

Vergleich unterschiedlicher Klassifikationsansätze am Beispiel von hoch auflösenden Satellitenbilddaten im Raum Leipzig

LOTHAR LINDE & WERNER KIRSTEIN, Leipzig

Keywords: remote sensing, IKONOS, knowledge classifier, eCognition, homogeneity, segmentation, objects, hierarchy

Zusammenfassung: Vom IKONOS-Satelliten stehen seit einigen Jahren geometrisch höchstauflösende Multispektraldaten zur Verfügung, die besonders für den Einsatz in hochkomplexen urbanen Bereichen sowie dem meist sehr kleinräumigen Übergangsbereich zum ländlichen Raum prädestiniert sind. Um dieses Informationspotential allerdings auch erfolgreich extrahieren zu können, müssen neue Wege zur Verarbeitung dieser Daten gegangen werden. Dabei konnte eine hierarchische, pixelorientierte Klassifikation (mit dem Erdas Imagine ExpertClassifier) durch die Möglichkeit der Einbindung verschiedenster synthetischer und nicht-spektraler Zusatzdaten zwar einige Probleme einer auf „training and test-areas“ (TTA) und statistischer Interpolation beruhenden Klassifikationen verringern. Eine zufriedenstellende Klassifikationsgüte für alle im Rahmen der Studie betrachteten Klassen konnte aber nur durch den Einsatz einer segmentbasierten Klassifikation (mit Definiens eCognition) erreicht werden. Dies setzt jedoch voraus, dass der Anwender – im der Klassifikation vorgeschalteten Segmentierungsprozess trotz dessen begrenzter Standardisierungs- und Steuermöglichkeiten – ein Höchstmaß an Objektgenauigkeit erzielt, da diese direkt Einfluss auf die Qualität der anschließenden Klassifikation nimmt.

Summary: *Comparison of Different Classifications at the Example of High-Resolution Imagery near Leipzig.* Since the last years the IKONOS-satellite provides multispectral data with highest geometric resolution. This allows analysing of highly diversified urban areas as well as their surrounding belt of small patched suburban and rural environments. However, these data require new classification methods in order to derive the information successfully. In the present study a pixel-based hierarchical classification (implemented by the Erdas Imagine ExpertClassifier) could reduce problems based on the processing of training and test-areas (TTA) and statistical analysis by its capability to include various auxiliary data in the class description. The accuracy of the classification was further enhanced by using a segment-based classification approach (implemented by Definiens eCognition). Nevertheless problems of this approach arise due to the segmentation process, that was developed for a maximum of automation. Although this simplifies the segmentation considerably, it also limits the possibilities to control this process efficiently in case the data quality falls below a certain standard. That may hinder the users success to define most accurate image segments as a prerequisite for a high quality of classification.

Einleitung

Nahezu alle europäischen Landschaften werden seit Jahrhunderten mehr oder weniger kontinuierlich durch den Menschen genutzt. Infolgedessen ist ihr raum-zeitliches Erscheinungsbild nicht nur ein Ergebnis der natürlichen Prozessdynamik, sondern in

starkem Maße das Produkt einer z. T. intensiven Anpassung der Landschaft an die sozio-kulturellen und politisch-ökonomischen Bedürfnisse bzw. Ansprüche der jeweiligen Gesellschaft (BECKER 1998, TURNER & GARDNER 1991, in WALZ et al. 2001).

Besonders in jüngster Zeit hat sich diese Transformation durch tief greifende politi-

sche und wirtschaftliche Veränderungen in den Staaten des ehemaligen Ostblocks stark beschleunigt. Um diese komplexen Interaktionen und die aus ihnen hervorgehenden Veränderungen und Folgen verstehen und gegebenenfalls steuernd eingreifen zu können, sind Planungsmaterialien nötig, die sowohl geometrisch als auch zeitlich hoch auflösend sind (Detailgenauigkeit und Aktualität).

An dieser Stelle können satellitengetragene Sensoren heute einen entscheidenden Beitrag leisten. Waren der Datenerfassung und -bewertung durch die ungenügende geometrische Auflösung älterer Satelliten vor allem im urbanen und suburbanen Bereich klare Grenzen gesetzt, stehen in jüngster Zeit mit dem Start hoch und höchst auflösender Satellitensensoren (z. B. IKONOS) in Bezug auf Aktualität sowie geometrische und spektrale Auflösung inzwischen geeignete Daten zur Verfügung (MANSBERGER 2000, MEINEL & REDER 2001).

