

Segmentbasierte Fusion geometrisch hoch aufgelöster und hyperspektraler Daten zur Verbesserung der Klassifikationsgüte am Beispiel einer urbanen Szene

ANSGAR GREIWE, MATHIAS BOCHOW & MANFRED EHLERS, Osnabrück

Keywords: remote sensing, imaging spectrometry, data fusion, urban site

Zusammenfassung: Sensordaten von drei flugzeuggetragenen Fernerkundungssystemen wurden über einem urbanen Testgebiet (Innenstadt von Osnabrück) aufgenommen. Um die Klassifikationsgüte durch eine Kombination der geometrisch hoch aufgelösten Orthophotos mit hyperspektralen Daten und einem Digitalen Oberflächenmodell zu verbessern, wurde eine segmentbasierte Fusion entwickelt. Nach Segmentierung der geometrisch hoch aufgelösten Orthophotos sind zur Klassifikation dieser Bildsegmente 19 Klassen mit zum Teil visuell sehr ähnlichen Oberflächen definiert worden. Des Weiteren ist durch Überlagerung der Bildsegmente aus den hyperspektralen Bilddaten die Ableitung entsprechender Referenzspektren für die jeweiligen Oberflächenmaterialien möglich. Nach Ableitung einer Maßzahl (sog. SAM-Score) aus einer Klassifikation der hyperspektralen Daten kann auf eine mögliche Klassenzugehörigkeit eines Bildsegments zu einer Materialklasse geschlossen werden. In unterschiedlichen Klassifikationsszenarios wurde die Verbesserung der Klassifikationsgüte durch eine Kombination der vorliegenden Sensordaten nachgewiesen.

Summary: *Segment based fusion of high spatial and high spectral resolution image data for urban classification improvement.* An urban test site (inner city of Osnabrueck, Northern Germany) has been mapped by three different airborne sensors. The recorded data (digital orthophotos, hyperspectral image data and a digital elevation model) were fused at feature level in order to improve the classification accuracy. Image segments were derived from the orthophotos, representing parts or the whole surface of an urban object. 19 classes were defined for these urban surface objects and end-member spectra of corresponding urban surface materials were derived from hyperspectral image data by use of the image segments. Classification results of hyperspectral image data were transformed to an 8-bit score (so called SAM-Score) containing information about the spectral fitting of a segment to a given class. Classification with different combinations of the available data were carried out in order to prove validity of the presented concept and to quantify the improvement of the classification accuracy.

1 Einleitung

Der Einsatz von Fernerkundungsdaten für Planungen, Monitoring, Modellierungen und für den Aufbau von Umweltinformationssystemen in Regionen mit kleinräumiger Struktur und einer großen Nutzungsvielfalt bedingt in zweierlei Hinsicht eine hohe Qualität der zu verwendenden Fernerkundungsdaten. Einerseits ist eine hohe geometrische Auflösung der Sensoren erforderlich,

um Grenzen oder Bestandteile der zu klassifizierenden Objekte trennen zu können, andererseits ist das Spektrum der reflektierenden Oberflächen für eine befriedigende Differenzierung möglichst detailliert abzutasten. Die spektrale Auflösung geometrisch höchstauflösender Systeme (SCHIEWE & EHLERS 2004, in diesem Heft) ist nicht ausreichend, um die aufgenommenen Oberflächen über den Verlauf ihrer Spektren zu charakterisieren und anschließend materialspezi-

fisch zu differenzieren. Hyperspektrale Sensoren (DAIS, HyMap) lassen dagegen aufgrund ihrer hohen Kanalanzahl eine vergleichsweise feine Differenzierung der Oberflächenmaterialien zu. Technische Limitierungen wie die Scanrate (10 Hz bis 25 Hz, vgl. WILSON & COCKS 2003) erlauben für diese Sensoren allerdings keine vergleichbare geometrische Auflösung.

Somit werden Ansätze zur Fusionierung von einerseits spektral und andererseits geometrisch hoch auflösenden Fernerkundungsdaten notwendig. Im Gegensatz zu pixelbasierten Verfahren (LEHMANN et al. 1998, ZHUKOV et al. 1998a, 1998b, 1999) wird in dieser Arbeit ein Ansatz vorgestellt, der sich durch eine segmentbasierte Fusionierung auszeichnet.

2 Zielsetzung

Wird die Erdoberfläche durch einen geometrisch hoch auflösenden Sensor abgetastet, können durch geeignete Verfahren Bildsegmente erzeugt werden (BAATZ & SCHÄPE 2000). Diese Bildsegmente repräsentieren die relativ homogenen Oberflächen eines (Teil-) Objekts. Ziel der hier vorgestellten Arbeit ist die Klassifikation der vorliegenden Bildsegmente unter Verwendung geometrisch und spektral hoch aufgelöster Fernerkundungsdaten sowie daraus abgeleiteter Objekthöhen.

