

# Landbedeckungsklassifikation von Satellitenaufnahmen unter Verwendung von Kontextinformation mit minimaler menschlicher Interaktion

ERIC BACH<sup>1</sup>, BJÖRN FRÖHLICH<sup>1,3</sup>, IRENE WALDE<sup>2,3</sup>, SÖREN HESE<sup>2,3</sup>,

CHRISTIANE SCHMULLIUS<sup>2,3</sup> & JOACHIM DENZLER<sup>1,3</sup>

*Zusammenfassung: Dieser Beitrag stellt ein Verfahren zur automatischen Klassifikation von Satellitenaufnahmen in verschiedene, vorher definierte, Landbedeckungsklassen vor. Das vorliegende Verfahren ermöglicht eine voll automatische Segmentierung und Klassifikation bei minimaler Nutzerinteraktion und wenigen Trainingsgebieten. Dazu werden Techniken der semantischen Segmentierung verwendet, die bereits in anderen Aufgabenstellungen der Bildverarbeitung, wie zum Beispiel in der Fassadenerkennung, große Erfolge aufweisen können. Bei dieser Methode werden neben lokalen Merkmalen auch kontextuelle Bezüge von Klassen untereinander berücksichtigt. Unter Zuhilfenahme von Kontextinformationen werden die Segmentierungsergebnisse signifikant verbessert. Das Verfahren ist flexibel und kann mit beliebig vielen Bildkanälen und deren Kombinationen arbeiten. Weiterhin ist es für verschiedene Szenarien einsetzbar und Anwendungen in anderen Themenbereichen mit räumlich geringer aufgelösten Daten sind möglich. Dennoch liegt der Schwerpunkt dieser Arbeit auf hochauflösten Satellitendaten im urbanen Bereich.*

## 1 Einleitung

Die Anfänge der Landbedeckungsklassifikation aus Luftbildern liegen ca. 70 Jahre zurück (ANDERSON et al. 1976). Seither werden Luft- und Satellitenbilder verwendet, um großräumig und berührungsfrei Landbedeckung zu extrahieren. DI GREGORIO (2005) definiert Landbedeckung als beobachtete (bio)physikalische Schicht der Erdoberfläche. Ob als Grundlagedaten für Veränderungsdetektion oder zur Ableitung relevanter Planungs- und Modellierungsparameter, Landbedeckung ist eine essentielle Information, um Themen wie Klimawandel, Biodiversität, Ressourcenmanagement, Ökosystemeinwirkungen, Wohnqualität, Landnutzung oder Katastrophenmanagement zu analysieren und zu visualisieren (HEROLD et al. 2008, HÜTTICH et al. 2011, WALDE et al. 2012). Manuelle Kartierung/Digitalisierung oder Vermessung bedeuten einen hohen finanziellen, personellen und zeitlichen Aufwand. Deshalb werden automatische Prozessierungsmöglichkeiten auf Basis von flächendeckend verfügbaren Fernerkundungsdaten genutzt und stetig verbessert. Räumlich sehr hochauflöste Satellitenbilder (QuickBird, Ikonos, Worldview) ermöglichen die Ableitung der heterogenen Vielfalt urbaner Landbedeckung. Durch die räumlich sehr hoch aufgelösten Satellitenbilder wurden OBIA-Methoden (Object Based Image Analysis) entwickelt (BENZ et al. 2004, HAY &

---

<sup>1</sup> Lehrstuhl für digitale Bildverarbeitung, Friedrich-Schiller-Universität Jena

<sup>2</sup> Lehrstuhl für Fernerkundung, Friedrich-Schiller-Universität Jena

<sup>3</sup> Graduiertenschule für Bildverarbeitung und Bildinterpretation, ProExzellenz Thüringen

eMail: {eric.bach,bjoern.froehlich,irene.walde,soeren.hese,c.schmullius,joachim.denzler}@uni-jena.de

