
4

4. *Segmentierung*

In diesem Kapitel werden Methoden zur Segmentierungen von Bilddaten und deren Anwendung auf HRSC-AX Daten erläutert.

4.1. Datenstruktur

Mit zunehmender Verfügbarkeit von sehr hochauflösenden Daten, im englischen auch als *Very High Spatial Resolution (VHSR)* bezeichnet, werden auch zunehmend geeignete Werkzeuge zur automatisierten Auswertung gefordert. Die detaillierte Analyse und automatisierte Klassifizierung von Bilddaten in städtischen Gebieten ist eines der Gebiete der Fernerkundung, das sich am schwierigsten gestaltet.

Städtische Gebiete sind durch sehr hohe spektrale und geometrische Heterogenität sowie variierende Strukturen charakterisiert. Der starke Wechsel unterschiedlichster Landnutzungen in verschiedensten Ausprägungen, wie etwa dicht und locker bebaute Areale, Wasserkörper, unterschiedliche Vegetation und Böden, verschiedene Dachmaterialien sowie die Heterogenität der einzelnen Objekte selbst, machen jede Analyse dieser Gebiete sehr komplex. Einerseits erlauben erst die hochauflösenden Bilddaten, urbane Räume zufrieden stellend zu analysieren und zu klassifizieren, andererseits werden durch ebendiese hohe Auflösung sowie die spektrale und räumliche Heterogenität städtischer Bereiche Probleme verursacht.

Erschwert wird die Auswertung von sehr hochauflösenden Daten noch durch ihre unterschiedlichen spektralen Eigenschaften über einen oder auch mehrere Befliegungstage hinweg. Durch den Sonnenstand, der unterschiedliche Beleuchtungssituationen bewirkt, und durch atmosphärische Effekte werden Veränderungen verursacht.

Die Nutzerakzeptanz für die Klassifikation korrespondiert sehr

stark mit der Qualität der Auswertungsergebnisse. Wie in vielen bisherigen Veröffentlichungen gezeigt wurde, sind die herkömmlichen pixelorientierten Klassifizierungsmethoden der urbanen Räume unter Verwendung von hochauflösenden Daten eher ungeeignet, da in den Klassifizierungsergebnissen der *salt-and-pepper*-Effekt auftritt.⁵⁴ Durch die hohe geometrische Auflösung von digitalen Kameras von bis zu 5 cm/pxl sind die einzelnen Pixel viel kleiner als die zu klassifizierenden Objekte. Dies führt unter Verwendung der pixelorientierten Klassifizierungsmethoden zur Erhöhung der Variabilität, des Rauschens und zu Fehlklassifizierungen innerhalb der semantischen

⁵⁴ Siehe hierzu: Blaschke, T. (2000): Ohne Salz und Pfeffer. In: *GeoBIT*, Nr. 2, S. 19-21; Koch, B. et al. (2003): Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. In: *Photogrammetrie, Fernerkundung Geoinformation*, (Jg. 2003), Nr. 3, S. 195-204; Diermayer, E. et al. (2006): Comparing Pixel- and Object-based Classification of Imperviousness with HRSC-AX Data. 1st EARSeL Workshop of the SIG Urban Remote Sensing, Humboldt-Univ. Berlin, S. 93; Kux, H. J. H. u. Moutinho Duque de Pinho, C. (2006): Object-Oriented Analysis of High Resolution Satellite Images for Intra-urban Land Cover Classification: Case Study in São José dos Campos, São Paulo State Brasil. In: *Proceedings of the 1st International Conference on Object-based Image Analysis (OBIA)*; Siachalou, S. et al. (2006): Classification Enhancement in Urban Areas. 1st EARSeL Workshop of the SIG Urban Remote Sensing, Humboldt-Univ. Berlin

Klassen. Somit stößt die separate Betrachtung des einzelnen Pixels bei der Klassifikation an ihre Grenzen. Die äußerst wichtige Klassifizierungsgenauigkeit leidet.⁵⁵ Besonders betroffen sind in diesem Fall anthropogene Objekte, die für die menschliche Wahrnehmung durch klare Kompaktheit, Geradlinigkeit und Homogenität charakterisiert sind. Jeder Nutzer, auch ein Nichtfachmann, der ein Satelliten- oder Luftbild betrachtet, erfasst intuitiv und subjektiv Formen, Muster und Zusammenhänge der realen Welt. Er nimmt nicht nur Farbinformationen oder Grauwerte wahr, sondern ist in der Lage, Formcharakteristika, Nachbarschaftsbeziehungen, strukturelle Merkmale und bestimmte Muster zu identifizieren.⁵⁶ Diese Leistungsfähigkeit der menschlichen Perception war für die Entwicklung der objekt-orientierten Bildanalyse ausschlaggebend. Allerdings erfordert diese Art der Wahrnehmung Erfahrung und Intelligenz -- Eigenschaften, über die Computer typischerweise nicht verfügen. Daher muss man sich heute noch damit begnügen, genau diese Fähigkeiten auf einfache Weise zu modellieren.

⁵⁵ Schiewe, J. u. Tufte, L. (2002): Potenzial regionen-basierter Verfahren für die integrative Auswertung von GIS- und Fernerkundungsdaten. In: Blaschke, T. (Hg.), Fernerkundung und GIS. Neue Sensoren - innovative Methoden, Heidelberg, S. 42-52.

⁵⁶ Blaschke, T. (2000): Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: neue Möglichkeiten für GIS-Anwender und Planer. In: 5. Symposium „Computergestützte Raumplanung“ - CORP 2000, www.corp.at

Eine überzeugende Bildanalyse soll demgemäß auf den semantischen Erkenntnissen aufbauen. Die Informationen über die Bedeutung der Objekte, deren Textur, Form und deren gegenseitige Relationen lassen sich nicht aus den einzelnen Pixeln gewinnen, sondern aus Gruppen von Pixeln, den so genannten Segmenten, die ein Objekt oder einen Teil eines Objektes repräsentieren. Wichtig ist hier, dass die Segmente Objekte der realen Welt in deren tatsächlicher Form widerspiegeln und auch ihre Beziehungen zu den umgebenden Objekten kennen.⁵⁷ Die Ausnutzung von solchen objektspezifischen Eigenschaften ermöglicht es, die Nachteile einer pixel-basierten Betrachtung zu überwinden.

Dieses Verfahren ist nützlich, um sehr unterschiedliche Pixel in bedeutungsvolle „homogene“ Objekte zu integrieren. Ein gutes Beispiel hierfür ist das Dach, das spektral sehr heterogen ist. Diese Heterogenität wird durch unterschiedliche Ziegel, durch Dachfenster und das Alter der Dachpappe, durch Schornsteine und durch zahlreiche andere Bauteile aus Metall verursacht. Mittels Segmentierung ist es möglich, dass die heterogenen Pixel so zusammengefasst werden, dass - im besten Fall - ein für das Dach repräsentatives Segment entsteht.

⁵⁷ Baatz, M. u. Schäpe, A. (2000): Multiresolution Segmentation: An Optimization Approach for High Quality Multi-scale Image Segmentation. In: Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium Salzburg 2000, (Ort?), S. 12-23.

Objekt-orientierte Klassifikationsverfahren bieten eine sinnvolle und unverzichtbare Alternative zu den pixel-basierten Verfahren bei der Auswertung der VHSR-Daten.

Die Bildsegmentierung schafft eine Grundvoraussetzung für die erfolgreiche objekt-orientierte Bildanalyse. Die Segmente werden vor der eigentlichen Klassifizierung in einem Segmentierungsschritt generiert. Typischerweise werden mehrere Pixel in homogenen Segmenten zusammengefasst. Deren Form und Größe sind abhängig von eingestellten Parametern, den so genannten Homogenitätskriterien. Die Segmente sind verbundene Pixelcluster, bilden also eine als einheitliches Ganzes zu betrachtende Menge von Einzelteilen und werden dementsprechend

auch als Bildobjektprimitive bezeichnet. Sie stellen eine starke und zuverlässige Basis für die nachfolgende Klassifikation dar. Eine erfolgreiche und sinnvolle Segmentierung ist entscheidend für das Klassifizierungsergebnis. Sinnlose oder nicht interpretierbare Segmente, wie ein aus „zwei Bäumen und einer halben Garage“ bestehendes Segment, können in der nachfolgenden Klassifizierung nicht mehr aussagekräftig voneinander getrennt werden.⁵⁸

Im Folgenden wird ein Überblick über die heute existierenden und die hier verwendeten Segmentierungsmethoden gegeben. In dieser Arbeit wurden die objekt-orientiert arbeitenden Bildanalysesoftwaren Definiens Professional 5.0 und Definiens Developer 6.0 verwendet.

