

Dissertation

**Automatisierungspotenzial von
Stadtbiotopkartierungen durch Methoden
der Fernerkundung**

zur Erlangung des akademischen Grades

Doktor der Naturwissenschaften
– Dr. rer. nat. –

eingereicht von:

Diplom-Umweltwissenschaftler Mathias Bochow
geboren am 21.01.1977 in Berlin

Juni 2009

Betreuer: Prof. Dr. Hermann Kaufmann, GFZ Potsdam

Zusammenfassung

Die Stadtbiotopkartierung hat sich in Deutschland als die Methode zur Schaffung einer ökologischen Datenbasis für den urbanen Raum etabliert. Sie dient der Untersuchung naturschutzfachlicher Fragen, der Vertretung der Belange des Naturschutzes in zahlreichen räumlichen Planungsverfahren und ganz allgemein einer ökologisch orientierten Stadtplanung. Auf diese Weise kommen die Städte ihrem gesetzlichen Auftrag nach, Natur und Landschaft zu schützen, zu pflegen und zu entwickeln (§ 1 BNatSchG), den es explizit auch innerhalb der besiedelten Fläche zu erfüllen gilt.

Ein Großteil der heute bestehenden 228 Stadtbiooptypenkarten ist in der Etablierungsphase der Methode in den 80er Jahren entstanden und wurde häufig durch Landesmittel gefördert. Der Anteil der Städte, die jemals eine Aktualisierung durchgeführt haben, wird jedoch auf unter fünf Prozent geschätzt. Dies hängt vor allem mit dem hohen Kosten- und Zeitaufwand der Datenerhebung zusammen, die durch visuelle Interpretation von CIR-Luftbildern und durch Feldkartierungen erfolgt.

Um die Aktualisierung von Stadtbiooptypenkarten zu vereinfachen, wird in der vorliegenden Arbeit das Automatisierungspotenzial von Stadtbiotopkartierungen durch Nutzung von Fernerkundungsdaten untersucht. Der Kern der Arbeit besteht in der Entwicklung einer Methode, die einen wichtigen Arbeitsschritt der Stadtbiotopkartierung automatisiert durchführt: Die Erkennung des Biooptyps von Biotopen. Darüber hinaus zeigt die Arbeit das Automatisierungspotenzial bei der flächenhaften Erhebung von quantitativen Parametern und Indikatoren zur ökologischen Bewertung von Stadtbiotopen auf. Durch die automatische Biooptypenerkennung kann die Überprüfung und Aktualisierung einer Biooptypenkarte in weiten Teilen der Stadt automatisiert erfolgen, wodurch der Zeitaufwand reduziert wird. Das entwickelte Verfahren kann in den bestehenden Ablauf der Stadtbiotopkartierung integriert werden, indem zunächst die Kartierung ausgewählter Biooptypen automatisch erfolgt und die verbleibenden Flächen der Stadt durch visuelle Luftbildinterpretation und Feldbegehung überprüft und zugeordnet werden.

Die thematische Einteilung der Biooptypen orientiert sich im urbanen Raum in erster Linie an der anthropogenen Nutzung, da diese den dominierenden Faktor für die biologische Ausstattung der Biotope darstellt. Die entwickelte Methode eignet sich vor allem zur Erkennung von baulich geprägten Biotopen, da die Nutzung – und dadurch der Biooptyp einer Fläche – durch eine automatische Analyse der Geoobjekte innerhalb der Biotopfläche ermittelt werden kann. Die Geoobjekte wiederum können durch eine Klassifizierung von multisensoralen Fernerkundungsdaten (hyperspektrale Flugzeugscannerdaten und digitale Oberflächenmodelle) identifiziert werden. Die Analyse der Geoobjekte und der urbanen Oberflächenarten innerhalb der Biotopfläche erfolgt anhand von räumlichen, morphologischen und quantitativen Merkmalen. Auf Basis dieser Merkmale wurden zwei Varianten eines automatischen Biotopklassifizierers entwickelt, die unter Verwendung von Fuzzy Logik und eines neu entwickelten, paarweise arbeitenden Maximum Likelihood Klassifizierers (pMLK) implementiert wurden. Für die bisher implementierten 10 Biooptypen, die zusammen etwa die Hälfte des Stadtgebiets abdecken, wurde eine Erkennungsgenauigkeit von über 80 % ermittelt. Der pMLK wurde erfolgreich in zwei Städten (Berlin, Dresden) erprobt, wodurch seine Übertragbarkeit nachgewiesen werden konnte.

Schlagnorte: Stadtbiotopkartierung, Fernerkundung, GIS, räumliche Analyse, Fuzzy Logik, Klassifizierung, Automatisierung, Objekterkennung

Abstract

Urban biotope mapping has become a standard method in Germany for building up an ecological spatial data base in urban areas. Such a data base enables the analysis of nature conservation issues, the representation of the interests of nature conservation in several planning processes and, in general, it supports ecologically oriented urban planning. Thus, urban biotope mapping is a powerful instrument for municipalities to fulfil their statutory obligations (§ 1, BNatSchG) of sustainably conserving, maintaining and developing landscape and nature within their city.

The majority of the 228 completed urban biotope maps in Germany has been produced in the 1980s when the method got established and was financially supported by the federal state governments. However, the percentage of all 228 maps that have ever been updated is estimated to be less than five percent. The reason for this very low rate can be identified in the cost-intensive data acquisition methods consisting of visual interpretation of CIR aerial photographs in combination with field surveys.

This thesis intends to facilitate periodical updates of urban biotope maps by reducing the effort using automated analysis methods of remote sensing data. The main part of this work consists of a newly developed method that automates an important step of urban biotope mapping: The identification of the type (or class) of a biotope. In a second aspect the thesis addresses the potential of automation in area-wide mapping of quantitative parameters and indicators as a basis for an ecological evaluation of urban biotopes. Using the developed method for automated biotope identification a biotope map can be examined and updated in an automated way for large parts of a city reducing the expenditure of time. The developed method can be easily integrated into the existing workflow of biotope mapping in a way that mapping of selected biotope types is carried out automatically and the remaining unmapped areas are examined and classified by visual interpretation of CIR aerial photographs and by field surveys.

Biotope types can be considered as classes of biotopes. In urban areas they reflect distinct types of land use because the anthropogenic use of an area is the dominating factor for its ecological quality. The developed method is especially suited for the identification of overbuilt biotopes because the type of land use – and thereby the biotope type of an overbuilt area – can be identified by automated analysis of the geo-objects contained in this area. The geo-objects can be obtained from a multi-sensoral classification of remote sensing data (airborne hyperspectral data and digital elevation models). The analysis of geo-objects and urban surface materials within the area of a biotope is based on spatial, morphological and quantitative features. These features form the input information for two developed versions of a biotope classifier implemented using fuzzy logic and a pairwise maximum likelihood approach, respectively. The accuracy of both classifiers was assessed for 10 selected biotope types that generally cover more than half of a city. The pairwise maximum likelihood classifier has been successfully applied for test sites of two cities (Berlin and Dresden) showing the transferability of the developed approach.

Keywords: urban biotope mapping, remote sensing, GIS, spatial analysis, fuzzy logic, classification, automation, object recognition

Dank

An erster Stelle möchte ich mich bei Prof. Dr. Hermann Kaufmann bedanken, der diese Arbeit betreut und exzellente Rahmenbedingungen für das gute Gelingen der Arbeit geschaffen hat. Als Mitarbeiter seiner Abteilung danke ich besonders für das entgegengebrachte Vertrauen und die gewährten Freiräume, die der Quell neuer Ideen sind.

Prof. Dr.-Ing. Manfred Ehlers hat mich während einer langen Strecke meiner Ausbildung begleitet. Ich verdanke ihm meine im Studium entstandene Begeisterung für die Geoinformatik und Fernerkundung, diverse Hiwi-Jobs, Thema und Betreuung meiner Diplomarbeit und eine Stelle als wissenschaftlicher Mitarbeiter im HyScan-Projekt, was mir die Möglichkeit gab, mich intensiv mit der hyperspektralen Fernerkundung zu befassen. Zu guter Letzt öffnete mir Herr Ehlers mit einem Anruf eine Tür im GFZ. Ich freue mich, dass ich ihn auch als Gutachter meiner Doktorarbeit gewinnen konnte und bedanke mich für die andauernde Unterstützung ganz herzlich.

Karl und Sigrid: Euch gilt mein Dank für die inhaltliche Betreuung der Arbeit und für das inhaltliche Korrekturlesen. Bei Dr. Karl Segl bleibt kein methodisch-technisches Problem ungeklärt, während die Diskussionen mit Dr. Sigrid Rößner helfen, die Gedanken zu ordnen und das große Ganze nicht aus dem Blick zu verlieren – diese Kombination ist super. Von euch habe ich viel gelernt! Für die Diskussionen über Fuzzy Logik danke ich zudem Dr. Volker Klemann.

