

Klassifikation von Fernerkundungsdaten zur Früherkennung von Borkenkäferschäden im Bayerischen Wald

MARTIN DRAUSCHKE¹ & PATRICK REIDELSTÜRZ²

Zusammenfassung: Im Kontext einer Machbarkeitsstudie zur Früherkennung von Borkenkäferbefall in Fichte wird ein Verfahren zur Klassifikation von Multispektraldaten vorgestellt und diskutiert. Die verwendeten Bilddaten stammen von einer 6-kanaligen Multispektralkamera aus einer Sportflugzeugbefliegung mit einer Flughöhe von 400 m über Grund. In zwei Experimenten werden Merkmale (Vegetationsindices) berechnet, die einerseits auf Erfahrungen in der Präzisionslandwirtschaft und andererseits auf dem Maschinellen Lernen basieren. Zur Klassifikation wurde der effektive Klassifikator Random Forest eingesetzt. Die Erkennung markanter Bäume (Strukturmerkmale) fällt mit einer Erkennungsrate von über 70% zufriedenstellend aus, der gesamte Klassifikationserfolg liegt bei 68% bei Verwendung von zehn Merkmalen bzw. bei 75%, wenn 101 Merkmale ausgenutzt werden.

1 Einleitung und Motivation

Der Borkenkäfer (insbesondere *Ips typographus*) ist einer der wirtschaftlich relevantesten Schädlinge in Wirtschaftswäldern und führt allein am Rand des Nationalparks Bayerischer Wald zu einem jährlichen Einschlag von 100 000 Festmeter Fichten-Käferholz.

Borkenkäferbefall wird nach internationalem Sprachgebrauch in drei Befallsstadien unterschieden: (1) *green attack stage* (Erstbefall eines Baumes mit vital erscheinender Baumkrone), (2) *red attack stage* (Rot-Färbung der Baumkrone) und (3) *grey attack stage* (Verlust der Nadelkrone und Tod des Baumes). Ein frischer Befall im *green attack stage* lässt sich äußerlich nicht ohne weiteres von gesunden Fichten unterscheiden.

Diese Arbeit bereitet eine Machbarkeitsstudie vor, in der der Einsatz schmalbandiger Multispektraldaten für die frühzeitige Erkennung befallener Fichten im *green attack* Stadium und deren Unterscheidung von unbefallenen Bäumen untersucht wird. Dazu werden Vegetationsindices analog zu erfolgreichen Ansätzen in der Präzisionslandwirtschaft wie z.B. (ZARCO-TEJADA et al., 2004) und ein effektiver, robuster Klassifikator für mehrere Klassen eingesetzt. Aufgrund fehlender terrestrischer Vergleichsdaten wird in dieser Studie eine UAV gestützte aerielle Waldzustandsinterpretation als Referenz für eine multispektrale Klassifikation herangezogen.

2 Versuchsaufbau

Als Datengrundlage dienen Bilder einer Cessna-Befliegung mit 400 m über Grund über einem Testgebiet im Nationalpark Bayerischer Wald am 5. August 2011. Im Außenbehälter wurde eine

¹ Martin Drauschke, Universität der Bundeswehr München, Institut für Angewandte Informatik, Werner-Heisenberg-Weg 39, 85577 Neubiberg; Email: martin.drauschke@unibw.de

² Patrick Reidelstürz, Hochschule Deggendorf, Technologie Campus Freyung, Grafenauer Straße 22, 94078 Freyung; Email: patrick.reidelstuerz@hdu-deggendorf.de

Multispektralkamera „TetraCam Mini MCA 6“ mitgeführt, die mit sechs schmalbandigen Filtern konfiguriert war (Tab. 1). Bei der Filterauswahl wurden diejenigen berücksichtigt, die erfolgreich in der Präzisionslandwirtschaft zur Bestimmung von Vegetationsindices eingesetzt werden. Unter dieser Priorität wurde bewusst auf einen Blau-Kanal verzichtet und damit auf die Möglichkeit, normale Farbbilder ableiten zu können.