Allerdings ergeben sich bei der Verarbeitung dieser Daten neue Probleme und Herausforderungen für den Anwender. Können die bisher vorliegenden Satellitenbilddaten

mit geringerer geometrischer Auflösung noch weitgehend erfolgreich durch die Betrachtung von Einzelpixeln klassifiziert werden, führt dieser zwar weit verbreitete, aber auf der Datenqualität der 70er Jahre aufbauende methodische Ansatz (BLASCHKE 2000) bei hoch- und höchstauflösenden Daten (Erhöhung der Objektdichte und spektralen Varianz) oft nur zu unbefriedigenden Ergebnissen. In diesem Zusammenhang hat die bisher kaum in die Klassifikation einbezogene Nachbarschaftsinformation der Pixel einen enormen Bedeutungsgewinn erfahren und findet aktuell Einsatz in „segmentorientierten“ (Abstraktion der gesamten Szene) oder „objektorientierten“ (Abstraktion gezielt für bestimmte Objekte) Klassifikationssystemen (BLASCHKE 2000, BLASCHKE et al. 2001, Meinel et al. 2001).

Untersuchungsgebiet

Die vorliegende Analyse einer IKONOS-Multispektralszene ist ein Kooperationsprojekt zwischen dem Umweltforschungszentrum Leipzig-Halle GmbH (UFZ) und dem Institut für Geographie der Universität




Abb. 1: Analytierte IKONOS-Satellitenszene vom Nordraum der Stadt Leipzig (Hintergrund, Aufnahme datum: 18.06.2002, Auflösung 4 m, Darstellung: Fehlfarben-IR [4-3-2]). Der vergrößerte Ausschnitt wurde zur besseren Darstellung der Ergebnisse im Artikel gewählt. Die beschriebenen Ergebnisse und Klassifikationsgenauigkeiten beziehen sich aber auf die Gesamtszene.

Leipzig. Es ist aus dem Projekt „Analyse und Bewertung der Naturraumpotenziale in der suburbanen Kulturlandschaft mit Methoden der Fernerkundung und GIS“ abgeleitet und in das UFZ-Verbundvorhaben „StadtNatur – Anforderungsprofile, Strategien und Maßnahmen zum Management von Natur in urbanen Landschaften“ eingebettet. Die untersuchte Szene vom 18.06.2002 verfügt über eine Bodenauflösung von 4 m und deckt einen 144 km² (8 km × 18 km) großen Bereich im Nordraum der Stadt Leipzig sowie des vorgelagerten suburbanen und ländlichen Raumes ab (Abb. 1). Damit ist die analysierte Szene deutlich größer als die in früheren Vergleichen anderer Autoren herangezogenen Ausschnitte (z. B. MEINEL et al. 2001: urban: 5,76 km²; NEUBERT & MEINEL 2002: urban: 5,76 km², ländlich: 12,25 km²). Im Gegensatz zu kleinräumigen Beispielausschnitten muss der Klassifikationsschlüssel für eine Gesamtszene (urbaner Raum *und* ländlicher Raum) allerdings eine deutlich erhöhte Objektvielfalt und eine damit einhergehende erhöhte Varianz korrekt erfassen, wobei insbesondere die Übergangsbereiche zwischen Stadt und Land in den Form- und Größenparametern ihrer Objekte eine Zwischenstellung einnehmen und damit die korrekte Objekt- und Klassentrennung über die gesamte Szene auch auf Segmentbasis deutlich erschweren können.

Materialien und Methoden

Datenprozessierung

Die Ausgangsdaten des IKONOS-Satellitenbildes lagen zum Zeitpunkt des Projektstarts vollständig georeferenziert vor. Die Szene war bis auf einen sehr kleinräumigen und schwachen Schleier im Südwesten praktisch wolkenfrei. Da die Originalszene in allen Kanälen (RGB, NIR) nur die Grauwerte im unteren Bereich der gesamten zur Verfügung stehenden Farbtiefe (11 bit) belegte, wurde zur besseren Trennung der Signaturen eine Grauwertstreckung über das ganze Grauwertspektrum vorgenommen.

