

Pixelorientierte versus segmentorientierte Klassifikation von IKONOS-Satellitenbilddaten – ein Methodenvergleich

GOTTHARD MEINEL, MARCO NEUBERT & JOHANNES REDER, Dresden

Zusammenfassung: Die Arbeit beschreibt die Klassifikation von IKONOS-Satellitenbilddaten mit einem pixel- und einem segmentorientierten Ansatz. Hierzu werden nach kurzer Charakterisierung des IKONOS-Bildmaterials die Klassifikationsprogramme ExpertClassifier (ERDAS) und eCognition (Definiens) vorgestellt, die erarbeiteten Klassifikatoren beschrieben und die jeweils erreichte Erkennungs- und Klassifikationsgüte verglichen. ExpertClassifier stützt sich auf eine für hochauflösendes Bildmaterial nur begrenzt leistungsfähige, pixelorientierte Klassifikationsstrategie, lässt aber in der Implementierung kaum Wünsche offen. Mit eCognition wird ein neuer Klassifikationsansatz verfolgt, indem zuerst Pixel homogener Gebiete zu Segmenten zusammengefasst werden. Für die Klassenzuweisung der Segmente können neben der spektralen Signatur auch Form, Größe sowie Nachbarschafts- und Hierarchiebeziehungen genutzt werden. Diese Faktoren werden mit steigender Bildauflösung immer wichtiger und ermöglichen zunehmend differenziertere, nutzungsorientierte Klassifikationsschlüssel. Allerdings lässt die derzeitige Implementierung von eCognition (Version 1.0) noch viele Wünsche offen.

Summary: *Pixel-driven versus segment-driven classification of IKONOS satellite imagery – a comparison of methods.* The study describes classification of IKONOS satellite imagery using a pixel and a segment-driven approach. To this end, following a brief portrayal of the IKONOS image material, the ExpertClassifier (ERDAS) and eCognition (Definiens) classification programs are introduced, the classifiers elaborated are described, and the respective qualities of recording and classification are compared. ExpertClassifier draws on a pixel-driven classification strategy that is not unrestrictedly effective for high-resolution material but leaves little to be desired in terms of implementation. With eCognition, a new approach to classification is pursued whereby pixels of homogeneous areas are initially collated into segments. As well as by spectral signature, classification of segments can be effected with reference to form, size, neighbourhood and hierarchy relations. These factors grow in importance as image resolution increases and facilitate ever more nuanced, use-driven classification keys. Implementation leaves a lot to be desired with eCognition (Version 1.0), however.

1 Einführung

Im Rahmen eines von der Deutschen Forschungsgemeinschaft geförderten Projektes zum Nutzen und zur Anwendung neuer, hochauflösender Satellitenbilddaten in der Raumplanung (Me 1592/1–2) wurden IKONOS-Daten für einen urban geprägten Raum (Stadtgebiet Dresden) klassifiziert. Dazu wurde ein pixelbasierter Klassifikationsansatz mit einem segmentbasierten verglichen. Zur Anwendung kamen jeweils neu-

este Softwareimplementierungen: ExpertClassifier (Version 8.4.1, ERDAS) und eCognition (Version 1.0, Definiens).

2 Informationen zu IKONOS-Satellitenbilddaten

Im Folgenden sollen einleitend einige wichtige Informationen zu IKONOS-Satellitenbilddaten gegeben werden, eine ausführliche Beschreibung findet sich in MEINEL & REDER

(2001). Die Daten haben eine geometrische Auflösung von 1 m im panchromatischen, und 4 m in den vier multispektralen Kanälen (VIS, NIR). Derzeit werden Daten im Wesentlichen nur auf Bestellung aufgenommen, da diese bedingt durch die geringe Schwadbreite erst punktuell vorliegen. Seit kurzem ist allerdings auch der Bezug von Archivdaten möglich. Mindestfläche ist hier 25 km² bei den gleichen Kosten pro km² wie sie für die Erstaufzeichnung gelten (18 US-\$ für PAN, 18 US-\$ für MS, 24 US-\$ für PSM mit 3 Kanälen und 29 US-\$ für PSM mit 4 Kanälen).

Der Mindestbestellwert für eine Datenaufzeichnung beträgt 3000 US-\$, die Mindestfläche 11 km × 11 km. Die Aufnahme-grenze muss nicht zwangsläufig rechteckig geschnitten sein, auch irreguläre Begrenzungen sind möglich. Die wichtigsten Bestellan-gaben sind die 4 Eckpunkte des gewünschten Aufnahmegebietes, ein Zeitfenster innerhalb dessen die Aufnahme erfolgen soll, die Bitbreite (8 oder 11 Bit) und der gewünschte Produkttyp. Derzeit werden die Daten unter der Bezeichnung CARTERRA in den drei Produktformen 1-P (1 m panchromatisch), 4-MS (4 m multispektral) und 1-PSM (durch das panchromatische Bild geschärftes 3-kanaliges Naturfarb- oder Infrarotprodukt oder alle vier geschärfte Einzelkanäle) angeboten.

Die Repetitionsrate von IKONOS ohne Sensorschwenk beträgt 140 Tage. Durch Schwenkung bis zu 26° reduziert sich die Repetitionsrate bis auf 1,5 Tage, was allerdings mit Auflösungseinbußen einhergeht. Auch das einfachste Produkt CARTERRA Geo ist unter Nutzung eines vordefinierten Ellipsoids (WGS84) und einer Kartenprojektion (z. B. UTM) entzerrt. Damit sind die Daten prinzipiell sofort in Geoinformationssystemen verwendungsfähig (GIS ready).

Zwischen Öffnung des Aufnahmefensters und Aufnahmedatum lagen bei der bestellten IKONOS-Szene 20 Tage, die Lieferzeit betrug 5 Tage. Für alle Aufgaben außerhalb des Desastermonitorings sind diese Zeiten erfreulich kurz. Jedoch muss bei IKONOS-Bestellungen ein Bewölkungsgrad bis zu 20%! akzeptiert werden. Sind geringere Be-

wölkungsgrade gewünscht, muss zu den ohnehin hohen Produktpreisen ein erheblicher Aufpreis gezahlt werden. In der Bildmitte der Dresdner Szene ist durch Bewölkung und daraus resultierender Schattenfläche ein Informationsausfall von insgesamt 18%! der Gesamtfläche zu verzeichnen. Es muss darum vermutet werden, dass die Aufzeichnung zum frühest möglichen Aufnahmetermin erfolgt, der bezüglich Bewölkungsgrad und Schwenkbereich die Standardbedingungen erfüllt.

