

Masterarbeit

**Automatische Detektion von Gebäuden mit
objekt-orientierter Klassifikation anhand von
Luftbildern**

Betreuer:

Prof. Dr.-Ing. Manfred Ehlers

Dipl.-Umweltwiss. Sascha Klonus

Vorgelegt von:

Robert Daniels

Matrikelnummer: xxxxxx

Osnabrück, den 19.06.2012

Studiengang Geoinformatik

Institut für Geoinformatik und Fernerkundung

Fachbereich 6: Mathematik / Informatik

Universität Osnabrück

Inhaltsverzeichnis

1 Einleitung	5
2 Grundlagen	6
2.1 Bilddaten	6
2.2 Klassifikationsverfahren	7
2.2.1 Unüberwachte Klassifikation	7
2.2.2 Überwachte Klassifikation	8
2.2.3 Objekt-orientierte Klassifikation	8
2.3 Segmentierung	9
2.3.1 Chessboard Segmentation	9
2.3.2 Quadtree-Based Segmentation	10
2.3.3 Contrast Split Segmentation	11
2.3.4 Multiresolution Segmentation	13
2.4 Objekt-orientierte Klassifikation	15
2.4.1 Samples	15
2.4.2 Feature Space	16
2.4.3 Process Tree	24
3 Anwendung	25
3.1 DOP1 (2008)	25
3.1.1 Segmentierung und Klassifikation	25
3.1.2 Ergebnis	36
3.1.3 Genauigkeit	39
3.2 DOP2 (2002)	40
3.2.1 Segmentierung und Klassifikation	40
3.2.2 Ergebnis	44
3.2.3 Genauigkeit	46
3.3 Vergleich und Analyse	47
3.3.1 Vorgehensweise	47
3.3.2 Ergebnis und Bewertung	49
4 Zusammenfassung und Fazit	52
5 Literatur	54
Anhang	55

Abbildungsverzeichnis

Abb. 1 Unterschiede in der Auflösung, Helligkeit, Kontrast und Schattenwurf von DOP1 und DOP26	
Abb. 2 Beispiel: Zweidimensionaler Merkmalsraum (Quelle: Lexikon der Fernerkundung, 2009)	7
Abb. 3 Clusterzentroide und Zuordnung der Pixel im zweidimensionalen Merkmalsraum (Quelle: Remote Sensing and Image Interpretation (Lillesand et al. 2008), S. 556).....	8
Abb. 4 Chessboard Segmentation angewandt auf DOP1, Object Size 20.	9
Abb. 5 Quadtree Segmentation angewandt auf DOP1. Color Mode, Scale 60.....	10
Abb. 6 Contrast Split Segmentation angewandt auf DOP1, Darstellung ohne (links) und mit (rechts) Hell-/Dunkel-Klassen. Chessboard Tile Size 10, 0-255, Step 5.	12
Abb. 7 Scale Parameter von 10 (links) bzw. 150 (rechts) bei gleichen Werten für Shape (0.1) und Compactness (0.9).....	14
Abb. 8 Shape Parameter von 0,1 (links) und 0,9 (rechts) bei gleichen Werten für Scale (50) und Compactness (0,9).....	14
Abb. 9 Compactness Parameter von 0,1 (links) und 0,9 (rechts) bei gleichen Werten für Scale (50) und Shape (0,5)	14
Abb. 10 Beispiel für die Auswahl von Samples für die Klassen Gebäude (rot), Vegetation (grün) und Straße (gelb).....	15
Abb. 11 Feature-Space in eCognition - Mean.....	16
Abb. 12 Feature-Space in eCognition – Pixel-based.....	16
Abb. 13 Innere Grenze eines Bildobjekts (Quelle: Reference Book, S. 234).....	17
Abb. 14 Äußere Grenze eines Bildobjekts (Quelle: Reference Book, S. 235).....	18
Abb. 15 Der umgebende Bereich (Bounding Box) eines Bildobjekts $B_v(d)$ mit einer Distanz von einem Pixel. Innerhalb befinden sich die Pixel (P_v), die das Objekt bilden. (Quelle: Reference Book, S. 236).....	18
Abb. 16 Feature-Space in eCognition – To Scene	19
Abb. 17 Feature-Space in eCognition – Hue, Saturation, Intensity	19
Abb. 18 Feature-Space in eCognition – Geometry	19
Abb. 19 Feature-Space in eCognition - Extent.....	20
Abb. 20 Links: Kantenlänge eines Bildobjekts v , oder zwischen zwei Objekte v und u . Rechts: Innere und äußere Kantenlänge eines Objekts. (Quelle: Reference Book S. 252).....	20
Abb. 21 Feature-Space in eCognition - Shape	21
Abb. 22 Kanten-Index eines Bildobjekts v . l_v und w_v sind die Länge und Breite des Bildobjekts, b_v ist die Kantenlänge des Bildobjekts. (Quelle: Reference Guide, S. 260).....	22
Abb. 23 Rectangular fit eines Bildobjekts. (Quelle: Reference Book, S. 269).....	22
Abb. 24 Feature-Space in eCognition – Relations to neighbour objects.....	23
Abb. 25 Beispiel für einen Process Tree	24
Abb. 26 Erste Segmentierung von DOP1. Parameter: Scale 10, Shape 0,9, Compactness 0,1	26
Abb. 27 Ergebnis der ersten Klassifikation von DOP1	27
Abb. 28 Neue, grobe Segmentierung mit den Parametern: Scale 150, Shape 0,4 und Compactness 0,1.....	28
Abb. 29 Klassifikation von Schatten (schwarz) und Nicht-Schatten (weiß).....	29
Abb. 30 Ausgewählte Features im Feature Space und Klassifikationsergebnis von „Grüne Vegetation“ (grün) und „Gebäude und Brache“ (gelb).....	30
Abb. 31 Ergebnis der ersten schrittweisen Klassifikation. Alle Klassen außer Gebäude und Schatten auf grün gesetzt	31
Abb. 32 Ergebnis vor (links) und nach (rechts) der feinen Segmentierung im Bereich der Gebäude (rot).....	32
Abb. 33 Feature Space Auswahl für die erste Gebäudeklassifikation nach der zweiten Segmentierung	33

Abb. 34 Ausgewählter Feature Space zur Unterteilung von verschatteten Gebäude und verschatteter Vegetation	34
Abb. 35 Veränderung durch den letzten Klassifikationsschritt basierend auf Farbwerten	35
Abb. 36 Klassenhierarchie für die Klassifikation von DOP1	36
Abb. 37 Segmentierung (links) und Klassifikationsergebnis (rechts) von DOP1	37
Abb. 38 Vergleich der groben Segmentierung von DOP1 (2008, links) und DOP2 (2002, rechts) ...	40
Abb. 39 Vergleich der groben Segmentierung (oben) mit der ersten (unten links) und zweiten (unten rechts) feinen Segmentierung von DOP2	41
Abb. 40 Klassenhierarchie von DOP2	43
Abb. 41 Segmentierung (links) und Klassifikationsergebnis (rechts) von DOP2. Legende siehe Abbildung 40.	44
Abb. 42 Ergebnis des Vergleichs mit den Referenzen DOP1 (oben links) und DOP2 (oben rechts) und den Ergebnissen der Vergleiche DOP1-DOP2 (unten links) und DOP2-DOP1 (unten rechts).	49
Abb. 43 Manueller Vergleich durch Layerdarstellung. Rötliche Farbtöne gehören zu DOP1, grünliche zu DOP2. Gelbliche Farbtöne zeigen Flächen, die in beiden Ergebnissen vorhanden sind.	50

Tabellenverzeichnis

Tab. 1 Auswertung des Ergebnisses von DOP1	39
Tab. 2 Auswertung des Ergebnisses von DOP2	46

1 Einleitung

Diese Arbeit stellt das Verfahren der objekt-orientierten Klassifikation ausführlich vor und wendet es auf zwei digitale Orthophotos an. Diese zeigen jeweils dasselbe Gebiet im Norden Deutschlands in den Jahren 2002 und 2008. Es handelt sich dabei um eine ländliche Gegend mit viel landwirtschaftlicher Nutzung und kleineren Siedlungsgebieten. Als Ziel sollen die Gebäude zuverlässig und genau erkannt werden und die Möglichkeiten der Erkennung von neuen Gebäuden untersucht werden. Hierbei soll sich zeigen, ob die objekt-orientierte Klassifikation Vorteile gegenüber anderen Verfahren bietet und ob bessere Ergebnisse möglich sind. Auch soll sich zeigen, ob diese Ergebnisse und Erfahrungen auf andere Bilddaten übertragbar sind und damit zukünftige Untersuchungen erleichtert und schneller durchführbar werden.

Die objekt-orientierte Klassifikation ist ein vergleichsweise neuer Ansatz im Gegensatz zu den verbreiteten, pixelbasierten Methoden innerhalb der überwachten und unüberwachten Klassifikation. Anstatt Pixel für Pixel zu bestimmen, welcher Klasse dieser am wahrscheinlichsten angehört, wird hier davon ausgegangen, dass ähnliche Pixel in der Nachbarschaft auch zum selben Objekt gehören. Deshalb werden die Pixel zunächst zu Objekten zusammengefasst und auf Basis dieser Objekte dann die Klassifikation durchgeführt.

Als Software wird das Programm *eCognition Developer 8* der Firma Inphiniens verwendet. Diese ist richtungweisend im Bereich der objekt-orientierten Klassifikation und bietet damit einen völlig anderen Ansatz im Vergleich zu der Software, die sonst in der Fernerkundung verwendet wird: Hier sind in erster Linie *Erdas Imagine* und *ENVI* zu nennen, die nur die klassischen, pixelbasierten Verfahren der überwachten und unüberwachten Klassifikation unterstützen.

2 Grundlagen

2.1 Untersuchungsgebiet und Bilddaten

Das Untersuchungsgebiet liegt in Münkeboe, Niedersachsen (ca. 8 km nordwestlich von Aurich) und hat eine Größe von ca. 0,6 km². Im nördlichen Teil dominieren landwirtschaftliche Flächen während sich im südlichen Teil das über die Jahre langsam wachsende Dorf Münkeboe befindet.

Als Testdaten liegen zwei digitale Orthophotos (DOP) unterschiedlicher Ausdehnung vor, von denen jeweils ein Subset mit identischem Ausschnitt erstellt wurde. DOP1 wurde im Jahr 2008 aufgenommen und hat eine Bodenpixelauflösung von 0,5 Metern. DOP2 wurde im Jahr 2002 aufgenommen und hat eine Bodenpixelauflösung von 1 Meter. Darüber hinaus gibt es deutliche Unterschiede in Sonnenstand und Schattenwurf und damit auch in Helligkeit und Kontrast. Beide Orthophotos enthalten lediglich drei Kanäle (rot, grün und blau - RGB). Ein weiterer Kanal z. B. im nahen Infrarot steht nicht zur Verfügung. Weitere Details über die Daten stehen nicht zur Verfügung.



Abb. 1 Unterschiede in der Auflösung, Helligkeit, Kontrast und Schattenwurf von DOP1 und DOP2

2.2 Klassifikationsverfahren

2.2.1 Unüberwachte Klassifikation

Bei der unüberwachten Klassifikation erfolgt die Einteilung in Klassen automatisch. Der Benutzer gibt lediglich an, wie viele Klassen erstellt werden sollen. Die Einteilung in verschiedene Cluster erfolgt über den Vergleich der Pixel im Merkmalsraum, also den verschiedenen Spektralbändern des Bildes. Das am häufigsten verwendete Verfahren in der unüberwachten Klassifikation ist das Isodata-Verfahren. Hierbei werden für jedes Cluster über die verschiedenen Spektralbänder die Standardabweichung sowie der euklidische Abstand der Clusterzentroiden berechnet. Liegen die Clusterzentroiden dicht beieinander, werden die Cluster zusammengefasst.¹ Abbildung 2 zeigt einen zweidimensionalen Merkmalsraum.

Nach der unüberwachten Klassifikation ist meist eine ausgiebige Nachbearbeitung nötig, in denen Klassen zusammengefasst und aussortiert werden, um ein gutes Ergebnis zu erzielen.

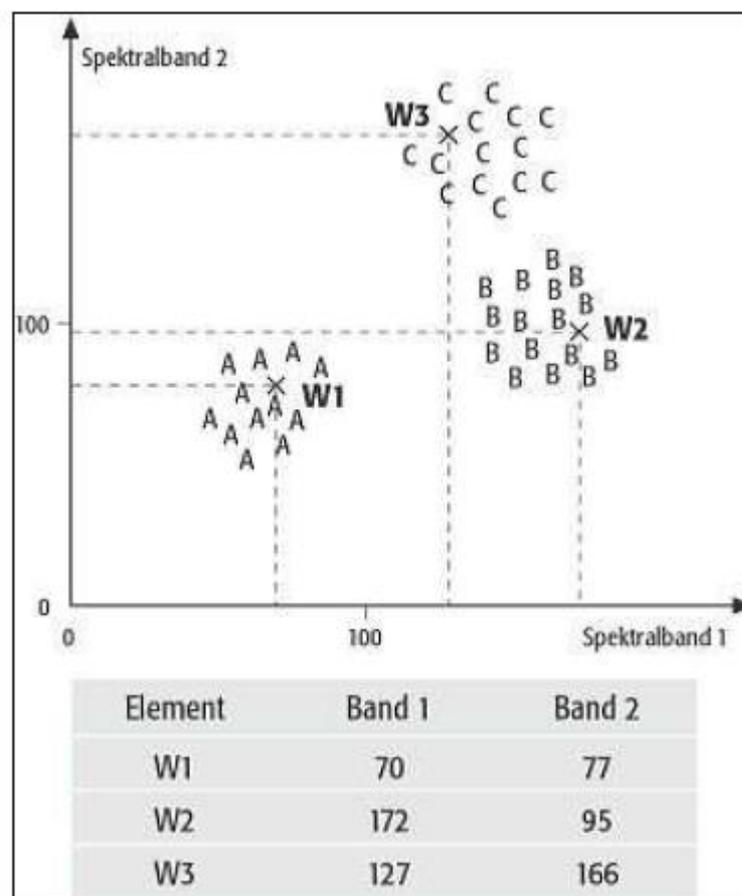


Abb. 2 Beispiel: Zweidimensionaler Merkmalsraum (Quelle: Lexikon der Fernerkundung, 2009)

¹ Lange (2006), S. 415

2.2.2 Überwachte Klassifikation

Bei der überwachten Klassifikation werden zunächst Trainingsgebiete (Area of Interest) festgelegt. Hierbei entscheidet der Benutzer, welche Flächen die gewünschte Klasse möglichst gut und homogen repräsentieren und markiert diese. Die Trainingsgebiete erhalten somit eine spektrale Signatur durch die Reflexionseigenschaften in den Spektralbändern.

Die Zuordnung der Pixel in die einzelnen Klassen, die durch die Trainingsgebiete definiert wurden, kann dann über verschiedene Verfahren durchgeführt werden. Das am meisten Genutzte ist hierbei das Maximum-Likelihood (Verfahren der größten Wahrscheinlichkeit). Hierbei werden für jede Klasse aus den Trainingsgebieten Clusterzentroide bestimmt. Die Zuordnung der Pixel erfolgt dann über die Berechnung der Wahrscheinlichkeit, in dem das jeweilige Pixel der Klasse zugeordnet wird, der es am wahrscheinlichsten angehört.²

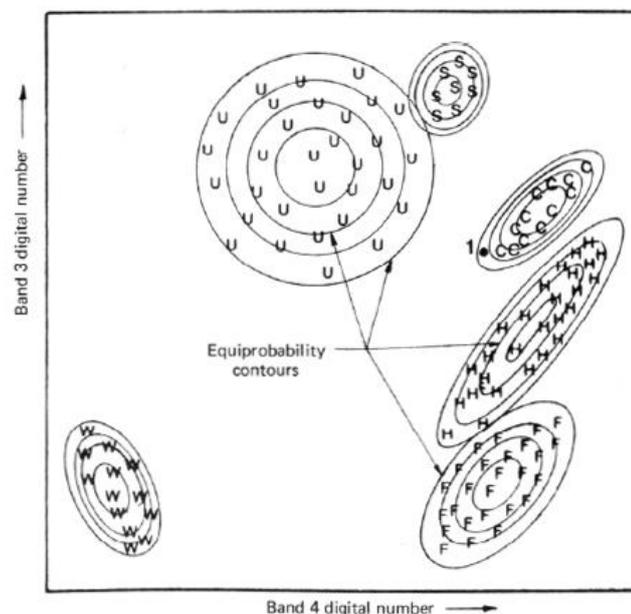


Abb. 3 Clusterzentroide und Zuordnung der Pixel im zweidimensionalen Merkmalsraum (Quelle: Remote Sensing and Image Interpretation (Lillesand et al. 2008), S. 556)

2.2.3 Objekt-orientierte Klassifikation

Die objekt-orientierte Klassifikation, die Bestandteil dieser Arbeit ist, verwendet einen komplett anderen Ansatz. Anstatt pixelweise zu bestimmen, welcher Klasse dieses angehört, wird das Bild zunächst in Segmente aufgeteilt. Es wird davon ausgegangen, dass ähnliche Pixel auch zum selben Objekt und damit zur selben Klasse gehören. Diese Segmente werden dann unter Berücksichtigung verschiedener Eigenschaften, die im *Feature Space* ausgewählt werden, in Klassen eingeteilt.³

² Lange (2006), S. 417

³ Campbell, Wynne (2010), S. 371-372

2.3 Segmentierung in der objekt-orientierten Klassifizierung

Der erste Schritt bei der objekt-orientierten Klassifikation ist die Segmentierung des Bildes mit dem Ziel, die einzelnen Objekte eines Bildes möglichst komplett in einem Segment zu erfassen, um so z. B. Straßen von Wiesen zu trennen oder Häuser von Gärten. eCognition bietet hierfür mehrere Segmentierungsverfahren an, von denen im Folgenden die vier üblichsten genauer betrachtet werden.

2.3.1 Chessboard Segmentation

Bei der Chessboard Segmentation, also Schachbrett-Segmentierung, wird das Bild in quadratische Objekte aufgeteilt. Diese Aufteilung erfolgt in fester Größe und nach einem festen Muster. Objekte werden somit entlang des Schachbrettrasters zerschnitten.⁴

Als Parameter lässt sich lediglich die Objektgröße der Rasterzellen festlegen.

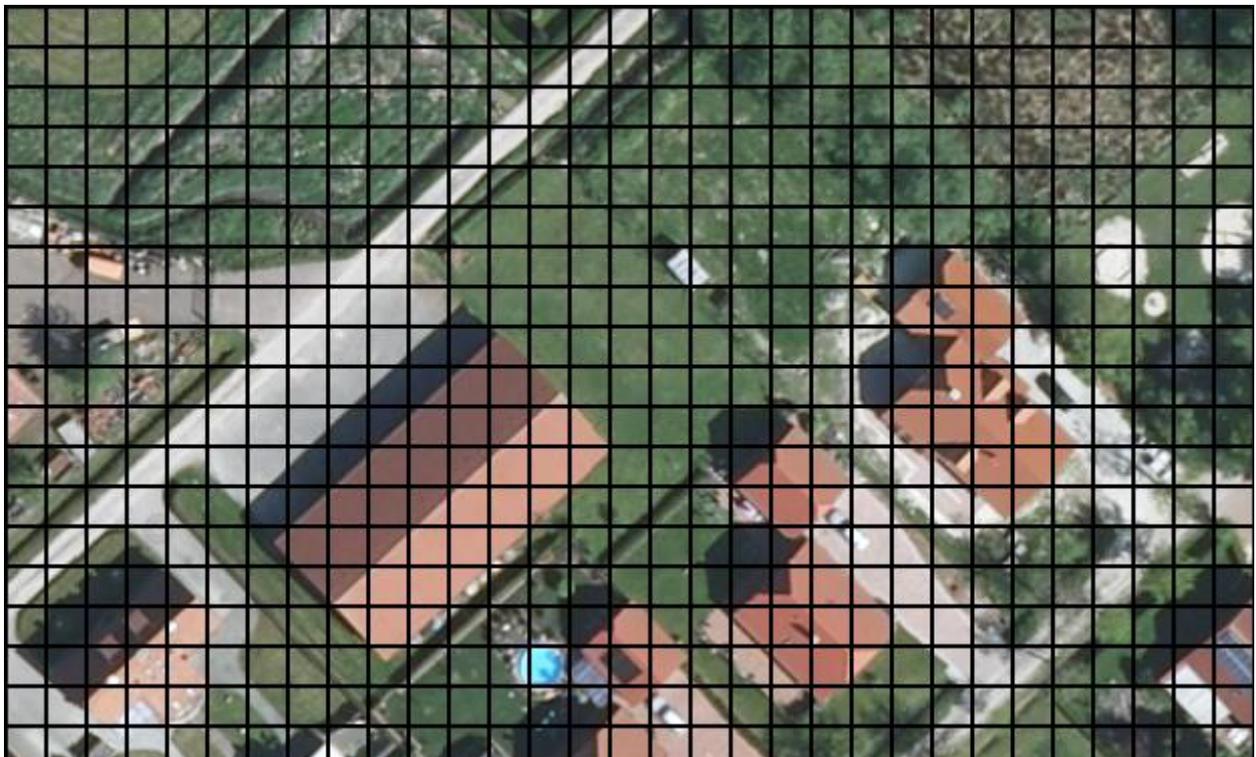


Abb. 4 Chessboard Segmentation angewandt auf DOP1, Object Size 20.