Folgende Aspekte werden behandelt:

- Integration der verschiedenen Daten im Verlauf der Prozessierung,
- Steigerung der Gesamt-Klassifikationsgüte durch die Verwendung von multisensoralen Datensätzen,
- Untersuchung der Trennbarkeit von visuell sehr ähnlicher Landnutzungsklassen aufgrund von Angaben zur Objekthöhe oder zum Oberflächenmaterial.

Zu diesem Zweck wurden 19 Klassen mit zum Teil sehr ähnlichen spektralen Ausprägungen ausgewählt. Dachbedeckungen wurden zum Beispiel farb- und materialspezifisch differenziert. Für rote bzw. dunkle (braune) Dachbedeckungen wurden somit aufgrund der Differenzierung in beton- oder

tonhaltige Materialien vier Klassen definiert (RF_RC = rot/Beton, RF_RY = rot/Ton, RF_BC = braun/Beton und RF_BY = braun/ Ton). Mit Kupfermetall gedeckte Dächer wurden je nach Verwitterungsgrad der Oberfläche in drei Klassen aufgeteilt. Ebenso wurde bei bitumenhaltigen Oberflächen zwischen Dach- und Straßenflächen unterschieden. Die Vegetation wurde in zwei Klassen aufgeteilt (Rasen mit offenem Boden, restliche Vegetation). Von einer weiteren Differenzierung der Vegetation (Klasse „Baum“) wurde aufgrund der ungeeigneten Höhendaten (s. Kapitel 3.2) abgesehen.

3 Datengrundlage

Für das vorgestellte Verfahren wurde eine urbane Testszene (Innenstadt Osnabrück) als Beispiel für eine hohe Landbedeckungs-Varibialität ausgewählt. Ein Gebiet von 410 m Breite und 1524 m Länge in Nord-Süd Ausrichtung wurde von verschiedenen Sensoren erfasst. So standen folgende Datensätze zur Verfügung:

- Digitales Orthophoto System,
- Höhenmodelle aus HRSC- und DGM5-Daten,
- Hyperspektrale Bilddaten (HyMap).

3.1 Digitale Orthophotos

Die hoch aufgelösten Luftbilder wurden mit dem an der FH Bochum entwickelten Luftaufnahmesystem LEO (Local Earth Observation, s. BÄUMKER et al. 1999) am 16. Mai 2003 aufgezeichnet. Die gescannten, im Bildmaßstab 1:10000 aufgenommenen Luftbilder wurden zu einem digitalen Orthophoto (Pixelgröße 12,5 cm) mit einer Lagegenauigkeit von $s_x = 20$ cm, $s_y = 22$ cm mosaikiert. Für die Erzeugung der Bildsegmente wurde ein Mosaik mit einer Auflösung von 50 cm erzeugt.

3.2 Höhenmodelle

Neben einem digitalen Geländemodell (DGM-5, Rasterweite 12,5 m, vertikale Genauigkeit 0,5 m) stand für das Untersu-

chungsgebiet ein weiteres, aus Bilddaten einer HRSC-A Kampagne generiertes Höhenmodell zur Verfügung (MÖLLER 2003). Aus diesen Datensätzen wurde ein normalisiertes Digitales Oberflächenmodell (nDOM) erstellt. Bedingt durch den jahreszeitlich frühen Zeitpunkt der Aufnahme (April 1999) ist anzumerken, dass Objekthöhen der Vegetation nicht korrekt erfasst wurden. Deshalb wurde auf eine weitere Differenzierung der Vegetationsklassen in der Zielsetzung verzichtet.

3.3 HyMap

Das Deutsche Zentrum für Luft- und Raumfahrt (DLR) ermöglichte den Autoren die Teilnahme an der „HyEurope“ Kampagne im Jahre 2003. Somit konnten am 15. Juli 2003 zeitnah zur LEO-Kampagne hyperspektrale Bilddaten mit dem Sensor HyMap für das Untersuchungsgebiet aufgenommen werden. Das reflektierte solare Spektrum zwischen 450 nm und 2500 nm wurde in 128 Kanälen mit einer Scanrate von 16 Hz aufgezeichnet. Durch Wahl einer geringen Flughöhe wurde eine Bodenpixelgröße von 3 m quer und 4 m längs zur Flugrichtung erzielt.

