



Erkennung von Borkenkäferbefall in Fichtenreinbeständen mit multi-temporalen RapidEye-Satellitenbildern und Dataming-Techniken

ALEXANDER MARX, Brandenburg an der Havel

Keywords: Borkenkäfer-Monitoring, Decision Trees, C5, Dataming

Summary: *Detection and Classification of Bark Beetle Infestation in Pure Norway Spruce Stands with Multi-temporal RapidEye Imagery and Data Mining Techniques.* The article at hand reveals the methodology and results of a research and development project in the field of applied remote sensing in forest protection and bark beetle monitoring. It was found that using multi-temporal RapidEye imagery, the ground truth data of bark beetle infestation and the application of dataming techniques allow for the recognition and separation of different infestation stages. The analysis suggests a weak trend for the identification of infested groups of trees, which are still widely green. In contrast, the classification of reddish-coloured deteriorating or dead tree groups shows a high accuracy (97 % user's, 82 % producer's, kappa: 0.89).

Zusammenfassung: Der vorliegende Artikel stellt die im Rahmen eines Forschungs- und Entwicklungsprojektes verwendeten Methoden und erzielten Ergebnisse auf dem Gebiet der angewandten Fernerkundung im Waldschutz, im Speziellen dem Borkenkäfer-Monitoring, dar. Es zeigte sich, dass unter Verwendung multi-temporaler RapidEye Satellitenbilder, terrestrischer Stichproben des Borkenkäferbefalls und der Anwendung von Dataming-Techniken eine Erkennung und Differenzierung unterschiedlicher Befallsstadien möglich ist. Die Auswertungen zeigen einen schwachen Trend zur Erkennbarkeit frisch befallener, noch weitgehend grüner Baumgruppen. Dagegen werden bei der Klassifikation der bereits rot verfärbten absterbenden und toten Baumgruppen hohe Genauigkeiten erreicht (97 % Nutzergenauigkeit, 82 % Herstellergenauigkeit, Kappa: 0,89).

1 Einleitung

1.1 Relevanz der Borkenkäferschäden für die Forstwirtschaft

Massenbefall von Fichtenbeständen durch die Borkenkäferarten Buchdrucker (*Ips typographus*) und Kupferstecher (*Pityogenes chalcographus*) sind ein ernstzunehmendes ökonomisches Problem in europäischen Wirtschaftswäldern (EPPO). So fielen beispielsweise im deutschen Bundesland Thüringen 2003, einem Jahr mit einem sehr heiß-trockenen Sommer und daher idealen Vermehrungsbedingungen für den Buchdrucker, 473384 Efm¹ Käferholz

an (TMLNU 2006). Auch in Übersee herrschen schwerwiegende Probleme mit anderen Borkenkäferarten. In British Columbia, Kanada, hatte das Befallsgebiet der fortschreitenden Gradation des Mountain Pine Beetles (*Dendroctonus ponderosae*) im Jahre 2006 eine Fläche von 130.000 km² erreicht. Der kumulative Verlust an Holz belief sich auf etwa 435 Millionen Kubikmeter (CBCNEWS 2008).

In Deutschland existieren etablierte Systeme zum Monitoring des Borkenkäferbefalls. Pheromon-Käferfallen, Fangbäume und vor allem die Begehung der Bestände durch die Revierförster liefern Daten über aktuelle Befallssituationen und Gradationsentwicklungen. Diese Monitoring-Techniken sind sehr arbeitsintensiv und heutzutage bei Reviergrößen, die oft 2.000 ha übersteigen, nicht mehr effektiv genug. Aus genannten Gründen be-

¹ Efm = Erntefestmeter. Entspricht dem gemessenen Derbholzvolumen, abzüglich 10 % Rindenverlust und 10 % Verlust bei der Holzernte.

steht ein großes Interesse daran, alternative Möglichkeiten zu untersuchen, welche die bereits bestehenden Methoden wirksam und kostengünstig unterstützen könnten.

1.2 Aktueller Stand der Forschung

Zur Detektion von Borkenkäferschäden mit Hilfe optischer Sensoren wurden in der Vergangenheit zahlreiche Forschungsprojekte durchgeführt. Insbesondere die Früherkennung spielte dabei eine bedeutende Rolle, da die Maßnahmen, die der Ausbreitung des Borkenkäfers entgegenwirken sollen nur dann wirksam sind, wenn die befallenen Bäume noch vor dem Ausflug der neuen Generation aus dem Waldbestand entfernt werden. Um dies zu verstehen, ist ein Blick auf den Ablauf der Gradation sowie die physiologischen Auswirkungen des Befalls auf die Bäume notwendig.