3 Beurteilung der IKONOS-Bildqualität

Die Qualität der Bilddaten kann mit sehr gut bewertet werden (Abb. 1). In den panchromatischen Bildern sind bei großem Kontrast durchaus die weißen Linien von Sportplatz-, Parkflächen- und Straßenmarkierungen sichtbar. Die radiometrische Auflösung ist mit 11 Bit sehr hoch. Während die panchromatischen Bildprodukte standardmäßig einer Grauwerttransformation (Dynamic Range Adjustment, DRA) unterzogen werden, kommen die multispektralen Daten ungestreckt zur Auslieferung. Gebäudedächer, Hausfassaden, offene Böden und in wenigen Fällen auch Kraftfahrzeuge führten teilweise zu Übersteuerungspunkten (0,08% der Fläche des panchromatischen Bildes), allerdings in keinem Fall zu nachfolgenden Streifenausfällen.

In den drei Kanälen des sichtbaren Spektrums der MS-Aufnahme wurde nur das erste Drittel, im nahen Infrarot ca. die Hälfte der zur Verfügung stehenden Grauwertbereiche ausgenutzt. Im multispektralen Bilddatensatz waren nahezu keine Übersteuerungspunkte zu detektieren. Teilweise wirkt sich der Schrägblick des Sensors problematisch auf die Auswertbarkeit der Bilddaten aus. So ist bei der Szene der Stadt Dresden, die mit einem Schwenkwinkel von 14° (76,8° Nominal Collection Elevation) aufgenommen wurde, die Kippung von Gebäuden deutlich zu sehen. Damit kommt es sowohl bei der Klassifikation durch Abbildung von Fassaden als auch der Kartierung durch Kantenverdeckung zu Problemen.

Durch die zeitgleiche Aufnahme von multispektralen und panchromatischen Bilddaten und die identischen Szeneneckkoordinaten ist Lage-Identität zwischen diesen Bilddaten gegeben, so dass die Berechnung einer Bildfusion sofort und in hoher Qualität bezüglich der Bildschärfe erfolgen kann.

Das Produkt CARTERRA Geo ist lediglich orbitentzerrt. Ohne Berücksichtigung reliefbedingter Verzerrungen wird seitens Space Imaging ein mittlerer Lagefehler von $< \pm 50$ m für 90 % der Punkte (CE90) bzw. $\pm 23,6$ m für 66,6 % der Punkte (RMSE) zugesichert. Dieser wurde aber mit 108 m mittlerem Lagefehler in x- und 144 m in y-Richtung wesentlich überschritten. Nur bei sehr geringem Sensorschwenkwinkel und geringer Reliefenergie kann auf eine Orthorektifizierung verzichtet werden. In den meisten Fällen wird sie jedoch notwendig sein, um die preisintensiven Bildprodukte entsprechend in Wert zu setzen. Da Space Imaging keinerlei Informationen zu dem Sensormodell und den Orbitparametern veröffentlicht, ist keine exakte Orthorektifizierung möglich und derzeit sind nur Näherungslösungen berechenbar (KERSTEN et al. 2000, TOUTIN & CHENG 2000). Stehen keine Modelle für eine Orthorektifizierung zur Verfügung, müssen die Bilddaten im not-

wendigen Präzisionslevel gekauft werden. Spätestens dann aber sind die Produktpreise so hoch, dass sie nicht mit Preisen von Ortholufbilddaten konkurrieren können.

4 Beschreibung des Untersuchungsgebietes

Für die Klassifikation sollte eine Teilfläche der IKONOS-Szene von Dresden ausgewählt werden, die viele verschiedene Bodenbedeckungs- und Flächennutzungsarten enthält. Dies trifft für einen Teil des westlichen Stadtgebietes Dresdens zu, welcher in einer Größe von $2,4 \text{ km} \times 2,4 \text{ km}$ ausgeschnitten wurde (Abb. 1). Im nördlichen Bereich liegen Areale mit überwiegender Industrie- und Gewerbenutzung. Im südlichen Teil sind neben landwirtschaftlichen Flächen auch Wohngebiete in Form von Einzelhaus- und Blockbebauung, Industrie-, Gewerbeflächen, Bahnflächen und -trassen, Kleingarten- und Parkanlagen, Friedhofsareale, Obstplantagen, Waldgebiete und ausgedehnte Wiesen- und Grünlandbereiche zu finden. Daneben treten Flächen auf, die erst in jüngster Vergangenheit verändert wurden bzw. sich noch in Bebauung befinden (offener Boden). Hierunter fallen u.a. Straßenneubauten, die z. B. in den digitalen



Abb. 1: Lage des Untersuchungsgebietes (grau dargestellt) in Dresden und innerhalb der IKONOS-Gesamtszene sowie panchromatischer Bildausschnitt (©Space Imaging Europe SA).

Blockdaten der Stadt Dresden (Stand 1999) noch nicht verzeichnet waren.

Weiterhin sollte das Gebiet relativ eben sein, um Lagefehler durch die fehlende Möglichkeit einer Orthorektifizierung gering zu halten.

5 Bildvorverarbeitung

Die IKONOS-Bilddaten (Aufnahmedatum 04.06.2000, 10.50 Uhr Ortszeit) mussten vor der Klassifizierung georektifiziert werden, da weitere Geodaten in die Klassifikation einbezogen werden sollten. Referenz für die Entzerrung bildete ein digitales Ortholuftbildmosaik aus dem Jahr 1999 mit einer Rasterweite von 1 m und einer Lagegenauigkeit von $\leq 0,5$ m. Auf den panchromatischen Bilddaten wurden 37 Passpunkte gleichverteilt generiert. Aus den Passpunkten errechnete sich mit einer polynomialen Transformationsgleichung zweiten Grades ein RMS-Fehler von 0,53 m ($\Delta x = 0,33$ m, $\Delta y = 0,42$ m). Die Transformationsgleichung kann wegen der identischen Bildlage von panchromatischen und multispektralen Bilddaten auch für die MS-Bildentzerrung verwendet werden. Die multispektralen Kanäle wurden zur Beibehaltung der Grauwerte für die spätere multispektrale Klassifikation mittels Nearest Neighbour, der panchromatische Kanal zur Vermeidung von Bildartefakten (z. B. Treppeneffekt) mit Cubic-Convolution auf die Projektion Transverse Mercator, Spheroid Bessel resampelt. Aufgrund des relativ ebenen Geländes traten in dem Bildausschnitt kaum Lageprobleme auf, die maximale Lageabweichung im Untersuchungsgebiet beträgt ≤ 3 m.