4.2. „State of the art“ Segmentierungsmethoden

Die Segmentierung der Bilddaten ist die Basis für die nachfolgende Klassifikation. Dieser Schritt ist von großer Bedeutung, da die Qualität der durch Segmentierung generierten Objekte direkt die Qualität der Klassifizierungsergebnisse beeinflusst. Es existieren mehrere Definitionen, die diesen Prozess charakterisieren. Unter Segmentierung versteht man nach HILDEBRANDT⁵⁹ „die Gruppierung von

Bild-elementen, die bestimmte Einheitlichkeitsprädikate erfüllen.“ Laut SCHIEWE⁶⁰ ist unter Segmentierung folgendes zu verstehen: „Segmentation is the process of completely partitioning a scene into non-overlapping regions (segments) in scene space...“ Und BLASCHKE⁶¹

⁵⁸ Weidner, U. u. Lemp, D. (2005): Objektorientierte Klassifizierung. In: Bähr, H.-P. u. Vögtle, T. (Hg.): Digitale Bildverarbeitung. Anwendungen in Photogrammetrie, Fernerkundung und GIS. Heidelberg, S. 106-122.

⁵⁹Hildebrandt, G. (1996:), Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und

Landschaftsökologie. Karlsruhe, Wichmann Verlag, S. 526.

⁶⁰ Schiewe, J. (2002): Segmentation of High-resolution Remotely Sensed Data - Concepts, Applications and Problems.; In: Proceedings on Symposium on Geospatial Theory, Processing and Applications, Ottawa, S. ? 2002

⁶¹Blaschke, T. (2000): Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: Neue

ergänzt die beiden Definitionen weiter: „[...] die Segmente (räumlich zusammenhängende Mengen von Pixeln) haben in der realen Welt eine Bedeutung. Die Segmentierung soll je nach Untersuchungszweck relevante Bildelemente bzw. repräsentierte Landschaftselemente ergeben“. Mittels Segmentierung werden demnach Bilder in zusammenhängende, nicht überlappende Bereiche zerlegt, die die Objekte der realen Welt wiedergeben und für die die bestimmten Homogenitätsbedingungen erfüllt sind. Die Segmentierungsverfahren finden heute in vielen Bereichen Anwendung. Bei SCHIEWE und TUFTE⁶² werden exemplarisch einige Anwendungsbereiche der Segmentierungsverfahren wie Medizin, Neuroinformatik, Nachrichtentechnik und Fernerkundung genannt.

In verschiedenen Untersuchungen wurden eine Vielzahl von unterschiedlichen Segmentierungsalgorithmen entwickelt. Im Rahmen dieser Arbeit werden nur diejenigen Segmentierungsverfahren beschrieben, die überzeugende und robuste Ergebnisse für Fernerkundungsanwendungen liefern. Die verfügbaren Segmentierungsmethoden werden unter anderem von HARALICK und

SHAPIRO⁶³ beschrieben und qualitativ verglichen. Zu diesen Methoden gehören *Measurement Space Guided Spatial Clustering*, *Single Linkage Growing Schemes*, *Hybrid Linkage Growing Schemes*, *Centroid Linkage Growing Schemes*, *Region Growing Schemes*, *Spatial Clustering Schemes*, *Split und Merge Schemes*. PAL und PAL⁶⁴ untersuchen die folgenden Methoden: *Gray level Thresholding*, *Iterative Pixel Classification*, *Surface Based Segmentation*, *Segmentation of Color Images*, *Edge Detection*, *Methods based on Fuzzy Set Theory*; JÄHNE⁶⁵ zeigt die Methoden der *pixelorientierten*, der *kantenbasierten*, der *regionenorientierten Verfahren* und der *modellbasierten Segmentierung* in allen Einzelheiten. MAINEL und NEUBERT⁶⁶

Möglichkeiten für GIS-Anwender und Planer.; In: 5. Symposium „Computergestützte Raumplanung“ - CORP 2000; www.corp.at

⁶² Schiewe, J. u. Tufte, L. (2002): Potenzial regionen-basierter Verfahren für die integrative Auswertung von GIS- und Fernerkundungsdaten.; In: Thomas Blaschke, Th. (Hg.) Fernerkundung und GIS, Neue Sensoren - innovative Methoden. Karlsruhe, 2002, S. 42-52.

⁶³ Haralick, R. M. u. Shapiro, L. G. (1985): Survey. Image Segmentation Techniques.; In: Computer Vision, Graphics and Image Processing 29, S. 100-132.

⁶⁴ Pal, N. R. u. Pal, S. K (1993): A Review on Image Segmentation Techniques. In: Pattern Recognition. 26. Jg., Nr. 9, S. 1277-1294.

⁶⁵ Jähne, B. (2005): Digitale Bildverarbeitung., 6. Aufl., Berlin u. Heidelberg.

⁶⁶ Meinel, G. u. Neubert, M. (2003): Bildsegmentierer - Ansätze, vergleichende Untersuchungsmethodik und erste Ergebnisse. In: Seyfert, E. (Hg.): Auf dem Weg zu operationellen Prozessketten in Photogrammetrie, Fernerkundung und Geoinformation. Vorträge 23. Wissenschaftlich-technische Jahrestagung der DGPF. Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation Bd. 12, Münster, S. 187-194.

sowie NEUBERT, HEROLD und MEINEL⁶⁷ untersuchen Bildsegmentierungssoftware, darunter auch eCognition, und vergleichen deren Segmentierungsqualität.

⁶⁷ Neubert, M. et al. (2006): Evaluation of Remote Sensing Image Segmentation Quality - Further Results and Concepts. In: Proceedings of the 1st International Conference on Object-based Image Analysis (OBIA) Salzburg

4.3. Datengetriebene Verfahren

Um einen allgemeinen Überblick über Bildsegmentierungsverfahren zu geben, kann man sie laut eCognition User Guide⁶⁸ in zwei Gruppen unterteilen und zwar in wissensbasierte (*top-down*) sowie datengetriebene (*bottom-up*) Verfahren.

Bei den *wissensbasierten Ansätzen*, die auch als modellgetriebene Verfahren bezeichnet werden, kennt der Benutzer die zu extrahierenden Objekte und formuliert ein Modell für sie. Dieses Modell wird in der Regel durch eine Datenbank realisiert. Das System sucht nach den besten Lösungen und Methoden, um die Objekte zu extrahieren. Segmentiert werden nur die zum Modell passenden Objekte. Jedes generierte Segment impliziert also eine semantische Bedeutung. Dieser Ansatz wurde im Rahmen der vorliegenden Arbeit nicht weiter untersucht, da das Untersuchungs-

gebiet zu heterogen für ein entsprechendes Modell ist.

Bei den *datengetriebenen Ansätzen* wird dagegen das ganze Bild anhand bestimmter statistischer Methoden und Parameter segmentiert. Die resultierenden Segmente haben keine semantische Bedeutung und müssen nicht unbedingt den Objekten der realen Welt entsprechen. Sie sind bloße Pixelcluster und werden deswegen häufig auch als Bildobjektprimitive bezeichnet. Der Benutzer entscheidet, welche Objekte der realen Welt segmentiert werden sollen.

Im Folgenden werden ausgewählte Verfahren der *bottom-up* Methode erläutert, da mithilfe dieses Verfahrens Segmente erzeugt werden, die Basiselemente für die wissensbasierte Klassifikation bilden. Diese Verfahren unterteilen sich in kanten- und regionenbasierte Verfahren.