Im Frühjahr (April/Mai) beginnen die adulten Käfer ab Tagestemperaturen von etwa 16,5 °C zu schwärmen, die Fichten zu befallen und ihre Eier unter der Rinde abzulegen, worauf die Larven schlüpfen und mit dem Fraß im Bast der betroffenen Bäume beginnen. Die Fraßaktivität greift das Phloem an. Dies ist das Transportgewebe für die Nährstoffe von den Blättern zur Wurzel. Der sekundäre Nährstoffmangel in den Blättern führt unter anderem zum allmählichen Zerfall des Chlorophylls. Im Zeitraum von Mitte Juni bis Ende Juli verlassen die aus den Puppen hervorgegangenen Imagos ihre Wirtsbäume, um neue Fichten zu befallen (NIERHAUS-WUNDERWALD & FORSTER 2004). Daher erfasst ein im April aufgenommenes Satellitenbild den Zustand vor dem Befall und ein Anfang/Mitte Juni aufgenommenes Bild den Befallszustand kurz vor dem Ausflug. So lässt sich theoretisch der Änderungsvektor in Bezug auf das sich verringere Chlorophyll erfassen.

Das Problem besteht jedoch darin, dass das rotbraune Verfärben der Baumkronen erst einsetzt, nachdem die Käfer die Brutbäume verlassen haben. Frisch befallene Bäume sind daher noch grün und zeigen nur schwache Anzeichen des Rückgangs der grünen Blattpigmente.

Die in der jüngsten Vergangenheit (nach 2000) publizierten Studien zu Untersuchungen der Erkennung des Frühbefalls konzentrierten sich insbesondere auf den nordamerikanischen Kontinent und das dortige Mountain Pine Beetle Problem. HEATH (2001) versuchte mit dem Compact Airborne Spectrographic Imager (CASI), einem Hyperspektralscanner, Frühbefall in *Pinus ponderosa* Beständen zu detektieren. Ein positiver Trend zeigte sich im grünen Spektralbereich bei 540 nm und im Red Edge bei 706 nm. Die spektralen Signaturen der gesunden und der frisch befallenen Bäume überlappten sich jedoch sehr stark. Gemäß WULDER et al. (2005) blieben alle bisherigen Untersuchungen dieser Art weitgehend erfolglos. Dagegen ist die Erkennung von bereits verfärbten Baumkronen mit unterschiedlich hohen Genauigkeiten vielfach nachgewiesen worden. So erreichten FRANKLIN et al. (2003) bei der Auswertung monotonaler Multispektraldaten eine Genauigkeit von 73 %. SHANKUN et al. (2003) zeigten, dass die Auswertung multi-temporalen Aufnahmen die Fehlerquote verringert. Sie untersuchten darüber hinaus die Genauigkeiten in Abhängigkeit von der Größe der geschädigten Baumgruppen: Für Gruppen von 10–29 Bäumen betrug die Genauigkeit 76 %, für 30–50 Bäume 81 %.

1.3 Zielstellungen

Mit der RapidEye Konstellation, betrieben von der RapidEye AG, die ihren Sitz in Brandenburg an der Havel hat, steht ein System von fünf hochauflösenden Erdbeobachtungssatelliten zur Verfügung. Alleinstellungsmerkmale sind das RedEdge Band und die hohe Wiederholrate, welche die Chance erhöht, wolkenfreie Aufnahmen im gewünschten Zeitfenster zu erhalten. Motiviert von den im Abschnitt 1.1 beschriebenen Zusammenhängen führten die RapidEye AG und ihr Projektpartner, die Thüringer Landesanstalt für Wald, Jagd und Fischerei (TLWJF), gemeinsam ein Forschungsprojekt durch, um folgende Fragestellungen zu untersuchen:

1. Sind RapidEye Daten eine geeignete Datenquelle zur Erkennung von durch Borkenkäfer geschädigten Fichtenbeständen?

2. Können unterschiedliche Befallsklassen erfasst werden?
3. Welche Genauigkeiten können mittels multi-temporalen Datenauswertung und Data-mining Techniken erzielt werden?

Die Methoden und Ergebnisse des Forschungsprojektes sind Gegenstand dieses Beitrages und werden in den folgenden Abschnitten dargestellt. Es ist die erste Untersuchung dieser Art unter Verwendung von RapidEye Daten.

2 Methode

2.1 Untersuchungsgebiet

Das Projektgebiet befindet sich im Bundesland Thüringen und bedeckt hauptsächlich die Forstämter Gehren, Sonneberg und Neuhaus (Koordinatenmittelpunkt: 11d11'38" E; 50d35'15" N). Es erstreckt sich über eine Fläche von 886 km², wobei die Gesamtwaldfläche 570 km² beträgt. Als Hauptbaumart dominiert *Picea abies* (Gemeine Fichte) mit 84 %. Außerdem sind *Fagus sylvatica* (Gemeine Buche) mit 7 %, *Pinus sylvestris* (Wald-Kiefer) mit 4 %, *Larix decidua* (Europäische Lärche) mit 2 % und sonstige Baumarten mit 3 % vorhanden.

