

Ivits, E., Koch, B., 2002, Optimierung der Erfassung der Landschaftsdiversität auf der Basis von Satelliten- und Luftbildern: ein Europäisches Landschaftskonzept. In: IÖR Schriften, Band 40, Dresden, 2003. im Druck.

Optimierung der Erfassung der Landschaftsdiversität auf der Basis von Satelliten- und Luftbildern: ein Europäisches Landschaftskonzept

Eva Ivits¹ und Barbara Koch²
Albert-Ludwigs-Universität Freiburg
Abteilung Fernerkundung und Landschaftsinformationssysteme
Tennenbacher Str. 4
79085 Freiburg

¹: eva.ivits@felis.uni-freiburg.de
²: barbara.koch@felis.uni-freiburg.de

Einleitung

Die aktuell vorherrschenden Strategien um Aussagen zur Biodiversität zu erhalten sind multivariable Korrelationsanalyse von Umwelt- und Artenvielfaltsdaten einerseits und digitale Klassifikation von Fernerkundungsaufnahmen andererseits. Um flächendeckende Informationen als Grundlage für Biodiversitätsstudien zu erhalten, werden u.a. Kartierungen der Landbedeckung mit Hilfe von Fernerkundungsdaten durchgeführt. Je nach Datengrundlage können dabei Landbedeckungsklassen mit unterschiedlicher Informationstiefe und Abgrenzungsschärfe erfasst werden. Inwieweit es möglich ist, mittels Fernerkundung Aussagen über die Habitate und damit indirekt über die Artenvielfalt zu treffen, basiert in der Literatur oft auf Annahmen. Nur selten wurden hierzu konkrete Korrelationsanalysen mit umfangreichen terrestrischen Aufnahmen durchgeführt. Das EU Projekt BioAssess (EVK2-CT1999-00041) versucht, ein europaweites Verfahren zur Erfassung und Beobachtung der Biodiversität zu entwickeln. Hierbei werden Fernerkundungsdaten mit terrestrischen Stichprobenaufnahmen zur Artenvielfalt, auf der Basis von Testgebieten in acht europäischen Ländern, verknüpft, um die Korrelation von Daten auf Landschaftsebene mit Artenvielfalt zu errechnen. Dabei hat die Berechnung von Landschaftsindizes besondere Bedeutung, um die Landschaften aus Fernerkundungsdaten zu beschreiben und miteinander zu vergleichen und

um Veränderungen wie z.B. Fragmentation zu quantifizieren. In diesem Zusammenhang sind zwei grundsätzliche Probleme zu berücksichtigen:

- Scharfe Grenzen zwischen Landbedeckungsklassen, und homogenen Habitatsflächen kommen in der Natur kaum vor. Es ist allerdings notwendig, solche Grenzen für landschaftsökologische Analysen zu ziehen, da solche Verfahren Objekte als Einheiten haben.
- Es gibt eine enorme Anzahl von Landschaftsindizes, die teilweise sehr stark korrelieren. Mit zusätzlichen Umweltdaten (z.B. Höhe, Hangneigung, oder Vegetationsindizes) und Artenvielfaltsdaten steht somit für die Korrelation eine Datenmenge und -vielfalt zur Verfügung, die nur mit anspruchsvollen statistischen Verfahren analysiert werden kann.

Die vorliegende Arbeit erläutert Ergebnisse aus einem objektbasierten Segmentierungs- und Klassifizierungsverfahren von Fernerkundungsdaten auf verschiedenen Skalenebenen zur Erfassung der Landschaft als Grundlage für Biodiversitätsstudien. Die Klassifizierungsergebnisse sind somit Eingangsdaten für die darauf folgende Landschaftsanalyse mittels Indizes und für die Korrelation mit biologischen Artenvielfaltsdaten.