Die vorliegende Arbeit ist in der Sektion 1.4 des Deutschen GeoForschungsZentrums in Potsdam entstanden. Mein herzlicher Dank gilt daher allen Kollegen und Weggefährten in der Sektion 1.4 für ihre Unterstützung und für interessante Diskussionen fachlicher und nicht-fachlicher Art, aber vor allem für das wunderbare Arbeitsklima in der Sektion. Besonders erwähnen möchte ich hier die Diplomanden, Hiwis und Praktikanten, die mir in der Zeit meiner Doktorarbeit zur Hand gegangen sind. Sofern ich noch alle zusammenbekomme, waren dies Silke Ahnert, Robert Behling, Andreas Eisele, Claudius Göhring, Matthias Kunz, Christoph Kunze, Christian Lutz, Andreas Müller, Theres Peisker, Stephanie Teteris und Max Zitzmann.

In der Fernerkundung ist man wie in kaum einer Disziplin auf gute Daten angewiesen. Für die größtenteils kostenlose Bereitstellung dieser bedanke ich mich ganz herzlich beim Institut für Planetenforschung des DLR Adlershof, beim Geomatics Lab des geographischen Instituts der Humboldt Universität zu Berlin, dem Deutschen Fernerkundungsdatenzentrum am DLR Oberpfaffenhofen, der Senatsverwaltung für Stadtentwicklung Berlin und dem Umweltamt Dresden.

Als Nicht-Stadtökologe benötigte ich immer wieder fachlichen Rat aus dieser Richtung. Mein herzlicher Dank geht daher an Prof. Dr. Dr. h. c. Herbert Sukopp (TU Berlin), Peter Werner (IWU Darmstadt), Dr. Michael Fietz (Luftbild u. Vegetation GbR), Holger Brandt (Senatsverwaltung Berlin) und Sebastian Schmidt (Umweltamt Dresden), die mir einen Einblick in Forschung und Praxis gewährten.

Für die graphische Unterstützung bei der Erstellung der Doktorarbeit möchte ich Ole und Theres danken. Dafür, dass sie als fachfremde Leser die sicherlich oftmals ermüdende Arbeit des Korrekturlesens auf sich genommen haben, danke ich Andrea, Udo und Niclas ganz herzlich. Ihr wart tapfer und gründlich!

Meinen Eltern danke ich für ihre vielseitige Unterstützung, Rückhalt und Vertrauen auf dem gesamten Weg meiner schulischen und universitären Ausbildung.

Inhaltsverzeichnis

Abbildungsverzeichnis	5
Tabellenverzeichnis	11
1 Einleitung	13
1.1 Motivation und Ziele	13
1.2 Aufbau der Arbeit	14
2 Grundlagen	17
2.1 Fernerkundung	17
2.1.1 Grundlagen der hyperspektralen Fernerkundung	17
2.1.2 Anwendungsfelder und Methoden der Fernerkundung in urbanen Gebieten	24
2.2 Fuzzy Logik	26
2.2.1 Unscharfe Mengen und Zugehörigkeitsfunktionen	26
2.2.2 Operationen auf unscharfen Mengen	27
2.2.3 Kartesisches Produkt, Relationen und Kompositionen als mathematische Grundbausteine von Fuzzy Logik Modellen	28
2.2.4 Aufbau eines Fuzzy Logik Modells an einem Beispiel	31
2.3 Stadtökologie und Stadtbiotopkartierungen	35
2.3.1 Entstehungsgeschichte der Stadtökologie	35
2.3.2 Der Zusammenhang zwischen Mensch und Natur in der Stadt: Von stadtökologischen Erkenntnissen zur Entwicklung der Stadtbiotopkartierung	37
2.3.3 Stadtbiotopkartierungen in der Praxis	38
3 Untersuchungsgebiete und Schaffung der Datenbasis	43
3.1 Untersuchungsgebiete	45
3.2 Stadtbiotopkartierungen	46
3.2.1 Entstehung und Vergleich der Kartierschlüssel	46
3.2.2 Definition der untersuchten Biotoptypen	48
3.2.3 Räumliche und thematische Mischbiotope	51
3.2.4 Die Biotopfläche als Bezugsfläche der Untersuchungen	53
3.3 Digitale Höhenmodelle	54

3.3.1	<i>Digitale Oberflächenmodelle (DOM)</i>	54
3.3.2	<i>Erzeugung digitaler Geländemodelle (DGM), normalisierter digitaler Oberflächenmodelle (nDOM) und Gebäudemasken</i>	57
3.4	Hyperspektrale Flugzeugscannerdaten.....	65
3.4.1	<i>Der HyMap-Sensor</i>	65
3.4.2	<i>Korrektur- und Vorverarbeitungsschritte</i>	66
3.4.3	<i>Klassifizierung und Entmischung von urbanen Oberflächen</i>	69
3.4.3.1	<i>Merkmalsbasierte Identifizierung von Trainingsspektren und Endmemberspektren</i>	75
3.4.3.2	<i>Maximum Likelihood Klassifizierung von puren Pixeln</i>	80
3.4.3.3	<i>Nachbarschaftsgestützte, iterative, lineare spektrale Entmischung</i>	82
3.4.3.4	<i>Validierung der Klassifizierung und spektralen Entmischung mit einer simulierten Szene</i>	85
3.4.4	<i>Thematische Gruppierung der Oberflächenarten</i>	97
3.4.5	<i>Segmentierung</i>	98
3.5	Die Datenbasis im Überblick.....	98
4	Entwicklung von Merkmalen zur Charakterisierung von Stadtbiototypen	101
4.1	Biotopmerkmale	104
4.2	Klassenmerkmale.....	107
4.3	Segmentmerkmale	109
4.4	Quantitative ökologische Parameter und Indikatoren.....	112
5	Wissensbasierter Aufbau von Fuzzy Logik Modellen zur Klassifizierung von Stadtbiotopen	119
5.1	Gründe für die Verwendung von Fuzzy Logik.....	120
5.2	Konzeption der Modelle	121
5.3	Auswahl von Merkmalen.....	125
5.4	Kalibrierung der Modelle	127
5.5	Genauigkeitsüberprüfung der Klassifizierung.....	129
6	Automatisierter Aufbau von ML-basierten Modellen zur Klassifizierung von Stadtbiotopen	133
6.1	Auswahl von Merkmalen.....	134

6.2	Aufbau und Kalibrierung der Modelle	136
6.3	Genauigkeitsüberprüfung der Klassifizierung.....	137
7	Diskussion und Ausblick	143
7.1	Automatisierungspotenzial bei der Erhebung ökologischer Parameter und Indikatoren	143
7.2	Vergleich der beiden entwickelten Biotopklassifizierer	144
7.3	Untersuchungen zur Robustheit und Übertragbarkeit der Biotopklassifizierer.....	146
7.3.1	<i>Ablehnung von Biotopen mit unbekanntem Biotoptyp</i>	146
7.3.2	<i>Verhalten der Biotopklassifizierer bei räumlichen und thematischen Mischbiotopen</i>	147
7.3.3	<i>Robustheit der Biotopklassifizierer gegenüber Fehlern in den Eingabedaten und der Prozessierungskette</i>	151
7.3.4	<i>Übertragbarkeit der Biotopklassifizierer auf andere Untersuchungsgebiete</i>	153
7.4	Ablauf der automatischen Biotopklassifizierung und Integration in den Prozess der Aktualisierung einer Stadtbioptypenkarte	154
7.5	Ausblick.....	156
	Literaturverzeichnis	159
	Abkürzungsverzeichnis und Glossar	171
	Anhang A: Klassenliste und Legende	175
	Anhang B: Konfusionsmatrizen der Biotopklassifizierungen	179
	Anhang C: Karten und kartenverwandte Darstellungen	183