Tab. 1: Verwendete Filter für die Erfassung schmalbandiger Intensitätsbilder.

| Band | b ₁ | b ₂ | b ₃ | b ₄ | b ₅ | b ₆ |
|-------------|----------------|----------------|----------------|----------------|----------------|----------------|
| Wellenlänge | 550 nm | 670 nm | 710 nm | 780 nm | 900 nm | 950 nm |

Auf der Untersuchungsfläche (Abb. 1) befinden sich zum Aufnahmezeitpunkt neben jungen und älteren unauffälligen Fichten und Buchen auch vom Borkenkäfer befallene Bäume in allen drei Stadien sowie Sturmholz.




Abb. 1: Untersuchungsfläche im Nationalpark Bayerischer Wald. Links: CIR-Bild mit den Bändern (b₄,b₂,b₁). Rechts: Bildkomposition aus den verbleibenden drei Bändern (b₃,b₅,b₆). Das Untersuchungsgebiet zeigt in der Bildmitte eine abgebrochene Sturmwurfauflösung mit geschältem Holz und oben links einen Sturmwurf. Im linken Bereich befinden sich Bodenbewuchs und Buchen, am unteren Bildrand Fichtenstangenholz. Rechts oberhalb der Auflösungsfläche befinden sich Fichten im red attack stage, dazwischen zum Auswertzeitpunkt nicht näher lokalisierte green-attack-Stadien sowie gesunde Fichten.

Die Kontrollbefliegung mit einem unbemannten Luftfahrzeug (3,2m Motorseglerkonfiguration) erfolgte am 18. November 2011, d.h. ca. drei Monate nach dem Multispektralflug. Die Bilder dieser Befliegung wurden photogrammetrisch orientiert und nach dem Fichten-Interpretationsschlüssel zur aeralen Waldzustandsinventur bei dreidimensionaler Betrachtung interpretiert (Abb. 2, nach HILDEBRAND, 1992). Diese Waldzustandsinventur auf Basis dreidimensionaler Strukturmerkmale ermöglichte eine manuelle Annotation (Abb. 3 links) von elf Zustandsklassen in 21 Bildern der Multispektralbefliegung, bei der diverse Bäume aus verschiedenen Blickwinkeln und unter verschiedenen Beleuchtungsverhältnissen erfasst wurden. Dabei wurden vier Klassen für Fichten definiert: gesunde (1) bzw. junge (2) Fichten, markante (3) Fichten aus der Waldzustandsansprache mit Hilfe von Strukturmerkmalen sowie Fichten im red- und grey-attack-Stadium (4). Hinzu kommen noch eine Klasse für die Buchen sowie

Klassen für Erdboden, Weg, Bodengewächse, Wasser, Holz (bearbeitet) und Sturmholz. Mit den letzten sechs genannten Klassen wird der Hintergrund modelliert.




Abb. 2: Stereomodel (anaglyph) zur großmaßstäbigen Kronenzustandsinterpretation aus der UAV-Befliegung




Abb. 3: Links: Manuelle Annotation einzelner Bereiche im Untersuchungsgebiet. Als Hintergrund wird das NIR-Band b_4 als Grauwertbild gezeigt. Rot markiert wurden markante Fichten, grün: gesunde Fichten, gelb: junge Fichten. Bereiche der Restklassen sind in verschiedenen Grautönen inkl. Schwarz visualisiert. Rechts: NDVI-Grauwertbild derselben Szene.

3 Methodik

Es werden zwei verschiedene Experimente durchgeführt. Zum einen werden zehn Vegetations- bzw. Chlorophyll-Indices manuell ausgewählt, die basierend auf Analysen von Multispektraldaten in der Präzisionslandwirtschaft auch für die Klassifikation von Borkenkäferschäden sinnvoll sein könnten. Zum anderen wird ein 101-dimensionaler Merkmalsraum verwendet, der die Intensitätswerte der sechs beobachteten Spektralbereiche sowie zahlreiche Kombinationen verschiedener Bänder analog zu den Vegetationsindices enthält. Die Vergrößerung des Merkmalsraums wird beim Maschinellen Lernen oft angewandt, um den Klassifikationserfolg zu verbessern (GUYON & ELISSEEFF, 2003).