6 Verwendete Eingangsdaten und Klassifikationsschlüssel

Aus Fernerkundungsbildmaterial allein können auch bei der durch IKONOS weiter gesteigerten geometrischen Bildauflösung nicht alle gewünschten Bodenbedeckungs- und Nutzungsklassen in ausreichender inhaltlicher und geometrischer Genauigkeit extrahiert werden. Die Einbeziehung zuneh-

mend flächendeckend vorhandener Geobasisdaten ermöglicht eine Verbesserung der Klassifikationsergebnisse (multi-source data fusion) und wurde deshalb auch im Rahmen der hier vorgestellten Arbeiten angewandt. Dabei kamen nur solche digitalen Geodatensätze in Betracht, die standardisiert und nahezu flächendeckend für Deutschland verfügbar sind.

Für die Klassifikation mit ExpertClassifier wurden die vier MS-Kanäle des IKONOS-Sensors (4 m Bodenauflösung), der Vegetationsindex NDVI sowie die zweite Hauptkomponente verwendet. Weitere Eingangsdaten waren ein aus den panchromatischen Bilddaten berechneter, modifizierter Texturlayer und eine durch statistische Operationen überarbeitete, unüberwachte Klassifikation.

Als Zusatzdaten kamen eine digitale Blockkarte (Digitalisierungsmaßstab 1:5000) sowie ein ATKIS-Datensatz zum Einsatz. Die Blockkarte ermöglichte die Abgrenzung von Straßenflächen (Blockrestfläche), die sich aus Fernerkundungsdaten aufgrund von Baumkronenverdeckung und einer Vielzahl unterschiedlicher Straßenbeläge nur unzulänglich klassifizieren lassen. Ein ATKIS-DLM25/1 wurde im Rahmen der pixelbezogenen Klassifikation zur Sicherung von unklaren Hypothesen bei speziellen Nutzungsklassen (Bahnfläche, Klärbecken) herangezogen. Bei Verwendung des ATKIS-Datensatzes wurde darauf geachtet, dass nur nahezu unveränderliche Flächennutzungen (z. B. Friedhöfe, Gleisanlagen und Flussläufe) in die Klassifikation Eingang fanden. Andere Flächen könnten sich, wenn man den Fortschreibungsstand von ATKIS-Daten bedenkt (im vorliegenden Fall 1993), in ihrer Nutzung bzw. Bodenbedeckung geändert haben. Ein ATKIS-DGM25 diente zur Vermeidung von Fehlklassifikationen von Gewässerflächen durch die Einbeziehung der bekannten Höhenlage der Elbe.

Grundlage der Segmentierung und Klassifikation mit eCognition war ein Bildprodukt aus panchromatischem Kanal und den vier multispektralen IKONOS-Kanälen, welches durch Bildfusion mittels Haupt-

komponentenverfahren berechnet wurde. Voruntersuchungen zeigten, dass mit diesem Fusionsbild (1 m Rasterweite) die Grenzen von Bodenbedeckungsklassen genauer erfasst werden konnten, als allein mit den multispektralen Daten (4 m Rasterweite) bzw. den panchromatischen Bilddaten allein. Weiterhin wurde der panchromatische Kanal des IKONOS-Bildes verwendet, der zur Abgrenzung sehr kleiner Objekte (z. B. Bäume und Gartenlauben) auf dem feinsten Segmentierungsniveau hilfreich war. Ein aus den IKONOS-Daten berechneter Vegetationsindex (NDVI) diente zur Trennung von vegetationsbedeckten und vegetationslosen Flächen sowie verschiedener Vegetationsbedeckungen (z. B. Wiese/Wald) in der Klassifikation. Auch in diesem Ansatz half der aufgerasterte digitale Blockdatensatz zur Straßenextraktion und zur Gebietsstrukturierung auf dem groben Segmentierungsniveau.

Da in eCognition nicht mit unterschiedlichen Rastergrößen der Eingangsdaten gearbeitet werden kann, mussten alle Daten auf die kleinste Rastergröße transformiert werden. Dies bedeutete eine Umrechnung aller Daten auf 1 m Rasterweite und damit eine enorme Vergrößerung der Eingangsdatensmenge.

Ursprüngliches Ziel im Rahmen des Klassifikationsvergleichs war die Verwendung des gleichen Klassifikationsschlüssels. Dieser musste im Verlauf der Arbeiten teilweise modifiziert werden (Tab. 1), da bei der Klassifikation mittels eCognition durch die Einbeziehung von Nachbarschaftsbeziehungen und Formfaktoren eine differenziertere und teilweise nutzungsorientierte Klassenbildung ermöglicht wurde (z. B. Sport-, Parkplätze, Obstanbau).

7 Pixelbasierte Klassifikation mit ExpertClassifier

7.1 Kurzbeschreibung der Implementierung

Mit dem ExpertClassifier stellt ERDAS in der Version 8.4 erstmals einen regelbasier-

ten, hierarchischen Klassifikationsansatz zur Verfügung. Bestandteile des ExpertClassifiers sind der Knowledge Engineer, der die Erstellung wissensbasierter Entscheidungsbäume mit Hilfe eines grafischen Editors ermöglicht und der Knowledge Classifier für die spätere operationelle Anwendung des Klassifikators. Für jede Klasse muss ein eigener Entscheidungsbaum entwickelt werden, der aus Hypothesen, Regeln, Bedingungen und Variablen besteht. Hypothesen beinhalten im Allgemeinen die zu generierenden Klassen, Regeln die Entscheidungskriterien, die es mittels Variablen und Bedingungen zu prüfen gilt. Die Verbindung der einzelnen Hypothesen, Regeln und Variablen erfolgt durch logische Verknüpfung.