Abbildungsverzeichnis

Abbildung 1–1 Einige Biotope im Luftbild (Quelle: GoogleEarth; © AeroWest) mit überlagerten Biotopgrenzen aus der Kartierung. Die hier gezeigten baulich geprägten Biotoptypen bestehen alle im Wesentlichen aus den gleichen Geoobjekten. Charakteristisch für die einzelnen Biotoptypen sind dagegen die Form, Größe, Häufigkeit und Anordnung der Geoobjekte im Biotop. (a: Blockrandbebauung, b: Blockbebauung, c: Hochhausbebauung, d + g: Einzelhausbebauung, e + h: Zeilenbebauung, i: Schrebergärten).....	15
Abbildung 2–1 Spektren ausgewählter urbaner Materialien (je drei). Zyan: Aluminiumdach, rot: rote Tonziegel, magenta: PVC-Dach, grün: grüner Kunstrasen, braun: Boden, blassrosa: Asphalt. Aus Gründen der Übersichtlichkeit wird in beiden Plots eine Liniendarstellung gewählt.	18
Abbildung 2–2 Quantifizierung der Strahlungsverluste auf dem Strahlungsweg Sonne – Erdoberfläche – Sensor (nach: Gibson 2000: 25).....	19
Abbildung 2–3 Die spektrale Strahldichte von schwarzen Körpern verschiedener Temperaturen. Sonne = 5900 K, Erde = 273 K (verändert nach: Albertz 1991: 13).....	20
Abbildung 2–4 Vergleich der spektralen spezifischen Einstrahlung der Sonne auf die äußere Erdatmosphäre und die Erdoberfläche. Die feinen Absorptionslinien der oberen Kurve werden durch solare Gase hervorgerufen. Die breiteren Absorptionsbanden der unteren Kurve resultieren zusätzlich aus dem Einfluss der Erdatmosphäre (verändert nach: Schowengerdt 1997: 42).....	20
Abbildung 2–5 Wege der elektromagnetischen Strahlung durch die Erdatmosphäre. Neben dem direkten Weg Sonne – Erdoberfläche – Sensor gelangt die Strahlung bedingt durch die atmosphärische Streuung auf je zwei zusätzlichen Wegen zum Pixel im Fokus des Sensors bzw. zum Sensor ohne Kontakt mit dem Pixel (verändert nach: Richards & Jia 1999: 40).....	21
Abbildung 2–6 Spiegelnde, gerichtete, diffuse und gemischte Reflexion (ergänzt nach: Albertz 1991: 18).....	22
Abbildung 2–7 Aufnahmeprinzip eines <i>Whiskbroom</i> und <i>Pushbroom</i> Scanners (verändert nach: Sabins 1997: 18).....	23
Abbildung 2–8 Eine mögliche Zugehörigkeitsfunktion für den Ausdruck „ x ist viel kleiner als 5“.....	27
Abbildung 2–9 Typische Formen von Zugehörigkeitsfunktionen (aus: Peisker 2006: 10).....	27
Abbildung 2–10 Graphische Veranschaulichung der Anwendung der Operatoren Komplement, Vereinigung, Durchschnitt und algebraisches Produkt auf zwei Mengen A und B (ergänzt nach: The MathWorks 2006: 2-14).....	28
Abbildung 2–11 Zugehörigkeitsfunktionen der Ausdrücke „Raumtemperatur ist gering“ $\mu_G(x)$ und „Heizungsregler ist hoch“ $\mu_H(y)$	30
Abbildung 2–12 Fuzzifizierung von Inputwerten durch Zugehörigkeitsfunktionen und Verknüpfung der unscharfen Mengen der Terme „heiß“ und „schnell“ mit dem MAX-Operator (aus: Peisker 2006: 13).....	32
Abbildung 2–13 Implikation einer Fuzzy-Regel mit dem MIN- und dem PROD-Operator (nach: Kecman 2001: 388, Peisker 2006: 13).....	33
Abbildung 2–14 Schema und Funktionsweise des gesamten Fuzzy Logik Modells am Beispiel der Bewertungspunkte 8 und 7 für die Temperatur und Lieferung der Pizza (aus: Peisker 2006: 14).....	34
Abbildung 2–15 Graphische Veranschaulichung verschiedener Defuzzifizierungsmethoden (aus: Peisker 2006: 15).....	34

Abbildung 2–16 Berücksichtigung der Stadtbiotopkartierungen im deutschen Planungssystem (ins Deutsche übersetzt aus: Werner 1999).....	39
Abbildung 2–17 Zeitlich-räumliche Verbreitung der Biotopkartierungen in Deutschland. Grün: Stand 1984, blau: Stand 1993, rot: Stand 2000. Gezeigt werden alle Städte, die bis zum Stichjahr eine selektive oder flächendeckend-repräsentative Biotopkartierung durchgeführt oder begonnen haben. Quellen: (Sukopp & Weiler 1988, Schulte <i>et al.</i> 1993, Schulte & Sukopp 2000).....	42
Abbildung 3–1 Lage der Untersuchungsgebiete (HyMap-Flugstreifen) in den Städten Dresden und Berlin.	46
Abbildung 3–2 Variationen der Zeilenbebauung in Berlin (Quelle: GoogleEarth; © AeroWest).....	50
Abbildung 3–3 Beispielbiotope der untersuchten Biotoptypen dieser Arbeit im Luftbild (Quelle: GoogleEarth; © AeroWest): a. Einzelhausbebauung, b. Industrie- und Gewerbeflächen, c. Kleingärten, d. Straßen, e. Hochhausbebauung, f. reiner Scher- und Zierrasen, g. Blockrandbebauung, h. Zeilenbebauung, i. Blockbebauung, j. offene Sport- und Erholungsanlagen.....	51
Abbildung 3–4 Die Biotope a und b bestehen aus Zeilenbebauung mit jeweils einem Hochhaus. Je nach vorgegebener Mindestflächengröße zählen sie also zu den Typ I oder Typ II Mischbiotopen. Biotop c gehört dagegen klar zum Typ I. Die Biotope d-g gehören zum Typ III, wobei d und f eine thematische Mischung aus Zeilen- und Blockrandbebauung sowie e und g eine Mischung aus Block- und Blockrandbebauung darstellen (Quelle: GoogleEarth; © AeroWest).	52
Abbildung 3–5 Spezifische Probleme unterschiedlicher DOMs. Oben: <i>last pulse</i> Laserscannerdaten, unten: stereoskopisch erzeugtes DOM. a: Wald (mit Wegen und Lichtungen), b: Höhenprofil durch ein Gebäude (Gebäudegrenzen aus ALK).....	56
Abbildung 3–6 Enge Straßenschluchten in stereoskopisch erzeugten DOMs. Links: Problemskizze, rechts: Auswirkung im stereoskopisch erzeugten DOM (blau) im Vergleich zum Laser-DOM (grün).	56
Abbildung 3–7 Links: Mit <i>Opening</i> erzeugtes DGM. Rechts: DOM zum Vergleich.	58
Abbildung 3–8 Richtungsabhängige Überprüfung eines potenziellen GOK-Pixels. Da das Pixel auf einem Gebäude liegt, werden tiefere Pixel in gegenüberliegenden Richtungen gefunden, d.h. in mehreren Kreissektoren, die nicht aneinandergrenzen. Daher kann das Pixel verworfen werden. Pixel an Hängen bleiben dagegen erhalten, da hier nur zu einer Seite tiefere Pixel gefunden werden.	60
Abbildung 3–9 Ausschnitt des stereoskopisch erzeugten DOMs von Dresden mit überlagerten verworfenen (rot) und bestätigten (grün) GOK-Pixeln.....	61
Abbildung 3–10 Höhenprofile des stereoskopisch erzeugten DOMs von Dresden (schwarz) und der daraus abgeleiteten DGMs. Blau: <i>Opening</i> , grün: eigene Methode. Die lokalen Erhöhungen entlang des Profils des DOMs werden durch Gebäude, einzelne Bäume oder Baumgruppen hervorgerufen.	62
Abbildung 3–11 Ausschnitt aus DOM, DGM und nDOM in 3D-Darstellung.....	63
Abbildung 3–12 Histogramme der absoluten Abweichungen zwischen DOM und abgeleitetem DGM an den Kontrollpunkten. Blau: eigene Methode, rot: <i>Opening</i> . Zur übersichtlicheren Darstellung wurden bei allen Histogrammen einzelne Ausreißer mit sehr großen Werten weggelassen.	64
Abbildung 3–13 Veranschaulichung der Hausmaske an einem Ausschnitt des Berliner HyMap-Streifens. Die zur Hausmaske gehörenden Pixel werden unverändert dargestellt, während nicht zur Maske gehörende Pixel in matten Farben gezeigt werden.....	65
Abbildung 3–14 Regressionsgeraden der <i>Empirical Line</i> Korrektur für ausgewählte Bänder....	67