MARX (2010) verwendet für seine Klassifikation von Borkenkäferschäden in Satellitenbildern einen einzelnen Entscheidungsbaum, der mit Hilfe der Software C5 der Firma RuleQuest konstruiert wird. Auf Grund der gelernten sieben Entscheidungen wird den Datensätzen eine Klasse zugeordnet. Die Klassifikationsmethode Random Forest verwendet dagegen viele solcher

Entscheidungsbäume und umgeht somit das Problem der Überangepasstheit des Klassifikators an die Trainingsdaten. Daher werden in beiden Experimenten die Merkmalsvektoren mit Random Forest nach (SHOTTON et al., 2008) klassifiziert. Um auch die Robustheit des Klassifikators beurteilen zu können, wurden aus den annotierten Bildbereichen zehn Mal voneinander verschiedene Trainings- und Testdaten ausgewählt.

3.1 Verwendete Merkmale: Vegetations- und Chlorophyll-Indices

Im ersten Versuch werden zehn Vegetations- bzw. Chlorophyll-Indices verwendet, von denen die meisten von ZARCO-TEJADA et al. (2004) einander gegenübergestellt und diskutiert werden. Alle diese Indices werden erfolgreich in der Präzisionslandwirtschaft eingesetzt, weil man mit ihnen gut vitale Vegetation von anderen Objekten unterscheiden kann.

Die ersten beiden ausgewählten Indices sind der Normalized Difference Vegetation Index NDVI (Abb. 2, rechts), d.h. die Verhältniszahl $b_4 - b_2$ zu $b_4 + b_2$, sowie der Green NDVI mit grünem anstatt roten Lichts ($b_4 - b_1$ zu $b_4 + b_1$). Es folgen die beiden Verhältniszahlen aus Red Edge zu Nahem Infrarot (b_3 zu b_4) sowie Grün zu Nahem Infrarot (b_1 zu b_4). Alle vier Merkmale werden schon seit vielen Jahren für die Erkennung von vitaler Vegetation in Multispektraldaten verwendet. Als fünftes Merkmal wird der Soil-Adjusted Vegetation Index SAVI, definiert nach (ZARCO-TEJADA et al., 2004) durch die Gleichung

$$m_5 = (1 + L) * \frac{(b_4 - b_2)}{(b_4 + b_2 + L)} \quad \text{mit } L = 0,4 \quad (1)$$

verwendet, der durch den Parameter L den Bodenanteil auf der beobachteten Fläche berücksichtigt. Die nächsten drei Merkmale, die Vegetationsindices TCARI und OSAVI sind nach (ZARCO-TEJADA et al., 2004) durch die Gleichung definiert:

$$m_6 = 3 * \left(b_3 - b_2 - 0.2(b_3 - b_1) \frac{b_3}{b_2} \right) \quad \text{und} \quad m_7 = 1,16 * \frac{b_4 - b_1}{b_4 + b_1 + 0,16} \quad (2)$$

Hinzu kommt noch ihr Verhältnis. Bei den letzten beiden Vegetationsindices handelt es sich um den Triangular Vegetation Index TVI bzw. eine seiner Modifikationen, der MTVI, definiert nach ZARCO-TEJADA et al. (2004) durch die Gleichung

$$m_8 = 60 * (b_3 - b_1) - 100 * (b_2 - b_1), \quad m_{10} = 1,44 * (b_4 - b_1) - 3 * (b_2 - b_1) \quad (3)$$

So ergibt sich ein 10-dimensionaler Merkmalsvektor für die pixelweise Klassifikation.