1 Methodik

2.1. Das Testgebiet

Im Rahmen des BioAssess Projektes werden fernerkundungsbasierte und terrestrische Indikatoren zur Erfassung und Beobachtung der Biodiversität parallel entwickelt. Das Ziel des Projektes ist es, terrestrisch abgeleitete Biodiversitätsindizes mit Indizes aus Fernerkundungsdaten zu vergleichen. Nach dem Vergleich soll eine Aussage zur Sensitivität, der aus Fernerkundungsdaten abgeleiteten Indizes im Hinblick auf die aus terrestrischen Aufnahmen entwickelten Indizes getroffen werden. Hierfür wurden Testgebiete in acht verschiedenen Bioregionen Europas (Finnland, Frankreich, Irland, Portugal, Schweiz, Spanien, Großbritannien, und Ungarn) mit verschiedenen Landnutzungsformen ausgewiesen. Zunächst wurden in jedem Land sechs Testgebiete mit 1*1 km Ausdehnung, ausgewählt, welche einen Gradienten von intensiver zu extensiver Landnutzung repräsentieren. In den Testgebieten führen einerseits Biologen Feldaufnahmen zu ausgewählten sieben Indikatorarten durch, andererseits werden Bildverarbeitungsmethoden entwickelt, die es ermöglichen die Daten schnell und leistungsfähig auf der Basis eines

übertragbaren Verfahrens zu klassifizieren. In der vorliegenden Arbeit werden Methoden und Ergebnisse anhand der Schweizer Testgebiete vorgestellt.

2.2. Datenoptimierung

Für die vorgestellte Untersuchung wurden drei Datensätze verwendet; multispektrale Landsat ETM Daten fusioniert mit panchromatischen IRS-1D Daten (in 5m Auflösung), multispektrale Quickbird Satellitendaten (2,8m Auflösung) und Luftbilder (0.6m Auflösung). Verschiedene Optimierungsschritte wurden durchgeführt, um für die relativ kleinen Testgebiete eine Datengrundlage zu schaffen, welche im Vergleich mit den terrestrischen Aufnahmen nutzbare Klassifizierungsergebnisse ermöglichen. Wichtige Optimierungsschritte waren die Reduzierung des Einflusses der Streifen des IRS Sensors auf das Bild, durch die Anwendung eines Sigma-Filters (Ivits und Koch, 2002). Darüber hinaus wurden verschiedene Fusionsalgorithmen getestet und zwei für die weitere Arbeit ausgewählt. Einerseits das AIF (Adaptive Image Fusion, Steinnocher, 1999) Verfahren, ein Filteralgorithmus, der zwar neben der Verbesserung der räumlichen Auflösung zu reduzierten Strukturinformation im Bild führt, aber die Grauwerteinformation des Bildes beibehält. Andererseits wurde für die visuelle Interpretation als auch für die Segmentierung der Satellitenbilder die AIF-sigma-IHS Fusionsmethode ausgewählt. Hierbei wird das AIF gefilterte Bild einer IHS-Transformation unterzogen, um wertvolle Strukturinformation zurückzugewinnen (Abb. 1.). Für das Luftbild wurde darüber hinaus der Local Region Filter angewandt, um die Varianz zwischen benachbarten Pixeln zu verringern.





Abb. 1: 1.: Landsat ETM (30m); 2.: IRS-1D (5m); 3.: AIF (5m); 4.: AIF-sigma-IHS Fusion (5m)
Datengrundlage: Landsat ETM, GAF, München und IRS-1D, Euromap, Neusterlitz,
Bearbeitung: Eva Ivits

Um die nach der Segmentierung folgende Klassifizierung zu optimieren, wurden zusätzlich abgeleitete Kanäle berechnet. Aus der spektralen Information der Landsat Szene wurden Kanäle wie Vegetationsindex, Tasseled Cap Transformationen und Principal Component Analysis

berechnet. Die Strukturinformation der IRS Szene wurde genutzt, um verschiedene Texturkanäle herzustellen. Hierbei wurden Statistiken sowohl erster Ordnung, wie Varianz, als auch zweite Ordnung wie GLCM und GLDV genutzt. Darüber hinaus wurde ein 25*25 m Höhenmodell und die daraus abgeleitete Hangneigung in die Klassifikation einbezogen. Von Quickbird und dem Luftbild wurden Vegetationsindex und Varianzbilder erstellt und zusätzlich wurde ein Oberflächenmodell, abgeleitet aus Stereoluftbildern, in die Analyse einbezogen.