4.3.1. Kantenbasierte Verfahren

Kantenbasierte Verfahren nutzen zur Segmentbildung so genannte Diskontinuitäten im Bild, also starke Änderungen des Grauwertes oder einen Höhengsprung im Oberflächenmodell. Solche Kanten werden als Segmentgrenzen definiert. Es werden Netzwerke von Grenzen aufgebaut, indem die Kanten in Gruppen zusammengefasst werden. Es

existieren unterschiedliche Kantendetektoren; PAL u. PAL⁶⁹ geben eine detailreiche Darstellung der *Roberts Gradient*, *Sobel Gradient*, *Prewitt Gradient* und *Laplace Operator*. Der wesentliche Nachteil der kantenbasierten Verfahren ist in der Tatsache

⁶⁸ Baatz, M. et al. (2004): eCognition User Guide. Definiens Imaging GmbH, München, S. 65 ff.

⁶⁹ Pal, N. R. u. Pal, S. K. (1993): A Review on Image Segmentation Techniques. In: Pattern Recognition. 26. Jg., Nr. 9, S. 1277-1294.

zu sehen, dass sich die Segmentkanten sehr leicht durch Rauschen der Werte beeinflussen lassen. Bei stark texturierten Bildfragmenten, wie Waldflächen, werden sehr viele Untersegmentierungen produziert, während gleichzeitig die anthropogenen Objekte relativ korrekt segmentiert werden. Infolgedessen ist die Homogenität, also die gleiche Größe der Segmente, bei kantenbasierten Verfahren nicht garantiert.⁷⁰

Das *Watershed-Segmentierungsverfahren* beruht ebenfalls auf der Ausnutzung von Diskontinuitäten im Bild. Unter Verwendung eines Gradientenoperators wird ein Kantenbild erstellt.

Dieses repräsentiert die topographische Oberfläche. Hohe Pixelwerte geben Bergkämme, niedrige Pixelwerte Täler wieder. Um jedes lokale Minimum des jeweiligen Geländereiefs wird ein Wasser-einzugsgebiet als die Menge aller Pixel definiert, die sich entlang eines negativen Gradienten in Abflussrichtung befinden. Diese Pixelmengen, Wasserbecken und Wasserscheiden stellen die gesuchten Segmente dar. Größe und Glättung der entstehenden Segmente werden durch das angewandte Ähnlichkeitskriterium bestimmt.⁷¹

⁷⁰ Schiewe, J. (2002): Segmentation of High-resolution Remotely Sensed Data – Concepts, Applications and Problems. In: Proceedings of Symposium on Geospatial Theory, Processing and Applications. Ottawa

⁷¹ Vincent, L. u. Soille, P. (1991): Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulations. In: PAMI., 13. Jg., Nr. 6, S. 583-598.

4.3.2. Regionenbasierte Verfahren

Regionenbasierte Verfahren generieren Segmente in Form von homogenen Flächen. Die Homogenität kann auf Grundlage von unterschiedlichen Merkmalen, wie den Grauwerten oder Textur, definiert werden. Die gängigsten regionenbasierten Segmentierungsmethoden sind *Region-Merging*, *Region-Splitting* und *Region-Growing*.

Region-Splitting ist eine wissensbasierte Segmentierungsmethode (*top-down*), die mit der gesamten Szene als Initialsegment beginnt und diese dann in immer kleinere Segmente zerlegt. Die Methode wird hier nicht weiter beachtet, weil die Erstellung einer Wissensdatenbank als zu zeitaufwendig angesehen wurde.

Das *Region-Merging*-Verfahren, das überwiegend im Softwarepaket *Definiens Professional* Anwendung findet, wird im nächsten Kapitel (1.1.) detailliert dargestellt.

Das *Region-Growing* ist ein weiteres regionenbasiertes Verfahren. Der Algorithmus, der auch Flächenwachstums-Algorithmus genannt wird, beginnt mit so genannten Saatzenen (seed pixels) als Anfangssegmenten und lässt diese mit den benachbarten Segmenten zusammenwachsen, sofern sie zu keinem anderen Segment gehören. Die Segmente werden dabei auf Ähnlichkeit, also auf ihre Homogenität geprüft. Erst wenn die Homogenität ausreichend ist und ein vordefinierter Schwellenwert nicht überschritten wird, wird das Pixel in das Segment integriert. Die Prüfung

⁷² Schiewe, J. (2002)

der Zugehörigkeit erfolgt über Ähnlichkeiten. Ein neuer Pixel wird entweder mit dem unmittelbar benachbarten Pixel des Nachbarsegments oder mit dem Mittelwert aller Pixel des Nachbarsegments verglichen. Wenn es keine Pixel mehr gibt, die diese Ähnlichkeitskriterien erfüllen und in das Segment integriert werden können, wird ein neues Segment mit einer neuen Saatzelle begonnen. Die Anzahl der Segmente und deren Größe sind von dem Verfahren abhängig, nach dem die Saatzellen gewählt werden und von den Schwellenwerten, die das Ähnlichkeitskriterium bestimmen.⁷³ Als einen Nachteil dieser Methode nennen BAATZ und SCHÄPE⁷⁴ ein fehlendes Kriterium, das den Abbruch des Flächenwachstums steuern könnte.

Ob zwei Nachbarobjekte miteinander verschmelzen, wird anhand des „*degree of fitting*“, des Übereinstimmungsgrades, entschieden. Der Verschmelzungsalgorithmus kann folgende Einschränkungen in Bezug auf die Nachbarschaft und die Ähnlichkeit aneinander grenzender Objekte betrachten:⁷⁵

⁷³ Blaschke, T. (2000)

⁷⁴ Baatz, M. u., Schäpe, A. (2000): Multiresolution Segmentation: An Optimization Approach for High Quality Multi-scale Image Segmentation.; In: *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT Symposium Salzburg 2000*, Heidelberg, 2000, S. 12-23.

⁷⁵ Schiewe, J. (2002)

-
- Im einfachsten Falle wird ein Element A (ein Segment oder Pixel) mit dem Nachbarelement B verschmolzen, wenn die Homogenität den definierten Schwellenwert nicht überschreitet („fitting“).
 - Ein Element A kann im Gegensatz dazu nur das Element B akzeptieren, das dem Homogenitätskriterium am besten entspricht („best fitting“). „Best“ bedeutet in diesem Fall, dass das Verschmelzen den kleinsten Wert für den „degree of fitting“ aufweist (im Vergleich zu allen möglichen Verschmelzungsprozessen mit anderen benachbarten Objekten), also eine möglichst kleine Veränderung der Homogenität bzw. Heterogenität innerhalb des neu gebildeten Segmentes verursacht.
 - Ein Element C wird nur mit dem Element A verschmelzen (welches genügend homogen
 - zu B ist), wenn sowohl B und C als auch A und C ähnlich genug sind („local mutual best fitting“). Dieses Verfahren hilft, das am besten zueinander passende Paar von Objekten in der lokalen Umgebung des Elementes A zu finden.
 - „Global mutual best fitting“ verbindet diejenigen Nachbarobjekte aus der ganzen Szene, die das Homogenitätskriterium am besten erfüllen.

Wachsen alle Segmente gleichzeitig, wird die Voraussetzung erfüllt, dass alle gebildeten Segmente eine möglichst ähnliche Größe haben sollen. Dies kann unter zwei Bedingungen aufrechterhalten werden: Erstens, jedes Pixel bzw. Segment wird nur einmal pro Segmentierungszyklus behandelt; zweitens, nachfolgende Verschmelzungen werden (in der Gesamt-szenenperspektive) so weit wie möglich voneinander entfernt verteilt. Die letzte Bedingung wird als *distributed treatment order of image objects* bezeichnet.

4.4. Multiskalare Segmentierung in Definiens Professional

Die bisherigen Segmentierungsmethoden konnten die Anforderungen der Firma Definiens Imaging nicht vollständig erfüllen. Daher wurde ein neues Verfahren entwickelt. Hauptziel war eine Generierung von Bildobjektprimitiven, die eine qualitativ gute Extraktion der Objekte der realen Welt in jeder gewählten Auflösung gewährleisten und damit eine Basis für nachfolgende objekt-orientierte Klassifikation und Prozessierung

darstellen. Im Wesentlichen wurden sechs Anforderungen an die Segmentierungsmethode gestellt, um zu zufrieden stellenden Ergebnissen zu gelangen:⁷⁶

- Das Segmentierungsverfahren soll möglichst homogene Segmente generieren, um die Bildobjekte optimal darstellen und separieren zu können.

