

# **„Selektives“ region growing – ein objektorientierter Klassifikationsansatz**

Claudius MOTT, Thorsten ANDRESEN, Stefan ZIMMERMANN,  
Thomas SCHNEIDER und Ulrich AMMER

## **Zusammenfassung**

Ein einfaches Regelwerk wird vorgestellt, welches Laub- und Nadelwald in sehr hoch auflösenden multispektralen IKONOS Daten mit einem objektorientierten Ansatz klassifiziert. Das Regelwerk entspricht einer Art „region growing“ Prozedur, die neben der Nachbarschaft auch klassenspezifisch spektrale Eigenschaften nutzt. Kernpunkt des Ansatzes ist die Unterscheidung zwischen stabilen und instabilen Objektmerkmalen, die in getrennten Arbeitsschritten behandelt werden.

Mit diesem Regelwerk lässt sich die hohe spektrale Varianz von sehr hoch auflösenden Fernerkundungsdaten deutlich besser bewältigen als mit herkömmlichen, pixel-basierten Klassifikationsmethoden. Das Ergebnis sind zusammenhängende Waldobjekte die den Ergebnissen einer visuellen Interpretation nahe kommen und direkt als Input in ein GIS verwendet werden können.

## **1 Einleitung**

Fortschritte in der Sensortechnologie führen zu der Entwicklung geometrisch, radiometrisch und spektral immer höher auflösender Systeme. Man erhofft sich von den damit erfassten Daten genauere Kenntnisse über die Bodenbedeckung, um daraus neue Anwendungen im kleinmaßstäblichen Bereich zu entwickeln. Mit jeder Verbesserung der Auflösung steigt auch die Komplexität des Informationsgehaltes. Bei einer Pixelgröße von unter 5 m, die heute von der IKONOS Sensor Generation erreicht wird, stoßen die herkömmlichen, pixelbasierten Klassifikationsmethoden an ihre Grenzen (DE KOK ET AL. 1999; SCHNEIDER & STEINWENDNER 1999). Traditionelle fernerkundliche Klassifikationsverfahren bewerten mit verschiedensten mathematisch-statistischen Methoden die spektrale Ausprägung eines Bildpunktes und weisen diesem eine Klasse zu. Einzelne Bildpunkte werden als voneinander unabhängige Elemente betrachtet. Bei sehr hoch auflösenden Fernerkundungsdaten steigt die spektrale Varianz der Pixelwerte, die eine thematisch sinnvolle Klasse abbilden. Auf Pixelebene ist das empfangene Signal nicht mehr eindeutig einer Klasse zuordenbar. Die aus pixelbasierten Klassifikationen resultierenden thematischen Karten sind zum Teil unvollständig und in der Flächenausbreitung stark zergliedert. Man hat in diesem Zusammenhang den aus dem Radar-Bereich stammenden Begriff „Salt and Pepper“ - Effekt übernommen (BLASCHKE, LANG ET AL. 2000). Mit zunehmender Auflösung tritt dieser Effekt verstärkt auf. Die Grenzen pixelbasierter Verfahren bei der Auswertung sehr hoch auflösender Datensätze haben objektorientierte Analysemethoden in den Mittelpunkt des Interesses gerückt. Objektorientierte Bildanalyseverfahren wurden bereits in den 70er Jahren entwickelt

(KETTIG AND LANDGREBE 1976). Anstelle von Bildpunkten werden homogene Segmente bewertet. Mit der Bildanalysesoftware „eCognition“ der Definiens-Imaging GmbH steht diese Form der Dateninterpretation erstmals einer breit gefächerten Nutzergruppe zur Verfügung.

