

## Einfluss der spektralen und räumlichen Auflösung von Fernerkundungsdaten bei der Nadelwaldklassifikation

MARTIN SCHLERF, JOACHIM HILL, SAMUEL BÄRISCH & CLEMENT ATZBERGER, Trier

**Keywords:** remote sensing, imaging spectrometry, spatial resolution, classification, forest

**Zusammenfassung:** Optische Fernerkundungsdaten wurden zur Kartierung von Nadelwaldflächen im westlichen Hunsrück eingesetzt. Es war zu untersuchen, ob hyperspektrale Daten einen höheren Informationsgehalt zur Unterscheidung von Baumarten und Altersklassen besitzen als multispektrale Daten. Zudem war zu prüfen, welchen Einfluss die räumliche Auflösung der Datensätze auf das Klassifikationsergebnis hat.

Die radiometrisch aufbereiteten und geometrisch korrigierten, hyperspektralen Reflexionsdaten aus dem Jahr 1999 wurden einem Verfahren zur Datenreduktion und -verbesserung unterzogen. Multispektrale TM-Daten wurden über eine spektrale bzw. geometrische Degradation aus den räumlich und spektral hoch aufgelösten Hyperspektraldaten abgeleitet. Es konnten drei verschiedene Datensätze erzeugt werden: spektral degradiert, räumlich degradiert und eine Kombination aus beidem. Die Datensätze wurden mit dem Spectral Angle Mapper klassifiziert.

Die Ergebnisse zeigen, dass die Kartierung der Nadelwaldflächen durch die Verwendung von Hyperspektraldaten gegenüber Multispektraldaten verbessert wird. Die Klassifikationsgenauigkeiten für die räumlich hoch aufgelösten Bilddaten ist jedoch geringer als für die geometrisch degradierten Daten, was dadurch erklärt werden kann, dass letztere eine geringere Bildvarianz aufweisen.

**Summary:** *Influence of the spectral and the spatial resolution of remote sensing imagery on forest classification.* Optical remote sensing imagery was classified to map coniferous forest cover for a study area located in the Western Hunsrück, Germany. Our objectives were to investigate if hyperspectral data contains more information relevant to the classification of species and age classes than multispectral imagery and to look at the influence of the spatial resolution on the classification accuracies.

Airborne hyperspectral data (HyMap) covering the entire test site has been acquired for July 1999. Subsequent to radiometric and geometric correction, data reduction and enhancement was performed by a Minimum Noise Fraction transformation. Multispectral data (TM) was simulated through degradation of the spectral and/or spatial information of the HyMap data. Three different synthetic datasets were created: spectrally degraded, spatially degraded and a combination of both. The classification was performed with the Spectral Angle Mapper algorithm.

The results show that mapping of coniferous forest cover is improved by the use of hyperspectral compared to multispectral data but that classification accuracy is lower using high spatial resolution data compared to spatially degraded data. This is explained by the lower image variance of the latter data set.

### 1 Einleitung

Die Kenntnis der Baumarten und Altersstrukturen in Waldökosystemen spielt im Forstmanagement eine wichtige Rolle. So wird beispielsweise die Baumartenzusammensetzung von Forstbeständen im Rahmen der Aktualisierung der Forsteinrich-

ungsdaten in regelmäßigen Abständen erfasst und Holzvorratsschätzungen sind in hohem Maße abhängig vom Bestandsalter. Auch in biogeochemischen Prozessmodellen, wie z. B. Forest-BGC (RUNNING & COUGHLAN 1988, RUNNING et al. 1994) erfolgt die Parametrisierung bestimmter Ein-

gangsvariablen in Abhängigkeit von der jeweiligen Baumartenspezies.