In dem Regelwerk können neben Bilddaten selbst auch Höhenmodelle, Hangneigung, Exposition sowie alle Arten synthetischer Kanäle (NDVI, Ratios, Texturen etc.) verwendet werden. Ebenso können Vektorlayer einschließlich ihrer Attributwerte eingebunden werden (Vektordaten werden allerdings intern aufgerastert). Daneben bietet der ExpertClassifier auch die Möglichkeit, Programme (SML und C-Programme) in die Entscheidungsbäume einzubinden. Damit ist es z. B. möglich, nur Flächen einer definierten Größe für die Zuweisung zu einer Klasse zuzulassen oder verschiedenste statistische Berechnungen, Filterungen, logische Verknüpfungen und Kombinationen dieser Operationen direkt in der Klassifikation zu nutzen. Eingangslayer müssen weder die gleiche Rasterauflösung haben, noch müssen sie identische Flächen abdecken. Sinnvolle Ergebnisse sind jedoch nur im Überschneidungsbereich aller Eingangslayer zu erwarten. Unsichere Aussagen können in ExpertClassifier durch die Wahl eines Confidence Levels gewichtet werden.

Für die Evaluierung einer Klassifikation bietet das Programm einen Pathwaycursor, mit dessen Hilfe für jeden Klassifikationspunkt die verwendeten Regeln (Strang innerhalb des Entscheidungsbaumes) visualisiert und ggf. interaktiv verbessert werden können. Neben gesamten Entscheidungsbäumen können auch einzelne Komponen-

ten innerhalb dieser aktiviert bzw. deaktiviert werden, was zu einer schnellen Evaluierung und sukzessiven Verbesserung der Klassifikation führt.

Das mit Hilfe des Knowledge Engineer erstellte Regelwerk kann durch Verwendung des Knowledge Classifiers auf andere Datensätze übertragen werden. Hierzu müssen die Eingangsdatensätze in dem erstellten Klassifizierungsmodell als Abfragevariable definiert werden. Gleichzeitig werden alle im Regelwerk integrierten Programme und grafischen Modelle übernommen.

7.2 Klassifikation mit ExpertClassifier

Grundlage für die Erstellung des Entscheidungsbaumes war das Wissen um die spektralen Eigenschaften der Bodenbedeckungsarten, die Rauigkeit innerhalb der Flächen, typische Flächengrößen und Höhenlagen. Die für die Bestätigung der Kriterien herangezogenen Variablen ergaben sich einerseits aus Vorwissen und relativ sicheren Annahmen, andererseits durch die Bestimmung geeigneter Diskriminanzwerte durch Ausmessen der multispektralen Kanäle und synthetischen Datensätze. Durch die zur Verfügung stehenden Evaluationswerkzeuge wurde die Klassifikation sukzessiv verbessert.

Abb. 2 zeigt exemplarisch den Entscheidungsbaum für die Klasse Acker. Es wurde die Regel aufgestellt, dass Ackerflächen zum Zeitpunkt der Aufnahme (04.06.2000) vege-

tationsbedeckt sind, eine relativ homogene Oberfläche (geringe Rauigkeit) zeigen und eine Mindestgröße von 0,6 ha haben. Diese einzelnen Annahmen werden im weiteren Verlauf wiederum als Hypothesen formuliert, als Regeln aufgestellt und mit den entsprechenden Variablen und Bedingungen definiert. Hinter der Variable Rauigkeit verbirgt sich der aus dem panchromatischen Kanal generierte und modifizierte Texturlayer. Das Maß der Vitalität wurde aus dem NDVI abgeleitet. Die Klassifikation erfolgte nun durch Auswahl der Pixel, die sowohl einen $NDVI > 0,5$ als auch eine Rauigkeit < 1900 aufweisen (Diskriminanzfunktion), eine Zusammenfassung derartiger, benachbarter Pixel (Segmentbildung durch CLUMP) und nachfolgender Auswahl von Segmenten $> 0,6$ ha (SIEVE). Diese Funktionen wurden im Spatial Modeller implementiert und in den Entscheidungsbaum eingebunden.

Für die Klasse Bahnflächen/Gleisanlagen konnte aufgrund des langzeitstabilen Charakters dieser Flächen auf ATKIS zurückgegriffen werden. Der ExpertClassifier bietet die Möglichkeit, Vektorattribute, in diesem Fall die ATKIS-Kennung für Bahnflächen (3501), auszuwerten. Zusätzlich diente die spektrale Signatur dieser Flächen als Entscheidungskriterium.

Die Rechenzeiten für die Untersuchungsfläche waren so gering, dass eine schnelle Evaluierung und umfassende Verbesserung der Klassifikation möglich waren.

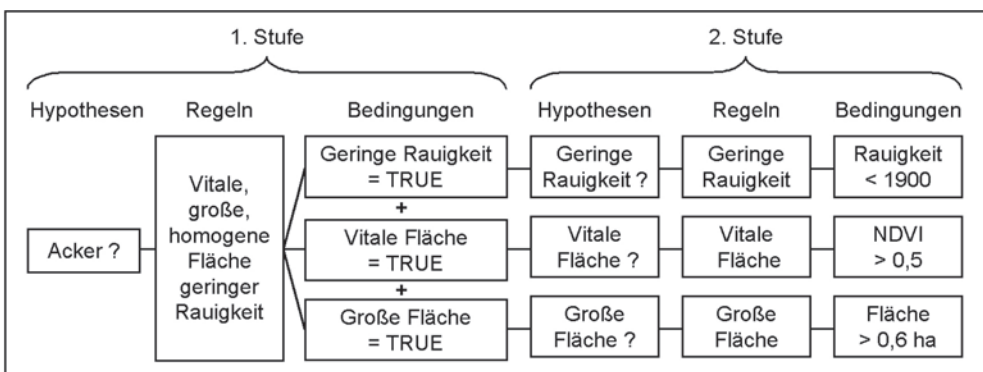


Abb. 2: ExpertClassifier-Entscheidungsbaum für die Klasse Acker.

8 Segmentbasierte Klassifikation mit eCognition

8.1 Kurzbeschreibung des methodischen Ansatzes

Die Firma Definiens AG (früher Delphi2) bietet seit Ende 2000 mit eCognition ein Softwareprodukt an, welches sich von pixelbasierten Methoden löst und segmentorientiert klassifiziert. Das Konzept der Software beruht auf der Fractal Net Evolution-Technik, wobei komplexe Sachverhalte mittels semantischer Netze dargestellt werden. Grundlegende programmtechnische Beschreibungen der Software sind bei BAATZ & SCHÄPE (1999, 2000) sowie im Online User Guide zu finden. Die Untersuchungen wurden im Rahmen einer Beta-Testung mit der Version 1.0 (26.06.2000) durchgeführt.

