

---

# 6

## 6. *Anwendung auf HRSC-AX Daten*

---

## 6.1. Untersuchungsgebiet

Als Untersuchungsgebiet wurde Berlin gewählt. Die Messflüge fanden am 16.08.2005 und 18.08.2005 statt. Es wurde eine Fläche von insgesamt 590 km<sup>2</sup> befliegen. Damit konnten etwa 75

Prozent des gesamten Stadtgebietes abgedeckt werden. Aus diesem Gebiet wurde ein Teil eines Flugstreifens exemplarisch untersucht.



Abb. 44 Flugplanung für Berlin 2005, Stadtgrenze durch rosa Polygon markiert

## 6.2. Messflug

Während des Messfluges wurde darauf geachtet, dass möglichst homogene Daten aufgezeichnet werden. Auf eine Änderung der Signalverstärkung innerhalb eines Befliegungstages und den Einsatz von Vorsatzfiltern wurde verzichtet, so

dass sich für beide Befliegungstage sehr ähnliche Datensätze ergaben; die Übertragbarkeit der Algorithmen auf den zweiten Befliegungstag wurde allerdings nicht untersucht, da hierfür (noch) keine 16bit Daten vorlagen.

## 6.3. Auswahl des Testgebietes

Alle Prozesse der Bildverarbeitung sind relativ langsam. Dies hängt vor allem mit der Größe der Datensätze zusammen. Unter Definiens Developer lassen sich große Szenen mit Hilfe des Werkzeugs *tiling and stitching* bequem in adäquate Kacheln unterteilen. Der an einem relativ kleinen Testgebiet erstellte Regelsatz ist einfach auf alle Kacheln zu übertragen, die nach der durchgeführten Analyse wieder mosaikiert werden. Eine solche Vorgehensweise trägt dazu bei, die Rechenzeiten erheblich zu verkürzen. Ein kompletter Regelsatz enthält alle

Prozesse der Bildanalyse: Segmentierung, Klassifizierung, Optimierung der Klassifizierung durch *merging*, *accuracy assessment* sowie Export der Ergebnisse. Diese sind Bestandteil eines *process tree* und lassen sich alle gemeinsam in einer bestimmten Sequenz oder – wenn nötig – einzeln anwenden. Um schnell und effektiv einen Regelsatz für die Analyse der urbanen Räume zu erstellen, wurde ein kleines aber repräsentatives Testgebiet in Berlin-Mitte ausgewählt. Dieser Testbereich ist 5000 x 5000 Pixel groß.



Abb. 45 Ausschnitt aus dem Testgebiet, CIR und RGB

## 6.4. Bilddaten

In diesem Kapitel werden die verwendeten Daten untersucht und auf ihre Segmentier- und Klassifizierbarkeit geprüft.

### 6.4.1. HRSC-AX 8bit Daten

Üblicherweise wird die radiometrische Auflösung im Rahmen der photogrammetrischen Prozessierung von 12bit auf 8bit reduziert. Diese Konvertierung ist nicht linear. Die Parameter der Reduktion werden in der Regel für jedes Projekt neu ermittelt. Optisch erscheinen die Orthophotomosaike sehr gut und homogen.

Vor allem in den hellen Bereichen werden die Daten stark zusammengefasst, wodurch besonders feine Kontraste verloren gehen. Obwohl die Auflösung in den Schattenbereichen

weniger stark reduziert wird als in den hellen Bereichen, gehen durch diese geringe Reduktion die wenigen Details verloren, und eine automatisierte Klassifizierung wird für große Gebiete nahezu unmöglich oder führt zu nicht akzeptablen und übertragbaren Ergebnissen. Für eine automatisierte Klassifizierung sind die HRSC-AX 8bit Daten eher ungeeignet, da besonders die dunklen Bereiche im Bild nur noch als Schatten klassifiziert werden können und der hohe radiometrische Umfang der Kameras nicht mehr ausgenutzt werden kann.

### 6.4.2. HRSC-AX 16bit Daten

Bei digitalen multispektralen Datensätzen ist eine Auflösung von mindestens 12bit optimal. Bei diesen

Daten sind genügend Informationen in den Schattenbereichen vorhanden, so dass sinnvolle multispektrale

Klassifizierungen vorgenommen werden können. In den hellen Bereichen bleiben geringe Kontrastunterschiede erhalten und können für Segmentierung und Klassifizierung ausgenutzt werden. Die Daten werden in signed“ 16bit verwaltet. Von den möglichen 65536

Grauwerten werden 4096 ausgenutzt; diese kann die Kamera maximal liefern. Die geometrische Auflösung liegt für diesen Messflug im panchromatischen Kanal bei 20cm und für den infraroten, roten, grünen und blauen Kanal bei 40cm.

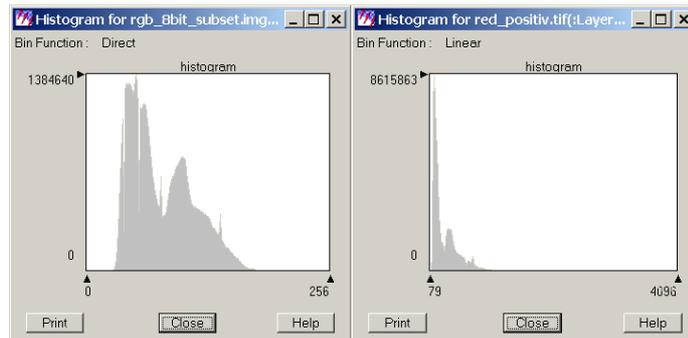


Abb. 46 Histogramme für den roten Kanal in 8- und 16bit

### 6.5. DOM

Es wurden die Oberflächenmodelle der HRSC und die des Laserscanners FALCON verwendet. Die DOM wurden für Klassifizierungsaufgaben in normierte DOM<sup>125</sup> überführt. Ein nDOM beinhaltet nur noch absolute Objekthöhen, die Höhe des Geländes

wurde subtrahiert. Ein nDOM ist unverzichtbar, um die absoluten Objekthöhen berücksichtigen zu können und trägt zur Vereinfachung des Problems der Trennung von Brücken und Hochbahn von anderen Gebäuden bei.

---

<sup>125</sup> Siehe hierzu Stefan Mayer (2003): Automatisierte Objekterkennung zur Interpretation hochauflösender Bilddaten in der Erdfernerkundung. Diss., Humboldt-Univ. Berlin.

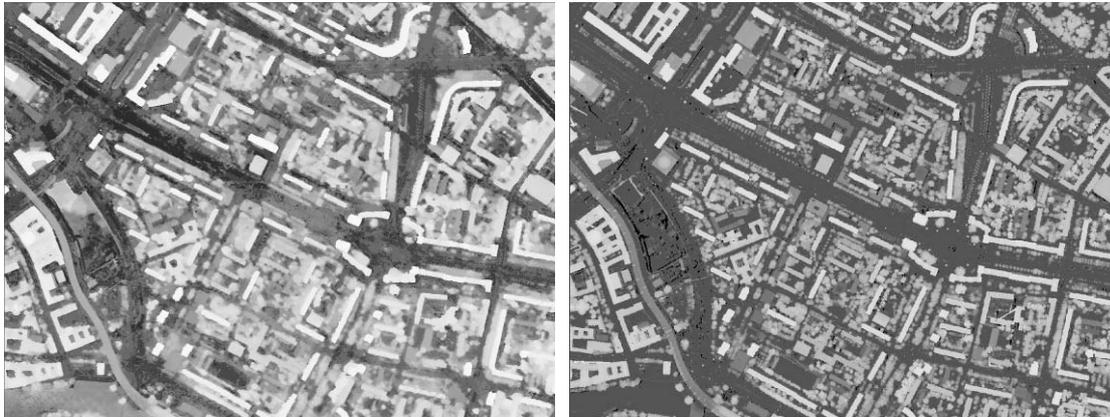


Abb. 47 Oberflächenmodell HRSC und LIDAR/LIDAR

## 6.6. Untersuchung der Segmentierung

Da es für die Segmentierungsparameter keine empfohlenen oder gar festgelegten Werte gibt, ist es zu Beginn der Analyse der neuen Bilddaten unerlässlich, unterschiedliche Werte sowohl für das *scale parameter* als auch für die Homogenitätskriterien *color* und *shape* zu untersuchen. Es wurden eine Reihe von Untersuchungen durchgeführt, die helfen sollen, die Frage zu beantworten, inwieweit die Anwendung des DOM die Segmentierungsergebnisse beeinflussen und eventuell verbessern kann.

Um die Qualität der Segmentierung unter Verwendung des DOM und dessen Einfluss auf die Extraktion der einzelnen Objekte überhaupt feststellen zu können, wurden folgende Untersuchungen durchgeführt:

- Segmentierung unter Verwendung von DOM und spektraler Information sowie
- Segmentierung nur auf Basis von spektraler Information ohne Verwendung von DOM.

Für die Ermittlung der optimalen Objekte in diesen Segmentierungen wurden verschiedene Parameter der *Multiresolution Segmentation* getestet, so dass die Vor- und Nachteile der beiden Methoden festgestellt werden konnten. Die Überprüfung der Extraktionsexaktheit ergab, dass die beiden Teilsegmentierungen zur Bewältigung dieser Aufgabe zwar relativ gut geeignet sind, aber dennoch verschiedene Fehler aufweisen. Die daraus gezogenen Schlussfolgerungen konnten zur Herleitung der optimalen Segmentierungsparameter für die anschließende eigentliche Segmentierung genutzt werden.

In den beiden Untersuchungen wurde die Segmentierung auf mehreren Segmentierungsebenen durchgeführt, um den gewünschten Objektgrößen und -formen für die vorgenommenen semantischen Klassen Rechnung zu tragen. Es wurden Segmentierungen mit dem *scale parameter* von 20 bis höchstens 150 durchgeführt.

Die Segmentierungsqualität soll an folgenden Kriterien gemessen werden:

- Geometrie (Extraktionsexaktheit, Lage der Segmentgrenzen, Unter- und Übersegmentierungen),
- Semantik (Übereinstimmung der resultierenden Objekte mit den realen semantischen Klassen) und

- Transparenz der Segmentierung (Erscheinungsbild der Segmente).

In den nachfolgenden Unterkapiteln werden die beiden Teilsegmentierungen im Detail präsentiert und verglichen.

Im Rahmen der Segmentierung wurden die folgenden Ansätze überprüft:

### 6.6.1. Segmentierung nur auf multispektralen Daten der HRSC basierend

Im Ergebnis zeigen Segmentierungen von 16bit Daten, die ohne Verwendung von Oberflächenmodellen erzeugt wurden, das Problem einer falschen oder zu starken Segmentierung. Die Ursachen hierfür liegen vor allem in der starken Heterogenität der Bilddaten. Trotzdem können, wie Abb. 48 (1) zeigt, besonders in Bereichen mit ähnlichen spektralen Eigenschaften falsche Segmente entstehen, obwohl der *scale parameter* klein genug gewählt wurde.

