

Früherkennung von Buchdruckerbefall dank Fernerkundung: Was ist schon möglich?

Luzia Götz

Waldökologie, Institut für Terrestrische Ökosysteme, ETH Zürich (CH)*

Achilleas Psomas

Eidgenössische Forschungsanstalt für Wald, Schnee und Landschaft, WSL (CH)

Harald Bugmann

Waldökologie, Institut für Terrestrische Ökosysteme, ETH Zürich (CH)

Früherkennung von Buchdruckerbefall dank Fernerkundung: Was ist schon möglich?

Befall durch den Buchdrucker (*Ips typographus*) ist in Fichtenwäldern der hochmontanen und subalpinen Stufe eine grosse Herausforderung für die Waldbewirtschaftung. Es ist unmöglich, im oft steilen Gelände einzig mit terrestrischen Beobachtungen alle anfälligen beziehungsweise bereits befallenen Fichten (*Picea abies*) rechtzeitig zu identifizieren. Um rechtzeitig eingreifen zu können, ist eine zeitsparende, kostengünstige und effektive Methode zum Auffinden dieser Fichten notwendig. Vielversprechend scheint die Technik der Fernerkundung. Deshalb untersuchten wir das Potenzial von hyperspektralen Fernerkundungsdaten für die Früherkennung gestresster oder befallener Fichten an einem Fallbeispiel im Lehr- und Forschungswald der Eidgenössischen Technischen Hochschule (ETH) Zürich in Sedrun im Kanton Graubünden. Der verwendete Ansatz beruht auf einer Kombination von Feldaufnahmen und hyperspektralen Daten, daraus berechneten spektralen Vegetationsindizes und einer Klassifizierung der Fichten in tote, gestresste und gesunde Bäume durch Random-Forest-Modelle, eine Methode des maschinellen Lernens. Es konnte gezeigt werden, dass gestresste Fichten mit diesem Ansatz zwar aufgespürt werden können, die Methode für den operativen Einsatz aber noch nicht ausgereift ist. Insbesondere wäre eine hangspezifische Kalibrierung nötig, was die praktische Anwendung verunmöglicht.

Keywords: hyperspectral data, European spruce bark beetle (*Ips typographus*), random forest, Norway spruce (*Picea abies*), early warning indicators

doi: 10.3188/szf.2020.0036

*Universitätstrasse 16, CH-8092 Zürich, E-Mail luzia.goetz@gmx.ch

Das Verbreitungsgebiet der Fichte (*Picea abies*), der häufigsten Baumart der Schweiz, umfasst beinahe das ganze Land (Abegg et al 2014). Optimale Standortbedingungen findet sie in der hochmontanen und subalpinen Stufe, wo sie natürlicherweise auch Reinbestände bildet. Diese sind im Vergleich zu Mischbeständen anfälliger für Störungen wie Windwurf und Borkenkäferbefall (Netherer & Nopp-Meyr 2005). Einer der wichtigsten Störfaktoren ist der Buchdrucker (*Ips typographus*; Seidl et al 2014). Zur Prävention und Bekämpfung von Käferkalamitäten ist die frühzeitige Erkennung und Entfernung befallener Fichten notwendig.

Ein Unternehmen aus Österreich bietet seit 2017 eine auf Fernerkundungsdaten beruhende Analyse und Detektion von Kalamitäten in der frühen Befallsphase an. Fernerkundung wird für diverse Anwendungen im Waldbereich erfolgreich eingesetzt (Goodenough et al 2004). Dazu gehören die Kartierung und Untersuchung der Dynamik von Käferka-

lamitäten (Jakus et al 2003, Mezei et al 2017) sowie die Modellierung solcher Dynamiken (Jakus et al 2011). Erst wenige Studien haben aber versucht, Fichten nach verschiedenen Befallsstadien zu klassifizieren (Lausch et al 2013, Fassnacht et al 2014, Havašová et al 2015). In diesen Studien wurden unter anderem hyperspektrale Daten verwendet. Auch wenn im Labor die spektralen Signale von frisch befallenen Fichten deutlich von denjenigen gesunder Fichten unterschieden werden konnten (Abdullah et al 2018), waren die bisherigen Versuche mit luftgestützter Fernerkundung nicht in dem Masse zufriedenstellend, als dass sie für die Früherkennung für die Praxis geeignet wären. Auch Chalachanova et al (2017) stellten fest, dass eine rechtzeitige Beurteilung des Zustandes der Fichten mit den derzeitigen Methoden grossflächig nicht möglich ist.

Eine Methode, mit der anfällige und befallene Fichten rasch lokalisiert werden könnten, wäre sehr hilfreich, vor allem in Gebirgsregionen in schwer

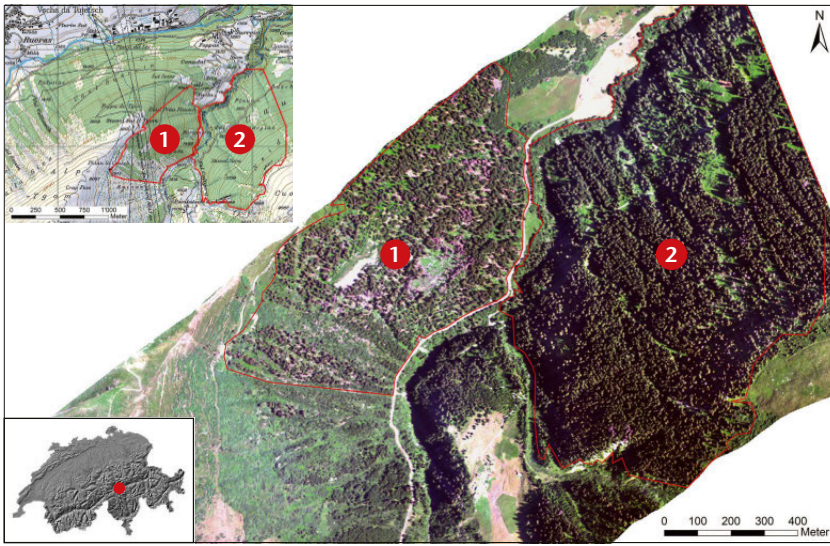


Abb 1 Lage des Untersuchungsgebiets und RGB-Ansicht der analysierten Hyperspektral-daten mit eingezeichnetem Perimeter des Untersuchungsgebiets (rote Linie): 1) Uaul Tgom mit dem Naturwaldreservat Uaul Prau Nausch und der gut sichtbaren Sturmfläche, 2) am Gegenhang östlich davon ein Teil des Uaul Cavorgia.