2.2 Verwendete Geodaten

Satellitenbilddaten

Das Untersuchungsgebiet wurde mit zwei wolkenfreien Gebietsabdeckungen mit den RapidEye Satelliten (siehe Tab. 1) aufgenommen. Bei beiden Aufnahmen beträgt der Schwenkwinkel -6° . Die Zeitreihe ist definiert durch die beiden Zeitpunkte T1 = 13. 04. 2009 und T2 = 13. 06. 2009. Dabei wurde die Wahl der Aufnahmezeitpunkte dem Lebenszyklus des Borkenkäfers angepasst (vgl. Abschnitt 1.2, zweiter Absatz).

Forstliche Grundlagendaten und Geodaten (bereitgestellt von der Thüringer Landesforstverwaltung):

- Ein Vektor-Layer aller Fichtenreinbestände, wobei ein Fichtenreinbestand durch einen Fichtenanteil größer gleich 90 % definiert ist,

Tab. 1: Eigenschaften der RapidEye Konstellation.

Kennzeichen des RapidEye-Systems	5 baugleiche Satelliten
Spektrale Auflösung	Blau (410–510 nm) Grün (520–590 nm) Rot (630–685 nm) Red Edge (690–730 nm) NIR (760–850 nm)
Radiometrische Auflösung	12 Bit
Geometrische Auflösung	6,5 m (nadir)
Schwadbreite	77,25 km
Wiederholungsrate	ab 1 Tag

- ein Wegelayer, der alle Forstwege im Bestand darstellt,
- Ortho-Luftbilder (1 m Auflösung) und
- Digitales Geländemodell, 5 m Auflösung.

Befallsstichproben

Der Projektpartner stellte ein Vektor-Layer zur Verfügung, das die von den Revierförstern aufgenommenen Stichproben des Borkenkäferbefalls enthält. Die zugehörige Tabelle führt die Attribute „OBJEKT“ (Befallsklasse, vgl. Abschnitt 2.5 Zielklassen und Indexbildung) und „BEFALL“ (die Anzahl der befallenen Bäume). Die Geometrien liegen als Polygone (Kreise) mit 10 m Radius vor.

2.3 Bildkorrekturen

Unter Nutzung der vom TLWJF (Thüringer Landesanstalt für Wald, Jagd und Fischerei) bereitgestellten Geodaten (Ortho-Luftbilder, Digitales Geländemodell, vgl. Abschnitt 2.2) wurden die Satellitenbilder ortho-rektifiziert und in eine Lagegenauigkeit überführt, deren Genauigkeit im Sub-pixelbereich liegt (RMS = 4 m). Zur Unterdrückung reliefbedingter Beleuchtungsunterschiede sowie zur Reduktion atmosphärischer Einflussfaktoren wurde eine Atmosphärenkorrektur durchgeführt und Reflektanzen berechnet.

2.4 Aktualisierung des Fichten-Layers

Eine Analyse der Vektordaten, welche die Grenzen der reinen Fichtenbestände markieren, zeigte, dass sie zum Teil nicht mehr den aktuellen Gegebenheiten entsprachen. 47% aller Bestandeskartierungen und ihrer Attributierungen stammen aus einer Inventur aus dem Jahre 1993. Beispielsweise haben die Stürme Lothar (1999) und Kyrill (2007) in der Zwischenzeit zahlreiche Kahlflecken verursacht. Außerdem enthalten die bezeichneten Reinbestände immerhin noch Laubbäume mit einem Durchmischungsanteil von bis zu 10%. Daher musste vor der Analyse des Borkenkäferbefalls zunächst eine aktualisierte Fichtenmaske hergestellt werden. Über den Anteil der Kiefern in den Fichtenreinbeständen lagen keine Informationen vor.

Für die Unterscheidung von Laubwald, Fichten und Kahlflecken innerhalb der Grenzen des nicht mehr aktuellen Bestandesdaten-Layers wurde zunächst davon ausgegangen, dass sich die Fichten am besten vom Rest des Bildes abgrenzen lassen, wenn dafür die April-Szene (T1) verwendet wird, da sie immergrün sind und sich daher von den zu diesem Zeitpunkt noch nicht sprießenden Laubbäu-