Das betroffene Segment ist hier rot markiert. Ein großer Vorteil einer Segmentierung, die kein DOM einbezieht ist die Tatsache, dass die eventuellen Fehler im DOM keinen Einfluss auf das Erscheinungsbild der Segmente haben. Fehler in Schattenbereichen oder in Innenhöfen – wie es beim HRSC-DOM der Fall ist – oder die ausgefranzten Kanten im LIDAR-DOM bleiben unberücksichtigt; die Form der Segmente wird nur aus den spektralen Informationen abgeleitet.

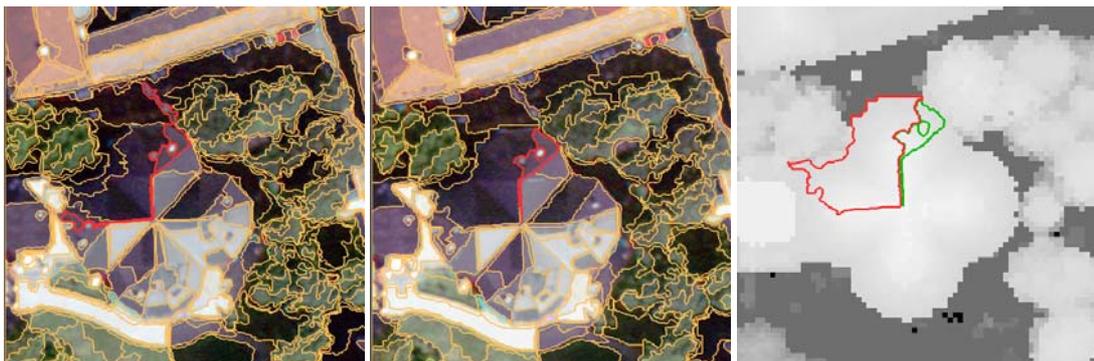


Abb. 48 Segmentierung ohne DOM(1), mit DOM (2), DOM

## 6.6.2. Segmentierung unter Verwendung von Oberflächenmodellen

Segmentierungen unter Verwendung des HRSC-Oberflächenmodells liefern grundsätzlich bessere Ergebnisse als die Segmentierungen, die kein Oberflächenmodell berücksichtigen. Problematisch sind hier lediglich einige Grenzbereiche. Diese sind naturgemäß aufgrund des photogrammetrisch ermittelten Modells in Bereichen mit geringem Kontrastumfang oder in Bereichen mit zu wenigen homologen Punkten in den panchromatischen Kanälen zu finden.

Abb. 48 (2) zeigt die erfolgreiche Trennung des problematischen Segmentes in mehrere Segmente. Diese Trennung ist Voraussetzung für die korrekte Klassifizierung der Objekte.

Abschließend lässt sich feststellen, dass in einigen Bereichen, die spektral sehr ähnlich waren, eine Trennung in verschiedene Segmente nur dann gelang, wenn ein Oberflächenmodell verwendet wurde. Es ist nahe liegend, dass sich Fehler im Oberflächenmodell in der Segmentierung fortpflanzen. Daher ist die Verwendung eines

Oberflächenmodells nur dann sinnvoll, wenn es zuverlässig und genau ist. Die Problematik der unsicheren Bereiche im HRSC-DOM, wie sie etwa bei engen Innenhöfen anzutreffen ist, pflanzt sich in der Segmentierung und damit auch in der Klassifizierung fort. Genaue Auskunft über die Qualitäten der Oberflächenmodelle sind Kapitel 3 zu entnehmen. Im Allgemeinen hat sich das LIDAR-DOM als äußerst genau und richtig erwiesen. Daher entstanden die besten Segmentierungsergebnisse unter Verwendung des LIDAR-DOM trotz der nicht sehr genauen Erfassung der Gebäudeausdehnung.

Tab. 12 zeigt die für eine erfolgreiche Klassifizierung minimal notwendigen Segmentierungsebenen. Für die Klassifizierung selbst ist es manchmal sinnvoll und einfacher, die Ebenen zu kopieren. Dies kann helfen, die Übersichtlichkeit der Klassifizierung für den Bearbeiter zu wahren.

level	Verwendungszweck der Ebene	Scale Parameter	Homogenitätskriterien		Anzahl der Segmente
			Color / Shape	Compactness / Smoothness	
level 7, 8	Gebäude, Hochbahn		kopiert		17 785 (nach dem merging)
level 6	Bewegte Boote	100	0.8 / 0.2	0.5 / 0.5	24 733
level 5	Dächer	100	0.8 / 0.2	0.5 / 0.5	25 588
level 4	Erhabene Objekte	90	0.6 / 0.4	0.8 / 0.2	58 996
level 2, 3	Wasserflächen, Vegetation, Strassen, Sportfelder, Sand etc.	40	0.9 / 0.1	0.7 / 0.3	261 853
level 1	Schatten	20	0.9 / 0.1	0.6 / 0.4	805 442

Tab. 12 Übersicht der minimal notwendigen Segmentierungen

## 6.7. Klassifizierung des Testgebietes

Die Regelbasis für die Analyse der urbanen Räume wurde in Form eines *process tree* anhand des repräsentativen Testgebietes aufgebaut. Diese Regelbasis enthält alle Prozesse und kann auf beliebige VHSR 16Bit-Datensätze der städtischen Gebiete übertragen werden. Die Software Definiens Developer 6.0 stellt ein funktionales Werkzeug zur Verfügung, das das Einbauen der so genannten *solutions* in die Regelbasis ermöglicht.

Um die Übertragbarkeit der Regelbasis auf beliebige urbane Räume zu gewährleisten, müssen die verwendeten Algorithmen und Klassenbeschreibungen robust und zuverlässig gestaltet werden. Als Hauptschwierigkeit bei der Lösung dieser Aufgabe hat sich die Heterogenität des verwendeten Datensatzes erwiesen. Obwohl die hohe räumliche Auflösung die Anzahl der Mischpixel deutlich reduziert, steigt proportional die Anzahl der wahrnehmbaren Klassen. Die gewünschten semantischen Klassen werden sehr komplex, und

deren Klassenbeschreibungen müssen vielschichtig gestaltet werden, was in einigen Fällen die Trennbarkeit und Stabilität der Klassen negativ beeinflusst. Als unabdingbar hat sich die Verwendung der Höheninformation erwiesen. Zur Verfügung stand auch ein thematischer Layer in Form von ALK-Daten. Diese wurden jedoch nicht direkt in die Segmentierung und die Klassifizierung einbezogen, sondern nur zur Evaluierung der Klassifikationsgüte angewandt, da thematische Layer eine Teilung in Segmente entlang der Grenzen im Layer erzwingen, die ALK älter als die Befliegung war und die Gebäudegrenzen nicht unbedingt den im Luftbild erkennbaren Konturen entsprechen. Die Analyse erfolgte auf insgesamt 7 *levels*. In folgenden Kapiteln werden die Regelbasen für die Analyse der wichtigsten semantischen Klassen im Detail dargestellt.

### 6.7.1. Trennung der Wasserflächen vom Schatten in level 1 und 2

Im ersten Schritt erfolgte die Trennung der verschatteten von den beleuchteten Objekten. Es wurden zwei Klassen angelegt: *bright areas* und *dark areas*. Die Klassifizierung wurde auf der niedrigsten Segmentierungsebene mit dem *scale parameter* 20 durchgeführt, um auch kleine Schattenbereiche noch aufzulösen. Zur Klassifizierung der Klasse *dark areas* wurde die Eigenschaft *brightness* verwendet.

Neben den echten Schattenbereichen finden sich zunächst in dieser Klasse auch die Objekte, die später den Klassen Wasser und Bitumendächer zugeordnet werden. Die Beschreibung der Klassifizierung dieser Objekte ist im Abschnitt „Dachmaterialien im level 5“ zu finden.

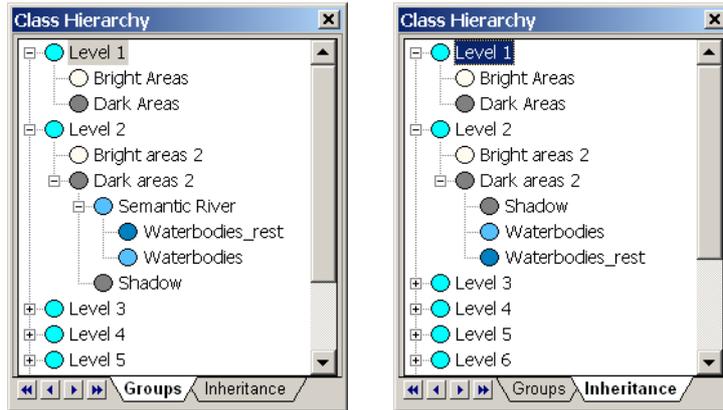


Abb. 49 Klassenhierarchie für level 1 und 2. Groups (links) und Inheritance (rechts)

Die Trennung der Wasserflächen vom Schattenbereich erfolgte auf dem *level 2* in *scale parameter 40*. Für Wasser wurden größere Segmente als für andere beschattete Objekte gebildet, so dass ein Schwellenwert für die Eigenschaft *Fläche* bestimmt werden konnte.

Einige *Nicht-Wasser-Objekte* erfüllen ebenfalls diese Eigenschaft, weshalb zusätzliche Merkmale in die Klassenbeschreibung einfließen mussten. Als hilfreich haben sich die Ratio des grünen und blauen Kanals sowie das NDVI erwiesen. Damit die Merkmalswerte der Klasse *waterbodies* stabil und robust für die Übertragbarkeit bleiben, wurden sie nicht an die Grenzbereiche der Trennbarkeit gezogen, so dass einige Segmente im Wasserbereich nicht der Klasse *waterbodies*

zugewiesen wurden. Um diese „Lücken“ zu schließen wurde eine Hilfsklasse erstellt: *waterbodies\_rest*. Hier wurden die Segmente klassifiziert, deren Grenze zur Klasse *waterbodies* groß genug ist. Um die beiden Klassen auf höhere *level* als eine semantische Klasse übertragen zu können, wurden sie auf der Registerkarte in *groups* unter der Elternklasse *semantic River* zusammengefasst. Diese Klasse erwies sich auf den höheren Ebenen bei der Klassifizierung von Booten und Brücken als sehr hilfreich. Die Stabilität der Klassen *waterbodies* und *waterbodies\_rest* beträgt: 0,89 und 0,93. Das Ergebnis der Flussklassifizierung ist in Abb. 51 zu sehen.



Abb. 50. Klassifizierungsergebnis für die Klasse *waterbodies*

### 6.7.2. Trennung der Vegetation von anderen erhabenen Objekten im level 3

Auf dem *level 3* mit dem *scale parameter 50* wurde das Hauptaugenmerk darauf gelegt, die Vegetation und erhabene Objekte (überwiegend Gebäude) voneinander zu trennen. Es wurde ein relativ kleiner *scale parameter* gewählt, um der feingliedrigen Vegetationsausprägung Rechnung zu tragen. Außerdem wurden verschiedene semantische Klassen auf diesem *level* gebildet siehe Abb. 51. Diese Klassen wurden vor allem mittels spektraler Eigenschaften klassifiziert. Zu bemerken ist, dass die Straßen auf diesem *level* nur initialisierend klassifiziert wurden. Eine vollständige Klassifizierung erfolgte auf dem *level 8* und ist in Kap. 1.1.1. im Detail dargestellt.