## **2 Fragestellung**

Übergeordnetes Ziel der Untersuchung ist die sukzessive Annäherung automatisierbarer Bildanalyseverfahren an die Ergebnisse einer visuellen Klassifikation. Das Teilziel der hier vorgestellten Studie war es, ein transparentes Regelwerk innerhalb der Software eCognition aufzubauen, um zunächst Laub und Nadelwald mit sehr hoch auflösenden FE-Daten zu klassifizieren. Das Problem der hohen spektralen Varianz solcher Daten soll unter Nutzung der Nachbarschaftsinformation adäquat behandelt werden. Klassifikationslücken innerhalb der Waldgrenzen sollen so sukzessive geschlossen werden. Als Vorgabe setzten wir beim Aufbau des Regelwerkes die strenge Trennung nach stabilen und instabilen Kriterien voraus.

## **3 Objektorientierte Ansatz**

„Objektorientierung“ im eigentlichen Sinne ist ein Konzept aus der Softwareentwicklung. Sachverhalte und Erscheinungen werden nicht mehr auf ihre Einzelheiten begrenzt, sondern als eingegliedertes Ganzes betrachtet, bei dem die einzelnen Komponenten miteinander verbunden sind und Abhängigkeiten zwischen ihnen bestehen (OESTEREICH 2001).

In der Fernerkundung bedeutet Objektorientierung, dass nicht einzelne Pixel in ihrer spezifischen spektralen Ausprägung betrachtet werden, sondern vielmehr Cluster angrenzender Pixel, so genannte Segmente.

In eCognition bewertet ein Segmentierungs-Algorithmus die spektrale Homogenität benachbarter Pixel unter Berücksichtigung des räumlichen Kontrastes (BAATZ & SCHÄPE 2000). Während der Segmentierung wird eine Datenbank aufgebaut, welche die spezifischen Eigenschaften jedes einzelnen Segmentes verwaltet. Durch diesen Vorgang wird ein Segment zu einem Objekt mit Eigenschaften. Neben einfachen spektralen Attributen, werden z.B. auch Textur, Form, Standardabweichung und Relationen zu anderen Bildobjekten (Kontext) ermittelt und stehen für die Klassifikation zur Verfügung.

Die Segmentierung der Bilddaten kann auf verschiedenen Ebenen (oder Level) mit ungleichen räumlichen Auflösungen durchgeführt werden („multi-resolution segmentation“). Einstellbar ist die Segmentgröße durch einen abstrakten Scale-parameter, welcher die spektrale Homogenität benachbarter Pixel bewertet. So ist es möglich, abhängig von der Fragestellung, den optimalen Maßstab für die Segmentgröße zu wählen. Die hierarchischen Bezüge der einzelnen Objekte zu Unter- bzw. Oberobjekten sind in der Objektdatenbank verfügbar.

## 4 Untersuchungsgebiet

Untersucht wurden zwei Ausschnitte (13Ha und 7 Ha) aus einem multispektralen IKONOS Datensatz vom 12ten August 2001 mit einer nominalen Auflösung von 4m. Die Untersuchungsgebiete liegen etwa 40 Kilometer südlich von München und repräsentieren typische Waldstrukturen von oberbayrischem Privatforst. Der entsprechende IKONOS Pan Datensatz mit einem Meter Bodenauflösung diente der Validierung und wurde von einem erfahrenen Interpret visuell klassifiziert. Die visuelle Interpretation wurde durch Feldkampagnen unterstützt.

## 5 Das Regelwerk

Als methodische Vorgabe bei der Erstellung des Regelwerkes stand die Forderung einer strikten Trennung von „instabilen“ und „stabilen“ Objektmerkmalen. Als instabil gelten solche Parameter, die von der Datengrundlage abhängig sind und sich von Datensatz zu Datensatz unterscheiden können, z. B. Sensor- und Datentyp, atmosphärische Bedingungen, Vegetationsperiode, etc. Stabile Eigenschaften sind überwiegend semantische Beziehungen der Bildobjekte zueinander, so z. B. dass eine Insel immer von Wasser umgeben ist oder sich eine Streuobstwiese aus Grünland und Obstbäumen zusammensetzt.

Der hier vorgestellte Klassifikationsansatz gliedert sich in drei sukzessive Verfahrensschritte, die auf zwei Segmentebenen ablaufen. Auf Ebene 1 werden „instabile“ Merkmale (spektrale) bewertet während auf Ebene 2 ausschließlich „stabile“ semantische Beziehungen zur Klassifikation herangezogen werden.