men und der restlichen Vegetation markant durch ihr Vegetationssignal abheben. Mittels einer unüberwachten Klassifikation (kmeans clustering) der April-Szene wurden auf Basis des NDVI 20 Klassen gebildet. Als Klassifikationsmaske wurde das Bestandesdaten-Layer verwendet. Durch eine folgende visuelle Interpretation wurden die Klassen aggregiert und danach durch das Setzen eines Schwellenwertes in die Klassen „Fichte“ und „nicht Fichte“ aufgeteilt. In die Klasse „nicht Fichte“ wurden die in Frage kommenden Kandidaten für die Klassen „Kahlflecke“ und „Laubwald“ übernommen. Wasser und Schatten wurden wie alle außerhalb des Bestandesdatenlayers liegenden Pixel in die „Null-Klasse“ aggregiert. Die Klasse „nicht-Fichte“ diente im Weiteren als Bearbeitungsmaske für die Analyse des zweiten Zeitschnittes (Juni). Auch hier erfolgte die Bearbeitung sequenziell wie bei der April-Szene: kmeans-clustering, visuelle Interpretation, Klassenaggregation und Unterscheidung in „Laubwald“ und „Kahlflecken“ sowie Schwellenwertverfahren zur Herstellung der entsprechenden Bitmaps. Zuletzt wurden mittels SIEVE-Verfahren Einzelpixel eliminiert (Schwellwert 4 Pixel), um den Salz- und-Pfeffer Effekt zu reduzieren. Abschließend wurden alle Bitmaps in ein Raster-Layer

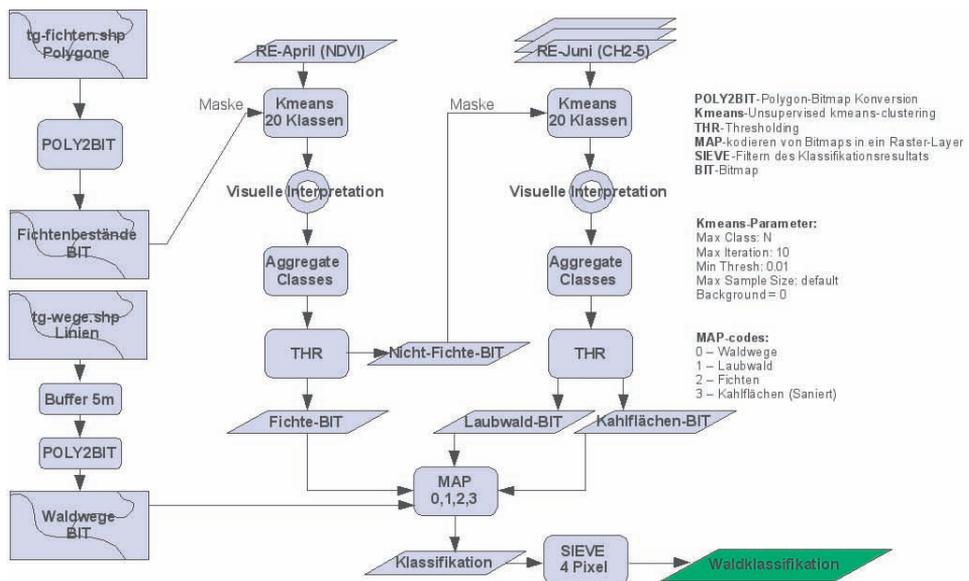


Abb. 1: Überblick multi-temporale Waldklassifikation (Aktualisierung des Fichten-Layers).

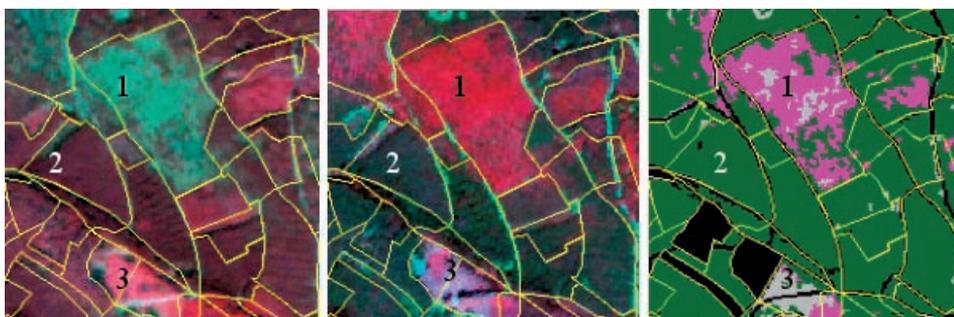


Abb. 2: Durch alle Jahreszeiten hindurch bleiben die Fichtenbestände (2, grün) phänologisch gesehen vergleichsweise stabil und sind von Laubbäumen und Kahlflächen gut unterscheidbar. Dagegen stehen die Laubholzbestände (1, violett), in diesem Falle Buchen, Mitte April erst kurz vor dem Austrieb und reflektieren noch kein Blattgrün. Im Juni sind die Blätter dann bereits voll entwickelt. Die Kahlflächen (3, grau) tragen im April, sofern sie nicht durch blanken Boden definiert sind, häufig eine von Kräutern, Gräsern, bisweilen auch Gebüsch und Baumanwuchs geprägte Vegetation. Sie lassen sich zumeist gut von den Fichten und Laubbäumen unterscheiden.

kodiert. Das Resultat der Prozedur ist die Waldklassifikation. Abb. 1 visualisiert das beschriebene Vorgehen.