3.2 Verwendete Merkmale: Ansatz des Maschinellen Lernens

Bei einer genauen Betrachtung der oben erwähnten Merkmale kann man gut die Ähnlichkeit von NDVI, SAVI und OSAVI erkennen. Der Unterschied liegt in der unterschiedlichen Belegung des Parameters L . Beim NDVI gilt $L=0$, beim SAVI in diesen Experimenten $L=0,4$, und beim OSAVI gilt $L=0,16$. Für eine Interpretation der Szene bzgl. der Vitalität von Vegetation ist der Parameter L sicherlich hilfreich, um Aufnahmen unterschiedlicher Zeitpunkte oder Orte miteinander vergleichen zu können. Für die Klassifikation kann die Wahl von L allerdings unerheblich sein, da es nur zu einer Stauchung bzw. Streckung des Wertebereichs des Merkmals führt. Wenn es einen Klassifikator gibt, der die zu untersuchenden Klassen mittels NDVI gut voneinander trennen kann, dann lässt sich aus diesem auch ein erfolgreicher Klassifikator ableiten, der SAVI oder OSAVI verwendet. Somit kann aus Sicht des Maschinellen Lernens hinterfragt werden, ob die Auswahl der Merkmale in vorherigen Abschnitt 3.1 sinnvoll ist. Eine ähnliche Diskussion wird auch von TOKARCZYK et al. (2012) angeregt.

Stattdessen können beliebige Kombinationen von Bändern analog zu den Berechnungen der Vegetationsindex-Ratios oder der NDVI-Formel zur Konstruktion eines hochdimensionalen Merkmalsraums verwendet werden. Eine Vergrößerung der Dimension des Merkmalsraums mittels solcher kombinierter Merkmale wird von GUYON & ELISSEFF (2003) empfohlen, um den Klassifikationserfolg weiter zu verbessern.

In Konsequenz wird in unserem zweiten Experiment ein Merkmalsvektor mit 101 Komponenten konstruiert, dessen erste sechs Komponenten die Intensitätswerte der verschiedenen Bänder sind, d.h. $m'_k = b_k$, mit $k = 1, \dots, 6$. Dann wurden 6 über 2, d.h. 15 viele Kombinationen von Verhältniszahlen bestimmt:

$$m'_k = \frac{b_i}{b_j}, \text{ mit } k = 7, \dots, 21, i = 1, \dots, 6, j = i + 1, \dots, 6. \quad (4)$$

Andere Kombinationen sind nur Reziproke dieser 15 Merkmale und verbessern daher nicht die Klassifikation und können deshalb unberücksichtigt bleiben. Es folgen 15 Merkmale analog zum NDVI, d.h.

$$m'_k = \frac{b_i - b_j}{b_i + b_j}, \text{ mit } k = 22, \dots, 36, i = 1, \dots, 6, j = i + 1, \dots, 6. \quad (5)$$

Hinzu kommen noch dreimal 6 über 3, d.h. insgesamt 60 Merkmale mit einer Kombination von drei Merkmalen, wobei diese auf drei verschiedene Weisen angeordnet werden:

$$m'_k = \frac{b_i - b_j}{b_n + b_j}, \quad m'_k = \frac{b_j - b_i}{b_n + b_i}, \quad m'_k = \frac{b_i - b_n}{b_j + b_n}. \quad (6)$$

Die letzten fünf Merkmale werden aus dem ersten Experiment übernommen, u. z. TCARI, OSAVI, ihr Verhältnis, TVI und MTVI. Der OSAVI wurde nur deshalb berücksichtigt, weil die Verhältniszahl von TCARI und OSAVI berücksichtigt bleiben sollte.

3.3 Klassifikation mit Random Forests

Die pixelweise Klassifikation an Hand der beobachteten Merkmale wurde mit Random Forests aus N vielen binären Entscheidungsbäumen nach (SHOTTON et al., 2008) durchgeführt. Ein Entscheidungsbaum besteht aus zwei verschiedenen Knotenarten: den inneren Knoten und den Blattknoten. In den inneren Knoten werden die dort vorliegenden Trainingsdaten in zwei Teile geteilt und beide Teile in den jeweiligen Kinderknoten übertragen. In den Blattknoten werden die Wahrscheinlichkeiten der Klassenzugehörigkeiten aller in diesem Knoten gelandeten Trainingsdaten berechnet. Der rekursive Aufbau eines Binärbaums endet entweder, wenn alle Trainingsdaten zu einer Klasse gehören oder wenn zu wenige Trainingsdaten im Knoten vorhanden sind, um diese zu teilen.