Software und methodische Konzepte

Das gesamte Gebiet der Szene wurde sowohl einer pixelorientierten (mit dem Erdas Imagine Knowledge Classifier V8.5) als auch einer segmentorientierten Klassifikationsmethode (mit Definiens eCognition V3) unterzogen. Analog zum Hauptprojekt wurde eine Teilklassifikation mit den Klassen Gehölze, Grünflächen sowie Gewässer angelegt.

Ableitung von Sekundärdaten

Zur erfolgreichen Klassifikation der Szene wurden aus der reinen Spektralinformation folgende weitere Daten abgeleitet: a) der NDVI, u. a. zur Unterstützung der Abgrenzung von Vegetation zu brach gefallenem oder verdichteten Gebieten sowie b) Texturwerte (jeweils einmal mit einer 3 × 3- und 7 × 7-Matrix berechnet, Abb. 2), u. a. zur besseren Abgrenzung von sehr heterogenen (z. B. Siedlungsgebiet, Forsten) zu homogenen Bereichen (z. B. Ackerflächen).

Außerdem standen weitere spektrale und thematische Zusatzdaten zur Verfügung, die auf ihre unterstützende Eignung in einer Klassifikation überprüft werden sollten. Mit einem Fusionsbild aus Landsat ETM+ (ms, 30 m) und IRS-1C-Daten (pan, 6 m) sollte vor allem die spektrale Auflösung verbessert und damit gegebenenfalls die Trennung der Klasse Gewässer unterstützt werden. ATKIS-Polygondaten standen zur Maskierung bereit. Auf die Verarbeitung eines Bildfusionsproduktes aus multispektralen (4 m) und panchromatischen (1 m) IKONOS-Daten – wie in anderen Projekten oft angewandt – wurde hier zu Gunsten einer maximalen Szenengröße (Rechenzeiten) verzichtet.

Berechnung der Klassifikationsgüte

Um die Güte der Klassifikationsergebnisse zu ermitteln, wurde für alle Klassen und beide methodischen Herangehensweisen ein Test mit dem „Erdas Imagine Accuracy Assessment Tool“ durchgeführt. Dazu wurden mit Hilfe des Zufallsgenerators pro Klassi-

fikation 50 Testpunkte innerhalb der Klasse gesetzt, um die Genauigkeit der Klassifikation (richtig vs. falsch erkannte Objekte) zu überprüfen. Zusätzlich wurden 50 weitere Punkte mit dem Zufallsgenerator im Bereich außerhalb der Klasse gesetzt, um auch die Reichweite der Klassifikation (nicht erkannte Objekte) als Gütekriterium mit einzubeziehen. Außerdem wurde die Güte jeweils über die gesamte Szene und nicht an spezifischen Ausschnitten berechnet.

Anwendung und Ergebnisse

Klassifikation mit dem Erdas Imagine Expert Classifier

Mit dem „Expert Classifier“, der als Teil der Software ERDAS IMAGINE Professional ausgeliefert wird, steht ein Klassifikations-tool zur Verfügung, das eine pixelorientierte Analyse auf der Basis eines vom Benutzer/Anwender entwickelten hierarchischen Regelwerkes durchführt. Dieser Ansatz hat zwei wesentliche Vorteile gegenüber auf

TTAs und statischer Interpolation basierenden Klassifikationsmethoden (ML oder MD):

- Die manuelle Festlegung von Grenzwerten ermöglicht eine präzisere Ansteuerung einzelner Signaturen.
- Es können gleichzeitig sowohl Spektraldaten, synthetische Kanäle (z. B. NDVI, Textur) als auch nicht-spektrale Daten (ggf. auch mit Nachbarschaftsinformation) als Entscheidungskriterien in die Klassifikation eingehen.