Durch die regelmäßige, rechtwinklige Einteilung erscheint diese Art der Segmentierung nur bei sehr grob aufgelösten Daten sinnvoll. Da in der Natur Objekte selten rechtwinklig ausgerichtet sind, ist diese Art der Segmentierung für Fernerkundungsdaten dieses Typs nicht sinnvoll.

⁴ Trimble (2010b), Reference Book, S. 27

2.3.2 Quadtree-Based Segmentation

Diese Art der Segmentierung unterteilt das Bild ebenfalls zunächst in ein regelmäßiges Raster. Darauf wird dann die Quadtree Baumstruktur angewandt: Falls das Segment nicht homogen ist, wird es in vier Untersegmente aufgeteilt. Die Untersegmente, die dann weiterhin nicht homogen sind, werden wieder unterteilt. Dieser Vorgang wird fortgesetzt, bis jedes Segment homogen ist.⁵

eCognition bietet hier verschiedene Parameter für die Segmentierung:

Scale legt die maximale Farbdifferenz des jeweils ausgewählten Bildlayers fest innerhalb der Rasterquadrate fest. Diese Option ist nur verfügbar, wenn der Color Modus gewählt wurde. Als weiterer Modus steht „Super Object Form“ zur Verfügung, der aber nur bei weiteren Bildebenen verfügbar ist.⁶

Weiterhin ist es möglich, den einzelnen Bildlayern (in diesem Fall RGB) verschiedene Gewichte zuzuweisen, um bestimmten Bildobjekten anhand ihrer Farbe eine höhere Priorität zuzuweisen.



Abb. 5 Quadtree Segmentation angewandt auf DOPI. Color Mode, Scale 60.

⁵ <http://www.geoinformatik.uni-rostock.de/einzel.asp?ID=1410>

⁶ Trimble (2010b), Reference Book, S. 29

Auch diese Art der Segmentierung erscheint für hochaufgelöste Fernerkundungsdaten weniger sinnvoll, da gerade an diagonalen Kanten sehr viele kleine Segmente entstehen. Für Daten mit niedriger Auflösung, die Kanten ohnehin nicht genau genug abbilden, könnte die Quadtree-Based Segmentation durchaus sinnvolle Einsatzgebiete bieten.

2.3.3 Contrast Split Segmentation

Die Contrast Split Segmentation unterteilt ein Bild in helle und dunkle Bereiche. Diese Unterteilung basiert auf einem Grenzwert. Helle Objekte haben Pixelwerte über diesem Grenzwert und dunkle Objekte haben Pixelwerte unter diesem Grenzwert. Der Grenzwert wird durch einen Algorithmus für jedes Objekt bestimmt, in dem zunächst die Chessboard Segmentation (vgl. Kapitel 2.3.1) ausgeführt wird. Innerhalb jeder Zelle des Schachbrett-Rasters wird dann die Unterteilung zwischen hell und dunkel bestimmt. Hierfür wird der Grenzwert schrittweise angehoben bis das beste Ergebnis innerhalb der vorgegebenen Parameter erreicht wird.⁷

eCognition bietet zahlreiche Parameter für diesen Prozess: Größe des Schachbrettrasters, ein Minimum und Maximum für den Grenzwert, die Schrittweite mit der der Grenzwert angehoben wird sowie die Festlegung, ob die Schrittweite zum vorherigem Wert addiert oder mit diesem multipliziert wird. Weiterhin wird festgelegt, auf welchen Layer der Prozess angewandt wird und ob für helle und dunkle Objekte eine Klasse erstellt wird oder nicht.

⁷ Trimble (2010b), Reference Book, S. 30-31

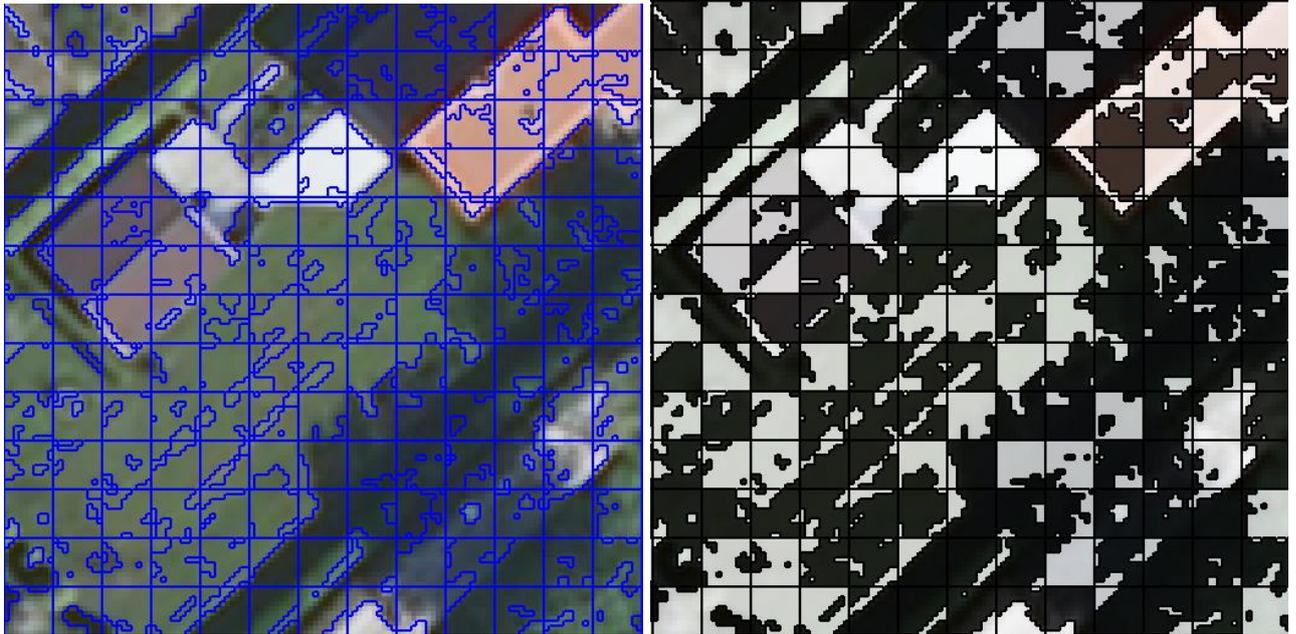


Abb. 6 Contrast Split Segmentation angewandt auf DOP1, Darstellung ohne (links) und mit (rechts) Hell-/Dunkel-Klassen. Chessboard Tile Size 10, 0-255, Step 5.

Durch die Unterteilung innerhalb des groben Schachbrettmusters ist dieses Verfahren für bestimmte Anwendungszwecke sinnvoll nutzbar. Durch Optimierung der Parameter könnte zum Beispiel eine Unterteilung zwischen Schatten und Nicht-Schatten vorgenommen werden. Dennoch ist die Unterteilung für Gebäude auch in diesem Fall nicht sinnvoll, da einzelne Segmente sowohl aus Gebäudeteilen als auch Vegetation bestehen.

2.3.4 Multiresolution Segmentation

Die Multiresolution Segmentation ist ein Algorithmus, der Regionen von klein zu groß miteinander verschmilzt. Zunächst wird jedes Pixel als einzelnes Objekt angesehen. Diese werden dann nach und nach zu größeren Segmenten zusammengefasst. Dazu wird lokal die Homogenität, also die Ähnlichkeit zwischen benachbarten Objekten betrachtet. In mehreren Durchläufen werden die Segmente immer weiter zusammengefasst. Der Benutzer legt durch die Vergabe von Parametern und Schwellwerten selbst fest, bis zu welchem Maße an Ähnlichkeit Pixel und Segmente vereint werden und damit letztendlich, wie groß die Segmente werden.⁸

Die Multiresolution Segmentation liefert für alle Objektgrößen eine gute Abstraktion der Objekte und bildet eine geeignete Segmentierung für alle Anwendungsgebiete.⁹ Die Segmentierung kann nicht nur auf Pixelebene angewandt werden sondern auch auf die Objektebene, wodurch es möglich ist, einzelne Bereiche oder Klassen einer vorherigen Klassifikation weiter zu segmentieren und dabei andere Bereiche, die keine feinere Segmentierung brauchen, unberührt zu lassen. Dies wird festgelegt über die Parameter Level- und Class-Filter festgelegt. Darüber hinaus können einzelne Layer verschieden stark gewichtet werden.¹⁰

Weitere wichtige Parameter sind Scale, Shape und Compactness. Scale legt fest, wie heterogen die Segmente im Ergebnis sein dürfen. Je homogener die Daten sind, umso größer werden die Segmente für einen bestimmten Scale Wert.¹¹ Shape legt das Verhältnis zwischen Form und Farbe fest. Je höher der Shape-Parameter gewählt wird, desto geringer ist der Einfluss der Farbe auf den Segmentierungsprozess. Compactness legt fest, wie stark die Dichte der Bildobjekte gewichtet wird. Hierdurch werden Objekte voneinander getrennt, die sich in ihrer Dichte unterscheiden, spektral aber sehr ähnlich sind. Je höher der Parameter gesetzt wird, umso dichter werden die Objekte.¹²

Die Abbildungen 7 bis 9 verdeutlichen die Auswirkung dieser Parameter.

⁸ Darwish et al., S. 1

⁹ Trimble (2010b), Reference Book, S. 35

¹⁰ Trimble (2010b), Reference Book, S. 36-37

¹¹ Trimble (2010b), Reference Book, S. 37

¹² Trimble (2010b), Reference Book, S. 38



Abb. 7 Scale Parameter von 10 (links) bzw. 150 (rechts) bei gleichen Werten für Shape (0.1) und Compactness (0.9)



Abb. 8 Shape Parameter von 0,1 (links) und 0,9 (rechts) bei gleichen Werten für Scale (50) und Compactness (0,9)



Abb. 9 Compactness Parameter von 0,1 (links) und 0,9 (rechts) bei gleichen Werten für Scale (50) und Shape (0,5)

2.4 Objekt-orientierte Klassifikation

Nachdem eine geeignete Segmentierung erstellt wurde, erfolgt die eigentliche Klassifikation des Bildes. Im Folgenden wird die Klassifikation nach der Nearest-Neighbour-Methode erläutert und später verwendet. Der Fokus liegt hier auf drei wichtigen Vorgängen und Elementen. Zunächst werden *Samples* für die Klassen festgelegt. Die Klassifikation erfolgt über die Betrachtung bestimmter Eigenschaften, die im *Feature Space* festgelegt werden. Oft ist es nötig, die Klassifikation in mehreren Schritten durchzuführen. Auch eine weitere Segmentierung bestimmter Klassen kann sinnvoll sein. All diese Vorgänge werden im *Process Tree* festgehalten, in dem auch Parameter verändert werden können und Vorgänge erneut ausgeführt werden können.

2.4.1 Samples

Auf Basis einer potentiell geeigneten Segmentierung werden Samples für die Klassifikation erstellt. Der Vorgang ähnelt der Festlegung von Trainingsgebieten bei der überwachten Klassifikation. In diesem Fall werden aber keine Testgebiete bzw. Areas of Interest in ihrer Form selbst bestimmt, sondern einzelne Segmente ausgewählt, die die Klasse in Farbe und Form möglichst gut repräsentieren.

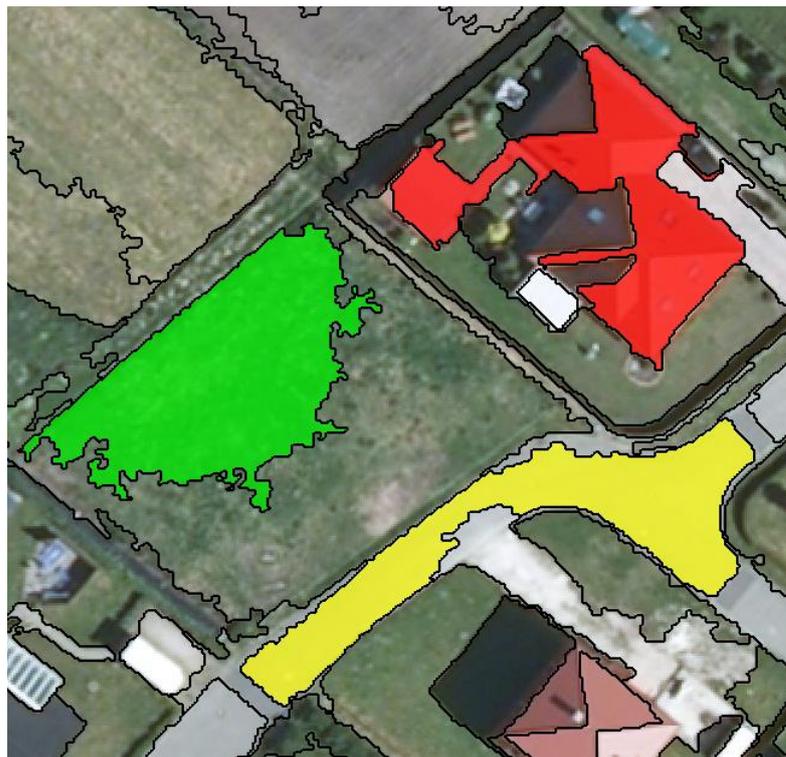


Abb. 10 Beispiel für die Auswahl von Samples für die Klassen Gebäude (rot), Vegetation (grün) und Straße (gelb)

2.4.2 Feature Space

Die festgelegten Samples werden bei der Klassifikation unter bestimmten Gesichtspunkten betrachtet, die vom Benutzer im Feature Space ausgewählt werden. eCognition stellt hier eine Vielzahl von Möglichkeiten bereit, von simplen Kriterien wie Farbe, Form und Helligkeit bis zu komplexen Features, die mathematische und statische Berechnungen auf Basis von Pixeln und Layern durchführen. Im Folgenden werden einige Features genauer betrachtet, die für die Aufgabenstellung dieser Arbeit sinnvoll erscheinen. Dazu wird jeweils ein mögliches Einsatzgebiet genannt.



Abb. 11 Feature-Space in eCognition - Mean

Features in diesem Bereich beziehen sich auf den Mittelwert der Intensität des jeweiligen Layerwerts eines Objekts.

Brightness

Hier wird die Helligkeit des jeweiligen Segments betrachtet. Dabei kann vom Benutzer festgelegt werden, welche Layer hierfür in Betracht gezogen werden.¹³ Sinnvolle Einsatzgebiete sind hier Fälle, wo Objekte bzw. Segmente mit deutlichen Helligkeitsunterschieden klassifiziert werden sollen, wie z. B. Vegetation und Schatten.

Kategorie: *Object Features* → *Layer Values* → *Pixel-based*:

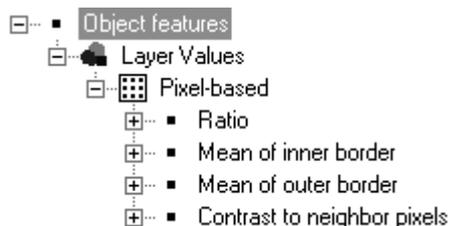


Abb. 12 Feature-Space in eCognition – Pixel-based

Diese Features beziehen sich auf bestimmte Pixelwerte eines Objekts bzw. Segments.¹⁴

¹³ Trimble (2010b), Reference Book, S. 227

¹⁴ Trimble (2010b), Reference Book, S. 231

Ratio

Das Feature bewertet, wie stark ein Layer zur gesamten Helligkeit beiträgt.¹⁵ Dies kann z. B. beim Erkennen von gesunder Vegetation nützlich sein. Dort kann der Layer „Grün“ ausgewählt werden, da dieser den stärksten Anteil an der Helligkeit im grünen Bereich hat.

Mean of inner border

Der durchschnittliche Wert der Intensität eines Pixels, das zu einem Bildobjekt gehört, welches seinen Rand mit anderen Bildobjekten teilt, die ebenfalls von Interesse sind und damit eine innere Grenze bildet.¹⁶ Als Parameter kann hier vom Benutzer der Layer ausgewählt werden, auf den sich dieses Feature bezieht. Der Wertebereich des Features liegt zwischen dem dunkelsten und hellsten möglichen Intensitätswert des ausgewählten Layers.

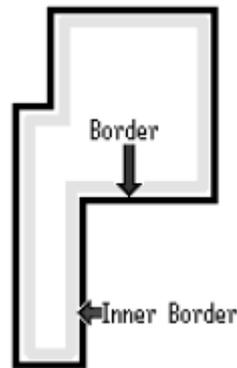


Abb. 13 Innere Grenze eines Bildobjekts (Quelle: Reference Book, S. 234)

Mean of outer border

Auch hier wird ein Layer vom Benutzer vorgegeben. In diesem Feature werden die Intensitätswerte der Pixel des Layers betrachtet, die zu Bildobjekten gehören, die nicht von Interesse sind, aber an Objekte von Interesse angrenzen.¹⁷ Auch hier liegt der Wertebereich des Features zwischen dem dunkelsten und hellsten möglichen Intensitätswert des ausgewählten Layers. Anwendungsgebiete können z. B. die Klassifikation von Gebäuden sein, die innerhalb von Grünflächen liegen, welche für die Klassifikation aber nicht von Bedeutung sind. Die Grünfläche könnte eine eindeutigere Intensität haben als das Gebäude selbst, weshalb die Betrachtung der äußeren Grenze sinnvoller ist.

¹⁵ Trimble (2010b), Reference Book, S. 231

¹⁶ Trimble (2010b), Reference Book, S. 234

¹⁷ Trimble (2010b), Reference Book, S. 235

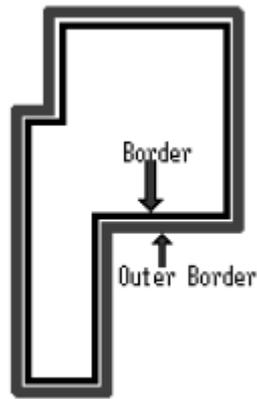


Abb. 14 Äußere Grenze eines Bildobjekts (Quelle: Reference Book, S. 235)

Contrast to Neighbor Pixels

Hier wird vom Benutzer ein Distanzwert der Layer angegeben, auf den das Feature angewandt wird. Um das jeweilige Objekt wird eine Fläche erstellt, deren Größe durch den Distanzwert bestimmt wird. Dann wird der Kontrast des Objekts mit dem Kontrast der umgebenden Fläche verglichen. Der Wertebereich liegt zwischen -1000 und 1000. Dieses Feature kann benutzt werden, um Grenzen und Abstufungen in der Szene zu finden.¹⁸ Einsatzbereiche können das Klassifizieren von Objekten sein, die einen großen Kontrast zu ihrer Umgebung aufweisen, z. B. Straßen, die durch landwirtschaftliche genutzte Felder führen.