Die Kartierung von Wäldern hinsichtlich ihrer Baumarten- und Altersverteilung aus Luftbildern stellt in der forstlichen Praxis ein gängiges Verfahren dar. Multispektrale Fernerkundungsdaten wurden bereits zur Unterscheidung von Nadel- und Laubwäldern (z. B. NELSON et al. 1985, HILL et al. 1995) und von Baumarten (z. B. WALSH 1980, FRANKLIN 1994, VOHLAND, 1997) eingesetzt. Eine genauere Erfassung von Forst-ökosystemen hinsichtlich ihrer ökologischen Eigenschaften wird mit hyperspektralen Fernerkundungsdaten angestrebt. So sind Hyperspektraldaten in forstwissenschaftlichen Untersuchungen bislang hauptsächlich zur Ableitung blattchemischer Größen (PETERSON et al. 1988, WESSMAN et al. 1988, JOHNSON et al. 1994, GASTELLU-ETCHEGORRY et al. 1995) und struktureller Parameter, wie z. B. des Blattflächenindex (GONG et al. 1992, UDELHOVEN et al. 2000) zur Anwendung gekommen. Jedoch haben sich wenige Studien mit der Kartierung von Baumartenspezies aus hyperspektralen Daten befasst. Mit *in situ* Hyperspektraldaten konnte eine Unterscheidung von sechs Koniferenarten (GONG et al. 1997) und mehrerer tropischer Baumarten (COCHRANE 2000) erzielt werden. Erfolge bei der Klassifikation von Waldbaumarten aus hyperspektralen Bilddaten zeigten Untersuchungen von FRANKLIN (1994) und MARTIN (1998). Derartige Datensätze wurden mit eingeschränktem Erfolg auch dazu verwendet, die Altersstruktur im Forst zu erfassen (NIEMANN 1995, KÖHL & LAUTNER 2001).

Bilddaten, die mittels flugzeuggestützter Bildspektrometer aufgezeichnet werden, haben in der Regel sowohl eine hohe spektrale als auch geometrische Auflösung. Beim Übergang zu satellitengestützten Sensoren muss aus technischen Gründen entweder eine geringere räumliche oder spektrale Auflösung in Kauf genommen werden. So hat beispielsweise der auf der EO-1 Plattform befindliche Hyperion-Sensor 220 Bänder (von 0,4 bis 2,5  $\mu\text{m}$ ) und eine räumliche Auflösung von 30 m. Dagegen weist der Ikonos-Sensor 4 Bänder bei einer Pixelgröße von

4 m auf. Es stellt sich daher die Frage, ob zur Klassifikation von Waldflächen eher eine hohe spektrale oder vielmehr eine hohe geometrische Auflösung der Bilddaten anzustreben ist.

## 2 Zielsetzung

Das in der vorliegenden Studie verfolgte Ziel war, die Eignung von vier Datensätzen mit unterschiedlicher spektraler und geometrischer Auflösung für die Erfassung von Baumarten und -alter für Nadelwälder zu vergleichen. Damit verbunden wurden zwei Hypothesen formuliert:

*Hypothese 1:* Hyperspektrale Daten enthalten ein größeres Maß an Informationen, die für die Waldklassifikation relevant sind, als multispektrale. Daher wird für den Datensatz hoher spektraler Auflösung eine bessere Klassifikationsgenauigkeit erwartet als für den geringer aufgelösten. Während multispektrale Sensoren das reflektierte Signal nur in wenigen Spektralkanälen aufzeichnen, erfassen Hyperspektralsensoren das gesamte Reflexionsspektrum. Hierfür stehen Analysemethoden zur Verfügung, die die gesamte im Spektrum enthaltene Information nutzen.

*Hypothese 2:* Räumlich hoch aufgelöste Daten enthalten mehr Informationen, die für die Waldklassifikation relevant sind, als Daten geringer geometrischer Auflösung. Daher wird für den Datensatz mit einer Pixelgröße von 5 m eine bessere Klassifikationsgenauigkeit erwartet als für den 30-m-Datensatz.