Auf der unteren Ebene werden im ersten Schritt pixelgroße Objekte gebildet (Scale-Parameter: 0). Die Trennung in Laub- und Nadelwald erfolgte durch Schwellwertbildung im grünen (0,52-0,61 $\mu$ m), roten (0,64-0,72 $\mu$ m) und nahen Infrarot (0,77-0,88 $\mu$ m) Kanal. Zur Absicherung des Ergebnisses wurde zusätzlich der NDVI bewertet. Die Klassifikation auf dieser Ebene beruht somit allein auf der Spektralinformation der IKONOS Daten. Das Ergebnis ist in Abb.1(C) dargestellt.


Im zweiten Schritt werden Nachbarschaftsbeziehungen und weiter gefasste spektrale Kriterien abgefragt. Ausgehend von der ersten „pixelbasierten“ Klassifikation wird im Folgenden die Nachbarschaft eines jeden (pixelgroßen) Segmentes bewertet. Ist die gemeinsame Grenze zu einer der beiden Waldklassen größer oder gleich 75% so wird der Wert im nahen Infrarot geprüft und das Pixelobjekt nur klassifiziert wenn der Wert innerhalb definierter Grenzen liegt. Bei jeder der Iterationen werden sukzessive Lücken unklassifizierter Pixelobjekte geschlossen und das Ergebnis bei der nächsten Iteration als Ausgangsklassifikation herangezogen. Der Vorgang wird wiederholt bis das Resultat stabil ist. Im vorliegenden Fall waren drei Iterationen notwendig. Der Ablauf ist einem „region-growing“ Verfahren vergleichbar. Die weiter gefassten spektralen Kriterien können klassenspezifisch definiert werden. Selektiv kann das „Wachsen“ von Klassen beeinflusst werden.

Im letzten Schritt wird ein neuer Level mit größeren Segmenten gebildet. Die Parameter für die Segmentierung wurden subjektiv nach dem Trial and Error-Prinzip ermittelt. Ein Homogenitätsfaktor von 12 schien geeignet um die Waldstrukturen hinreichend genau zu

repräsentieren. Die Gewichtung des Farbparameters betrug: 0.5 (Form: 0.5). Der Parameter „smoothness“ wurde mit 0.6 („compactness“ 0,4) gewichtet. Zur Klassifikation wurde diesem Level das Verhältnis der Unterobjekte Laubwald zu Gesamtwald herangezogen. War der Anteil von Laubwald in einem Segment größer oder gleich 50%, wurde dieses der Klasse Laubwald zugewiesen. War der Laubwaldanteil kleiner als 50% bedeutete das, dass Nadelwald in dem entsprechenden Segment dominierte. Zusätzlich galt die Bedingung dass mindestens 80% der Gesamtfläche eines Segmentes mit Wald bedeckt sein muss.

## 6 Ergebnisse und Diskussion

In Abbildung 1(A) ist Untersuchungsgebiet 1 als Graustufenbild des multispektralen IKONOS Datensatzes (Kanalkombination: R: NIR, G: grün, B: blau) dargestellt. Es ist 13 Hektar groß und zeigt typische Laub- und Nadelwaldstrukturen. Das Ergebnis der visuellen Interpretation durch einen erfahrenen Interpreten ist in Abbildung 1(B) dargestellt. Diese Auswertung gilt als Referenz. In die Interpretation floss das Wissen aus Feldbegehungen mit GPS-Messungen ein. In Abbildung 1(C) ist das Klassifikationsergebnis des ersten, auf spektrale Merkmale beruhenden, Verfahrensschrittes dargestellt. Bei einer Daten-Auflösung von 4m ist die natürliche Heterogenität des Kronendachs in den Daten repräsentiert. Das Ergebnis ist lückenhaft und genügt nicht den Ansprüchen einer thematischen Waldkarte, da keine einheitlichen Flächen vorhanden sind, die in einem GIS verwaltet werden können. Diese Lücken werden in weiteren Klassifikationsdurchläufen unter Nutzung der Nachbarschaftsinformation zum Teil geschlossen (Abb.1(D)). Erst auf einem höheren Hierarchielevel, wo das Verhältnis der Unterobjekte zur Klassifikation herangezogen wird, entspricht das Ergebnis den Erwartungen eines Nutzers (Abb.1(E)).