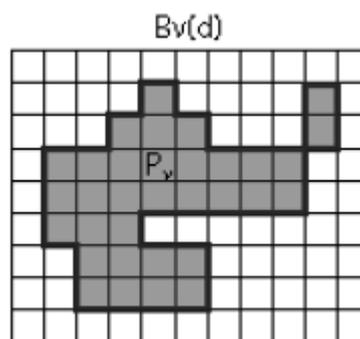


Abb. 15 Der umgebende Bereich (Bounding Box) eines Bildobjekts $B_v(d)$ mit einer Distanz von einem Pixel. Innerhalb befinden sich die Pixel (P_v), die das Objekt bilden. (Quelle: Reference Book, S. 236)

¹⁸ Trimble (2010b), Reference Book, S. 235-236

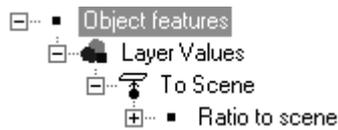


Abb. 16 Feature-Space in eCognition – To Scene

Ratio to Scene

Berechnet das Verhältnis zwischen den Pixeln, die ein Objekt bilden und der durchschnittlichen Intensität des gesamten Layers.¹⁹ Hierbei kann vom Benutzer festgelegt werden, von welchem Layer die Intensität betrachtet wird.



Abb. 17 Feature-Space in eCognition – Hue, Saturation, Intensity

Hue, Saturation, Intensity

Dieses Feature führt eine Umwandlung vom RGB Farbraum in den HSI Farbraum durch.²⁰

Während im RGB Farbraum in jedem der drei Kanäle eine Farbe vorliegt, erhält man durch die Umrechnung in den HSI Farbraum drei Kanäle für Hue (Farbton), Saturation (Sättigung) und Intensity (Helligkeit). Dieses Feature kann bei der Beurteilung von Farbe und Helligkeit eines Segments bzw. Objekts nützlich sein.



Abb. 18 Feature-Space in eCognition – Geometry

Geometry Features

Bei diesen Features wird die Geometrie der Objekte betrachtet. Für diese Arbeit sind vor allem die Features Größe (Extent) und Form (Shape) von Bedeutung, da diese gut geeignet sind, um unterschiedliche Objekte wie Gebäude, Straßen und Felder zu unterscheiden. Die Features werden aus den Pixeln berechnet, die zu den Objekten gehören. Da es sich um Rasterbilder handelt, sind die

¹⁹ Trimble (2010b), Reference Book, S. 248-249

²⁰ Trimble (2010b), Reference Book, S. 249

Geometry-Features abhängig von der Ausrichtung des Bildes. Wenn das Bild gedreht wird, ändert sich auch die Geometrie.²¹ Einsatzgebiete für alle diese Features sind Objekte, die sich in Farbe, Intensität und Textur kaum von anderen Objekten unterscheiden, aber eine andere Form und Größe haben.

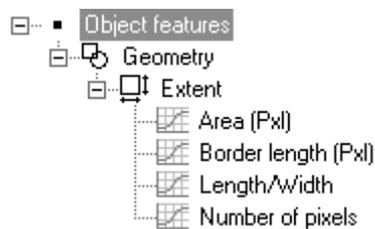


Abb. 19 Feature-Space in eCognition - Extent

Area

Betrachtet die Pixel, die zu einem Objekt gehören. Falls das Bild Informationen über die Einheit der Pixel in seinen Metadaten hat, können Pixel in Maßeinheiten umgerechnet werden. Falls nicht, werden einfach die Pixel gezählt.²²

Border length

Die Kantenlänge (Border length) wird durch die Summe der Kanten eines Objekts bzw. die Summe der Kanten, die sich ein Objekt mit anderen teilt, bestimmt. Hierbei werden nicht nur die äußeren Kanten summiert sondern auch eventuell vorhandene innere Kanten, wenn z. B. ein weiteres Objekt innerhalb des Objektes liegt.²³

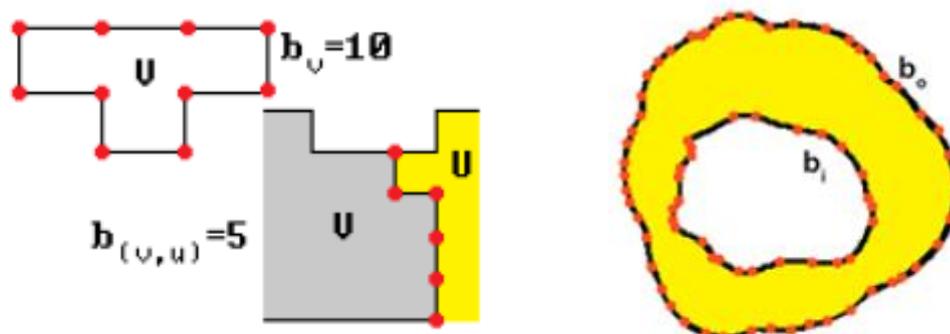


Abb. 20 Links: Kantenlänge eines Bildobjekts v , oder zwischen zwei Objekte v und u . Rechts: Innere und äußere Kantenlänge eines Objekts. (Quelle: Reference Book S. 252)

²¹ Trimble (2010b), Reference Book, S. 251

²² Trimble (2010b), Reference Book, S. 251

²³ Trimble (2010b), Reference Book, S. 252

Length/Width

Hier wird das Verhältnis zwischen Länge und Breite eines Bildobjekts berechnet. Dabei werden zwei Methoden verwendet:

1. Das Verhältnis von Länge und Breite ist identisch zum Verhältnis des Eigenwerts der Kovarianzmatrix, wobei der größere Eigenwert der Zähler des Bruches ist.²⁴
2. Dem Verhältnis von Länge und Breite kann man sich auch durch die Verwendung der umgebenden Hülle annähern.²⁵

Beide Berechnungen werden verglichen und das kleinere der beiden Ergebnisse als Feature-Wert zurückgegeben.²⁶

Number of pixels

Die Anzahl der Pixel, die ein Objekt formen. Maßeinheiten werden hier nicht berücksichtigt.²⁷

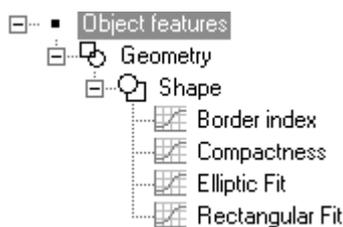


Abb. 21 Feature-Space in eCognition - Shape

Border Index

Der Border-Index (Kanten-Index) gibt an, wie die Kanten eines Objekts geformt sind. Je kantiger ein Objekt ausgeprägt ist, umso höher ist sein Index. Zur Berechnung wird ein Rechteck um das Objekt gelegt. Das Verhältnis zwischen Kantenlänge des Objekts und Kantenlänge des Rechtecks ergibt den Kanten-Index.²⁸

²⁴ Trimble (2010b), Reference Book, S. 254

²⁵ Trimble (2010b), Reference Book, S. 255

²⁶ Trimble (2010b), Reference Book, S. 255

²⁷ Trimble (2010b), Reference Book, S. 256

²⁸ Trimble (2010b), Reference Book, S. 259

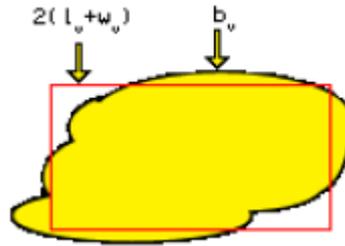


Abb. 22 Kanten-Index eines Bildobjekts v . l_v und w_v sind die Länge und Breite des Bildobjekts, b_v ist die Kantenlänge des Bildobjekts. (Quelle: Reference Guide, S. 260)

Compactness

Das Feature Kompaktheit (Compactness) beschreibt, wie kompakt ein Objekt ist. Diese Feature ist ähnlich zum Feature Border-Index, bezieht sich aber auf die Fläche. Je kompakter ein Objekt desto kleiner bzw. kürzer ist seine Umgrenzung. Die Kompaktheit wird aus der Länge und Breite geteilt durch die Anzahl der Pixel berechnet.²⁹

Elliptic fit

Beim Elliptic fit wird bestimmt, wie gut ein Bildobjekt in eine Ellipse gleicher Größe passt. Hierzu wird der Bereich innerhalb der Ellipse mit dem Bereich außerhalb verglichen. Der Wertebereich geht hier von 0 (Objekt passt gar nicht die Ellipse) bis 1 (Objekt passt perfekt und ist komplett innerhalb der Ellipse).³⁰

Rectangular fit

Ähnlich wie beim Elliptic fit wird hier bestimmt, wie gut ein Objekt in ein Rechteck gleicher Größe und gleichem Flächeninhalt passt. Auch hier wird der Bereich außerhalb des Rechtecks mit dem Bereich innerhalb verglichen, der Wertebereich geht ebenfalls von 0 bis 1.³¹

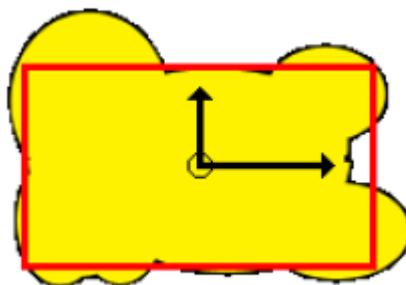


Abb. 23 Rectangular fit eines Bildobjekts. (Quelle: Reference Book, S. 269)

²⁹ Trimble (2010b), Reference Book, S. 260

³⁰ Trimble (2010b), Reference Book, S. 262

³¹ Trimble (2010b), Reference Book, S. 268-269

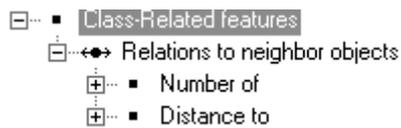


Abb. 24 Feature-Space in eCognition – Relations to neighbour objects

Class-Related Features liefern Informationen über alle Bildobjekte einer bestimmten Klasse innerhalb des Bildes.

Number of

Der Benutzer gibt hier eine Klasse und eine Distanz an. Das Feature gibt darauf als Ergebnis zurück, wie viele Objekte dieser Klasse innerhalb der angegebenen Distanz um das aktuelle Objekt vorhanden sind.

Distance to

Der Benutzer gibt eine Klasse vor. Das Feature berechnet den Abstand zur angegebenen Klasse ausgehend vom aktuellen Objekt.

Da sich in der Umgebung einer Klasse häufig mehrere Objekte der gleichen Klasse befinden, können diese Features nützlich sein, um Objekte mit untypischer Form und Ausdehnung in der Nachbarschaft richtig zu bestimmen.

2.4.3 Process Tree

Im Process Tree in eCognition werden zunächst alle Prozesse ausgewählt und die gewünschten Parameter eingestellt.

Somit kann später nicht nur leicht nachvollzogen werden, welche Schritte mit welchen Einstellungen vorgenommen wurden, es ist auch möglich, einzelne Elemente innerhalb einer Prozesskette zu verändern und den Prozess danach erneut auszuführen. Alle auf dem veränderten Prozess aufbauenden Aktionen werden dann mit den neuen Voraussetzungen neu durchlaufen und das Ergebnis entsprechend angepasst.

Weiterhin ist es möglich, Unterprozesse zu schaffen und somit Zwischenergebnisse für verschiedene Teilzwecke unterschiedlich weiterzuverarbeiten.

Eine Klassifikation kann so in mehreren Schritten ausgeführt werden. Daraufhin können bestimmte Klassen in weitere Unterklassen unterteilt werden, während andere Klassen völlig unberührt bleiben. Auch können bestimmte Klassen als Grundlage für weitere Prozesse verwendet werden, wie z. B. eine weitere Segmentierung der Klasse Vegetation, die dann wieder Basis für eine Klassifikation wird, während eine Klasse Wasser aber komplett ignoriert und nicht weiter segmentiert wird.

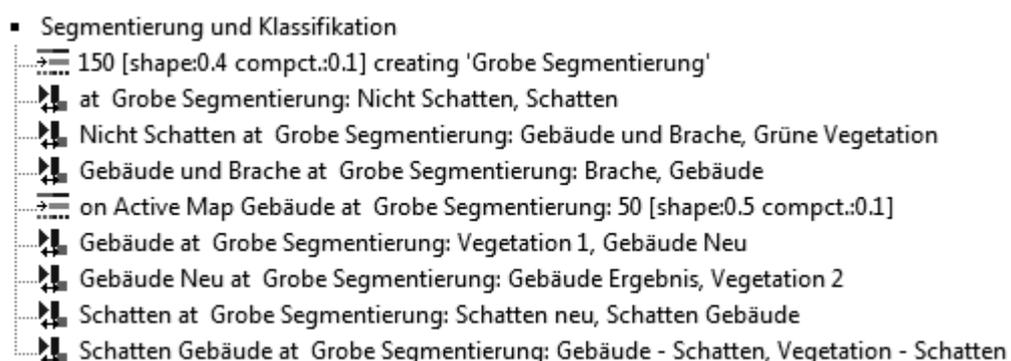


Abb. 25 Beispiel für einen Process Tree

3 Anwendung

Im folgenden Kapitel wird die Vorgehensweise für die objekt-orientierte Klassifikation von der Segmentierung über die Klassifikation bis zur Beurteilung des Ergebnisses beschrieben. Hierbei werden zunächst detailliert die Schritte der Bearbeitung des ersten digitalen Orthophotos (DOP) von 2008 beschrieben. Danach wird die Erfahrung daraus auf das zweite digitale Orthophoto von 2002 angewandt und wenn nötig die Parameter und die Auswahl der Features an die anderen Eigenschaften des Bildes angepasst. Da das Orthophoto von 2008 eine höhere Auflösung hat erscheint es sinnvoller, zunächst dieses zu bearbeiten und danach die Parameter auf das niedriger aufgelöste Orthophoto von 2002 anzupassen. Eine Anpassung von fein zu grob ist meist einfacher als der umgekehrte Fall. Nach der Bearbeitung beider Bilder folgt eine Analyse des Ergebnisses und der Vergleich beider Ergebnisse zur Beurteilung der Möglichkeiten zur Erkennung von neuen Gebäuden.

3.1 DOP1 (2008)

Wie im Kapitel 2.1 erläutert, verfügt dieses Orthophoto über drei Kanäle (rot, grün und blau – RGB) und hat eine Bodenpixelauflösung von 0,5 Metern. (Siehe auch Anhang I)

3.1.1 Segmentierung und Klassifikation

Die völlig andere Herangehensweise der objekt-orientierten Klassifikation zeigt sich in der Praxis sehr schnell darin, dass sich Erfahrungen aus der überwachten und unüberwachten Klassifikation mit Isodata und Maximum Likelihood (vgl. Kapitel 2.2.1 und 2.2.2) kaum auf die objekt-orientierte Klassifikation übertragen lassen.

Nach ersten Versuchen wird für die Segmentierung ein Scale Parameter von 10 gewählt. Shape wird auf den maximal möglichen Wert von 0,9 gesetzt, damit kleinere Unterschiede in Farbe und Helligkeit der Dächer keine große Auswirkung haben. Der Compactness Parameter wird auf den kleinsten Wert 0,1 gesetzt, damit die Segmente nicht zu klein werden.

Das Ergebnis (vgl. Abb. 26) erscheint auf den ersten Blick durchaus gut. Obwohl die Häuserdächer und auch die Grünflächen in mehrere Segmente unterteilt sind, wird die Begrenzungen zu anderen Objekte gut erkannt. Durch die Zusammenfassung dieser Segmente durch die Klassifikation sollten sich die Objekte gut klassifizieren lassen.

Im nächsten Schritt werden die Klassen erstellt. Für die Gebäude werden drei Klassen bestimmt und entsprechende Segmente als Samples, für Dächer im direkten Sonnenlicht, dunkle Dächer und Dächer in normaler Helligkeit gewählt. Dazu kommen zwei Klassen für helle und dunkle Vegetation, außerdem Brache und Straßen.

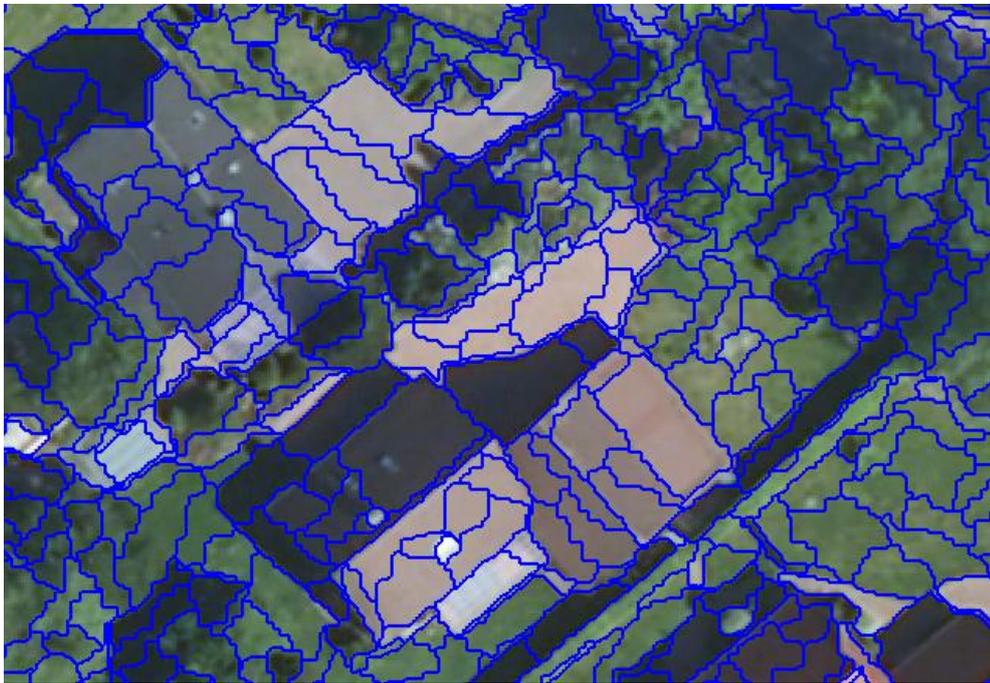


Abb. 26 Erste Segmentierung von DOP1. Parameter: Scale 10, Shape 0,9, Compactness 0,1

Im Feature Space werden Compactness, Shape Index, Rectangular Fit und Number of Pixels ausgewählt, da diese theoretisch gut für die Erkennung geeignet sein sollten. Danach wird die Klassifikation ausgeführt.