## 3 Untersuchungsgebiet und Datengrundlage

Das Untersuchungsgebiet (49°40'N, 7°10'E) umfasst den im westlichen Hunsrück gelegenen Idarwald. Der Höhenzug des Hunsrücks, morphologisch durch einen NE-SW streichenden Härtingsrücken gekennzeichnet, ist aus unterdevonischem Taunusquarzit aufgebaut. Auf den nährstoffarmen, zum Teil stark versauerten Böden bilden arten-


arme Buchenwälder die natürlichen Waldgesellschaften. Heute nimmt jedoch die Fichte (*Picea abies*), mit der ab dem Ende des 18. Jahrhunderts aufgeforstet wurde, den größten Flächenanteil ein, gefolgt von Buche (*Fagus sylvatica*), Traubeneiche (*Quercus petraea*) und Douglasie (*Pseudotsuga menziesii*) (Arbeitskreis Standortkartierung 1985).

Hyperspektrale Bilddaten wurden im Juli 1999 aufgenommen. Der verwendete HyMap-Sensor erfasst den Wellenlängenbereich von 400 bis 2500 nm in 128 Spektralkanälen bei einer spektralen Bandbreite von 10–20 nm. Die geometrische Auflösung wurde über die Flughöhe auf fünf Meter festgelegt. Die radiometrische Korrektur der Bilddaten erfolgte am RSD der Universität Trier nach einem von HILL et al. (1995) entwickelten Verfahren. Dabei wurden die aufgezeichneten Grauwerte zunächst über eine Sensorkalibrierung in Strahldichten umgerechnet und dann atmosphärisch und topographisch bedingte Einflüsse eliminiert. Die Geocodierung des Datensatzes wurde mit der Software PARGE (SCHLÄPFER et al. 1998) durchgeführt.

Das zur Verfügung stehende forstliche geographische Informationssystem (FoGIS) enthält die aktuellen Forsteinrichtungsdaten (Stichtag: 01. 10. 1994) in aufbereiteter Form. Das FoGIS deckt nahezu den gesamten HyMap-Flugstreifen ab und stellt im Wesentlichen bestandsweise Informationen zur Baumartenzusammensetzung und Altersstruktur zur Verfügung (VOHLAND 1997).

#### 4 Methoden

In Vorbereitung auf die Klassifikation wurden einige Schritte der Datenvorverarbeitung durchgeführt. Da sich die weitere Klassifikation ausschließlich auf Nadelwaldbestände beschränkte, wurden Bildpixel, die keinen Nadelwald repräsentieren, ausmaskiert. Dies erfolgte über eine Nadelwaldmaske, die mittels einer unüberwachten Klassifikation (Isodata-Algorithmus) aus den Hyperspektraldaten erzeugt wurde. Aus dem resultierenden Datensatz konnten alle



**Abb. 1:** Vier Datensätze unterschiedlicher spektraler und räumlicher Auflösung. Oben links: TM 30 m, oben rechts: TM 5 m, unten links: HyMap 30 m, unten rechts: HyMap 5 m.

vier zu klassifizierenden Datensätze berechnet werden (Abb. 1).

##### 4.1 Minimum Noise Fraction Transformation

Der hyperspektrale Datensatz musste einem Verfahren der Datenreduktion und -verbesserung unterzogen werden. Dies ist notwendig, da von abbildenden Spektrometern erfasste Fernerkundungsdaten aufgrund ihrer hohen spektralen Auflösung ein hohes Maß an redundanter Information enthalten; lange Rechenzeiten und Schwierigkeiten bei der Klassifikation können die Folge sein. Als Standardmethode zur Reduktion und Verbesserung von hyperspektralen Fernerkundungsdaten hat sich die Minimum Noise Fraction (MNF) Transformation (GREEN et al. 1988, LEE et al. 1990) entwickelt. Die MNF berechnet, ähnlich der Hauptkomponentenanalyse, für Linearkombinationen der ursprünglichen Spektralwerte Gewichte, mit denen das Koordinatensystem durch Drehung der Achsen in ein neues rechtwinkliges Achsensystem transformiert wird. Die neuen Achsen stellen die Faktoren dar. Diese sind mit zunehmender Ordnungszahl nach sukzessiv abnehmendem Signal-Rausch Verhältnis geordnet. Somit lassen sich die Komponenten mit hohem Informa-

tionsgehalt von den nur noch wenig Information enthaltenen abtrennen. Bei den verwendeten Bilddaten wurden anhand eines Eigenwert-Plots 19 MNF-Bänder mit den höchsten Eigenwerten von den restlichen Komponenten mit hohem Rauschanteil abgetrennt und für die weitere Datenauswertung verwendet.