Die aufgezeichneten Bildzeilen des Rohdatenmaterials werden durch parametrische Geokodierung auf ein DGM projiziert (PARGE, s. SCHLÄPFER et al. 1999). Die hierzu notwendigen Metadaten wie Fluglagendaten (INS/GPS) lagen dabei vor. Durch die Verwendung eines DGM mit 2 m Auflösung anstelle der 3 m Auflösung der Bilddaten wurde die Anzahl der „double mapped pixel“ von 1,8% auf 0,3% reduziert (vgl. SCHLÄPFER 2002). Um den Lageversatz einzelner Pixel, bedingt durch unterschiedliche Objekthöhen, zu minimieren, wurde zur Geokodierung das in Abschnitt 3.2 erwähnte nDOM verwendet. Die Lagegenauigkeit der Szene wurde abschließend anhand von Passpunkten überprüft. Sie liegt mit 1,8 m im Bereich der Bodenpixelgröße des geokodierten Flugstreifens und zeigt damit eine zufrieden stellende Genauigkeit. Die gemessenen Strahldichten wurden durch das Softwarepaket FLAASH (Fast Line-of-sight

Atmospheric Analysis of Hyperspectral Cubes, s. ADLER-GOLDEN et al. 1999) in absolute Reflexionswerte überführt. Nach Überprüfung der durch FLAASH ermittelten Reflexionswerte (einige Gewässerflächen enthielten in einigen Kanälen negative Werte) konnten 104 der 128 Bänder für die weitere Bearbeitung verwendet werden.

4 Methoden

Die Oberflächen der zu klassifizierenden Objekte werden durch Bildsegmente der geometrisch hoch aufgelösten Daten repräsentiert. Diese Segmente werden dazu verwendet, Werte aus geometrisch geringer aufgelösten Daten zu aggregieren. So ist neben den Farbwerten der hoch aufgelösten Daten der Bezug eines Segments zu vergleichsweise grob aufgelösten hyperspektralen Daten möglich.

Für die Ableitung von Materialzusammensetzungen aus hyperspektralen Daten sind für die einzelnen Materialien klar definierte Referenzspektren, sogenannte Endmember, notwendig. Diese werden im hier vorgestellten Ansatz durch eine segmentbasierte Endmemberselektion (siehe Kapitel 4.1) aus dem Bildraum der hyperspektralen Daten selektiert. Liegen für alle Klassen Endmember vor, kann der Datensatz mit einem Klassifikationsverfahren wie dem Spectral Angle Mapper (SAM) klassifiziert werden. Aus dem Ergebnis des SAM kann ein Maß für die Zugehörigkeit eines Segments zu einer speziellen Materialklasse abgeleitet werden (SAM-Score, Kapitel 4.2). Die Klassifikation der einzelnen Segmente erfolgt letztlich unter der Berücksichtigung der RGB-Farbwerte, des jeweiligen SAM-Scores und der Höhenwerte des nDOM. Die einzelnen Schritte wie in Abb. 1 dargestellt, sollen im Folgenden näher erläutert werden.

4.1 Segmentbasierte Endmemberbestimmung

Referenzspektren bzw. Endmember können aus Labor- bzw. Feldmessungen mit einem Spektrometer oder alternativ aus den vorliegenden Bilddaten gewonnen werden. Für

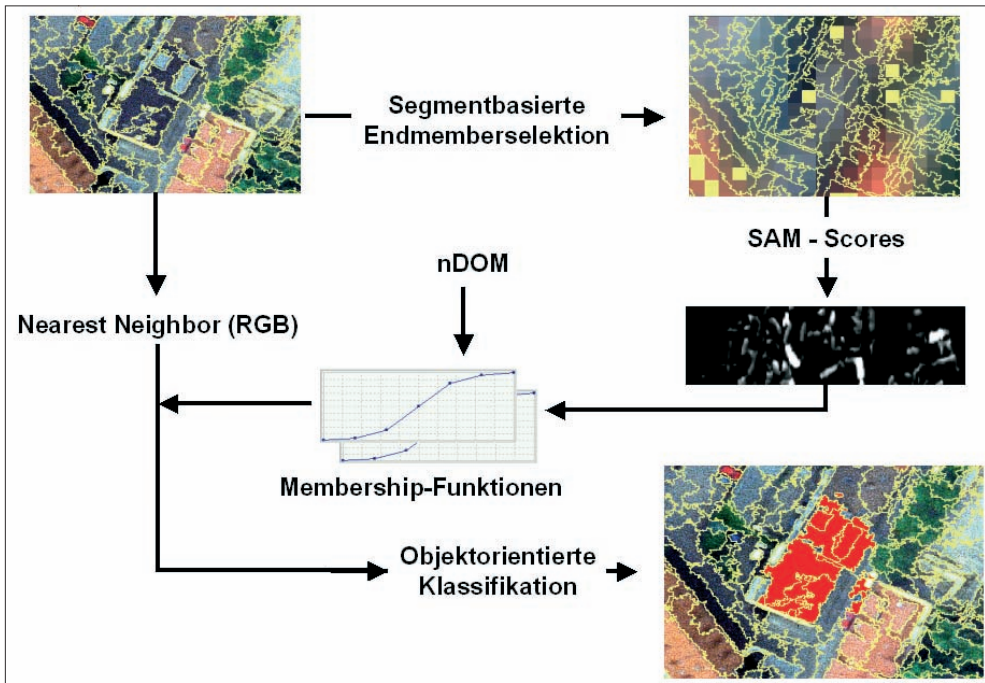


Abb. 1: Ablauf der multisensoralen, segmentbasierten Klassifikation.