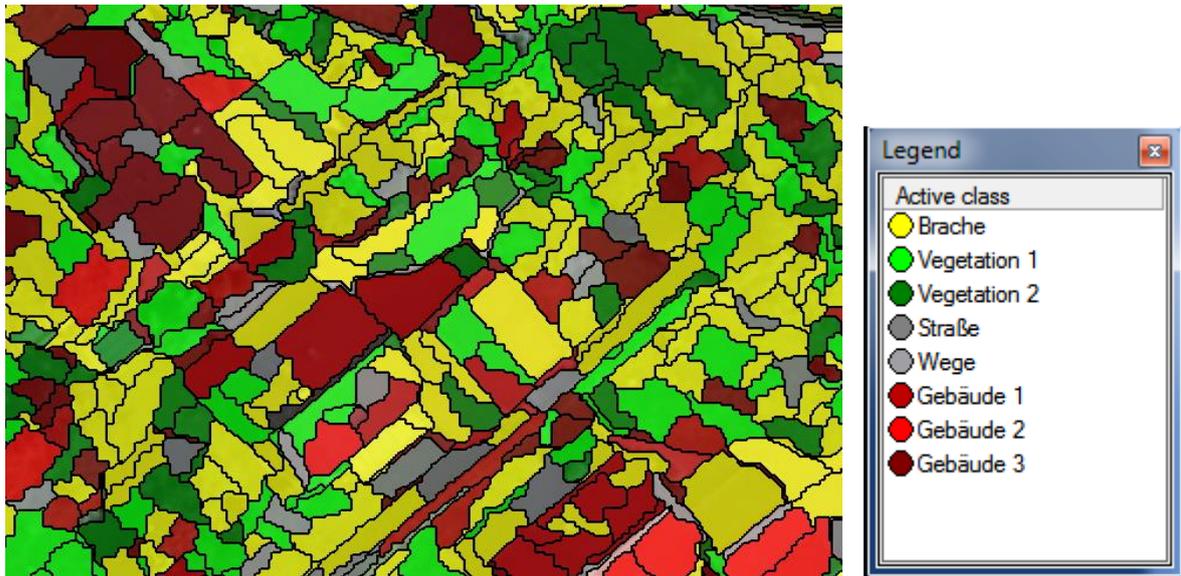


Abb. 27 Ergebnis der ersten Klassifikation von DOP1

Das Ergebnis (vgl. Abb. 27) erweist sich leider als unbrauchbar. Zwar werden einige Gebäudeteile recht gut erkannt, andere aber völlig falsch klassifiziert. Auch Teile der Vegetation werden als Gebäude erkannt. Es zeigt sich, dass gewisse Klassen für die Klassifikation sehr problematisch sind. So lassen sich Gebäude und Brache teilweise sehr schwer trennen. Schatten von Gebäuden und Schatten von Vegetation sind praktisch nicht zu unterscheiden. Auch die Segmentierung erweist sich als ungünstig, da durch die Aufteilung der Objekte in mehrere Segmente deren Form nicht mehr zu erkennen ist. Diese Eigenschaften sind aber wichtig, um bei der Klassifikation ein eindeutiges Ergebnis zu erhalten. Ein Segment, das ein Hausdach beinhaltet, unterscheidet sich in Größe und Form deutlich von landwirtschaftlicher Brache. Diese Objekte müssen daher optimal erkannt werden, um die Voraussetzung für eine gute Klassifikation zu bieten.

Im zweiten Versuch wird zunächst eine völlig neue Segmentierung erstellt. Es zeigt sich, dass es nicht möglich ist, eine Segmentierung zu finden, die für alle Objekttypen ein gutes Ergebnis liefert. Deshalb wird eine gröbere Segmentierung erstellt um diese später anhand einer Teilklassifikation in bestimmten Bereichen feiner zu segmentieren. Für die grobe Segmentierung (vgl. Abb. 28) wurde ein Scale Parameter von 150 gewählt, um größere Segmente zu erhalten, die Objekte nicht unterteilen. Als Shape-Parameter wurde 0,4 gewählt und für Compactness 0,1. Hierdurch ließ sich die Trennung der Segmente noch einmal verbessern.

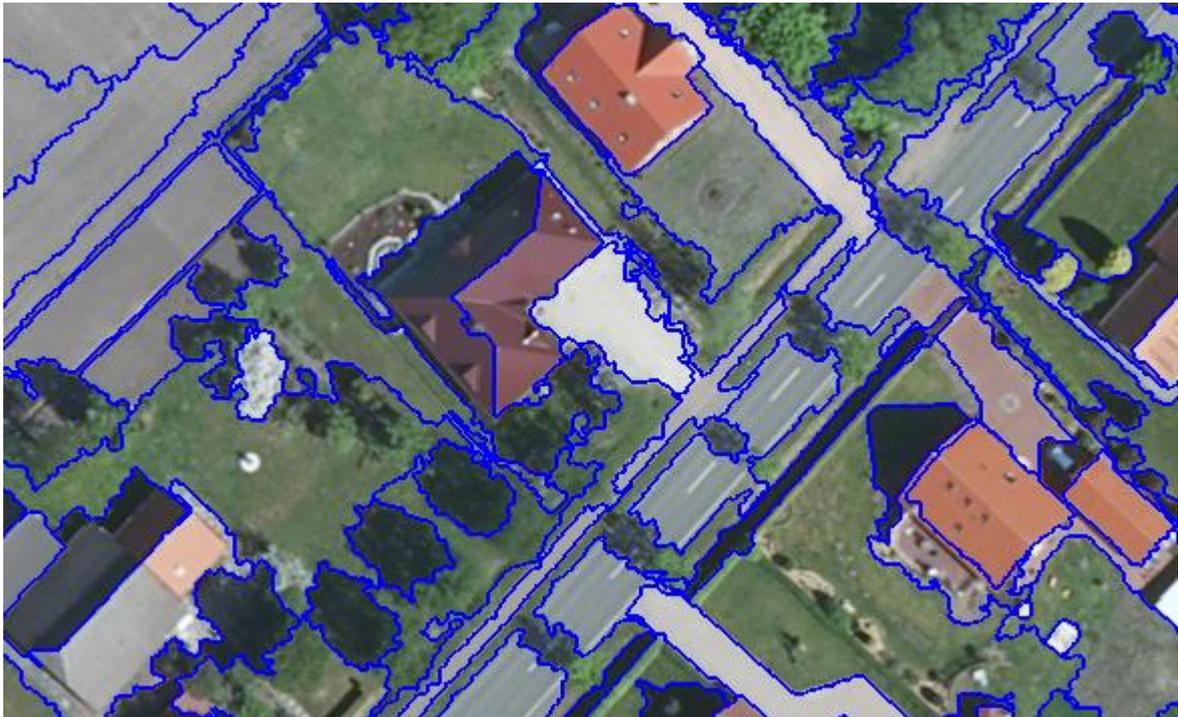


Abb. 28 Neue, grobe Segmentierung mit den Parametern: Scale 150, Shape 0,4 und Compactness 0,1.

Das Ergebnis der neuen Segmentierung zeigt, dass vor allem die Gebäude nun meist nur noch aus einem bis drei Segmenten bestehen. Teilweise gibt es aber immer noch Segmente, die mehrere Objekte vereinen. Große Objekte wie landwirtschaftliche Felder bestehen oft nach wie vor aus mehreren Segmenten. Die Anzahl der Segmente ist aber bereits deutlich zurückgegangen. Diese Probleme sollten sich dann in einer späteren, feineren Segmentierung lösen lassen.

Auch die Klassifikation in einem Schritt erweist sich nach den Ergebnissen des ersten Versuchs als nicht Erfolg versprechend. Es scheint daher sinnvoll, die Klassifikation schrittweise durchzuführen, um die Problemklassen im Bereich von Schatten, Brache und Gebäude von den anderen Klassen zu trennen.

Die erste und einfachste Unterscheidung erschien daher verschattete und nicht verschattete Objekte bzw. Segmente zu trennen. Dazu werden die zwei Klassen „Schatten“ und „Nicht-Schatten“ erstellt. Als Samples dienen dann Schattensegmente bzw. nicht verschattete Segmente, ungeachtet davon, um welche Art von Objekten es sich dabei handelt. Da sich in diesem Fall die Eigenschaften der Segmente simpel in hell und dunkel aufteilen, wird im Feature Space lediglich das Feature

Brightness (Helligkeit) ausgewählt. Die folgende Klassifikation erkennt dann recht zuverlässig alle verschatteten Segmente (vgl. Abb. 29).



Abb. 29 Klassifikation von Schatten (schwarz) und Nicht-Schatten (weiß)

Beide Klassen müssen nun weiter unterteilt werden. Zunächst werden die nicht verschatteten Gebiete genauer klassifiziert. Hierzu schien die Unterteilung der Klasse „Nicht-Schatten“ in „Gebäude und Brache“ und „Grüne Vegetation“ sinnvoll. Da der erste Versuch zeigt, dass Gebäude und Brache schwer zu trennen sind, wird für diese beiden Objektklassen zunächst nur eine Klasse erstellt, um sie später weiter zu unterteilen. Nach der Wahl geeigneter Samples werden im Feature Space verschiedene Features getestet um zu einer möglichst guten Klassifikation zu kommen. Abbildung 30 zeigt die Features, die sich letztendlich als die beste Wahl herausgestellt haben.



Abb. 30 Ausgewählte Features im Feature Space und Klassifikationsergebnis von „Grüne Vegetation“ (grün) und „Gebäude und Brache“ (gelb)

Durch die Auswahl der Features wird die Helligkeit (Brightness), die Intensität der Pixel des jeweiligen Objekts und der angrenzenden Objekte (Mean of inner/outer border) sowieso der Kontrast zu den benachbarten Pixeln (Contrast to neighbor pixels) im Layer 2 (grün) betrachtet, um eine bessere Abgrenzung der Vegetation zu ermöglichen. Weiterhin wird die Größe und Form der Objekte berücksichtigt, also die Anzahl der Pixel (Area), die Länge des Randes des Segments (Border length) und allgemein die Länge und Breite (Length/Width) des Objekts. Weiterhin legt der Border Index fest, wie glatt die Kanten des Segments sind. Dies ist hier sinnvoll, da Gebäude grade Kanten haben während Vegetation meist recht unregelmäßige Segmente bildet.

Das Ergebnis (vgl. Abb. 30) erweist sich insofern als gut, dass als Vegetation auch nur Vegetationsflächen erkannt wurden. Gebäude und Brache wurden zusammen mit Straßen klassifiziert. Die Unterscheidung zwischen Vegetation und Brache war nicht immer erfolgreich. Da der Hauptbestandteil dieser Arbeit aber das Erkennen von Gebäuden ist, ist eine gewisse Ungenauigkeit in den übrigen Klassen für das Ergebnis nicht von Bedeutung.

Im nächsten Schritt wird nun versucht, nur die Gebäude zuverlässig zu erkennen. Dafür wird die Klasse „Gebäude und Brache“ unterteilt, je eine Klasse für „Brache“ und „Gebäude“ erstellt und für beide neue Samples gewählt. Hierbei muss drauf geachtet werden, dass die Samples in Form und Helligkeit möglichst gute ihre Klasse repräsentieren. Im Feature Space wird die Auswahl der vorher-

rigen Klassifikation beibehalten, da die Bedingungen zwar ähnlich sind, durch die neuen Samples jedoch ein genaueres Ergebnis zu erwarten ist.

Da die Gebäudeklasse nach diesem Schritt nach wie vor Teile von Brache enthielten, wurde diese Klasse testweise noch einmal weiter unterteilt. Das Ergebnis (vgl. Abb. 31) zeigt eine deutliche Verbesserung zum allerersten Ergebnis (vgl. Abb. 27). Die Gebäude wurden zumindest teilweise erkannt, Straßen und Teile der Vegetation wurden allerdings auch als Gebäude erkannt. Eine Anpassung des Feature Space bringt hier keine weitere Verbesserung.



Abb. 31 Ergebnis der ersten schrittweisen Klassifikation. Alle Klassen außer Gebäude und Schatten auf grün gesetzt

Da viele Gebäudesegmente nicht nur Gebäudeteile enthielten, sondern auch Einfahrten und Gartenbereiche, zeigte sich, dass eine weitere, feine Segmentierung nötig ist, um das Ergebnis zu verbessern. Als Basis für diese feinere Segmentierung wird die Klasse „Gebäude“ verwendet, damit die Klassen bzw. Bereiche „Schatten“ und „Grüne Vegetation“ nicht weiter segmentiert werden.

Für die feine Segmentierung wird vor allem der Scale Parameter deutlich herabgesetzt (von 150 auf 50), der Shape Parameter dagegen leicht erhöht (von 0,4 auf 0,5), damit die Segmente nicht zu stark unterteilt werden.

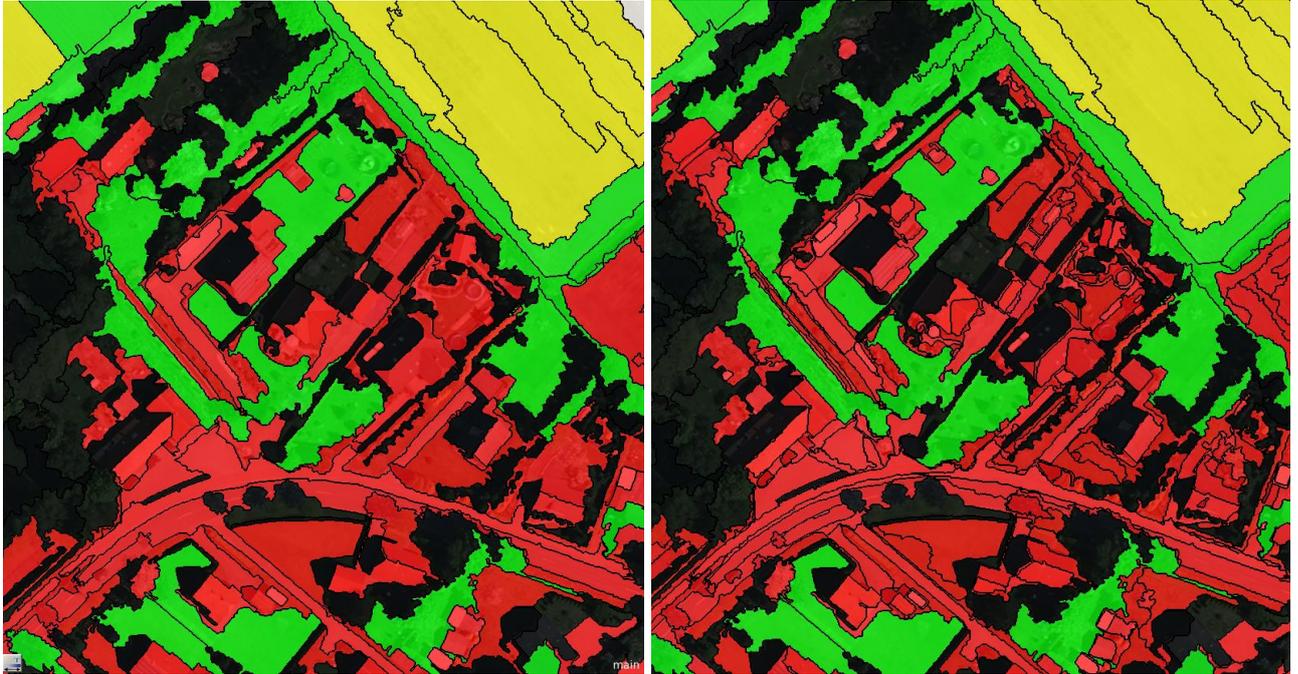


Abb. 32 Ergebnis vor (links) und nach (rechts) der feinen Segmentierung im Bereich der Gebäude (rot).

Die feine Segmentierung (vgl. Abb. 32) zeigt vor allem eine deutlich bessere Abgrenzung der Gebäudedächer und damit die Möglichkeit für eine genauere Klassifikation.

Im nächsten Schritt erfolgt eine weitere Teilklassifikation der nun genauer segmentierten Gebäude. Im Feature Space wird die vorherige Auswahl (vgl. Abb. 30) abgeändert. Die Intensität der Pixel (Mean of inner/outer border) wird entfernt, da hier die Intensität keinen direkten Zusammenhang zur Klasse „Gebäude“ hat. Als zusätzliches Feature erscheint die Betrachtung der Kompaktheit der Objekte (Compactness) als sinnvoll. Außerdem wird in den Beziehungen zu benachbarten Objekten (Relations to neighbor objects) die Distanz zur Klasse Schatten berücksichtigt und der Kontrast zu benachbarten Pixeln. Der Grund dafür ist, dass Gebäude durch ihre Höhe häufig Schatten werfen und diese Klasse damit in ihrer Nähe haben. Die Bereiche auf landwirtschaftlichen Feldern, die vorher als Gebäude erkannt wurden, fallen so heraus, da dort kein Schatten in der Nähe ist.

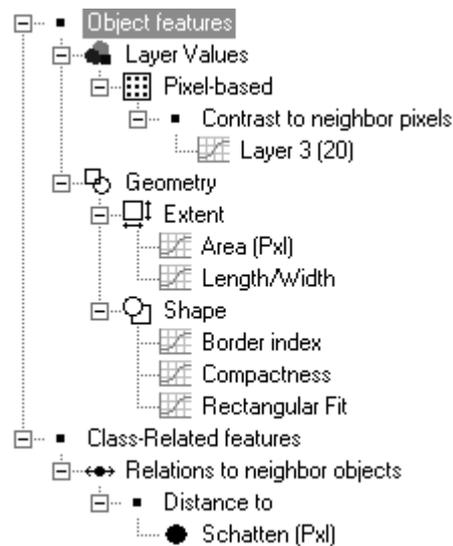


Abb. 33 Feature Space Auswahl für die erste Gebäudeklassifikation nach der zweiten Segmentierung

Die Anzahl der fehlklassifizierten Segmente lässt sich so deutlich verringern. Da ihre Anzahl aber immer noch zu hoch ist, wird auf Basis der letzten Klassifikation eine weitere Unterteilung vorgenommen. Im Feature Space werden nun lediglich Features zur Beurteilung der Form ausgewählt: Border Index, Rectangular Fit und Shape index. Die Auswahl der Samples erfolgt gezielter, damit diese in ihrer Form ihre Klasse noch eindeutiger repräsentieren. Das Ergebnis bringt eine weitere Verbesserung mit sich.

Die Gebäude sind nun bereits recht gut erkannt worden. Weshalb im nächsten Schritt eine genauere Unterteilung des Schattens vorgenommen wird, um Gebäude-Elemente von verschatteter Vegetation zu trennen. Im Feature Space (vgl. Abb 34) wird neben den zuvor benutzen Features zur Größe und Form nun die Distanz zur Klasse „Gebäude“ betrachtet, da Segmente verschatteter Gebäude im Normalfall an Gebäudesegmente angrenzen.

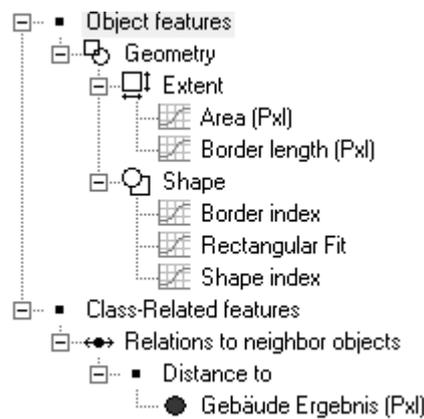
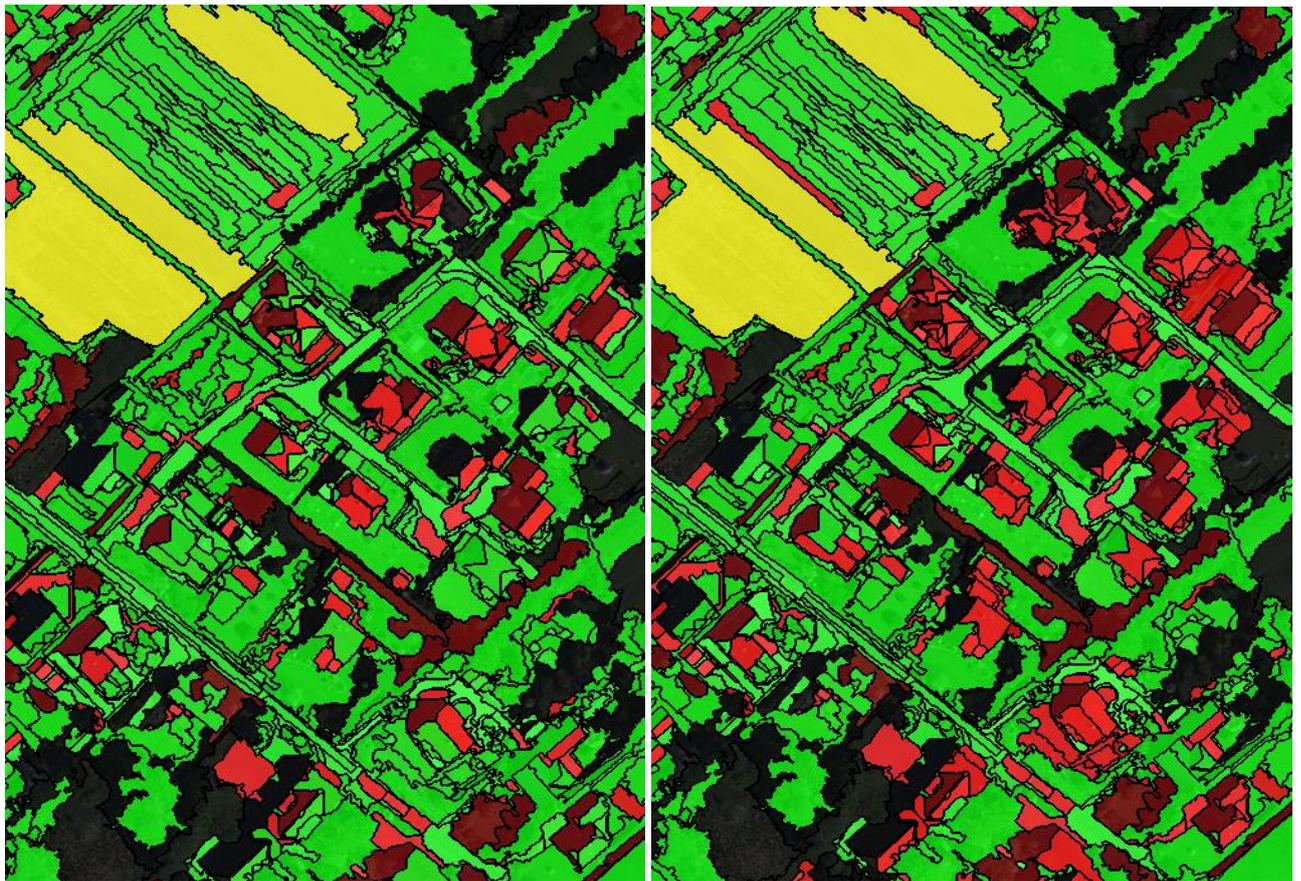


Abb. 34 Ausgewählter Feature Space zur Unterteilung von verschatteten Gebäude und verschatteter Vegetation

Das Zwischenergebnis zeigt, dass verschattete Gebäudeteile recht gut erkannt werden aber wie zuvor Teile der Vegetation als Gebäude eingestuft werden. Deshalb ist auch hier eine weitere Unterteilung nötig. Wegen der eindeutigen Form der Gebäudeteile und deren Schatten im Vergleich zum Vegetationsschatten wird im Feature Space lediglich betrachtet, wie glatt die Segmentkanten (Border Index) und wie rechteckig die Segmente (Rectangular fit) sind. Die Klassifikation ergibt auch hier eine weitere Verbesserung.