Abb 2 Blick auf den Uaul Tgom mit dem 2007 ausgeschiedenen Naturwaldreservat Uaul Prau Nausch. Im Zentrum befindet sich die durch einen Sturm im Frühling 2012 entstandene Lücke mitten im Wald. Foto: Timothy Thrippleton, September 2015

zugänglichem Gelände mit komplexer Topografie. Eine derartige Region ist die Surselva im Kanton Graubünden, wo der Buchdrucker derzeit lokal sehr aktiv ist. Dieses Gebiet bot sich deshalb an, die Möglichkeiten der luftgestützten Fernerkundung zur Früherkennung von Käferbefall zu evaluieren. Die vorliegende Studie verfolgte zudem die Ziele, die Bedingungen für eine erfolgreiche Anwendung zu analysieren und die Grenzen der Methode auszuloten.

Material und Methoden

Untersuchungsgebiet

Das Untersuchungsgebiet befindet sich in der Gemeinde Tujetsch (GR) und umfasst den ostexponierten Teil des Lehrwaldes der ETH Zürich, den Uaul Tgom mit dem Naturwaldreservat Uaul Prau Nausch,

sowie einen Teil des Uaul Cavorgia am Gegenhang, südlich von Sedrun (Abbildung 1). Das Gebiet liegt in den nördlichen Zwischenalpen und somit in der Übergangszone zwischen ozeanischem und kontinentalem Klima. Die mittlere Jahrestemperatur liegt bei 5 bis 6 °C, die jährliche Niederschlagsmenge bei 1250 mm im Tal und 1600 mm an der oberen Waldgrenze (Doutaz et al 2009).

Der untersuchte Waldbestand erstreckt sich von knapp 1500 m ü.M. bis an die Waldgrenze auf gut 1900 m ü.M. Im Uaul Tgom, unterhalb von ca. 1600 m ü.M. (in der hochmontanen Stufe) ist der Bestand geschlossen und wurde grösstenteils als Ehrenpreis-Fichtenwald mit Wollreitgras (Standort 55C) kartiert (Doutaz et al 2009). Oberhalb von rund 1600 m ü.M. (in der subalpinen Stufe) tendieren die Bestände zur Rottenstruktur. Der Bestand wurde den verschiedenen Ausprägungen des Alpenlattich-Fichtenwaldes zugeordnet (57C, 57V und 57A). Im Uaul Cavorgia wurde der Bestand in der hochmontanen Stufe als typischer Hochstauden-Tannen-Fichtenwald (50) beschrieben, wobei die Weisstanne (*Abies alba*) hier nicht mehr vorkommt. In der subalpinen Stufe wurde der Standort als Hochstauden-Fichtenwald mit Schachtelhalm (60E) klassifiziert.¹

Das Naturwaldreservat Uaul Prau Nausch wurde 2007 gegründet. Angesichts des Risikos für einen Befall durch den Buchdrucker wurde die Option von Zwangsnutzungen auch innerhalb des Reservats im Vertrag explizit festgehalten. Erste Käfernester wurden bereits wenige Jahre nach der Gründung des Naturwaldreservats beobachtet, gab es aber noch wenig Anlass zur Sorge in diesem recht gut strukturierten Wald. Im Frühling 2012 warf dann aber ein Sturm zahlreiche Fichten im Zentrum des Reservats, wobei eine Lücke von ungefähr 1.5 ha Grösse entstand (Abbildung 2). Die grosse Menge an frischem Totholz bot dem Borkenkäfer gute Brutbedingungen. In der Folge erarbeitete der kantonale Forstdienst 2015 eine Strategie (s. Fahse & Heurich 2011), um den nördlich angrenzenden Uaul Surrein vor Borkenkäferbefall zu schützen. Es wurde ein rund 500 m breiter Pufferstreifen angelegt, der etwa zur Hälfte im Reservat zu liegen kam.

Fernerkundungsdaten

Die Fernerkundungsdaten wurden am 7. Juli 2016 durch ein Team der Remote Sensing Laboratories der Universität Zürich mit einem APEX-Sensor (Airborne Prism Experiment)² von einem Flugzeug aus aufgenommen. Die Daten verfügen über 284 Bänder, einen Spektralbereich von 400 bis 2400 nm und eine räumliche Auflösung von 2 m.

¹ Waldstandortkartierung des Amtes für Wald und Naturgefahren des Kantons Graubünden: http://map.geo.gr.ch/gr_web-maps/wsgi/theme/Waldstandorte (24.11.2019)

² http://apex.vgt.vito.be/sites/apex.vgt.vito.be/files/APEX_Fact_Sheet_Final.pdf (24.11.2019)