⁷⁶ Baatz, M. u., Schäpe, A. (2000)

- Die durchschnittliche Größe der Segmente soll an den gewünschten Maßstab anpassbar sein, um den unterschiedlichen Strukturen, die in unterschiedlichen Maßstäben abgebildet werden, Rechnung zu tragen.
- Die resultierenden Objekte sollen eine ähnliche Größe haben, um deren gegenseitige Vergleichbarkeit in Bezug auf deren Attribute wie Textur, Form oder Tonwert zu gewährleisten.
- Die Segmentierungsprozedur soll auf unterschiedliche Datensätze und unterschiedliche Kombinationen anwendbar und für verschiedenste Problemstellungen durchführbar sein.
- Die Segmentierungsergebnisse sollen reproduzierbar sein.
- Die Segmentierungsprozedur soll auch bei großen Datensätzen in einer möglichst kurzen Zeit durchführbar sein.

Definiens Imaging entwickelte die so genannte *multiresolution segmentation*, nachfolgend multiskalare Segmentierung genannt, die in dem Softwarepaket *Definiens Professional* enthalten ist.

Die multiskalare Segmentierung ist eine *bottom-up-, Region-Merging-Methode*, die mit einzelnen Pixeln als Startobjekten beginnt. In nachfolgenden Schritten wird jeweils ein Paar von Bildobjekten zu immer größeren Objekten zusammengefasst. Der Vorgang des Zusammenfassens

wird als *merging* bezeichnet.⁷⁷ In jeder Verschmelzung wird jedes Segment nur einmal berücksichtigt. Diese Vorgehensweise wird angewandt, um eine möglichst ähnliche Größe der Segmente sicherzustellen.⁷⁸ Das Softwarepaket *Definiens Professional* nutzt den *local mutual best fitting*-Verschmelzungsalgorithmus. Zwar liefert auch der *global mutual best fitting*-Algorithmus gute Ergebnisse, hat aber einen entscheidenden Nachteil: Er benutzt nicht die Voraussetzungen des *distributed treatment order* und lässt Segmente erst in Regionen entstehen, die eine niedrige spektrale Heterogenität aufweisen. Das führt zu einem ungleichen Wachstum der Segmente und zu einer Unausgewogenheit zwischen Regionen mit hoher und niedriger spektraler Heterogenität. *local mutual best fitting* in Verbindung mit *distributed treatment order* führt die homogensten Verschmelzungen der Segmente durch, auch wenn die Bilddaten durch relativ hohe spektrale Heterogenität gekennzeichnet sind. Dieser kombinierte Algorithmus lässt auch in heterogenen Szenen die

⁷⁷ Leukert, K. (2002): Untersuchungen zur Segmentierung von Satellitenbilddaten für die Extraktion von GIS-Objekten. In: Seyfert, E. (Hg.): Vorträge 22. Wissenschaftlich-Technische Jahrestagung der DGPF 2002 in Neubrandenburg. Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung Bd. 11, Stuttgart, S. 237-244.

⁷⁸ Weidner, U. u. Lemp, D. (2005): Objektorientierte Klassifizierung. In: Bähr, H.-P. u. Vögtle, T. (Hg.), *Digitale Bildverarbeitung. Anwendungen in Photogrammetrie, Fernerkundung und GIS*, Stuttgart, S. 106-122.

Segmente simultan wachsen und garantiert dadurch eine symmetrische Behandlung aller Bereiche; gleichzeitig minimalisiert er die Heterogenität der resultierenden Segmente.⁷⁹ Diese Pixelverschmelzungen unterliegen

einer Optimierungsprozedur, die die durchschnittliche Heterogenität der Objekte minimiert. Hierbei wird die Heterogenität der Objekte mit deren Größe gewichtet.

4.4.1. Homogenitätskriterium *scale parameter*

Das Definiens Professional Softwarepaket nutzt den *local mutual best fitting*-Verschmelzungs-Algorithmus. In jedem Durchlauf wird das Paar derjenigen Nachbarobjekte verschmolzen, die das kleinste Wachstum der Heterogenität innerhalb des Objektes verursachen werden. Wenn dieses Heterogenitätswachstum einen bestimmten Schwellenwert überschreitet, wird der Verschmelzungsprozess angehalten.⁸⁰ Der Benutzer kann also das Segmentierungsverfahren beeinflussen, indem er den Heterogenitätsschwellenwert, den so genannten *object scale parameter*, bestimmt. Werden größere Veränderungen der Heterogenität zugelassen (großer *scale parameter*), so finden mehrere Verschmelzungen statt, und es entstehen auch größere Objekte. Der Heterogenitätsschwellenwert steht indirekt in Beziehung zur Größe der resultierenden Segmente, da er die

maximal zugelassene Heterogenität des Objektes definiert. Bei einem gegebenen *scale parameter* ist die Homogenität bzw. Heterogenität direkt linear abhängig von der Objektgröße. Dementsprechend sind die resultierenden Objekte bei heterogenen Daten als kleiner bei homogenen Daten.⁸¹

Beim Verschmelzen von Nachbarobjekten werden bei dieser Segmentierungsmethode auch geometrische Eigenschaften der Objekte berücksichtigt. Das Heterogenitätskriterium in *Definiens Professional* besteht aus zwei Komponenten, der Farb- und der Formhomogenität. Im Folgenden werden die Berechnungsmethoden für die beiden Homogenitätskriterien dargestellt, wobei alle Formeln dem User Guide für eCognition⁸² entnommen wurden.

⁷⁹ Baatz, M. u. Schäpe, A. (2000): Multiresolution Segmentation: An Optimization Approach for High Quality Multi-scale Image Segmentation. In: Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT Symposium Salzburg 2000. (Salzburg), S. 12-23.

⁸⁰ Baatz, M. et al. (2004): eCognition User Guide. München, S. 76ff.

⁸¹ Baatz, M. u. Schäpe, A. (2000): Multiresolution Segmentation: An Optimization Approach for High Quality Multi-scale Image Segmentation. In: Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT Symposium Salzburg 2000, Heidelberg, S. 12-23.

⁸² Baatz, M. et al. (2004)

4.4.2. Homogenitätskriterium Farbe

Die Farbhomogenität wird in *Definiens Professional* mit der Summe der Standardabweichungen der spektralen

Werte der einzelnen eingehenden Layer c gewichtet mit der Masse des jeweiligen *layer*:

$$h_{color} = \sum_c \omega_c \cdot \sigma_c$$

Eine Segmentierung, die ausschließlich auf dem Farbhomogenitätskriterium basiert, wird zum Teil in ausgefransten und unregelmäßig großen Segmenten resultieren, siehe Abb. 33. Dieser Effekt ist bei stark texturierten oder rauschenden Datensätzen, wie etwa Radardaten, verstärkt zu beobachten.

Um die Abweichung von kompakten und glatten Segmentformen so gering wie möglich zu halten, ist es empfehlenswert, beim Segmentierungsprozess das Kriterium für Farbhomogenität mit dem für Formhomogenität sinnvoll zu verbinden.

4.4.3. Homogenitätskriterium Form

Es gibt zwei Möglichkeiten, die Formhomogenität des Objektes zu beeinflussen und zwar über Kompaktheit und Glattheit.

Die Kompaktheit (*Compactness*) eines Segments wird folgendermaßen definiert, wobei l die Randlänge und n die Anzahl der Pixel des Objekts ist:

$$h_{compact} = \frac{l}{\sqrt{n}}$$

Die Glattheit (*smoothness*) eines Segmentes wird folgendermaßen definiert, wobei l die kürzeste

Randlänge eines rasterparallelen umschreibenden Rechtecks (*bounding box*) ist:

$$h_{smooth} = \frac{l}{b}$$

Die Kriterien für die Glattheit und Kompaktheit werden durch den Benutzer gewichtet und zur Form-

homogenität zusammengefasst, wobei die Gewichtungswerte in dem Intervall $0 \leq \omega \leq 1$ liegen:

$$h_{shape} = \omega_{compact} \cdot h_{compact} + (1 - \omega_{compact}) \cdot h_{smooth}$$

In Abb. 33 sind zwei identische Bildausschnitte zum Vergleich dargestellt. Das linke Bild wurde ausschließlich unter Verwendung des Farbhomogenitätskriteriums, das rechte Bild unter Verwendung beider Homogenitätskriterien für Farbe und Form segmentiert. Es ist deutlich zu

erkennen, dass das sinnvolle Verbinden von beiden Kriterien in kompakteren und glatteren Objekten resultiert. Je nach Daten, die man zur Segmentierung einbeziehen möchte, kann man beide Kriterien entsprechend gewichten und so die gewünschte Form der Segmente erzeugen.