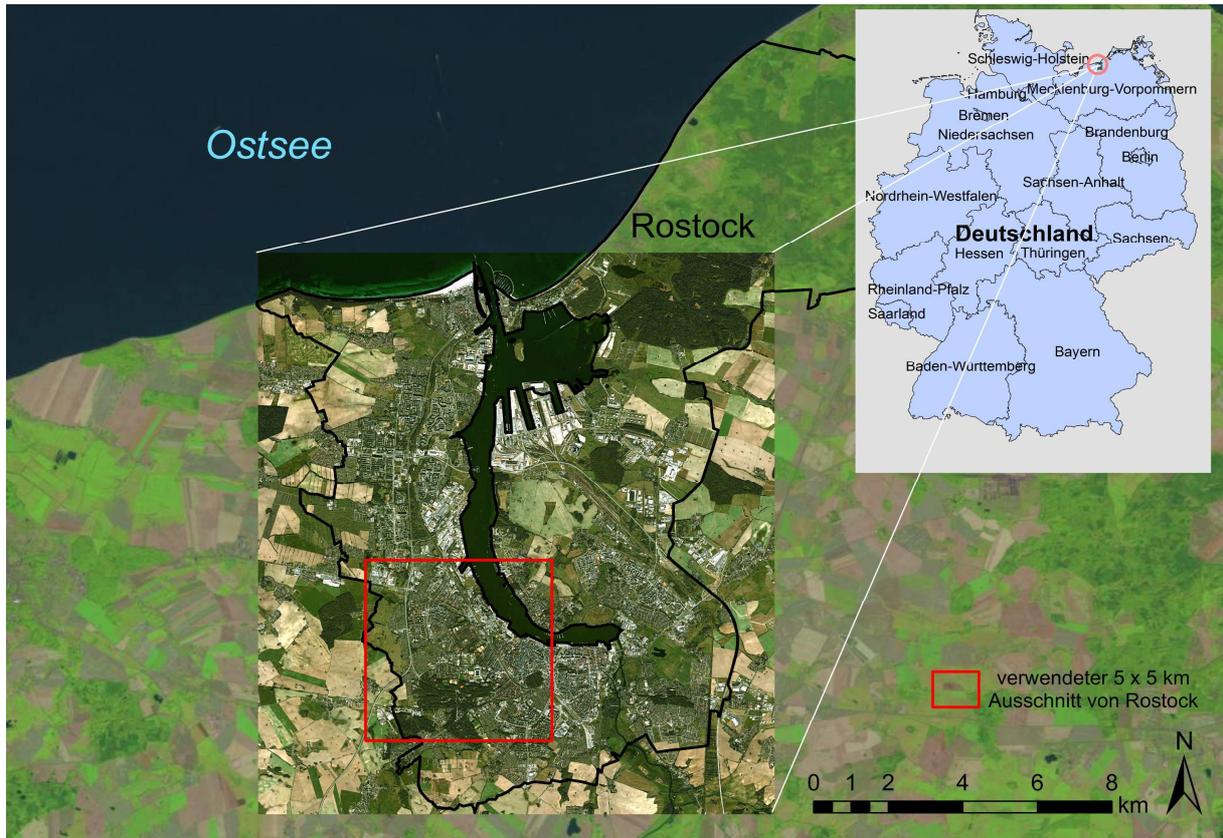


Abb. 1: QuickBird Szene (©DigitalGlobe, Inc., 2011) mit überlagerten Stadtgrenzen von Rostock und Kennzeichnung des verwendeten Ausschnitts. Hintergrund: Landsat 7 Szene (zur Verfügung gestellt vom U.S. Geological Survey, 1999).

CASTILLA 2008, BLASCHKE 2010), die in urbanen Analysen den pixelbasierten Verfahren vorzuziehen sind (MYINT et al. 2011). Pixelbasierte Verfahren betrachten ausschließlich spektrale Eigenschaften während objektbasierte Methoden, neben spektralen Eigenschaften auch Form, Textur oder Nachbarschaftsmerkmale in den Klassifikationsprozess einbeziehen.

In dieser Arbeit wird ein Verfahren zur automatischen semantischen Segmentierung und Klassifikation vorgestellt, dass mit Hilfe von minimaler Nutzerinteraktion und wenigen Trainingsgebieten urbane Landbedeckung aus hochaufgelösten Satellitenbildern extrahiert. Als Verfahren werden die so genannten Iterative Context Forests von FRÖHLICH et al. (2012a,b) verwendet. Bei dieser Methode werden neben lokalen Merkmalen auch kontextuelle Bezüge von Klassen untereinander berücksichtigt. So ist in Industriegebieten die Wahrscheinlichkeit der Nachbarschaft von Gebäuden und versiegelten Flächen wie z.B. Parkplätzen höher als bei Gebäuden in Gartenanlagen. Unter Zuhilfenahme von Kontextinformationen werden die Segmentierungsergebnisse signifikant verbessert. Das Verfahren ist flexibel und kann mit beliebig vielen Bildkanälen und deren Kombinationen arbeiten. Während eines Trainingsschrittes werden die optimalen Merkmale für eine Klasse aus einem großen Merkmalspool selbstständig ausgewählt, was der hohen spektralen Form- und Struktur-Variabilität der Klassen Rechnung trägt. Als Merkmale werden bewährte Maße aus der

Bildverarbeitung verwendet, wie zum Beispiel Rechteckmerkmale aus der Personendetektion. Die Iterative Context Forests wurden für Aufgabenstellungen der Bildverarbeitung wie z.B. Fassadenerkennung entwickelt und bezüglich Fernerkundungsdaten adaptiert.