Nr.	Vegetationsindex	Abkürzung	Referenz
Stress			
1	Carter Index 1	CTR1	Carter (1994)
2	Carter Index 2	CTR2	Carter (1994)
3	Modified Red Edge NDVI	MNDVire	Sims & Gamon (2002)
4	Modified Red Edge Simple Ratio	MRESR	Sims & Gamon (2002)
5	Photochemical Reflectance Index	PRI	Gamon et al (1997)
6	Red Edge Vegetation Stress Index	RVSI	Merton & Huntington (1999)
7	Structure insensitive pigment index 1	SIPI1	Peñuelas et al (1995)
8	Structure insensitive pigment index 2	SIPI2	Peñuelas et al (1995)
9	Vogelmann 1	VOG1	Vogelmann et al (1993)
10	Vogelmann 2	VOG2	Vogelmann et al (1993)
Chlorophyll			
11	Leaf Chlorophyll Index	LCI	Datt (1999a)
12	Maccioni 2001	Macc01	Maccioni et al (2001)
13	Normalized Pigment Chlorophyll Ratio Index	NPCI	Blackburn (1999)
14	Pigment Specific Simple Ratio Chlorophyll a	PSSRa	Blackburn (1998b)
15	Pigment Specific Simple Ratio Chlorophyll b	PSSRb	Blackburn (1998b)
16	Pigment Specific Simple Ratio Carotenoid	PSSRc	Blackburn (1998b)
17	Ratio of RTCARI and ROSAVI	R	Croft et al (2014)
18	Red Edge Inflection Point	REIP	Horler et al (1983)
19	Red Edge Position	REP	Curran et al (1995)
20	Revised Modified Chlorophyll Absorption	RMCARI	Croft et al (2014)
21	Revised Optimal Soil Adjusted Vegetation Index	ROSAVI	Wu et al (2008)
22	Reflectance at the Reflection Point	Rre	Guyot & Baret (1988)
23	Revised Transformed Chlorophyll Absorption Index	RTCARI	Wu et al (2008)
24	Simple Ratio Vegetation Index 1	SR1	Croft et al (2014)
25	Simple Ratio Vegetation Index 2	SR2	Croft et al (2014)
26	Zarco and Miller	ZM	Zarco-Tejada et al (2001)
27	Green Normalized Difference Vegetation Index	GNDVI	Gitelson et al (1996)
28	Normalized Difference Vegetation Index	NDVI	Rouse et al (1974)
29	Normalized Difference Vegetation Index 2	NDVI2	Rouse et al (1974)
30	Red Edge Normalized Difference Vegetation Index	NDVire	Sims & Gamon (2002)
Wasser			
31	Moisture Stress Index	MSI	Hunt & Rock (1989)
32	Normalized Difference Infrared Index	NDII	Hardisky et al (1983)
33	Normalized Difference Water Index	NDWI	Gao (1995)
34	Water Band Index	WBI	Peñuelas et al (1994)
Stickstoff			
35	Normalized Difference Nitrogen Index	NDNI	Serrano et al (2002)

Tab 1 Übersicht über die in Betracht gezogenen Vegetationsindizes für die Klassifizierung der Fichten.

Die Verarbeitung der vorprozessierten APEX-Daten wurde mit den Programmen R (R Core Team 2017) und ArcGIS durchgeführt. Zuerst wurde die Waldfläche manuell eingegrenzt (Abbildung 1). Danach wurden die stark beschatteten Pixel entfernt, indem die Fläche unter der Spektrumskurve (Area under the curve) berechnet und ein Grenzwert für zu schattige Verhältnisse festgelegt wurde. Schliesslich wurde mit der statistischen Methode Random Forest (RF) die Unterscheidung von Wald und Wiese trainiert, um die Wiesenpixel aus dem Datensatz zu entfernen. RF ist eine Klassifizierungsmethode, die in der Fernerkundung oft eingesetzt wird (Mellor et al 2013, Ham et al 2005, Weber et al 2018). Die Klassifikation beruht auf einem Lernprozess, dem «machine learning», bei dem eine Vielzahl von Entscheidungsbäumen gebildet wird, wobei jeder Baum eine «Stimme» für eine Klasse abgibt. Speziell ist, dass bei jeder Knotenbildung innerhalb eines Entscheidungsbaumes aus einer zufällig generierten Teilmenge der insgesamt p Variablen eine Variable für die Teilungsregel ausgewählt wird – auch wenn diese Variable bereits für eine frühere Teilung benutzt worden ist (Breiman 2001). Die Methode überzeugt durch Einfachheit, Effizienz und Robustheit (Häsch 2017).

Feldaufnahmen

Als Grundlage zur Klassifizierung der Bäume wurden von Juni bis August 2016 Zustand und Koordinaten von 217 Fichten im Uaul Prau Nausch mittels Feldaufnahmen erhoben. Der Zustand der Fichten wurde in die drei Klassen «tot», «gestresst» und «gesund» eingeteilt. Eine Fichte galt als tot, wenn sie keine grünen Nadeln mehr trug. Die gestressten Fichten wiesen Merkmale wie Einbohrlöcher, Harzfluss, Bohrmehl und/oder verlichtete Kronen auf. Die restlichen Fichten wurden als gesund klassifiziert. Die Koordinaten wurden mithilfe des Postex®-Systems von Haglöf relativ zu einem Fixpunkt eingemessen, wobei die Koordinaten des Fixpunktes mit dem HiPer-SR-Site-Receiver von Topcon eruiert wurden. Da eine Echtzeitkorrektur wegen ungenügender Verbindung des Receivers zum Server nicht möglich war, wurden die Messungen statisch durchgeführt und später am PC postprozessiert. Damit wurde eine Genauigkeit der Einmessung von <30 cm erreicht.

Bei der Extraktion der Reflexionswerte aus den hyperspektralen Daten wurde klar, dass sich einige der bei den Feldaufnahmen erhobenen Fichten aufgrund von Schattenwurf nicht für eine Klassifizierung eignen. Schliesslich verblieben 71 gesunde, 94 tote und 11 gestresste Fichten. Um mehr gestresste Fichten für die Untersuchung zur Verfügung zu haben, wurden die Daten von 25 Bäumen miteinbezogen, die infolge Käferbefalls Ende August 2016, d.h. nach dem Befliegen, gefällt wurden. Mit diesen zusätzlichen Daten erhöhte sich die Anzahl gestresster Fichten auf 36. Da die Generierung von RF-Model-




Abb 3 Vergleich der Testgenauigkeiten (1.0 = 100% korrekt klassifiziert) des ein- und des zweistufigen Klassifikationsansatzes für die zwei verwendeten Datensätze.