Abb. 33 Segmentierung der HRSC-AX Daten mit dem *scale parameter* 50: unter ausschließlicher Verwendung des Farbhomogenitätskriteriums (links) und unter Verwendung von beiden Homogenitätskriterien für Farbe und Form (rechts).

In mehreren Aufsätzen wurde untersucht und beschrieben, welchen Einfluss die Heterogenitätskriterien und deren unterschiedliche Gewichtung auf die Segmentierungsergebnisse haben. LEUKERT⁸³ untersucht anhand der künstlich erstellten Bilder geeignete Segmentierungsparameter und deren Einfluss auf die Extraktionsgüte unterschiedlicher Objekte; HOFFMANN⁸⁴ sowie ZHANG

und MAXWELL⁸⁵ referieren Ergebnisse ähnlicher Untersuchungen, die aber anhand der natürlichen Bilder durchgeführt wurden. FRAUMAN und WOLFF⁸⁶ untersuchen den Einfluss unterschiedlicher *scale parameter* auf die Anzahl der gebildeten Segmente, um einen Schwellenwert für zufriedenstellende Segmentierungen in Abhängigkeit von Objektart und geometrischer Auflösung zu definieren.

⁸³ Leukert, K. (2002): Untersuchungen zur Segmentierung von Satellitenbilddaten für die Extraktion von GIS-Objekten. In: Seyfert, E. (Hrsg.): Vorträge 22. Wissenschaftlich-Technische Jahrestagung der DGPF, 2002 in Neubrandenburg. Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung Bd. 11, S. 237-244.

⁸⁴ Hoffmann, A. (2001): Neue Ansätze zur Auswertung und Klassifizierung von sehr hoch auflösenden Daten: Methoden der Segmentierung, der hierarchischen Segmentierung und der per-Parcel-Methode mit Daten der Digitalen Kamera HRSC-A und ihre Anwendbarkeit für die

Aktualisierung topographischer Karten. Diss., Humboldt-Univ. Berlin.

⁸⁵ Zhang, Y. u. Maxwell, T. (2006): A Fuzzy Logic Approach to Supervised Segmentation for Object-Oriented Classification. In: Proceedings of ASPRS 2006 Annual Conference, Reno, Nevada.

⁸⁶ Frauman, E. u. Wolff, E. (2006): Segmentation of Very High Spatial Resolution Satellite Images in Urban Areas for Segments-based classification. In: Proceedings of the 1st International Conference on Object-based Image Analysis (OBIA), Salzburg, 2006.

4.4.4. Overall-Fusionswert

Während des Segmentierungsprozesses wird ein so genannter Overall-Fusionswert für die mögliche Verschmelzung der benachbarten

Segmente berechnet und mit dem durch den Benutzer gewählten *scale parameter* verglichen. Dieser Fusionswert wird folgendermaßen definiert:

$$f = \omega \cdot h_{color} + (1 - \omega) \cdot h_{shape}$$

Die Standardabweichungen werden mit der Segmentgröße n gewichtet:

$$h_{color} = \sum_c \omega_c \left(n_{Merge} \cdot \sigma_c^{Merge} - \left(n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2} \right) \right)$$

Die Änderung in der Heterogenität des Segments nach der Verschmelzung wird durch die Differenz zwischen den Werten der Heterogenitäten vor und

nach der Fusionierung berechnet. Dies resultiert in folgenden Formeln für Kompaktheit und Glattheit:

$$h_{smooth} = n_{Merge} \cdot \frac{l_{Merge}}{b_{Merge}} - \left(n_{obj1} \cdot \frac{l_{obj1}}{b_{obj1}} + n_{obj2} \cdot \frac{l_{obj2}}{b_{obj2}} \right)$$

$$h_{compact} = n_{Merge} \cdot \frac{l_{Merge}}{\sqrt{n_{Merge}}} - \left(n_{obj1} \cdot \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} \cdot \frac{l_{obj2}}{\sqrt{n_{obj2}}} \right)$$

Aufgrund der Festlegung des *scale parameter* und aller Homogenitätskriterien wird das Erscheinungsbild der Segmente durch den Benutzer bestimmt, so dass genau diejenigen Bildobjektprimitive erzeugt

werden, die für die jeweilige Fragestellung benötigt werden. In Abb. 34 wird das Verhältnis zwischen allen Parametern der Segmentierung dargestellt.

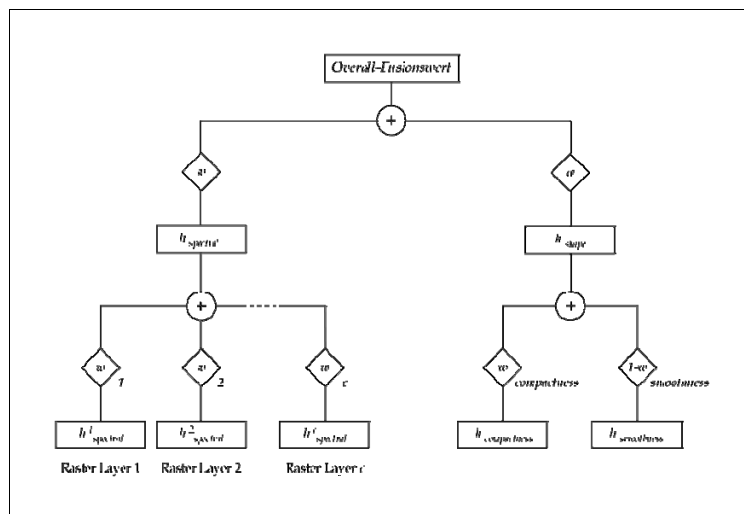


Abb. 34 Verhältnis zwischen den Segmentierungsparametern bei „Multiresolution Segmentation“ in Definiens Professional 5.0 87

Es können gleichzeitig mehrere Rasterdaten, auch mit unterschiedlicher radiometrischer und geometrischer Auflösung und Ausdehnung, sowie Vektordaten in Form von thematischen Layern in die Segmentierung und Klassifizierung einbezogen werden. Dadurch ist es möglich, unterschiedliche Daten zur Segmentierung auf verschiedenen hierarchisch angeordneten Ebenen zu verwenden. Der oberste, größte *level* kann beispielsweise anhand von thematischen Vektordaten, die Stadtbezirke darstellen, segmentiert werden, wohingegen auf allen niedrigeren Ebenen anhand der spektralen Informationen die Objektprimitive geschaffen werden. Es ist auch möglich, bei der Segmentierung ein digitales Oberflächenmodell einzubeziehen, um eine bessere Extraktion der Gebäude oder deren Trennung von spektral ähnlichen Strassen zu erzielen. In der multiskalaren Segmentierung besteht zudem die Möglichkeit, die einzelnen Informationen unterschiedlich zu gewichten; nicht alle Datensätze müssen an der Segmentierung teilnehmen. Layer, die für die Segmentierung nicht notwendig sind, sollten deaktiviert werden. Bei Daten mit unterschiedlicher radiometrischer Auflösung hat der Layer mit der höheren Bittiefe den größeren Einfluss auf die endgültige Form der Segmente.⁸⁸ Soll der Layer mit niedrigerer Bittiefe

ausschlaggebend für die Segmentierung sein, muss hier eine stärkere Gewichtung gewählt werden.

Die multiskalare Segmentierung ermöglicht in Anlehnung an die menschliche Perzeption die Segmentierung von Bilddaten auf mehreren Maßstabsebenen. Die menschliche Wahrnehmung tendiert nämlich im ersten Schritt dazu, die Bilder als grobe homogene Bereiche zu generalisieren und sie erst im nachfolgenden Schritt zu charakterisieren und in kleinere bedeutungsvolle Teile zu unterteilen.⁸⁹ Weil es in der Natur kaum harte Grenzen gibt und auch selten ein echtes Kontinuum vorkommt, ist es schwer, bedeutungsvolle Objekte eindeutig in einem Maßstab zu definieren.⁹⁰ Die multiskalare Segmentierung der Bilddaten ermöglicht es, die realen Zusammenhänge wiederzugeben.