die Ableitung von Endmembern aus Bilddaten sind unter anderem folgende Verfahren entwickelt worden:

- Manuelle Endmemberselektion (BATESON & CURTISS 1996),
- Pixel Purity Index (PPI) in Kombination mit dem n-dimensional Visualizer (NDV) – implementiert in der Software ENVI (BOARDMAN et al. 1995),
- NFIND-R (WINTER 1999),
- Iterative Constrained Endmembers Algorithm (ICE) (BERMAN et al. 2003),
- Autonomous Morphological Endmember Extraction (AMEE) (PLAZA et al. 2002)

Die genannten Verfahren setzen voraus, dass die Spektren der gesuchten Endmember sogenannte „spectral features“ aufweisen und sich so von anderen Spektren signifikant unterscheiden. Durch diese Eigenschaft bilden diese Pixel im Merkmalsraum der hyperspektralen Bilddaten eine konvexe Hülle um die Gesamtheit der zu klassifizierenden Pixel. Alle Pixel im Innern der

Punktwolke sind das Resultat einer Mischung der ermittelten Endmember. Je nach Anwendungsfall kann jedoch die a priori Definition einer zu untersuchenden Klasse dazu führen, dass diese Voraussetzungen nicht gegeben sind.

Oberflächen im urbanen Raum bestehen meist aus Materialmischungen. Ihr spektraler Verlauf ist relativ monoton, sie weisen kaum „spectral features“ auf. Als Folge sind die repräsentierenden Referenzpixel solcher Klassen durch Algorithmen wie dem PPI nicht zu detektieren. Um dennoch für jede definierte Klasse Endmember aus den Bilddaten zu gewinnen, werden in unserem Ansatz zunächst alle Pixel im hyperspektralen Datensatz selektiert, die, wie auch deren acht Nachbapixel, vollständig im selben Segment liegen (dargestellt als gelbe Pixel in Abb. 2, Mitte). Aus diesen Endmemberkandidaten werden diejenigen manuell zusammengefasst, die tatsächlich eine Materialklasse repräsentieren. Durch Mittelung der Spektren dieser manuell selektierten Pi-

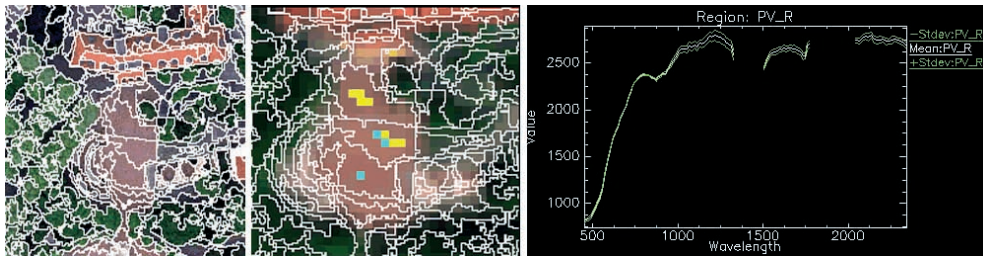


Abb. 2: Segmentbasierte Endmemberselektion, links: Ausschnitt (LEO), Mitte: Endmember (cyan), rechts: Spektrum der Klasse „rotes Pflaster (Beton)“.

xelgruppen entstehen die Spektren der Endmember.

Für jede der 19 a priori definierten Klassen wird ein Endmember definiert. Eine Ausnahme stellen die Klassen „Asphalt“ und „Dach/Bitumen“ dar, für die untersucht wurde, ob ein gemeinsamer Endmember diese beiden bitumenhaltigen Materialklassen ausreichend charakterisiert.