Um die Vegetation von anderen erhabenen Objekten zu trennen, wurden im ersten Schritt die Klassen *bright areas 3* und *dark areas 3* mithilfe des klassenbezogenen Merkmals „Relative Area of Sub Objects“ auf diese Ebene übertragen. Die Vegetation, als Kinderklasse von *bright areas 3*, wurde mittels eines Schwellenwertes für das berechnete NDVI von anderen Objekten getrennt. Das Verwenden von nur einer Eigenschaft in der Klassenbeschreibung garantiert eine hohe Stabilität und die sichere Übertragbarkeit dieser Klasse. Mittels Höheninformation konnte zwischen hoher und niedriger Vegetation unterschieden werden. Es entstanden Klassen für hohe (ab 8 m) und niedrigere Bäume sowie Klassen für Wiesen und Sträucher. Für die Vegetation, die sich im Schattenbereich befand, also der Klasse *dark areas 3* angehört, wurde eine Klasse *vegetation in shadow* angelegt. Weil diese sich in Anbetracht der Spektraleigenschaften

im Bereich des Schattens befindet, ist sie in der *Inheritance*-Registerkarte eine Kinderklasse von *Shadow\_3*. In der *Groups*-Registerkarte gehört sie aber der semantischen Klasse *Vegetation* an. Ein solches Zusammenfassen unter einer semantischen Klasse in der *Groups*-Registerkarte ist ein ausgesprochen großer Vorteil der Software. Die klassenbezogenen Merkmale kommen nämlich immer auf die Elternklassen aus der *Groups*-Registerkarte zurück, so dass deren Kinderklassen mitberücksichtigt werden. So kann man Kinderklassen, die in der *Inheritance*-Registerkarte aufgrund der Spektraleigenschaften unterschiedlichen Eltern angehören, unter einer semantischen Elternklasse in der *Groups*-Registerkarte zusammenfassen und bequem auf andere *level* übertragen.

Die Stabilität der Klassen *high vegetation*, *low vegetation* und *vegetation in shadow* beträgt entsprechend 1,0, 0,99 und 0,99. Da sich der künstliche Rasen auf den Sportfeldern spektral wesentlich von der Vegetation unterscheidet, konnte er nicht mithilfe des NDVI klassifiziert werden. In diesem Fall wurde die Ratio für den grünen Kanal verwendet. Die Stabilität für diese Klasse beträgt 0,89.

Es ist zu bemerken, dass der Klasse *vegetation* auch Objekte, die begrünte Dächer repräsentieren, zugewiesen wurden. Die korrekte Klassifizierung von solchen Objekten erwies sich überwiegend auf der dritten Segmentierungsebene als problematisch. Da die hier generierten Segmente relativ klein und in Vegetationsbereichen aufgrund der hohen Bittiefe fraktal sind, konnten keine geometrischen Eigenschaften in die Klassenbeschreibung der

begrüntem Dächern eingesetzt werden. NDVI war an dieser Stelle ebenfalls wenig hilfreich, da es im Untersuchungsgebiet auch Dächer gibt, die sehr hohe Werte für dieses Merkmal aufweisen vergleichbar der normalen Vegetation. Weitere Untersuchungen ließen feststellen, dass sich die begrünten Dächer leichter auf viel größeren Segmentierungsebenen korrekt klassifizieren lassen und zwar durch die klassenbezogenen Eigenschaften. Mehr zur Klassifizierung der begrünten Dächer findet sich im Abschnitt zur „Klassifizierung der begrünten Dächer im level 8“. Die Objekte der begrünten Dächer wurden somit auf den zwei nächsten Ebenen als „Nicht-Gebäude“ behandelt und erst auf dem level 7 nachträglich korrekt klassifiziert und der Klasse *buildings* zugewiesen.

Da die Klasse *vegetation* eine sehr hohe Stabilität aufweist, konnte man alle anderen Objekte unter einer Elternklasse *not vegetation* mittels der invertierten Eigenschaft *not vegetation* zusammenfassen. Dieses Merkmal wurde somit an alle Kinderklassen vererbt, darunter auch an die Klasse *elevated objects*. Da sich einige Dachflächen spektral nur schwer von Straßen trennen lassen, wurde in die Klassenbeschreibung von erhabenen Objekten zusätzlich die Höheninformation integriert. Auf diese Art und Weise wurde eine Basis – „Anfangsobjekte“ – für die Klassifizierung der Gebäude geschaffen. Die Stabilität der Klasse *elevated objects* beträgt 1,0. Im Folgenden wird die Klassifizierung der Gebäude im Detail dargestellt.

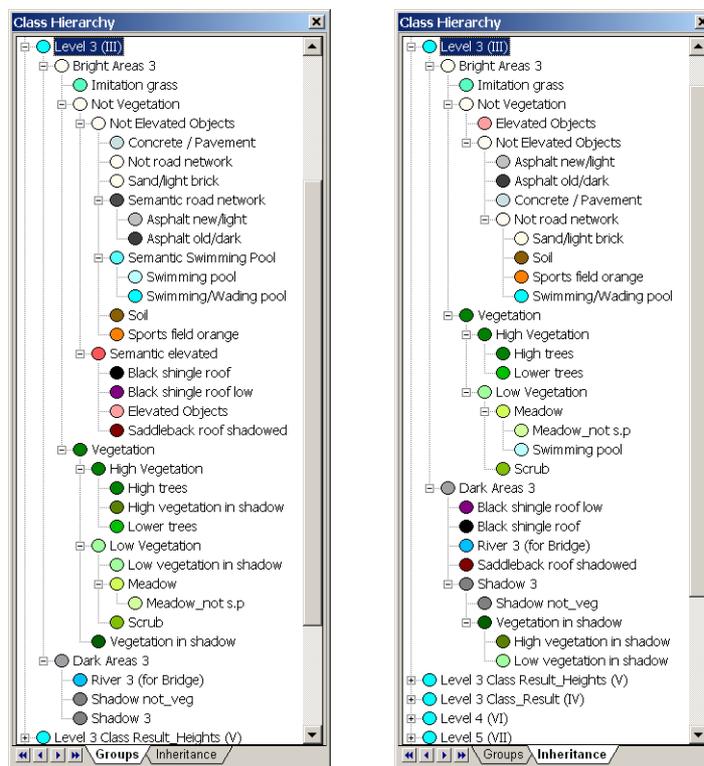


Abb. 51 Klassenhierarchie für level 3: Groups-(links) und Inheritance-Registerkarten (rechts)

### 6.7.3. Trennung dunkler Dachflächen vom Schattenbereich im level 3

Aufgrund der Tatsache, dass einige Dächer mit sehr dunklem Material wie Bitumen bedeckt sind oder sich im Schatten befinden (Schattenseiten der Satteldächer), wurden sie anfangs der Klasse *dark areas 3* zugewiesen. Die Klasse *elevated objects* ist aber eine der Unterklassen von *bright areas 3*. Um die Gebäude auf den höheren *level* weiter einheitlich klassifizieren zu können, wurde eine semantische Klasse in der *Groups*-Registerkarte für erhabene Objekte erstellt: *semantic elevated*, siehe auch die Klassenhierarchie in Abb. 51. Diese Elternklasse fasst unter sich alle

Klassen zusammen, die die Gebäude repräsentieren: *elevated objects*, *black shingle roofs* und *saddleback roof\_shadow*. Alle Gebäude-Objekte konnten somit auf die anderen *level* übertragen und weiter als eine einheitliche Klasse verwendet werden. Die Bitumendächer und die beschatteten Satteldächer wurden mittels des nahen Infrarot-Kanals und NDVI klassifiziert. Zusätzlich wurde Höheninformation verwendet, um die Trennung von spektral ähnlichen Straßen zu gewährleisten. Das Klassifizierungsergebnis der erhabenen Objekte auf dem *level 3* ist in Abb. 52 zu sehen.



Abb. 52 Klassifizierungsergebnis für erhabene Objekte: Unterklassen in Inheritance-Darstellung, Elternklasse *Semantic Elevated* in *Groups*-Darstellung

### 6.7.4. Klassifizierung der Gebäude in level 3 bis 8

Die Klassifizierung der Gebäude wurde auf dem *level 3* initialisiert. Auf allen nachfolgenden *levels* wurden die Gebäude-Objekte bezüglich Höhe und Dachbedeckung klassifiziert und von anderen erhabenen Objekten getrennt. Auf manuelle Klassifizierungs- oder Konturverbesserungen wurde verzichtet, weil die Analyse

automatisiert ablaufen sollte. Schließlich wurden alle Gebäude-Objekte fusioniert und als thematischer Raster-Layer resp. Shape-File exportiert, um die Evaluierung in einer anderen Software durchführen zu können.

---

### Erhabene Objekte im *level 3*

Im ersten Schritt wurde eine semantische Klasse *semantic elevated* auf dem *level 3* erstellt, die alle erhabenen Objekte zusammenfasst, die einen Höhenwert größer als 2,8 m aufweisen. Hierunter fallen nicht nur Gebäude, sondern auch Hochbahnstrecken, Straßenlaternen, Mauern und Zäune sowie erhabene Brücken. Diese Klasse wurde auf höhere Segmentierungsebenen übertragen. Schritt für Schritt wurden die Gebäude-Objekte von den anderen erhabenen Objekten separiert.

In den spektralen HRSC-AX-Daten sind die erhabenen Objekte, darunter auch Baumobjekte, von der Ausdehnung her um einige Pixel kleiner als im LIDAR-DOM. Daher kommt es an einigen Stellen in der Klasse *semantic elevated* - besonders bei hoher Vegetation - zu Fehlklassifi-

zierungen. Als Vegetation wurden nur diejenigen Segmente klassifiziert, die einen hohen Wert für NDVI aufzeigen konnten. Alle Nicht-Vegetation-Objekte wurden unter der Elternklasse *Not Vegetation* mittels invertierter Eigenschaft *not vegetation* zusammengefasst, siehe die Klassenhierarchie in Abb. 51. Deren Kinderklassen, darunter auch *elevated objects*, erhielten aufgrund dessen die Eigenschaft *not vegetation* vererbt. Die an die klassifizierten Bäume angrenzenden Objekte - laut DOM: Baum-Segmente - die keinen ausreichend großen NDVI-Wert aufzeigen konnten, aber eine bestimmte Höhe hatten, wurden als *not vegetation*, also *elevated objects* klassifiziert. Diese Fehlklassifizierung ist in Abb. 53 zu sehen. Wie das Problem der falsch klassifizierten erhabenen Objekte gelöst wurde, wird im Abschnitt „“ erläutert (s.u.).