Der Aufbau dieser Arbeit ist wie folgt strukturiert: Kapitel 2 beschreibt das Untersuchungsgebiet und das vorhandene Datenmaterial. In Kapitel 3 wird das Verfahren zur semantischen Segmentierung und die Adaptionen für Fernerkundungsdaten erläutert. Die Ergebnisse werden in Kapitel 4 dargelegt und diskutiert. Das Fazit und ein kurzer Ausblick schließen diesen Beitrag ab.

## **2 Untersuchungsgebiet und Datenbeschreibung**

Das Untersuchungsgebiet Rostock, eine norddeutsche Hansestadt mit mehr als 200.000 Einwohnern und einer Fläche von ca. 181 km<sup>2</sup> (MECKLENBURG-VORPOMMERN STATISTISCHES AMT), liegt an der Warnow-Mündung in die Ostsee. Eine wolkenfreie QuickBird Szene vom September 2009 mit vier Kanälen (Blau, Grün, Rot, Nahes Infrarot) ist verfügbar (Abb. 1). Ein 25 km<sup>2</sup> großer Ausschnitt mit einer Bodenpixelauflösung von 2m wurde verwendet, um die Methode zu testen. Die Szene wurde als Ortho-Ready Standard (OR2A) Produkt (CHENG et al. 2003) geliefert und ist auf eine mittlere Geländehöhe projiziert. Das Satellitenbild wurde bezüglich atmosphärischer Effekte korrigiert und mit Hilfe von Passpunkten und einem Geländemodell orthorektifiziert. Zusätzlich liegen LiDAR Daten für das Untersuchungsgebiet von 2006 vor. Um ein normalisiertes Oberflächenmodell (nDSM) zu erhalten, wurde das Geländemodell vom Oberflächenmodell subtrahiert. Damit stehen relative Objekthöhen als Rasterdatensatz mit einer Auflösung von zwei Metern zur Verfügung.

## **3 Semantische Segmentierung**

Die Bezeichnung semantische Segmentierung fasst verschiedene Verfahren zur pixelgenauen Annotation von Bildern zusammen ohne auf ein spezielles Anwendungsszenario beschränkt zu sein.

Als Segmentierung wird der Prozess zur Einteilung eines Bildes in disjunkte Pixelmengen, sogenannte Regionen bezeichnet. Pixel innerhalb einer Region sind bezüglich eines für alle Regionen gleichen Homogenitätskriterium (z.B. der Farbe) ähnlich. Ziel der Segmentierung ist es, das Bild in eine einfacher analysierbare Form zu überführen, oder eine Darstellung zu finden, die auf die für eine konkrete Anwendung wesentlichen Bestandteile reduziert ist. Die klassische Segmentierung ist ein unüberwachtes Verfahren, was bedeutet, dass die Pixel zwar in Regionen zusammengefasst sind, diesen Regionen aber keine Bedeutung zugeordnet wird. Weiterhin bedeutet dies auch, dass es nicht zwangsläufig einen Trainingsschritt gibt. Regionen enthalten im Idealfall genau einen wesentlichen Bestandteil eines Bildes. Diese Bestandteile werden in dieser Arbeit als Objekte bezeichnet. Da der Idealfall häufig nicht erreicht wird, kann zwischen Über- und Untersegmentierung unterschieden werden. Während bei der Untersegmentierung verschiedene Objekte in einer Region zusammengefasst werden, kann bei der Übersegmentierung ein einzelnes Objekt aus mehreren Regionen bestehen.

