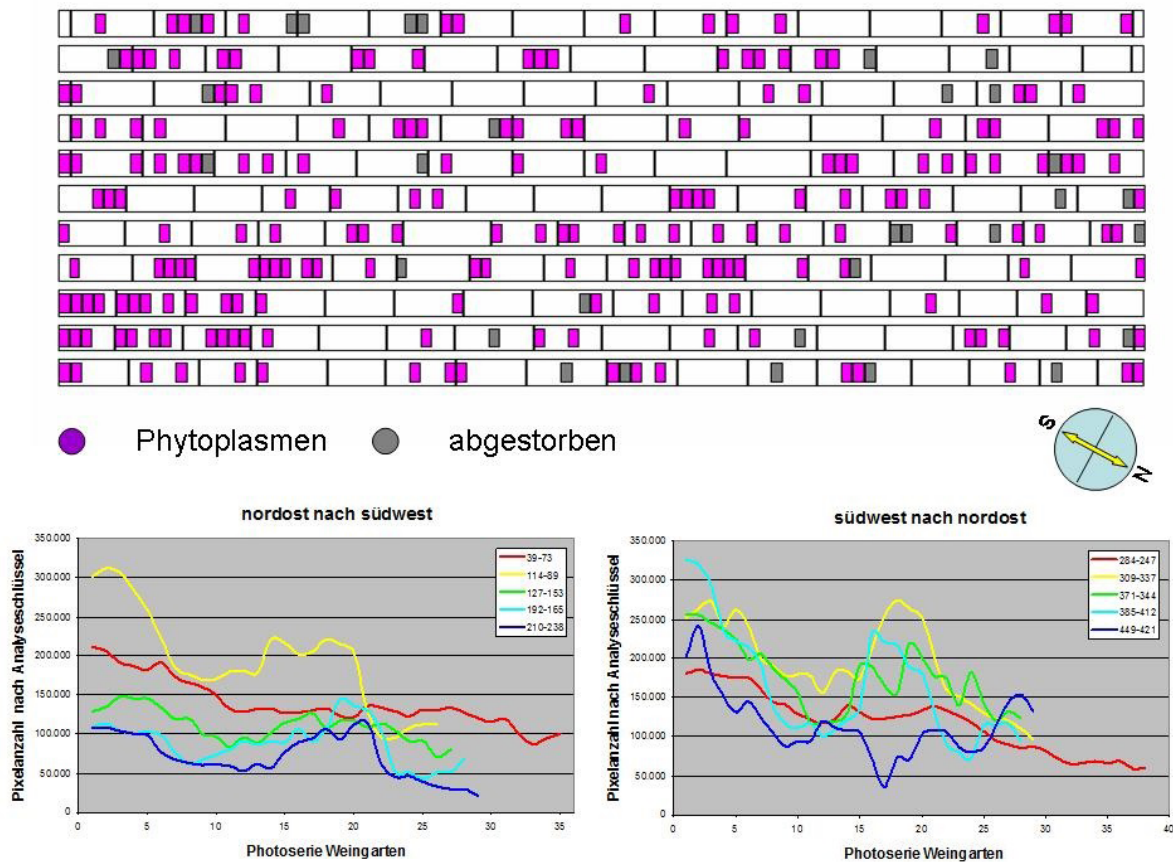


Abb. 5: Blaufränkisch-Weingarten in St. Georgen; oben: Ergebnis der Weingarten-Begehung und Symptomerkennung 2018; unten: Pixelanzahl pro Bild, die nach Analyseschlüssel erkannt wurden, bei Überflügen in Längsrichtung des Weingartens

Weingartens fiel auf, dass auch einzelne Flecken in den Fahrgassen erkannt wurden. Es handelte sich dabei um abgefallene, symptomtragende Reblätter. Im Falle von Windverwehungen könnten diese zu einer Ergebnisverfälschung führen. Auch die beobachtete, generell unterschiedliche Wüchsigkeit der Reben je nach Nähe zum Niederwald, muss bei der Quantifizierung berücksichtigt werden.