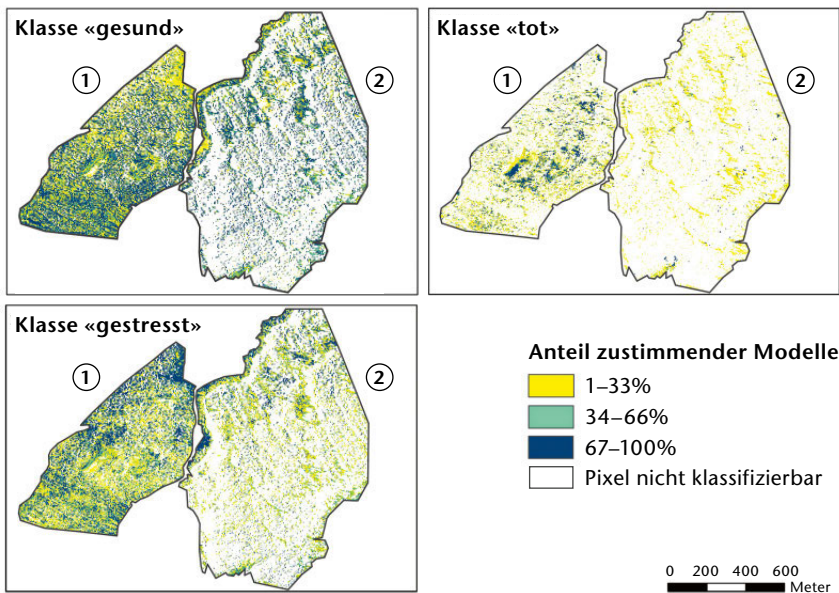


Abb 4 Klassifizierung der Fichtenpixel mithilfe von 100 Random-Forest-Modellen mit einer Testgenauigkeit von $\geq 70\%$ zu den Klassen «gesund», «tot» und «gestresst». Die blauen Pixel symbolisieren diejenigen Fichten, die in mindestens 67 der 100 Modelle der jeweiligen Klasse (z.B. «gesund») zugewiesen worden waren. Bei den grün oder gelb markierten Pixeln war die Zuweisung deutlich geringer. 1: Uaul Tgom, 2: Uaul Cavorgia.

len sensitiv auf eine ungleiche Anzahl Datenpunkte pro Klasse reagiert (Khalilia et al 2011), wurde der Datensatz durch die zufällige Auswahl von 36 gesunden und 36 toten Fichten ausgeglichen (undersampling). Dies ergab eine Gesamtzahl von 108 Fichten für die Klassifizierung.

Auswahl der Indizes zur Klassifizierung

Nach der Verarbeitung der APEX- und der Felddaten wurden 35 spektrale Vegetationsindizes für alle terrestrisch aufgenommenen Fichten berechnet (Tabelle 1). Das Ziel war, dass die Indizes möglichst alle relevanten stressinduzierten Veränderungen abdecken. Ein Set von Indizes stammte aus Studien, die sich mit allgemeinem Pflanzenstress auseinandergesetzt hatten. Weiter wurden Indizes gewählt, die für Untersuchungen zum Chlorophyll- oder Stickstoffgehalt angewendet worden waren, da ge-

zeigt werden konnte, dass sich der Chlorophyll- und Stickstoffgehalt in den Nadeln gesunder und von Käfern befallener, grüner Fichten signifikant unterscheiden (Abdullah et al 2018). Schliesslich wurden Indizes für den Wassergehalt gewählt, da Trockenheit die Abwehrfähigkeit der Fichte gegen Käferbefall vermindert (Netherer et al 2015). Nicht verwendet wurden absolute Reflexionswerte, weil sie sehr stark von der Topografie und der Beleuchtungsgeometrie abhängen (Lillesand & Kiefer 2000).

In einem nächsten Schritt wurden die Indizes nach ihrer Interkorrelation gruppiert. Darauf basierend wurden vier Indizes für die Klassifizierung ausgewählt, die nicht oder nur schwach korreliert ($|r| < 0.7$) und für den vorliegenden Fall am sinnvollsten waren: der Photochemical Reflectance Index, die Red Edge Position, der Normalized Difference Nitrogen Index sowie der Water Band Index. Diese vier Indizes wurden für die 108 im Feld aufgenommenen Fichten berechnet.

Prüfung der RF-Modelle

Mit diesem Datensatz wurde geprüft, wie gut die RF-Modelle in der Lage waren, die drei Klassen (tote, gesunde, gestresste Bäume) zu unterscheiden. Dabei wurden zwei verschiedene Ansätze gewählt: einerseits eine einstufige Klassifizierung, bei der das Modell für die Bildung der drei Klassen trainiert wurde, andererseits eine zweistufige Klassifizierung, bei der zuerst zwischen toten und noch lebenden Fichten unterschieden wurde und erst danach zwischen gesunden und gestressten. Um die beiden Ansätze vergleichen zu können, wurden jeweils zufällig 70% der Daten fürs Trainieren des RF-Modells und 30% als Testdaten verwendet. Bei der Anwendung der trainierten Modelle wurde die Testgenauigkeit (Accuracy) berechnet, die zeigte, welcher Anteil der Fichten korrekt klassifiziert wurde. Um sicherzustellen, dass die besten RF-Modelle generiert wurden, wurde der Prozess 1000-mal wiederholt. Aus den 1000 RF-Modellen des besser klassifizierenden Ansatzes (ein- oder zweistufig) wurden zufällig 100 ausgewählt, die eine Testgenauigkeit $\geq 70\%$ aufwiesen. Schliesslich wurden die vier Indizes auch für alle Pixel der nicht klassifizierten Fichten berechnet, um die 100 ausgewählten RF-Modelle auf diese anzuwenden und die Prädisposition der Bäume im ganzen Untersuchungsgebiet zu errechnen und kartografisch darzustellen.

Resultate

Bei den klassifizierten Fichten variiert die Testgenauigkeit der RF-Modelle zwischen 39.4% und 87.9%, wobei der Median bei 63.6% liegt (Abbildung 3 links). Dabei sind die Leistungen der beiden Ansätze zur Bildung der RF-Modelle annähernd gleich. Deshalb wurde für die Anwendung auf die




Abb 5 Mittlere Spektren der für die Generierung der Random-Forest-Modelle benutzten Daten nach Klassen, wobei die gestressten Fichten in zwei Unterklassen aufgeteilt wurden: in die im Feld als gestresst klassierten und in die gefällten Fichten, von denen angenommen wurde, dass sie ebenfalls gestresst waren.

Pixel der nicht klassifizierten Fichten der einfachere einstufige Ansatz verwendet.