**Abb. 1:** (A) erstes Untersuchungsgebiet, (B) visuelle Interpretation, (C) erste spektrale Klassifikation auf Ebene 1, (D) 3te Iteration unter Nutzung von Nachbarschaftsbeziehungen, (E) Klassifikationsergebnis auf Segmentlevel 2

Die Klassifikationsgenauigkeit wurde durch eine Verschneidung der Ergebnisse mit der visuellen Interpretation ermittelt. Die Producer's und User's Accuracy pro Klassifikationsschritt ist für beide Untersuchungsgebiete in Tabelle 1 dargestellt.

	Level 1-1. Durchlauf (spektral)		Level 1-1. Iteration (Nachbarschaft)		Level 1-2. Iteration (Nachbarschaft)		Level 1-3. Iteration (Nachbarschaft)		Level 2 (VH Unterobj.)	
	User's A.	Prod.'s A.	User's A.	Prod.'s A.	User's A.	Prod.'s A.	User's A.	Prod.'s A.	User's A.	Prod.'s A.
<b>Testgebiet 1</b>										
Nadelwald	78,6%	79,8%	79,0%	87,3%	79,0%	87,9%	78,9%	88,0%	79,1%	90,8%
Laubwald	88,0%	57,6%	88,3%	59,6%	88,3%	59,6%	88,3%	59,7%	87,3%	73,5%
<b>Testgebiet 2</b>										
Nadelwald	81,2%	73,8%	81,9%	80,2%	82,0%	81,0%	82,0%	81,1%	78,0%	86,3%
Laubwald	87,4%	77,7%	87,4%	79,2%	87,3%	79,2%	87,3%	79,3%	86,3%	82,4%

**Tab. 1:** dargestellt ist die Producer's und User's Accuracy für beide Untersuchungsgebiete, gemessen an einer visuellen Interpretation

Auf Level 1 nimmt die Producer's Accuracy innerhalb beider Untersuchungsgebiete für Nadelwald deutlich (8,2% bzw. 7,3%) für Laubwald leicht (2,1%, bzw. 1,6%) zu. Die Ursache für diese Ungleichheit lässt sich mit dem unterschiedlichen Aufbau des Kronendachs beider Waldtypen erklären. Die kegelförmigen Baumkronen der Nadelbäume beschatten die Umgebung. Dies führt dazu, dass diese Bereiche im ersten Schritt rein spektral nicht erfasst werden können. In den folgenden Iterationen werden diese Bereiche dann aufgrund der Nachbarschaftsbeziehungen geschlossen. Bei einer Auflösung von 4 Metern erscheint das Kronendach des Laubwaldes wesentlich homogener und weniger texturiert, als das des Nadelwaldes, was die geringen Veränderungen der Klassifikationsgüte erklären würde. Auffallend ist zudem die unterschiedliche Ausgangsgenauigkeit bei Laubwald in Testgebiet 1 verglichen mit Testgebiet 2. Ein Teil des Laubwaldbestandes ist dort zur Verjüngung unter Schirm ausgeholzt worden, was große Lücken im Kronendach zur Folge hat. Waldboden und große Schattenbereiche werden in den Satellitendaten abgebildet. Anders als bei visueller Interpretation, wo diese Bereiche der Waldfläche zugewiesen werden, scheitert das „region growing“ Verfahren bei der Zuordnung. Die strengen Nachbarschaftsbedingungen von mind. 75% gemeinsame Grenze werden in diesen Fällen nicht erfüllt, da die Bereiche zu groß sind. In Untersuchungsgebiet 2 (hier nicht bildlich dargestellt) ist das Kronendach des Laubwalds homogen und diese Effekte haben keinen Einfluss.