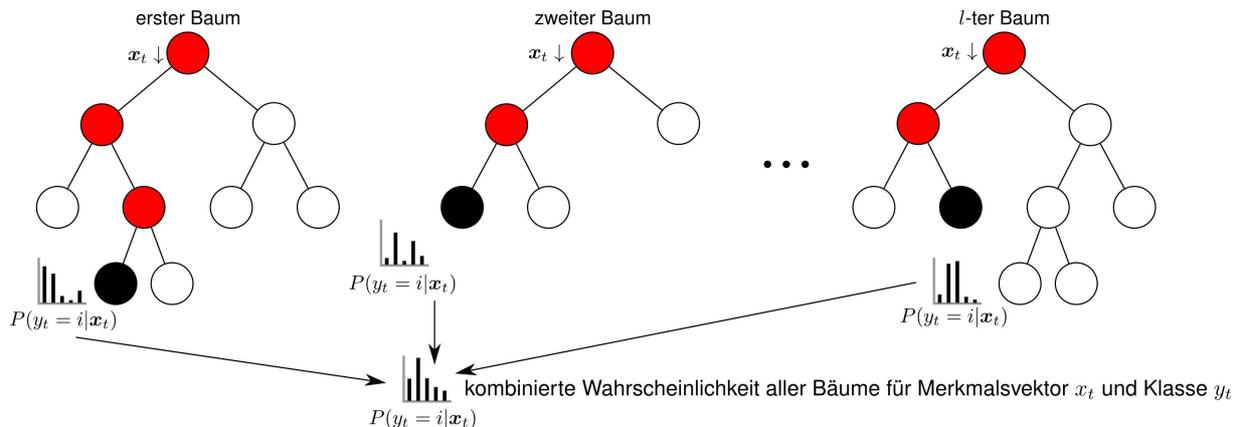


Abb. 2: Zufälliger Entscheidungswald aus  $l$  Bäumen. Für einen beispielhaften neuen Merkmalsvektor  $x_t$  zeigen die roten Knoten den Weg des Merkmalvektors an und die schwarzen die resultierenden Blätter.

Bei der semantischen Segmentierung wird jeder Region zusätzlich eine semantische Bedeutung zugeordnet. Dies ist üblicherweise ein Klassenname aus einer Menge von vorher definierten und trainierten Klassen. Die Auswahl der Klassen hängt von dem gewählten Szenario und der Zielstellung ab. So kann z.B. die Satellitenaufnahme eines Landes betrachtet werden, wobei die gewählten Klassen Stadt oder Wald sein könnten. Wird hingegen die Aufnahme einer einzelnen Stadt betrachtet, dann wären sinnvolle Klassen beispielsweise Dach oder versiegelte Fläche. In diesem Abschnitt werden die Iterative Context Forests (ICF) von FRÖHLICH et al. (2012a,b) vorgestellt. Anschließend werden die Unterschiede und Adaptionen im Vergleich zur Originalarbeit gezeigt.

### 3.1 Notwendige Grundlagen

Merkmalsvektoren sind eine abstrakte Ansammlung von Merkmalen, die ein Objekt oder den Teil eines Objektes beschreiben. So ist z. B. der durchschnittliche Farbwert innerhalb eines Objektes eine einfache Ansammlung von Merkmalen. Um komplexere Strukturen beschreiben zu können, sind neben Farbe auch Textur und Form wichtige Eigenschaften, die durch Merkmale beschrieben werden sollten.

Das Klassifikationsproblem bezeichnet in der Mustererkennung die Zuordnung eines Klassennamen zu einem Merkmalsvektor. Um dies zu erreichen, müssen bereits vorher beschriftete Merkmalsvektoren zur Verfügung stehen, die die Klassen repräsentativ beschreiben. Ein Klassifikator versucht das Problem aus den Trainingsdaten während eines Trainingsschrittes zu abstrahieren, um neuen, unbekanntem Merkmalsvektoren eine Klasse zuzuordnen zu können.

### 3.2 Iterative Context Forests

Iterative Context Forests (ICF) sind eine spezielle Art von Klassifikator, die auf Entscheidungswäldern (engl.: Random Decision Forests, RDF) (BREIMAN, 2001) basieren, die wiederum ein Ensemble von Entscheidungsbäumen (engl.: Decision Tree, DT) darstellen.

#### 3.2.1 Entscheidungsbäume

Entscheidungsbäume (DUDA et al., 2000, Kapitel 8.2) sind ein schneller und einfacher Weg, um das Klassifikationsproblem zu lösen. Die Menge an Trainingsdaten wird durch simple

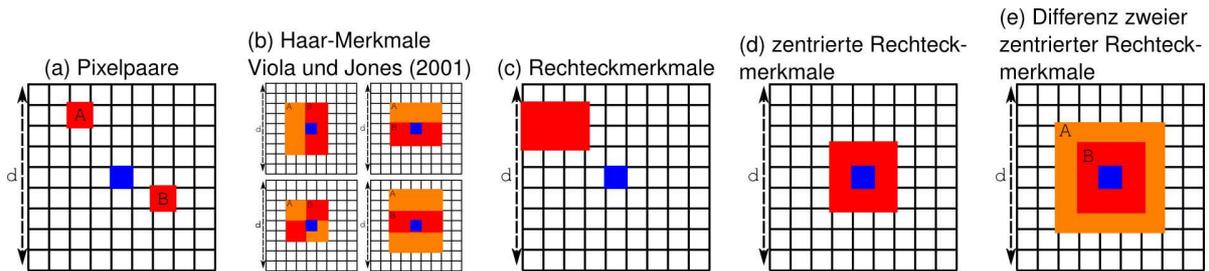


Abb. 3: Merkmalsextraktion auf den Kanälen: Merkmale werden in einem Fenster der Größe  $d$  um einen aktuellen Pixel (blauer Pixel) extrahiert. In Abhängigkeit vom gewählten Merkmalstypen werden entweder einzelne Pixel oder ganze Regionen betrachtet. Jeder Parameter (z.B. Größe und Position eines Rechtecks) wird zufällig gewählt.