Die am 26.06.2018 mittels UAV aufgenommenen Bilder wurden mit dem gleichen Analyseschlüssel untersucht. Obwohl die bereits verfärbten Blätter gut erkannt wurden, wies der Hintergrund zu diesem Zeitpunkt einen

höheren Rotanteil auf, was einer guten Trennung entgegenwirkte.

Die Untersuchung des Grüner Veltliner-Weingartens zeigte ebenfalls eine inhomogene Verteilung der Reberkrankungen (nicht dargestellt), wobei zwei Peaks zu erkennen sind, beide nicht am Rand (also in Straßennähe bzw. beim Forst; Anhang 2).

Zusammenfassend lässt sich sagen, dass die seitliche Sicht auf die Reben zwar gut geeignet ist, um erkrankte Reben zu erkennen und zu verorten, dass für quantitative Untersuchungen aber der Blick von senkrecht oben bevorzugt werden sollte.

**STANDORT GOLS –
ZWEIGELT/ST. LAURENT-WEINGARTEN MIT
NEPOVIRUS-SYMPTOMEN**

Der Weingarten am Standort Gols wies 2018, wie auch schon in den Jahren davor, herdförmige Flecken mit Ende Mai deutlich sichtbarer Wuchsdeprivation auf. Vorangehende Untersuchungen hatten zum Nachweis

von GFLV und des Überträgers, *Xiphinema index*, geführt. Wir interessierten uns für die Quantifizierung der Wachstumshemmung mithilfe von senkrecht nach unten aus 50 m Höhe aufgenommenen Bildern. Alle sieben bis zehn Meter wurde eine Aufnahme gemacht, was bis zu 62 Bilder pro Weingartenlänge entspricht.