Die Klassifizierung aller Pixel (Abbildung 4) zeigt, dass es einige Waldgebiete gibt, bei denen sich die RF-Modelle mehrheitlich einig sind, zum Beispiel im unteren und südlichen Teil des Uaul Prau Nausch. Es finden sich aber auch überall Pixel, die nur von 34% bis 66% der RF-Modelle einer bestimmten Klasse zugeordnet wurden und somit schwierig zu interpretieren sind. Wie erwartet deckt sich die Klassifizierung der toten Fichten sehr gut mit dem RGB-Luftbild (Abbildung 1). Allerdings wurde ein Teil der Aussichtsplattform im Uaul Prau Nausch, der als Artefakt im Datensatz enthalten blieb, ebenfalls als tot klassifiziert. Die Jungwaldflächen in der nördlichen Spitze des Uaul Prau Nausch sowie im unteren (westlichen) Teil des Uaul Cavorgia hingegen wurden unzutreffend als gestresst klassifiziert. Gut sichtbar sind auch die grossen datenfreien Bereiche im Uaul Cavorgia, die durch die Entfernung der beschatteten Pixel entstanden sind.

Die spektralen Signale der nachträglich gefällten Fichten unterschieden sich deutlich von den als gestresst aufgenommenen (Abbildung 5). Im sichtbaren Bereich zwischen 0.4 und 0.7 µm ist der Reflexionswert der gefällten Fichten überraschenderweise tiefer als jener der gesunden Fichten. Die Reflexion der gestressten Fichten hingegen liegt erwartungsgemäss zwischen jener der gesunden und der toten Fichten. Zwischen 0.7 µm und 1.4 µm stimmen die beiden Werte meist ebenfalls nicht überein. Dasselbe Muster wie im sichtbaren Bereich findet man auch im Bereich oberhalb von 1.4 µm. Dies war der Auslöser für die erneute Generierung von RF-Modellen mit dem Datensatz ohne die nachträglich gefällten Fichten. Da der Stichprobenumfang der Klasse «gestresst» damit auf $n = 11$ sank, wurde die Leistung der RF-Modelle entsprechend unbefriedigend. Die Testgenauigkeit sank bei beiden RF-Model-

dellen im Mittel unter 40%, was ein deutliches Zeichen für den Datenmangel war (Abbildung 3 rechts).

Diskussion

Der in dieser Studie entwickelte Ansatz zur Eruiierung gestresster Fichten aus Hyperspektraldaten funktioniert grundsätzlich. Es konnte gezeigt werden, dass gestresste Fichten mit einem relativ einfachen Vorgehen gefunden werden könnten. Die Auswahl der spektralen Indizes beruht auf einer intensiven Literaturrecherche und ist gut begründet. Die 1000-fache Generierung von RF-Modellen und die anschliessende zufällige Auswahl von deren 100 mit einer Testgenauigkeit $\geq 70\%$ stellen ein differenziertes Vorgehen dar. Das Resultat kann dadurch besser interpretiert werden, als wenn die Zuordnung der nicht klassifizierten Pixel lediglich mit dem besten RF-Modell (d.h. jenem mit der höchsten Testgenauigkeit) durchgeführt worden wäre. Doch noch ist dieser Ansatz nicht ausgereift und kann ohne weitere Forschungsarbeiten nicht operativ angewendet werden. Das Problem ist, dass eine präzise Karte der gestressten Fichten damit nicht erzeugt werden kann. Im Folgenden werden die Gründe dafür erörtert und mögliche Verbesserungen diskutiert.

Hyperspektrale Daten

Aus hyperspektralen Daten können diverse Informationen extrahiert werden, die für Entscheidungen im Waldbau von Bedeutung sind (Goodenough & Bannon 2014). Es gibt aber auch Grenzen, wie die vorliegende Studie zeigt. Die Aufnahme der Reflexion mit einer räumlichen Auflösung von zwei Metern führt zu gemischten Signalen. Das heisst, alle Objekte, die in einem Pixel Licht reflektieren, tragen zum Signal dieses Pixels bei. Im vorliegenden Fall können dies die Kronen einer oder mehrerer Fichten, andere Gehölzpflanzen, krautige Vegetation, Felsblöcke usw. sein. Vor allem in der subalpinen Stufe, wo die Fichten in Rotten stehen, wird das Signal eines Pixels oft von mehreren Fichten geprägt, oder es ist gemischt mit Signalen anderer Oberflächenbedeckungen am Rand der Kronen. Zwar zeigten Abdullah et al (2018), dass die Nadeln von gestressten Fichten sich in ihrem spektralen Signal von Nadeln gesunder Fichten klar unterscheiden. Bei dieser Studie wurden aber lediglich Nadeln gesammelt und im Labor gemessen, es wurden also keine Fernerkundungsdaten ausgewertet. Solche «reinen» Messungen wären auch mit einer wesentlich höheren räumlichen Auflösung aus der Luft nicht möglich, da zum Beispiel auch die verholzten Teile der Kronen (Zweige, Äste) das Signal stets beeinflussen.

Eine weitere Unsicherheit birgt der Zeitpunkt der Befliegung. Einerseits ist die Aktivität des Käfers abhängig vom jährlich wechselnden Temperaturver-

lauf (Wermelinger 2004), und andererseits ist ungewiss, ab welchem Zeitpunkt die gestressten Fichten im spektralen Signal als solche erkennbar sind. Zudem ist es wahrscheinlich, dass die Fichten zum Aufnahmezeitpunkt unterschiedliche Stressgrade aufweisen. Dies könnte auch erklären, weshalb sich die Spektren der gefällten Fichten deutlich von jenen der im Feld aufgenommenen gestressten Fichten unterscheiden. Zum Zeitpunkt der Befliegung konnte man sie im Feld noch nicht als gestresst erkennen. Mitte August, als sie gefällt wurden, hätte man vermutlich ein anderes spektrales Signal registriert.

Auch die Tageszeit beeinflusst die Fernerkundungsdaten. Je nach Sonnenstand kann im Gebirge der beschattete Anteil an Fichtenkronen sehr hoch sein, wie im vorliegenden Fall im Uval Cavorgia. Es besteht somit das Risiko, gestresste Fichten gar nicht erfassen zu können, da kein brauchbares Signal vorhanden ist. Der ideale Aufnahmezeitpunkt der Fernerkundungsdaten ist demnach von diversen Faktoren abhängig und schwierig zu eruieren. Weitere Untersuchungen, zum Beispiel mit mehreren Aufnahmen pro Jahr, wären sehr aufschlussreich, aber teuer in der Realisierung. Eine Alternative könnten Befliegungen mit Drohnen darstellen.