4.2 SAM-Scores

Aus der segmentbasierten Endmember-Selektion resultiert eine Spektralbibliothek (Spectral Library) mit den Referenzspektren der Endmember. Durch ein pixelbasiertes Verfahren wie dem Spectral Angle Mapper (SAM) wird für ein zu klassifizierendes Pixel pro Endmember ein spektraler Winkel nach folgender Gleichung ermittelt:

$$\cos \varphi = \frac{\sum_{i=0}^n e_i r_i}{\sqrt{\sum_{i=0}^n e_i^2} \sqrt{\sum_{i=0}^n r_i^2}} \quad (1)$$

mit

i = Kanal

n = Anzahl der Kanäle

e = Referenzspektrum (Endmember)

r = Spektrum des zu klassifizierenden Pixel

Jedes Pixel erhält so bei n Endmembers n Winkelwerte, die in einem sogenannten Rule-Image abgelegt werden können. Besitzt ein Pixel im Vergleich zu einem Endmember ein identisches Spektrum, erhält es einen Winkelwert = 0. Je kleiner der Winkel, des-

to größer ist die Übereinstimmung zwischen Pixel und Klassendefinition. Durch eine lineare Transformation auf eine 8 Bit Skala kann einem perfekt passenden Pixel (identischer Endmember) der Wert 255 und einem Pixel, dessen spektraler Winkel einen bestimmten Schwellwert überschreitet, der Wert 0 zugewiesen werden. Dieses Maß der Übereinstimmung zwischen Einzelspektrum eines Pixels und Referenzspektrum eines Endmembers wird im Folgenden SAM-Score genannt.

Erste Ansätze mit einem festen Schwellwert für alle Klassen (GREIWE et al. 2003) führten jedoch zu einer Überbestimmung schwach besetzter Klassen (z. B. Wasser in der vorliegenden urbanen Testszene, wie in Abb. 4 dargestellt). Daher wurde ein Verfahren entwickelt, bei dem der Betrag eines Winkelwertes, der zu einem SAM-Score mit dem Wert 0 führt, für jede Klasse automatisiert und somit nutzerunabhängig ermittelt wird.

Hierbei werden zunächst die spektralen Winkel (W) für jedes Pixel der Größe ihres Betrages nach sortiert ($W_i < W_j < W_k$). Aus den Differenzen $W_j - W_i$ und $W_k - W_i$ kann ermittelt werden, ob es einen signifikant besten Winkelwert für dieses Pixel gibt. Sollte dies der Fall sein, wird das Pixel für eine Berechnung des SAM-Score der Klasse i markiert. Ist $W_j - W_i < 0.33 W_i$, wird das Pixel neben Klasse i auch Kandidat für Klasse j . Für die drittbeste Klasse k erfolgt die Überprüfung analog. Der Grenzwert für die Klasse i wird durch den größten Winkelwert aller markierten Pixel der Klasse i bestimmt. Wie aus Abb. 3 ersichtlich, erhält jedes Pixel




Abb. 3: Pixel mit geringstem SAM-Winkel für Endmember 3 (links) erhält neben einem SAM-Score für Endmember Nr. 3 auch Werte für Nr. 4 und Nr. 8. (rechts).




Abb. 4: SAM-Score als Graustufenbild bei der schwach repräsentierten Klasse „Wasser“. Schwellwertselektion: links = fest, mitte = manuell, rechts = automatisch.




Abb 5: SAM-Score der häufig vorkommenden Klasse „rote Dachbedeckung (Ton)“ Schwellwertselektion: links = fest, mitte = manuell, rechts = automatisch.

für seine maximal drei besten Klassen (kleinste SAM-Winkel) SAM-Scores.

Während das Verfahren mit gleichem Schwellwert nur bei stark repräsentierten

Klassen (s. Abb. 5) funktioniert, ist das hier vorgestellte automatisierte Verfahren unabhängig von der Häufigkeit einer Klasse erfolgreich. Die Ergebnisse in Abb. 4 und 5

zeigen auch deutliche Verbesserungen gegenüber der manuellen Selektion von Schwellwerten (jeweils Mitte), deren Auswahl zudem von Szene zu Szene neu erfolgen müsste.

4.3 Klassifikation

Die Klassifikation wurde mit dem in eCognition implementierten Fuzzy-Logic Klassifikator durchgeführt. Wie aus Abb.6 ersichtlich wird, können einem Segment neben den RGB-Werten die Information über die Objekthöhe sowie einzelne SAM-Scores für mögliche Materialzuweisungen wie „Offener Boden“ (SOIL) oder „rotes Zementpflaster“ (PV_R) zugeordnet werden.

Basierend auf diesen Merkmalsausprägungen werden für jede Klasse Fuzzy-Sets aus den nDOM-Werten und den relevanten SAM-Scores über sog. „membership functions“ erzeugt. Es wurde auf die Möglichkeit der klassenspezifischen Modifikation der „membership functions“ verzichtet und für alle Klassen eine einheitliche Abbildungsfunktion verwendet. Die RGB-Farbinformationen werden über Trainingsflächen einer Klasse zugewiesen und über einen „nearest neighbor“ Klassifikator in ein Maß für eine Klassenzugehörigkeit überführt.