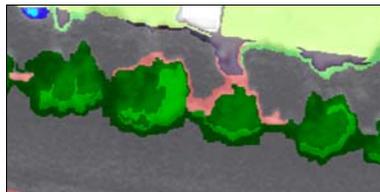


Abb. 53 Falsch klassifizierte Bäume aufgrund der Ausdehnungsunterschiede zwischen Spektraldaten und DOM. Bäume in grün, erhabene Objekte in rosa

### Trennung der erhabenen Brücken von Gebäuden in *level 3* und 6

In der Klassenbeschreibung der *elevated objects* im *level 3* wurde ein Schwellenwert für die Höheninformation verwendet. Als erhaben wurden an dieser Stelle alle Objekte interpretiert, die höher als 2,8 m sind. Darunter befinden sich auch erhabene

Brücken, die nicht als Gebäude klassifiziert, sondern der semantischen Klasse Straßen zugewiesen werden sollten. In diesem Kapitel wird beschrieben, wie die Brücken von Gebäuden getrennt wurden.

Die Klassifizierung der Brücken erfolgte auf dem *level 6* mit dem *scale* parameter 100. Diese Segmentierungsebene diente vor allem der Klassifizierung der bewegten Boote auf dem Fluss. Die hier zu diesem Zweck angelegte Klasse *river\_6* wurde mittels der klassenbezogenen Eigenschaft „Relative Area of Sub-Objects: *river\_3*“ vom *level 3* übertragen. In die Klassenbeschreibung der Klasse *bridge (over river)* wurde vor allem das klassenbezogene Merkmal „Distance to: *river\_6*“ integriert. Es wurde hier ein Intervall von 0 bis 20,5 m bestimmt. Der rechte Grenzwert bezeichnet die größte Entfernung eines Brücken-Objektes vom Wasser. Zusätzlich wurden das geometrische Merkmal

Länge und die Höheninformation verwendet. Die so klassifizierten Brücken konnten nachträglich auf den *level 3* übertragen werden. In die Klassenbeschreibung von *elevated objects* wurde zusätzlich die klassenbezogene Eigenschaft „Existence of Super-Objects: *Bridge (over river)*“ integriert. Der Wert wurde auf Null eingestellt, d.h. dass nur diejenigen Objekte der Klasse *elevated objects* zugewiesen werden, die nicht der Klasse *bridge (over river)* auf dem *level 6* gehören. Die Stabilität der Klasse *Bridge (over River)* in *level 6* beträgt 0,99. Diese komplexe Klassifizierungsreihenfolge ist in Abb. 54 im *Process Tree* zu erkennen.

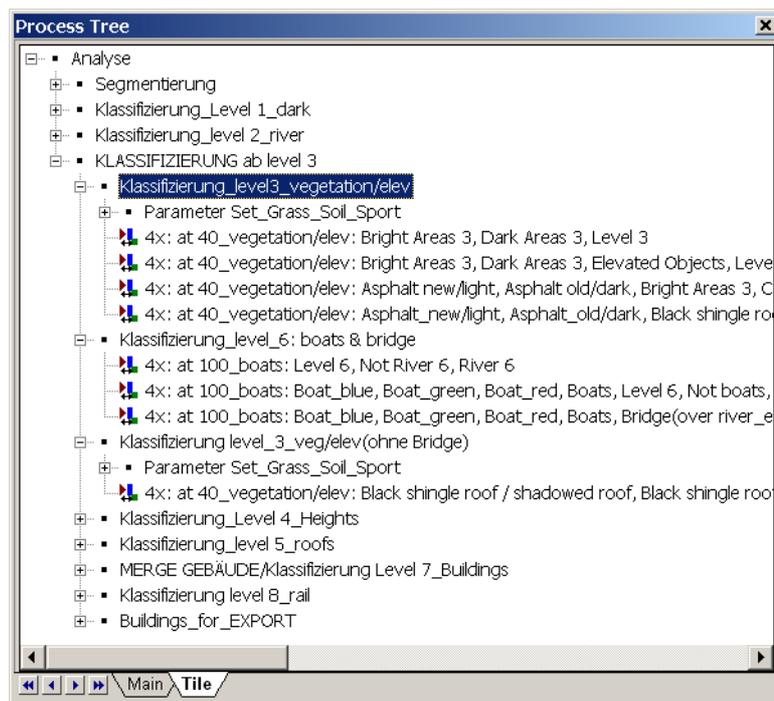


Abb. 54 Process Tree: Trennung der Brücken von anderen erhobenen Objekten

---

## Höhenklassifizierung im level 4

Erhabene Objekte im level 3“ beschriebenen falsch klassifizierten erhabenen Objekte aus der Gebäudeklasse auszuschließen, wurde auf dem level 4 mit scale parameter 90 die Klasse *heights* angelegt. In ihre Klassenbeschreibung wurde die klassenbezogene Eigenschaft „*relative area of sub-objects: subobjects: semantic elevated*“ integriert. Dieses Merkmal ist ein Quotient aus der Fläche der Sub-Objekte einer bestimmten Klasse und der Fläche des betroffenen Objektes.<sup>126</sup> Die Werte werden in einem Intervall von 0 bis 1 angegeben. Ein Schwellenwert für diese Eigenschaft erlaubt es, alle zu kleinen und allein stehenden Objekte aus dem Sublevel zu vernachlässigen. Der Schwellenwert wurde hier auf 0,68 eingestellt. Somit konnten mithilfe des oben beschriebenen Merkmals fast alle falsch klassifizierten Objekte aus der Klasse *heights* ausgeschlossen werden.

Auf dem level 4 wurden die Höhen der einzelnen Objekte - überwiegend Gebäude - ermittelt. Diese Ergebnisse könnten zur Analyse stadtklimatischer Aspekte verwendet werden. Es wurden insgesamt fünf Klassen für unterschiedliche Höhen erstellt. In den Klassenbeschreibungen wurden Schwellenwerte und Intervalle für die Höheninformation verwendet. Die Klasse *not heights* besitzt nur ein invertiertes Merkmal *not heights* und

dient vor allem dem Zweck der besseren Darstellung der klassifizierten Objekte. Alle nicht Höhen-Objekte werden unter einer Maske der Klasse *not heights* abgedeckt. Die Klassenhierarchie für level 4 wurde in Abb. 55 dargestellt. Aufgrund der Tatsache, dass auch für diese Klassen nur eine Eigenschaft in den Klassenbeschreibungen verwendet wurde, beträgt die Stabilität für sie alle 1,0. Eine sichere Übertragbarkeit ist somit gewährleistet.

Die einzigen Fehlklassifizierungen, die auf dieser Segmentierungsebene auftauchen, sind kleine Dachbereiche, die der Klasse *not heights* zugewiesen wurden. Es handelt sich entweder um begrünte Dächer, die auf dem dritten level der Klasse *Vegetation* angehören und deswegen nicht mit *semantic elevated* als Gebäude übertragen wurden, oder es sind kleine beschattete Bereiche (z.B. einen Schornsteinschatten), die den Schwellenwert der Eigenschaft „*relative area of sub-objects semantic elevated*“ nicht erfüllen. Mehr zur korrekten Klassifizierung der begrünten Dächer findet sich in Kapitel „Klassifizierung der begrünten Dächer im level 8“. In Abb. 56 wurde das Klassifizierungsergebnis für level 4 dargestellt.

---

<sup>126</sup> Baatz, M. et al. (2004), S. 140.

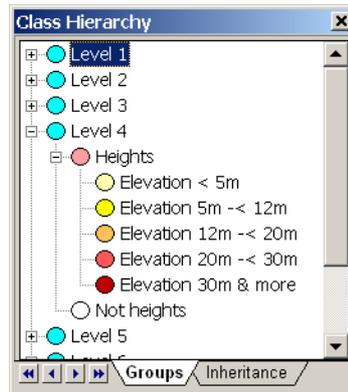


Abb. 55 Klassenhierarchie für level 4, beide Registerkarten sind gleich



Abb. 56 Klassifizierungsergebnis der Höhen der erhobenen Objekte

### Dachmaterialien im level 5

Auf dem level 5 mit dem *scale parameter* 100 wurden die Dachmaterialien klassifiziert. Das Hauptziel dieser Klassifizierung war es, die sehr heterogenen und komplexen Dachflächen in einheitliche Segmente zusammenzufassen. An dieser Stelle ist zu bemerken, dass die Verwendung

von VHSR 16bit Daten einen großen Einfluss auf das Endergebnis der Segmentierung ausübt. Das Erscheinungsbild der anthropogenen Objekte, vor allem der Gebäude, wird stark beeinträchtigt: Sie werden nicht selten übersegmentiert. So werden alle Feinheiten und selbst die kleinsten

Objekte, die sich stark von ihrer Umgebung unterscheiden, segmentiert. Beispiele hierfür sind die spektral sehr hellen Klimaanlage, Fenster auf den Satteldächern oder Schornsteine. Das Anwenden eines größeren *scale parameter* hilft an dieser Stelle nicht wirklich weiter, da wiederum diejenigen Objekte, die homogene Dachflächen aufweisen, untersegmentiert werden können. Um die exakte Form der Gebäude zu bewahren, wurden sie auf dem *level 5* mit dem optimalen *scale parameter* 100 klassifiziert. Nachfolgend wurden die Dachsegmente mit den Gebäude-Objekten fusioniert.

Die Klassenhierarchie für *level 5* wurde in Abb. 57 dargestellt. Im ersten Schritt wurde die Klasse *roofs* angelegt, in deren Klassenbeschreibung die klassenbezogene Eigenschaft „*relative area of sub-objects: heights*“ verwendet wurde. Es wurde ein Schwellenwert von 0,68 für dieses Merkmal bestimmt, was das nochmalige Ausschließen der zu kleinen, allein stehenden Objekte verursachte. Die Klasse *Not roofs*

besitzt ein invertiertes Merkmal „*not roofs*“ und dient, ähnlich wie die Klasse *not heights*, im *level 4* der optimalen Darstellung. Weil es relativ viele Dach-Objekte gab, die sich in Schattenbereichen befanden, was nicht ohne Einfluss auf deren Spektraleigenschaften blieb, wurden zwei Kinderklassen erstellt: *dark roofs* und *bright roofs*. Die beiden Klassen wurden mittels Helligkeit klassifiziert. Sie besitzen weitere Kinderklassen, die im Detail die Dachmaterialien repräsentieren. Diese wurden überwiegend mittels spektralen Eigenschaften klassifiziert. Für einige wenige Objekte, die zwar keine Klassenbeschreibung der Dachmaterialien erfüllen konnten, aber trotzdem im ersten Schritt als *roofs* klassifiziert wurden und eindeutig zu Gebäuden gehören sollten, wurde eine zusätzliche Klasse: *unclassified roofs* erstellt. In diese Klasse wurden alle Objekte aufgenommen, die unklassifiziert blieben und einen bestimmten Schwellenwert für die Entfernung zur Klasse *roofs* nicht überschritten.