Vegetationsindizes

Als Indizes wurden nicht nur solche gewählt, mit denen man den Käferbefall registrieren würde, sondern auch solche, die eine Prädisposition (d.h. Stress der Fichten) anzeigen können. Je nach Gradation des Buchdruckers und physiologischem Zustand der Fichte ist ein Befall mehr oder weniger wahrscheinlich. Ist die Abundanz des Buchdruckers hoch, so sind die Käfer in der Lage, auch gesunde Fichten zu befallen. Ist sie jedoch tief, gelingt es den Käfern nur, in bereits deutlich geschwächten Fichten zu brüten (Kärvemo et al 2014). Die Prädisposition kann unter anderem durch Trockenheit induziert sein (Netherer et al 2015), weshalb auch Indizes gewählt wurden, die den Wassergehalt widerspiegeln.

Nach der Berechnung der Korrelation zwischen den Indizes wurde darauf geachtet, dass die Indizes, die für die Klassifizierung ausgewählt wurden, möglichst alle oben genannten Kategorien abdecken. Die manuelle und damit subjektive Wahl der nicht korrelierten Indizes dürfte – wenn überhaupt – nur einen geringen Einfluss auf das Resultat gehabt haben, da die Korrelation innerhalb der Gruppen sehr hoch war.

Terrestrische Aufnahmen

Die Menge der terrestrisch erhobenen Daten ist für die robuste Klassifizierung von Fernerkundungsdaten enorm wichtig. Doch für jede Klasse genügend Datenpunkte zu finden, war im vorliegenden Fall aus zwei Gründen schwierig. Erstens gestalteten sich die Aufnahmen im steilen und zum

Teil nahezu unbegehbaren Gelände als zeitintensiv, und zweitens war die Erkennung von gestressten Fichten nicht einfach und teils subjektiv. Die Sicht auf die Krone und den Stamm ist meistens limitiert, und die an den Nadeln im Labor messbaren spektralen Unterschiede (Abdullah et al 2018) sind im Feld von Auge natürlich nicht erkennbar.

Die Felddaten wurden alle am gleichen Hang gemacht. Weitere Aufnahmen an Hängen aller Expositionen wären notwendig, um eine generell anwendbare Klassifizierung zu generieren, da die Reflexion auch von der Exposition und der Hangneigung beeinflusst wird. Der Arbeitsaufwand für die Felddaten würde sich aber vervielfachen, und die Schwierigkeit, gestresste Fichten zu finden, bliebe bestehen. Dies würde dafür sprechen, einen Bestand über eine längere Zeitdauer zu beobachten und regelmässig zu befliegen, sodass genügend Fernerkundungsdaten von Fichten aufgenommen werden könnten, die zu Beginn noch gesund sind, danach vom Käfer befallen werden und schliesslich absterben. Ein derartiges umfassendes Vorgehen hätte die Vorteile, dass keine aufwendigen Felddaten im Gelände nötig wären und Daten für unterschiedliche Stresslevel erhoben werden könnten. Die Nachteile sind, dass die Untersuchung über mehrere bis viele Jahre laufen müsste und die mehrfache Befliegung des Bestandes sehr teuer wäre. Wie erwähnt könnten die Kosten durch die Befliegung mit einer Drohne (Näsi et al 2015, Chalachanova et al 2017) anstelle eines Kleinflugzeugs gesenkt werden. Dies haben Ackermann et al (2018) in vier parallel durchgeführten Versuchen getestet. Auch sie sind dabei zum Schluss gekommen, dass noch keine praxistaugliche Methode zur Früherkennung von Buchdruckerbefall besteht. Zudem nennen sie als Nachteile von Datenaufnahmen durch Drohnen namentlich die gesetzlichen und witterungsbedingten Restriktionen, die kurze Flugzeit und somit eine geringe Flächenabdeckung sowie die geringe Nutzlast, welche die Auswahl der Sensoren einschränkt.

Fazit

Die Untersuchung zeigt, dass gestresste und vom Buchdrucker befallene Fichten im Prinzip mit einer relativ simplen, auf spektralen Fernerkundungsdaten basierenden Methode lokalisiert werden könnten. Sie zeigt aber auch, dass die Menge und die Qualität der Daten entscheidend für eine robuste Klassifizierung sind. Es sind Beobachtungen und Aufnahmen von hyperspektralen Daten über eine längere Zeit oder unter verschiedensten Standortbedingungen (Hangneigung, Exposition, Kleinrelief) nötig, um die spektralen Signale bei unterschiedlichen Stresslevels erfassen und die RF-Modelle verifizieren zu können. Wir ziehen die Schlussfolgerung,

dass es noch vertiefte Forschungsarbeiten braucht, bis beginnender Käferbefall operationell aus der Luft erkannt werden kann. ■

Eingereicht: 25. August 2019, akzeptiert (mit Review): 19. November 2019

Dank

Wir bedanken uns bei den Remote Sensing Laboratories der Universität Zürich für die APEX-Datenaufnahmen, beim Amt für Wald und Naturgefahren des Kantons Graubünden für die grosszügige finanzielle Beteiligung an den Kosten der Flugkampagne, beim Revierforstamt Tujetsch für die Mitwirkung bei der Eruiierung der zu untersuchenden Fichten, bei der statistischen Beratungsstelle der ETH Zürich für methodische Hilfestellungen sowie bei Philippe Tschanz, Cyril Durrer und Ueli Schmid für die Mithilfe bei der Feldarbeit.