Auffallend im bisherigen Ergebnis ist, dass einige Gebäude-Objekte als Vegetation erkannt wurden, obwohl sich diese vor allem bei roten Dächern farblich deutlich von Vegetation und Brache unterscheiden. Deshalb wird eine letzte Klassifikation auf Basis der Klassen „Grüne Vegetation“, „Vegetation und Straße 1“ und „Vegetation und Straße 2“ durchgeführt. Im Feature Space werden hierzu die Features Ratio zum Layer 1 (roter Farbkanal) und der Hue-Wert (Farbwert) aus dem Hue, Saturation, Intensity Modell gewählt. Das Ergebnis wird in die Klassen „Gebäude – Rote Dächer“ und „Vegetation neu“ unterteilt. Nach der Wahl geeigneter Samples und der Ausführung der Klassifikation lässt sich das Ergebnis noch einmal deutlich verbessern.



Legend	
Active class	
●	Schatten
●	Grüne Vegetation
●	Brache
●	Gebäude
●	Gebäude - Schatten

Abb. 35 Veränderung durch den letzten Klassifikationsschritt basierend auf Farbwerten

Die Anzahl der richtig erkannten Gebäude-Objekte ist noch einmal deutlich höher. Einige Fehlklassifizierungen sind auch hinzugekommen, deren Anzahl ist aber deutlich geringer als die Anzahl der Verbesserungen.

3.1.2 Ergebnis

Das Ergebnis hat nach den einzelnen Klassifikations-Schritten keine hundertprozentige Genauigkeit, lässt sich aber auch durch die Veränderung von Features und Samples nicht weiter verbessern. Ein weiterer Kanal bzw. Layer im Infrarotbereich oder Höhendaten des Gebiets wären nötig, um das Ergebnis weiter zu verbessern. Diese Daten sind nicht vorhanden.

Durch die Klassenhierarchie (vgl. Abb. 36) ließ sich das Ergebnis im Vergleich zu den ersten Versuchen zwar deutlich verbessern, das Ergebnis zeigt bei den Gebäuden aber nicht die erhoffte Genauigkeit, da Gebäudeteile fehlen oder Einfahrten ebenfalls als Gebäude erkannt wurden.

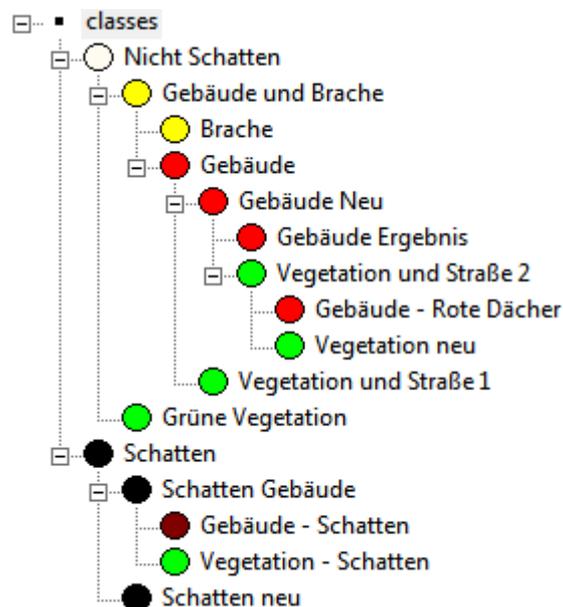


Abb. 36 Klassenhierarchie für die Klassifikation von DOP1

Problematisch sind auch die in Deutschland üblichen Spitzdächer. Hierdurch zeigt ein Häuserdach durch die unterschiedliche Ausrichtung in zwei bzw. vier Richtungen auch ebenso viele unterschiedliche Reflexionseigenschaften. Im Ergebnis sind die Dächer daher stellenweise zwar teilweise erkannt worden, aber nicht das komplette Dach.

Die Unterscheidung von Gebäuden und Straßen erweist sich ebenfalls als problematisch. Durch die rechteckige Form von Straßen-Objekten, die vor allem durch Vegetationsschatten immer wieder unterteilt werden und damit selten als größere Objekte erkannt werden, sind diese in ihrer Form Häuserdächern sehr ähnlich. Der Versuch einer weiteren Unterteilung von Straßen und Gebäuden

erweist sich daher auch als kontraproduktiv, da die Anzahl der Fehlklassifikationen dann sehr hoch ist.

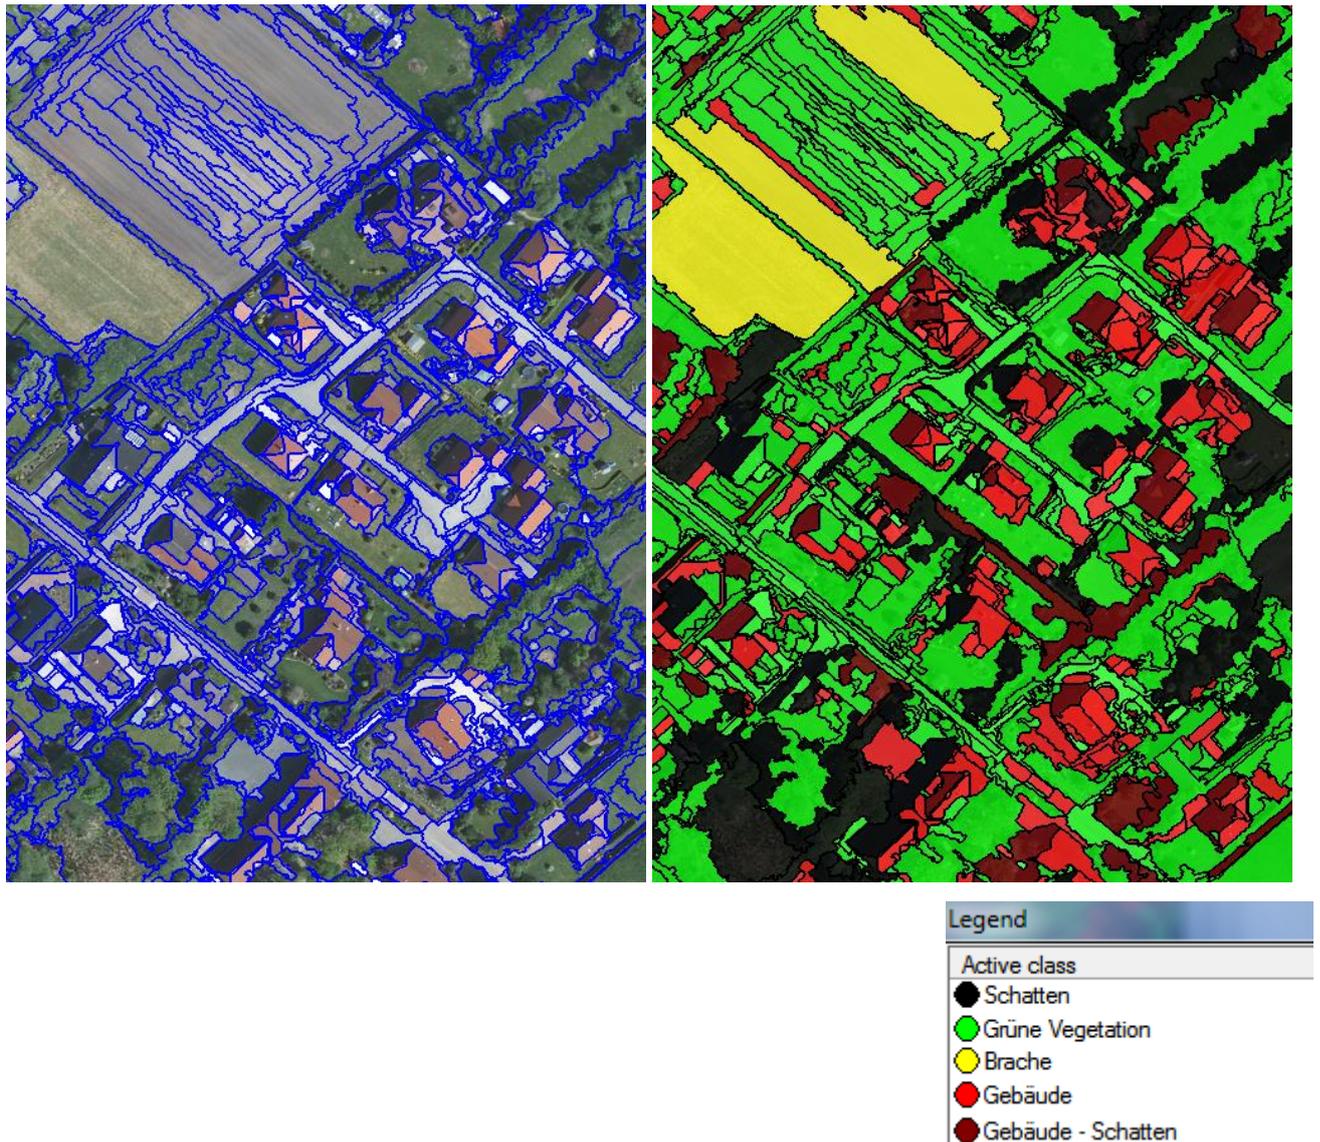


Abb. 37 Segmentierung (links) und Klassifikationsergebnis (rechts) von DOP1

Abbildung 37 zeigt einen Ausschnitt des Ergebnisses, der stellvertretend die Probleme bei der Klassifikation zeigt. So ist zu sehen, dass fast alle Gebäude (hellrot) größtenteils erkannt wurden. Von einigen Gebäuden werden aber auch die Einfahrten und Teile der sie umgebenden Grünanlagen als Gebäude klassifiziert. Auch wird ein kleiner Teil der landwirtschaftlichen Fläche im Nordwesten als Gebäude erkannt. Die verschatteten Gebäudeteile (dunkelrot) vervollständigen in mehreren Fällen die Gebäude, die Klasse beinhaltet aber auch Vegetationsschatten, vor allem im Südosten. Die Straßen befinden sich größtenteils in der zuletzt erstellten Klasse Vegetationsklasse. Eine weitere Trennung von Vegetation und Straße erweist sich als problematisch, da viele Objekte dann falsch klassifiziert werden. Positiv fällt auf, dass kaum Straßen als Gebäudeteile erkannt wurden. Da der

Schwerpunkt dieser Arbeit auf der Erkennung von Gebäuden liegt, ist eine gröbere Klassifikation der anderen Objektklassen nicht entscheidend für das Ergebnis.

3.1.3 Genauigkeit

Während in der überwachten und unüberwachten Klassifikation meist eine Genauigkeitsanalyse (Accuracy Assessment) erstellt wird, in dem eine hohe Anzahl zufällig verteilter Punkte vom Benutzer betrachtet werden, der dann jeweils die Genauigkeit bewertet, wird in der objekt-orientierten Klassifikation meist eine Maske verwendet, die als Referenz das richtige Ergebnis enthält. In diesem Fall wäre dies eine Maske mit den Gebäudeflächen, z. B. Daten aus der allgemeinen Liegenschaftskarte. Solche liegen in diesem Fall nicht vor. Die praktikabelste Lösung ist daher, die Anzahl der Gebäude zu zählen und auszuwerten, wie viele von diesen Gebäuden erkannt wurden. Da teilweise nur Gebäudeteile erkannt wurden, wird ein Gebäude als richtig erkannt gewertet, wenn mindestens 50% erkannt wurden.

Anzahl Gebäude	Min. 50% erkannt	Nicht erkannt	Ergebnis (in Prozent)
246	224	22	91%

Tab. 1 Auswertung des Ergebnisses von DOP1

Die Zählung der Gebäude ergibt, dass sich in der Szene DOP1 von 2008 insgesamt 246 Gebäude befinden. Von diesen 246 Gebäuden werden 224 mindestens zu 50% erkannt. Daraus folgt, dass 91% der Gebäude erkannt wurden, während 22 Gebäude gar nicht oder nur zu einem geringen Anteil erkannt wurden. Dabei muss allerdings bedacht werden, dass auch Objekte als Gebäude erkannt wurden, die gar keine sind. Diese Objekte werden in dieser Zählung nicht berücksichtigt. Eine Auswertung der Fehlklassifikation erweist sich als schwer umsetzbar, da dafür bekannt sein muss, wie viele Segmente insgesamt vorhanden sind und wie viele falsch erkannt wurden. Darüber hinaus muss dann auch beachtet werden, dass sich die Segmente in ihrer Größe deutlich unterscheiden, weshalb auch die Fläche der Segmente in die Bewertung einfließen müsste. eCognition Developer bietet hierfür keine Funktion, mit der so eine Auswertung möglich ist. Eine Lösung wäre der Export der Klassen im Shape- oder Rasterformat und eine Auswertung z. B. in ArcGIS. Dies ist aber nicht Bestandteil dieser Arbeit.

3.2 DOP2 (2002)

Auch dieses Orthophoto verfügt über drei Kanäle (rot, grün und blau – RGB), hat aber im Vergleich zum DOP1 nur eine Bodenpixelauflösung von 1 Meter. Durch die geringere Auflösung und den Unterschieden in Kontrast und Schattenwurf (vgl. Anhang I und II) muss sich zeigen, wie gut sich die Erfahrungen der Klassifikation von DOP1 auf DOP2 übertragen lassen.

3.2.1 Segmentierung und Klassifikation

Die Erfahrungen der Klassifikation von DOP1 zeigen, dass es sinnvoll ist, bei DOP2 von vornherein die gleiche Vorgehensweise zu verwenden: Segmentierung, Teilklassifikationen, feine Segmentierung und weitere Teilklassifikationen bis zum Ergebnis.

Durch die geringere Auflösung lassen sich die Segmentierungsparameter der ersten Klassifikation nicht übernehmen. Um ein ähnlich gutes Ergebnis zu erhalten, wird der Parameter Scale auf 75 gesetzt, Shape auf 0,5 und Compactness auf 0,1. Dennoch zeigen sich durch die geringe Auflösung Unterschiede in der Segmentierung.



Abb. 38 Vergleich der groben Segmentierung von DOP1 (2008, links) und DOP2 (2002, rechts)

Als erstes wird auch hier durch die Klassifikation „Schatten“ und „Nicht-Schatten“ über die Helligkeit (Brightness) getrennt. Im Vergleich zum DOP1 sind durch die Aufnahmebedingungen die Schattenflächen deutlich größer und beinhalten mehr Gebäudeteile die später noch vom Schatten getrennt werden müssen.

Auch die Unterteilung der Klasse „Nicht-Schatten“ in „Grüne Vegetation“ und „Gebäude und Brache“ erfolgt analog zu DOP1 mit identischem Feature Space. Im Gegensatz zum DOP1 kann hier bereits die Klasse „Gebäude und Brache“ als Basis für die feine Segmentierung verwendet werden, da bedingt durch die geringere Auflösung und den höheren Kontrast die Klasse „Grüne Vegetation“ bereits einen Großteil der landwirtschaftlichen Flächen beinhaltet. Durch die anderen Bedingungen sind die optimalen Parameter für die feine Segmentierung nicht so eindeutig zu bestimmen wie beim DOP1, weshalb mit zwei Segmentierungen experimentiert wird (vgl. Abb. 39).