Die Software eCognition geht von einem segmentorientierten Ansatz aus, d. h. im ersten Schritt werden homogene Flächen zu Bildsegmenten zusammengefasst. Im zweiten Schritt – der eigentlichen Klassifikation – wird ein wissensbasierter Entscheidungsbaum erstellt, wobei der Klassifikationsprozess entweder über fuzzy logic basierte Zugehörigkeitsfunktionen oder durch die Auswahl von Testflächen (Nearest Neighbour-Klassifikator) erfolgen kann. Durch das Anlegen mehrerer Segmentierungsebenen entsteht ein semantisches Netzwerk von Bildsegmenten. So können neben den Grauwertinformationen selbst Relationen zu benachbarten, unter- oder übergeordneten Bildsegmenten sowie Formeigenschaften genutzt werden. Durch die Bildung von Segmenten wird das unvermeidliche „Salt and Pepper“-Rauschen von pixelbasierten Ansätzen vermieden (BLASCHKE 2000a, BLASCHKE 2000b).

Bei eCognition handelt es sich im Gegensatz zu ERDAS Imagine um ein reines Bildanalysesystem, welches derzeit ausschließlich auf PC-Basis implementiert ist. Bildverarbeitungsoperationen, die der Klassifikation vorausgehen, müssen außerhalb von eCognition mit einem Bildverarbeitungsprogramm (in diesem Fall ERDAS Imagine) ausgeführt werden. Als Ein-

gangsdaten lässt das System nur Rasterdaten zu.

8.2 Segmentierung mit eCognition

Die Segmentierung der Rasterdaten in homogene Areale und damit die Abstraktion von Rasterzellen zu Regionen stellt die Basis des eCognition-Ansatzes dar. Dadurch wird die Anzahl der zu klassifizierenden Bildelemente stark verringert und der Datenumfang deutlich reduziert. Die Segmentierung lässt sich insbesondere durch den Scalefaktor steuern, der indirekt die Größe der Segmente bestimmt. Um die für das jeweilige Bild beste Segmentierung zu erreichen, müssen die Segmentierungsparameter letztlich durch wiederholte Versuche herausgefunden werden.

Um den Einfluss des Scalefaktors auf die durchschnittliche Segmentgröße zu ermitteln, wurde anhand einer Beispielfläche (840×700 Pixel) die Segmentierung mit verschiedenen Scalefaktoren durchgeführt. Dabei ergab sich ein quadratischer Zusammenhang zwischen Scalefaktor und durchschnittlicher Objektgröße (Abb. 3).




Abb. 3: Zusammenhang zwischen Scalefaktor und Anzahl der segmentierten Bildobjekte sowie durchschnittlicher Objektgröße für die gewählte Testfläche.

Ein wichtiger Aspekt eines Segmentierungsprogramms ist die Reproduzierbarkeit der Segmente, da diese Grundlage für die anschließende Klassifizierung sind. Es zeigte sich, dass bei wiederholter Segmentierung eine identische Reproduktion der Segmente

bei unveränderter Größe des Bildausschnittes gegeben ist. Wurde allerdings die Größe des Bildausschnittes geändert, so ergab sich bei gleichen Segmentierungsparametern ein verändertes Segmentmuster. Die Segmentgrenzen werden nicht nur am Bildrand – was verständlich wäre – sondern auch innerhalb des Bildes verändert. Da bedingt durch die hohen Rechenzeiten in eCognition zweckmäßigerweise eine Klassifikation erst an einem Teilausschnitt einer größeren Bildszene ausgeführt und anschließend die Klassifikation auf die Gesamtszene übertragen wird, ist dieser Effekt ausgesprochen nachteilig.

In der Regel sollte ein Bild mit mehreren Scalefaktoren segmentiert werden, um dem Bildgehalt in seiner hierarchischen Strukturierung gerecht zu werden. Nach Aussagen von Definiens ist aus Sicht der Bearbeitungszeit eine Segmentierung von feinen zu groben Segmenten empfehlenswert, denn den größten Rechenaufwand benötigt die feinste Segmentierung, da hier unmittelbar auf Pixelebene gearbeitet wird. Weitere Segmentierungen (mit größerem Scalefaktor) nutzen die vorhandenen Segmente und fassen sie in geringerer Rechenzeit zu größeren zusammen.

Für die Segmentierung wurden die in Abschnitt 6 beschriebenen Eingangsdaten verwendet mit folgenden Besonderheiten: Der panchromatische Layer wurde nur im feinen Skalenniveau verwendet. Der NDVI-Layer wurde nicht zur Segmentierung herangezogen, wohl aber zur nachfolgenden Merkmalsauswertung im Rahmen der Klassifikation.

Die Segmentierung des Untersuchungsgebietes erfolgte in den drei Ebenen fein (Scalefaktor: 10, mittlere Segmentgröße: 23 Pixel), mittel (50/487) und grob (165/6589). Im Feinskalenniveau werden kleinste Objekte wie Bäume, Gartenlauben und Dachelemente abgegrenzt, allerdings auch Inhomogenitäten innerhalb einheitlicher Bodenbedeckungen. Im mittleren Skalenniveau werden im Wesentlichen ganze Gebäude segmentiert, während im groben Skalenniveau große Flächen wie Gewässer, Felder und ganze Baublöcke abgegrenzt werden.

8.3 Klassifikation mit eCognition

Die Bildsegmente wurden entgegen der Segmentierungsreihenfolge von grob zu fein in den drei Ebenen anhand ihrer mittleren Grauwerte, Formmerkmale, Nachbarschaftsbeziehungen und Relationen zu über- und untergeordneten Segmenten klassifiziert. In der groben und mittleren Ebene wurden Zugehörigkeitsfunktionen formuliert. Abb. 4 zeigt anhand der Klassifikation von Ackerflächen, dass dabei mit Hilfe grafischer Verteilungsfunktionen die klassenbildenden Wertebereiche festgelegt werden. Auf der Feinsegmentebene wurde das Ergebnis mit Hilfe von Testflächen, die durch visuelle Interpretation einer bestimmten Nutzungsklasse zugeordnet wurden, verfeinert. Die Auswahl der Kriterien zur Unterscheidung der Klassen erfolgte durch Abfragen einzelner Elemente (Image Object Information) bzw. durch einen Feature View, durch den jedes Kriterium flächenhaft grafisch dargestellt werden kann. Die bereits zugeordneten Klassen können in der Objekt- sowie Ebenenhierarchie nach unten und oben vererbt werden. Auf diesem Weg entstand nach und nach ein umfangreicher, wissensbasierter Klassifikationsbaum. Zur Evaluierung der Klassifikation waren sowohl die segmentbezogene (tabellarische) als auch die flächenhafte (graphische) Darstellung der wahrscheinlichsten Klassenzugehörigkeit (Best Classification Result)