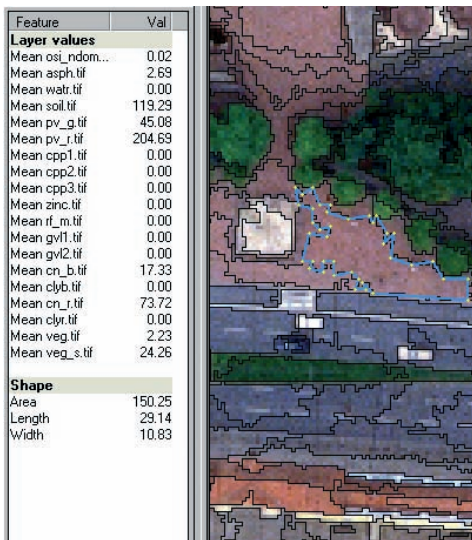


Abb. 6: SAM-Scores und nDOM-Höhe für ein Segment.

5 Ergebnisse und Diskussion

Zum Nachweis der Wirksamkeit des hier beschriebenen Ansatzes wurden in eCognition in verschiedene Klassifikationsszenarios untersucht. Durch Kombination von Ortho-photo, SAM-Score (Ssc) und nDOM wurden folgende fünf Varianten erzeugt:

Tab. 1: Klassifikationsvarianten mit den verwendeten Datensätzen.

Variante	Ortho-Photo	SAM-Score	nDOM
RGB	X		
RGB + DOM	X		X
Ssc		X	
Ssc + DOM		X	X
RGB + Ssc + DOM	X	X	X

Für jede Variante wurde die Erkennungsgüte (user accuracy) und die Gesamterkennungsgüte (overall accuracy) ermittelt. Die Steigerung der Genauigkeit durch Verwendung des nDOM blieb aufgrund der teilweise nicht ausreichenden Genauigkeit der Höhendaten etwas unter den Erwartungen (s. Abb. 7). Die Verwendung der hyperspektralen Daten zeigte hingegen, dass die Trennbarkeit und damit die Gesamterkennungsgüte gesteigert wurden.

Die Ergebnisse zeigen auch deutlich, dass farblich ähnliche Oberflächen mit unterschiedlichen Materialeigenschaften durch eine hyperspektrale Analyse besser klassifi-




Abb. 7: Erkennungsgüte (overall accuracy) der Varianten aus Tab. 1.

Tab. 2: Erkennungsgüte (user accuracy).

	RGB	RGB mit nDOM	RGB mit nDOM und SAM-Score
Dach (Bitumen)	27	35	32
Straßenfläche	40	62	68
Wasser	69	64	74
Kupferdach_1	61	53	77
Kupferdach_2	91	91	91
Kupferdach_3	16	34	70

ziert wurden als die alleinige Auswertung des Orthophotos (RGB) (hyperspektral: 63,5%, RGB: 51,8%). Wurden nDOM und SAM-Scores zusätzlich in die Klassifikationsprozess aufgenommen, konnte die Genauigkeit signifikant auf 73,3% gesteigert werden. Bei der Betrachtung der Erkennungsgüte einzelner Klassen (s. Tab. 2) wird deutlich, dass der Versuch, einen Endmember aus Straßenflächen-Segmenten für die Klassifikation von bitumenhaltigen Oberflächen zu verwenden, nicht erfolgreich war. Bei Verwendung der SAM-Scores konnte die Erkennungsgüte bitumenhaltiger Dachflächen im Vergleich zu Straßenflächen nicht in demselben Maß gesteigert werden.

Während die Erkennungsgüte von im RGB Farbraum schwer differenzierbaren Klassen (Wasser/Straßenfläche) durch Verwendung der SAM-Scores nur geringfügig gesteigert werden konnte (Wasser von 69% auf 74%), hat sich die Klassifikationsgüte bei diesen Klassen durch die Verwendung des SAM-Score deutlich verbessert (s. Tab. 3).

Für Kupferdächer wurden drei Klassen definiert, deren Erkennungs- und Klassifikationsgüte gesteigert werden konnte. Helles, grün reflektierendes Kupfer (Kupferdach_2) ist zwar im RGB-Farbraum hinreichend genau zu charakterisieren, dennoch konnte die Klassifikationsgüte hier von 83% auf 94% gesteigert werden. Größer fällt die Verbesserung bei dunklem, verwit-

Tab. 3: Klassifikationsgüte (producer accuracy).

	RGB	RGB mit nDOM	RGB mit nDOM und SAM-Score
Dach (Bitumen)	29	26	42
Straßenfläche	20	46	76
Wasser	60	78	98
Kupferdach_1	81	79	96
Kupferdach_2	83	83	94
Kupferdach_3	29	40	75

tertem Kupfer (Kupferdach_3) auf, das analog zur Klasse „Wasser“ durch eine Definition im RGB-Farbraum, selbst unter Verwendung eines nDOM, nicht die Genauigkeiten erreicht, die durch die Verwendung der hyperspektralen Zusatzinformation gewährleistet wird.