Literatur

- ABDULLAH H, DARVISHZADEH R, SKIDMORE AK, GROEN TA, HEURICH M (2018) European spruce bark beetle (*Ips typographus* L.) green attack affects foliar reflectance and biochemical properties. *Int J Appl Earth Obs Geoinf* 64: 199–209.
- ACKERMANN J, ADLER P, HOFFMANN K, HURLING R, JOHN R ET AL (2018) Früherkennung von Buchdruckerbefall durch Drohen. *AFZ/Wald* 73 (19): 50–53.
- BLACKBURN GA (1998) Spectral indices for estimating photosynthetic pigment concentrations: a test using senescent tree leaves. *Int J Remote Sens* 19: 657–675.
- BLACKBURN GA (1999) Relationships between spectral reflectance and pigment concentrations in stacks of deciduous broadleaves. *Remote Sens Environ* 70: 224–237.
- BREIMAN L (2001) Random forests. *Machine Learning* 45: 5–32.
- CARTER GA (1994) Ratios of leaf reflectances in narrow wavebands as indicators of plant stress. *Int J Remote Sens* 15: 697–703.
- CHALACHANOVA JF, DURACIOVA R, PAPCO J, JAKUS R, BLAZENEC M (2017) Integration of heterogeneous data in the support of the forest protection: Structural concept. In: Ivan I, Singleton A, Horák J, Inspektor T, editors. *Rise of big spatial data*. Cham: Springer Nature Switzerland AG. pp. 387–405.
- CROFT H, CHEN JM, ZHANG Y (2014) The applicability of empirical vegetation indices for determining leaf chlorophyll content over different leaf and canopy structures. *Ecol Complexity* 17: 119–130.
- CURRAN PJ, WINDHAM WR, GHOLZ HL (1995) Exploring the relationship between reflectance red edge and chlorophyll concentration in slash pine leaves. *Tree Physiol* 15: 203–206.
- DATT B (1999) A new reflectance index for remote sensing of chlorophyll content in higher plants: Tests using eucalyptus leaves. *J Plant Physiol* 154: 30–36.
- DOUTAZ J, FREY HU, BUGMANN H (2009) Standortkartierung im Lehr- und Forschungswald der ETH in Sedrun. *Schweiz Z Forstwes* 160: 27–36. doi: 10.3188/szf.2009.0027
- FAHSE L, HEURICH M (2011) Simulation and analysis of outbreaks of bark beetle infestations and their management at the stand level. *Ecol Model* 222: 1833–1846.
- FASSNACHT FE, LATIFI H, GHOSH A, JOSHI PK, KOCH B (2014) Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality. *Remote Sens Environ* 140: 533–548.
- GAMON JA, SERRANO L, SURFUS JS (1997) The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. *Oecologia* 112: 492–501.
- GAO BC (1995) A normalized difference water index for remote sensing of vegetation liquid water from space. *Imaging Spectrometry* 2480: 225–236.
- GITELSON AA, KAUFMAN YJ, MERZLYAK MN (1996) Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sens Environ* 58: 289–298.
- GOODENOUGH DG, BANNON D (2014) Hyperspectral forest monitoring and imaging implications. In: *Proc SPIE 9104 Spectral imaging sensor technologies: innovation driving advanced application capabilities*, 28 May 2014, Maryland (USA). 9 p.
- GOODENOUGH DG, PEARLMAN J, CHEN H, DYK A, HAN T ET AL (2004) Forest information from hyperspectral sensing. *Proc IGARSS 2004: IEEE international geoscience and remote sensing symposium*, 20–24 Sept 2004, Anchorage, Alaska (USA). Vol IV. pp. 2585–2589.
- GUYOT G, BARET F (1988) Utilisation de la haute résolution spectrale pour suivre l'état des couverts végétaux. *Proc 4th international colloquium on spectral signatures of objects in remote sensing*, 18–22 January 1988, Aussois (France). p. 287 und p. 279.
- HAM J, CHEN YC, CRAWFORD MM, GHOSH J (2005) Investigation of the random forest framework for classification of hyperspectral data. *IEEE Trans Geosci Remote Sens* 43: 492–501.
- HÄSCH R, HELLWICH O (2017) Random Forests. In: Heipke C, editor. *Photogrammetrie und Fernerkundung: Handbuch der Geodäsie*. Wiesbaden: Springer Spektrum. pp. 603–643.
- HARDISKY MA, KLEMAS V, SMART RM (1983) The influence of soil-salinity, growth form, and leaf moisture on the spectral radiance of spartina-alterniflora canopies. *Photogramm Eng Remote Sens* 49: 77–83.
- HAVASOVA M, BUCHA T, FERENCIK J, JAKUS R (2015) Applicability of a vegetation indices-based method to map bark beetle outbreaks in the High Tatra Mountains. *Ann For Res* 58: 295–310.
- HORLER DNH, DOCKRAY M, BARBER J (1983) The red edge of plant leaf reflectance. *Int J Remote Sens* 4: 273–288.
- HUNTER, ROCK BN (1989) Detection of changes in leaf water content using near-infrared and middle-infrared reflectances. *Remote Sens Environ* 30: 43–54.
- JAKUS R, GRODZKI W, JEZIK M, JACHYM M (2003) Definition of spatial patterns of bark beetle *Ips typographus* (L.) outbreak spreading in Tatra Mountains (Central Europe), using GIS. In: McManus ML, Liebold AM, editors. *Ecology, survey and management of forest insects*, Proceedings. Newtown Square PA: USDA Forest Service. pp. 25–32.
- JAKUS R, ZAJICKOVA L, CUDLIN P, BLAZENEC M, TURCANI M ET AL (2011) Landscape-scale *Ips typographus* attack dynamics: from monitoring plots to GIS-based disturbance models. *IForest-Biogeosci For* 4: 256–261.
- KHALILIA M, CHAKRABORTY S, POPESCU M (2011) Predicting disease risks from highly imbalanced data using random forest. *BMC Medical Informatics and Decision Making* 11: article 51.
- KARVEMO S, ROGELL B, SCHROEDER M (2014) Dynamics of spruce bark beetle infestation spots: Importance of local population size and landscape characteristics after a storm disturbance. *For Ecol Manage* 334: 232–240.
- LAUSCH A, HEURICH M, GORDALLA D, DOBNER HJ, GWILLYM-MARGIANTO S ET AL (2013) Forecasting potential bark beetle outbreaks based on spruce forest vitality using hyperspectral remote-sensing techniques at different scales. *For Ecol Manage* 308: 76–89.
- LILLESAND TM, KIEFER RW (2000) *Remote sensing and image interpretation*. Hoboken: John Wiley. 650 p.