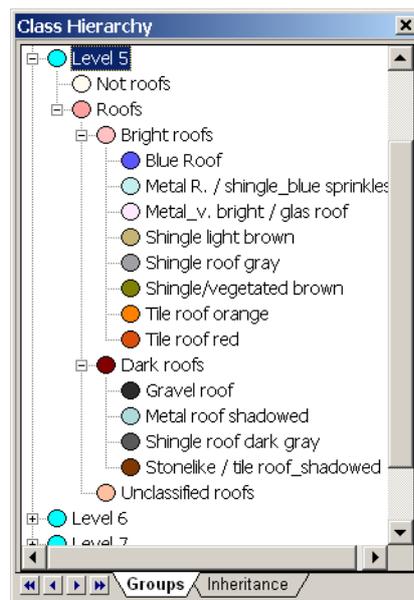


Abb. 57 Klassenhierarchie für level 5. Beide Registerkarten sind gleich

Die Stabilität der Dachbedeckungsklassen ist im Allgemeinen schwach, für *dark roofs* beträgt sie 0,42 und für *bright roofs* 0,67. Die schwachen Werte für die Stabilität resultieren aus der relativ großen Anzahl der Unterklassen, was auf die starke Heterogenität der Daten zurückzuführen ist. Die Klassenbeschreibungen sind sich ähnlich, was aber der Realität entspricht: Die Vielfältigkeit der Dachmaterialien ist enorm groß. Wie in Kapitel 1.1.1 über die verfügbaren *accuracy assessment* Methoden in Definiens Developer beschrieben wird, liefert die Stabilitätsstatistik keine Aussagen über die Richtigkeit und Genauigkeit der Klassifizierung selbst, sondern trifft eher Aussagen über die Relation zwischen der besten und der zweitbesten Klassifizierung. Wenn der Wert für die Stabilität klein ausfällt, kann das auch bedeuten – wie es

überwiegend im Fall der Dachmaterialien anzutreffen war –, dass die Zugehörigkeitswerte zur besten und zur zweitbesten Klasse ähnlich hoch sind. Die Klassifizierung der Dachmaterialien dient nur Vereinheitlichungszwecken: Ihre schwache Stabilität beeinträchtigt nicht die endgültige Evaluierung der Klassifikationsgüte der Gebäude. Die Dach-Objekte aus diesem *level* wurden auf die höhere Ebene – *level 7* – übertragen, zu größeren Objekten fusioniert und weiter bearbeitet und evaluiert. In Abb. 58 ist das Klassifizierungsergebnis der Dachmaterialien zu sehen. Man erkennt, dass auch die Hochbahn mitklassifiziert wurde. Um diese von den übrigen Gebäuden zu trennen, wurden weitere Schritte bezüglich der Objektgeometrie notwendig.



Abb. 58 Klassifizierungsergebnis der Dachmaterialien

## Trennung der Hochbahn von Gebäuden im *level 8*

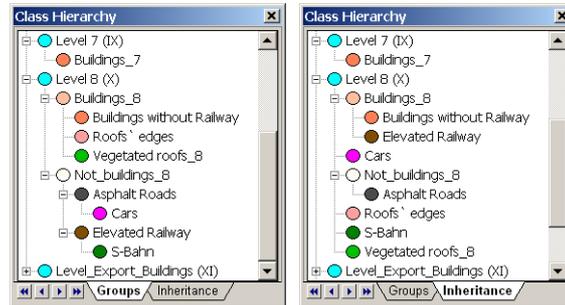


Abb. 59 Klassenhierarchie für *level 7* und *8*: *Groups* (links) und *Inheritance* (rechts)

Die Hochbahn ist zwar ein Gebäude im weiteren Sinne, unterscheidet sich aber in seiner Bestimmung als Bahnanlage von allen anderen Gebäuden und soll daher getrennt klassifiziert werden, zumal sie in den ALK-Daten nicht erfasst ist. Die Klassifizierung der Hochbahn erfolgte auf dem *level 8*, die Klassenhierarchie wurde in Abb. 59 dargestellt.

Auf *level 7* befinden sich Gebäude-Objekte, die fusioniert und auf den *level 8* übertragen wurden. Durch die Fusionierung erhielt das Hochbahn-Objekt eine nur für dieses Objekt charakteristische Länge. Diese Eigenschaft wurde in die Klassenbeschreibung von *elevated railway* integriert. Die „Lücken“ in diesem Segment stammen von den bewegten Zügen, die sich hinsichtlich der spektralen Eigenschaften wesentlich von der Hochbahn unterscheiden. Um schließlich die Hochbahn als ganzes Objekt ausgeben zu können, wurden die Züge mittels Algorithmus „*Enclosed by Class: railway elevated*“ klassifiziert und bilden in der

*Groups*-Registerkarte die Kinderklasse von *railway elevated*. Die Stabilität der beiden Klassen *elevated railway* und *S-Bahn* beträgt 1,0. Die klassifizierte Hochbahn ist in Abb. 60 zu sehen. Für die Gebäude wurde eine neue Klasse *buildings without railway* erstellt, die in der Klassenbeschreibung nur die invertierte Eigenschaft „*not railway elevated*“ besitzt. Dementsprechend ist deren Stabilität sehr hoch und beträgt: 1,0. Um an die vollständige und korrekte Form der Gebäude zu erhalten, mussten nur noch die begrünten Dächer als Bestandteil der Gebäude klassifiziert werden.

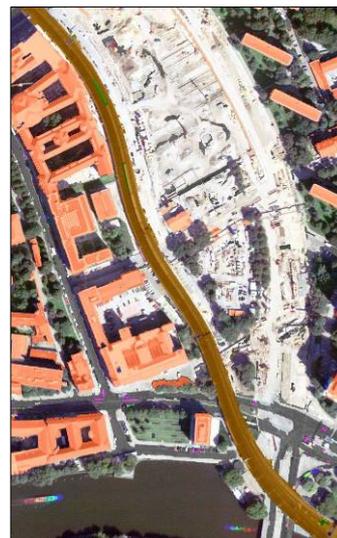


Abb. 60 Klassifizierungsergebnis des *levels 8*: Hochbahn wurde von Gebäuden getrennt klassifiziert

### Klassifizierung der begrünten Dächer im *level 8*

Wie in den vorherigen Kapiteln beschrieben, blieben die begrünten Dächer bis zum *level 7* als Vegetation klassifiziert und wurden nicht als Gebäude-Objekte auf die höheren *level* übertragen. Dies führte zur Entstehung unklassifizierter „Lücken“. Die fehlende Klassifizierung wurde auf *level 8* nachträglich ergänzt. Die sich hier befindenden Gebäude-Objekte

sind fusioniert und stellen ganz grobe Segmente dar. Die Segmente der begrünten Dächer waren in den meisten Fällen von den Gebäude-Objekten umgeben, so dass man den den Algorithmus „*Enclosed by Class: buildings without railway*“ benutzen konnte. Zusätzlich wurde ein Intervall für den NDVI bestimmt.

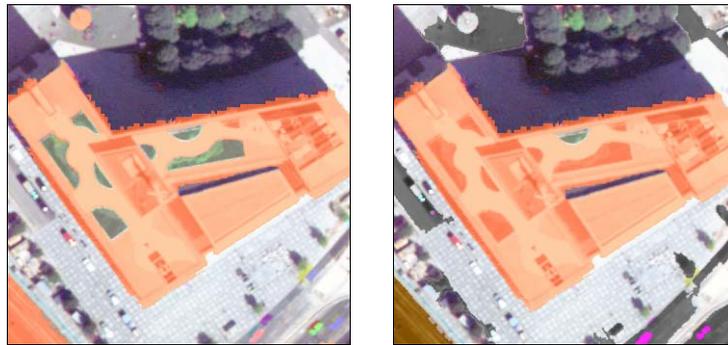


Abb. 61 Klassifizierung der begrünten Dächer: unklassifiziert, klassifiziert und als Kinderklasse der Gebäude mit verbleibendem Restfehler



Abb. 62 Klassifizierungsergebnis der Gebäude

Wie in Abb. 61 zu sehen ist, blieben manche begrünten Dächer immer noch unklassifiziert. Dies lag vor allem daran, dass sie einen zu hohen Wert für NDVI aufwiesen. Dieser sollte trotzdem nicht erhöht werden, weil die Gefahr bestand, auch die sich in kleinen Innenhöfen befindenden Bäume als begrünte Dächer zu klassifizieren. Da es nur sehr wenige solcher Objekte gab, konnten sie vernachlässigt werden.

Die Gebäude wurden erfolgreich von anderen erhabenen Objekten getrennt und um die begrünten Dächer ergänzt. Sie konnten in dieser korrekten Form als thematischer Raster-Layer und als Shape-File exportiert und mithilfe einer anderen Software bezüglich ihrer Genauigkeit beurteilt werden. Das Klassifizierungsergebnis der Gebäude wurde in Abb. 62 dargestellt. Von Vegetation verdeckte Gebäude und stark verschattete Dächer sind die eigentlich problematischen Bereiche und verursachen die meisten Fehler.

### 6.7.5. Klassifizierung bewegter Objekte

Die Klassifizierung von Landnutzungs-klassen wie Gewässern oder Straßen in urbanen Räumen ist wichtig und soll so genau wie möglich durchgeführt werden. Bewegte Objekte werden in HRSC-Bilddaten mehrfach abgebildet, da die Aufnahme in den einzelnen Kanälen zu verschiedenen Zeitpunkten erfolgt. Autos oder Boote in Bewegung unterscheiden sich spektral stark von ihrer Umgebung. Sogar bei einem sehr großen *scale parameter* bilden sie daher separate Segmente und sind nicht Teil der umgebenden Klassen.

Natürlich sollen die bewegten Objekte derjenigen Klasse zugewiesen werden, die sie verdecken. Zu diesem Zweck wurden sie nach der Klassifizierung unter einer Elternklasse in der *Groups*-Registerkarte mit deren Umgebungs-klassen zusammengefasst. Perspektivisch sollen diese Klassifizierungen auch dazu dienen, alle bewegten Objekte automatisiert zu entfernen und durch die verdeckte Klasse zu ergänzen.

Die bewegten Boote wurden auf *level 6* klassifiziert. Die Klassenhierarchie für diesen *level* ist in Abb. 63 zu sehen.

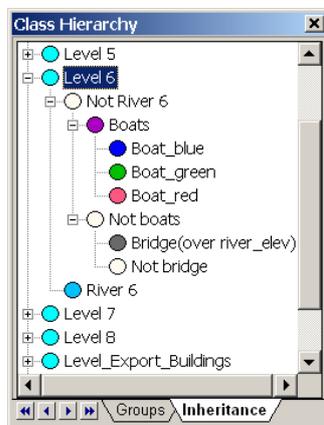


Abb. 63 Klassenhierarchie für level 6.