Der multispektrale Datensatz wurde erzeugt, indem aus den Hyperspektraldaten die Bänder selektiert wurden, die den zentralen Wellenlängenpositionen der TM Kanäle entsprechen. Die beiden multi- und hyperspektralen Datensätze wurden schließlich räumlich degradiert, indem die 5 m Bildpixel durch Mittelwertbildung in 30 m Pixel überführt wurden (Abb. 1).

#### 4.2 Training

Als Grundlage einer überwachten Klassifizierung wird in der Trainingsphase versucht, das spektrale Muster der zu untersuchenden Objektklassen möglichst repräsentativ in den verschiedenen Erscheinungsformen zu erfassen. Die Extraktion der Spektralsignaturen erfolgte unter Zuhilfenahme der im FoGIS enthaltenen Bestandspolygone (5-15 Polygone pro Objektklasse, 100-1000 Pixel pro Polygon). Es wurden nur solche Objektklassen berücksichtigt, die durch mindestens drei Bestände vertreten waren. Die Bestandspolygone sind zuvor nach innen gebuffert worden, um Mischpixel, die an den Bestandsgrenzen auftreten können, auszuschließen. Bereiche mit stark abweichendem Reflexionsverhalten, beispielsweise Sturmwurfflächen, die noch nicht im FoGIS ausgewiesen waren, wurden nach visueller Überprüfung ausgeschlossen. Die Trainingsdaten wurden über einen Zufallsgenerator in drei Pixeluntergruppen aufgeteilt: 10 Prozent für Trainingszwecke (Trainingspixel), 25 Prozent zur Validierung der Klassifikationsergebnisse (Validierungspixel); die verbleibenden 65 Prozent Pixel wurden nicht weiter verwendet. Mit dieser Gestaltung der Trainingsphase konnte die oftmals schwierige Aufteilung der Trainingsdaten in räumlich zusammenhängende Trainings- und Validierungsflächen vermieden werden,

die, je nach Art der Aufteilung, unterschiedliche Klassifikationsergebnisse zur Folge haben kann. Der relativ geringe Umfang an Trainingspixeln trägt der Tatsache Rechnung, dass in der Praxis zeitaufwendig zu erhebende Geländedaten häufig nur in eingeschränktem Umfang zur Verfügung stehen. Nach einer visuellen Analyse der extrahierten Reflexionsspektren wurde entschieden, sechs Objektklassen zu unterscheiden (vier Altersklassen bei Fichte und zwei Altersklassen bei Douglasie). Mit zunehmendem Bestandsalter zeigt sich insbesondere im nahen Infrarot eine starke Abnahme der Reflexion (nicht gezeigt). Douglasien haben ein generell höheres Reflexionsniveau als Fichten gleichen Alters. Während die jüngeren Altersklassen gut voneinander separierbar erscheinen, sind insbesondere für die Trennung von Baum- und Altholz (Fichte) Schwierigkeiten zu erwarten.

#### 4.3 Klassifikation und Validierung

Für die Klassifikation wurde der Spectral Angle Mapper (KRUSE et al. 1993) eingesetzt. Dieses Verfahren ist relativ unempfindlich gegenüber Beleuchtungs- und Albedoeffekten. Der Algorithmus vergleicht in einem ersten Schritt im n-dimensionalen Merkmalsraum pixelweise jedes Bildspektrum (unbekannte Klasse) mit jedem der 44 Trainingsspektren (bekannte Klasse) und berechnet den dazugehörigen spektralen Winkel. Im Klassifikationsschritt wird dann einem Bildpixel die Objektklasse zugewiesen, die den geringsten Spektralwinkel aufweist. Im Anschluss an die Klassifikation wurden die 44 Unterklassen zu 6 Hauptklassen zusammengefasst. Einzelne, fehlklassifizierte Bildpixel konnten im Postklassifizierungsschritt (sieve and clump) entfernt werden.