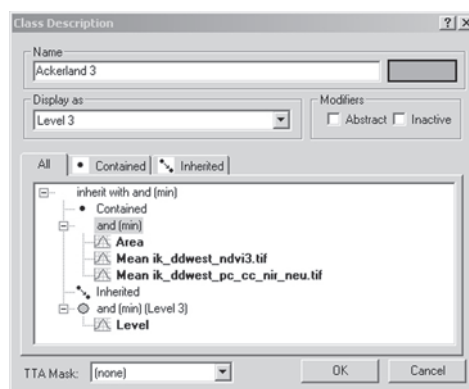


Abb. 4: Klassifikation von Ackerflächen in eCognition.



Abb. 5: Klassifikationsergebnis der Gesamtfläche (links: ExpertClassifier, rechts: eCognition).

nützlich. Zusätzlich ist eine direkte manuelle Klassenzuweisung möglich, die hier jedoch nicht genutzt wurde.

9 Vergleich der Klassifikationsergebnisse und der Implementierungen

9.1 Visueller Vergleich der Klassifikationen

Beim visuellen Vergleich der beiden Klassifikationsergebnisse zeigen sich einige signifikante Unterschiede (Abb. 5). Während eCognition durch die vorgeschaltete Segmentierung sehr homogene Flächen ausbildet, bedingt die Klassifikation mit ExpertClassifier das bekannte kleinteilige Pixelklassifikationsmuster („Salt and Pepper“-Rauschen).

Abb. 6 stellt verschiedene Ausschnitte der Klassifikationen im Bildvergleich dar. Die oberste Reihe zeigt, wie mittels eCognition ein Straßenneubau richtig klassifiziert wurde (durch Auswertung von Form und Nachbarschaft), während dieser bei ExpertClassifier nur teilweise und nur als versiegelte Freifläche ausgewiesen werden konnte. Die mittlere Reihe verdeutlicht, dass sich IKONOS-Daten generell zur Klassifikation von

Einzelhäusern nutzen lassen, obwohl eine korrekte Klassifikation durch die detaillierte Darstellung der vielfältigen Dachmaterialien sowie verschiedener Besonnungssituationen erschwert wird. Ein Fluss und zwei Sportplätze konnten mit eCognition klassifiziert werden, wie die untere Bildfolge zeigt.

Unterschiede ergaben sich auch im Anteil der unklassifizierten Flächen (in Abb. 5 und 6 schwarz dargestellt), welcher bei der pixelbasierten Klassifikation mit 0,42 % der Gesamtfläche größer ausfiel als bei der segmentorientierten (0,07 %). Im letzten Fall können unklassifizierte Segmente (z. B. seltener Nutzungsklassen) auch manuell der entsprechenden Nutzungsklasse zugeordnet werden, so dass prinzipiell eine vollständige Klassifikation möglich ist. Bei der pixelbasierten Klassifikation verbleiben immer einzelne unzusammenhängende Pixel, die nicht eindeutig einer Klasse zugeordnet werden können.

Durch die Einbeziehung von Nachbarschaftsbeziehungen und Flächenform werden in eCognition differenziertere Klassenschlüssel möglich. So konnten Sportplätze durch eine Form- und Größenanalyse sowie bestimmte Gebäude durch ihre Nachbarschaft zu Straßen klassifiziert werden. Im




Abb. 6: Ausschnitte des Untersuchungsgebietes (links: IKONOS-Bild, Mitte: Klassifikationsergebnis ExpertClassifier, rechts: eCognition).

Allgemein lässt sich feststellen, dass sich mit eCognition große, homogene Flächen sicherer und mit geringerem Zeitaufwand klassifizieren lassen als stark heterogene Flächen.

9.2 Vergleich der Klassifikationsgüte

Für die Berechnung der Klassifikations- und Erkennungsgüte wurde das Accuracy Assessment-Tool von ERDAS Imagine benutzt. Für jede Klasse wurden unabhängig

von ihrem Flächenanteil je 20 Testpunkte durch einen Zufallsgenerator erzeugt. Um Testpunkte auf Nutzungsgrenzen zu verhindern (die sich letztlich auch im Rahmen der visuellen Interpretation nicht eindeutig zuordnen lassen), sollten die Testpunkte innerhalb homogener Flächen liegen.

Grundlage der visuellen Bedeckungs-/Nutzungsbestimmung für diese Testpunkte war in erster Linie das Bildfusionsprodukt der IKONOS-Daten. In Zweifelsfällen wurde eine Luftbildaufnahme des Jahres 1999

Tab. 1: Erkennungs- und Klassifikationsgüte im Vergleich.

Klasse	ExpertClassifier		eCognition	
	Erkennungs- güte [%]	Klassifika- tionsgüte [%]	Erkennungs- güte [%]	Klassifika- tionsgüte [%]
Ackerland	100,0	100,0	100,0	100,0
Wiese/Rasen	78,3	90,0	80,9	85,0
Elbwiese	94,7	90,0	–	–
Sportplatz	–	–	100,0	95,0
Wald/Baumbestand	95,2	100,0	100,0	95,0
Laubgehölz, verbuschtes Gelände	85,7	90,0	–	–
Obstanbau	–	–	100,0	95,0
Garten/Kleingarten ¹	94,1	80,0	–	–
Gewässer	100,0	100,0	100,0	100,0
Industrie-/Gewerbefläche ²	–	–	62,5	75,0
Bebauung	90,9	100,0	94,7	90,0
Bahnfläche	100,0	90,0	100,0	100,0
Autobahn	–	–	100,0	100,0
Straßenfläche ³	–	–	–	–
Vegetationslose Fläche, unversiegelt	85,7	60,0	83,3	75,0
Versiegelte Fläche	68,0	85,0	69,6	80,0
Parkplatz	–	–	83,3	75,0
Gesamtklassifikationsgüte	89,6		89,6	

¹ Die Klasse Garten/Kleingarten wurde bei der Klassifikation mit eCognition in der hier geprüften feinsten Segmentierungsebene in ihre Bodenbedeckungsbestandteile zerlegt.