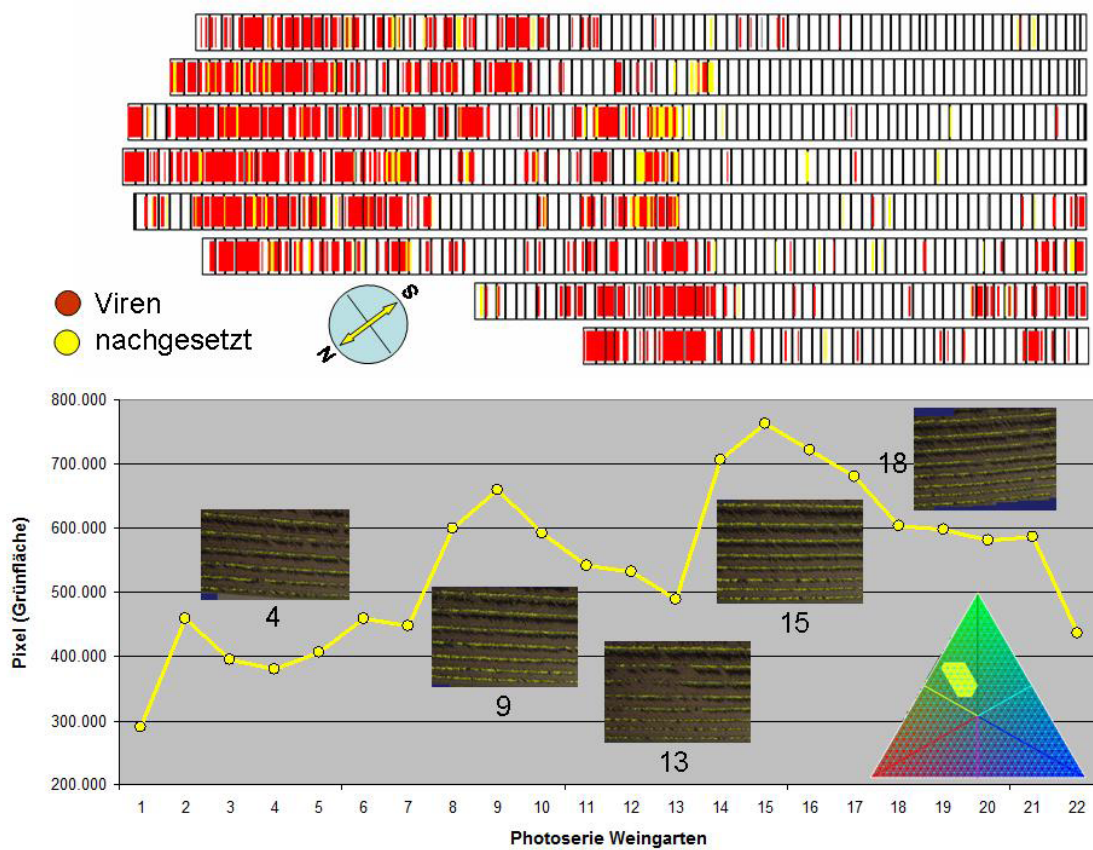


Abb. 6: Zweigelt/St. Laurent-Weingarten in Gols; oben: Ergebnis der Weingarten-Begehung und Symptomerfassung 2018; unten: Pixelanzahl pro Bild, die nach Analyseschlüssel (Insert rechts unten) erkannt wurden, bei Überflügen in Längsrichtung des Weingartens

Um den Weingartenrand möglichst einfach ausblenden zu können, wurden redundante Bilder nicht berücksichtigt, d. h., der Überlappungsgrad wurde vermindert und nur jedes dritte Bild berücksichtigt. Nachdem die Weingartenumgebung eliminiert worden war, gestaltete sich die Suche nach einem Analyseschlüssel sehr einfach, da der lockere Boden in den Fahrgassen und zwischen den Rebstöcken offen gehalten worden war. Damit entscheidet die Farbe der Rebblätter, die sich am 19.05.2018 zwischen grün und gelb bewegte (Abb. 6, Insert rechts unten).

Die Begehung des Weingartens zeigte (Abb. 6, oben), dass sich vor allem im etwas erhöht liegenden Nordosten der Rebanlage sehr viele Reben mit Wachstumsdefiziten befanden. In Weingartenmitte war im Nordwesten ein kleinerer Herd mit wuchsschwachen Reben zu sehen und ein weiterer, kleiner Fleck im Süden der Anlage am niedrigsten Punkt.

Im Wesentlichen folgt auch die Analyse der Weingartenaufnahmen mittels UAV dieser Beschreibung. Vergleichsweise niedrige Werte (Anzahl der Target-Pixel) finden sich im ersten und letzten Bild, was natürlich daran liegt, dass sie nicht nur den Weingarten zeigen. Links in Abbildung 6, unten (der Nordosten des Weingartens), bleibt die Pixelanzahl dort niedrig, wo die Virussymptome besonders ausgeprägt sind. Es spielt auch eine Rolle, dass zunächst nur sechs Reihen, später acht, vorhanden sind. Etwa beim neunten Bild in Weingartenlängsrichtung erreicht die Anzahl selektierter Pixel pro Bild ein lokales Maximum, nimmt dann aber wieder ab, obwohl die Reihenzahl zunimmt. Das ist eine Konsequenz der Tatsache, dass wieder ein Herdgebiet erreicht wird. Erst hinter dem Erkrankungsherd steigt die Pixelanzahl rapide, um schließlich wieder abzusinken, was aber hier nur zum Teil der Virose zugeschrieben werden kann; die Wüchsigkeit ist in der Tieflage etwas geringer.

STANDORT TADTEN – ZWEIFELT-WEINGARTEN MIT NEPOVIRUS-SYMPTOMEN

Der Zweifelt-Weingarten in Tadten ist der einzige Ver- suchsstandort, der völlig eben gelegen ist. Die am besten zur Analyse geeigneten Photos wurden aus 25 m Höhe aufgenommen, eines etwa alle 5 m und damit etwa 50

in einer Reihe. Die Sorte 'Zweifelt' gehört zu den blau- beerigen Rebsorten. Die Fahrgasse jeder zweiten Reihe wurde vom Bewuchs freigehalten; wo Begrünung vorhanden war, dominierte *Trifolium repens*. Auch hier wurde herdförmige Wuchsdeprivation beobachtet und als deren Verursacher GFLV festgestellt. Entsprechend wollten wir die gleiche Fragestellung untersuchen wie in Gols: Lässt sich die Wachstumshemmung durch die Erkrankung entlang des Weingartens mittels Drohnen- photos beobachten und quantifizieren?