Die User's accuracy verändert sich in Level 1 während den Iterationen nur unwesentlich. Sie liegt für beide Testgebiete im Bereich 78% bzw. 82% für Nadelwald und bei 87% bzw. 88% für Laubwald. Auf Level 1 funktioniert das Regelwerk im Prinzip ähnlich wie ein Filter, der jedoch zusätzlich zur Nachbarschaft auch spektrale Bedingungen (hier NIR) in die Filterentscheidung einbezieht.

Das Ergebnis nach dem letzten Verfahrensschritt, bei dem die Klassifikation auf dem Verhältnis der Unterobjekte Laub- und Nadelwald beruht, zeigt eine weitere Verbesserung der Producer's Accuracy. Auffallend ist hier der Sprung bei Laubwald in Untersuchungsgebiet 1. Dieses belegt, dass Segmente problematischer Bereiche wie Schatten und Waldboden, die in den ersten zwei Verfahrensschritten nicht zugeordnet

werden konnten, nach diesem Schritt in die Klassifikation integriert werden. Die geringfügige Rückgang der User's Accuracy ist ein Hinweis darauf, dass es auch zu Fehlklassifikationen kommt.

## 7 Schlussfolgerung

Ausgehend von einer initialen Klassifikation lässt sich die Genauigkeit unter Nutzung von Nachbarschaftsinformation deutlich verbessern. Kombiniert man diese Information mit spektralen Kriterien können Fehlklassifikationen vermieden werden. Der Nutzer hat so direkten Einfluss darauf, welche benachbarten Objekte zu einer Klasse hinzugefügt werden. In dieser Studie wurde auf der unteren Ebene mit pixelgroßen Objekten gearbeitet, um nur die Nachbarschaft gesondert zu betrachten. Arbeitet man mit größeren Segmenten ist es möglich auf eine Vielzahl weiterer Eigenschaften, wie Textur oder Form eines Objektes, zurückzugreifen und kann so möglicherweise die Klassifikationsgüte weiter verbessern.

Als wichtiges methodisches Ergebnis der vorgestellten Studie ist die erfolgreiche Trennung des Klassifikationsablaufs nach stabilen und instabilen Kriterien zu nennen. Diese Trennung nach semantischen und von der Datengrundlage abhängigen Parametern erleichtert eine Übertragbarkeit der Regelwerke. Das semantische oder stabile Regelwerk lässt sich immer übertragen, während der instabile Teil des Regelwerkes auf die Datengrundlage angepasst werden muss. Quasi nebenbei liefert das Verfahren Objekte, die direkt in eine GIS Umgebung übernommen werden können.

## 8 Danksagung

Diese Studie ist im Rahmen des Projektes AQUATIC entstanden, welches durch das BMBF gefördert wird. Projektnummer: 50 EE 0040 & 50 EE 0041.

## 9 Literatur

- BAATZ, M. AND A. SCHÄPE (2000). Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2000*, Salzburg, Herbert Wichmann Verlag.
- BLASCHKE, T., S. LANG, et al. (2000). Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. *Environmental Information for Planning, Politics and the Public*. A. Cremers and K. Greve. Marburg, Metropolis-Verlag. Volume II.
- DE KOK, R., T. SCHNEIDER, et al. (1999). Object based image analysis of high resolution data in the alpine forest area. *Joint WSf ISPRS WG I/1, I/3 and IV/4: SENSORS AND MAPPING FROM SPACE 1999*, Hannover, Germany.
- KETTIG, R. L. AND D. A. LANDGREBE (1976). "Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects." *Ieee Transactions on Geoscience and Remote Sensing* 14(1): 19-26.

Oestereich, B. (2001). Objektorientierte Softwareentwicklung. München, R. Oldenbourg.  
SCHNEIDER, W. AND J. STEINWENDNER (1999). "Landcover Mapping by Interrelated  
Segmentation and Classification of Satellite Images." International Archives of  
Photogrammetry and Remote Sensing 32(7-4-3 W6).