



## Objekt-orientierte Klassifizierung von LiDAR Daten und Orthofotos zur Vegetations- und Gebäudekartierung

Michael Pregesbauer, St. Pölten; Christian Weise, München

### Kurzfassung

Im vorliegenden Beitrag wird die objektorientierte Klassifikation von Gebäuden und Vegetation auf Basis von hochauflösenden Orthofotos und Airborne Laserscanning Daten vorgestellt. Durch die Kombination von Bilddaten mit Höhendaten konnte die Klassifizierungswahrscheinlichkeit gegenüber der ausschließlichen Verwendung von Bilddaten signifikant gesteigert werden.

**Schlüsselwörter:** Landnutzungskartierung, Automatische Bildklassifizierung, eCognition

### Abstract

This paper is introducing the object oriented classification of buildings and vegetation based on digital Orthofotos and Airborne Laserscanning data. The reliability of classification compared to the exclusively utilization of orthofotos was improved due to the usage of image and elevation data.

**Keywords:** Land Use Mapping, Automatic Image Classification, eCognition

### 1. Einleitung

Die Kartierung digitaler Orthofotos in die Objektklassen Vegetation/Wald und Gebäude wird in der Regel interaktiv durchgeführt. Dies führt dazu, dass Wald- und Baulandsbilanzen nur in generalisierter Form durchgeführt werden können und dass derartige Erhebungen in adäquater Genauigkeit nur unter hohen Zeit- und Kostenaufwand möglich sind.

Der Einsatz von objektorientierter Klassifikation erlaubt grundsätzlich die automatische Kartierung beider Objektarten. Die Klassifizierungsgenauigkeit ist jedoch unter ausschließlicher Verwendung von Orthofotos nicht zufriedenstellend da durch die spektralen Eigenschaften der unterschiedlichen Bodenbedeckungen keine eindeutige Zuweisung zu den Objektklassen möglich ist. Die Stabilität der Klassifikation lässt sich jedoch durch die Verwendung von ALS (Airborne Laserscanning) Daten erheblich steigern.

Der nachfolgende Beitrag stellt ein objektorientiertes Verfahren vor, mit dem hochauflösende Orthofotos in Kombination mit ALS Daten in die Objektklassen Vegetation/Wald und Gebäude klassifiziert werden können. Die Orthofotos werden dazu zunächst segmentiert und in der nachfolgenden Klassifizierung aufgrund von Klassenbeschreibungen den entsprechenden Klassen zugewiesen.

Die Ergebnisse und deren Genauigkeit werden sowohl qualitativ als auch hinsichtlich der Durchführbarkeit in der Praxis bewertet.

### 2. Datengrundlage

Für die objektorientierte Analyse standen Orthofotos (Flugjahr Sommer 2007) mit den Kanälen Rot, Grün, Blau und nahes Infrarot mit einer Ground Sampling Distance von 12,5 bzw. 15 cm zur Verfügung. Ergänzt wurden die Eingangsdaten durch ein normalisiertes Oberflächenmodell (nDOM) mit einer Gitterweite von 1 Meter (Flugjahr Herbst/Winter 2007/08). Für die Datenprozessierung wurden als Bearbeitungskachel die Größe eines DKM Blattes mit dem Blattschnitt 1:2000 (1,25x1 km) verwendet.

Entscheidend für die Stabilität der Klassifikation ist die Wahl des oder der Testgebiete, auf Basis deren die Regelwerke entwickelt werden. Die gegenständlichen Testgebiete zur Regelwerkentwicklung weisen neben geschlossener Bebauung auch zersiedelte Strukturen sowie große Waldflächen auf.

Um nach Fertigstellung des Regelwerkes die Performance zu testen wurde ein 200 km<sup>2</sup> Bereich im Süd-Westen von Niederösterreich automatisch klassifiziert.

### 3. Objekt-orientierte Klassifizierung

Die objektorientierte Klassifikation beruht im Gegensatz zur pixelbasierten Klassifikation, über Parameter wie Form und Farbe, auf definierten homogenen Pixelgruppen. Diese Segmente können dann mit Ihren objektbezogenen oder semantischen Eigenschaften mit Nachbarsegmenten in Beziehung gesetzt und Objektarten zugewiesen werden. Somit teilt sich die objekto-

rientierte Klassifikation zunächst in eine Segmentierung und in die anschließende Klassifizierung auf, die auch iterativ wiederholt werden kann.