Die N Entscheidungsbäume heißen Random Forest, weil in drei Schritten der Zufall ausgenutzt wird, um die Komplexität des Lernverfahrens klein zu halten. Zunächst wird jeder einzelne Entscheidungsbaum nur auf einem zufällig ausgewählten Teil der Trainingsdaten gelernt. Um keine Klasse zu bevorzugen, werden die Trainingsdaten so ausgewählt, dass eine Gleichverteilung der Klassen im Wurzelknoten eines jeden Entscheidungsbaums vorliegt. Dann ist auch die Entropie im Wurzelknoten maximal. Außerdem spielt der Zufall bei jeder Aufteilung der Trainingsdaten in den inneren Knoten eine Rolle: Mehrere Merkmale und Schwellwerte werden zufällig im entsprechenden Wertebereich ausgewählt. Nach SHOTTON et al. (2008) ist das Kriterium der maximalen Entropiereduzierung in den Kinderknoten eine sehr gute Entscheidung für die Auswahl des besten Merkmals und des besten Schwellwerts.

Wenn ein Random Forest auf neuen Daten angewandt wird, wird für jeden Datensatz in jedem der N Entscheidungsbäume der Blattknoten bestimmt, zudem der Datensatz auf Grundlage der hierarchisch angeordneten Entscheidungen gehört. Die Wahrscheinlichkeiten für alle

Klassenzugehörigkeiten werden über alle N Blattknoten aufsummiert, die Klasse mit der höchsten Summe wird als Klassifikationsergebnis ausgegeben.

Die Experimente dieser Arbeit werden mit jeweils $N = 200$ Entscheidungsbäumen in einem Random Forest durchgeführt. Wird N deutlich kleiner gewählt, sinkt der Klassifikationserfolg, bei einer größeren Anzahl von Entscheidungsbäumen, steigt nur die Laufzeit des Lernens, aber nicht mehr der Klassifikationserfolg. In allen Entscheidungsbäumen werden zehn Merkmale und zehn Schwellwerte zufällig ausgewählt, um die beste Entscheidung innerhalb eines inneren Knotens zu treffen.




Abb. 4: Visualisierung der Klassifikation mit Random Forests mit gesunden Fichten (grün), jungen Fichten (gelb), markanten Fichten aus der aerialen Waldzustandsinterpretation nach Strukturmerkmalen (rot), Fichten im *red-* bzw. *grey-attack*-Stadium (weiß), Buchen und Unterwuchs (türkis) und alle Restklassen (grau).

4 Ergebnisse

Für beide Experimente wird eine Kreuzvalidierung mit zehn Versuchen durchgeführt. Dazu werden dieselben 5000 Pixel je Versuch und Klasse aus den manuell annotierten Daten für das Training zufällig ausgewählt. Hinzu kommen weitere 5000 von den Trainingsdaten verschiedene und ebenfalls zufällig ausgewählte Pixel je Versuch und Klasse für die quantitative Beurteilung des Lernerfolgs. In jedem Versuch setzt sich der Klassifikator Random Forest aus 200 Entscheidungsbäumen zusammen. Nach Anwenden der gelernten Entscheidungsbäume des Random Forests werden die sechs Klassen *Erdboden*, *Weg*, *Bodengewächse*, *Wasser*, *Holz (bearbeitet)* und *Sturmholz* zu einer neuen Klasse *Rest* zusammengefasst. Das vereinfacht insbesondere die Darstellung von Konfusionsmatrizen (Tab. 2 und 3).