Abbildung 3–15	Vergleich der Spektren nach ACUR_R und nach der <i>Empirical Line</i> Korrektur mit den im Feld gemessenen Spektren.....	67
Abbildung 3–16	Aufnahmegeometrie eines flugzeuggetragenen Zeilenscanners.....	68
Abbildung 3–17	Die Abbildung zeigt schematisch die vorliegende Situation bei der Übertragung der Grauwerte der HyMap-Pixel in das Rasterbild im Zielsystem. Der Grauwert $G_{x,y}$ eines Pixels im Zielbild wird durch Interpolation nach Gleichung (3-1) aus den Grauwerten einer maximalen Menge (hier 3) von HyMap-Pixeln berechnet, die innerhalb eines Suchradius liegen.	69
Abbildung 3–18	Hierarchische Gliederung der Oberflächenarten des urbanen Raums nach stadttökologischen Gesichtspunkten. Die unterste Ebene enthält die fernerkund- lich erfassbaren urbanen Oberflächenarten (verändert nach: Heiden 2004: 28).	70
Abbildung 3–19	Beispiel eines zwei-dimensionalen Merkmalsraums mit drei Klassen. Die verschiedenen Dreiecke zeigen die Resultate verschiedener Methoden zur automati- schen Bestimmung von <i>Endmembers</i> aus Bilddaten (verändert nach: Berman 2004, bzw. Berman <i>et al.</i> 2004). Quellen der Methoden: ICE: (Berman <i>et al.</i> 2004), Winter: (Winter 1999), Craig: (Craig 1994).	72
Abbildung 3–20	Variationen zweier Dachmaterialien (blau: Zink; rot: Polyethylen) und deren spektrale Mischungen (grün) im Verhältnis 50:50.	74
Abbildung 3–21	Ablaufdiagramm der Klassifizierung und spektralen Entmischung. Die Fälle 1, 2 und 3 nachbarschaftsbedingt unterschiedlicher Endmemberkombinationen werden in Abbildung 3–27 auf Seite 83 erläutert.	75
Abbildung 3–22	Ablauf der iterativen Merkmalsselektion (n = Anzahl vorhandener Merkmale).	77
Abbildung 3–23	Anwendung des pMLK zur Klassifizierung eines Pixels.	78
Abbildung 3–24	Histogramme der Zugehörigkeitswahrscheinlichkeiten. Um die Histo- gramme mehrerer Klassen übersichtlich in einem Diagramm darzustellen, wurde von der üblichen Darstellung als Balkendiagramm abgewichen. Weiterhin wurde jede Kurve durch Division durch ihren Maximalwert auf den Wertebereich 0-1 normiert.	79
Abbildung 3–25	Prinzipiskizze des <i>Purity-Check</i> , gezeigt an einem 2-dimensionalen Merkmalsraum. Zur vereinfachten Darstellung besitzt die Klasse in beiden Dimensio- nen die gleiche Varianz. Der gezeigte Schwellenwert d_{s0} entspricht der größten Maha- lanobis-Distanz des vom Klassenzentrum betrachteten 80 %-Quantils.	81
Abbildung 3–26	Klassifizierte Pixel nach Anwendung des pMLK und nach der ML- Klassifizierung purer Pixel im Vergleich. Die Klassen sind in der Darstellung zu thema- tischen Hauptklassen zusammengefasst. Eine Legende befindet sich im Anhang A.....	82
Abbildung 3–27	Drei Fälle der nachbarschaftsbasierten Auswahl von Endmemberkombinationen zur linearen spektralen Entmischung eines Pixels (ins Deutsche übersetzt aus: Roessner <i>et al.</i> 2001).....	83
Abbildung 3–28	Ausschnitte der Entmischungslayer der Klassen rote Tonziegel (neu), Polyethyldach, Asphalt, Bahngleise, Fluss, Laubbäume und Schatten auf vegetationsfreien Flächen. Die Graustufen drücken die Flächenanteile der Klassen am Pixel aus. Weitere Beispiele befinden sich im Anhang C (Abb. C-6).	84
Abbildung 3–29	Ausschnitt einer aus den Entmischungsergebnissen abgeleiteten Klassifizierung. Abbildung C-5 im Anhang C zeigt eine Gesamtansicht für das Untersuchungsgebiet Berlin, die Abbildungen C-1 und C-2 zeigen entsprechende Darstellungen für Dresden. Im rechten, oberen Bild wurden die Klassen thematisch zu Hauptklassen zusammengefasst. Die unteren Bilder zeigen die einzelnen Klassen der Dachmaterialien (links) und der übrigen Klassen (rechts) in einer detaillierteren Aufschlüsselung, wobei die jeweils andere Gruppe grau bzw. weiß unterlegt ist. Entsprechende Legenden befinden sich im Anhang A.....	85

Abbildung 3–30	Erzeugung einer künstlichen Stadtszene zur Validierung des spektralen Entmischungsverfahrens. $V \rightarrow R = \text{Vektor-Raster-Konvertierung}$	86
Abbildung 3–31	Auswirkung der Umgebungspixel und der Position einer Klasse im Pixel auf ihren Flächenanteil bei der Abtastung mit einem normalverteilten Filter. Die Abbildung zeigt vier Felder mit je 19x19 Pixeln des 50cm-Rasterreferenzbilds (Größe des normalverteilten Filters). Der Kern von 7x7 Pixeln eines jeden Feldes ist die Fläche, die vom simulierten 3,5 m Pixel überdeckt wird (entspricht der FWHM der Sensor-PSF). Die graue Testklasse füllt den 7x7 Kern im ersten Feld vollständig aus, in den übrigen Feldern beträgt ihr wahrer Flächenanteil am 3,5m Pixel 44,9 % (22 von 49 Pixeln), sie wird jedoch zentral, gleichmäßig und peripher positioniert. Nach der Filterung betragen die errechneten Flächenanteile der grauen Klasse und die relativen Abweichungen zur Wahrheit 58,4 % (-41,6 %), 32,9 % (-12,0 %), 25,9 % (-19,0 %) und 19,9 % (-25,0 %).	88
Abbildung 3–32	Abtastung des 50cm-Rasterreferenzbilds mit normal- und gleichverteiltem Filterkern zur Erzeugung von F_{HyMap} und F_{True} . Die räumliche Auflösung eines Fernerkundungsbildes entspricht der FWHM der Sensor-PSF. Dies führt dazu, dass ca. 40 % des Signals eines Pixels in seiner Umgebung aufgezeichnet wird (Fläche unter der Sensor-PSF, die nicht innerhalb der 7x7 Pixel liegt) und dass also nur 60 % von der eigentlichen Fläche des Pixels stammt.	88
Abbildung 3–33	Querprofil durch ein Gebäude. Gezeigt werden die Flächenanteile des Dachendmembers für F_{True} (grün; gleichverteilte Filterung) und F_{HyMap} (blau; normalverteilte Filterung).	89
Abbildung 3–34	Mittlere Abweichung der Flächenanteile F_{HyMap} von F_{True} . Jede Linie zeigt eine Klasse. Die Abweichungen der Pixel einer Klasse wurden pro Flächenanteilintervall der Pixel im Referenzbild gemittelt. Der grau hinterlegte Bereich entspricht der durchschnittlichen Standardabweichung der Klassen, abgetragen von einer gemittelten Kurve der Klassen.	91
Abbildung 3–35	Mittlere Abweichung der Flächenanteile F_{Unmix} von F_{HyMap} . Jede Linie zeigt eine Klasse. Die Werte resultieren aus einer Mittelung der Pixel der Klasse pro Flächenanteilintervall im Referenzbild. Der grau hinterlegte Bereich entspricht der durchschnittlichen Standardabweichung der Klassen, abgetragen von einer gemittelten Kurve der Klassen. Die vier Diagramme zeigen die im Text genannten Gruppen I-IV.	93
Abbildung 3–36	Mittlere Abweichung der Flächenanteile der Klassen bedingt durch die Sensorabtastung und die Entmischungsmethode (links). Das rechte Diagramm zeigt den kombinierten Fehler aus beiden.	94
Abbildung 3–37	Abhängigkeit der Über- und Unterschätzung der Flächenanteile der Klassen von ihrer durchschnittlichen Segmentgröße.	94
Abbildung 3–38	Echtfarbenansicht der simulierten Szene und räumliche Verteilung der obengenannten fünf Fälle (Fall I: weiß; Fall II: rot; Fall III: grün; Fall IV: schwarz; Fall V: blau).	95
Abbildung 3–39	Lage der korrekt (weiß) und falsch oder nicht (schwarz) klassifizierten Pixel im Bild sowie der entmischten Pixel, bei denen beide (grün) oder nur der erste (orange) <i>Endmember</i> richtig ist bzw. der erste <i>Endmember</i> nicht richtig ist (rot).....	96
Abbildung 3–40	Ausschnitt aus dem Segmentierungsbild der Klassengruppe Gebäude und dem HyMap-Bild (RGB-Darstellung) zum Vergleich. Die Segmente besitzen im Bild eine durchnummerierte ID. Zur besseren Darstellung sind sie hier in weiß dargestellt.....	98
Abbildung 3–41	Datenbasis (c – f) eines Biotops (a: HyMap RGB-Darstellung, b: RGB-Luftbild) für die Berechnung von Merkmalen. c: Fläche des Biotops, d: ein exemplarisches Entmischungsergebnis für die Klasse „rote Tonziegel (neu)“, e: das nDOM, f: ein exemplarisches Segmentierungsergebnis für die Klassengruppe „Dächer“.	99