Im vorliegenden Projekt hat sich die Kombination dieser beiden Eigenschaften als entscheidender Vorteil für die Klassifikation der hoch auflösenden Daten erwiesen. Da allein auf der Basis von Spektraldaten keine korrekte Trennung zwischen Gehölzen und einigen Grünflächen möglich war, wurden zusätzlich der NDVI und Texturdaten in den Entscheidungsbaum einbezogen, während eine 7×7 -Hochpassfilterung Klassifikationslücken in Wald- und Forstbereichen bis auf wenige kleinräumige Ausnahmen

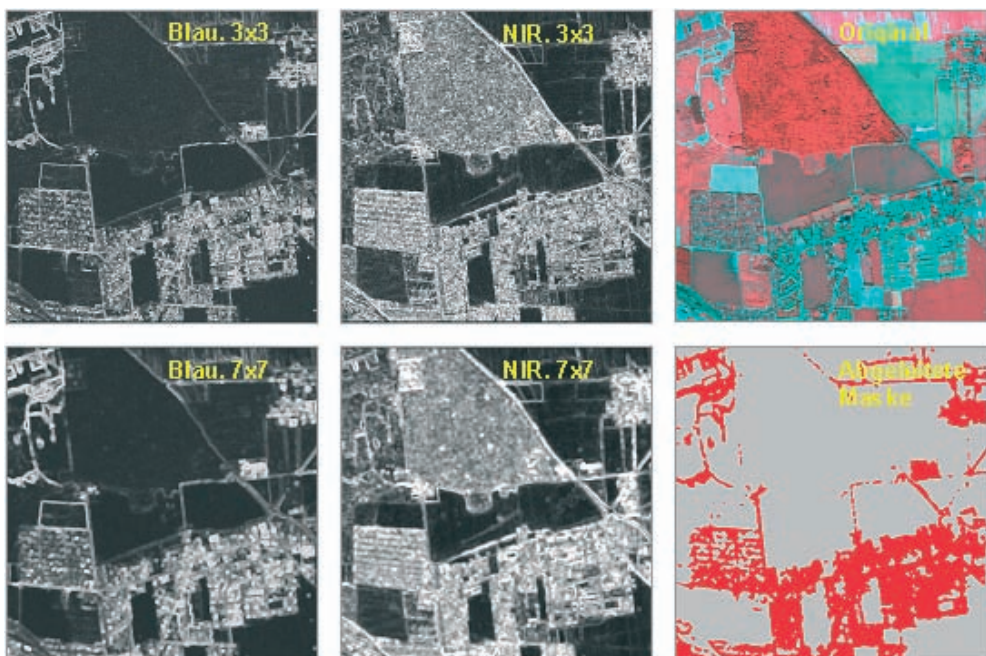


Abb. 2: Textur-Dateien aus verschiedenen Spektralkanälen des IKONOS-Satelliten und in verschiedener Matrixgröße. Hell = sehr heterogen, dunkel = sehr homogen.

schließen konnte (Abb. 3, links). Diese Vorgehensweise konnte allerdings nicht in gleichem Maße auf ländliche und urbane Gebiete angewendet werden: während die Texturdaten im ländlichen Bereich für eine deutliche Verbesserung der Klassifikationsgüte sorgten, führte die Randunschärfe der Texturdaten im urbanen Gebiet durch die Dominanz sehr kleiner Objekte (Solitär bäume) zu einer deutlichen Unterschätzung des Gehölzanteils.

Um diesem Fehler vorzubeugen wurden Siedlungsbereiche über die Klassifikation von Texturwerten des blauen und grünen Spektralanteils (hohe Reflexion bebauter Flächen) und der darauf folgenden Schließung kleinerer Lücken mit einem 7×7 -Hochpassfilter ausmaskiert (Abb. 2). In diesen Bereichen wurde anschließend auf den Einsatz von Texturdaten verzichtet. Auch für die Klassifikation von Gewässern konnte diese Maske erfolgreich eingesetzt werden, vor allem um Fehlklassifikationen im Bereich von Gebäudeschatten zu unterdrücken. Restfehler durch Gebäudeschatten in sehr locker bebauten Bereichen, die nicht erfolgreich von der Maske erfasst werden konnten, wurden über die Objektgröße (CLUMP & SIEVE < 20 Pixel) eliminiert.