Charakteristisch für die sich bewegend Boote ist deren sehr kleine Entfernung zur Klasse *river\_6*, die aus *level 3* übertragen wurde. Diese Eigenschaft *floss* in die Klassenbeschreibung der Klasse *boats* ein. Zusätzlich wurde die geometrische Eigenschaft *Länge* benutzt. Die Kinderklassen, die die Bewegungszeitphasen in unterschiedlichen Farben darstellen, wurden mittels Ratio der entsprechenden Kanäle klassifiziert. An dieser Stelle ist zu bemerken, dass die Bewegungsphasen zusammenfassend in drei Farben - Blau, Grün und Rot - abgebildet wurden. In der Wirklichkeit werden manchmal die sich bewegend Objekte in mehreren Mischfarben dargestellt. Die Unterschiede in der Darstellung hängen von der Bewegungsrichtung der Objekte ab. Die Stabilität aller Klassen der sich bewegend Boote beträgt 1,0. Es ist nahe liegend, dass hohe Stabilitäten besonders leicht dann erreicht werden, wenn nur sehr wenige Klassen auf diesem *level* erzeugt werden. Das Klassifizierungsergebnis ist in Abb. 64 zu sehen. Die Straßen wurden

ursprünglich auf *level 3* klassifiziert und anschließend mittels des klassenbezogenen Merkmals „*relative area of sub-objects: semantic road network*“ auf *level 8* übertragen. Dieser *level* wurde aufgrund des relativ großen *scale parameters* - 100 mit fusionierten Gebäuden - gewählt. Die Klassenhierarchie des *level 8* ist in Abb. 59 dargestellt. Im nachfolgenden Schritt wurden die Straßen-Objekte fusioniert, so dass man den Algorithmus *Enclosed by Class: asphalt roads* für die Klassifizierung der Autos auf den Straßen benutzen konnte. Zusätzlich wurde das Merkmal *Größe* verwendet, damit nur Autos und nicht andere größere Objekte der Klasse *Cars* zugewiesen werden. Diese Klasse ist in der *Groups*-Registerkarte Kinderklasse von *asphalt roads*; somit können die beiden bequem fusioniert und übertragen werden. Die Stabilität der Klassen *asphalt roads* und *cars* beträgt entsprechend 0,96 und 1,0. Das Klassifizierungsergebnis für Straßen und sich bewegend Autos wurde in Abb. 64 gezeigt.

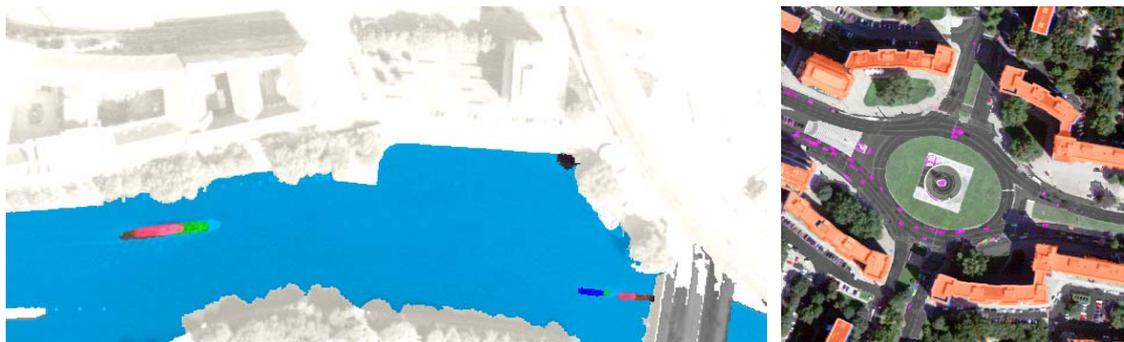


Abb. 64 Klassifizierung bewegter Objekte (Schiffe, Autos)

## 6.8. Klassifizierungsergebnis und statische Evaluierung des Testgebietes

Nach dem erfolgreichen Testen der Algorithmen an einem kleineren Ausschnitt wurden diese auf das gesamte Projektgebiet übertragen. Wegen der relativ kleinen Ausdehnung dieses Gebietes von 10800\*7800 Pixel war ein echtes *tiling* mit Hilfe des entsprechenden Werkzeuges in *Definiens Developer* nicht notwendig; der Datensatz wurde am Stück segmentiert und klassifiziert.

Die gesamte Analyse (Segmentierung und Klassifizierung einschließlich) wurde insgesamt drei Mal durchgeführt, da untersucht werden sollte, ob ein Oberflächenmodell und wenn ja welches die Klassifizierungs- und Segmentierungsprozesse optimal unterstützt. Für die Klassifizierung selbst wurde immer das LIDAR-

Oberflächenmodell verwendet. Wäre auf ein Oberflächenmodell verzichtet worden, hätten nicht alle Klassen gebildet werden können, da Höhenunterschiede dazu genutzt wurden, Klassen zu bilden und scharf zu trennen. In Tab. 13 werden die Kombinationen der verwendeten Daten bei den drei Analysemodellen zusammengestellt. Die drei Modelle wurden mit Großbuchstaben von A bis C benannt. Wie man in den Zeilen ablesen kann, wurden die Modelle A und B mithilfe zweier unterschiedlicher DOM segmentiert und dann auch unter Verwendung dieses jeweiligen DOM klassifiziert. Das letzte Modell untersucht ein Fall, in dem das DOM nicht zur Segmentierung sondern nur zur Klassifizierung einbezogen wurde.

	Analysemodell A	Analysemodell B	Analysemodell C
Segmentierung	HRSC-DOM, multispektrale Daten HRSC	LIDAR-DOM/ multispektrale Daten HRSC	multispektrale Daten HRSC
Klassifizierung	HRSC-DOM, multispektrale Daten HRSC	LIDAR-DOM, multispektrale Daten HRSC	LIDAR-DOM, multispektrale Daten HRSC

Tab. 13 Kombinationen der für drei unterschiedliche Analysemodelle verwendeten Daten

### Analysemodell A

In diesem Modell wurde bei der Segmentierung das HRSC-DOM und multispektrale Daten der HRSC eingesetzt. Bei der Klassifizierung wurde das LIDAR-DOM verwendet. Betrachtet man alle Klassen, also Asphalt, Gebäude, Beton, Kunstrasen, Hochbahn, Sand, Schatten, Boden/Erde, Schwimmbad, Hohe Vegetation, niedrige Vegetation und Gewässer in einer Stichprobe mit 520 Punkten, beträgt

das arithmetische Mittel für die Klassifizierungsgenauigkeit 88,08%. Am sichersten werden erwartungsgemäß die beiden Klassen für Wasser klassifiziert. Hier Betrag die Genauigkeit 100%. Genauigkeiten größer oder gleich 90% wurden bei allen Klassen bis auf die Klassen Sand, Boden, Sportplätze und niedrige Vegetation erzielt. Das Ergebnis ist damit als gut bis sehr gut einzustufen.



Abb. 65 Klassifizierungsergebnis des Analysemodells A

### Analysemodell B

In der statistischen Auswertung des gesamten Ergebnisses wird ein Wert von 87,5% erreicht. Alle Klassen erzielten eine Genauigkeit größer oder gleich 90%, bis auf die bereits in „Klassifizierung A“ genannten Klassen. Zwar ist das Klassifizierungsergebnis unter Verwendung LIDAR-DOM etwas schlechter; der Unterschied zum Klassifizierungsergebnis, bei dem ausschließlich HRSC-AX Daten verwendet wurden, ist mit 0,58% äußerst gering. Der Klassifizierungs- und Segmentierungsalgorithmus sollte daher an einem größeren Untersuchungsgebiet getestet werden. Trotz dieser etwas schlechteren Ergebnisse der Stichprobe erscheint bei einem

visuellen Vergleich diese Klassifizierung die besten Ergebnisse zu liefern. Ein Problem das zu diesem möglicherweise irreführenden Ergebnis führt, könnte eine zu geringe Anzahl von Stichproben sein. Um diese Vermutung bestätigen oder verwerfen zu können, sollte in Zukunft – trotz des sehr hohen zeitlichen Aufwandes - eine Vollerhebung durchgeführt werden. Deutlich erkennt man in Abb. 66 im Vergleich zu Abb. 65, dass hier die Ergebnisse in den bereits in Kap. 3 besprochenen Problem-bereichen des HRSC-DOM deutlich besser sind. Dies gilt speziell für Schattenbereiche und Innenhöfe.



Abb. 66 Klassifizierung mit LIDAR



Abb. 67 Klassifizierungsergebnis in optimaler Kombination

Abb. 67 zeigt die optimale Kombination aus Vegetationsklassen, Straßen, Gebäuden, und Gebäudehöhen. Definiens Developer erlaubt das

Zusammenfügen der Klassifizierungsergebnisse aus verschiedenen *levels* auf eine Ergebnisebene. Der Kappa-Wert betrug für alle Klassen 0.8646.

## Analysemodell C

In diesem Analysemodell wurde das DOM ausschließlich als eine der Eigenschaften in Klassenbeschreibungen, also ausschließlich bei der Klassifizierung benutzt. Eingesetzt wurde das LIDAR-DOM. Die Segmente wurden demzufolge nur anhand spektraler Informationen erstellt. Ein Vergleich der unterschiedlichen Segmentierungen (unter Verwendung des DOM und ohne DOM) wurde bereits am Testgebiet durchgeführt und in Kap. 6.6 im Detail dargestellt. Bei Analysemodell C konnte festgestellt werden, dass aufgrund der Nichtverwendung des Oberflächenmodells bei der Segmentierung die Form der Objekte, besonders der Gebäude-Objekte, besser wiedergegeben wird, da die fehlerhaften Bereiche des DOM nicht berücksichtigt sind. Die Gebäude werden hier korrekt erfasst und Schattenbereiche stellen kaum ein Problem für die Klassifizierung dar.

Dieses Beispiel zeigt, dass es kaum einen Unterschied macht oder sogar

günstiger ist, kein Oberflächenmodell für die Segmentierung zu verwenden, wenn dieses nicht zu nahezu 100% richtig ist. Für die Klassenbeschreibung bestimmter Klassen ist aber ein DOM unabdingbar (z.B. zur Trennung der Gebäude von spektral ähnlichen Strassen) und sollte demzufolge immer bei der Klassifizierung der städtischen Gebiete verwendet werden. Voraussetzung hierfür ist natürlich, dass multispektrale Information stärker gewichtet wird als die Information des Oberflächenmodells. Die visuelle Evaluierung des Klassifizierungsergebnisses fiel sehr positiv aus-bis auf ein großes begrüntes Dach, das als Vegetation klassifiziert blieb. Das Verwenden des im Abschnitt „Klassifizierung der begrünteten Dächer in level 8“ beschriebenen Algorithmus „*enclosed by class: buildings without railway*“ führte nicht zum Erfolg. Die *overall Kappa* Statistik erreichte trotzdem einen sehr hohen Wert von 0,8708. Dieser Wert ist dem aus Analysemodell A fast gleich.



Abb. 68 Klassifizierungsergebnis des Analysemodells C

## Bewertung der Ergebnisse

In den Statistiken der unterschiedlichen Analysemodelle ergeben in der Summe nur sehr geringe Unterschiede. Untersucht man jedoch die Ergebnisse nach Klassen getrennt ergibt sich ein anderes Bild. Die besten Ergebnisse sind in den Analysemodellen A und C zu finden, im Analysemodell B, dem Modell in dem LIDAR Daten für Segmentierung und Klassifizierung verwendet werden, wurde in einer Klasse das beste Ergebnis erzielt. Tab. 14 zeigt diese Resultate.