Abbildung 4–1	Drei Ebenen der Merkmalsberechnung. Die jeweils farbig dargestellten Pixel des Biotops gehen pro Ebene in die Merkmalsberechnung ein.....	101
Abbildung 4–2	Prinzipskizze des Algorithmus „Jarvis March“ zur Berechnung der konvexen Hülle einer Punktmenge.....	102
Abbildung 4–3	Konvexe Hülle, Biotopinnenbereich und Biotoprandbereich gezeigt für Beispielbiotop der Blockbebauung und Blockrandbebauung. Die helle Umrisslinie umrandet die Biotopfläche. Die roten Punkte markieren die als Hausdach klassifizierten Biotoppixel. In den oberen Bildern stellt die dunkle Linie jeweils die konvexe Hülle um die Dachpixel dar, in den unteren die Grenze zwischen Biotopinnenbereich und -randbereich.....	103
Abbildung 4–4	Links: Richtungszahlen für den Kettencode ausgehend vom Pixel P. Rechts: Skizze einer Kette.	104
Abbildung 5–1	Arbeitsschritte von den Ausgangsdaten bis zum Aufbau des Biotop-Klassifizierers.....	119
Abbildung 5–2	Histogramme zweier Merkmale für die prototypischen und untypischen Biotop der Biotoptypen Blockbebauung (links) und Zeilenbebauung (rechts).....	124
Abbildung 5–3	Struktur und Funktionsweise eines Fuzzy Modells zur Erkennung eines Biotoptyps. Die Anzahl der Inputvariablen (Merkmale) ist nicht begrenzt. Der Ausgabewert des Modells ist als Ähnlichkeitswert interpretierbar.....	124
Abbildung 5–4	Überlappungsfälle der Merkmals-Histogramme zweier Biotoptypen.....	125
Abbildung 5–5	Trapezförmige und <i>spline</i> -basierte Zugehörigkeitsfunktionen.	127
Abbildung 5–6	Zwei Strategien zur Einstellung der Grenzen der Zugehörigkeitsfunktionen (hier mit Trapezform) basierend auf den Merkmals-Histogrammen der Trainingsbiotop. .	129
Abbildung 5–7	Gesamtgenauigkeit und Anteil der klassifizierten Biotop in Abhängigkeit vom gesetzten Schwellenwert auf die von den Modellen berechneten Ähnlichkeitswerte. .	131
Abbildung 6–1	Ablauf der iterativen Merkmalsselektion ($n =$ Anzahl vorhandener Merkmale).	136
Abbildung 6–2	Struktur und Funktionsweise eines ML-basierten Modells zur Erkennung eines Biotoptyps. Aus Darstellungsgründen werden 3 2-dimensionale Inputvariablen gezeigt. Die realen Modelle besitzen $b-1$ k -dimensionale Inputvariablen, wobei b die Anzahl der implementierten Biotoptypen und k die Anzahl der selektierten Merkmale ist, die für jede Biotoptypenpaarung variabel ist. Der Ausgabewert des Modells ist als Ähnlichkeitswert interpretierbar.	137
Abbildung 6–3	Gesamtgenauigkeiten der Klassifizierungen in Abhängigkeit von der maximal erlaubten Merkmalsanzahl pro Paarweisklassifizierer.	138
Abbildung 6–4	Der Merkmalsselektionsprozess mit der SFS Methode verbildlicht an einer Baumstruktur. Der rote Pfad zeigt eine Möglichkeit, ausgehend von der Nullmenge, zwei von vier Merkmalen zu selektieren (nach Kohavi & John 1997: 284, bzw. Guyon 2005: 3,4).....	140
Abbildung 6–5	Gesamtgenauigkeit und Anteil der klassifizierten Biotop in Abhängigkeit vom gesetzten Schwellenwert auf die von den Modellen berechneten Ähnlichkeitswerte. Dabei wird links jeweils die Variante mit der gesamten Merkmalsdatenbasis gezeigt und rechts die Klassengruppenvariante.	142
Abbildung 7–1	Die Ähnlichkeitswerte der Flächen des Typs I im Vergleich zu ausgewählten Biotoptypen.	149
Abbildung 7–2	Ähnlichkeitswerte der thematischen Mischbiotop (Typ III). Die Höhe des zweithöchsten Ähnlichkeitswerts ist mit einem grauen Balken hinterlegt, wenn dieser 10 % überschreitet.....	150

Abbildung 7–3 Auswirkung eines geometrischen Versatzes der Eingabedaten auf die Klassifizierungsgenauigkeit der Biotopklassifizierer (pMLK = ML-basierter Biotopklassifizierer, Fuzzy = Fuzzy-Biotopklassifizierer).	153
Abbildung 7–4 Ablauf der automatischen Biotopklassifizierung. Sie besteht aus 4 Phasen: A. Datenerhebung und Vorbereitung, B. Merkmalsberechnung, C. Aufbau und Genauigkeitsüberprüfung des Klassifizierers, D. Anwendung des Klassifizierers. Einige zur Phase A gehörende und in den Kapiteln 3.3.2 und 3.4.2 beschriebene Datenvorverarbeitungsschritte werden aus Gründen der Übersichtlichkeit nicht dargestellt.	156

Tabellenverzeichnis

Tabelle 2-1	Relationsmatrix $x \Rightarrow y$ der Regel aus Gleichung (2-11)	30
Tabelle 3-1	Übersicht über die verwendeten Ausgangs- und Zusatzdaten.....	44
Tabelle 3-2	Gegenüberstellung der Biotoptypen der Wohnbebauung (zweite Gliederungsebene) aus den jeweiligen Haupttypen für Siedlung/Wohnbebauung. Diese sind in Tabelle 3-3 und Tabelle 3-4 grau hinterlegt. Die Namen der Biotoptypen wurden aus Gründen der Übersichtlichkeit teilweise verkürzt.	47
Tabelle 3-3	Gegenüberstellung des Berliner und des BfN-Kartierschlüssels. Gezeigt wird jeweils die erste Gliederungsebene der Schlüssel (Haupttypen). Entsprechungen oder Überschneidungen zwischen den Haupttypen sind durch die waagerechten Trennlinien angedeutet.	48
Tabelle 3-4	Gegenüberstellung des Dresdner Kartierschlüssels und des Schlüssels der AG Methodik.	48
Tabelle 3-5	Vergleich der Genauigkeiten der Methoden zur DGM Berechnung (LE80 / LE90 in Dezimetern).	64
Tabelle 3-6	Klassenliste der verwendeten 67 urbanen Oberflächenarten (s. auch Anhang A). .	70
Tabelle 3-7	Akkumulierter Flächenanteil der Pixel an den Bildern F_{True} und F_{HyMap} , die eine oder mehrere Oberflächen enthalten.	89
Tabelle 3-8	Statistik der Flächenanteile des 1.-5. <i>Endmembers</i> für F_{True} und F_{HyMap}	90
Tabelle 3-9	Globale Flächenanteile der urbanen Oberflächen und absolute Abweichungen von diesen, bedingt durch Sensorabtastung und spektraler Entmischung.....	90
Tabelle 3-10	Übersicht über die Klassengruppen (Klassenkürzel s. Anhang A).....	97
Tabelle 4-1	Liste ökologischer Parameter und Indikatoren. Die Spalte FE enthält eine Einschätzung, inwieweit sich die Parameter / Indikatoren anhand von hyperspektralen Fernerkundungsdaten und in Deutschland (zukünftig) flächendeckend vorhandener GIS-Daten (z.B. dem AFIS-ALKIS-ATKIS-Modell) automatisch erfassen lassen. (1): Automatische Erfassung vollständig möglich. (2a) Erfassung nur in modifizierter Form möglich, da einige urbane Oberflächenarten (z.B. Fassadenbegrünung, Rasengittersteine oder Pflasterarten mit unterschiedlichen Fugenanteilen) nicht unterschieden werden können. (2b) Erfassung nur in modifizierter Form möglich, da einzelne Faktoren (z.B. Anschluss an die Kanalisation, Schädigungsgrad der Vegetation) nicht erfassbar sind. (2c) Kombination aus 2a und 2b. (3) Automatische Erfassung nicht möglich.	113
Tabelle 4-2	Übersicht der wichtigsten Oberflächenarten, auf denen die Berechnung der in Tabelle 4-1 aufgeführten Parameter und Indikatoren basiert (verändert nach Meinel & Netzband 1996).....	117
Tabelle 5-1	Übersicht der in den Fuzzy Modellen verwendeten Merkmale. Die drei Blöcke unterteilen die Merkmale in Biotop-, Klassen- und Klassensegmentmerkmale. Für die letzteren beiden ist jeweils die Klassengruppe aufgeführt, die Grundlage der Berechnungen ist.	126
Tabelle 5-2	Ergebnis der Genauigkeitsüberprüfung für die Kombination Trapezfunktion/Strategie 2. Gezeigt werden die <i>Omission</i> und <i>Commission Errors</i> der Klassen und die Konfusionsmatrix. In der Konfusionsmatrix befinden sich die Testbiotope in den Zeilen und die Klassenzuweisungen des Klassifizierers in den Spalten.....	130
Tabelle 6-1	<i>Omission Error</i> , <i>Commission Error</i> und Konfusionsmatrix der Klassifizierung der Biotope im Untersuchungsgebiet Berlin. In der Konfusionsmatrix befinden sich die Testbiotope in den Zeilen und die Klassenzuweisungen des Klassifizierers in den Spalten. Das gezeigte Ergebnis wurde mit der Klassengruppenvariante bei Begrenzung auf	