Schwieriger gestaltete sich die Klassifikation von Grünflächen (Parks, Wiesen, Weiden), die explizit von ackerbaulich genutzten Flächen (bepflanzte Äcker) getrennt werden sollten. Zum Aufnahmezeitpunkt der Szene (18. 06. 2002) konnten diese weder auf der Basis von Spektralwerten noch mittels NDVI sicher unterschieden werden. Mit dem Einsatz von Texturdaten konnte zwar der Umstand genutzt werden, dass die Felder im Untersuchungsgebiet im Gegensatz zu Grünflächen über eine geringere Kleinstreliefierung und eine gleichmäßigere Artenzusammensetzung verfügen, was sich in leicht erhöhten Homogenitätswerten niederschlägt. Traktorensuren oder Vernäsungsbereiche sorgten aber auch in diesem Fall für Fehlklassifikationen, die sich nicht weiter effektiv reduzieren ließen (Abb. 3, links). Größenmaße (CLUMP & SIEVE), die von MEINEL et al. (2001) eingesetzt wurden, konnten in der vorliegenden Szene ebenfalls

nicht als sicheres Ausschlusskriterium herangezogen werden, da sowohl im Übergang zwischen urbanem und ländlichem Raum als auch in den innerstädtischen Auegebieten sehr große Grünflächen existieren, während gleichzeitig mit zunehmender Nähe zur Stadt und der damit einhergehenden Flächenzerschneidung die Größen der Ackererschläge z.T. deutlich unter die Ausdehnung der städtischen Grünflächen fallen. Auch der Einsatz spektral höher auflösender Daten des LANDSAT/IRS-Fusionsbildes stellte sich nicht als hilfreich für die Klassifikation heraus. Wenn man auf den Einsatz ggf. veralteter Sekundärdaten (wie z. B. ATKIS, Biotoptypenkartierung etc.) als Masken verzichtet, muss man zumindest bei dieser Klasse und zu dieser Jahreszeit mit deutlichen, kaum eliminierbaren Fehlern rechnen.

Klassifikation mit Definiens eCognition

Die segmentorientierte Klassifikation mit Definiens eCognition nutzt eine grundlegend andere Vorgehensweise als der Erdas Imagine ExpertClassifier: anstatt Pixel für Pixel einzeln zu klassifizieren, werden hier benachbarte Pixel mit ähnlichen Eigenschaften (homogene Gebiete) zu Segmenten zusammengefasst.

Ausgangspunkt dafür ist entweder das Pixel als kleinstes anzunehmendes Segment oder ein untergeordnetes Level mit kleineren Segmenten. Auf deren Basis führt eCognition ein „bottom-up region-merging“ der Nachbarn durch, wobei es aus dem Grad der Homogenität/Heterogenität der Nachbarn die Fusionskosten (*merging costs* → *degree of fitting*) für den jeweiligen Zusammenschluss ermittelt und diese dem vom Benutzer bestimmten „least degree of fitting“-Wert (*scale parameter*, definiert über das *composition of homogeneity criterion*) gegenüberstellt. Liegen die Fusionskosten unter dem vom User bestimmten Grenzwert, wird die Fusion durchgeführt, liegt sie darüber, wird der „region-merging“-Prozess abgebrochen und damit eine Grenze des Objektes definiert (BAATZ & SCHÄPE 2000). Leider hängt




Abb. 3: Links Klassifikationsergebnisse mit Erdas Imagine Knowledge Engineer, rechts mit Definiens eCognition. Zur besseren Erkennbarkeit sind Gehölze in gelb und Grünflächen in rot dargestellt.

die Qualität der „multiresolution segmentation“ mit einer bestimmten Parameterkonstellation (*scale parameter* und *composition of homogeneity criterion*) stark von den Eigenschaften der Eingangsdaten ab und ist damit kaum standardisierbar. Deshalb muss die jeweils am besten geeignete Parameterkonstellation für jede Szene iterativ neu evaluiert werden („trial and error“ – Prinzip, u. a. MEINEL et al., 2001; NEUBERT & MEINEL, 2002) – was aufgrund der enormen Rechenzeiten für eine Vollszene effektiv nur an Testgebieten geschehen kann. In der Praxis ließen sich die Ergebnisse bzw. Qualitäten aus diesen Testgebieten allerdings nicht zufrieden stellend auf die gesamte Szene übertragen, sodass die Evaluation an der Gesamtszene durchgeführt werden musste – ein extrem zeitaufwendiger Prozess, der mehr Zeit in Anspruch nahm als die anschließende Klassifikation. Als Daten für die Segmentierung gingen letztendlich die Kanäle 2–4 (gleich gewichtet) jeweils mit den *scale parametern* 05, 15, 50 und 100 sowie dem *composition of homogeneity criterion* 0.7 (color) / 0.3 (shape) sowie 0.5 (smoothness) / 0.5 (compactness) ein.