Die Validation der Klassifikationsergebnisse erfolgte anhand der 25 Prozent Bildpixel, die nicht in den Trainingsprozess mit eingegangen waren. Für jede Klassifikation wurde eine Konfusionsmatrix errechnet, indem die tatsächliche Klasse eines Referenzpixels mit der in der Klassifikation zugewiesenen Klasse verglichen wird. Zwei Maße



für die Klassifikationsgenauigkeit wurden berechnet. Die Gesamtklassifikationsgenauigkeit (Overall Accuracy, OAA) quantifiziert den Prozentanteil korrekt klassifizierter Pixel:

$$OAA = \frac{\sum_{k=1}^q n_{kk}}{n} \cdot 100 \quad (1)$$

wobei  $n_{kk}$  die Anzahl der korrekt klassifizierten Validierungspixel (Diagonale der Konfusionsmatrix),  $q$  die Anzahl an Klassen und  $n$  die Gesamtzahl der Validierungspixel bezeichnet. Der Kappa Koeffizient kompensiert Effekte, die sich durch eine zufällige Übereinstimmung ergeben (FOODY 2002):

$$KAPPA = \frac{n \sum_{k=1}^q n_{kk} - \sum_{k=1}^q n_{k+} n_{+k}}{n^2 - \sum_{k=1}^q n_{k+} n_{+k}} \quad (2)$$

wobei  $n_{k+}$  die Summe der Validierungspixel in einer Klasse und  $n_{+k}$  die Summe der klassifizierten Pixel in dieser Klasse darstellt.

## 5 Ergebnisse und Diskussion

Die Ergebnisse der Klassifikationen sind anhand der Gesamtklassifikationsgenauigkeiten und der Kappa-Koeffizienten in Tab. 1 zusammengefasst. Detaillierte Angaben zu den Klassifikationsgenauigkeiten der einzelnen Objektklassen finden sich in SCHLERF et al. (2002). Für einen Datensatz (hyperspektral, 5 m) ist das klassifizierte Bild bei-



**Abb. 2:** Trainingsgebiete über Hyperspektraldaten (HyMap-Bänder 83-29-15) (links); Klassifikationsergebnis und überlagerte Bestandsgrenzen (rechts); blau: Fichte-Altholz, gelb: Fichte-Baumholz, grün: Fichte-Stangenholz, cyan: Fichte-Dickung, rot: Douglasie-Stangenholz, orange: Douglasie-Dickung.

**Tab. 1:** Zusammenfassung der Klassifikationsergebnisse.

Datensatz	Gesamtklassifikationsgenauigkeit (%)	Kappa Koeffizient
A: HyMap 5 m	81.4	0.78
B: HyMap 30 m	95.0	0.94
C: TM 5 m	55.9	0.47
D: TM 30 m	69.5	0.64

spielhaft in Abb. 2 dargestellt. Insgesamt ergeben die hyperspektralen Datensätze deutlich bessere Klassifikationsergebnisse als die multispektralen Datensätze, mit Unterschieden von etwa 25 Prozent (OAA) bei beiden Varianten unterschiedlicher geometrischer Auflösung. Damit wird die zuvor aufgestellte Hypothese 1 eindeutig belegt. Offensichtlich ist die Information zur Unterscheidung von Baumarten und Altersklassen nicht vollständig in wenigen spektralen

Bändern sondern im gesamten Reflexionsspektrum enthalten. Ähnliche Ergebnisse zeigten sich auch in vergleichbaren Untersuchungen. So konnte beispielsweise bei der Schätzung des Blattflächenindex mit Hyperspektraldaten eine größere Genauigkeit als mit Multispektraldaten erzielt werden (GONG et al. 1992).