Beispiele für die Erfassung der Waldklassen mittels multi-temporalen Datenanalyse zeigt Abb. 2.

Da die existierenden Bestandesdaten nicht mehr aktuell sind, können sie auch nicht zur Qualitätsbewertung verwendet werden. In Abstimmung mit dem Auftraggeber (TLWJF) wurden die Klassengenauigkeiten durch rein visuelle Beurteilung der Satellitenbilder wie folgt geschätzt: Fichten > 90 %, Laubwald: > 80 %, Kahlflächen > 90 %.

2.5 Analyse des Borkenkäferbefalls

Zielklassen und Indexbildung

Die Zielklassen wurden in Absprache mit dem Projektpartner definiert (siehe Tab. 2).

Für die weitere Analyse wurden nur Stichproben ausgewählt, die mehr als 30 befallene Bäume („BEFALL“ > 30) enthielten. Die Geometrien dienten alsdann der Extraktion der Trainingspixel aus der Zeitreihe. Neben den RapidEye-Kanälen wurden Indizes in die Analyse mit einbezogen, die sensitiv für Veränderungen des Chlorophyllgehaltes (vgl. Abschnitt 1.2) sind (siehe Tab. 3).

Nach der Selektion der geeigneten Probestellen enthält K1 = 9309, K2 = 127 und K3 = 217 Trainingspixel. K4 wurde bereits erfasst (vgl. Abschnitt 2.4 Aktualisierung des Fichtenlayers) und in der weiteren Analyse nicht weiter berücksichtigt.

In der Folge wurde eine explorative Datenanalyse durchgeführt, die dazu diente, die extrahierten Trainingspixel zu beurteilen. Die Analyse ergab, dass die untersuchten spektralen Merkmale in den Stichproben der Zielklassen weder normalverteilt waren (Kolmogorov-Smirnov-Test, $\alpha = 0,05$), noch ähnliche

Tab. 2: Zielklassen.

Klasse	Attribut	Eigenschaften
K1	Gesund	Nadeln der Fichten grün und vital
K2	Befallen	Nadeln der Fichten grün und vermindert vital
K3	Rot	Nadeln der Fichten rotbraun verfärbt, mit oder ohne Nadelverlust, absterbend oder bereits abgestorben
K4	Saniert	Kahlflächen

Tab. 3: Indizes.

Index	Formel	Referenz
Red Edge NDVI	$NDVI_{RedEdge} = \frac{Nir - RedEdge}{Nir + RedEdge}$	GITELSON et al. 1994
Green NDVI	$NDVI_{Green} = \frac{RedEdge - Green}{RedEdge + Green}$	BUSCHMANN und NAGEL 1993
RATIO	$RATIO = \frac{NDVI_{RedEdge}}{NDVI_{Green}}$	k.A.
Chlorophyll Green Model	$CGM = \frac{Nir}{Green} - 1$	GITELSON et al. 2005
Chlorophyll Red Edge Model	$CRM = \frac{Nir}{RedEdge} - 1$	GITELSON et al. 2005

Streuungen besaßen (Test auf Homogenität der Varianzen, Levene Statistik, $\alpha = 0,05$). Daher musste von überwachten Klassifikationsmethoden, welche Normalverteilung sowie Varianzgleichheit in den untersuchten Gruppen verlangen (BACKHAUS et al. 2003, JENSEN 1998), Abstand genommen werden (z.B. Maximum Likelihood Klassifikation).

Datamining – Erzeugung des Entscheidungsbaum-Modells

Als gültiger Ansatz zur Unterscheidung der Befallsklassen wurde daher auf die Datamining Software C5 der Firma RULEQUEST® zurückgegriffen. C5 erstellt regelbasierte, induktive Entscheidungsbaummodelle. Gegeben sein muss dabei ein Trainingsdatensatz, der alle potenziell zur Klassifikation beitragenden Merkmale enthält. Im Gegensatz zum Maximum Likelihood Klassifikator wird in den Trainingsdaten weder eine Normalverteilung der Merkmalsausprägungen vorausgesetzt, noch eine Homogenität der Varianzen. Es ist demnach ein nicht-parametrisches, also verteilungsfreies Verfahren. Bei dem Trainingsdatensatz ist die Klassenzugehörigkeit jedes Pixels bekannt (*supervised*).