Dafür gestaltete sich die Klassifikation auf der Basis der definierten Segmente/Ob-

jekte einfacher als mit dem zuvor beschriebenen pixelorientierten Ansatz. Verantwortlich dafür waren vor allem zwei Vorteile des segmentorientierten Ansatzes: die angelegte Hierarchie aus kleinen Sub-Objekten (Level 1, scale parameter 05) und sukzessive ansteigenden großen Super-Objekten (Level 2, 3 und 4, scale parameter 15, 50, 100) ermöglicht es, die korrekt klassifizierte Objekte sowie die Masken für falsch klassifizierte Objekte nicht mehr auf ein und demselben Level definieren zu müssen, sondern das jeweils geeignetste Level (Aggregations- und Abstraktionsgrad) dafür zu wählen und diese anschließend zu verknüpfen. Außerdem stellen die Segmente Form und Nachbarschaftsdaten für die anschließende Klassifikation zur Verfügung, auf die im pixelorientierten Ansatz als Entscheidungskriterium nicht zurückgegriffen werden kann.

Im konkreten Fall der Klasse Gehölze konnte zwar auf der Ebene der kleinsten Objekte (scale parameter 05), in der Solitärgehölze ausklassifiziert werden sollten, Fehlklassifikationen durch Traktorensuren nicht unterdrückt werden. In einem Superlevel (scale parameter 50) gingen diese aber erfolgreich in der Klasse Acker auf und konnten somit ausmaskiert und rückver-

knüpft werden. Außerdem konnte der Objektzusammenhang für die Klassifikation größerer Forste auf der Basis größerer Segmente gegenüber dem pixelorientierten Ansatz verbessert werden (Abb. 3, rechts). Die gleiche Vorgehensweise führte auch zu einer deutlichen Verbesserung der Ergebnisse für die Klasse Grünflächen (Abb. 3, rechts).

Für die Klasse Gewässer ergaben sich die Vorteile in der Klassifikation gegenüber dem pixelorientierten Ansatz nicht so sehr aus der hierarchischen Betrachtung zwischen Sub- und Superobjekten, sondern aus dem Vergleich der Nachbarn. So konnten bei der Klassifikation von Gewässern Gebäudeschatten als Fehlklassen erfolgreich ausgeschaltet werden, da der Kontrast zwischen dem Gebäudeschatten und dem dazugehörigen Hausdach in der Regel deutlich größer ausfiel als der Kontrast zwischen dem Gewässer und seinem Ufer („mean difference to brighter neighbours“).

Zusammenfassung und Ausblick

Durch die Gegenüberstellung einer pixelorientierten und einer segmentbasierten Klassifikation auf der Basis eines hochauflösenden IKONOS-Satellitenbildes konnten sowohl Vor- als auch Nachteile beider Ansätze erfolgreich miteinander verglichen werden. Dabei stellte sich heraus, dass insbesondere Klassen/Objekte, die sich allein auf der Basis von pixelbasierten Spektral- und Strukturinformationen nicht erfolgreich trennen lassen (z. B. Wiesen und Parks vs. Ackerflächen), durch die Abstraktionsleistung des segmentorientierten Ansatzes deutlich genauer ausklassifiziert werden können (EI: 73%; eCognition: 93%). Darüber hinaus konnte mit dem segmentbasierten Ansatz vor allem bei größeren Objekten (z. B. Wäldflächen) der Objektzusammenhang verbessert und der Salt-and-Pepper Effekt effizient verringert werden.

Im Gegensatz dazu lieferte die segmentbasierte Verarbeitung bei der Klassifikation sehr homogener (z. B. Gewässer: EI: 97%; eCognition: 97%) oder sehr kleiner Objekte (z. B. Solitärgehölze: EI: 97%; eCognition: 96%) keinen entscheidenden Vorteil gegen-

über pixelbasierten Verfahren. Die Vorteile der von eCognition genutzten Objekthierarchien und Nachbarschaftsbeziehungen treten in diesen Fällen in den Hintergrund, während Probleme bei der korrekten Segmentdefinition bzw. durch die sinnvollen Mindestgröße der Segmente (Unterdrückung von Objekten nahe der Pixelebene) evident werden.