Eine sehr feine Segmentierung mit kleinem *scale parameter* kann auf einer unteren Ebene angelegt werden. Basierend auf dieser Ebene können dann immer gröbere Ebenen mit jeweils größerem *scale parameter* generiert werden.

Die Fläche, die durch ein Objekt repräsentiert wird, kann man als die Summe aller Flächen seiner Sub-

⁸⁷ Aus: Zhang, Y. u. Maxwell, T. (2006): A fuzzy logic approach to supervised segmentation for object-oriented classification, in Proceedings of ASPRS Annual conference, Reno, Nevada

⁸⁸ Baatz, M. et al. (2004).

⁸⁹ Gorte, B. G. H. (1998): Probabilistic segmentation of remotely sensed images, PhD thesis, ITC, publication n. 63, Enschede.

⁹⁰ Blaschke, T. u. Strobl, J. (2001): What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. In: GIS 6/01, S. 12-17.

Objekte definieren, so dass die Grenzen der Super-Objekte genau mit denen der Sub-Objekte übereinstimmen. Dieses Verfahren ist notwendig, um ein hierarchisches Netzwerk von Segmenten aufbauen zu können, das die Bildinformationen in unterschiedlichen Objektgrößen repräsentiert. Wie in Abb. 35 dargestellt, sind die einzelnen Maßstabebenen vernetzt, so dass jedes Segment nicht nur die Eigenschaften seiner Nachbarobjekte kennt, sondern auch die der Sub-Objekte und Super-Objekte.⁹¹ Auch nach der Segmentierung bleibt die Information der Einzelpixel erhalten. Somit kann man die Relationen zwischen den Objekten und deren lokalem Kontext zur Bestimmung der Charakteristika in den Klassen ausnutzen. Jedes Segment besitzt auch in unklassifiziertem Zustand eigene spektrale Werte samt Statistik, wie Mittelwert und Standardabweichung, Texturmaße für einzelne Kanäle oder geometrische Merkmale, wie etwa Größe, Länge, Kompaktheit, Rundheit und eigenen Umfang. Hinzu kommen eine Vielzahl weiterer Eigenschaften, die für die Klassifizierungsregeln verwendet werden können.

Die Segmentierung des Bildes in mehreren Maßstabsebenen hat sich als sehr sinnvoll und unabdingbar erwiesen, da man bei Betrachtung nur einer hierarchischen Ebene lediglich einzelne Bereiche als optimal segmentiert und andere als zu stark generalisiert oder zu fein gegliedert wahrnimmt.⁹² Das Ziel einer erfolgreichen Klassifikation sind Bildobjekte, die dem Bildinhalt angepasst sind und die realen Objekte wahrheitsgemäß wiedergeben. Die multiskalare Segmentierung schafft die Möglichkeit, die Grenzen zwischen den Objekten anhand von unterschiedlichen Datensätzen - von regionalen zu globalen und von mittel zu hoch auflösenden Daten - genau zu reproduzieren und erlaubt ferner eine Überwachung der Genauigkeit der extrahierten Objekte durch einfaches Umschalten zwischen den einzelnen Ebenen. Die Möglichkeiten der Einstellung und Zusammensetzung aller Parameter für die Bildsegmentierung sind groß.

⁹¹ Baatz, M. et al. (2004).

⁹² Lang, S. (2002): Zur Anwendung des Holarchiekonzepts bei der Generierung regionalisierter Segmentierungsebenen in höchst-auflösenden Daten. In: Blaschke, T. (Hg.): Fernerkundung und GIS. Neue Sensoren - innovative Methoden, Heidelberg, S. 24-32.

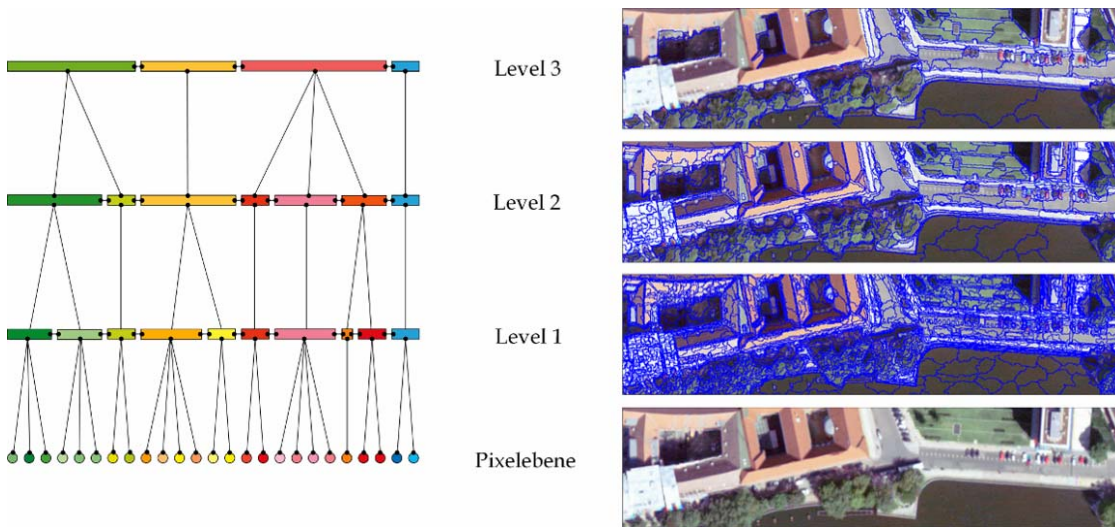


Abb. 35 Hierarchisches Netzwerk der Bildobjekte in abstrakter Darstellung (links) und in Pixel View (rechts)

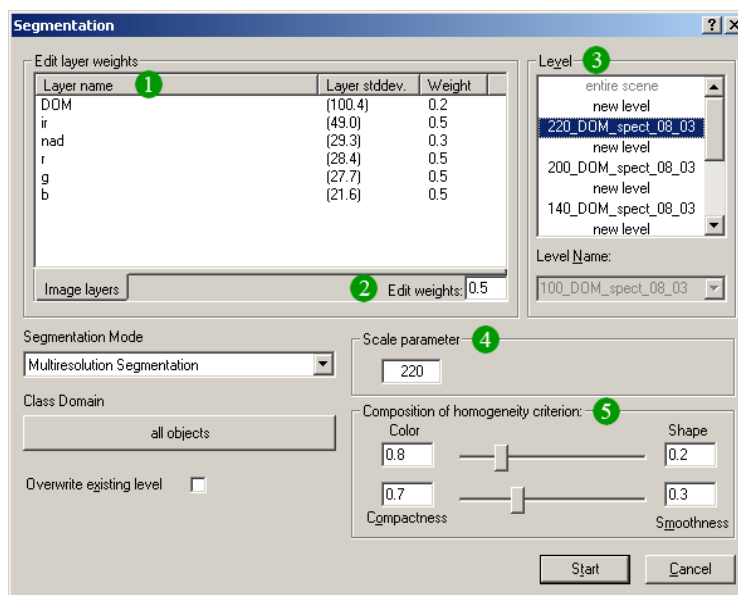


Abb. 36 Die Segmentierung in Definiens Professional 5.0. Einstellung der Segmentierungsparameter für Multiresolution Segmentation

Zusammenfassend können in der multiskalaren Segmentierung mehrere und beliebige Datensätze **1** einbezogen und gewichtet werden **2**. Es können Bildobjekte auf mehreren Ebenen (*level*) **3** generiert werden. Die Größe und Anzahl der Segmente kann durch den Heterogenitäts-Schwellen-

wert (*scale parameter*) **4** beeinflusst werden. Schließlich wird das Erscheinungsbild der Segmente durch das entsprechende Gewichten der Homogenitätskriterien **5** für Farbe und Form (*color/shape*) und für Kompaktheit und Glattheit (*compactness/smoothness*) ermittelt.

Um zu optimalen und zufriedenstellenden Segmentierungsergebnissen zu gelangen, sollten folgende Grundregeln beachtet werden:⁹³

- Es sollte ein *scale parameter* gewählt werden, der keine übersegmentierten Objekte liefert.
- Zur Analyse spektraler Daten sollte ein möglichst großer

Wert für das Farbkriterium verwendet werden.