- MACCIONI A, AGATI G, MAZZINGHI P (2001) New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *J Photochem Photobiol B-Biology* 61: 52–61.
- MELLOR A, HAYWOOD A, STONE C, JONES S (2013) The performance of random forests in an operational setting for large area sclerophyll forest classification. *Remote Sens* 5: 2838–2856.
- MERTON R, HUNTINGTON J (1999) Early simulation results of the ARIES-1 satellite sensor for multi-temporal vegetation research derived from AVIRIS. In: Proc 8th annual JPL airborne earth science workshop, 9–11 February, Pasadena CA (USA). p. 1999.
- NASI R, HONKAVAARA E, LYYTIKAINEN-SAARENMAA P, BLOM-QVIST M, LITKEY P, HAKALA T ET AL (2015) Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. *Remote Sens* 7: 15467–15493.
- NETHERER S, MATTHEWS B, KATZENSTEINER K, BLACKWELL E, HENSCHKE P ET AL (2015) Do water-limiting conditions predispose Norway spruce to bark beetle attack? *New Phytol* 205: 1128–1141.
- NETHERER S, NOPP-MAYR U (2005) Predisposition assessment systems (PAS) as supportive tools in forest management – rating of site and stand-related hazards of bark beetle infestation in the High Tatra Mountains as an example for system application and verification. *For Ecol Manage* 207: 99–107.
- PENUELAS J, BARET F, FILELLA I (1995) Semiempirical indexes to assess carotenoids chlorophyll-a ratio from leaf spectral reflectance. *Photosynthetica* 31: 221–230.
- PENUELAS J, GAMON JA, FREDEEN AL, MERINO J, FIELD CB (1994) Reflectance indexes associated with physiological-changes in nitrogen-limited and water-limited sunflower leaves. *Remote Sens Environ* 48: 135–146.
- SERRANO L, PENUELAS J, USTIN SL (2002) Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals. *Remote Sens Environ* 81: 355–364.
- SIMS DA, GAMON JA (2002) Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sens Environ* 81: 337–354.
- R CORE TEAM (2017) A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna: R Core Team, www.R-project.org.
- ROUSE JW, HAAS RH, SCHELL JA, DEERING DW, HARLAN JC (1974) Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. Greenbelt MD: NASA, NASA/GSFC Type III Final Report. p. 371.
- VOGELMANN JE, ROCK BN, MOSS DM (1993) Red edge spectral measurements from sugar maple leaves. *Int J Remote Sens* 14: 1563–1575.
- WEBER D, GINZLER C, FLÜCKIGER S, ROSSET C (2018) Potenzial von Sentinel-2-Satellitendaten für Anwendungen im Waldbereich. *Schweiz Z Forstwes* 169: 26–34. doi: 10.3188/szf.2018.0026
- WERMELINGER B (2004) Ecology and management of the spruce bark beetle *Ips typographus* – a review of recent research. *For Ecol Manage* 202: 67–82.
- WU CY, NIU Z, TANG Q, HUANG WJ (2008) Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agric For Meteorol* 148: 1230–1241.
- ZARCO-TEJADA PJ, MILLER JR, NOLAND TL, MOHAMMED GH, SAMPSON PH (2001) Scaling-up and model inversion methods with narrowband optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. *IEEE Trans Geosci Remote Sens* 39: 1491–1507.

Quellen

- ABEGG M, BRÄNDLI UB, CIOLDI F, FISCHER C, HEROLD-BONARDI A ET AL (2014) Viertes Schweizerisches Landesforstinventar – Ergebnisse tabellen und Karten im Internet zum LFI 2009–2013 (LFI4b). doi: 10.21258/1000001

Détection précoce des infestations de scolytes par télédétection: qu'est-ce qui est possible actuellement?

L'infestation par les scolytes (*Ips typographus*) dans les forêts d'épicéa (*Picea abies*) uniformes des zones haut-montagnard et subalpin est un défi majeur pour la gestion. Il est impossible d'identifier à temps tous les épicéas susceptibles à une infection ou déjà infestés dans les pentes raides uniquement à partir des observations terrestres, et d'empêcher la gradation des scolytes. Une méthode rapide, peu coûteuse et efficace pour trouver ces épicéas est nécessaire, et la technique de télédétection semble prometteuse. C'est pourquoi nous avons étudié le potentiel des données de télédétection hyperspectrales pour la détection précoce des épicéas stressés ou infestés à l'aide d'une étude de cas dans la forêt expérimentale de l'École polytechnique fédérale de Zurich à Sedrun. L'approche est basée sur une combinaison d'études de terrain, de données hyperspectrales, d'indices de végétation calculés à partir de celles-ci et de classification dans les trois classes «mort», «stressé» et «sain» par Random Forests, une méthode de «machine learning». Il a été démontré que les épicéas stressés peuvent être trouvés avec cette approche, mais elle n'est pas encore prête pour une utilisation opérationnelle. En particulier, un étalonnage de la méthode en fonction de la pente spécifique est nécessaire, ce qui rend l'application pratique impossible.

Early detection of bark beetle infestations by remote sensing: what is feasible today?

Infestation by the Norway spruce (*Picea abies*) bark beetle (*Ips typographus*) in uniform forest stands of the high montane and subalpine stage is a major challenge for management. It is impossible to identify in time all susceptible or already infested spruces in the often steep terrain solely by terrestrial observations and to prevent the proliferation of the beetle. A time-saving, cost-effective and effective method for finding these spruces is necessary and remote sensing techniques appear promising. Therefore, we investigated the potential of hyperspectral remote sensing data for the early detection of stressed or infested spruces using a case study in the experimental forest of the Swiss Federal Institute of Technology Zurich (ETHZ) in Sedrun. The approach that we developed is based on a combination of field surveys, hyperspectral data, vegetation indices calculated from these and their classification into the three classes “dead”, “stressed” and “healthy” using Random Forests, a machine-learning approach. We demonstrate that stressed spruces can be identified with this approach, but it is not yet ready for operational use. In particular, a slope-specific calibration of the method is necessary, which makes practical application impossible.