Ursache für das schlechtere Abschnei

den des kombinierten Ansatzes aus HRSC-Bilddaten und LIDAR Oberflächenmodell in der Bildanalyse sind in den verschiedenen Aufnahmezeitpunkten der Daten und den unterschiedlichen Aufnahmegeometrien der Sensorprodukte zu suchen. Bei der HRSC basieren die Orthobilder auf dem Oberflächenmodell auf denselben Ausgangsdaten. Dadurch ergibt sich eine optimale Korrelation von Bilddaten und Oberflächenmodell, was in den etwas besseren Klassifizierungsergebnissen Ausdruck findet.

	Analyse Modell A	Analyse Modell B	Analyse Modell C
Class Name	Kappa	Kappa	Kappa
Asphalt	0.9181	0.8903	0.9453
Buildings	0.8923	0.9459	1.0000
Concrete	0.9712	0.9133	0.9708
Imitation grass	0.8926	0.9458	0.9729
Railway	0.9730	0.9461	0.9461
Sand	0.6823	0.6045	0.5544
Shadow	0.9727	0.9189	0.9193
Soil	0.5508	0.5273	0.6797
Sport field	0.7088	0.8131	0.5806
Swimming pool	1.0000	0.9461	0.9193
Vegetation high	0.9459	0.9458	0.9191
Vegetation low	0.8361	0.8632	0.9453
Water bodies	1.0000	1.0000	1.0000
Overall Kappa Statistics	0.8709	0.8646	0.8708
Prozentsatz der korrekten Klassifizierung	88,08	87,50	88,08

Tab. 14 Kappa-Statistik

## 6.9. Visuelle Evaluierung der Klassifizierung

In diesem Kapitel werden die Klassifizierungsergebnisse visuell untersucht und bewertet. Hier wird zum einen gezeigt, was sich als sinnvoll und nützlich erwiesen hat, zum anderen werden Schlüsse für zukünftige Arbeiten gezogen.

### 6.9.1. Klassifizierungsergebnisse Gebäude

In Abb. 69 werden die Klassifizierungsergebnisse eines Gebäudekomplexes aus den Analysemodellen A bis C im Vergleich dargestellt. An diesen Beispielen ist deutlich zu sehen, dass die Qualität des Oberflächenmodells entscheidend für die Zuverlässigkeit der Klassifizierung ist. Es ist unter Umständen besser, auf die Verwendung eines DOM bei der Segmentierung zu verzichten und ausschließlich multispektrale Informationen zu nutzen. In der Abb. 69 ist zu erkennen, dass die Gebäude in den Analysemodellen B (Segmentierung und Klassifizierung unter Verwen-

dung des *LIDAR-DOM*) und C (Verwendung des *LIDAR-DOM* ausschließlich zur Klassifizierung) korrekt erfasst wurden. In der Klassifizierung des Modells A, bei der HRSC-DOM zur Segmentierung benutzt wird, sieht man deutlich, dass die fälschlicherweise erhobenen Innenhöfe im DOM eine falsche Klassifizierung verursachen. Diese Problematik trat in allen fehlerbehafteten Bereichen des DOM auf. Teilweise konnten die besten Ergebnisse unter völligem Verzicht auf ein Oberflächenmodell bei der Segmentierung erzeugt werden.

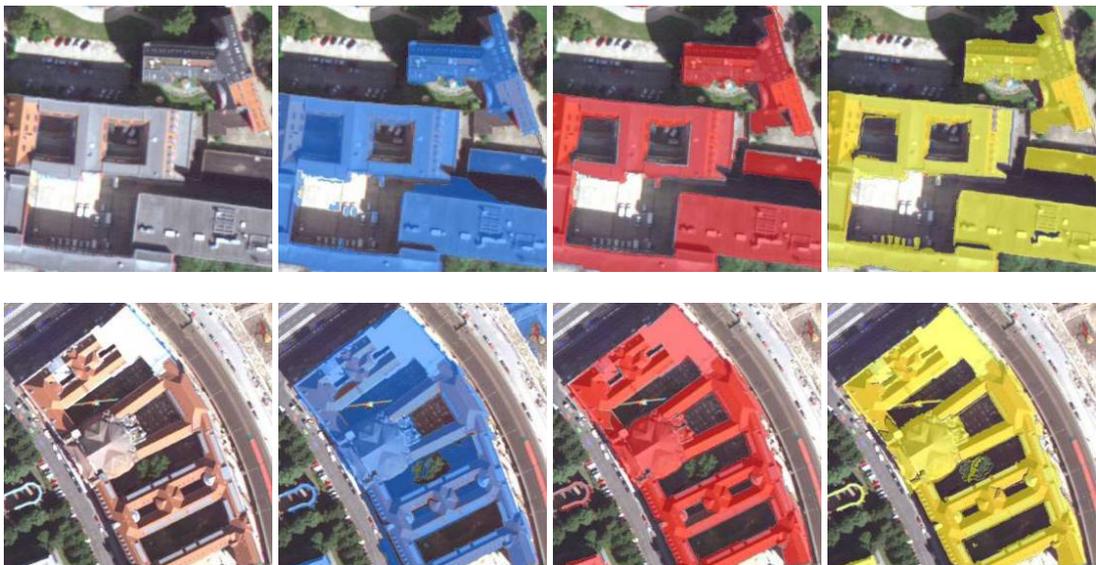


Abb. 69 Klassifizierung der Innenhöfe, RGB, Analysemodelle A (blau), B (rot) und C (gelb)

---

## 6.9.2. Verschneidung der ALK mit der Klassifizierung und Monitoring

In den folgenden Beispielen wird gezeigt, dass eine Überführung von Klassifizierungsergebnissen in eine Vektordatei, hier im *shape*-Dateiformat, und die Auswertung in einem GIS sehr nützliche Ergebnisse liefern können.

Ein direkter Vergleich zwischen ALK und Klassifizierungsergebnis ist nur mit Einschränkungen möglich. So werden typischerweise Gebäude entlang ihrer Grundrisse für die ALK aufgenommen; diese Möglichkeit besteht bei der Erhebung basierend auf Orthophotos kaum, da sie zumeist von Dachüberständen verdeckt sind. Einzige Ausnahme sind hier alle Gebäude ohne oder mit nur geringem Dachüberstand z.B. Hochhäuser und Plattenbauten, pyramiden- und pyramidenstumpffartig sowie kegel- und kegelstumpffartige Gebäudeformen, die in urbanen Räumen bei 30-50% der Gebäude zu finden sind.

Abb. 70 zeigt das Ergebnis der Gebäudeklassifizierung, eine Überlagerung der Bilddaten mit ALK und das Differenzbild zwischen Klassifizierungsergebnis und ALK. In diesem Beispiel ist gut zu erkennen, dass ein abgerissenes Gebäude im Differenzbild korrekt wiedergegeben wird, so dass ein Benutzer mit dieser Information die ALK leichter fortführen könnte.

Ein anderes Ergebnis ist in Abb. 71 zu sehen. Hier treten genau genommen zwei Probleme auf. Ein Gebäude ist offensichtlich entfernt worden, ein anders teilweise von Bäumen so verdeckt, dass es kaum noch erkennbar ist. Nichtsdestotrotz wird dem Benutzer schnell klar, dass hier ein deutlicher Unterschied zwischen Kartenwerk und Luftbild besteht.

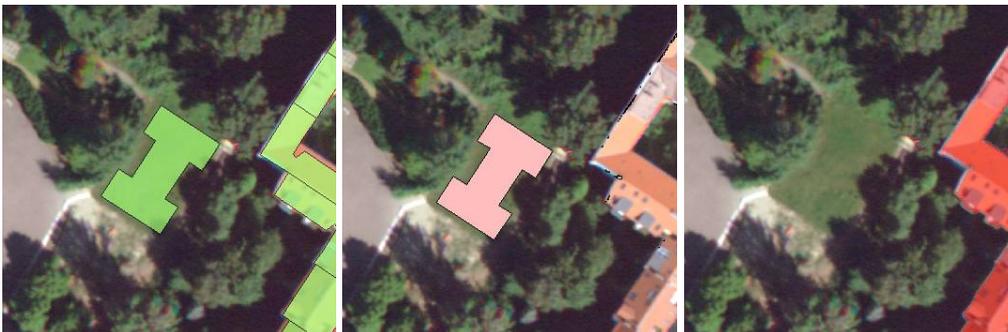


Abb. 70 Gebäudeklassifizierung, ALK, Differenzbild Gebäude-ALK

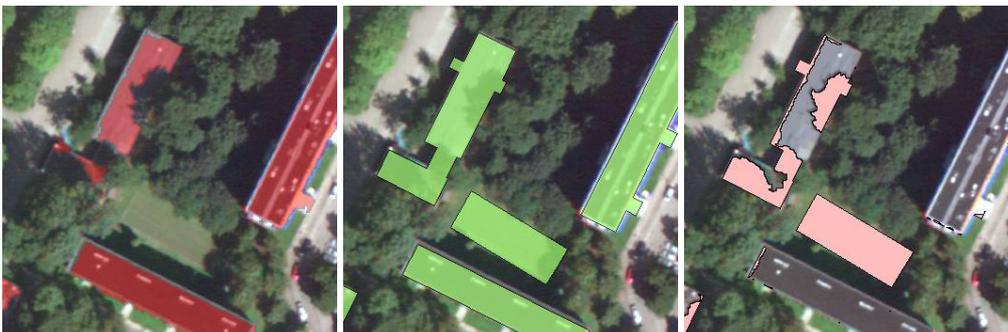


Abb. 71 Gebäudeklassifizierung, ALK, Differenzbild Gebäude-ALK

Abb. 72 zeigt zwei Gebäude, die vollständig von Bäumen verdeckt werden. Eine Klärung durch den Betrachter des Luftbildes ist hier nicht möglich, da einfach nicht erkannt werden kann, ob die Gebäude tatsächlich von Bäumen verdeckt sind oder einfach abgerissen wurden. Hier könnte eine Befliegung in der vegetationsfreien Zeit nützlich sein oder aber die Auswertung von *LIDAR*-Daten - sofern vorhanden. Ansonsten bliebe hier nur die Recherche vor Ort.

Die beschriebene Methode lässt sich für viele Aufgaben des Monitoring einsetzen. Eine Übertragung auf andere Bereiche der Klassifizierung ist denkbar; so ließe sich auch ein Abgleich mit dem Baumkataster der Berliner Bezirke durchführen mit dem Ziel, Veränderungen zu erfassen.

Durch die Erstellung eines Differenzbildes sind Bereiche mit Veränderungen schnell zu identifizieren. Sinnvoll erscheint der Einsatz dieser Methode vor allem in Bereichen, die einem schnellen Wandel unterliegen. Als Beispiele hierfür seien im Berliner

Raum das Entwicklungsgebiet der Wasserstadt am Rummelsburger See und der geplante Großflughafen Berlin-Brandenburg genannt. Zwar lässt sich die ALK kaum auf Basis der Luftbilder aktualisieren, jedoch ist es möglich, Gebiete mit Veränderungen schnell zu erfassen und dann eine genaue Erhebung nach den Regeln der ALK zu veranlassen.