- Um Objekte mit glatten Kanten zu erhalten, sollte ein relativ großer Wert für *smoothness* eingehalten werden.
- Ein hoher Wert für *compactness* erzeugt eher kompakte Objekte.

4.5. Weitere Segmentierungsverfahren mit Definiens Developer

Außer der in dieser Arbeit verwendeten Multiskalaren Segmentierung bietet Definiens Professional mehrere andere Verfahren zur Zerlegung des Bildes in Bildobjekte, die eine Grundvoraussetzung der objekt-basierten Bildanalyse sind. Der Umfang der Segmentierungsmethoden ist groß: von den einfachsten wie

Chessboard Segmentation bis zu sehr komplexen und komplizierten, wie Multiresolution oder Contrast Filter Segmentation. In den nachfolgenden Kapiteln werden diese Segmentierungsmethoden nach Definiens Developer Reference Book⁹⁴ im Detail dargestellt

4.5.1. Chessboard Segmentation

Die Chessboard Segmentation ist das einfachste Segmentierungsverfahren in dieser Software. Es unterteilt das ganze Bild oder einen bestimmten Bildbereich, die so genannte *image object domain* (z.B. nur die Objekte, die einer vordefinierten Klasse gehören), in quadratische Segmente gleicher

Größe. Die Netzlinien sind nach der linken und oberen Bildgrenze ausgerichtet. Die Größe der Quadrate ist vom Bearbeiter in Pixelzahl zu bestimmen.

⁹³ Baatz, M. et al. (2004).

⁹⁴ Definiens AG (2006): Definiens Developer Reference Book, München, S. 8ff

4.5.2. Quad Tree Based Segmentation

Diese Segmentierungsmethode zerlegt das ganze Bild oder *image object domain* in quadratische Blöcke unterschiedlicher Größe. Das *quad tree* Netz besteht aus Quadraten, deren Seiten aus einer Potenz der Zahl 2 berechnet werden.

Die Netzlinien sind nach der linken und oberen Bildgrenze ausgerichtet. Die Größe der quadratischen Blöcke wird durch die eingestellten Homogenitätsparametern bestimmt. Jeder Block muss erstens die maximal mögliche Größe annehmen und

zweitens die eingestellten Homogenitätskriterien erfüllen. Die Homogenitätskriterien bestehen aus zwei Parametern: *mode* und *scale*. Der Parameter *mode* definiert die maximal zugelassene Farbdifferenz innerhalb der Blöcke – dieser Wert muss kleiner als der *scale*-Wert sein – und die Form der Super-Objekte. Der Parameter *scale* definiert die maximal zugelassene Farbdifferenz jedes gewählten *layer* innerhalb der Blöcke.

4.5.3. Spectral Difference Segmentation

Bei der *Spectral Difference Segmentation* werden benachbarte Segmente nach deren Grauwertintensitäten miteinander verschmolzen. Der einzige durch den Operateur einzustellende Wert ist der *Maximum Spectral Difference*, ein Schwellenwert für die Grauwertdifferenz, den die angrenzenden Objekte nicht überschreiten dürfen, wenn sie

verschmolzen werden sollen. Dieser Algorithmus wurde für die Optimierung der schon bestehenden multiskalaren Segmentierung entwickelt. Es werden die spektral ähnlichen Objekte fusioniert. Das Vorhandensein eines Segmentierungslevels ist demzufolge eine Voraussetzung.

4.5.4. Contrast Filter Segmentation

Die Contrast Filter Segmentierung ist ein komplexes fortgeschrittenes pixelbasiertes Verfahren zur Generierung der Objekte von hoher Qualität. Definiens Developer stellt zwei Contrast Filter Algorithmen zur Verfügung: „v5“ und „v6“. Da sich diese in nur einem Parameter unterscheiden, wird nur der erste in Detail dargestellt. Der Contrast Filter Segmentation Algorithmus benutzt Pixelfilter, um die potenziellen Objekte anhand der Kontraste und Gradienten zu definieren. Die resultierende Pixelklassifizierung wird als

thematischer Layer gespeichert. Jedes Pixel wird einer der folgenden Klassen zugewiesen: *no object*, *object in first layer*, *object in second layer*, *object in both layers*, *ignored by threshold*. Anschließend wird der thematische Layer mittels Chessboard Segmentation in die Objekte umgewandelt. Der Operateur muss folgende Parameter einstellen:

- Scale: bestimmt die Größe der Filtermatrix, zur Verfügung stehen 3x3, 5x5, 11x11, 15x15, 21x21 Matrizen. Man kann

- gleichzeitig mehrere Scale untersuchen lassen;
- Value: definiert die Kontrast-suche für jeden Scale. Zur Auswahl stehen die Werte: „0“ - deaktiviert die Kontrast-filterung, „1“ - benutzt Kontrastfilter um die Objekte aufzusuchen, die heller sind als deren Umgebung, „-1“ - benutzt Kontrastfilter, um die Objekte aufzusuchen, die dunkler sind als deren Umgebung;
- Gradient: Benutzt den zusätz-lichen minimalen Gradient für die Objekte;
- Lower Threshold: Pixel mit einem kleineren Grauwert unterhalb dieses Schwellenwert werden der Klasse *ignored by threshold* zugewiesen;
- Upper Threshold: Pixels mit einem größeren Grauwert oberhalb dieses Schwellenwerts werden der Klasse *ignored by threshold* zugewiesen.

4.6. Evaluierung der Segmentierungsergebnisse

Es gibt keine feste Regel, nach der die Parameter der multiskalaren Segmentierung eingestellt werden. Ihre Bestimmung hängt sehr stark von den verwendeten Daten und von der Zielsetzung der Analyse ab. Dass die Wahl der Segmentierungsparameter ausschließlich dem Benutzer über-lassen bleibt, ermöglicht einerseits eine flexible Durchführung der Segment-

ierung in Abhängigkeit von der jeweiligen Fragestellung, andererseits wird die Segmentierung durch die Vielzahl der bestehenden Einstellungs-möglichkeiten und die in dem Softwarepaket fehlende Methode zur Evaluierung der Segmentierungsgüte erschwert. Zur Bestimmung der optimalen Parameter müssen verschie-dene Einstellungen getestet werden.

4.6.1. Visuelle Evaluierung

Obwohl die Evaluierung der Segmentierungsergebnisse der Fernerkundungsdaten für den Erfolg der nachfolgenden Klassifikation und somit für die ganze Bildanalyse ausschlaggebend ist, steht im Definiens Professional-Softwarepaket bisher keine automatisierte Standardmethode hierfür zur Verfügung. Meistens erfolgt eine visuelle, qualitative Beurteilung des segmentierten Bildes. Demzufolge dürfen von einer Segmentierung keine fehlerfreien Ergebnisse erwartet werden.

SCHIEWE führt hierzu folgendes aus: *„...the most reliable evaluation method is still a visual interpretation that has to consider the exact geometrical position of*

*the segment borders as well as the membership of one and only one object class to a single region.“*⁹⁵

HARALICK und SHAPIRO beschreiben die Qualitätsanforderungen an Segmentierungsergebnisse wie folgt: *„Die gebildeten Objekte sollen bezüglich deren bestimmten Charakteristika, wie Grauwerte oder Textur, einheitlich und homogen sein. Die Nachbarobjekte sollen sich dementsprechend in Bezug auf diese Homogenitätskriterien, eindeutig*

⁹⁵ Schiewe, J. (2002)

unterscheiden. Die gebildeten Segmente sollen einfache Formen und keine inneren Löcher aufweisen. Die Kanten der Objekte sollen möglichst glatt und nicht ausgefranst sein. Schließlich sollen die Segmentgrenzen mit den Grenzen der realen Objekte exakt übereinstimmen.“⁹⁶

Fehlerhafte Segmentierungen

In diesem Abschnitt werden mögliche Probleme und Fehler in Segmentierungsprozessen gezeigt. Grundsätzlich gilt, dass mit steigender Heterogenität der Daten auch die Probleme bei der Erzeugung einer sinnvollen Segmentierung zunehmen.