Entscheidungen (z.B. ist der Wert im Grünkanal größer 127 oder nicht) in zwei Teilmengen aufgespalten. Diese Teilmengen werden mit anderen, ebenso einfachen, binären Entscheidungen weiter aufgeteilt, bis jede Teilmenge nur noch aus Merkmalsvektoren einer Klasse besteht. Dadurch entsteht eine Baumstruktur, bei der die Teilmengen mit nur noch einer Klasse als Blatt bezeichnet werden und alle anderen als innerer Knoten. Dieser Baum wird von einem neuen Merkmalsvektor mit unbekannter Klasse wiederum durchlaufen, bis dieser Vektor in einem Blatt endet. Die resultierende Klasse des unbekanntem Merkmalsvektors ist dieselbe, wie allen Trainingsmerkmalsvektoren in dem Blatt zugeordnet wurde. Als Trennfunktion einer Menge in zwei Teilmengen wird jeweils die beste Aufteilung durch erschöpfende Suche in den Trainingsdaten bezüglich der Maximierung der Kullback-Leibler-Entropie gewählt.

### 3.2.2 Zufällige Entscheidungswälder

In der Praxis hat sich gezeigt, dass Entscheidungsbäume sich stark an die Trainingsdaten anpassen (Überanpassung). Gerade bei stark verrauschten Daten kann sich ein Baum soweit aufteilen, dass viele Blätter nur noch einen Merkmalsvektor enthalten. Um das zu verhindern hat BREIMAN (2001) ein Verfahren vorgestellt, dass durch verschiedene zufällige Selektionen eine Überanpassung verhindert. Als erstes wird nicht mehr nur ein Baum trainiert, sondern mehrere. Jeder dieser Bäume bekommt eine andere zufällige Teilmenge an Trainingsdaten zum Trainieren. Weiterhin wird nicht solange trainiert, bis nur noch Merkmalsvektoren einer Klasse in einem Knoten vorkommen. Es gibt stattdessen verschiedene Abbruchkriterien: eine maximale Tiefe des Baumes darf nicht überschritten werden, eine minimale Anzahl von Trainingsbeispielen in einem Blatt darf nicht unterschritten werden und eine minimale Entropie darf nicht unterschritten werden. Somit entsteht eine a-posteriori Wahrscheinlichkeit aus der Verteilung der Klassen der verbliebenen Merkmalsvektoren in einem Blatt pro Baum. Ein neuer Merkmalsvektor durchschreitet alle Bäume und die wahrscheinlichste Klasse aus allen Bäumen wird dem unbekanntem Merkmalsvektor zugeordnet (siehe Abb. 2).

### 3.2.3 Ausnutzen von mehreren Millionen Merkmalen

Das vorgestellte Verfahren basiert auf der Extraktion von vielen verschiedenen Charakteristika aus einem Eingabebild. Neben den einzelnen Eingabekanälen können zusätzliche Kanäle, wie z.B. das Gradientenbild berechnet werden. Auf jedem dieser Kanäle und auf Kombinationen von diesen können pro Bildpunkt in einer Nachbarschaft  $d$  diverse Merkmale berechnet werden. So beispielsweise die Differenz zweier zufällig gewählter Pixel relativ zum aktuellen Pixel oder der mittlere Wert eines zufällig gewählten Bereiches relativ zum aktuellen Pixel (siehe Abb. 3).

### 3.2.4 Autokontextmerkmale

Der Hauptunterschied zu einem klassischen Entscheidungswald ist die Verwendung von sich verändernden Merkmalen während des Trainingsprozesses. Die Bäume müssen dafür zwangsläufig Ebene für Ebene gelernt werden. Nach jeder Ebene werden die Wahrscheinlichkeiten für jeden Pixel und für jede Klasse als zusätzlicher Kanal der möglichen Merkmalsauswahl hinzugefügt. Wenn davon ausgegangen wird, dass das vorherige Ergebnis mit hoher Wahrscheinlichkeit richtig ist, kann dadurch Kontextwissen aus der Nachbarschaft extrahiert und verwendet werden.