Die Begehung im Mai über sechs Rebzeilen (Abb. 7, oben) zeigte einen großen Erkrankungsfleck, auf dem allerdings die meisten symptombehafteten Reben bereits eliminiert worden und neue nachgepflanzt waren. Zumindest vorübergehend zeigten die neuen noch keine Symptome einer Nepovirose.

Die Vorgehensweise sollte jener in Gols entsprechen, nur dass diesmal jede zweite Fahrgasse begrünt war und damit das Problem bestand, Rebblattgrün von anderem Grün zu unterscheiden.

Letztlich muss man zugeben, dass das nicht gelungen ist. Die Auswertung mittels Drohne (Abb. 7) zeigt lediglich, dass die Gründecke, seien es Reben oder Fahrgassenbe- grünung, nach Nordwesten dichter wird.

Weil es offensichtlich nicht möglich war, die Fahrgas- senbegrünung zu eliminieren, wurde erstmals auch versucht, die absolute Helligkeit der Grün- bzw. Rot- komponente zu berücksichtigen. Anhang 3 zeigt, dass dadurch scheinbar der durch die Fahrgassenbegrü- nung verursachte Fehler zweiter Art vermindert wird. Das ist aber eine Täuschung. In Abbildung 7, unten, ist die Anzahl der Target-Pixel in der Photoserie, die das Überfliegen des Weingartens in Längsrichtung do- kumentiert, dargestellt, wobei zusätzlich zur Auswahl durch den Simplex (Insert, Abb. 7) noch die Forderung hinzugekommen ist, dass die Helligkeit der Grundfarbe Grün einen bestimmten Wert im Bereich 0 bis 255 über- schreiten solle. Die Kurven sind sehr ähnlich, womit die Annahme, die falschpositive Zuordnung von Fahrgas- senbegrünungspixel werde vermindert, nicht korrekt ist. Außerdem kann man sich nicht sicher sein, ob man auf diese Weise nicht vielleicht eher das Ausmaß der Bewöl- kung zum Aufnahmezeitpunkt dokumentiert als Eigen- heiten der Weingartenbegrünung.