Der in diesem Beitrag vorgestellte Ansatz wurde unter Verwendung der Cognition Network Language von der Definiens AG in der Version 7.0.9 realisiert.

### 3.1. Segmentierung

Um ein Maximum an Performance zu erreichen ist es notwendig die Bearbeitungskachel in Teile mit einer maximalen Größe von 2000x2000 Pixel zu unterteilen (Prinzip Tiling & Stitching, siehe Abbildung 1). Eine solche Vorgehensweise trägt dazu bei die Rechenzeiten erheblich zu verkürzen, da jede Kachel separat im Rastergrid analysiert wird. Die Gesamtszene wird daher zunächst in

1. Teilmengen mit der Größe von 2000x2000 Pixel zerlegt (Tiling),
2. im Anschluss werden inertielle Segmente erzeugt,
3. die nach Zusammenfügen der Teilmengen (stitching) zu Objektprimitiven vereinigt werden
4. und abschließend klassifiziert werden.

Die Inertialen Segmente werden mit einer *Quadtree Based Segmentation* erzeugt [1]. Dabei werden Quadrate mit maximaler Größe erzeugt die das Homogenitätskriterium von Farbe und Maßstabsparameter erfüllen. Da im ersten Schritt auf den Teilmengen gearbeitet wird, sind auch die auftretenden Randeffekte zu berücksichtigen, sodass weiter auch der Rand der Teilmenge als Objektklasse klassifiziert wird. Für den rechenintensiven Schritt der inertialen Segmentierung stellt das Arbeiten mit Teilmengen sicher, dass die Eingangsdaten nahezu beliebig groß sein können.

Um die eigentlichen Objekt Primitive zu erzeugen werden die einzelnen Teilmengen wieder zu Gesamtszene zusammengefügt. Auf der Gesamtszene werden die Randeffekte der Grenzen der Teilmengen entfernt.

Die Objekt Primitive werden unter Verwendung von *Parent Process Objects* (PPO) [1] erzeugt. Dazu wird ein Segment als Stammsegment definiert und alle anderen Segmente als Kandidaten behandelt. Die Kandidaten werden selbst zu einem Stammsegment, wenn sie die Klasseneigenschaften des Stammsegmentes erfüllen. Der