Ab der dritten Version bietet die Software eCognition (eCognition User Guide) die GLCM (Grey-Level Co-Occurrence Matrix) und GLDV (Grey Level Difference Vector) Texturparameter an. Gegenüber traditionellen Methoden werden in eCognition die Texturen nicht in einem „Moving-Window“, sondern anhand der Pixel innerhalb der segmentierten Objekte abgeleitet. Damit verliert man zwar die Möglichkeit, mit verschiedenen



*Abb. 2: Ein Waldobjekt (Links), dessen Pixel-basierte (Mitte) und Objekt-basierte Textur (Rechts)
Datengrundlage: Landsat ETM, GAF, München und IRS-1D, Euromap, Neusterlitz,
Bearbeitung: Eva Ivits*

Fenstergrößen das Texturmerkmalsbild zu bearbeiten, aber das Verfahren hat den großen Vorteil, dass die Texturen innerhalb des Objektes berechnet werden, wobei auch benachbarte Pixel außerhalb der Objektgrenzen in die Berechnung einbezogen werden. Damit kann vermieden werden, dass der sogenannte „Edge Effekt“, der sowohl Segmentierung als auch Klassifizierung stark beeinflusst, auftritt (siehe Abbildung 2.). Um directionale Unabhängigkeit erreichen zu können, wurden die 4 Richtungen der Texturen gemittelt und das Ergebnis in die Klassifikation einbezogen.

2.3 Segmentierung

Die fusionierten Landsat ETM-IRS und Quickbird Bilder wurden unter Nutzung des „Fractal Net Evolution Approach“ (FNEA) mit der Software eCognition (Baatz und Schäpe, 1999) segmentiert. Der FNEA verwendet

eine Segmentierungstechnik im objektorientierten Rahmen, mit dem Ziel, benachbarte Pixel mit ähnlichen Grauwerten zu Objekten zusammenzufassen. Darüber hinaus wird die Größe der segmentierten Objekte durch den Optimierungsalgorithmus auf der Basis von Heterogenitätskriterien festgelegt. Hierbei werden einerseits die spektralen Werte der in die Segmentierung einbezogenen Kanäle und andererseits die Form der zu segmentierenden Objekte berücksichtigt. Innerhalb der Segmente wird nach drei Verfahren je ein Wert pro Bildkanal berechnet:

1. Das Objekt bekommt für den jeweiligen Kanal den Mittelwert aller Pixel innerhalb des Segments.
2. Das Objekt bekommt für den jeweiligen Kanal die Standardabweichung aller Pixel innerhalb des Segments.
3. Der Mittelwert aller Pixel eines Kanals innerhalb des Objektes wird durch den Mittelwert aller Kanäle innerhalb des Objektes dividiert.

Diese drei Verfahren wurden mit dem optimierten Fernerkundungsdatensatz kombiniert und in die Klassifikation einbezogen.

Die Segmentierung kann in hierarchischen Ebenen mit immer größeren Segmenten durchgeführt werden, wobei zwischen den verschiedenen Ebenen und deren Objekten ein semantisches Netz gebildet wird




Abb. 3: Hierarchische Segmentierung eines Objektes
 Datengrundlage: Landsat ETM, GAF, München und IRS-1D, Euromap, Neusterlitz,
 Bearbeitung: Eva Ivits

(Abbildung 3.). Die größeren Segmente behalten dabei die Objektgrenzen der kleineren. Damit wird es möglich, bei der Klassifizierung Bezüge zwischen mehreren hierarchischen Ebenen herzustellen. Für die Segmentierung des Landsat ETM basierten Datensatzes wurde die AIF-sigma-IHS Fusion verwendet. Dieses Fusionsprodukt besitzt sowohl sehr gute räumliche als auch spektrale Eigenschaften und erfüllt damit gute Voraussetzungen für die oben genannten Segmentierungskriterien. Das Quickbirdbild musste für die Segmentierung nicht verändert werden, während das Orthophoto erst gefiltert werden musste, um optimale Objektkanten zu erreichen.