Die geometrisch hoch aufgelösten Datensätze zeigen hingegen deutlich schlechtere Klassifikationsergebnisse als die gering aufgelösten Datensätze; die Unterschiede betragen hier annähernd 14 Prozent (OAA) im hyperspektralen als auch im multispektralen Fall. Somit wird Hypothese 2 klar widerlegt; vielmehr kann für das hier verwendete Verfahren belegt werden, dass eine Zunahme der räumlichen Auflösung bei der Klassifikation von Nadelwaldflächen zu schlechteren Ergebnissen führt. Die Gründe liegen darin, dass sich insbesondere Fichten durch eine mit dem Alter zunehmende Kronendachrauigkeit auszeichnen (SCHARDT 1990). Dies hat zur Folge, dass die Baumkronen im geometrisch hoch aufgelösten Bild einen beleuchteten und einen beschatteten Teil aufweisen, was sich durch kleinräumige Variationen im Spektralverhalten zeigt. Dies wird noch dadurch verstärkt, dass Lücken im Kronendach aufgelöst werden, deren Reflexionsverhalten sich durch Einflüsse des Unterwuchses oder der Bodenstreu stark von dem der Baumkronen abhebt. Diese Effekte werden im räumlich gering aufgelösten Datensatz durch Verringerung der Bildvarianz ausgeglichen. Ähnliche Resultate sind auch in der Literatur zu finden. So existieren Untersuchungen, in denen eine Zunahme der räumlichen Auflösung ebenfalls keine Erhöhung der Klassifikationsgenauigkeiten ergeben hat (MARTIN & HOWARTH 1989).

## 6 Ausblick

Das Potential verschiedener Sensoren zur Erfassung von Waldflächen ist bislang noch nicht eindeutig identifiziert worden. Gegenwärtige und zukünftige Sensorentwicklungen streben eine Erhöhung der räumlichen und/oder spektralen Auflösung an. Die Ergebnisse der vorliegenden Untersuchung be-

legen, dass die Klassifikation von Nadelwaldflächen durch eine Erhöhung der spektralen Auflösung verbessert wird. Dagegen wurde durch eine Erhöhung der räumlichen Auflösung keine Verbesserung erzielt. Allerdings wurden mit Textureigenschaften verbundene Informationen, die möglicherweise in den Daten enthalten sind, nicht berücksichtigt.

Ein alternatives Konzept der digitalen Bildverarbeitung betrachtet nicht einzelne Bildpixel, sondern homogene Pixelgruppen, so genannte Bildobjekte. Bei diesen objektbasierten Ansätzen werden homogene Pixelgruppen klassifiziert, die aus kontextueller Bildinformation abgeleitet werden (BLASCHKE & STROBL 2001). Es wird daher zukünftig angestrebt, die vorgestellte pixelbasierte Klassifikation im Sinne einer weiteren räumlichen Degradation auf Basis von Objekten durchzuführen. Zu diesem Zweck ist geplant, einen von ATZBERGER (2003; dieses Heft) entwickelten Ansatz anzuwenden. Danach werden auf einem segmentierten Bild für jedes Bildobjekt spektrale Objektsignaturen (wie z. B. Steigung und Bestimmtheitsmaß der linearen Relationen zwischen zwei Spektralkanälen) berechnet. Diese den Objekten eigene Texturinformation kann anschließend mit in den Klassifizierungsprozess einfließen und möglicherweise zu besseren Klassifizierungsergebnissen führen.

## Danksagung

Die Untersuchung wurde von der Deutschen Forschungsgemeinschaft (DFG) im Rahmen des SFB 522 „Umwelt und Region“ gefördert. Wir danken Dr. PATRICK HOSTERT (Humboldt-Universität, Berlin), Dr. THOMAS UDELHOVEN, WOLFGANG MEHL (Joint Research Centre; Ispra, Italy) und SEBASTIAN MADER für die gewährte Unterstützung bei der Vorverarbeitung der HyMap-Daten. Das Forst-GIS wurde dankenswerterweise von MICHAEL VOHLAND bereitgestellt. Herrn ANDREAS MÜLLER und Frau ANDREA HAUSOLD vom Deutschen Zentrum für Luft- und Raumfahrt danken wir für die erfolgreiche Befliegung mit dem HyMap-Sensor.