Untersegmentierung meint eine Segmentierung, bei der die entstehenden Segmente zu groß sind (s. Abb. 39). Die Objekte oder Objektprimitive können deshalb die Objekte der realen Welt nicht repräsentieren und sind daher nicht mehr sinnvoll. Befinden sich etwa Teile eines Flusses und Teile des Ufers in einem Segment, ist eine spätere Trennung nur über manuelles Schneiden der Polygone möglich. Damit ist eine automatisierte

Klassifizierung ausgeschlossen. Durch eine *Übersegmentierung* werden die entstehenden Segmente zu klein und geben die Objekte nicht vollständig wieder (s. Abb. 38). Ein Objekt besteht dann aus mehreren Segmenten. Für die Klassifizierung muss deshalb eine größere Anzahl von Klassen erzeugt und verwaltet werden. Eine Übersegmentierung ist meist weniger problematisch zu beseitigen, da sich durch geeignete Strategien die zu kleinen Segmente zu größeren verschmelzen lassen. Oft werden hierarchische Verfahren wie der „*watershed*“-Algorithmus angewendet. Daten mit einer Farbtiefe von 16 bit haben sich als empfindlicher für eine Übersegmentierung erwiesen als 8-bit-Daten, da hier noch mehr feine Unterschiede vorhanden sind und die Heterogenität der Daten deutlich größer ist.

⁹⁶ Haralick, R. M. u., Shapiro, L. G. (1985): Survey. Image Segmentation Techniques. In: Computer Vision, Graphics and Image Processing. Nr. 29, S. 100-132.




Abb. 37 Untersegmentiertes Gebäude, scale parameter 120 (links), dasselbe korrekt segmentierte Gebäude, scale parameter 90 (rechts)




Abb. 38 Übersegmentiertes Gebäude, scale parameter 90 (links), dasselbe korrekt segmentierte Gebäude, scale parameter 120 (rechts)

Grundsätzlich können auch falsche Segmente entstehen, die entweder über- oder untersegmentiert sind und

kein Objekt der realen Welt sinnvoll repräsentieren, wie in Abb. 39 zu sehen ist.




Abb. 39 Falsche Segmentierung: Innenhof mit Schattenseite des Satteldaches zusammengefasst (links), Gebäude mit nebenan stehender Laterne zusammengefasst (rechts)

4.6.2. Automatisierte Evaluierung

Automatisierte Algorithmen zur Überprüfung von Segmentierungen stehen in der Fernerkundung nicht zur Verfügung. Zwar gibt es einige statistische Verfahren zur Evaluierung der Ergebnisse, diese beziehen sich aber bis jetzt auf einfache Photos, wie z.B. bei LIU und YANG⁹⁷ oder HARALICK und SHAPIRO⁹⁸, oder auf synthetische Bilder, wie z.B. bei ZHANG⁹⁹. Eine Übertragbarkeit auf hochauflösende Fernerkundungsdaten ist daher nur bedingt möglich. Im Folgenden wird zumindest ein Ansatz auf Tauglichkeit zur Analyse von Segmentierungen getestet.

Einen breiten Überblick über die automatisierten Beurteilungsmethoden der Segmentierungsergebnisse gibt ZHANG¹⁰⁰. Er gliedert die bestehenden Evaluierungsverfahren in zwei Hauptkategorien: analytische und empirische. Die *analytische Methode* untersucht direkt die Segmentierungsalgorithmen, indem sie deren Prinzipien, Anforderungen, Nutzbarkeit, Komplexität, etc. berücksichtigt. Die *empirische Methode* bewertet hingegen die Qualität der Segmentierung selbst. Sie wird weiter in „*empirical goodness*“ und „*empirical*

discrepancy“ unterteilt. Bei *Goodness-Methoden* werden qualitative Maße, wie z.B. *Intra-region Uniformity*, *Contrast* und *Shape*, für das segmentierte Bild ermittelt. Die meisten dieser Maße werden nach der menschlichen Intuition bezüglich „idealer“ Segmentierung bestimmt. Für die empirischen *Discrepancy-Methoden* ist im Gegensatz dazu ein Referenzbild notwendig. Hier werden die Unterschiede zwischen dem segmentierten Bild und dem Referenzbild mittels unterschiedlicher Diskrepanzparameter berechnet. Gängige Maße hierfür sind: die Prozentzahl und die relative Position der falsch segmentierten Pixel, die Anzahl der Objekte im Bild sowie die Merkmalswerte von segmentierten Objekten, z.B. deren geometrische Eigenschaften. Die *Goodness-Methoden* werden bei YANG et al.¹⁰¹ als unüberwachte und die *Discrepancy-Methoden* als überwachte Evaluierungsmethoden bezeichnet.

Die von LIU und YANG¹⁰² 1994 entwickelte Evaluierungsfunktion gehört zu den empirischen Methoden und erlaubt es, sowohl natürliche als auch synthetische Bilder zu beurteilen. Der große Vorteil besteht vor allem in der Fähigkeit, lokale und globale Segmentierungsergebnisse zu evaluieren.

⁹⁷ Liu, J. u., Yang, Y. (1994): Multiresolution Color Image Segmentation. In: PAMI, 16. Jg., Nr. 7, S. 689-701.

⁹⁸ Haralick, R. M. u., Shapiro, L. G. (1985)

⁹⁹ Zhang, Y. J. (1996): A Survey on Evaluation Methods for Image Segmentation.; In: Pattern Recognition, 29. Jg., Nr. 8, S. 1335-1346.

¹⁰⁰ Zhang, Y. J. (1996)

¹⁰¹ Yang, L. et al., (1995): A Supervised Approach to the Evaluation of Image Segmentation Methods. In: Proceedings of CAIP 1995. Lecture Notes in Computer Science. Bd. 970, Berlin, S. 759-765.

¹⁰² Liu, J. u., Yang, Y. (1994)

Die Homogenität der Segmente mit ihren Merkmalen und die Nachbarsegmente, die sich hinsichtlich dieser Merkmale unterscheiden sollen, werden berücksichtigt. Diese Funktion enthält dementsprechend neben der Größe der Segmente oder deren Fläche in Pixel auch deren Anzahl sowie den so genannten „color error“ der Segmente.

Eine Übertragbarkeit der genannten Evaluierungsfunktionen auf VHSR-Fernerkundungsdaten wurde bis jetzt nicht untersucht. Die Erstellung einer Referenzsegmentierung wäre hier wegen des großen Aufwandes nur bedingt durchführbar. Außerdem erschweren die sehr große Heterogenität und Komplexität des Untersuchungsgebietes sowie die hohe Bittiefe der Daten die Generierung von Segmenten, die die Form der Objekte der realen Welt zufrieden stellend widerspiegeln könnten. Sehr oft kommt es vor, dass die gewünschten Objekte - besonders die anthropogenen - aus mehreren Segmenten bestehen. Diese können nachträglich auf die höheren Segmentierungsebenen als eine semantische Klassengruppe (*groups* im jeweiligen Klassenhierarchiefenster) übertragen, klassifiziert und erst dann verschmolzen werden. Solche zusammengefassten Segmente entstehen aber auf Basis der

Klassifizierung und sind dementsprechend klassifikationsabhängig.

Die hier dargestellten quantitativen Evaluierungsmaße, die im Unterschied zu den qualitativen kein Referenzbild benötigen, liefern nur einen globalen Wert für die Gesamtsegmentierung. Die unterschiedlichen Objektklassen, die sich im Erscheinungsbild erheblich unterscheiden können, werden somit nicht berücksichtigt.

Die genannten Schwachpunkte der Evaluierungsmethoden führten zu der Entscheidung, die Segmentierungsergebnisse des Untersuchungsgebietes visuell anhand der in Kap. 6.6 genannten Beurteilungskriterien zu bewerten. Außerdem wird auch das Endergebnis der Bildanalyse evaluiert. Diese Vorgehensweise hat sich als effizient erwiesen, da die erhaltenen Klassifizierungsergebnisse eine Aussage über die Richtigkeit der Segmentierung liefern können (s. Kap. 1.1.1. und Kap. 6.6.2.). Allgemein lässt sich sagen, dass weitere Evaluierungsmöglichkeiten denkbar sind. Verschiedene Ansätze zur Gebäudeextraktion aus *LIDAR*-Daten und anderen Modellen sind heute bekannt und werden mehr oder weniger erfolgreich eingesetzt. Die so bestimmten Gebäude ließen sich dann als Referenz nutzen. Geeignete Referenzen müssen in der Regel manuell erstellt werden.