Die quantitative Analyse der Klassifikation ergibt einen Erkennungserfolg von 68% bei den zehn manuell ausgewählten Merkmalen sowie von 75% bei den 101 definierten Merkmalen. Jede Zeile dieser beiden Tabellen gibt den Prozentsatz an, mit dem ein Datensatz der Klasse (siehe Zeile) zu einer Klasse (siehe Spalte) klassifiziert wird. Die fett gedruckten Angaben stellen dabei den Erfolg der korrekt klassifizierten Datensätze an.

Die Klassifikation von Fichten im *red-* und *grey-attack*-Stadium (F-red/grey), Buchen und dem Rest liefert in beiden Versuchen die zuverlässigsten Ergebnisse. Bei der Klassifikation von gesunden bzw. jungen Fichten sowie markanten Fichten gibt es die größten Fehler. Die

Klassifikation mit zehn Merkmalen liefert in allen Fällen schlechtere Ergebnisse, teilweise um bis zu 8%.

Tab. 2: Konfusionsmatrix mit sechs Klassen für Klassifikation mit Random Forest bzgl. 10 Merkmale.

| | F-gesund | F-markant | F-red/grey | F-jung | Buche | Rest |
|------------|--------------|--------------|--------------|--------------|--------------|--------------|
| F-gesund | 0,388 | 0,197 | 0,000 | 0,305 | 0,101 | 0,008 |
| F-markant | 0,110 | 0,728 | 0,010 | 0,006 | 0,008 | 0,138 |
| F-red/grey | 0,000 | 0,000 | 0,746 | 0,000 | 0,000 | 0,254 |
| F-jung | 0,173 | 0,021 | 0,000 | 0,662 | 0,143 | 0,001 |
| Buche | 0,063 | 0,042 | 0,000 | 0,118 | 0,752 | 0,025 |
| Rest | 0,007 | 0,073 | 0,087 | 0,001 | 0,037 | 0,795 |

Tab. 3: Konfusionsmatrix mit sechs Klassen für Klassifikation mit Random Forest bzgl. 101 Merkmale.

| | F-gesund | F-markant | F-red/grey | F-jung | Buche | Rest |
|------------|--------------|--------------|--------------|--------------|--------------|--------------|
| F-gesund | 0,465 | 0,150 | 0,000 | 0,287 | 0,090 | 0,008 |
| F-markant | 0,087 | 0,755 | 0,004 | 0,012 | 0,017 | 0,125 |
| F-red/grey | 0,000 | 0,004 | 0,824 | 0,000 | 0,000 | 0,172 |
| F-jung | 0,152 | 0,015 | 0,000 | 0,742 | 0,090 | 0,001 |
| Buche | 0,038 | 0,041 | 0,000 | 0,062 | 0,835 | 0,023 |
| Rest | 0,002 | 0,042 | 0,067 | 0,000 | 0,021 | 0,868 |

Zu berücksichtigen bleibt, dass die Klasse der markanten Fichten nach dem Schlüssel zur aeralen Waldzustandserfassung aus dreidimensionalen Strukturmerkmalen nach den Stufen 2 und 3 abgeleitet wurden, wonach die Baumkrone nicht mehr optimal ausgeprägt, aber auch noch nicht offensichtlich stark geschädigt oder tot ist (HILDEBRAND, 1992). Das Interessante ist dabei einerseits, dass die Bäume in der schlechter aufgelösten Multispektralbefliegung drei Monate zuvor nach dem Interpretationsschlüssel unauffällig waren und andererseits, dass die aus dem UAV Flug abgeleitete Klasse nicht über thematische Spektralinformationen definiert ist. Die Interpretation analysiert dabei nicht die Ursache einer schlecht ausgeprägten Baumkrone, sondern lediglich, dass sich der Baum nicht im optimalen äußeren Erscheinungszustand befindet. Das muss nicht zwingend durch eine *green attack stage* des Borkenkäferbefalls ausgelöst sein, sondern kann genauso beispielsweise durch einen Schaden im Randbereich des Sturmwurfs durch Anschieben und Abreißen des Feinwurzelsystems des Baumes verursacht sein.