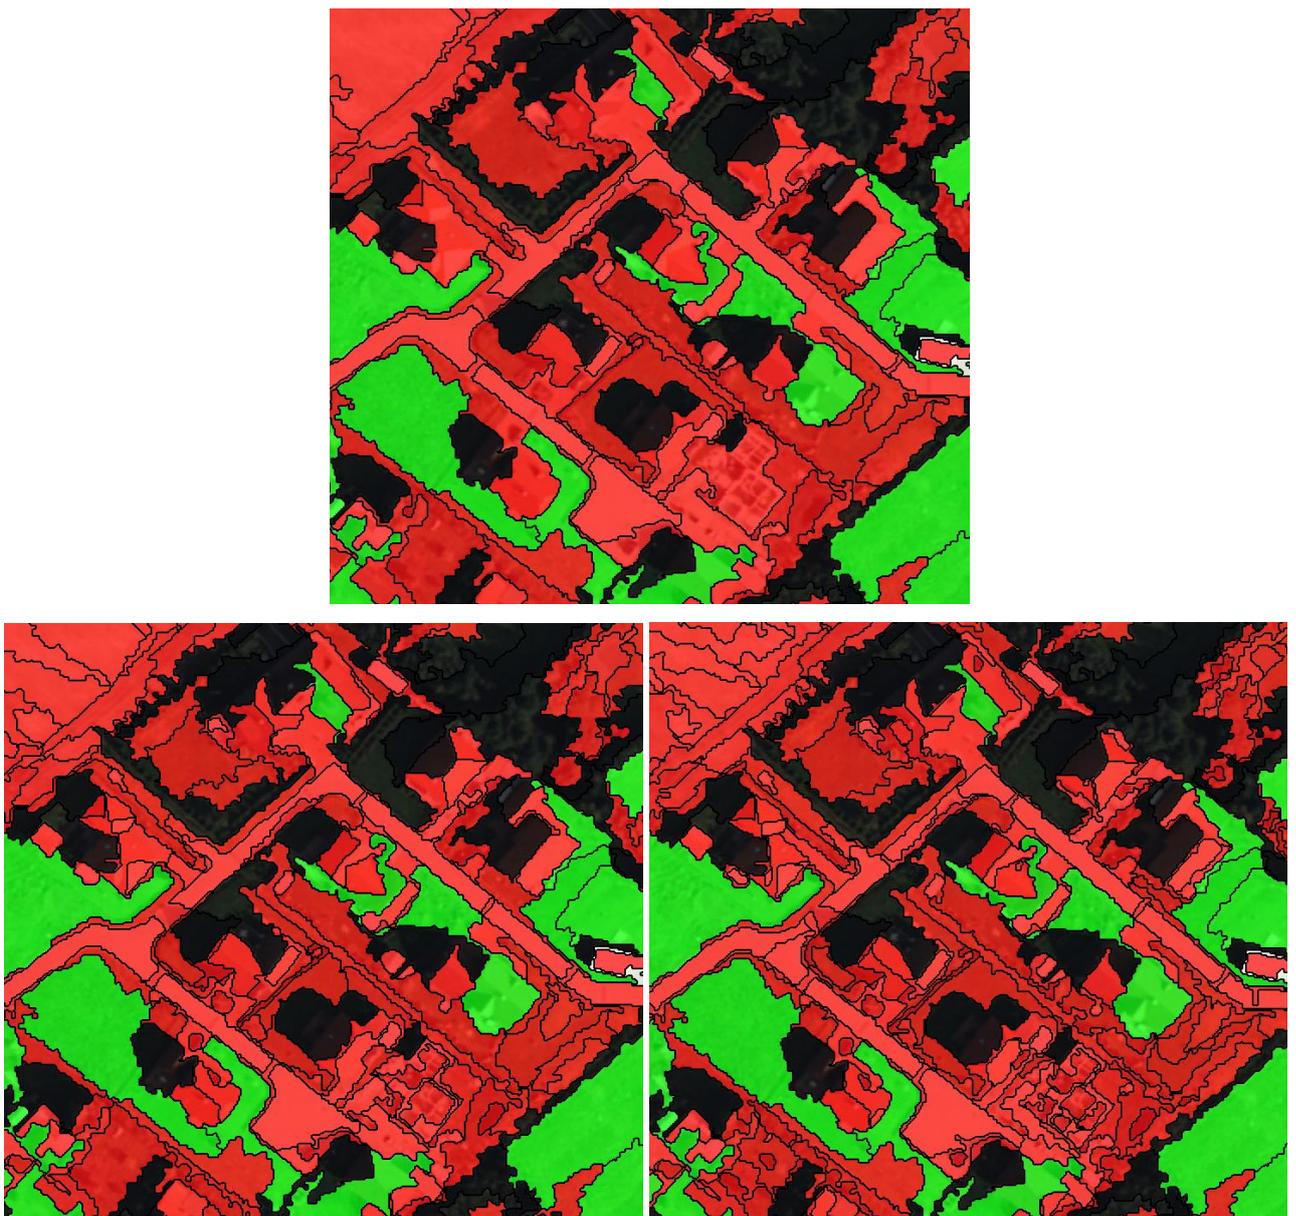


Abb. 39 Vergleich der groben Segmentierung (oben) mit der ersten (unten links) und zweiten (unten rechts) feinen Segmentierung von DOP2

Segmentierung 1 (Scale 40, Shape 0,5, Compactness 0,1) ist etwas gröber, was letztendlich für ein Ergebnis sorgt, in dem zwar kaum Vegetations-Segmente als Gebäude erkannt, aber auch viele Gebäude-Segmente gar nicht erkannt werden.

Die zweite Segmentierung (Scale 35, Shape 0,4, Compactness 0,1) ist feiner, wodurch die Gebäude deutlich besser erkannt werden aber auch die Fehler zunehmen. Da die Gebäude hier Priorität haben, wird im Folgenden mit der zweiten Segmentierung weitergearbeitet.

Nun werden die weiteren Klassifikationsschritte analog zu DOP1 mit der gleichen Auswahl im Feature Space (vgl. Abb. 33) vorgenommen. Zunächst erfolgt die Trennung von „Gebäude und Brache“ in zwei einzelne Klassen für „Gebäude“ und „Brache“. Die Gebäudeklasse wird nun noch einmal unterteilt. Im Gegensatz zum DOP1 ist dies hier allerdings bedingt durch die anderen Bildeigenschaften in einem Schritt möglich. Als Features werden hier lediglich Border Index und Rectangular fit ausgewählt.

Auch der Schatten wird nun analog zum DOP1 weiter unterteilt. Zunächst in die Klassen „Schatten neu“ und „Schatten Gebäude“. Danach wird „Schatten Gebäude“ auch hier in „Gebäude – Schatten“ und „Schatten – Vegetation“ unterteilt.

Im letzten Schritt folgt die Klassifikation der roten Dächer über die Features Ratio und Hue, Intensity, Saturation auf Basis der Klassen „Grüne Vegetation“ und „Vegetation und Straße“. Als Ergebnis entstehen die Klassen „Gebäude – Rote Dächer“ und „Vegetation neu“.

Die Klassenhierarchie (vgl. Abb. 39) entspricht damit weitestgehend der von DOP1.

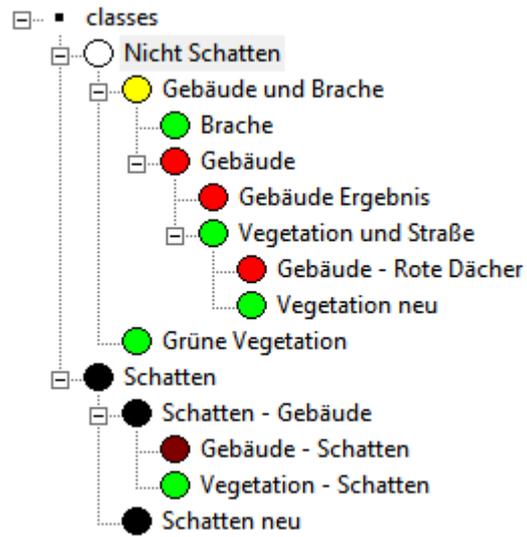


Abb. 40 Klassenhierarchie von DOP2

Wie beim DOP1 ist auch hier keine weitere Verbesserung in der Erkennung von Gebäuden durch Anpassung des Feature Space möglich.

3.2.2 Ergebnis

Das Ergebnis beim DOP2 ist insgesamt nicht so genau wie das Ergebnis von DOP1. Hier zeigen sich die Nachteile der geringeren Auflösung und auch der größere Schattenwurf erweist sich als problematisch. Auch hier liegen keine Infrarot- oder Höhendaten vor, um das Ergebnis verbessern zu können.

Die Problembereiche sind hier ebenfalls ähnlich, aber stärker ausgeprägt.



Abb. 41 Segmentierung (links) und Klassifikationsergebnis (rechts) von DOP2. Legende siehe Abbildung 40.

Abbildung 41 zeigt stellvertretend die Probleme bei der Klassifikation von DOP2. Im Vergleich zu DOP1 fällt als erstes auf, dass häufig Objekte, die an Häuser angrenzen, als Brache erkannt worden sind. Dies liegt wahrscheinlich in der etwas anderen Unterteilung der Klassenhierarchie und der unterschiedlich feinen Segmentierung begründet. Für die Betrachtung der Gebäude ist aber auch hier die Genauigkeit im Bereich Vegetation und Brache nicht bedeutend.

Die Klasse Gebäude (hellrot) zeigt, dass häufiger Teile der Vegetation als Gebäude erkannt wurden. Dies ist vor allem in der landwirtschaftlichen Fläche im Nordwesten zu sehen, die im Vergleich zum DOP1 deutlich mehr Fehlklassifikationen enthält. Auch ist hier die Unterteilung von Gebäuden und Straßen deutlich schlechter ausgefallen. Genauso fällt auch die Erkennung der Gebäude an sich schlechter aus. So werden von mehreren Gebäuden lediglich kleine Teile erkannt, z. B. bei einem Gebäude im östlichen Bereich. Die Einbeziehung der Gebäudeschatten (dunkelrot) sorgt auch hier für eine Verbesserung des Ergebnisses. Die Zahl der falsch erkannten Vegetationsschatten ist zudem deutlich geringer als beim DOP1.

3.2.3 Genauigkeit

Zur Bewertung der Genauigkeit wurde hier dieselbe Vorgehensweise wie beim DOP1 verwendet. Da die Aufnahme, die DOP2 zeigt, von 2002 stammt und damit sechs Jahre früher als DOP1 aufgenommen wurde, gibt es in der Anzahl der Gebäude kleine Unterschiede. So wurden in den sechs Jahren drei Gebäude abgerissen und zwölf sind hinzugekommen. Die Gesamtanzahl beläuft sich somit auf 237 Gebäude. Von diesen 237 wurden 205 mindestens zu 50% erkannt. Daraus folgt, dass 86,5% der Gebäude erkannt wurden.

Anzahl Gebäude	Min. 50% erkannt	Nicht erkannt	Ergebnis (in Prozent)
237	205	32	86,5%

Tab. 2 Auswertung des Ergebnisses von DOP2

Auch hier muss wie beim DOP1 bedacht werden, dass sich die falsch als Gebäude erkannten Segmente nicht im Ergebnis von 86,5% widerspiegeln. Da hier noch mehr Fehlklassifikationen als bei der 2008er Szene vorhanden sind, muss das Ergebnis von daher unbedingt unter diesem Gesichtspunkt betrachtet werden.

3.3 Vergleich und Analyse

Im letzten Teil dieser Arbeit werden die beiden Ergebnisse verglichen. Hierbei wird noch einmal die Genauigkeit betrachtet und beurteilt, inwiefern die Ergebnisse dazu geeignet sind, Veränderungen an den Gebäuden zu erkennen.

3.3.1 Vorgehensweise

Zum Vergleich der Ergebnisse müssen diese zunächst jeweils aus den eCognition Projekten zu DOP1 und DOP2 exportiert werden um dann gemeinsam in einem neuen Projekt betrachtet zu werden. Da es hier in erster Linie um die Gebäude geht, wurden jeweils nur die Gebäudeklassen als Rasterdatei exportiert. Alle anderen Klassen sind damit schwarzer Hintergrund und werden in der Auswertung einfach als „Keine Gebäudeklasse“ gesehen.

Nach dem Import der beiden Ergebnisse befinden sich diese in jeweils einem Layer bzw. Level. Jeder Level muss nun zunächst noch einmal segmentiert werden, um die Gebäudeklassen vom Hintergrund zu trennen, da sich die Segmentierung nicht zusammen mit der Klassifikation exportieren lässt. Die Segmentierung erweist sich hier als relativ simpel, da die Flächen stets einfarbig sind und der Kontrast zum Hintergrund groß ist. So werden die Parameter „Shape“ und „Compactness“ jeweils auf 0,1 gesetzt. Der „Scale“-Parameter für das DOP1-Ergebnis wird auf 50 gesetzt, beim DOP2-Ergebnis (bedingt durch die geringere Auflösung) auf 25.

Als nächstes werden beide Segmentierungen klassifiziert, um die Klassen „Gebäude“ und „Hintergrund“ zu erhalten. Durch die simplen Eigenschaften des Ergebnisses reicht es hier, im Feature Space das Feature „Brightness“ zu wählen. Nach diesen beiden Klassifikationen erfolgt der eigentliche Vergleich.

Beim Vergleich wird betrachtet, inwiefern sich die beiden Ergebnisse unterscheiden. Was ist hinzugekommen, was ist nicht mehr da und was ist gleich geblieben. Durch die unterschiedlichen Ergebnisse muss dieser Vergleich in beide Richtungen ausgeführt werden: Da jeweils auf Basis der Klassifikation von der Gebäude-Klasse ausgehend geprüft wird, was sich dort im anderen Ergebnis bzw.

Layer befindet, bringt der Vergleich DOP1-DOP2 ein anderes Ergebnis als der Vergleich DOP2-DOP1. Gewisse Bereiche würden sonst gar nicht betrachtet werden.

Für die Vergleiche DOP1-DOP2 und DOP2-DOP1 werden jeweils drei Klassen erstellt: „Unverändert“, „Neu“ und „Weg“. Für die Auswahl der Samples müssen dann jeweils die passenden Segmente der jeweiligen Gebäude-Klassifikation gewählt werden. Hierzu muss zwischen beiden Ergebnissen hin- und hergeschaltet werden, um zu sehen, was „Unverändert“ (in beiden Ergebnissen) bzw. „Neu“ (nicht in diesem Ergebnis, aber im anderen) oder „Weg“ (nur im anderen Ergebnis, aber nicht in diesem) ist. Da diese Unterschiede eindeutig sind, ist für jede Klasse ein Sample vollkommen ausreichend.

Für beide Vergleiche wird nun jeweils eine Klassifikation ausgeführt. Dazu wird jeweils ein Ergebnis und dessen Gebäude-Klassifikation ausgewählt. Im Feature Space wird dann das Feature „Ratio to Scene“ ausgewählt und dort jeweils der andere Layer gewählt, also der, der gerade nicht klassifiziert wird. Das Ergebnis zeigt dann für jede Klassifikation die Unterschiede und Übereinstimmungen, jeweils in drei Klassen eingeteilt.

3.3.2 Ergebnis und Bewertung

Das Ergebnis der Vergleiche ist schlechter als es nach der Betrachtung der beiden Klassifikationen zu erwarten war.

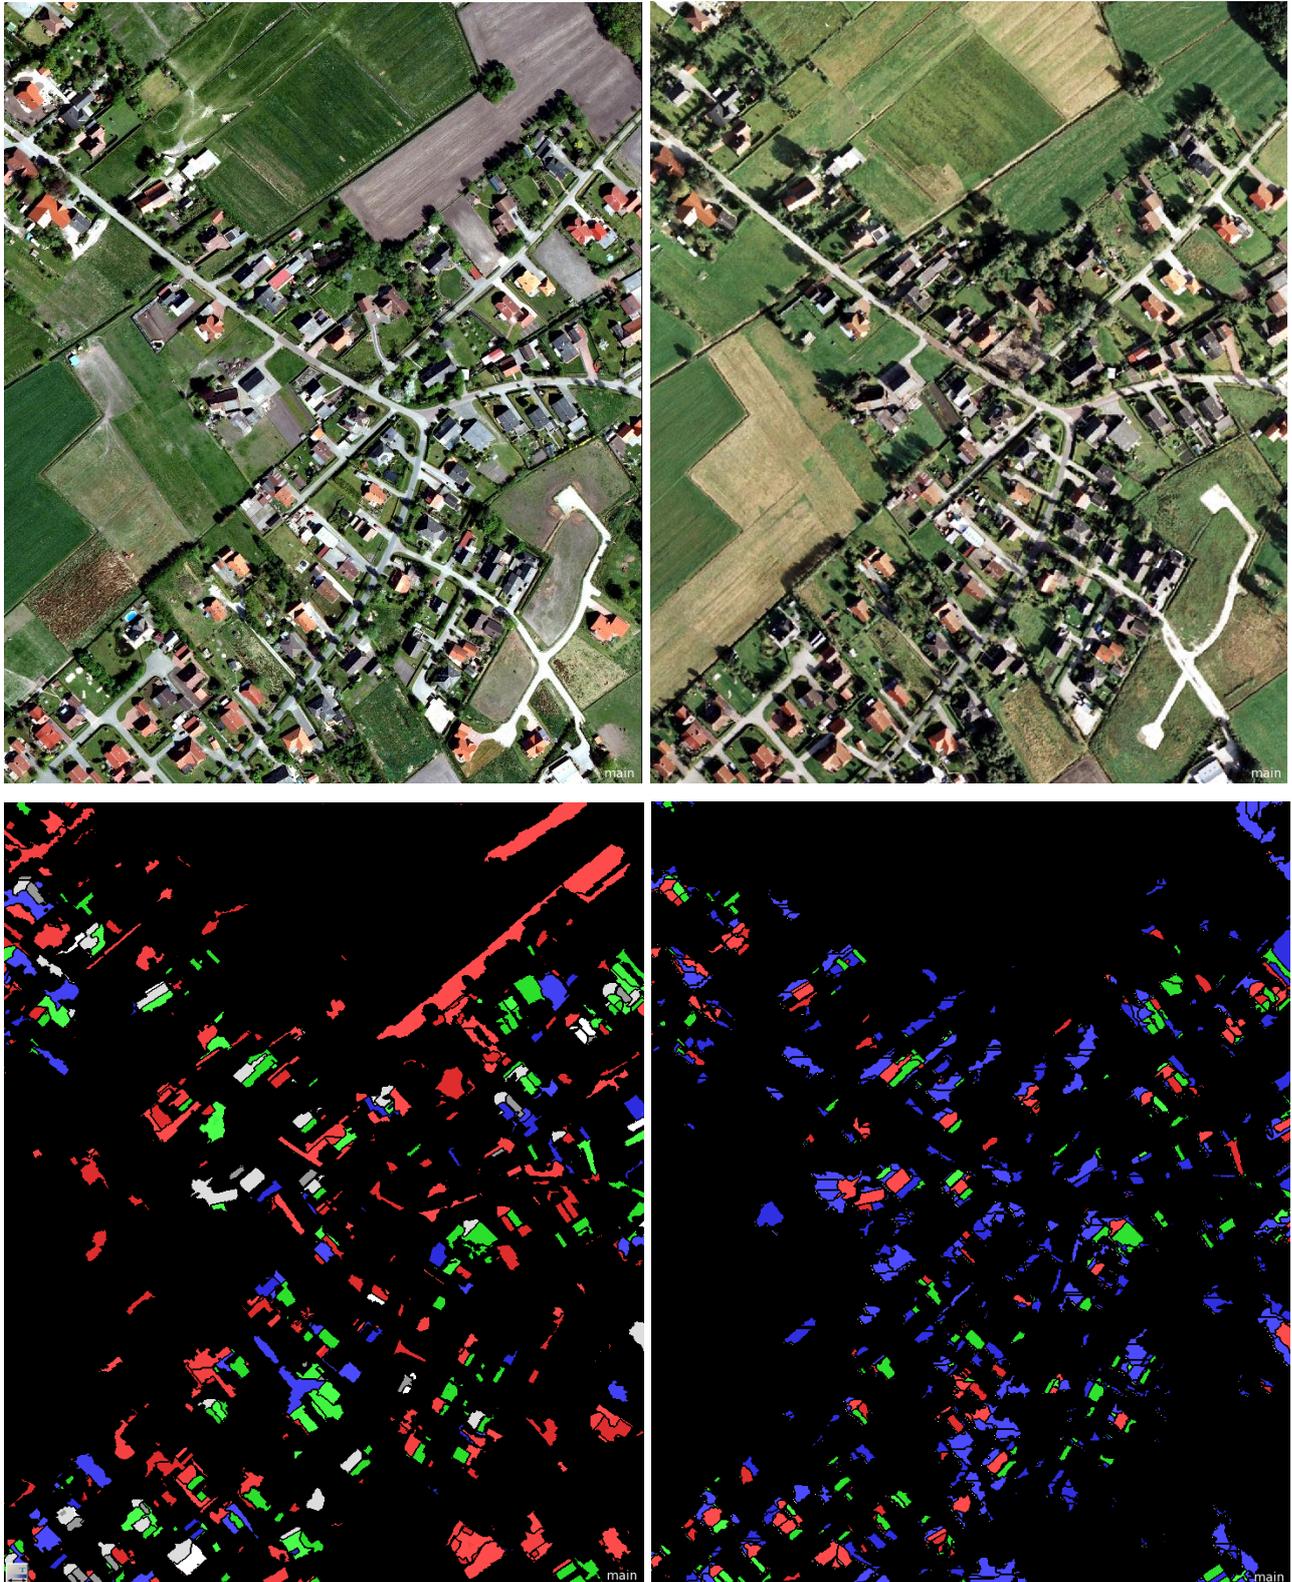


Abb. 42 Ergebnis des Vergleichs mit den Referenzen DOP1 (oben links) und DOP2 (oben rechts) und den Ergebnissen der Vergleiche DOP1-DOP2 (unten links) und DOP2-DOP1 (unten rechts).