### 3.3 Adaptionen für Fernerkundungsprobleme

Das vorgestellte Verfahren wurde bisher auf Datensätze angewandt, die Hausfassaden abgebildet haben (FRÖHLICH et al., 2012a,b). Dieses Szenario unterscheidet sich von den Ansprüchen der Fernerkundung. Bei dem in dieser Arbeit verwendeten 5 x 5 km großen Ausschnitt von Rostock sind die abgebildeten Objekte durch die hohe Gebietsabdeckung und Auflösung kleiner, als beispielsweise ein Fenster einer Hauswand bei einer Fassadenaufnahme. Um dieser Charakteristik gerecht zu werden, wurde die Fenstergröße  $d$  reduziert (siehe Abschnitt 3.2.3 und Abb. 3). Des Weiteren sind einige der verwendeten Merkmalskanäle aus FRÖHLICH et al. (2012b) nicht sinnvoll auf Fernerkundungsdaten anwendbar. Dazu gehört der geometrische Kontext (HOIEM et al., 2005). Stattdessen kommen als zusätzliche Merkmale für die klassische Bildverarbeitung untypische Kanäle wie nahes Infrarot und LiDAR nDSM zum Einsatz. Durch den flexiblen Algorithmus ist die Nutzung von beliebig vielen Merkmalskanälen möglich. Aus diesem Grund kann als zusätzlicher Eingabekanal der „Normalized Differenced Vegetation Index“ (NDVI) genutzt werden. Dieser Index, berechnet aus rotem und nahem Infrarot Kanal, ermöglicht eine gute Abgrenzung von Vegetation und versiegelten Flächen.

## 4 Ergebnisse und Diskussion

Zum Testen wurden einzelne Trainingsgebiete markiert. Auf den restlichen Bereichen wurde das vorgestellte Verfahren getestet und für zufällig ausgewählte 75 Punkte je Klasse validiert. Jede Klassifikation der unterschiedlichen Kanalkombinationen wurde mit zufällig ausgewählten Merkmalen zehnmal wiederholt und die Ergebnisse gemittelt. Die Landbedeckungsklassen Gebäude, Versiegelt, Boden, Baum, Gras und Wasser wurden extrahiert.

Alle Tests wurden mit der Fenstergröße von zehn Pixeln für nicht kontextuelle Merkmale und 40 Pixeln für alle kontextuellen Merkmale durchgeführt. Diese Werte haben sich in vorangestellten Testläufen als optimal herausgestellt.

Bei dem Test des vorgestellten Verfahrens auf dem QuickBird Datensatz (Abb. 4a) ergab sich eine relativ geringe producer accuracy (Herstellergenauigkeit) und user accuracy (Nutzergenauigkeit) für die Klassen Gebäude, Gras, sowie versiegelte Flächen. Unter Einbeziehung der relativen Objekthöhen aus dem LiDAR nDSM konnte die producer accuracy für die Klassen Versiegelt und Gebäude verbessert werden (Abb. 4b). Die user accuracy der Klassen Gebäude, Gras und versiegelte Flächen wurde ebenfalls signifikant verbessert. Durch die Hinzunahme des NDVI (Abb. 4c) verbessert sich die producer und user accuracy für die Klasse Gras. Nimmt man, zusätzlich zu dem QuickBird Datensatz, nDSM und NDVI hinzu (Abb. 4d), verbessert sich die Erkennungsrate nochmals leicht.