maximal 14 Merkmale pro Paarweiseklassifizierer erzielt. Die Gesamtgenauigkeit und der Kappa Koeffizient belaufen sich auf 82,0 % bzw. 0,789.....	141
Tabelle 7-1 Vor- und Nachteile der beiden Biotopklassifizierer.....	145
Tabelle 7-2 Ablauf einer Stadtbiotopkartierung nach Schulte <i>et al.</i> (1993: 496).....	154
Tabelle B-1 Untersuchungsgebiet Berlin, alle Klassen, maximal 12 Merkmalen pro Paarweiseklassifizierer.	179
Tabelle B-2 Untersuchungsgebiet Dresden, Klassengruppenvariante, maximal 11 Merkmalen pro Paarweiseklassifizierer.	180
Tabelle B-3 Untersuchungsgebiet Dresden, alle Klassen, maximal 11 Merkmalen pro Paarweiseklassifizierer.	181

1 Einleitung

1.1 Motivation und Ziele

Die Stadtbiotopkartierung ist eine in Deutschland weit verbreitete und etablierte Methode zur ökologischen Bestandsaufnahme der Stadt. Die Gründe für eine solche Bestandsaufnahme sind vielfältig: Beispielsweise wächst die Siedlungs- und Verkehrsfläche in Deutschland täglich um durchschnittlich 115 ha und erreichte 2004 einen Anteil von 12,8 % der Landesfläche (Statistisches Bundesamt 2006: 387f.). Diese wachsende Fläche bei Schutz, Pflege und Entwicklung der natürlichen Ressourcen außer Acht zu lassen, liegt nicht im Sinne eines umfassenden Naturschutzes und so schließt das Bundesnaturschutzgesetz (§ 1, BNatSchG) die besiedelte Fläche bereits seit der Fassung vom 20.12.1976 in seinen Zuständigkeitsbereich ein. Außerdem leben immer mehr Menschen in städtischen Gebieten. Dieser auch global zu beobachtende Trend führte 2004 in Deutschland zu einem Anteil von 84,6 % der in städtischen oder halbstädtischen Gebieten lebenden Bevölkerung (Statistisches Bundesamt 2005). Auch aus rein anthropogener Sicht ist daher eine ökologische Bestandsaufnahme der Stadt wichtig, da eine naturnahe Ausstattung des Lebensumfelds des Menschen eine höhere Lebensqualität mit sich bringt. So hat sich die Stadtbiotopkartierung in Deutschland als die Methode etabliert, um im urbanen Raum eine ökologische Datenbasis zu schaffen zur Untersuchung naturschutzfachlicher Fragen, zur Vertretung der Belange des Naturschutzes in zahlreichen Planungsverfahren und ganz allgemein für eine ökologisch orientierte Stadtplanung.

Seit ihrer Entwicklung Ende der 70er Jahre sind in Deutschland in 228 Mittel- und Großstädten Stadtbiotopkartierungen durchgeführt worden (Werner 2008, mündl.). Von Anfang an standen sich dabei zwei methodische Ansätze gegenüber (detaillierter ausgeführt in Kap. 2.3.3): Die selektive und die flächendeckende Stadtbiotopkartierung. In einem Versuch, eine einheitliche Vorgehensweise vorzuschlagen, sind die Vorteile beider Methoden in der sogenannten flächendeckend-repräsentativen Stadtbiotopkartierung kombiniert worden (Schulte *et al.* 1993). Dennoch gibt es in beiden Methoden und auch in ihrer Kombination Verbesserungspotenzial. So müssen bei der Kartierung häufig quantitative Größen wie z.B. Versiegelungsgrad und Vegetationsanteile durch Schätzung im Gelände oder aus Luftbildern ermittelt werden. Diese Schätzung ökologischer Biotopparameter birgt ein relativ hohes systematisches und zufälliges Fehlerpotenzial. Weiterhin ist die Bestimmung des Biotoptyps zu einem gewissen Maße subjektiv durch den Kartierer beeinflusst, da die thematische Abgrenzung der Biotoptypen in ihrer Reinform zwar klar ist, jedoch in der Realität nicht selten schwer einzuordnende Mischformen auftreten (Kap. 3.2.3 und 7.3.2).

Ein weiterer kritischer Punkt ist für viele Kommunen der Zeit- und Kostenfaktor der Kartierungen, die durch visuelle CIR-Luftbildinterpretation und Feldkartierungen durchgeführt werden. Ein Großteil der heute bestehenden 228 Kartierungen ist in der Etablierungsphase der Methoden (80er Jahre in den alten Bundesländern) entstanden und wurde häufig durch Landesmittel gefördert (Schulte & Sukopp 2000). In den 90er Jahren folgten weitere Erstkartierungen schwerpunktmäßig in Städten der neuen Bundesländer. Seitdem ist die Anzahl neuer Erst-

kartierungen jedoch stark zurückgegangen. Noch dramatischer erscheint die Anzahl der Aktualisierungskartierungen. Seitens der Wissenschaft wird empfohlen, etwa alle 5 Jahre anhand von Luftbildern und einer Nachkartierung ausgewählter Flächen zu prüfen, ob eine Aktualisierung der Biotoptypenkarte notwendig geworden ist (Schulte *et al.* 1993: 500). Der Anteil der Städte, die seit der Erstkartierung eine solche Aktualisierung durchgeführt haben, wird jedoch auf unter 5 % geschätzt (Sukopp 2008, Werner 2008, mündl.). Aufgrund des stetigen Wandels der Flächennutzungen in Städten ist daher anzunehmen, dass viele der vorliegenden Biotoptypenkarten in Teilen veraltet sind. Dennoch stellen viele Kommunen in Zeiten knapper Kassen und mit dem guten Gewissen, eine Erstkartierung durchgeführt zu haben, die periodische Aktualisierung der Biotoptypenkarten hinter andere Aufgaben zurück.

Um die fortlaufende Aktualisierung von Stadtbioptypenkarten zu fördern, untersucht die vorliegende Arbeit das Automatisierungspotenzial von Stadtbiotopkartierungen durch Nutzung von automatischen Auswertungsverfahren von Fernerkundungsdaten. Dabei soll und kann weder die Feldbegehung noch die visuelle Auswertung von Fernerkundungsbildern vollständig durch automatische Verfahren ersetzt werden. Es ist vielmehr das Ziel der Arbeit, *ausgewählte Teile* einer Stadtbiotopkartierung durch rechnergestützte Auswertungen zu automatisieren. Die zu entwickelnden Verfahren sollen Teil der Gesamtmethodik Stadtbiotopkartierung werden und in sinnvoller Kombination mit der visuellen Luftbildinterpretation und der Feldbegehung eingesetzt werden können.

Die vorliegende Arbeit baut auf umfangreiche und langjährige Methodenentwicklungen in der Sektion 1.4, Fernerkundung des Helmholtz Zentrums Potsdam – deutsches GeoForschungsZentrum (GFZ Potsdam) auf, wie es in den entsprechenden Kapiteln dargestellt wird. Aufgrund der bisherigen Erfahrungen wurden zwei Teilbereiche der Stadtbiotopkartierung ausgewählt, deren Automatisierungs- und Objektivierungspotenzial untersucht werden sollen: Die Berechnung ökologischer Parameter für Stadtbiotope und die Bestimmung des Biotoptyps. Der erste Untersuchungsgegenstand – die Berechnung ökologischer Parameter – ist am GFZ Potsdam bereits in der Doktorarbeit „Analyse hyperspektraler Flugzeugscannerdaten zur ökologischen Charakterisierung städtischer Biotope“ von Uta Heiden (2004) realisiert worden. Er wird in dieser Arbeit wiederaufgegriffen, um das Automatisierungspotenzial von Stadtbiotopkartierungen umfassender darzustellen. Der zweite Untersuchungsgegenstand – die Bestimmung des Biotoptyps – bildet dagegen den Hauptbestandteil dieser Arbeit. Mit Blick auf die Anwendung – der Aktualisierung einer bestehenden Biotoptypenkarte – wurde eine Software entwickelt, die in der Lage ist, den Biotoptyp einer gegebenen Fläche (eines Biotops aus der bestehenden Kartierung) automatisch aus Fernerkundungsdaten zu erkennen. Dabei werden für die zu klassifizierenden Biotope Ähnlichkeitswerte zu den Biotoptypen berechnet, aus denen die Klassifizierungsentscheidung abgeleitet wird. Die Problematik dieser Aufgabe wird im folgenden Kapitel weiter ausgeführt.