Farben: rot=neu, blau=weg, grün=unverändert

So erweist sich bei der Betrachtung der Ergebnisse (vgl. Abb. 42) vor allem die Vegetation, die falsch als Gebäude erkannt wurde als problematisch. Der Vergleich DOP1-DOP2 bewertet viele Flächen als neu, bei denen es sich in Wahrheit um Vegetation handelt. Das größte Problem ist die unterschiedliche Segmentierung der beiden Ergebnisse, da sich selbst in der Klassifikation von DOP2 noch die geringere Auflösung der Ursprungsdaten widerspiegelt. Auch wird der Hintergrund nicht als ein Segment angesehen, sondern in viele kleine Segmente eingeteilt. Dies ist aber nicht zu vermeiden, weil bei einer gröberen Segmentierung die Gebäude nicht deutlich vom Hintergrund getrennt werden. So treffen beim Vergleich der Ergebnisse Segmente der Gebäudeklassifikation des einen Layers auf unterschiedlich große Segmente des anderen Layers. Teilweise liegen mehrere Gebäudeobjekte in einem Segment des anderen Layers, wodurch es bei der Auswertung zu Problemen kommt. Im Vergleich DOP1-DOP2 sind daher weiße Flächen zu sehen, wo eine eindeutige Zuordnung in der automatischen Auswertung nicht möglich war. Die meisten dieser Flächen müssten rot sein. Dies ist jedoch kein Fehler, der beim automatischen Vergleich entstanden ist.

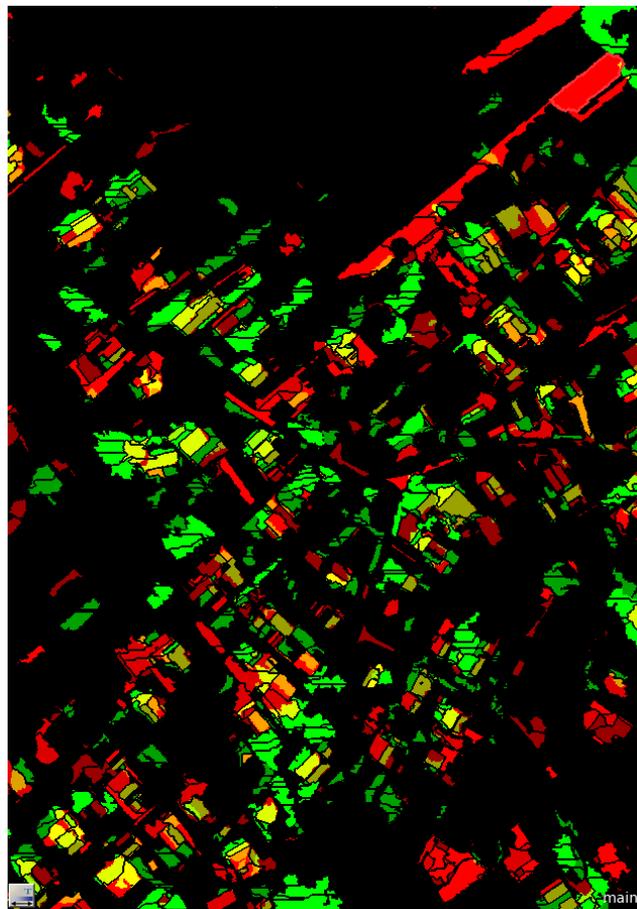


Abb. 43 Manueller Vergleich durch Layerdarstellung. Rötliche Farbtöne gehören zu DOP1, grünliche zu DOP2. Gelbliche Farbtöne zeigen Flächen, die in beiden Ergebnissen vorhanden sind.

Abbildung 43 zeigt einen manuellen Vergleich, in dem beide Ergebnisse in eCognition geöffnet wurden. DOP1 wird im grünen Kanal angezeigt, DOP2 im roten Kanal. Dadurch ergeben sich gelbliche Flächen in den Bereichen, wo beide Ergebnisse identisch sind. Ein optischer Vergleich mit den beiden Ergebnissen in Abbildung 42 zeigt, dass die Auswertung richtig vorgenommen wurde.

Das Ergebnis der automatischen Auswertung (vgl. Abb. 42) zeigt durchaus richtige Resultate. So wurden z. B. die neuen Gebäude im Südosten beim DOP1-DOP2-Vergleich korrekt erkannt. Die Anzahl der grünen, also unveränderten Flächen müsste aber deutlich größer sein. Das Problem ist, dass hier bereits kleine Unterschiede in den Klassifikationen schon ausreichen, um eine richtige Erkennung schwer bis unmöglich zu machen. Die Voraussetzungen für ein gutes Ergebnis sind daher mit den gegebenen Daten nur bedingt gegeben.

Für ein möglichst gutes Ergebnis sollten daher die Bilddaten die gleiche Bodenpixelauflösung haben und einen möglichst ähnlichen Sonnenstand. Darüber hinaus würde ein weiterer spektraler Kanal im nahen Infrarotbereich bereits ausreichen, um die Vermischung von Gebäuden und Vegetation deutlich zu reduzieren. Ebenfalls zur Verbesserung beitragen würden Höhendaten des Untersuchungsgebietes. Durch deren Auswertung könnte nicht nur die Höhe sondern auch die Form der Objekte bestimmt werden, da Gebäudeoberflächen eine deutlich regelmäßigere Form haben als Vegetation.

In dieser Form ist zwar die Erkennung der Gebäude relativ erfolgreich gelungen, der Vergleich der beiden Ergebnisse ist durch die unterschiedlichen Bedingungen aber nur sehr eingeschränkt brauchbar.

4 Zusammenfassung und Fazit

Die Auswertung und Klassifikation der Orthophotos über das objekt-orientierte Verfahren hat gezeigt, dass unter den gegebenen Bedingungen relativ gute Ergebnisse möglich sind, die sich durch bessere Voraussetzungen und zusätzliche Daten noch weiter verbessern ließen.

Bei der Segmentierung der Bilddaten erweist sich von den vorgestellten Methoden nur die Multiresolution Segmentation als brauchbar, da die anderen Methoden zu stark auf festen Rastern basieren. Die vorgestellten Funktionen des Feature Space haben meist die gewünschten Ergebnisse in den jeweiligen Einsatzgebieten gebracht. Bemerkenswert ist, dass oft die einfachen Methoden wie z. B. Brightness, Area und Rectangular Fit die deutlichsten und besten Ergebnisse hervorbringen.

Die eigentliche Klassifikation zeigt, dass Erfahrungen aus der überwachten und unüberwachten Klassifikation nur schwer oder gar nicht auf die objekt-orientierte Klassifikation übertragbar sind. So liegen auch die Probleme an völlig anderen Stellen. Während bei den pixelbasierten Klassifikationen oft einzelne Pixel falsch klassifiziert werden, die dann über Filter und den Nachbarschaftsbedingungen ausgeglichen werden müssen, sind hier durch das völlig andere System immer ganze Objekte betroffen. Deshalb sind die Problembereiche bei den unterschiedlichen Klassifikationsarten völlig anders verteilt.

Beim Vergleich der Ergebnisse fällt in erster Linie auf, wie stark sich die Unterschiede in der Bodenpixelauflösung und der andere Sonnenstand auf das Ergebnis auswirken. Idealerweise sollten die Bilddaten daher möglichst ähnliche Eigenschaften haben, um ein gutes Ergebnis zu bekommen.

Die Erkennung der Gebäude an sich hat besonders bei DOP1 ein gutes Ergebnis hervorgebracht. 91% der Gebäude wurden mindestens zur Hälfte erkannt. Bei DOP2 wurden immerhin noch 86,5% erkannt. Das größte Problem ist hier letztendlich vor allem beim Vergleich der Ergebnisse die irrtümlich als Gebäudeobjekte erkannten Teile der Vegetation. Mit einem zusätzlichen spektralen Kanal im Infrarotbereich sollten sich diese Probleme aber schnell beseitigen lassen und das Ergebnis des Vergleichs deutlich genauer werden.

Auch hat sich gezeigt, dass sich die Erfahrungen der Klassifikation von DOP1 recht gut auf DOP2 übertragen lassen. Gewisse Anpassungen waren vor allem bei der Segmentierung nötig. Dies liegt in

der unterschiedlichen Auflösung der Bilder begründet. Bei gleichen Bedingungen sollten sich auch diese Werte übertragen lassen. Die Auswahl der gleichen Features bringt auch die erwarteten, ähnlichen Ergebnisse und sollte sich gut auf andere, ähnliche Klassifikationen übertragen lassen. Dies gilt ebenfalls für den hierarchischen Aufbau der Klassen und die weitere, feine Segmentierung.

Letztendlich zeigt der automatisierte Vergleich der Ergebnisse, dass es unter diesen Bedingungen nicht möglich ist, neue Gebäude zuverlässig zu erkennen. Hierfür müsste das Ergebnis genauer sein und die Bilddaten ähnlicher.

Zusammenfassend lässt sich sagen, dass unter den folgenden Bedingungen eine objekt-orientierte Klassifikation zu sehr guten Ergebnissen führen kann:

1. Eine möglichst hohe geometrische Auflösung. Diese sollte bei allen Bilddaten identisch sein
2. Ähnliche Aufnahmezeitpunkte und ähnlicher Sonnenstand, um einen ähnlichen Schattenwurf zu bekommen
3. Spektrale Kanäle nicht nur im sichtbaren RGB-Bereich, sondern auch im nahen Infrarot
4. Wenn möglich auch Höhendaten um die Genauigkeit zu erhöhen

Unter diesen Bedingungen bietet der objekt-orientierte Ansatz sehr gute Möglichkeiten für eine genaue Klassifikation.

Abschließend ist das Ergebnis dieser Arbeit unter den genannten Bedingungen durchaus als gut zu bewerten. Auch ist es unwahrscheinlich, dass eine pixelbasierte Klassifikation ein besseres Ergebnis hervorgebracht hätte. So kamen (ETTARID ET AL., 2008) bei einem Vergleich der pixelbasierten und objekt-orientierten Vorgehensweise bei der Erkennung von Gebäuden zu dem Ergebnis, dass der objektorientierte Ansatz eine deutliche Verbesserung darstellt. Auch (SHACKELFORD ET AL., 2003) kamen bei ihrer Beurteilung zu dem Potential der objekt-orientierten Klassifikation zu dem Ergebnis, dass diese im Vergleich zum pixelbasierten Ansatz eine detailliertere Klassifikation in urbanen Gebieten ermöglicht.

Die objekt-orientierte Klassifikation ist ein relativ neuer Ansatz, der gerade erst anfängt, sein Potential zu zeigen. Erst bei einer Etablierung dieses Systems wird es in größerem Umfang verwendet werden und dann seine Möglichkeiten und Vorteile im praktischen Gebrauch zeigen.

5 Literatur

Publikationen

de Lange, N. (2006): *Geoinformatik in Theorie und Praxis*, 2. Auflage, Springer Verlag Berlin Heidelberg

Campbell, J. B., Wynne, R. H. (2011): *Introduction to Remote Sensing*, 5. Auflage, The Guilford Press

Lillesand, T. M., Kiefer, R. W., Chipman, J. W. (2008): *Remote sensing and image interpretation*, 6. Auflage, John Wiley & Sons.

Newell, J., Pontus, O. (ohne Jahr): *eCognition Tutorial: Classifying a Quickbird Image*, Dept. of Geography and Environment, Boston University

Stoinski, S. (2007): *Klassifizierung von Waldgebieten aus CIR-Luftbildern*. Diplomarbeit, Technische Universität Berlin.

Ettarid, M., Rouchdi, M., Labouab, L. (2008): *Automatic extraction of buildings from high resolution satellite images*, Department of Cartography and photogrammetry – Institut Agronomique et Vétérinaire Hassan II

Shackelford, A., Davis, C. H. (2003): *A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas*, IEEE Transaction on geoscience and remote sensing, Vol. 41, No. 10.

Darwish, A., Leukert, K., Reinhardt, W. (ohne Jahr): *Image Segmentation for the Purpose Of Object-Based Classification*. GIS Lab, University of the Bundeswehr Munich

Trimble Documentation (2010a): *eCognition Developer 8.64.0 – User guide*

Trimble Documentation (2010b): *eCognition Developer 8.64.0 – Reference Book*

Internetquellen

Geoinformatik-Service, Uni Rostock

<http://www.geoinformatik.uni-rostock.de/einzel.asp?ID=1410> vom 01.06.2012

Lexikon der Fernerkundung: Merkmalsraum

<http://www.fe-lexikon.info/lexikon-m.htm#merkmalsextraktion> vom 02.06.2012

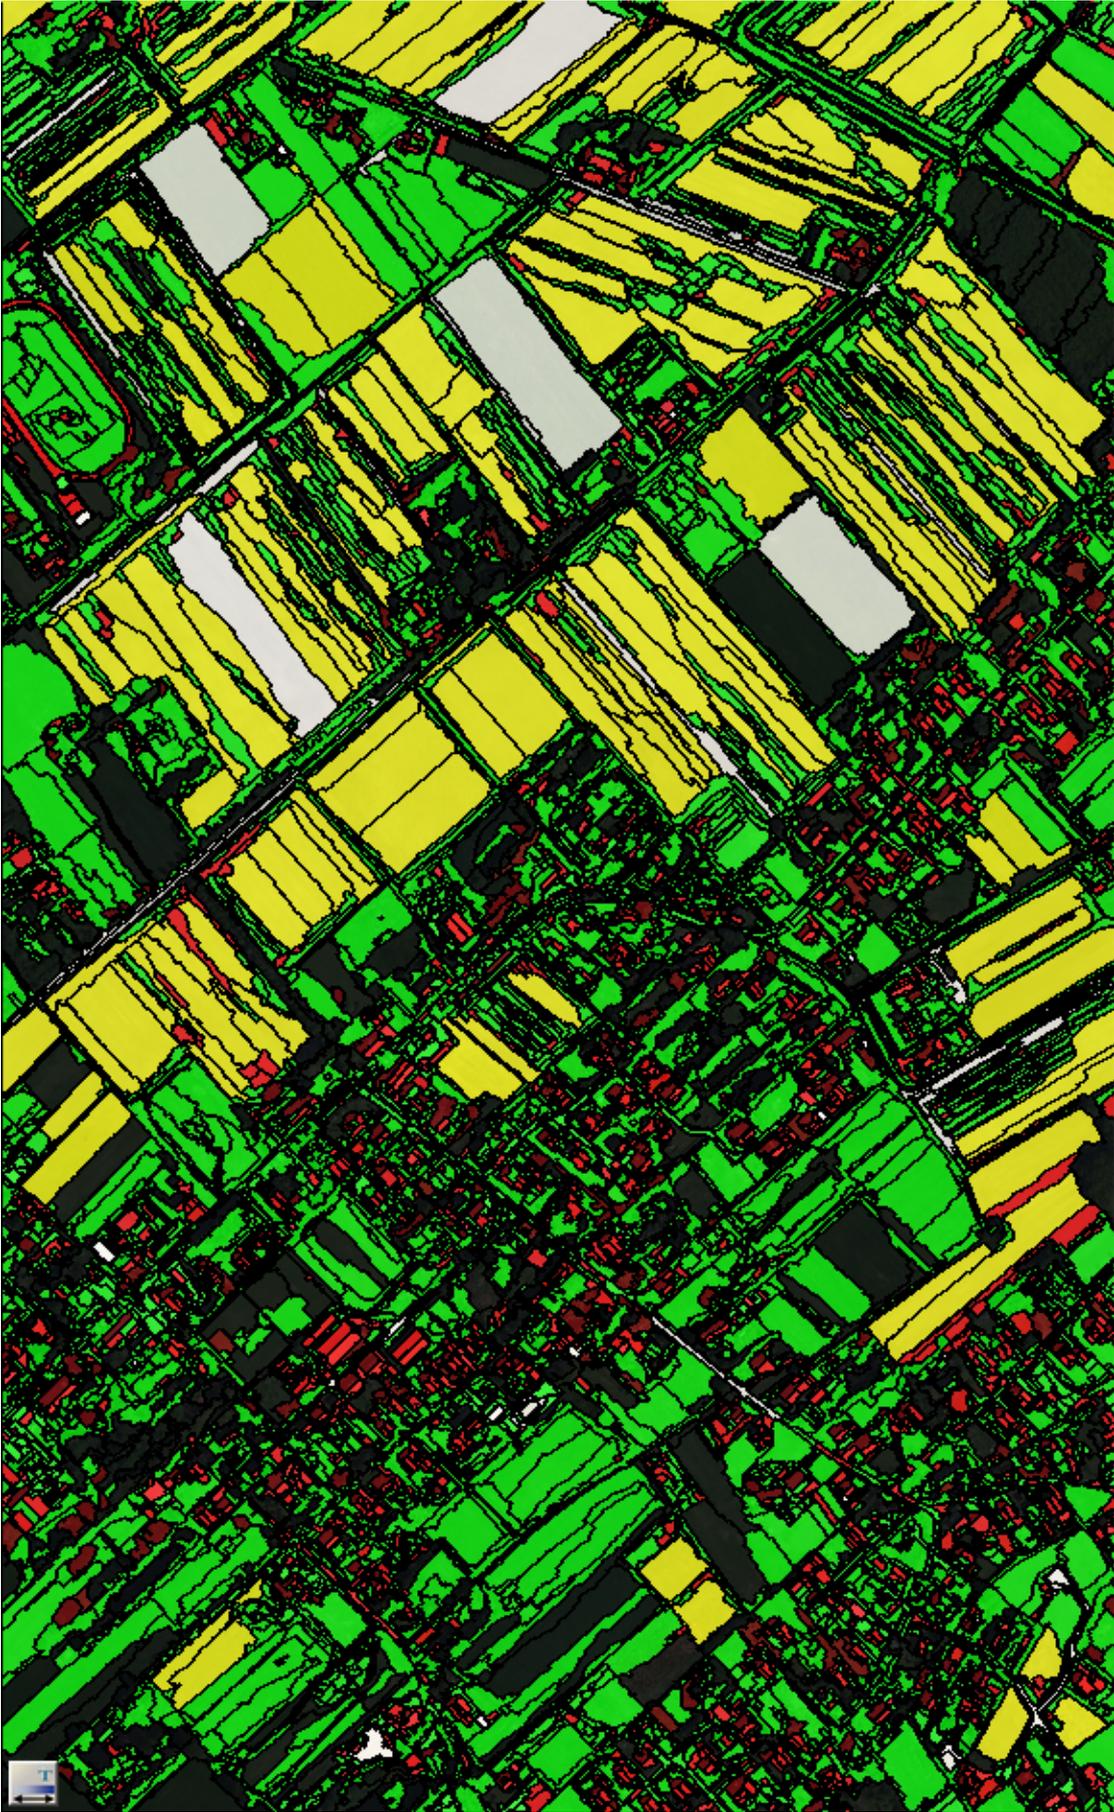
Anhang I - DOP1 (2008)