6 Ausblick

Das vorgestellte Verfahren verbindet die Eigenschaften spektral und geometrisch hoch aufgelöster Bilddaten. Ein Verfahren zur segmentbasierten Fusion wurde vorgestellt und der Vorteil dieses Ansatzes durch die Untersuchung unterschiedlicher Klassifikationsvarianten nachgewiesen. Eine weitere Automatisierung einzelner Prozessschritte analog der automatisierten SAM-Score Generierung wird angestrebt. Hierzu zählen neben einer automatisierten, segmentbasierten Endmemberselektion die Einbeziehung von numerischen Merkmalen (Ratios, s. SEGL et al. 2003), welche aus den hyperspektralen Bilddaten abgeleitet werden können.

Das vorgestellte Verfahren ist in hohem Maße abhängig von der geometrischen Genauigkeit der einzelnen Bilddaten. Liegen Bilddaten vor, die tatsächlich koregistriert wurden, lässt sich die Genauigkeit des hier vorgestellten Ansatzes weiter steigern. In Zukunft werden erste Systeme operabel sein, die Verfügbarkeit von spektral und

geometrisch hoch auflösenden multisensoralen Datensätzen für ein beliebiges Untersuchungsgebiet verbessern, da die flugzeuggetragenen Sensoren koregistrierend montiert werden können. Ein Beispiel für ein bereits operables System ist die Kombination aus Hymap und Multispektralkamera „Redlake Mega Plus MS3100“, denkbar ist in Zukunft die Kombination von ARES (s. KAUFMANN et al. 2003) und Zeilensensoren wie der HRSC oder der ADS.

7 Danksagung

Für die Ermöglichung der Teilnahme an der HyEurope 2003 Kampagne sei an erster Stelle ANDREAS MÜLLER vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) gedankt. Weiterer Dank gilt STEFANIE HOLZWARTH (DLR) und DANIEL SCHLÄPFER (Remote Sensing Laboratories, Zürich, Schweiz) für die Unterstützung bei der Geokodierung der Daten sowie Prof. Dr. HEIMES und RAINER BRECHTKEN für die Unterstützung im LEO 2003 Projekt.

8 Literatur

- ADLER-GOLDEN, S.M., MATTHEW, M.W., BERNSTEIN, L.S., LEVINE, R.Y., BERK, A., RICHTSMEIER, S.C., ACHARYA, P.K., ANDERSON, G.P., FELDE, G., GARDNER, J., HIKE, M., JEONG, L.S., PUKALL, B., MELLO, J., RATKOWSKI, A. & BURKE, H.-H., 1999: Atmospheric correction for short-wave spectral imagery based on MODTRAN4. – SPIE Proc. Imaging Spectrometry **3753**: 61–69.
- BAATZ, M. & SCHÄPE, A., 2000: Multiresolution Segmentation – An Optimization Approach for High Quality Multi-scale Image Segmentation. – In: STROBL, J. et al. (Hrsg.): *Angewandte Geographische Informationsverarbeitung XII*. – Beiträge zum AGIT-Symposium Salzburg 2000, pp. 12–23, Herbert Wichmann Verlag, Karlsruhe.
- BÄUMKER, M., BRECHTKEN, R., HEIMES, F.-J. & RICHTER, T., 1999: Direkte Georeferenzierung mit dem Luftaufnahmesystem LEO. – In: *Proceedings 10. Internationale Geodätische Woche, Obergurgl*.
- BATESON & CURTISS, 1996: A Method for manual endmember Selection and Spectral Unmixing. – *Remote Sensing and Environment* **55**: 229–243.
- BERMAN, M., KIIVERI, H., LAGERSTROM, R., ERNST, A., DUNNE, R. & HUNTINGTON, J., 2003: ICE: An automated statistical approach to identifying endmembers. – *Proc. 2003 IEEE International Geoscience and Remote Sensing Symposium*, Vol. 1, Toulouse, France, pages 279–283, July 2003.
- BOARDMAN, J.W., KRUSE, F.A. & GREEN, R.O., 1995: Mapping Target Signatures via Partial Unmixing of AVIRIS Data. – *Summaries, Fifth JPL Airborne Earth Science Workshop*, JPL Publication **1**: 23–26.
- GREIWE, A., BOCHOW, M. & EHLERS, M., 2003: Fusion of Multisensor Remote Sensing Data for Urban Land Cover Classification. – In: EHLERS, M. (Ed.): *Remote Sensing for Environmental Monitoring, GIS Applications, and Geology III*. – *Proceedings of SPIE Vol. 5239*.
- KAUFMANN, H., CHABRILLAT, S., DECH, S., HABERMAYER, M., HOLZWARTH, S., MEHL, H., MÜLLER, A., RICHTER, R. & SEGL, K., 2003: Environmental Mapping and Analysis Program Based on the Use of the Airborne Reflective Emissive Spectrometer (ARES). – In: HABERMAYER, M., MÜLLER, A. & HOLZWARTH, S. (Hrsg.): *3rd EARSeL Workshop on Imaging Spectroscopy*, 13–16 May 2003.
- LEHMANN, F., BUCHER, T., HESE, S., HOFFMANN, A., MAYER, S., OSCHÜTZ, F. & ZHANG, Y., 1998: Die Kombination von hyperspektralen HyMap-Daten und HRSC-A Multispektral und DGMdaten zur Validierung und Nutzung in verschiedenen Anwendungsgebieten. – *DGPF Jahrestagung 1998*.
- MÖLLER, M., 2003: Urbanes Umweltmonitoring mit digitalen Flugzeugscannerdaten. – 160 S., Wichmann Verlag, Heidelberg.
- PLAZA, A., MARTINEZ, P., PEREZ, R. & PLAZA, J., 2002: Spatial/Spectral Endmember Extraction by Multidimensional Morphological Operations. – *IEEE Trans. On Geoscience and Remote Sensing* **40-9**: 2025–2041.
- SCHIEWE, J. & EHLERS, M., 2004: Semantisches Potential digitaler flugzeuggestützter Fernerkundungssensoren. – *Photogrammetrie – Fernerkundung – Geoinformation* **2004** (6): 463–474 (dieses Heft).
- SCHLÄPFER, D., SCHAEPMAN, M.E. & ITTEN, K.I., 1998: PARGE: Parametric Geocoding Based on GCP-Calibrated Auxiliary Data. – *SPIE International Symposium on Optical Sciences, Engineering and Instruments*, San Diego (CA).
- SCHLÄPFER, D., 2002: *PARAMetric GEocoding, UserGuide, Version 2.0*.