Die Segmentation wurde für alle Daten hierarchisch durchgeführt. Zuerst wurde eine Ebene mit kleinen Objekten segmentiert und danach wurde eine neue Ebene, in der die Polygone so klein wie notwendig, und so groß wie möglich wurden. Dabei wurde die Ebene gesucht, in der die Polygone klein genug waren, um für die Biodiversität wichtige Habitate, wie z.B. kleine Baumgruppen, zu repräsentieren, aber auch groß genug, um sie mit wenigen Trainingsobjekten klassifizieren zu können. Bei der Landsat Szene reichte eine Ebene für die erste Klassenhierarchie und deren Kopie war ausreichend, um die zweite Klassenhierarchie klassifizieren zu können. Bei den Quickbird- und Luftbildern waren mehrere segmentierte Ebenen notwendig, um Häuser, Straßen, kleine Waldfläche und verschiedene Waldtypen segmentieren und klassifizieren zu können.

2.4 Klassifizierung

Aus der Vielzahl der Informationsebenen wurden im nächsten Schritt die Kanäle, welche als Klassifizierungsgrundlagen geeignet sind, herausgefiltert. Traditionell wird hierzu eine Signaturenanalyse genutzt. Der Kanalauswahl wurde in der vorliegenden Arbeit mit einer schrittweisen Diskriminanzanalyse durchgeführt. Hierbei gibt man eine Reihe potentiell zur Erklärung in Betracht kommende Variablen an (die Kanäle) und läßt die Auswahl der am besten für die Vorhersage der Gruppenzugehörigkeit geeigneten Variablen von der Diskriminanzanalyse vornehmen. Der Algorithmus wählt aus den Variablen, schrittweise jeweils die geeignetsten aus, bis von den noch nicht ins Modell aufgenommenen Variablen kein signifikanter Erklärungsbeitrag mehr erwartet werden kann. Die schrittweise Diskriminanzanalyse wurde mit dem Softwarepaket SPSS durchgeführt.

In eCognition erfolgt die Klassifizierung entweder nach dem „Fuzzy-Logik“ oder nach dem „Nearest-Neighbour“ Klassifizierungsverfahren. Der Vorteil von der „Fuzzy –Logic“ Anwendung ist, dass die Klassen nicht mit harten Grauwertgrenzen definiert werden. Während ein Objekt als Trainingsgebiet der Klasse A zugewiesen wurde, kann ein anderes Objekt mit ähnlichen Grauwerten auch noch in die Klasse B gehören. „Schwierige“ Objekte wie z.B. Fels und Stadtflächen lassen sich dadurch einfacher klassifizieren. Obwohl die überlappenden Grauwertenbereiche mit Fuzzy-Logik gewisse Flexibilität erlauben, müssen die Grenzen der Klassen trotzdem vordefiniert werden. Bei der Bearbeitung nur eines Datensatzes ist dies kein Problem, bei der Übertragung des Klassifikationsschemas auf andere Szenen werden allerdings die vordefinierten Grenzen, trotz ihrer Flexibilität, problematisch. Je nach Aufnahmezeitpunkt, Vegetationsperiode, atmosphärischen Störungen oder auch unterschiedlichen

Landbedeckungscharakteristiken ändern sich die Grauwertebereiche der Klassen und eine genaue Klassifikation ist nicht mehr gewährleistet. Deshalb wurde die Nearest-Neighbour Methode angewandt. Nach der Nearest Neighbour Methode werden Objekte anhand der Euklidischen Distanz der einen oder anderen Klasse zugeordnet. Dabei wird nur der mehrdimensionale Merkmalsraum vordefiniert, in dem die segmentierten Objekte klassifiziert werden sollen. Dieser Merkmalsraum ist relative flexibel auf unterschiedliche Szenen übertragbar.

Segmentierte Ebenen einer höheren Hierarchiestufe können anhand von Spektral- oder Texturcharakteristik von den darunter liegenden Ebenen, oder auch anhand der Anzahl und Form darunter liegender Objekte klassifiziert werden. So kann man z.B. Flächen als Klasse ohne Vegetation anhand der größeren Segmente klassifizieren und diese anhand kleinerer Objekte nach Häusern, Straßen, oder offenen Flächen aufteilen (siehe Abbildung 4.). Die Objekte der verschiedenen Ebenen können nach