Damit etabliert sich die segmentbasierte Klassifikation insbesondere für die Erkennung und Verarbeitung komplexer Klassen/Objekte in hoch auflösenden Datensätzen, während pixelorientierte Ansätze für die Verarbeitung geringer auflösender Daten sowie für spektral/strukturell leicht abgrenzbare Klassen auch in Zukunft eine geeignete Alternative darstellen.

Danksagung

Der vorliegende Beitrag ist aus einem Folgeauftrag zum ursprünglichen Forschungsprojekt: „Analyse und Bewertung des Naturraumpotenzials in der suburbanen Kulturlandschaft mit Methoden der Fernerkundung und GIS“ entstanden. Das genannte Projekt wie auch die anschließende Verlängerung der Forschungsarbeiten wurde freundlicherweise vom Umweltforschungszentrum Leipzig-Halle GmbH (Förderkennzeichen UFZ 12–99) finanziert.

Literatur

- 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, H. Wichmann Verlag, Karlsruhe.
- BECKER, W., 1998: Die Eigenart der Kulturlandschaft – Bedeutung und Strategien für die Landschaftsplanung. – VWF – Verlag für Wissenschaft und Forschung, Berlin.
- BLASCHKE, T., 2000: Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: Neue Möglichkeiten für GIS-Anwender und Planer. – In: SCHRENK, M. (Hrsg.): CORP'2000: Computergestützte Raumplanung. – Band 1, 153–162, Wien.

- BLASCHKE, T. & STROBL, J., 2001: What's wrong with pixels? Some recent developments inter facing remote sensing and GIS. – *GIS* **6**: 12–17.
- LANG, S. & BLASCHKE, T., 2003: Hierarchical object representation – comparative multi-scale mapping of anthropogenic and natural features. – *ISPRS Archives* **34** (2003), Part 3/W 8: 181–186.
- MANSBERGER, G., 2000: Erste Erfahrungen mit 1-Meter-Satellitendaten von IKO-NOS. CORP'2000: Computergestützte Raumplanung – Archiv: <http://www.corp.at/archiv/corp—1996—2002.htm>.
- MEINEL, G. & REDER, J., 2001: IKONOS-Satellitenbilddaten – ein erster Erfahrungsbericht. – *Kartographische Nachrichten* 1/01: 40–46.
- MEINEL, G., NEUBERT, M. & REDER, J., 2001: Pixelorientierte versus segmentorientierter Klassifikation von IKONOS-Satellitenbilddaten – ein Methodenvergleich. – *Photogrammetrie – Fernerkundung – Geoinformation* **2001** (3): 157–170.
- NEUBERT, M. & MEINEL, G., 2002 Segmentbasierte Auswertung von IKONOS-Daten – Anwendung der Bildanalyse-Software eCognition auf unterschiedliche Testgebiete. – In: BLASCHKE, T. (Hrsg.): *Fernerkundung und GIS: Neue Sensoren – innovative Methoden.* – pp. 108–117, H. Wichmann Verlag, Heidelberg.
- STEILEN, G., 2002: Klassifikation hochauflösender Satellitendaten mit Hilfe der Segmentierungssoftware eCognition. – Diplomarbeit, Göttingen.
- WALZ, U., SYRBE, R.-U., DONNER, R. & LAUSCH, A., 2001: Erfassung und ökologische Bedeutung der Landschaftsstruktur. – *Naturschutz u. Landschaftsplanung* **33**: 101–105.

Anschriften der Autoren:

Dipl.-Geogr. LOTHAR LINDE
 Prof. Dr. WERNER KIRSTEIN
 Universität Leipzig, Institut für Geographie
 Johannisallee 19a, 04103 Leipzig
 Tel.: 0341-973 2956, Fax: 0341-971 1837
 e-mail: Lothar.Linde@rrcap.unep.org
 kstein@rz.uni-leipzig.de

Manuskript eingereicht: Februar 2004
 Angenommen: März 2004