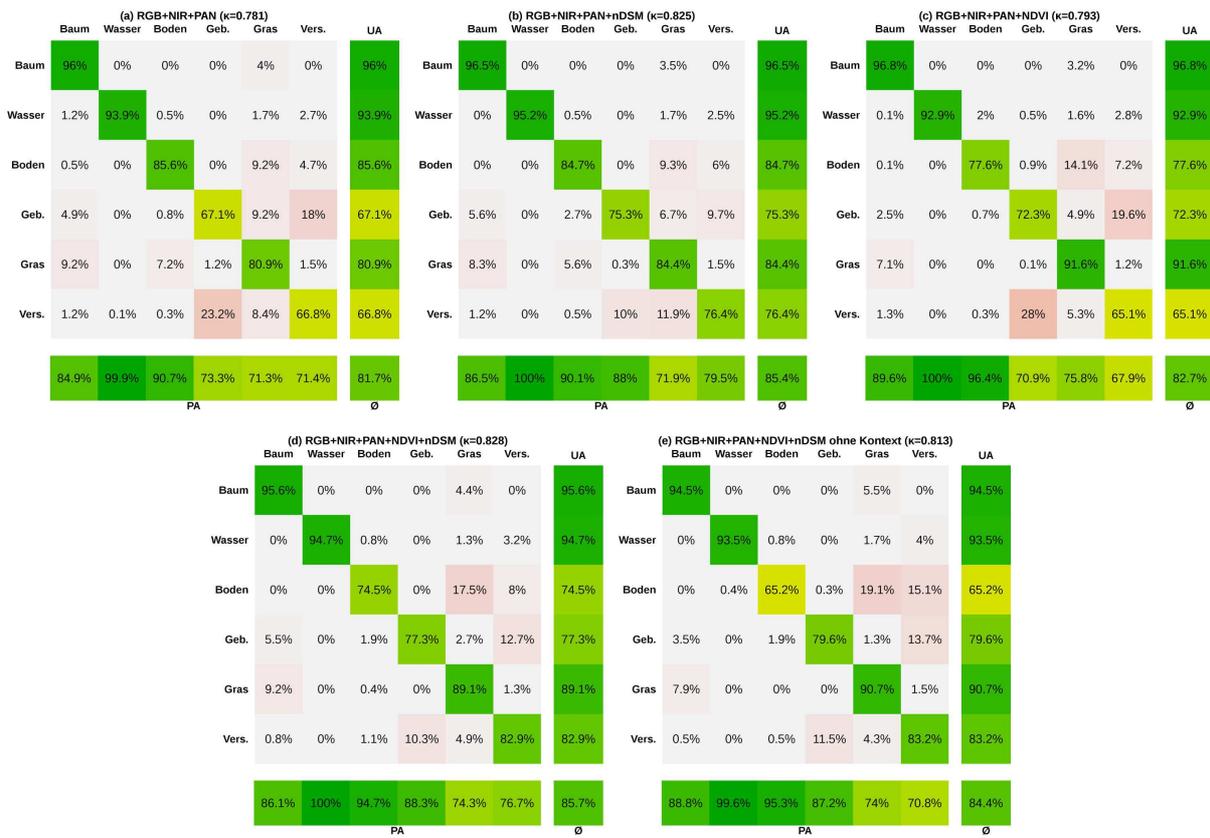


Abb. 4: Ergebnis unter Verwendung der QuickBird-Kanäle (RGB, NIR, PAN) (a-e) und zusätzlicher Verwendung des LiDAR nDSM (b,d,e), des NDVI (c-e) und ohne Kontextinformation (e). UA: user accuracy, PA: producer accuracy, Ø: durchschnittliche Erkennungsrate.

In Abb. 4e sind die Ergebnisse der besten Methode (QuickBird Daten, NDVI und nDSM Kanäle) ohne die Verwendung der Autokontextmerkmale dargestellt. Die Erkennungsraten und die producer accuracy sind für viele Klassen schlechter, wie in Abb. 4d unter Verwendung der Kontextinformationen. Deutlich wird der Einfluss von Kontextinformationen bei Betrachtung der Fehlerrate von Boden in Abb. 4e. Ohne Kontext entscheidet sich der Klassifikator oft für versiegelte Fläche anstatt Boden. Mit Kontext hingegen wird Boden vom Klassifikator sicherer erkannt (vgl. Abb. 4d). Eine mögliche Erklärung ist, dass die Bodengebiete weniger im Stadtgebiet sondern im Umland vorkommen. Dadurch ist die Nachbarschaft von Boden zu Gras/Baum wahrscheinlicher als die zu Gebäuden. Unter Einbezug dieser Nachbarschaftsinformationen wird Boden mit geringerer Fehlerrate klassifiziert (Abb. 4d). Das beste Klassifikationsergebnis (Nutzen von Kontextinformationen auf QuickBird Daten, nDSM und NDVI) ist in Abb. 5 dargestellt.

## 5 Fazit und Ausblick

In dieser Arbeit wurde ein aktuelles Verfahren der Bildverarbeitung für die Semantische Segmentierung vorgestellt. Weiterhin wurde veranschaulicht, wie dieses Verfahren für die Landbedeckungsklassifikation verwendet werden kann. In den Experimenten konnte gezeigt

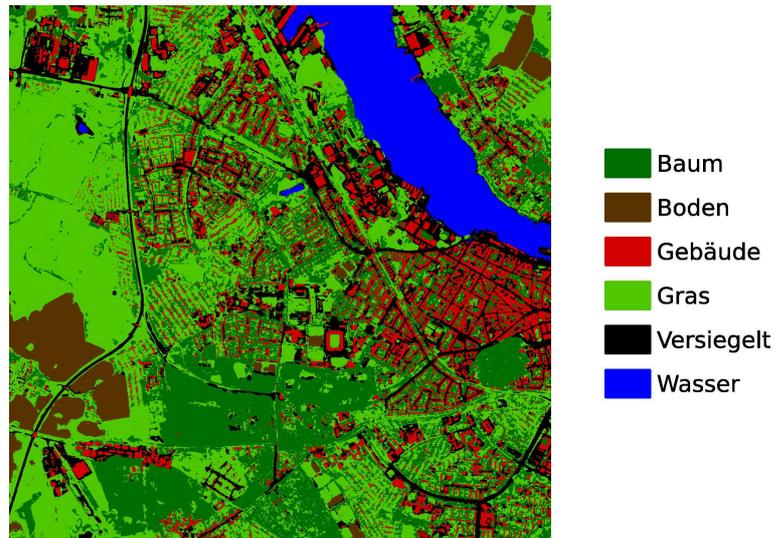


Abb. 5: Klassifikationsergebnis des 5 x 5km Ausschnittes von Rostock.

werden, dass die Verwendung von LiDAR nDSM, NDVI sowie von Kontextinformationen für diese Problemstellung das Ergebnis signifikant verbessern.