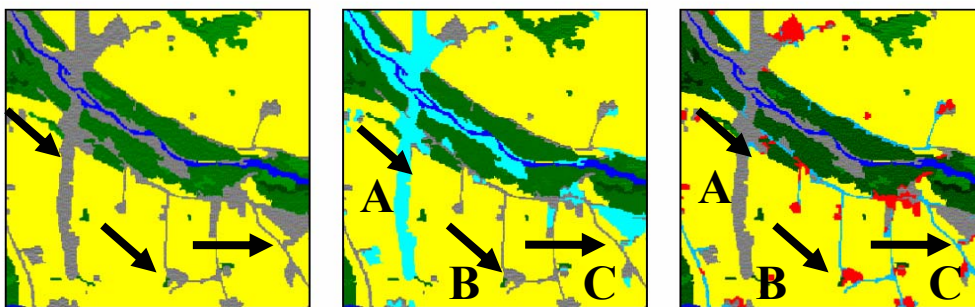


Abb. 4: Links: Fläche ohne Vegetation; Mitte: (A) offene Fläche und (B) versiegelte Fläche; Rechts: (A) offene Fläche, (B) versiegelte Fläche mit Häusern und (C) Straßen
 Datengrundlage: Landsat ETM, GAF, München und IRS-1D, Euromap, Neusterlitz,
 Bearbeitung: Eva Ivits

benutzerdefinierten Regeln in Klassen zusammengefasst werden. Dies gestattet die Entwicklung eines hierarchischen Klassifikationssystems. Für eine europäische Anwendung, wo verschiedene Landschaften klassifiziert werden müssen, ist dies ein großer Vorteil; es ist somit möglich ein übertragbares Klassifizierungsschema zu entwickeln.

Das Klassifikationsschema wurde nach dem CORINE System hierarchisch entwickelt. Auf der einfachsten Stufe wurden Wald, Grünland, Landwirtschaft, Agro-Forstwirtschaft, offene Flächen, versiegelte Flächen, Wasser und Feuchtgebiete definiert. Auf weiteren Ebenen wurde Wald zusätzlich in Nadel-, Laub-, Mischwald und offene Waldflächen, die sonstigen Vegetationsflächen in Grünland und Ackerflächen differenziert. Auf der dritten Ebene wurden solche Klassen aufgenommen, die nur in einzelnen Ländern vorkommen und nicht für alle Länder charakteristisch sind. In dieser Arbeit werden Ergebnisse aus der ersten und zweiten Klassifizierungsebene dargestellt.

3. Ergebnisse und Diskussion

3.1 Diskriminanzanalyse

Es wurden insgesamt 340 Kanäle aus dem fusionierten Landsat-IRS Datensatz und 227 aus den Quickbird- und Orthophotodaten mit der eCognition Software berechnet. Bei den aus den fusionierten Landsat-IRS errechneten Kanälen wurden nach 7 Iterationen keine signifikanten Änderungen im Erklärungswert mehr festgestellt und wurden daher 7 Kanäle in das Modell aufgenommen. Die Diskriminanzanalyse hat die gefilterte IRS-1D Szene gegenüber der ursprünglichen Szene bevorzugt selektiert. Überraschend ist die Tatsache, dass außer der gefilterten IRS Szene keiner der ursprünglichen Kanäle über die Diskriminanzanalyse selektiert wurde. Neben dem gefilterten Datensatz wurden aus den AIF und AIF-Sigma-IHS fusionierten Landsat Datensätzen die Kanäle 3 (Rot), 4 (Nahes Infrarot) und 5 (Mittleres Infrarot) und der Ratiokanal Mittleres Infrarot durch Rot in das Diskriminanzmodell aufgenommen. Der Algorithmus hat keinen von den Tasseled Cap und Vegetationsindex Kanälen ausgewählt, sondern die GLCM Correlation und GLCM Homogeneity Texturkanäle, berechnet aus den fusionierten Produkten. Aufbauend auf das Ergebnis der Diskriminanzanalyse haben sich die Ratiowerte als wichtige Klassifizierungsgrundlage erwiesen, die Standardabweichung spielte dagegen für die Trennbarkeit keine Rolle (siehe Tab. 1.).