In vielen Regionen der Erde existieren keine elektronischen Karten zur Verwaltung von Katasterdaten. Sicherlich wäre es mit einem enormen Aufwand verbunden, Rio de Janeiro oder Sao Paulo in Brasilien mit einer Einwohnerzahl in der Agglomeration deutlich jenseits der 10-Millionengrenze in der Genauigkeit der ALK zu erfassen. Hier bieten sich die Methoden der Fernerkundung und speziell des Monitoring basierend auf Fernerkundungsdaten an. Besonders die Möglichkeit, unter *Definiens Developer* Klassen direkt als *shape*-Dateien mit ihrer Attributtabelle zu exportieren, kann hier ein effektives Arbeiten in sehr großen Bereichen unterstützen.



Abb. 72 Gebäudeklassifizierung, ALK, Differenzbild Gebäude-ALK

---

Abb. 73 zeigt die Baustelle des neuen Einkaufszentrums ALEXA am Berliner Alexanderplatz. In diesem Beispiel sieht man, dass die Oberflächenmodelle zu verschiedenen Zeitpunkten aufgenommen wurden. Der Bau ist im HRSC Oberflächenmodell weiter fort-

geschritten als in dem drei Monate früher aufgezeichneten LIDAR Modell. Daher wird basierend auf dem HRSC-Oberflächenmodell ein Gebäude klassifiziert, nicht aber auf der Basis des LIDAR Oberflächenmodells.



Abb. 73 RGB, Klassifizierung basierend auf LIDAR-DOM (rot) und auf HRSC-DOM (blau)

### 6.9.3. Anwendung des Ergebnisses zur Kartierung des Versiegelungsgrades

Eine verbreitete Anwendung von Klassifizierungsergebnissen in urbanen Räumen ist die Kartierung des Versiegelungsgrades eines Stadtgebietes. Die Überbauung von natürlichen Böden hat negative Auswirkungen auf das Stadtklima und somit auch auf die Flora und Fauna, den Wasserhaushalt und den Lebensraum des Menschen. Besonders im Sommer kommt es zu einer starken Aufheizung von versiegelten Flächen. Die Verdunstung durch Vegetation ist stark eingeschränkt, und die relative Luftfeuchtigkeit sinkt. Folgen der hohen Versiegelung in Großstädten und Ballungsräumen sind zu kleine Vegetationsbestände, was die Verdunstung und das Binden der Luftschadstoffe

durch die Vegetation einschränkt und ein Sinken der Luftfeuchtigkeit verursacht. Die Versiegelung der Böden hat außerdem negative Folgen für den Wasserhaushalt.<sup>127</sup>

Die Senatsverwaltung für Stadtentwicklung ist Herausgeber des Berliner Umweltatlases. In diesem befindet sich auch eine Karte, die den Versiegelungsgrad des Berliner Stadtgebiets widerspiegeln soll. Die erste Versiegelungsanalyse wurde für das Jahr 1993 durchgeführt. Sie wurde anhand der Satellitenbildinterpretation

---

<sup>127</sup> Senatsverwaltung für Stadtentwicklung (2007): [http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/da102\\_01.htm](http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/da102_01.htm)

von 1985 bzw. 1988 entstandenen Landsat-TM-Aufnahmen und auf der Grundlage der Statistik des Statistischen Landesamtes erstellt und in den Jahren 1991 und 2004 durch Abgleich mit Luftbildern aktualisiert. Diese Daten können nur eingeschränkt die Grundlage für eine zuverlässige Versiegelungsanalyse bilden, da erstens die Auflösung der Landsat-TM-Aufnahmen für die Klassifizierung eines städtischen Gebietes nicht ausreicht und zweitens die erwähnten Statistiken auf dem Liegenschaftskataster basieren. Die tatsächliche Landbedeckung wird möglicherweise falsch wiedergegeben, da ein Flurstück, das als Gebäude- und Freifläche ausgewiesen ist, unter Umständen gar nicht bebaut ist, also eigentlich in der Karte als Freifläche erscheinen müsste.<sup>128</sup>

Aufgrund dieser Mängel in der Kartierung des Versiegelungsgrades wurde im Rahmen dieser Arbeit eine Untersuchung durchgeführt, wie sich Klassifizierungsergebnisse basierend auf HRSC-AX-Daten nutzen lassen, um den Versiegelungsgrad genauer wiederzugeben und dabei auch kleinere unversiegelte Flächen akkurat zu berücksichtigen. Einzige Einschränkung war hier die geometrische Auflösung der Bilddaten

von 20 cm, die nicht immer ausreichend ist, um teilversiegelte Flächen, also Pflasterungen oder Rasengittersteine, zu erfassen. Deshalb wurden die Klassifizierungsergebnisse in ein GIS überführt. Innerhalb des GIS erfolgte eine Verschneidung mit den vorliegenden Blöcken und Blockteilflächen aus der ALK. Dadurch konnte der Versiegelungsgrad innerhalb eines Blocks bestimmt werden.

Abb. 74 stellt beide Kartierungen gegenüber. Beim visuellen Vergleich zeigt sich, dass es sehr wenige Flächen gibt, die den gleichen Versiegelungsgrad in beiden Karten aufweisen. Im Umweltatlas wird bis auf wenige Ausnahmen ein grundsätzlich höherer Versiegelungsgrad ausgewiesen als in der Klassifizierungsauswertung. In großen Blöcken wirkt es sich am stärksten aus, dass kleinere nicht versiegelte Flächen aufgrund der vorher geschilderten Erhebungsmethode nicht berücksichtigt werden. Hier sind gravierende Unterschiede zur realen Versiegelung zu beobachten. Die quantitativen Unterschiede liegen bei bis zu 50%. Eine weitere Erklärung für die kleineren Versiegelungsgrade basierend auf dem Klassifizierungsergebnis ist die Verdeckung einiger versiegelter Flächen durch Bäume.

---

<sup>128</sup> Ebd.



Abb. 74 Versiegelungsgrad im Umweltatlas und als Verschneidung aus Klassifizierung und ALK

Trotz der vorher erwähnten Probleme bei Klassifizierungen und bei der Erhebung von teilversiegelten Flächen sind die Ergebnisse viel genauer. Ein sinnvoller Ansatz zur Fortführung dieser Kartierung könnte daher eine Neuerhebung der Daten basierend auf Klassifizierungen von hochauflösenden digitalen Luftbilddaten sein. Mit zunehmender geometrischer Auflösung dieser Daten ist es denkbar, dass in Zukunft auch teilversiegelte Flächen erfasst werden können. Optimal wäre

die Kombination aus einer möglichst vegetationslosen Frühjahrsbefliegung zur Klassifizierung der Gebäude und einer Sommerbefliegung zur Klassifizierung der Vegetation.

Unter dem Gesichtspunkt, dass Befliegungen des Berliner Stadtgebiets aus rechtlichen Gründen ohnehin regelmäßig stattfinden müssen, ergeben sich in diesem Bereich weitere Möglichkeiten des Monitoring.

#### 6.9.4. Übertragbarkeit der Algorithmen auf andere Datensätze

Im Rahmen dieser Arbeit wurde auch untersucht, wie sich Algorithmen auf andere oder weitere Datensätze übertragen lassen. Da keine zwei Luftbilddatensätze hinsichtlich ihrer spektralen Eigenschaften ähnlich und gar gleich sind, müsste man Werkzeuge zur Verfügung haben, die

es erlauben würden, die an einem Testgebiet entworfene Regelbasis so zu steuern, dass sie sich optimal an die sich verändernden physikalischen Eigenschaften der zu analysierenden Aufnahmen anpasst und das Anwenden der Analyse auch an einem sehr unterschiedlichen Bild erlaubt.

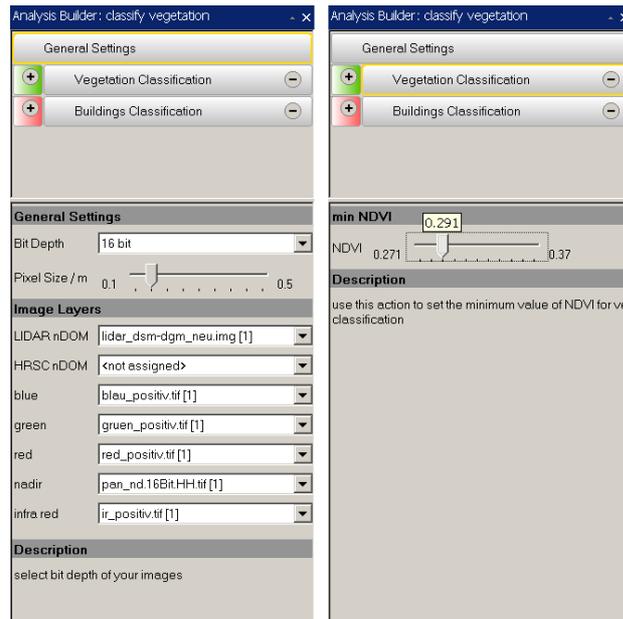


Abb. 75 Beispiel für die Erstellung einer action library

Solche Werkzeuge und eine umfangreiche Liste von Analysealgorithmen stellt *Definiens Developer* dem Bearbeiter zur Verfügung. Die Software erlaubt es, der entwickelten Regelbasis eine so genannte *action library* hinzuzufügen, die einzelne *actions* beinhaltet. Diese *actions* werden durch den Bearbeiter entworfen und können aus Schieberegler, Checkbox, Drop-Down-List und weiteren Komponenten bestehen. Der Nutzer kann die einzelnen Algorithmen aus der *action library* auswählen oder deren Grenz- und Mittelwerte mittels *action* Komponenten beeinflussen. In eine *action library* (vgl. Abb. 75) sollen auch Komponenten für allgemeine Einstellungen (*general settings*) wie Bittiefe, Pixelgröße und benutzte Layers eingebaut werden. Deren Bestimmung durch den Anwender erlaubt das Verknüpfen der benutzten Bilddaten mit den geeigneten *actions*. Die Festlegung der allgemeinen Einstellungen ermöglicht das Anpassen der einzelnen Algorithmen an die verwendeten Daten. Hierbei ist besonderes Augenmerk auf die Robustheit der entworfenen Regelbasis

zu legen. Je robuster und einfacher die entworfenen Algorithmen, desto sicherer und zuverlässiger die Übertragbarkeit der Analyse auf die anderen Datensätze. Im Idealfall werden nur die Statistiken der einzelnen Layer verwendet. Dies ist nicht immer möglich, da die hohe Heterogenität der Datensätze das einfache Gestalten der Algorithmen einschränkt. An einigen Stellen lässt es sich nicht vermeiden, ganz genaue Merkmalswerte in den Klassenbeschreibungen zu benutzen, was wiederum die Übertragbarkeit erschwert.

Erste Ergebnisse lassen erkennen, dass zumindest die Übertragbarkeit von Klassifizierungsalgorithmen auf weitere HRSC-AX Datensätze komfortabel möglich ist. Eine Klassifizierung großer Gebiete wird damit stark vereinfacht, da der zeitliche Aufwand bei der Übertragung eines bestehenden Algorithmus geringer ist, als bei einer kompletten Neuentwicklung. Der Arbeitsaufwand reduziert sich dadurch signifikant.