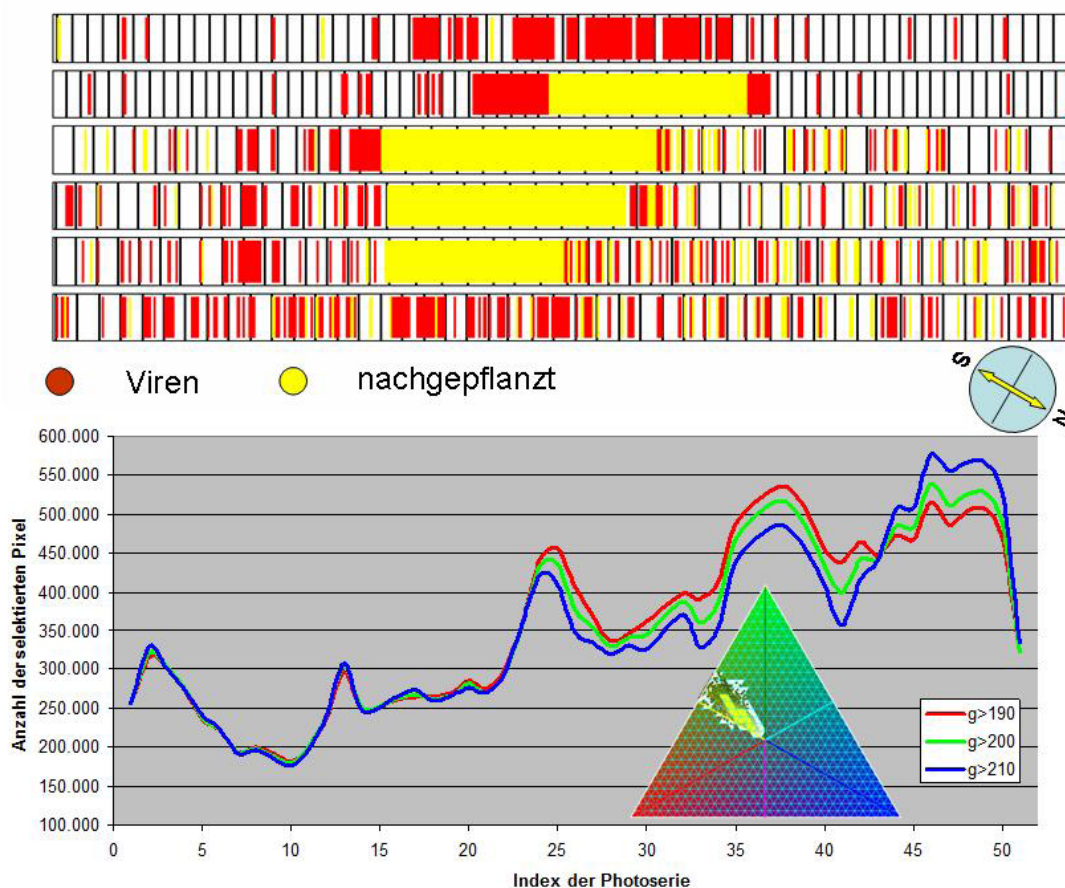


Abb. 7: Zweigelt-Weingarten in Tadtien; oben: Ergebnis der Weingarten-Begehung und Symptomerfassung 2018; unten: Pixelanzahl pro Bild, die nach Analyseschlüssel (Insert rechts unten) und einer Zusatzbedingung (die die absolute Farbintensität der Grundfarbe Grün betrifft, die sich zwischen 0 und 255 bewegen kann) erkannt wurden, bei Überflügen in Längsrichtung des Weingartens


Wir haben auf Data Mining Basis untersucht, ob es möglich ist, aus einer Serie von Photos, die mit über dem Weingarten fliegenden Drohnen im Spektralbereich des sichtbaren Lichts aufgenommen wurden, wichtige Informationen über das Ausmaß der Reberkrankung zu erhalten. Blattverfärbungen können leicht erkannt und quantifiziert werden, besonders bei Rotwein-Rebsorten. In Jungrebananlagen, bei denen die Gesunderhaltung besonders wichtig ist, könnte daher das Auffinden erkrankter Reben mittels UAVs Bedeutung erlangen. Es

ist allerdings durch Einzelpixelanalyse nicht möglich, verschiedene Erkrankungen, die ähnliche Symptome verursachen, korrekt zu diagnostizieren. Lokal unterschiedliche Wüchsigkeit innerhalb der Rebanlage kann ebenfalls festgestellt werden, sofern sich die Reben vom Hintergrund trennen lassen, was bei begrünten Fahrgassen nicht ausreichend der Fall ist. Generell ist es unserer Auffassung nach wegen der Vielfalt des Hintergrundes (also z. B. der Gestaltung der Fahrgassen) nicht möglich, auf die Anschauung und das Eingreifen des Men-