Landsat-IRS Datensatz	Quickbird	Luftbild
Ratiowert* AIF Nahes Infrarot	Ratiowert* Grün	Ratiowert* Vegetationsindex
Ratiowert* AIF 5 durch 4	Mittelwert* Nahes Infrarot	Mittelwert* Vegetationsindex
Mittelwert* des gefilterten IRS Bildes	GLCM Mittelwert von Nahes Infrarot Varianz	GLCM Mittelwert Oberflächenmodell
Ratiowert* der AIF-sigma-IHS Mittleres Infrarot	Ratiowert* des blauen Kanals	GLCM Homogeneity von Varianz des Nahen Infrarot
GLCM Correlation von AIF 5 durch 4	Ratiowert* des Vegetationsindex	GLCM Mittelwert des gefilterten roten Kanals
GLCM Correlation vom AIF-Sigma-IHS roten Kanal	GLCM Homogeneity des blauen Kanals	Ratiowert* des gefilterten roten Kanals
GLCM Homogeneity vom AIF-Sigma-IHS Nahes Infrarot	GLCM Mittelwert des grünen Kanals	GLDV Entropy von Nahinfrarot

Tabelle 1: Ergebnisse der Diskriminanzanalyse; *: berechnet nach eCognition Ratio- und Mittelwerten

Für die hochaufgelösten Daten wurden zunächst die gleichen Klassen untersucht wie für den geringer aufgelösten Datensatz. Darüber hinaus

wurden neue Klassen hinzugenommen, die sich aus der höheren Auflösung ergaben. So wurde anhand der Quickbird- und Luftbilddaten ein schmaler Fluß erkannt und als Trainingsgebiet ausgewählt. Darüber hinaus wurden im Luftbild Schatten neben Häusern und Baumgruppen klassifiziert. Nach dem beschriebenen Verfahren der Diskriminanzanalyse wurden auf der Basis der Quickbird- und Luftbilddatensätze ebenfalls sieben Kanäle anhand des Wilk's-Lambda Wertes selektiert. Interessant ist in diesem Zusammenhang, dass das Geländeoberflächenmodell für Quickbird als nicht wichtig erachtet wurden, während für das Luftbild das Geländeoberflächenmodell schon im dritten Diskriminanzschritt ausgewählt wurde. Für Quickbird wurde der rote Kanal als nicht wichtig betrachtet, während für das Luftbild das Nahe Infrarot und der rote Kanal als die für die Klassifikation am geeignetsten ausgewählt wurden. Während für den Quickbird Datensatz drei Texturkanäle ausreichten, wurden für das Luftbild vier ausgewählt. Wegen der höheren Auflösung mussten hier neben den spektralen Kanälen auch mehrere Texturmerkmalsbilder einbezogen werden.

3.3 Klassifizierung

Die Gesamtgenauigkeit der ersten Klassifizierungsebene aller Bilder lag bei über 90% (siehe Tab. 2). Das Luftbild wurde mit 99% am genauesten klassifiziert, während sich für das Quickbirdbild und Landsat-IRS Fusionsbild 97% bzw. 94% Gesamtgenauigkeit ergaben. In der Quickbirdszenen wurde Wald mit der objektbasierten Methode sowohl nach der Hersteller- als auch nach der Nutzergenauigkeit 100% korrekt erkannt. Auch aus dem Luftbild und Landsat-IRS Datensatz wurden Waldflächen mit über 97% Nutzergenauigkeit klassifiziert. Versiegelte und offene Flächen wurden anhand des Luftbildes am genauesten und im Landsat-IRS am wenigsten genau erkannt. Bei der gegebenen Auflösung des Luftbildes sind diese Flächen deutlich zu erkennen, während anhand des Landsat-IRS Fusionsbildes diese beiden Klassen kaum voneinander unterscheidbar sind. Dies ergibt eine schlechtere Segmentierung und Klassifikation. Zusammenhängende Waldflächen sind in allen Datensätzen gut trennbar.