1.2 Aufbau der Arbeit

Im Folgenden wird die Aufgabenstellung aus Sicht der Fernerkundung beschrieben. Aus diesen Vorüberlegungen ergeben sich spezifische Anforderungen an die zu verwendenden Methoden und Daten und schlussendlich die gewählte Vorgehensweise sowie der Aufbau der Arbeit.

Urbane Biotoptypen können grundsätzlich in baulich geprägte und nicht baulich geprägte Typen eingeteilt werden. Insbesondere die baulich geprägten Typen bestehen aus unterschiedlichen, räumlich klar abgegrenzten Geoobjekten (Häuser, Bäume, Straßen etc.), die wiederum aus unterschiedlichen urbanen Oberflächen (z.B. Dachmaterialien, Vegetationstypen, Asphalt,

Schotter, Wasser etc.) bestehen (**Abbildung 1–1**). Daher kann die automatische Bestimmung des Biotoptyps eines Biotops aus Fernerkundungsbildern nicht pixelweise durchgeführt werden (vgl. Schowengerdt 1997: 395). Vielmehr müssen immer alle Pixel eines Biotops gemeinsam ausgewertet werden, um daraus den Typ des Biotops abzuleiten. Dafür muss die Abgrenzung des Biotops *a priori* bekannt sein. Diese Bedingung ist bei der Aufgabe der Aktualisierung einer bestehenden Stadtbiotopenkarte gegeben.



Abbildung 1–1 Einige Biotop¹ im Luftbild (Quelle: GoogleEarth; © AeroWest) mit überlagerten Biotopgrenzen aus der Kartierung. Die hier gezeigten baulich geprägten Biotoptypen bestehen alle im Wesentlichen aus den gleichen Geobjekten. Charakteristisch für die einzelnen Biotoptypen sind dagegen die Form, Größe, Häufigkeit und Anordnung der Geobjekte im Biotop. (a: Blockrandbebauung, b: Blockbebauung, c: Hochhausbebauung, d + g: Einzelhausbebauung, e + h: Zeilenbebauung, i: Schrebergärten).

Obwohl keine eindeutige Beziehung zwischen einem Biotoptyp und einer oder mehreren Oberflächenarten besteht, kann die Zusammensetzung eines Biotops aus verschiedenen Oberflächen-

¹ Leser, die sich an dieser Stelle über die Verwendung des Begriffs „Biotop“ wundern, wo doch fast nur Häuser zu sehen sind, seien auf die Erläuterung der flächendeckend-repräsentativen Stadtbiotopkartierung in Kap. 2.3.3 verwiesen.

arten einen ersten Hinweis auf dessen Typ geben. Daher ist eine Klassifizierung der Fernerkundungsdaten nach urbanen Oberflächen essentiell wichtig für die Bestimmung von Stadtbiotoptypen. So hängt die ökologische Funktion einer Fläche stark von der Art ihrer Oberfläche ab. Entscheidend für die Festlegung des Biotoptyps ist neben der Zusammensetzung eines Biotops aus verschiedenen Geoobjekten beziehungsweise Oberflächenarten auch deren Verteilung und Anordnung im Biotop, wie aus **Abbildung 1–1** ersichtlich wird. Die hier gezeigten Biotope unterschiedlichen Typs bestehen im Wesentlichen aus den gleichen Oberflächenarten beziehungsweise Geoobjekten. Betrachtet man die Gebäude, fällt auf, dass diese unterschiedlich, aber pro Biotoptyp ganz spezifisch angeordnet sind oder eine spezifische Form oder Höhe haben. Wenn es gelingt, diese charakteristischen Eigenschaften der Biotoptypen bzw. deren Geoobjekte mit automatisch berechneten Merkmalen numerisch zu erfassen, stellen diese Merkmale die geeignete Datengrundlage für deren Unterscheidung dar.

Aus den obigen Ausführungen ergeben sich die folgenden Anforderungen an die Methode und an die zu verwendenden Daten. Der zu entwickelnde Biotopklassifizierer muss alle Pixel eines Biotops in die Auswertung einbeziehen. Die beiden, im Rahmen der Arbeit entwickelten Lösungswege werden in Kapitel 5 und 6 vorgestellt. Der grundsätzliche Unterschied zwischen beiden Lösungswegen ist die Art, wie der Klassifizierer aufgebaut wird, nämlich zum einen wissensbasiert und kontrolliert durch den Analysten, zum anderen vollständig automatisch durch den Computer. Auf der einen Seite erlernt der Computer das Wissen des Analysten, auf der anderen Seite lernt er anhand von Trainingsdaten und kann so eventuell sogar Zusammenhänge aufdecken, die dem Analysten noch nicht bekannt waren.

Die Erkennung von Biotoptypen erfolgt nicht direkt auf den fernerkundlichen Ausgangsdaten, sondern auf Basis von daraus abgeleiteten, numerischen Merkmalen (Kap. 4), die die charakteristischen Eigenschaften der Biotoptypen beschreiben und rechnerisch erfassen sollen. Die Datenbasis für die Berechnung dieser numerischen Merkmale wird ausführlich in Kapitel 3 vorgestellt. Die wichtigste Grundlage sowohl für die Berechnung ökologischer Parameter, als auch für die Bestimmung der Biotoptypen bildet die flächendeckende Bestimmung der urbanen Oberflächen. Nach dem Stand der Wissenschaft bietet sich hierfür die Klassifizierung von hyperspektralen Daten an (Kap. 3.4), da diese erfahrungsgemäß die größte thematische Differenzierung ermöglichen. Weitere notwendige Eingangsdaten sind die Biotopgrenzen (Kap. 3.2.4) und ein digitales Oberflächenmodell (Kap. 3.3). Dieses kann zum einen die Unterscheidung der urbanen Oberflächen unterstützen (verschiedene Materialien werden sowohl ebenerdig, als auch in Hausdächern verbaut), zum anderen bietet es zusätzliche Möglichkeiten für die Berechnung von ökologischen Parametern (Kap. 4.4) und für die Berechnung der Merkmale. Vervollständigt wird der Aufbau der Arbeit durch einen Überblick über den Stand der Wissenschaft der relevanten Fachgebiete (Kap. 2) und eine abschließende Diskussion der erzielten Ergebnisse (Kap. 7).

2 Grundlagen

Dieses Kapitel vermittelt die wesentlichen Grundlagen sowie den Stand der Wissenschaft der durch die Arbeit berührten Fachdisziplinen und Methoden. Davon ausgehend, dass die ihrem Kernbestandteil nach methodisch-fernerkundliche Arbeit eine entsprechend vorgebildete Leserschaft ansprechen wird, wird im Kapitel Fernerkundung auf eine allgemeine Einführung verzichtet. Es werden die von der Arbeit besonders betroffenen Bereiche der hyperspektralen Fernerkundung als methodischer und der urbanen Fernerkundung als thematischer Teilbereich behandelt. Anschließend werden die Grundzüge der Fuzzy Logik, die in Kapitel 5 zur Klassifizierung von Stadtbiotopen eingesetzt wird, sowie die Theorie und Praxis der Stadtökologie geschildert.

2.1 Fernerkundung

„Remote sensing is the practice of deriving information about the earth’s land and water surface using images acquired from an overhead perspective, using electro-magnetic radiation in one or more regions of the electromagnetic spectrum, reflected or emitted from the earth’s surface.“

J. B. Campbell (1996: 5)

Während die Fernerkundung auch allgemein als „Informationsgewinnung über Objekte aus der Ferne“ definiert wird, gibt Campbell eine anwendungsbezogene Definition der Fernerkundung, die das Hauptanwendungsgebiet beschreibt: Die Messung der von der Erdoberfläche reflektierten oder emittierten elektromagnetischen Strahlung mit entsprechenden zumeist flugzeug- oder satellitengestützten Sensoren bzw. die Auswertung der dabei entstehenden (Bild-)Daten unter verschiedensten Fragestellungen mit unterschiedlichen Methoden. Für eine Erläuterung der physikalischen Grundlagen der Fernerkundung wird an dieser Stelle z.B. auf Rees (2001) oder Schowengerdt (1997, Kap. 2-3) verwiesen. Einen Überblick über fernerkundliche Methoden und Anwendungen im Allgemeinen geben zahlreiche Lehrbücher (z.B. Albertz 1991, Sabins 1997, Schowengerdt 1997, Lillesand & Kiefer 1999, Richards & Jia 1999, Jensen 2007). Die beiden folgenden Unterkapitel konzentrieren sich auf die fernerkundlichen Teilgebiete, die von dieser Arbeit besonders berührt werden: Auf die hyperspektrale Fernerkundung und auf die Nutzung von Fernerkundungsdaten in urbanen Gebieten.