Die durch dreidimensionale Strukturmerkmale definierte Klasse *markante Fichte* (F-markant) ist in der schlechter aufgelösten Multispektralbefliegung drei Monate zuvor nach diesen Strukturmerkmalen also unauffällig und die Klassifikation erfolgt unabhängig von diesen Strukturmerkmalen nach thematischer Spektralinformation.

Es hat daher den Anschein, dass man Auffälligkeiten einer Baumkrone bei den dreidimensionalen Strukturmerkmalen auch mit einer Analyse inhaltlicher Information (Spektren) deutlich machen kann, ohne dass die dreidimensionalen Strukturmerkmale in den Multispektralbildern deutlich sind. Dabei ist nicht geklärt, ob die Merkmale in den Multispektralbildern wegen der geringeren Auflösung oder wegen des zeitlichen Vorlaufes von drei Monaten nicht sichtbar werden.

5 Ausblick

Die in diesem Aufsatz beschriebene Studie, wurde im Jahr 2012 mit einer durch die Bayerische Landesanstalt für Wald- und Forstwirtschaft finanzierten Machbarkeitsstudie zur Früherkennung von Borkenkäferbefall in Fichten mit Hilfe von Multispektraldaten fortgesetzt. Dadurch war es möglich, im Jahr 2012 harte Referenzdaten über den Verlauf des Borkenkäferbefalls zu dokumentieren. In insgesamt sechs Multispektralbefliegen können für einzelne Bäume nicht nur tatsächlicher Borkenkäferbefall im *green attack stage*, sondern auch die aktuellen Käferentwicklungsstadien zugewiesen werden. Das war durch ein intensives Dauermonitoring auf den Flächen sowie über die Rückrechnung von angebrachten Thermologgerdaten mit Abgleich der verfügbaren Daten aus dem Pheromonfallen-Monitoring über die Korrelation zur Tagestemperatursumme möglich.

Die Auswertungen sind zum aktuellen Zeitpunkt noch nicht abgeschlossen. Es bleibt abzuwarten, ob mit der vorgeschlagenen Methodik weitere Hinweise für die Machbarkeit einer Borkenkäferfrüherkennung mit schmalbandigen Multispektralinformationen abgeleitet werden können.

Danksagung

Die Autoren danken Christian Matera für die Annotation der Daten und für seine Unterstützung bei den vorbereitenden Arbeiten. Ein weiterer Dank für die Unterstützung geht an die Nationalparkverwaltung Bayerischer Wald und das Institut für Robotik und Mechatronik des DLR Oberpfaffenhofen. Nicht unerwähnt bleiben soll die uneingeschränkte Unterstützung und Begleitung der Studie durch Dr. Heinrich Rall, ehemaliger Leiter der Abteilung Forschung und Dokumentation im Nationalpark Bayerischer Wald.

6 Literaturverzeichnis

- GUYON, I. & ELISSEFF, A., 2003: An Introduction to Variable and Feature Selection, *Journal of Machine Learning Research*, **3** (Mar), S. 1157-1182.
- HILDEBRANDT, G. (Hrsg.), 1992: *Anwendungen der Fernerkundung zur Beurteilung des Gesundheitszustandes der Wälder*. Walphot, Belgien.
- MARX, A., 2010: Erkennung von Borkenkäferbefall in Fichtenreinbeständen mit multi-temporalen RapidEye-Satellitenbildern und Dataming-Techniken. *Photogrammetrie – Fernerkundung – Geoinformation*, **2010** (4), S. 243-252.
- SHOTTON, J.; JOHNSON, M. & CIPOLLA, R., 2008: Semantic Texton Forests for Image Categorization and Segmentation, *IEEE Conference on Computer Vision and Pattern Recognition*.
- TOKARCZYK, P.; MONTOYA, J. & SCHINDLER, K., 2012: An Evaluation of Feature Learning Methods for High Resolution Image Classification, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **1-3**, S. 389-394.
- ZARCO-TEJADA, P.J.; BERJÓN, A. & MILLER, J.R., 2004: Stress Detection in Crops with Hyperspectral Remote Sensing and Physical Simulation Models, *Airborne Imaging Spectroscopy Workshop*.