Obwohl die Genauigkeit in der zweiten, detaillierteren Ebene allgemein schlechter ist als in der gröberen Ebene, waren die Ergebnisse der Klassifikationen immer noch sehr gut. Auch hier hat das Luftbild die beste Gesamtgenauigkeit von über 96% ermöglicht, mit dem Landsat-IRS- und Quickbirddatensatz konnte eine Gesamtgenauigkeit von 90% erreicht werden. Laubwald und Mischwald wurden anhand aller drei Datensätze, mit zwischen 80 und 90% Nutzergenauigkeit richtig erkannt. Diese Klassen

scheinen, aufgrund der Tatsache, dass diese Flächen am häufigsten im Gebiet vorkommen, die stabilsten zu sein. Nadelwaldflächen erzielten auf der Basis von Landsat-IRS- und Luftbilddaten in der Nutzergenauigkeit eine viel höhere Genauigkeit als die Quickbirddaten. Nadelwaldflächen sind in der radiometrischen und räumlichen Auflösung der Landsat-IRS Szene sehr homogene Objekte, während anhand Quickbirddaten die Flächen viel

	Landsat-IRS		Quickbird		Luftbild	
<i>Ebene 1</i>						
Gesamtgenauigkeit	0,948		0,975		0,994	
Genauigkeit	Nutzer	Hersteller	Nutzer	Hersteller	Nutzer	Hersteller
Wald	0,995	0,975	1	1	0,998	1
Grünland	0,946	1	0,993	1	0,994	1
Versiegelt	0,733	0,546	0,851	0,722	0,976	0,958
Offene Fläche	0,852	0,899	0,882	0,921	1	0,973
<i>Ebene 2</i>						
Gesamtgenauigkeit	0,900		0,900		0,963	
Genauigkeit	Nutzer	Hersteller	Nutzer	Hersteller	Nutzer	Hersteller
Laubwald	0,804	0,895	0,851	0,701	0,991	0,893
Nadelwald	1	0,488	0,843	0,989	1	0,891
Mischwald	0,833	0,889	0,854	0,676	0,876	0,994
Siedlungsfläche	1	0,872	0,960	0,792	0,934	0,702
Wege	1	0,578	0,882	0,886	0,885	0,958

Tabelle 2: Genauigkeit der Klassifikation

heterogener erscheinen. Bei der Auflösung der Luftbilder sind diese Flächen wiederum über die einzelnen Baumkronen gut zu erkennen. Dies ergibt die Nutzergenauigkeit der drei Datensätze.

Überraschend wurden Siedlungsfläche und Wege anhand von Landsat-IRS Daten mit einer Nutzergenauigkeit von 100% richtig klassifiziert. Allerdings wurden sehr wenige Objekte als Wege und Siedlungsflächen auf der Basis der Landsat-IRS Daten erkannt und segmentiert, deshalb konnten auch nur wenige als Referenz für die Verifizierung ausgewählt werden. Diejenigen Objekte aber, die für die Genauigkeitsprüfung ausgewählt werden konnten, waren zu 100% richtig klassifiziert.

Die Fehlermatrix zeigt mit über 90% und oft bis 100% Genauigkeit extrem Werte, wie sie mit einem pixelbasierten Ansatz nie erreicht werden. Dies ist darauf zurückzuführen, dass es sich hier um die Verifizierung von generalisierten Objekten handelt, während bei der Verifizierung von pixelbasierten Daten auf einzelne Bildelemente zurückgegriffen wird. Bei einzelnen Bildelementen entstehen insbesondere aufgrund von Mischpixel und einer häufig verwendeten generalisierten Vergleichsgrundlage

Fehlklassifizierungen. Dies produziert unmittelbar eine hohe Genauigkeit der Klassifikation die allerdings vorsichtig behandelt werden muß.

4 Zusammenfassung

Der FNEA Ansatz hat sich in dieser Studie als sehr nützlich für eine flexible und stabile Segmentation verschiedener Landschaftsstrukturen bei unterschiedlichen Fernerkundungsdaten erwiesen. Während im Rahmen einer visuellen Interpretation die Landschaftselemente zwischen mehreren Interpreten unterschiedliche Größe und Form bekommen, erlauben segmentierte Objekte die Beschreibung von wesentlichen Landschaftselementen mit Geometrien, die nicht von Interpretationsfehlern beeinflusst wurden. Für landschaftsökologische Auswertungen, bei denen Objekteigenschaften, wie Fläche, Umfang und Nachbarschaftsbeziehungen eine entscheidende Rolle spielen, können so objektorientierte Methoden ein stabiles Verfahren zur Objektdelinierung bieten.