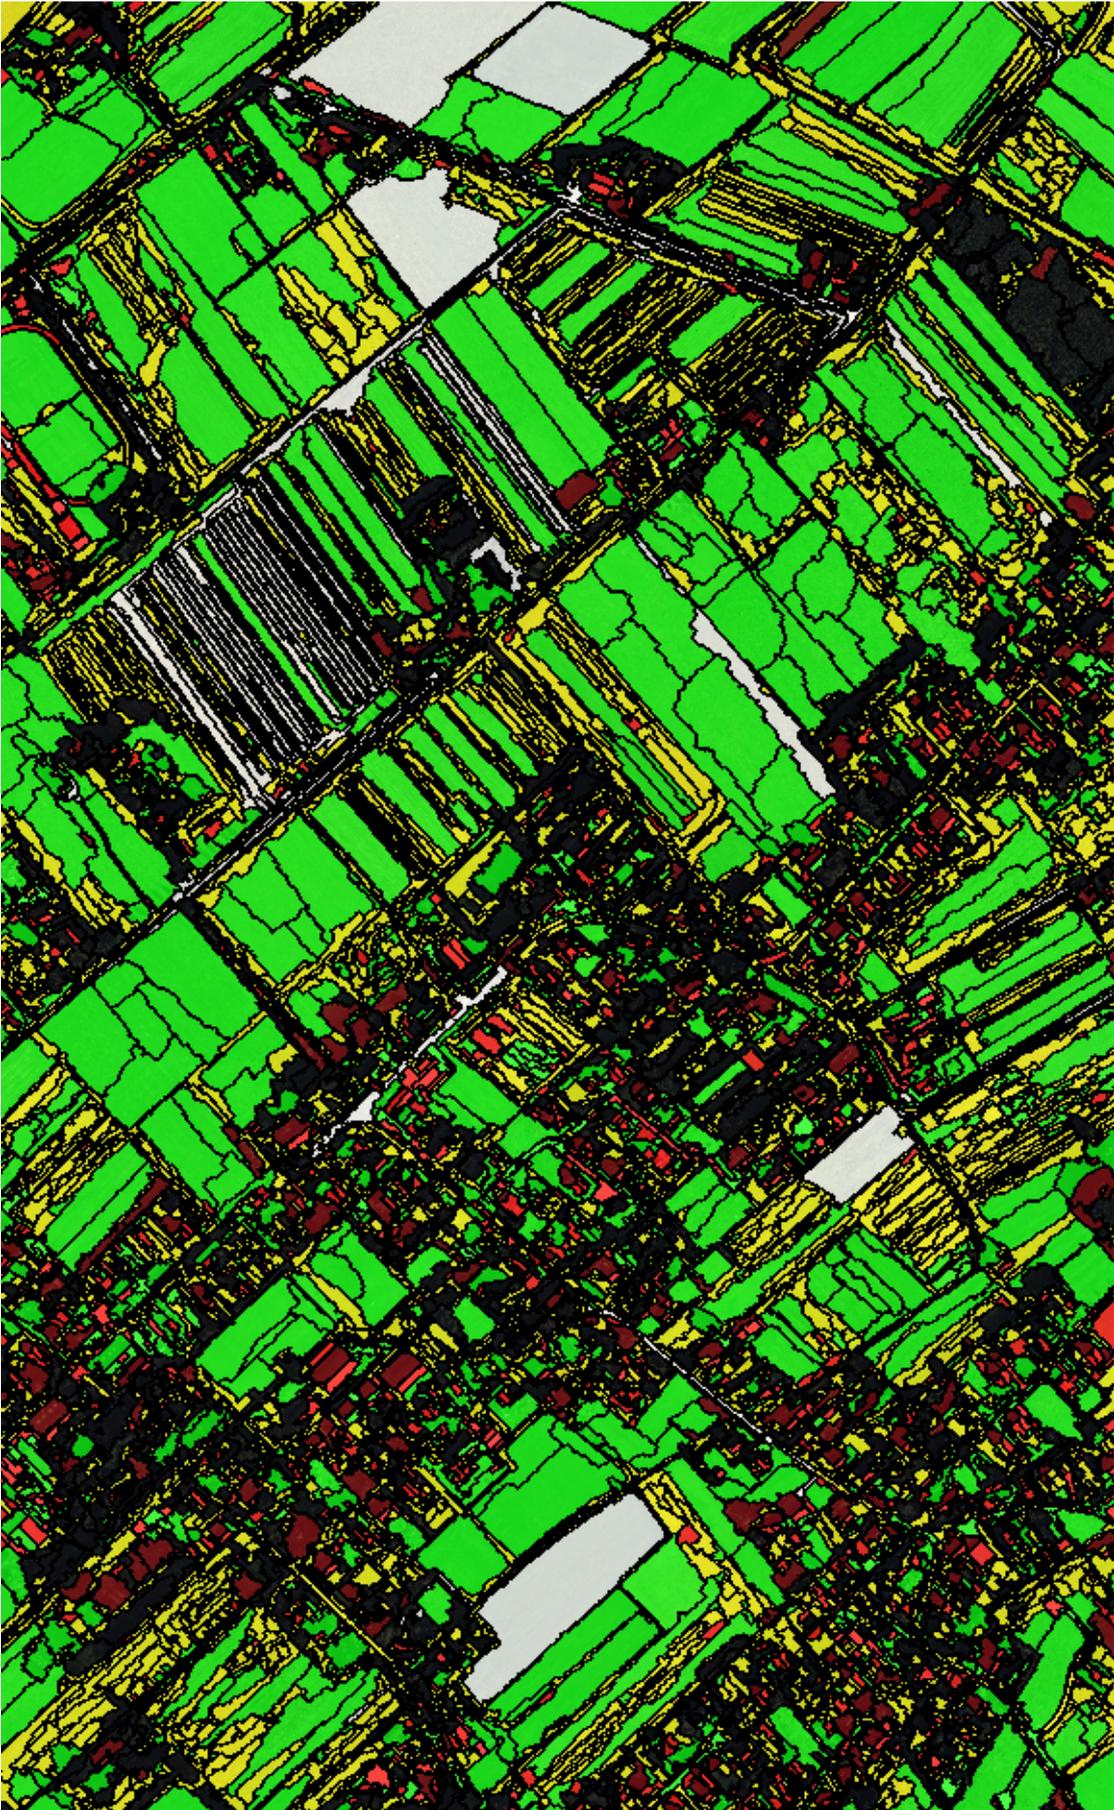
Anhang II – DOP2 (2002)



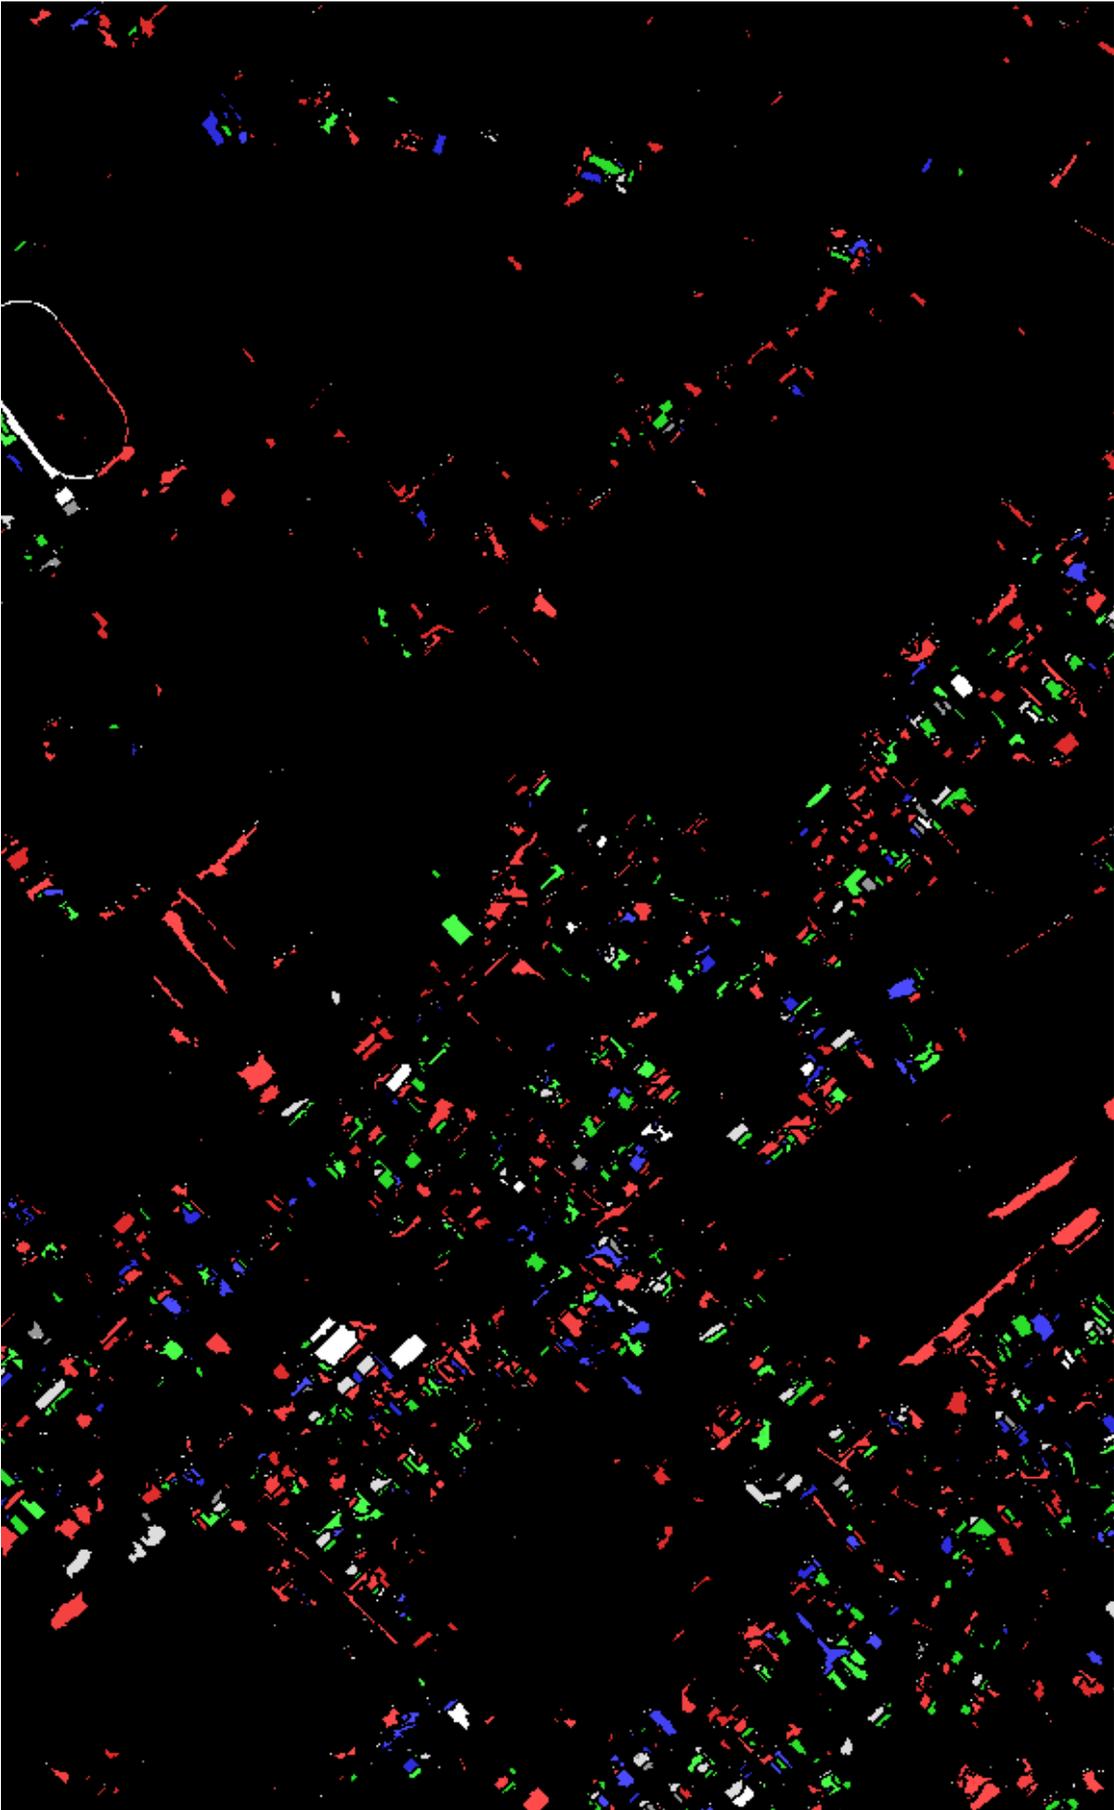
Anhang III – Klassifikation DOP1



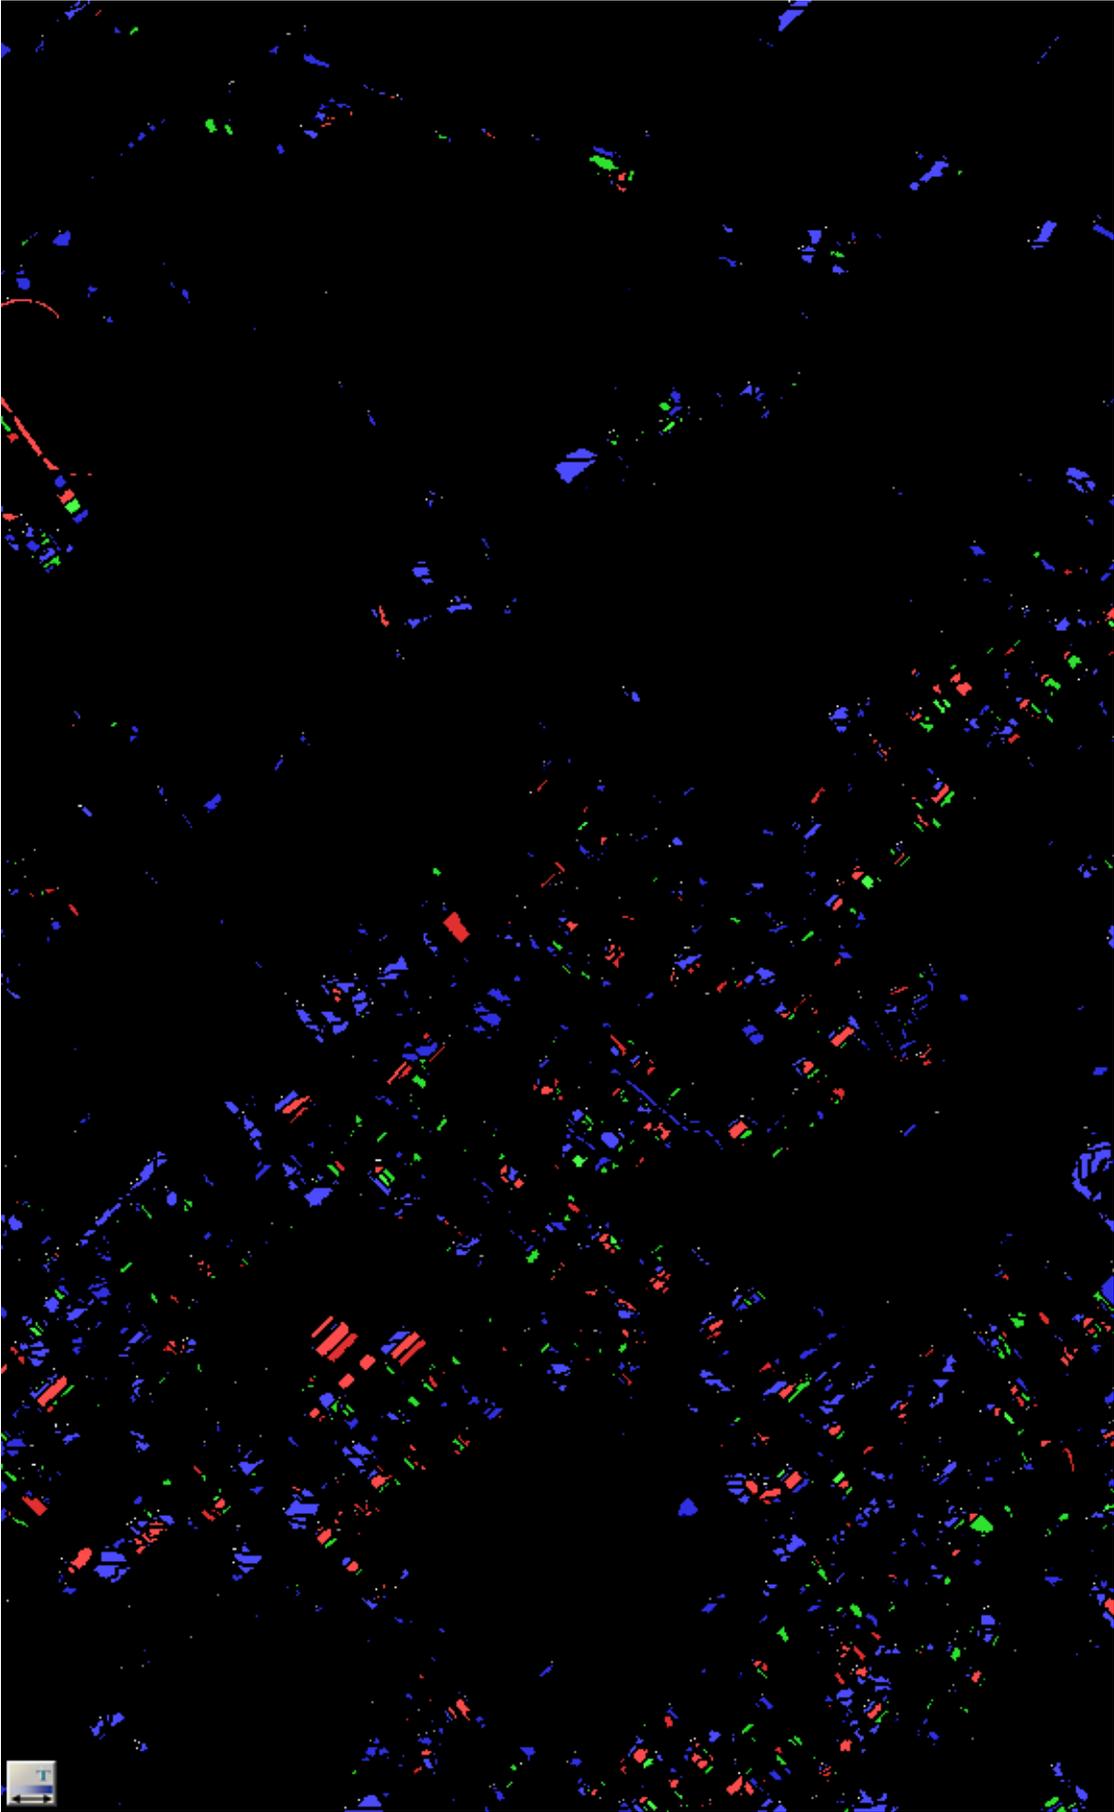
Anhang IV – Klassifikation DOP2



Anhang V – Klassifikationsvergleich DOP1-DOP2



Anhang VI – Klassifikationsvergleich DOP2-DOP1



Anhang VII - CD-ROM mit Bilddaten und eCognition Projekten

Bitte auch die Datei info.txt auf der CD beachten.

Zusammenfassung

Diese Masterarbeit untersucht die Möglichkeiten der objekt-orientierten Klassifikation im Hinblick auf die automatische Erkennung von Gebäuden. Hierfür liegen zwei Luftbilder aus den Jahren 2002 und 2008 vor, die jeweils das gleiche Gebiet zeigen. Weiterhin wird untersucht, ob die Klassifikationsergebnisse dazu geeignet sind, neu hinzugekommene Gebäude zuverlässig zu erkennen. Zunächst erfolgt ein kurzer Vergleich der gebräuchlichen Klassifikationsverfahren. Im Hauptteil werden verschiedene Segmentierungsverfahren verglichen und die Vorgehensweise der objekt-orientierten Klassifikation beschrieben. Danach erfolgt die eigentliche Anwendung auf die beiden Luftbilder und die Auswertung der Ergebnisse. Zum Abschluss erfolgt eine Zusammenfassung, die noch einmal die Qualität der Ergebnisse beurteilt und vergleicht und die Möglichkeiten der objekt-orientierten Klassifikation bewertet.

Abstract

This master thesis examines the object oriented classification technique regarding the possibilities of the detection of buildings by using two sample datasets of the same scene in 2002 and 2008. After that the resulting classification is examined to conclude if a reliable detection of new buildings is possible. At first the most common classification techniques are introduced. Different segmentation techniques are compared and the procedure of object oriented classification is explained. Then the procedure is used on the two images and the results are examined. In the concluding summary the results are briefly compared again and the possibilities of object oriented classification are rated.

Eidesstattliche Erklärung

Hiermit versichere ich, dass ich die Masterarbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe, alle Ausführungen, die anderen Schriften wörtlich oder sinngemäß entnommen wurden, kenntlich gemacht sind und die Arbeit in gleicher oder ähnlicher Fassung noch nicht Bestandteil einer Studien- oder Prüfungsleistung war.

Osnabrück, den 19.06.2012

Robert Daniels

Gröbelweg 12

49082 Osnabrück

Martikel-Nr. xxxxxx