Im vorliegenden Fall entspricht dies der Borkenkäferbefallsklasse. Der selbstlernende Algorithmus (*machine learning algorithm*) basiert auf dem Prinzip der sogenannten rekursiven Partitionierung. Der Lernprozess beginnt (*Induktion*) mit der Betrachtung der heterogenen Grundgesamtheit aller Daten (*start*

node). Bestimmten Regeln zufolge werden die am besten geeigneten Variablen ausgewählt (*black box*) und der Datensatz an Knotenpunkten (*nodes*) so oft multipel gegabelt, bis die Endknoten (*end nodes*) so homogen wie möglich sind und die günstigste Zuordnung der Fälle in ihre jeweilige Klasse gewährleistet wird. Dabei muss der beste Kompromiss gefunden werden zwischen „Übertrainieren“ und „Generalisieren“. Das so erzeugte Entscheidungsbaummodell wird dann auf den bisher ungesehenen Eingangsdatensatz, der alle im Modell verwendeten Merkmale enthalten muss, angewendet (*Deduktion*), und für jedes Pixel die Klassenzugehörigkeit vorhergesagt. Abb. 3 und 4 illustrieren das grundlegende Prinzip. Stichproben der Klasse „Saniert“ (Kahlflächen) wurden nicht in die Trainingsphase aufgenommen, da diese Klasse bereits mit hoher Genauigkeit als Nebenprodukt während der Erstellung der Fichtenmaske erzeugt wurde. Das Erzeugen und Trainieren des Entscheidungsbaum-Modells erfolgte getrennt für den 3-Klassen-Fall (Befallen, Rot, Gesund), und für den 2-Klassen Fall (Rot, Gesund). Aus der Trainingsphase resultierte die automatische Auswahl folgender Variablen: T1Green, T1Red, T1NDVIRE, T1RATIO, T2Green, T2Red, T2NDVIRE, T2RATIO. Nach dem Trainieren wurde das Modell auf die entsprechenden Datensätze angewendet. Zuletzt erfolgte eine Kodierung der Klasse „Saniert“ in die thematischen Ergebnismasken.

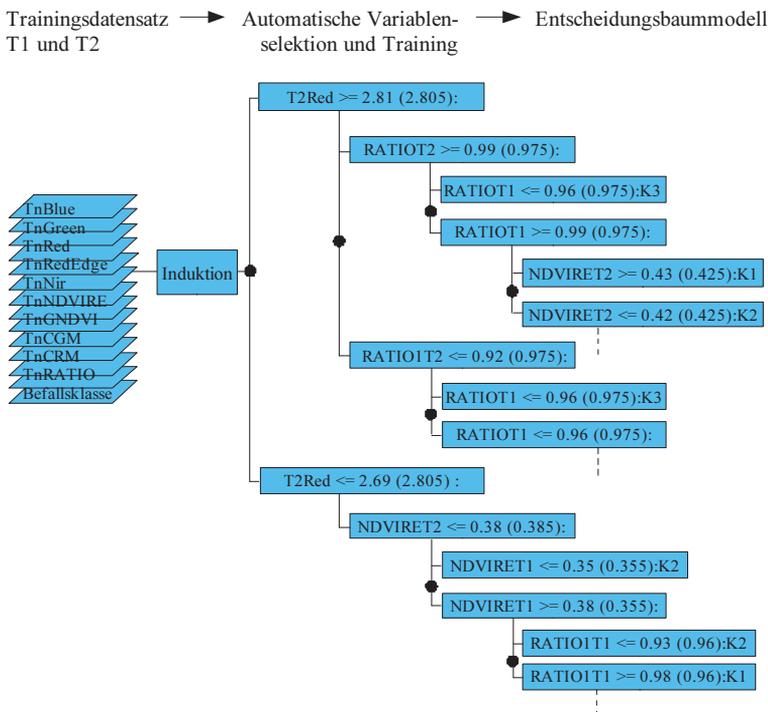


Abb. 3: Prinzip der Generierung des Entscheidungsbaummodells. An den Enden der multiplen Verzweigungen stehen die durch unterschiedliche Variablen und Regeln definierten Zielklassen (K1 = Gesund, K2 = Befallen, K3 = Rot).

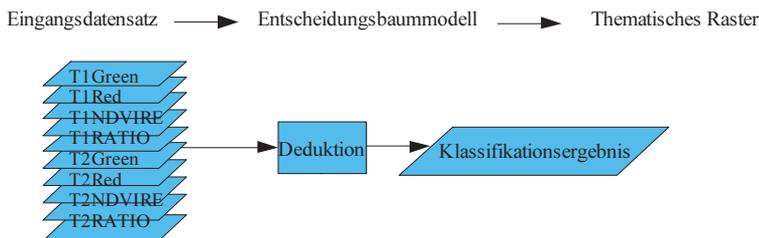


Abb. 4: Anwendung des Modells auf den bisher ungesehenen Datensatz.

3 Klassifikationsergebnisse und Qualitätsbewertung

Abb. 5 und 6 zeigen Ausschnitte aus den thematischen Ergebnisrastern.