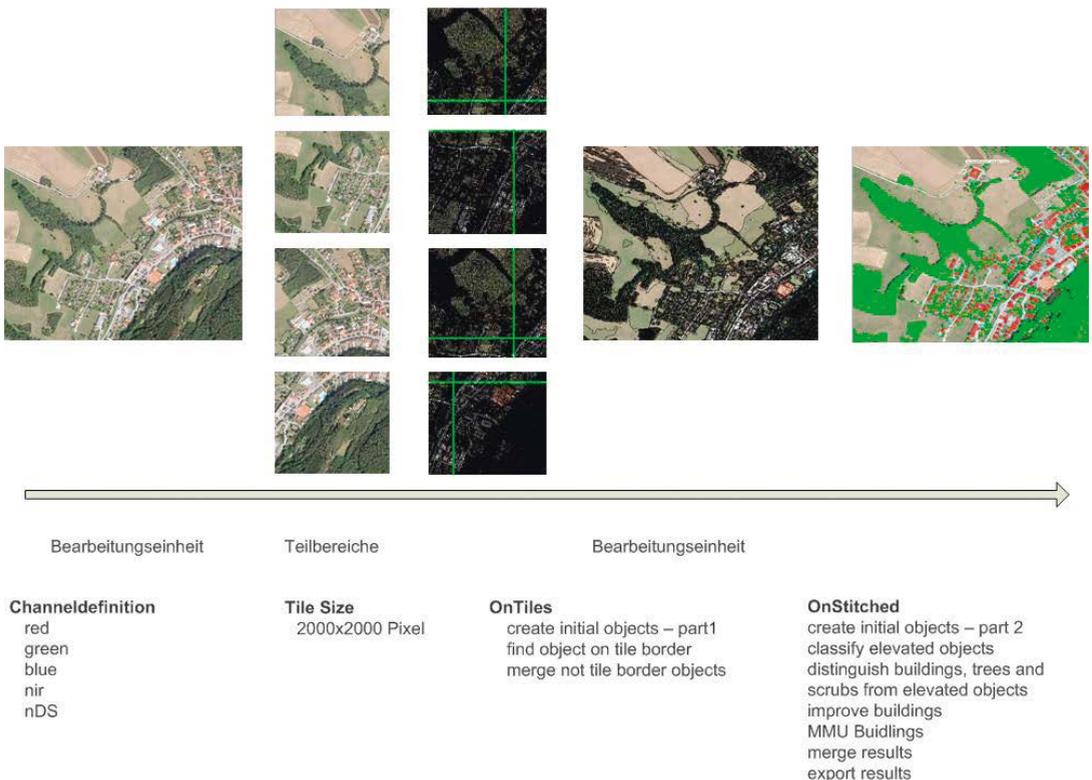


Abb. 1: Datenbearbeitung nach dem Prinzip des „Tiling & Stitching“

Prozess der *Image Object Fusion* wird solange in einer Schleife wiederholt, bis kein Kandidat die Klasseigenschaften der Stammsegmente erfüllt. So werden Objektprimitive erzeugt, die der Form nach weitestgehend den zu klassifizierenden Objekten entsprechen (Abbildung 2).

In vorliegenden Fall muss der Klassenkandidat die nachfolgenden Eigenschaften erfüllen um mit einem Stammsegment vereinigt zu werden:

- Die absoluten Differenzen zwischen Stammsegment und dem Kandidaten aller Spektralkanäle müssen kleiner als der definierte spektrale Schwellenwert sein.
- Die absolute Höhendifferenz zum Stammsegment muss kleiner sein als der definierte Schwellenwert.
- Das Stammsegment muss an den Kandidaten zumindest zu 10% angrenzen

Durch die Verwendung von *Fuzzy Functions* [1] wurde gewährleistet dass der Kandidat mit dem Stammsegment auch dann vereinigt wird, wenn die Klassenvoraussetzung zu einem definierten Prozentsatz erreicht ist.

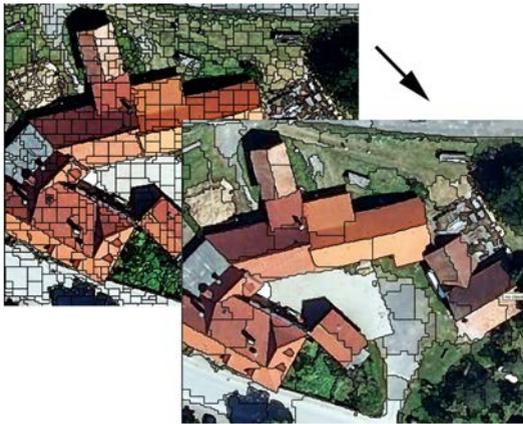


Abb. 2: links: Quadtree Segmentation, rechts: Segmentierung mit PPOs

### 3.2 Klassifizierung

Die unter 3.1. erzeugten Segmente bilden die Grundlage für die nachfolgende Klassifizierung. Im Idealfall wird jedes zu klassifizierende Objekt durch ein oder mehrere Segmente abgebildet, wobei keine Mischsegmente, d.h. Segmente die zwei oder mehrere Klassen abbilden auftreten sollten.

Aufgrund der Verwendung von hochauflösenden Bild- und Höhendaten konnte für die beiden Klassen *Vegetation/Wald* und *Gebäude* mit je-

weils nur zwei Klasseigenschaften das Auslangen gefunden werden:

Klasse	Eigenschaft
Vegetation/ Wald	Durchschnittliche Höhe
	Normalized Differenced Vegetation Index (NDVI)
Gebäude	Durchschnittliche Höhe
	Normalized Differenced Vegetation Index

Tab. 1: Klasseigenschaften für die Objektklassen *Gebäude* und *Vegetation/Wald*

Bei der Klassifizierung durchlaufen die Segmente nachfolgende Logik:

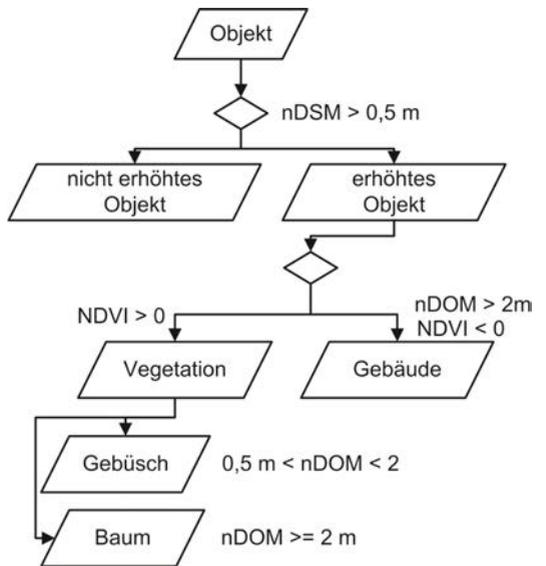
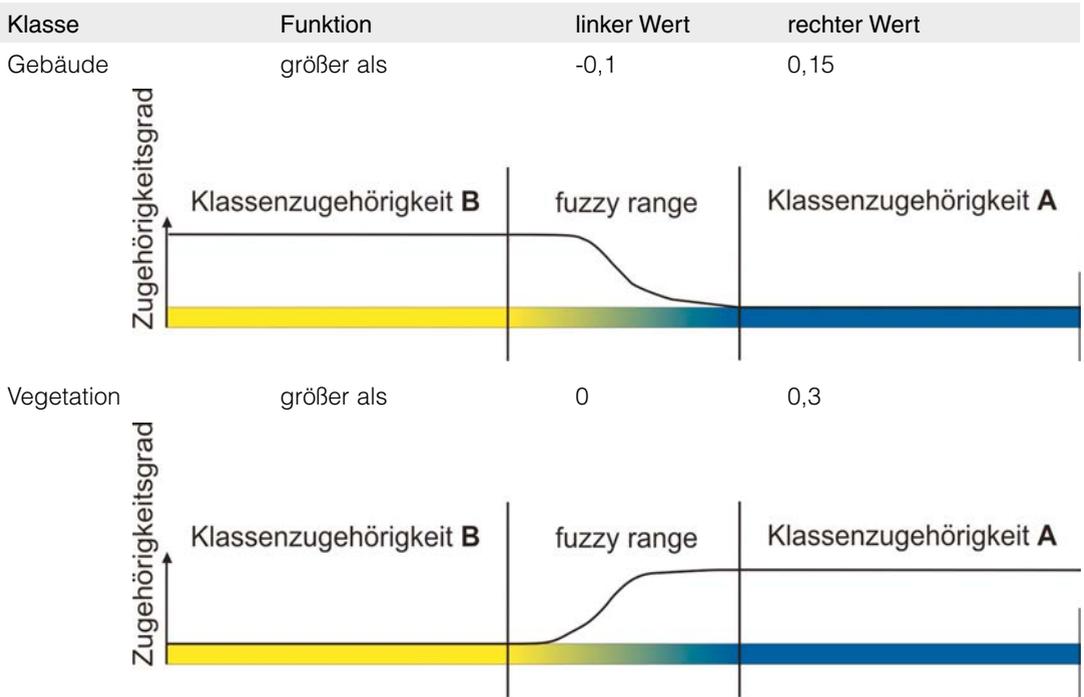


Abb. 3: Klassifizierungslogik für die Objektklassen *Gebäude* und *Vegetation/Wald*

Objekt die größer als 0,5 Meter sind werden zunächst einer temporären Klasse zugewiesen. Alle Objekte unter 0,5 Meter bleiben als nicht erhöhte Objekte als nicht klassifiziert erhalten. Unter den erhöhten Objekten wird aufgrund des NDVI in die Klassen *Gebäude* und *Vegetation* geteilt. Ein harter Schwellenwert für die Klassenbeschreibung hat sich jedoch als nicht geeignet erweisen, sodass die Klasseigenschaft NDVI mit einer *Fuzzy Function* beschrieben wurde. Dabei wird das Segment jener Klasse zugeordnet, zu welcher es die stärkste Zugehörigkeit aufweist. Für die Klassen wurden folgende Zugehörigkeitsfunktionen gewählt:



Tab. 2: Beschreibung der Klassenzugehörigkeit mit einer Fuzzy Function

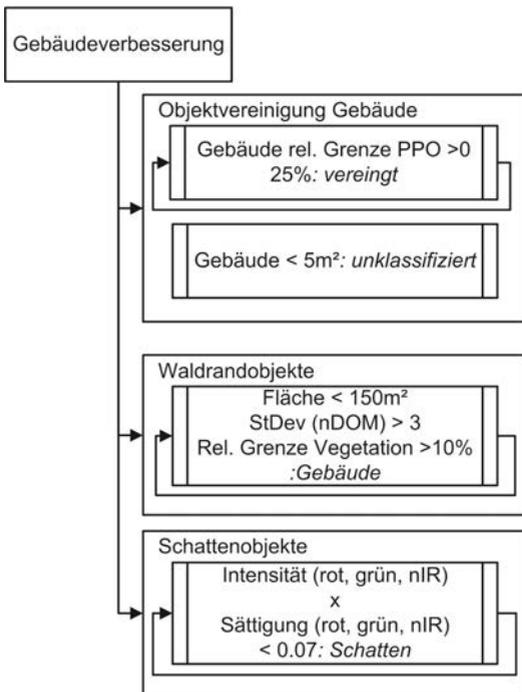


Abb. 4: Verbesserung der Objektklasse Gebäude

Die so erhaltene Klassifizierung bildet eine erste gute Näherung ab, die dann in der Folge verbessert wurde. Im ersten Klassifikationsschritt wurde die Klassenbeschreibung für die Gebäude zu optimistisch gewählt, sodass auch Vegetationsobjekte als Gebäude erkannt wurden. Vornehmlich handelt es sich um Objekte an den Waldrändern – dabei handelt es sich um Schattenbereiche, die annähernd dieselben spektralen Eigenschaften aufweisen wie dunkle Hausdächer. Diese Fehlklassifikationen können durch die Merkmale der Objektfläche, Standardabweichung des normalisierten Oberflächenmodells sowie der relative Grenze zu Vegetationsobjekten beschrieben werden (Abbildung 4).

In den Schattenbereichen von Gebäuden kommt es ebenfalls zu Fehlklassifikationen, da die spektralen Eigenschaften des Schatten jene der Vegetation nahe kommen und weiters ansteigenden Flanken der Gebäude im nDOM dazu beitragen, dass das Klassenkriterium für erhöhte Objekte erfüllt ist. Durch die Einführung eines Schattenindex aus dem Produkt von Intensität aus dem rot, grün und nIR Kanal sowie der

Sättigung aus dem rot, grün und nIR Kanal können die Objekt reklassifiziert werden.

#### 4. Diskussion der Ergebnisse des durchgeführten Praxistests

Wie bereits unter 3.1. gezeigt ist die Qualität der Segmentierung der Ausgangsdaten für den Erfolg der anschließenden Klassifizierung entscheidend. Die Segmentierung wurde unter ausschließlicher Verwendung der Bilddaten durchgeführt. Eine Zuweisung zu den Objektklassen ist jedoch mit der notwendigen Stabilität nur durch die Verwendung des normalisierten Oberflächenmodells möglich. Die Kombination von Bild- und Höhendaten ermöglicht es, Klasseneigenschaften zu definieren, die ausschließlich auf spektralen und geometrischen Merkmalen passieren und somit die notwendige Stabilität und Übertragbarkeit des Regelsatzes gewährleisten.

Der entwickelte Regelsatz wurde im Zuge eines Performance Tests auf ein Gebiet mit einer Fläche von rund 200 km<sup>2</sup> angewandt. Eine quantitative Analyse der Ergebnisse hat gezeigt, dass bei den Gebäudeflächen 94,3% und bei den Waldflächen 96,1% der Flächen korrekt klassifiziert wurden. Entscheidend für die Erreichung der hohen Klassifizierungszuverlässigkeit ist, dass die Eingangsdaten möglichst zeitnahe erfasst wurden.

#### Literaturverzeichnis

[1] *Definiens AG (2009):* Definiens Developer 7 User Guide, Munich, 2009-08-17

#### Anschrift der Autoren

Dipl. Ing. Michael Pregesbauer, Amt d. Niederösterreichischen Landesregierung, Abteilung Vermessung und Geoinformation, Landhausplatz 1, 3109 St. Pölten.

E-mail: Michael.Pregesbauer@noel.gv.at

Dipl. Geogr. Christian Weise, Definiens AG, Trappnetreustrasse 1, D-80339 München.

E-mail: cweise@definiens.com

vgi



**Diamond**  
AIRBORNE SENSING

„Planung – Durchführung – Auswertung“  
**Laserscanning & Photogrammetrie**  
für Klein- und Großaufträge

Precision from Above 

Tel: +43 (0) 2622/26700-1184  
www.diamond-sensing.com info@diamond-sensing.com