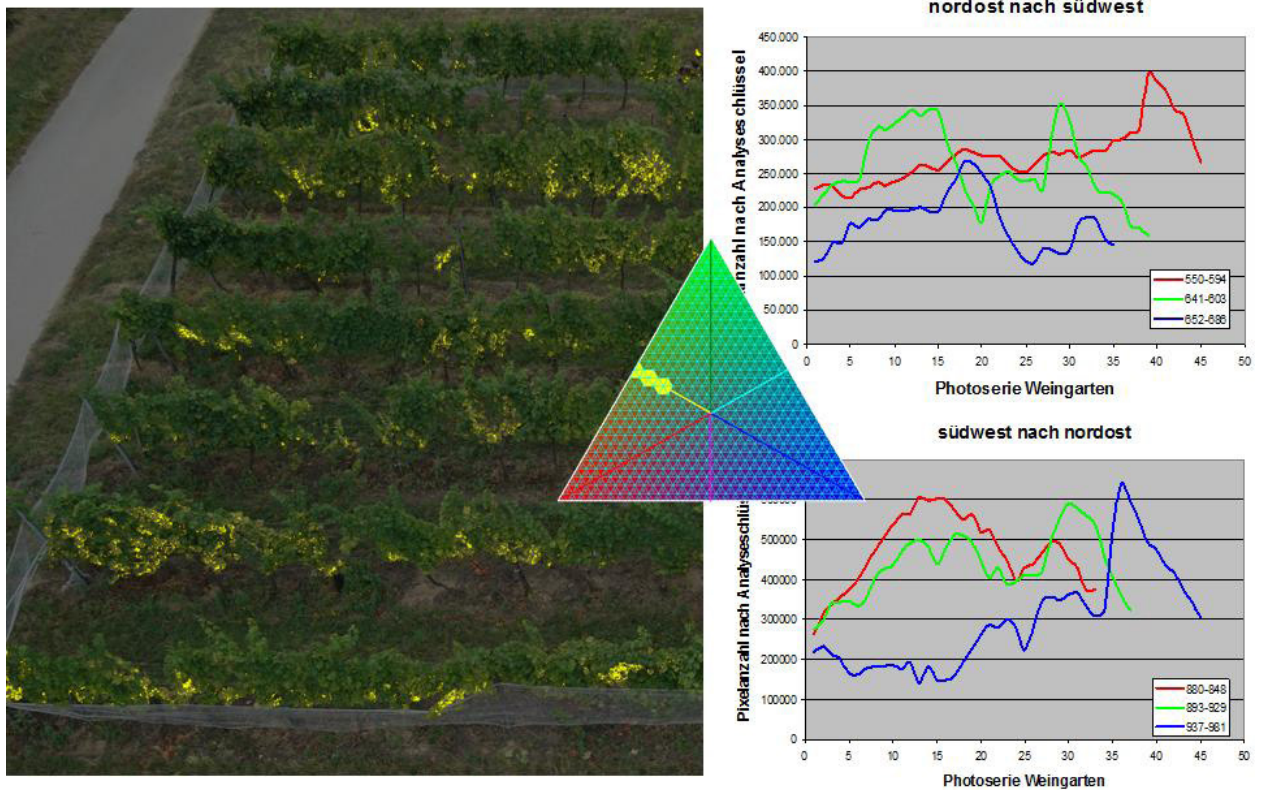
schen zu verzichten. Möglich wäre dies nur, wenn eine Software mit hoher Präzision Reblaub erkennen kann. Dazu reicht aber eine Einzelpixelanalyse nicht aus; es ist vielmehr Gestalterfassung erforderlich. Um z. B. ein Neuronales Netz in dieser Hinsicht zu schulen, müsste allerdings der Umfang des Beispielssets enorm groß sein, weil Reben in unterschiedlichem Abstand und aus verschiedenen Positionen dargeboten werden müssten.

Die Entwicklung einer derartigen Künstlichen Intelligenz sprengt wahrscheinlich die Möglichkeiten der meisten Weinbauinstitute.


ALBETIS et al. (2018) berichten über ähnliche Probleme und kommen ebenfalls zu dem Schluss, dass ein „improving [of] vine vegetation masking“ erforderlich ist. Möglicherweise bietet hier der Ansatz von KERKECH et al. (2018) die beste Aussicht auf Erfolg.



Anhang 1: St. Georgen, Blaufränkisch-Weingartenbegehung 29.08.2019



Anhang 2: St. Georgen, Grüner Veltliner-Weingarten; Beispielbild, Analyseschlüssel und Auswertungsergebnis



Anhang 3: Tadtten, Zweigelt-Weingarten; Analyseschlüssel und als zusätzliche Bedingung ein Schwellenwert für die Helligkeit der Grundfarben grün oder rot (0 bis 255); links oben: ohne Zusatzbedingung; rechts oben: Grün>190; links unten: rot>190