## Literatur

- ARBEITSKREIS STANDORTKARTIERUNG, 1985: Forstliche Wuchsgebiete und Wuchsbezirke in der Bundesrepublik Deutschland. – Münster.
- ATZBERGER, C., 2003: Möglichkeiten und Grenzen der fernerkundlichen Bestimmung biophysikalischer Vegetationsparameter mittels physikalisch basierter Reflexionsmodelle. – Photogrammetrie, Fernerkundung, Geoinformation, **2003** (1): 51–61 (dieses Heft).
- BLASCHKE, T. & STROBL, J., 2001: What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. – GIS, **6**: 12–17.
- COCHRANE, M. A., 2000: Using vegetation reflectance variability for species level classification of hyperspectral data. – Int. Jour. Rem. Sens., **10**: 2075–2087.
- FOODY, G. M., 2002: Status of land cover classification accuracy assessment. – Remote Sens. Environ., **80**: 185–201.
- FRANKLIN, S. E., 1994: Discrimination of subalpine forest species and canopy density using digital CASI, SPOT PLA, and Landsat TM data. – Photogr. Eng. & Rem. Sens., **60** (10): 1233–1241.
- GASTELLU-ETCHEGORRY, J. P., ZAGOLSKI, F. MOUTIN, E. et al., 1995: An assessment of canopy chemistry with AVIRIS – a case study in the Landes Forest, South-west France. – Int. Jour. Rem. Sens., **16** (3): 487–501.
- GONG, P., PU, R. & MILLER, J. R., 1992: Correlating leaf area index of Ponderosa pine with hyperspectral CASI data. – Canadian Journal of Remote Sensing, **18**: 275–282.
- GONG, P., PU, R. & YU, B., 1997: Conifer species recognition: an exploratory analysis of in situ hyperspectral data. Remote Sens. Environ., **62**: 189–200.
- GREEN, A. A., BERMAN, M., SWITZER, P. et al., 1988: A transformation for ordering multispectral data in terms of image quality with implications for noise removal. – IEEE Trans. Geosc. Rem. Sens. **26**, 1: 65–74.
- HILL, J., MEHL, W. & RADELOFF, V., 1995: Improved forest mapping by combining corrections of atmospheric and topographic effects. – In: ASKNE, J. (Ed.): Sensors and environmental applications of remote sensing. – Proc. 14th EARSeL Symposium, Göteborg, Sweden, 6–8 June 1994. 143–151, A. A. Balkema: Rotterdam, Brookfield.
- JOHNSON, L. F., HLAVKA, C. A. & PETERSON, D. L., 1994: Multivariate analysis of AVIRIS data for canopy biochemical estimation along the Oregon transect. – Remote Sens. Environ., **47**: 216–230.
- KÖHL, M. & LAUTNER, M., 2001: Erfassung von Waldökosystemen durch Hyperspektraldaten. – Photogrammetrie – Fernerkundung – Geoinformation, **2001** (2): 107–117.
- KRUSE, F. A., LEFKOFF, A. B., BOARDMAN et al., 1993: The spectral image processing system (SIPS) – Interactive visualization and analysis of imaging spectrometer data. – Remote Sens. Environ., **44**: 145–163.
- LEE, J. B., WOODYATT, A. S. & BERMAN, M., 1990: Enhancement of high spectral resolution remote sensing data by noise-adjusted principal components transform. – IEEE Trans. Geosc. Rem. Sens. **28**, 3: 295–304.
- MARTIN, L. & HOWARTH, P., 1989: Change-detection accuracy assessment using SPOT multispectral imagery of the rural-urban fringe. – Remote Sens. Environ., **30**: 55–66.
- MARTIN, M. E., NEWMAN, S. D., ABER, J. D. et al., 1998: Determining forest species composition using high spectral resolution remote sensing data. – Remote Sens. Environ., **65**: 249–254.
- NELSON, R. F., LATTY, R. S. & MOTT, G., 1985: Classifying northern forests using Thematic Mapper Simulator data. – Photogr. Eng. & Rem. Sens., **50**: 607–617.
- NIEMANN, K. O., 1995: Remote sensing of forest stand age using airborne spectrometer data. – Photogr. Eng. & Rem. Sens., **61** (9): 1119–1127.
- PETERSON, D. L., ABER, J. D., MATSON, P. A. et al., 1988: Remote sensing of forest canopy and leaf biochemical contents. – Remote Sens. Environ., **24**: 85–108.
- RUNNING, S. W., 1994: Testing Forest-BGC ecosystem process simulations across a climatic gradient in Oregon. – Ecol. Appl., **4**: 238–247.
- RUNNING, S. W. & COUGHLAN, J. C., 1988: A general model for forest ecosystem processes for regional applications. I. Hydrologic balance, canopy gas exchanges and primary production processes. – Ecol. Model. **42**: 125–154.
- SCHARDT, M., 1990: Verwendbarkeit von Thematic Mapper-Daten zur Klassifizierung von Baumarten und natürlichen Altersklassen. DLR-FB 90–44, Oberpfaffenhofen.
- SCHLÄPFER, D., SCHAEPMAN, M. E. & ITTEN, K. I. (1998): PARGE: Parametric Geocoding Based on GCP – Calibrated Auxiliary Data. – SPIE Int. Symp. on Opt. Sc. Eng. and Instr., San Diego (CA): 334–344.
- SCHLERF, M., ATZBERGER, C. & HILL, J., 2002: Tree species and age class mapping in a Central European woodland using optical remote sens-