Die Qualitätsbewertung (siehe Tab. 4 und 5) basiert auf einer 10-fachen Kreuzvalidierung der Trainingspixel, wobei bei jedem Durchlauf zufällig 10 % der Trainingspixel ausgewählt und zur Validierung des Modells zurückgehalten wurden. Daher ist sie auch ein

zulässiger Indikator für die Bewertung der Klassifikationsergebnisse.

Im 3-Klassen Fall ist ersichtlich, dass befallene Fichten hauptsächlich mit gesunden verwechselt werden. Von den insgesamt 127 Referenz-Pixeln der Klasse „Befallen“ werden 59 fälschlicherweise als „Gesund“ und 16 als „Rot“, klassifiziert (Herstellergenauigkeit). Demnach wurden 47 % der Klasse „Befallen“ nicht erkannt. 12,5 % der Klasse „Befallen“ wurden der Klasse „Rot“ zugeordnet. Umge-

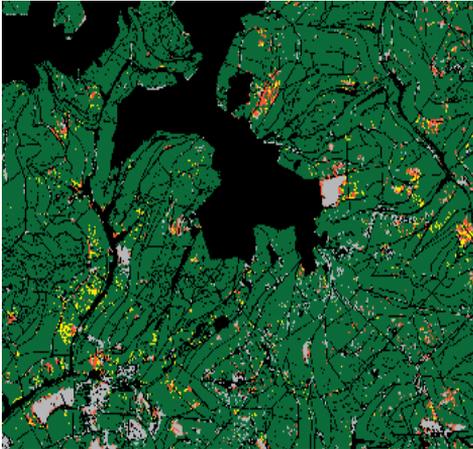


Abb. 5: Klassifikation in 4 Klassen: Gesund (grün), Befallen (gelb), Rot (rot), Saniert (grau).



Abb. 6: Klassifikation in 3 Klassen: Gesund (grün), Rot (rot), Saniert (grau).

Tab. 4: Confusion-Matrix der Befallsklassifikation (3 Klassen-Fall).

3 Klassen-Fall Referenz (Probeflächenpixel)	Klassifikation				Herstellergenauigkeit
	Befallen	Rot	Gesund	Summe	
Befallen	52	16	59	127	40,94 %
Rot	10	174	33	217	80,18 %
Gesund	6	9	9294	9309	99,84 %
Summe	68	199	9386	9653	
Nutzergenauigkeit	76,47 %	87,44 %	87,44 %		Kappa: 0,78

Tab. 5: Confusion-Matrix der Befallsklassifikation (2 Klassen-Fall).

2 Klassen-Fall Referenz (Probeflächenpixel)	Klassifikation			Herstellergenauigkeit
	Rot	Gesund	Summe	
Rot	178	39	217	82,03 %
Gesund	6	9303	9309	99,94 %
Summe	194	9342	9526	
Nutzergenauigkeit	96,74 %	99,58 %		Kappa: 0,89

kehrt gehören von 68 als „Befallen“ klassifizierten Fällen 10 in Wirklichkeit der Klasse „Rot“ und 6 der Klasse „Gesund“ an (Nutzergenauigkeit). Im 2-Klassen Fall fällt die durchschnittliche Genauigkeit der Klasse „Rot,“ mit

einer Herstellergenauigkeit von 82% und einer Nutzergenauigkeit von 97% höher aus als im 3-Klassen Fall. Bisher nicht quantifiziert wurden Fehlklassifikationen an den Bestandesrändern.

4 Diskussion

Multi-temporale RapidEye Daten sind eine geeignete Datenquelle, um rot verfärbte, absterbende oder bereits abgestorbene Fichten (Klasse K3) zu erfassen (vgl. Abschnitt 2.5 Zielklassen und Indexbildung). Befallene Fichten (Klasse K2) zeigen zwar einen Trend zur Detektierbarkeit, jedoch mit einer für die forstliche Praxis nicht verwertbaren Genauigkeit. Die erreichten Genauigkeiten für die Klasse K3 fallen dagegen wesentlich höher aus. Mit der Kartierung der Klasse K3 und ihrer alleinigen Abgrenzung von der Klasse K1 (gesund) ist eine operationelle Unterstützung des Borkenkäfer Monitoring in sofern möglich, als dass die Chancen für das Auffinden der befallenen Fichten erhöht werden, da die Besiedlung neuer Brutbäume im Frühjahr weitgehend in der Nähe der Schadstellen aus dem Vorjahr geschieht und im Vorjahr nicht alle Befallsnester durch Begehungen aufgefunden werden können.