LITERATUR

- ALBETIS, J., DUTHOIT, S., GUTTLER, F., JACQUIN, A., GOULARD, M., POILVÉ, H., FÉRET, J.B. AND DEDIEU, G. 2017: Detection of Flavescence Dorée Grapevine Disease Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery. *Remote Sens.* 9: 308.
- ALBETIS, J., JACQUIN, A., GOULARD, M., POILVÉ, H., ROUSSEAU, J., CLENET, H., DEDIEU, G. AND DUTHOIT, S. 2018: On the Potentiality of UAV Multispectral Imagery to Detect Flavescence Dorée and Grapevine Trunk Diseases. *Remote Sens.* 11: 23.
- AL-SADDIK, H., SIMON, J.C., BROUSSE, O. AND COINTAULT, F. 2016: DAMAV Project for Vineyard Disease Detection by UAV Imagery. In: *Proceedings of the International Conference on Agricultural Engineering, Automation, Environment and Food Safety.* Aarhus, Denmark, 26–29 June; pp. 1–7
- BARBEDO, J.G.A. 2019: A Review on the Use of Unmanned Aerial Vehicles and Imaging Sensors for Monitoring and Assessing Plant Stresses. *Drones*, 3(2), 40, <https://doi.org/10.3390/drones3020040>
- BELOEV, I.H. 2016: A Review on Current and Emerging Application Possibilities for Unmanned Aerial Vehicles. *Acta Technol. Agric.* 19: 70–76.
- BERGMANN, T. 2014: Herbolzheimer Bauer bekämpft Schädlinge per Drohne. <https://www.badische-zeitung.de/herbolzheim/herbolzheimer-bauer-be-kaempft-schaedlinge-per-drohne--87037193.html> (11.02.2020)
- CHEN, Y., ZHAO, H., MAO, J. et al. 2019: Controlled flight of a microrobot powered by soft artificial muscles. *Nature* 575: 324–329. <https://doi.org/10.1038/s41586-019-1737-7> (11.02.2020)
- ERICKSON, H. 2018: The future of agriculture: using drones to fight crop diseases. <https://news.siu.edu/2018/08/090118-using-drones-to-fight-crop-disease.php>, (11.02.2020)
- FORNACE, K.M., CHRIS J., DRAKELEY, C.J., WILLIAM, T., ESPINO, F. AND COX, J. 2014: Mapping infectious disease landscapes: unmanned aerial vehicles and epidemiology. *Trends in Parasitology* 1–6
- GENNARO, S.D., BATTISTON, E., MARCO, S.D., FACINI, O., MATESE, A., NOCENTINI, M., PALLIOTTI, A. AND MUGNAI, L. 2016: Unmanned Aerial Vehicle (UAV)—Based Remote Sensing to Monitor Grapevine Leaf Stripe Disease within a Vineyard Affected By Esca Complex. *Phytopathol. Mediterr.* 55: 262–275.
- HESSDÖRFER, D. 2020: Trockenstressbestimmung mittels Drohneneinsatz. https://www.lwg.bayern.de/weinbau/rebe_weinberg/192006/index.php, (11.02.2020)
- KERKECH, M., HAFIANE, A. AND CANALS, R. 2018: Deep Learning Approach with Colorimetric Spaces and Vegetation Indices for Vine Diseases Detection In UAV Images. *Comput. Electron. Agric.* 155: 237–243.
- KNOPF, P. 2016: Winzerfalke gegen Stare. <https://www.skyability.com/winzerfalke-gegen-stare/> (11.02.2020)
- MA, K. Y., CHIRARATTANANON, P., FULLER, S. B. AND WOOD, R. J. 2013: Controlled flight of a biologically inspired, insect-scale robot. *Science* 340: 603–607.
- ORF 2017: Jäger retten mit Drohnen Rehkitze vor Mähdreschern. <https://orf.at/v2/stories/2393188>, (11.02.2020)
- SIDDIQI, S. 2016: Sri Lanka's drone pioneers. *ICT Update* 82: 4.
- TSOUROS D.C., BIBI, S. AND SARIGIANNIDIS, P.G. 2019: A Review on UAV-Based Applications for Precision Agriculture. *Information* 10: 349. doi:10.3390/info10110349
- YAMAMOTO, K., TOGAMI, T. AND YAMAGUCHI, N. 2017: Super-Resolution of Plant Disease Images for the Acceleration of Image-based Phenotyping and Vigor Diagnosis in Agriculture. *Sensors* 17: 2557. doi:10.3390/s17112557
- ZHANG, C. AND KOVACS, J.M. 2012: The Application of Small Unmanned Aerial Systems for Precision Agriculture: A Review. *Precis. Agric.* 13: 693–712.

Eingelangt am 15. Februar 2020