² Versiegelte Industrie-/Gewerbeflächen sind bei der Klassifikation mittels ExpertClassifier in der Klasse versiegelte Fläche enthalten.

³ Straßenflächen wurden von der Gütebestimmung ausgeschlossen, da sie nicht klassifiziert, sondern unmittelbar aus der Blockrestfläche abgeleitet wurden.

verwendet, in einigen Fällen erfolgte die Sicherung durch Vorortbegehung. Die Ergebnisse der Klassifikationskontrolle sind in Tab. 1 dargestellt.

Beide Klassifizierungen zeigen die gleiche Gesamtklassifikationsgüte von 89,6%. An dieser Stelle sei aber noch einmal darauf hingewiesen, dass die Klassifikation von ExpertClassifier im 4 m Raster mit 11 Klassen, während die von eCognition im 1 m Raster mit 13 Klassen erfolgte. In den einzelnen Klassen treten jedoch teilweise erhebliche

Unterschiede auf. Am deutlichsten äußern sich diese in den Klassen unversiegelte, vegetationslose Flächen, Bahnflächen und Bebauung.

9.3 Übertragung der Klassifikation auf eine gesamte IKONOS-Szene

Ein unter ExpertClassifier angelegter Entscheidungsbaum kann prinzipiell mit wenig Aufwand auf ganze Satellitenszenen übertragen werden. Allerdings müssen alle abso-

lut gesetzten Diskriminanzwerte des Entscheidungsbaumes kontrolliert und in der Regel überarbeitet werden. Aus den Erfahrungen zur Klassifikation von ganzen Satellitenbildszenen kann geschlussfolgert werden, dass bei der Arbeit mit ExpertClassifier die Erarbeitung des Entscheidungsbaumes gleich an der Gesamtszene erfolgen sollte und auf die Erarbeitung anhand eines Testgebietes verzichtet werden kann. Das erspart eine zweite Abstimmung der Diskriminanzwerte und ist letztlich durch die interaktive Arbeit auch bei großen Bilddatenmengen möglich. Die Berechnung der in die Klassifikation einbezogenen Modelle benötigte etwa 100 Minuten, die Klassifikation der Gesamtszene erfolgte in ca. 25 Minuten.

Auch eCognition erlaubt prinzipiell eine Übertragung des Klassifikationsbaumes auf andere Flächen. Wichtige Voraussetzung dafür ist, dass die Grauwertbereiche der zu klassifizierenden Bildausschnitte übereinstimmen. Werkzeuge zur Übertragung der Klassifikation sind durch die Import-/Exportfunktion für den Klassifikationsbaum, einen Batch-Betrieb (Protokoll) sowie durch die Exportmöglichkeit für bereits gewählte Testflächen gegeben. Zu beachten ist, dass die verwendeten Layer in gleicher Anzahl und identischer Reihenfolge Verwendung finden müssen. Bei der Segmentierung der Gesamtszene entstehen zudem andere (wenn auch vergleichbare) Segmente, was sich auf die Übertragbarkeit der Klassifikation negativ auswirkt.

Die Arbeit mit ganzen Satellitenszenen wirft bei eCognition einige programmtechnische Probleme auf. Die Grenze wird bei der Berechnung einer IKONOS-Gesamtszene durch die Datenmenge erreicht. So ließ sich die kleinste Segmentierungsebene (Scalefaktor 10) nicht erstellen, da der benötigte Arbeitsspeicher hierfür nicht ausreichte (512 MB). Allein die Eingangsdaten haben einen Speicherumfang von 1,6 GB (7 Layer á 237 MB). Um einen Eindruck von den Prozessierungszeiten für eine IKONOS-Gesamtszene zu vermitteln, sind in Tab. 2 einige Rechenzeiten aufgelistet.

Aufgrund der hohen Rechen- und Visualisierungszeiten sollte darum generell der

Entscheidungsbaum in eCognition an einer Teilfläche erarbeitet und dann auf die Gesamtszene übertragen werden, was allerdings weitere Probleme nach sich zieht (neue Segmentierung, neue Abstimmung der Zugehörigkeitsfunktionen).

9.4 Vergleich der Softwareimplementierungen

Während der ExpertClassifier im Umgang mit großen Datenmengen keine Probleme hat, sind hier eCognition deutliche Grenzen gesetzt. Auch bei Erfüllung der gestellten Hardwareanforderungen, wie z. B. sehr großer Hauptspeicherausbau, ergeben sich sehr lange Rechen- und Projektladezeiten bei der Prozessierung von ganzen Szenen. Durch die sehr unterschiedlichen Rechenzeiten ergeben sich letztlich bessere Möglichkeiten der interaktiven Verbesserung bei der Klassifikation mit ExpertClassifier als bei der Arbeit mit eCognition.

Während ERDAS Imagine mit unterschiedlichen Rastergrößen im Klassifikationsprozess umgehen kann, ist mit eCognition nur die Bearbeitung gleicher Rasterwei-

Tab. 2: Prozessierungszeiten einer IKONOS-Gesamtszene einschließlich Zusatzdaten im 1 m Raster (1,6 GB) mittels eCognition (die Werte beziehen sich auf folgende Hardware: PC AMD Athlon 1 GHz, 512 MB RAM, Win2000).

Prozess	Rechenzeit [min]
Rasterdaten laden	ca. 30
Segmentierung (Scale 16)	ca. 150
Segmentierung (Scale 50)	ca. 75
Speichern (2 Ebenen)	ca. 30
Segmentierung (Scale 165)	ca. 60
Wechsel der Ebenenansicht	ca. 25
Projekt öffnen	ca. 15
Feature View	ca. 10
Klassifikation	ca. 60
Bildausschnitt verschieben	ca. 2

ten möglich. Bei unterschiedlicher Rasterung der Eingangsdaten müssen diese in die kleinste Rasterweite resampelt werden, was zu einer Vervielfachung der Datenmenge führt und die Rechenzeit erheblich erhöht. Auch die Unterstützung von verbreiteten Rasterformaten beim Export ist derzeit bei eCognition noch mangelhaft (nur ASCII und TIFF). Die Erzeugung von Vektorformaten, in denen die Klassifikationsergebnisse prinzipiell vorliegen, ist noch nicht möglich. Demgegenüber bietet ExpertClassifier neben der Unterstützung vieler Raster- und Vektorformate auch die Einbindung von Vektordaten in den Klassifikationsprozess.