Das Datamining, hier umgesetzt mit der Software C5, ist eine geeignete Methode, um basierend auf terrestrischen Referenzdaten und den verwendeten Bändern und Indices (vgl. Abschnitt 2.5 Zielklassen und Indexbildung) ein Entscheidungsbaummodell zu generieren, mit dem sich die Zielklassen (K1, K3) mit der beschriebenen Qualität abbilden lassen. Offen bleibt die Frage, ob sich das Modell auf das Folgejahr übertragen lässt. Um dies zu testen, müssten zu den gleichen Zeitpunkten T1 und T2 Daten aufgenommen werden. Ginge man davon aus, für jede Auswertung aktuelle Bodenreferenzdaten zur Verfügung zu haben, müsste untersucht werden, wie die Mindestgröße der Stichprobe sein muss, um dieselben Nutzer- und Herstellergenauigkeiten zu leisten.

Als positiver Nebeneffekt ist die Aktualisierung und Präzisierung der Fichtenvorkommen und deren Abgrenzung von laubabwerfenden Baumarten und Kahlflächen zu werten. Hier hat sich die Verwendung multi-temporalen Daten (ein Datensatz unmittelbar vor dem Beginn der Vegetationsperiode, ein Datensatz nach dem Einsetzen der Vegetationsperiode) als besonders gewinnbringend erwiesen. Als weiterführende Untersuchung wird hier die Detektierbarkeit der in den Fichten-

reinbeständen eingemischten Kiefern als sinnvoll erachtet.

Literatur

- BACKHAUS, K., ERICHSON, B., PLINKE, W. & WEIBER, R., 2003: Multivariate Analysemethoden – Eine Anwendungsorientierte Einführung. – 10. Auflage, 818 Seiten, Springer, Berlin.
- BUSCHMANN, C. & NAGEL, E., 1993: In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. – *International Journal of Remote Sensing* **14**: 711–722.
- CBCNEWS 2008: In Depth Science, The beetle and the damage done. – www.cbc.ca/news/background/science/beetle.html (18.2.2010).
- EPPO: Data Sheets on Quarantine Pests, *Ips typographus*, Prepared by CABI and EPPO for the EU under Contract 90/399003. – EPPO: European and Mediterranean Plant Protection Organization, www.eppo.org/QUARANTINE/insects/Ips_typographus/IPSXTY_ds.pdf (18.2.2010).
- FRANKLIN, S.E., LAVIGNE, M.B., MOSKAL, L.M., WULDER, M.A. & McCAFFREY, T.M., 2001: Interpretation of forest harvest conditions in New Brunswick using Landsat TM enhanced wetness difference imagery (EWDI). – *Canadian Journal of Remote Sensing* **27**: 118–128.
- GITELSON, A.A. & MERZLYAK, M.N., 1996: Remote estimation of chlorophyll content in higher plant leaves. – *International Journal of Remote Sensing* **18** (12): 2691–2697.
- GITELSON, A.A., VIÑA, A., CIGANDA, V., RUNDQUIST, D.C. & ARKEBAUER, T.J., 2005: Remote estimation of canopy chlorophyll content in crops. – *Geophysical Research Letters* **32**: L08403.
- HAN, J. & KAMBER, M., 2001: *Data Mining-Concepts and Techniques*. – Simon Fraser University, Morgan Kaufmann Publishers.
- HEATH, J., 2001: The detection of mountain pine beetle green attacked lodgepole pine using Compact Airborne Spectrographic Imager (CASI) data. – M.Sc. Thesis, Univ. British Columbia, Vancouver, B.C., Kanada.
- JENSEN, J.R., 1996: *Introductory Digital Image Processing*. – Pearson Prentice Hall Inc., Upper Saddle River, New Jersey, USA.
- NIERHAUS-WUNDERWALD, D. & FORSTER, B., 2004: Zur Biologie der Buchdruckerarten – Merkblatt für die Praxis. – Eidg. Forschungsanstalt WSL CH-8903 Birmensdorf, Bibliothek WSL, Schweiz.
- SKAKUN, R.S., WULDER, M.A. & FRANKLIN, S.E., 2003: Sensitivity of the thematic mapper en-

- hanced wetness difference index to detect mountain pine beetle red-attack damage. – *Remote Sensing of Environment* **86**: 433–443.
- TMNLU 2006: Forstbericht 2006. – Thüringer Ministerium für Landwirtschaft, Naturschutz und Umwelt, Beethovenstraße 3, 99096 Erfurt.
- WULDER, M.A., WHITE, J.C., BENTZ, B., ALVAREZ, M.F. & COOPS, N.C., 2005: Estimating the probability of mountain pine red-attack damage. – *Remote Sensing of Environment* **101**: 150–166.

Adresse des Autors:

ALEXANDER MARX M.Sc. Forest Information Technology, RapidEye AG, Molkenmarkt 30, Brandenburg an der Havel, Tel: +49-3381-8904-326, Fax -101, e-mail: marx@rapideye.de, colax@gmx.de.

Manuskript eingereicht: Februar 2010

Angenommen: April 2010