Die objektbasierte Klassifizierung zeigte insgesamt sehr gute Klassifizierungsergebnisse für alle Datensätze. Es zeigte sich jedoch auch, dass solche Klassen, die mit genügender Fläche vertreten sind, teilweise auf der Basis der Landsat-IRS Daten besser trennbar sind, als auf der Basis der sehr hochauflösten Quickbird- oder auch Luftbilddaten. Dort wo die Flächen allerdings eine Größe erreichen, die nur durch Mischpixel dargestellt werden kann, sind die hochauflösten Datensätze im Vorteil. Der Verfahrensablauf der objektbasierten Methode kann nur limitiert auf die verschieden aufgelösten Daten übertragen werden. Die Unterschiede, hervorgerufen durch Pixelgröße, radiometrische Eigenschaften und Aufnahmezeitpunkt, fordern für jeden Datensatz ein eigenes Klassifikationsschema. Eine Anpassung des Klassifikationsschemas ist auch bei Übertragung in andere Gebiete notwendig, wenn auch der Prozessablauf beibehalten werden kann.

Die Haralick Texturen haben positiv zur Klassifizierung aller drei Datensätze beigetragen. Nicht nur bei strukturreichen Landschaftselementen, wie versiegelten Flächen oder beim Wald - Grünland Übergang, sondern auch für die Klassifikation verschiedener Waldtypen haben sich die Texturen als sehr nützlich erwiesen. Bei hoher Auflösung können zwar kleine Objekte erfasst werden, aber die Varianz innerhalb der Objekte nimmt zu. Dies macht die Klassifikation anhand spektraler Information kompliziert, anhand von Texturen können aber diese Flächen oft erfasst werden. Die schrittweise Diskriminanzanalyse aller mit eCognition erstellten Informationsebenen liefert eine Kanalauswahl und

damit einen mehrdimensionalen Merkmalsraum. Mit diesem ist es möglich schwer visuell erkennbare Klassen zufriedenstellend zu klassifizieren. Gerade die Anzahl der Kombinationen zwischen Textur und spektraler Information ist ein wichtiger Ansatz, um die Klassifikation schnell und leistungsfähig zu machen.

Der Nearest Neighbour Algorithmus erwies sich als flexibel einsetzbar, und über das hierarchische Netz zwischen den verschiedenen Ebenen konnte ein schneller Klassifikationsablauf erreicht werden. Die hierarchische Klassifikation ist ein Ansatz, der es wesentlich vereinfacht in verschiedenen Bioregionen nach einem einheitlichen Verfahrensansatz unterschiedliche Vegetationsklassen auszuweisen. Die einfachste Ebene mit allgemeinen Klassen, wie Wald, sonstige Vegetation und Siedlungen, erlaubt sogar eine direkte Übertragung des Verfahrens und damit Vergleich der Landschaftsstrukturen in verschiedenen Regionen. Darunterliegende Ebenen mit weiteren habitatspezifischen Ausweisungen von Landschaftselementen sind möglich, bedürfen aber oft einer Anpassung des Klassifikationsschemas.

Danksagung

Die Autoren bedanken sich bei der eidgenössischen Forschungsanstalt für Wald Schnee und Landschaft (WSL, Birmensdorf, CH) für die Unterstützung mittels des digitalen Geländemodells und die Erstellung der Orthophotodaten.

Literatur

- Baatz, M. and A. Schäpe, 1999: *Object-Oriented and Multi-Scale Image Analysis in Semantic Networks*. In: *Proc. Of the 2nd International Symposium on Operationalization of Remote Sensing*. August 16th-20th, 1999. Enschede. ITC.
- eCognition User Guide, 2002, <http://www.definiens-imaging.com>.
- Ivits, E., Koch, B., 2002, *Object-Oriented Remote Sensing Tools for Biodiversity Assessment: a European Approach*, Proceedings of the 22nd EARSeL Symposium, Prague, Czech Republic, 4-6 June 2002, Millpress Science Publishers, Rotterdam, Netherlands.
- Koch, B., Ivits, E., 2003, *Landschaftsanalyse auf neuen Wegen?* Österreichische Forstzeitschrift, eingereicht Januar, 2003.

Steinnocher, K., 1999, *Adaptive Fusion of Multisource Raster Data Applying Filter Techniques*, International Archives of Photogrammetry and Remote Sensing, Vol. 32, Part 7-4-3 W6, pp. 108-115.