- ing imagery and orthophoto derived stem density – performance of multispectral and hyperspectral sensors. – 22nd EARSeL Symposium “Geoinformation for European-wide integration”, Prague.
- UDELHOVEN, T., ATZBERGER, C. & HILL, J. (2000): Retrieving structural and biochemical forest characteristics using artificial neural networks and physically based reflectance models. – In: BUCHROITHNER (Hrsg.): A decade of trans-european remote sensing cooperation. – Proceedings of the 20<sup>th</sup> EARSeL Symposium, Dresden, Germany, 205–211.
- VOHLAND, M. (1997): Einsatz von Satellitenbildern (Landsat TM) zur Ableitung forstlicher Bestandsparameter und Waldschadensindikatoren. – Diplomarbeit, Universität Trier.
- WALSH, S.J. (1980): Coniferous tree species mapping using Landsat data. – *Remote Sens. Environ.*, **9**: 11–26.
- WESSMAN, C.A., ABER, J.D., PETERSON, D.L. et al. (1988): Remote sensing of canopy chemistry and nitrogen cycling in temperate forest ecosystems. – *Nature*, **335**: 154–156.
- Anschriften der Autoren:
- Dipl.-Geogr. MARTIN SCHLERF, Abteilung Fernerkundung, Universität Trier, Geozentrum H-809, D-54286 Trier, Tel.: +49-651-201-4593, e-mail: schlerf@uni-trier.de
- Prof. Dr. rer. nat. JOACHIM HILL, Abteilung Fernerkundung, Universität Trier, Geozentrum H-808, D-54286 Trier, Tel.: +49-651-201-4592, e-mail: hillj@uni-trier.de
- cand. Dipl.-Geogr. SAMUEL BÄRISCH, Fernerkundung, Universität Trier, Geozentrum H-842a, D-54286 Trier, e-mail: baer5101@uni-trier.de
- Dr. rer. nat. CLEMENT ATZBERGER, Abteilung Fernerkundung, Universität Trier, Behringstraße, D-54286 Trier, Tel.: +49-651-201-4596, Fax: +49-651-201-3815, e-mail: atzberger@feut.de
- Manuskript eingereicht: November 2002  
Angenommen: November 2002