- SEGL, K., HEIDEN, U., MÜLLER, M. & KAUFMANN, H., 2003: Endmember Detection in Urban Environments Using Hyperspectral HyMap Data. – Proceedings of the 3rd EARSeL Workshop on Imaging Spectroscopy, 13–16 May 2003.
- WILSON, I.J. & COCKS, T.D., 2003: Development of the Airborne Reflective Emissive Spectrometer (ARES) – a Progress Report. – In: HABERMEYER, M., MÜLLER, A. & HOLZWARH, S. (Hrsg.) 2003: 3rd EARSeL Workshop on Imaging Spectroscopy, 13–16 May 2003.
- WINTER, M. E., 1999: Fast Autonomous Spectral Endmember Determination in Hyperspectral Data. – Proceedings of the 13th International Conference on Applied Geologic Remote Sensing **II**: 337–344.
- ZHUKOV, B., OERTEL, D., BERGER, M., KAUFMANN, H. & MÜLLER, A., 1998a: Unmixing and Fusion of Multi-Sensor Multi-Resolution Data Acquired Over The Makhtesh Ramon Negev Desert. – In: RANCHIN, T. & WALD, L. (Hrsg.): Proceedings of the 2nd International Conference “Fusion of Earth Data – Merging Point Measurements, Raster Maps and Remotely Sensed Images”. Sophia Antipolis.
- ZHUKOV, B., OERTEL, D. & LANZL, F., 1998b: Unmixing and Fusion of Multi-Resolution Images with Applications to TM/Landsat and Simulated ASTER Data. – In: RANCHIN, T. & WALD, L. (Hrsg.): Proceedings of the 2nd International Conference “Fusion of Earth Data-Merging Point Measurements, Raster Maps and Remotely Sensed Images”. Sophia Antipolis.
- ZHUKOV, B., OERTEL, D., LANZL, F. & REINHÄCKEL, G., 1999: Unmixing-Based Multisensor Multiresolution Image Fusion. – IEEE Transactions on Geoscience and Remote Sensing **37** (3): 1212–1225.

Anschriften der Autoren:

Dipl.-Umweltwiss. ANSGAR GREIWE
 Dipl.-Umweltwiss. MATHIAS BOCHOW
 Prof. Dr.-Ing. MANFRED EHLERS
 Forschungszentrum für Geoinformatik und
 Fernerkundung
 Universität Osnabrück
 Eichendorffweg 30, D-49377 Vechta
 Tel.: 04441-15-324/-428/-423
 e-mail: {agreiwe, mbochow, mehlers}@fzg.uni-
 vechta.de

Manuskript eingereicht: Juli 2004
 Angenommen: August 2004