Für die zukünftige Arbeit ist die Verwendung einer unüberwachten Segmentierung geplant, um die Genauigkeit, insbesondere an den Klassenrändern, zu verbessern. Eine weitere Verbesserung der Erkennungsraten und des Detaillierungsgrades ist zu erwarten, wenn die pangeschärften Bilder mit einer räumlichen Auflösung von 60 cm verwendet werden. Zusätzlich soll die Performanz bezüglich der Analyse der gesamten hochauflösten QuickBird Szene (13,8 x 15,5km) untersucht werden.

## Danksagung

Diese Arbeit wurde von der ProExzellenz Initiative des Thüringer Ministeriums für Bildung, Wissenschaft und Kultur (TMBWK) unterstützt (Förderkennzeichen: PE309-2). Wir möchten der Stadt Rostock für die Bereitstellung der LiDAR-Daten danken.

## 6 Literaturverzeichnis

- ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E., 1976: A Land Use and Land Cover Classification System for Use with Remote Sensor Data. United States Government Printing Office, Washington. U.S. Geological Survey Circular, **671**.
- BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; MARKUS, H., 2004: Multi-Resolution, Object-Oriented Fuzzy Analysis Of Remote Sensing Data For Gis-Ready Information, *ISPRS Journal of Photogrammetry & Remote Sensing*, **58**, S. 239–258.
- BLASCHKE, T., 2010: Object Based Image Analysis For Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, **65** (1), S. 2–16.
- BREIMAN, L., 2001: Random Forests. Machine Learning, Kluwer Academic Publishers, **45**, S. 5–32.
- CHENG, P.; TOUTIN, T.; ZHANG, Y.; WOOD, M., 2003: QuickBird – Geometric Correction, Path and Block Processing and Data Fusion. *Earth Observation Magazine*, **12** (3), S. 24–28.

- DI GREGORIO, A., 2005: Land cover classification system software version 2. Based on the orig. software version 1. rev. Rome. Environment and natural resources series Geo-spatial data and information, **8**.
- DUDA, R. O.; HART, P. E. & STORK, D. G., 2000: Pattern Classification (2nd Edition), Wiley-Interscience.
- FRÖHLICH, B.; RODNER, E. & DENZLER, J., 2012a: As Time Goes By — Anytime Semantic Segmentation with Iterative Context Forests, Symposium of the German Association for Pattern Recognition (DAGM), S. 1–10.
- FRÖHLICH, B.; RODNER, E. & DENZLER, J., 2012b: Semantic Segmentation with Millions of Features: Integrating Multiple Cues in a Combined Random Forest Approach”, Asian Conference on Computer Vision (ACCV).
- HAY, G. J.; CASTILLA, G., 2008: Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. Object-Based Image Analysis. Spatial Concepts For Knowledge-Driven Remote Sensing Applications. Berlin, London: Springer, S. 75–89.
- HEROLD, M.; WOODCOCK, C.E.; LOVELAND, T.R.; TOWNSHEND, J.; BRADY, M.; STEENMANS, C.; SCHMULLIUS, C.C., 2008: Land-Cover Observations as Part of a Global Earth Observation System of Systems (GEOSS): Progress, Activities, and Prospects. IEEE Systems Journal, **2** (3), SS. 414–423.
- HOIEM, D.; EFROS, A. A. & HEBERT, M., 2005: Geometric Context from a Single Image, International Conference of Computer Vision (ICCV), IEEE, **1**, 654–661.
- HÜTTICH, C.; HEROLD, M.; WEGMANN, M.; CORD, A.; STROHBACH, B.; SCHMULLIUS, C.; DECH, S., 2011: Assessing effects of temporal compositing and varying observation periods for large-area land-cover mapping in semi-arid ecosystems: Implications for global monitoring. Remote Sensing of Environment, **115** (10), S. 2445–2459.
- MECKLENBURG-VORPOMMERN STATISTISCHES AMT. [Online]. <http://www.statistik-mv.de>.
- MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S.; WENG, Q., 2011: Per-Pixel Vs. Object-Based Classification Of Urban Land Cover Extraction Using High Spatial Resolution Imagery. Remote Sensing of Environment, **115** (5), S. 1145–1161.
- VIOLA, P. & JONES, M., 2001: Rapid Object Detection Using A Boosted Cascade Of Simple Features, Computer Vision and Pattern Recognition, IEEE (CVPR), **1**, 511–518.
- WALDE, I.; HESE, S.; BERGER, C.; SCHMULLIUS, C., 2012: Graph-based Urban Land Use Mapping from High Resolution Satellite Images. ISPRS Ann. Photogramm. Remote Sensing Spatial Inf. Sci., **I-4**, S. 119–124.