Derzeit muss in eCognition, im Gegensatz zum ExpertClassifier, mit identischen Bildausschnitten der Eingangsdaten gearbeitet werden. Diese Tatsache führt bei der Klassifikation mit eCognition zu einem höheren Aufwand in der Datenvorbereitung. Auch kann in eCognition nachträglich kein weiterer Layer in ein Klassifikationsprojekt eingefügt werden. Hierzu müssen ein neues Projekt erstellt und alle Berechnungen erneut durchgeführt werden.

Beide Klassifikatoren verfügen über Programmteile zur statistischen Bestimmung der Klassifikationsgüte, wobei die des ExpertClassifier weiterführend sind. Nur hier ist der Import von nutzerdefinierten Kontrollpunkten und das Setzen von zufälligen Kontrollpunkten unter verschiedenen Randbedingungen möglich. Als reines Bildanalyseprogramm bietet eCognition nicht die Funktionalität eines Bildverarbeitungsprogrammes (z. B. keine NDVI-Berechnung). Vorteile bietet der ExpertClassifier zudem durch die Möglichkeit einer Einbindung von Programmen in den Klassifikationsprozess (offenes System).

10 Zusammenfassung und Ausblick

Neue hoch- und höchstauflösende Scanner- und Satellitenbilddaten erfordern neue, nicht nur pixel- und grauwertbezogene Auswertansätze. In dem Maß, wie sich die geometrische Auflösung der Bilddaten erhöht

und eine breitere Palette von Eingangsdaten in der Klassifikation Verwendung findet, müssen neben der spektralen Signatur der Rasterzellen auch Merkmale größerer, zusammenhängender Flächen genutzt werden. Formen, Flächengrößen, Nachbarschafts- und Hierarchiebeziehungen sind derartige, wichtige Merkmale vieler Bodenbedeckungen/Flächennutzungen. Mit der Extrahierung dieser neuen Merkmale können Klassen differenzierter und sicherer gebildet werden. Neben der bisher im Vordergrund stehenden Klassifizierung von Bodenbedeckungen aus Fernerkundungsdaten wird die Bestimmung der Flächennutzung zunehmend wichtiger. Zum Teil kann dieser Anspruch durch die Klassifikation mit eCognition erreicht werden. Als Beispiel soll hier die Klasse Sportplatz dienen, welche nicht nur eine Aussage über die Bodenbedeckung, sondern auch über die Nutzungsform darstellt. Daneben bietet der segmentorientierte Ansatz eine Verringerung des Anteils unklassifizierter Flächen und zeigt eine weitaus homogenere Klassifikation als die herkömmliche, pixelbasierte Klassifizierung, die immer zu Pixelrauschen tendiert.

Mit eCognition steht erstmals ein kommerzielles Programm zur segmentbasierten Klassifikation zur Verfügung. In das Softwarekonzept ist eine große Zahl neuer Ansätze eingeflossen, allerdings lässt die Implementierung derzeit noch einige Wünsche offen. Wichtig wäre vor allem eine Integration von eCognition in GI-Systeme und Fernerkundungssoftware, eine flexiblere Nutzbarkeit von Eingangsdaten für eine Klassifikation (variable Rasterweiten, nicht idente Bildausschnitte, Unterstützung wichtiger Bildformate) und die Verbesserung der Interaktivität des Programms, die derzeit bei großen Eingangsdatensätzen nicht gegeben ist.

Danksagung

Die Autoren danken der Firma Definiens AG, München, für die Bereitstellung der Beta-Version des Softwarepaketes eCognition.

Literatur

- BAATZ, M. & SCHÄPE, A., 1999: Object-oriented and multi scale image analysis in semantic networks. – In: Proc. 2nd International Symposium on Operationalisation of Remote Sensing Conference and Exhibition, Enschede, ITC.
- BAATZ, M. & SCHÄPE, A., 2000: Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. – In: STROBL, J., BLASCHKE, T. & GRIESEBNER, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung – Beiträge zum AGIT-Symposium Salzburg 2000. Wichmann, 12–23, Karlsruhe.
- BLASCHKE, T., 2000a: Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: Neue Möglichkeiten für GIS-Anwender und Planer. – In: SCHRENK, M. (Hrsg.): Beiträge zum 5. Symposium zur Rolle der Informationstechnologie in der und für die Raumplanung. 153–162, Wien.
- BLASCHKE, T., 2000b: Ohne Salz und Pfeffer – Objektorientierte Bildanalyse – eine Revolution in der Fernerkundung. – *GeoBit* 2/2000, 30–32.
- EXPERT CLASSIFIER, Documentation, ERDAS Imagine, 1999.
- KERSTEN, TH., BALTASAVIAS, E., SCHWARZ, M. & LEISS, I., 2000: IKONOS-2 CARTERRA GEO – Erste geometrische Genauigkeitsuntersuchungen in der Schweiz mit hochauflösenden Satellitendaten, Vermessung, Photogrammetrie, Kulturtechnik 8/2000, 490–497.
- MEINEL, G. & REDER, J., 2001: IKONOS-Satellitenbilddaten – ein erster Erfahrungsbericht. *Kartographische Nachrichten* 1/2001, 40–46.
- MEINEL, G., REDER, J. & NEUBERT, M., 2000: IKONOS-Satellitenbilddaten und ihre Klassifikation – ein erster Erfahrungsbericht. GUGM 2000, Germering.
- SCHMIDT, R., 2000: Untersuchung des Bildanalyse-systems eCognition. Unveröff. Diplomarbeit, Uni. Hannover.
- TOUTIN, T. & CHENG, P., 2000: Demystification of IKONOS, *EOM* 7/2000, 17–21.
- Internetdokumentationen:
 Definiens: www.definiens.com
 Space Imagine Europe: www.si-eu.com
 Erdas: www.erdas.com
- Anschrift der Verfasser:
 Dr.-Ing. GOTTHARD MEINEL, Dipl.-Geogr. MARCO NEUBERT, Dipl.-Geogr. JOHANNES REDER, Institut für ökologische Raumentwicklung e.V., Dresden, Weberplatz 1, D-01217 Dresden, e-mail: G.Meinel/M.Neubert/J.Redere@ioer.de
- Manuskript eingereicht: Januar 2001
 Angenommen: Januar 2001