2.1.1 Grundlagen der hyperspektralen Fernerkundung

Die hyperspektrale (Erd-)Fernerkundung zählt zum Bereich der passiven, optischen Fernerkundung, d.h. der Messung der von der Erdoberfläche reflektierten Solarstrahlung. Dadurch unterscheidet sie sich von der Fernerkundung mit aktiven Sensoren (z.B. Laser- oder Radarsensoren), die eine eigene Strahlungsquelle besitzen, und von der thermalen Fernerkundung, die nicht im

optisch-reflektiven Bereich des elektromagnetischen Spektrums misst, sondern im thermalen Infrarot (3 – 14 μm).

Die passiven, optischen Sensoren werden in der Regel anhand ihrer spektralen Auflösung in multispektrale (wenige spektrale Kanäle), hyperspektrale (viele Kanäle; i.d.R. > 40), und sogar ultraspektrale Sensoren eingeteilt – mit fließenden Grenzen. Eine entsprechende Einteilung erfolgt auch anhand der räumlichen Auflösung. Hyperspektrale Sensoren (auch abbildende Spektrometer genannt) zeichnen sich dadurch aus, dass sie für jedes Bildelement im Bereich des sichtbaren Lichts (VIS: 0,4 – 0,7 μm), des nahen (NIR: 0,7 – 1,0 μm) und des mittleren Infrarots (SWIR: 1,0 – 2,5 μm) ein nahezu kontinuierliches Spektrum mit sehr vielen, schmalen und aneinandergrenzenden Kanäle aufnehmen². Die hohe spektrale Auflösung ermöglicht eine detaillierte Wiedergabe der spektralen Signaturen (kurz: Spektren) von Objekten der Erdoberfläche (**Abbildung 2–1**, rechts). Die Darstellung in **Abbildung 2–1** zeigt, dass die Varianz der Reflexionshöhe innerhalb einer Klasse sehr groß sein kann und dass eine Unterscheidung aufgrund der absoluten Reflexionshöhe häufig schwierig ist. Die ausreichende Abtastung von lokalen spektralen Charakteristika wie z.B. Absorptionsbanden und Reflexionsmaxima trägt somit zu einer im Vergleich zu multispektralen Daten höheren Differenzierbarkeit der Oberflächen bei.

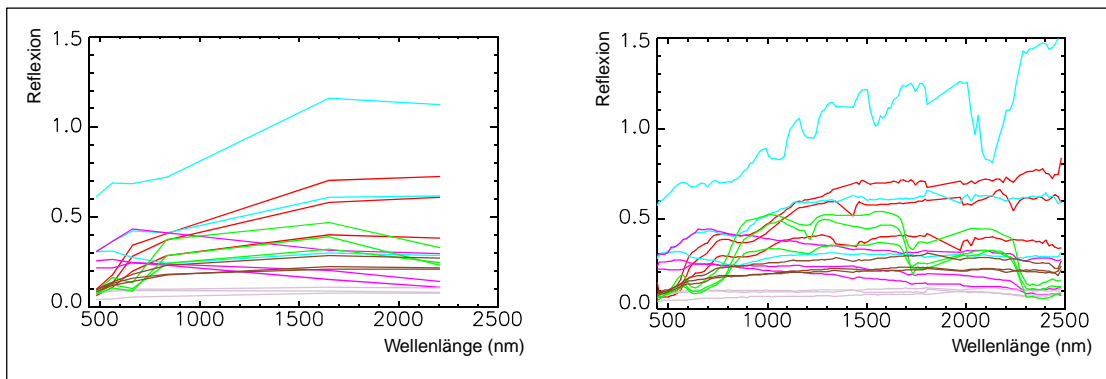


Abbildung 2–1 Spektren ausgewählter urbaner Materialien (je drei). Zyan: Aluminiumdach, rot: rote Tonziegel, magenta: PVC-Dach, grün: grüner Kunstrasen, braun: Boden, blassrosa: Asphalt. Aus Gründen der Übersichtlichkeit wird in beiden Plots eine Liniendarstellung gewählt.

Um das von einem Sensor gemessene Signal, das Spektrum einer Oberfläche, zu verstehen und analysieren zu können, ist es notwendig, die physikalischen Prozesse und Einflüsse zu kennen, die die elektromagnetische Strahlung auf ihrem Weg Sonne – Erdoberfläche – Sensor (**Abbildung 2–2**) beeinflussen. Aus ihnen resultieren die spektralen Eigenschaften – die Form, der Verlauf – des gemessenen Spektrums, aber auch die Notwendigkeit einer präzisen Vorprozessierung dieser Daten, bevor eine Auswertung stattfinden kann. Die Einflüsse treten auf bei der Interaktion der elektromagnetischen Strahlung mit der Atmosphäre, mit der Erdoberfläche und bei ihrer Messung im Sensor und werden im Folgenden kurz beschrieben. Anschließend werden die entsprechenden Korrekturschritte aufgeführt.

² Eine Einführung in die hyperspektrale Fernerkundung findet sich z.B. in van der Meer & de Jong (2001)).

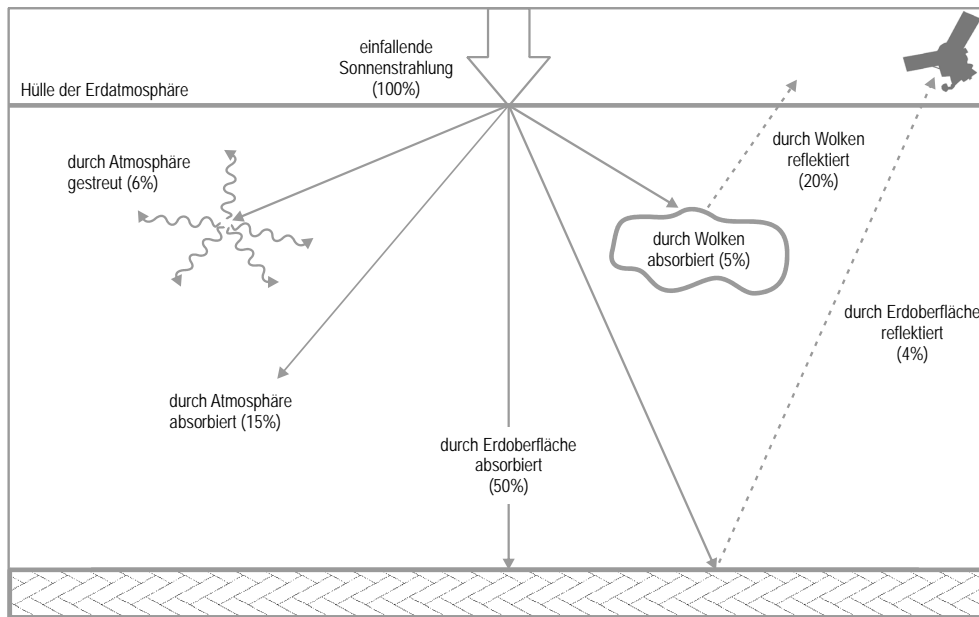


Abbildung 2-2 Quantifizierung der Strahlungsverluste auf dem Strahlungsweg Sonne – Erdoberfläche – Sensor (nach: Gibson 2000: 25).

Interaktion der elektromagnetischen Strahlung mit der Atmosphäre

Die von der Sonne emittierte Strahlung (engl.: *spectral radiant exitance*) entspricht der spektralen Strahldichte eines schwarzen Körpers mit einer Temperatur von 5900 K (Schowengerdt 1997: 37). Sie wird in $[\text{W m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}]$ angegeben und ist in **Abbildung 2-3** in Abhängigkeit von der Wellenlänge dargestellt. Abweichungen von dieser theoretischen Kurve entstehen in der Realität vor allem wellenlängenspezifisch in sehr schmalen Absorptionslinien geringer Tiefe, die durch die solaren Gase hervorgerufen werden. Die spektrale spezifische Ausstrahlung der Sonne integriert über alle Richtungen des Halbraums in $[\text{W m}^{-2} \mu\text{m}^{-1}]$ wird durch das Plancksche Strahlungsgesetz beschrieben (**Gleichung (2-1)**). Die auf die äußere Erdatmosphäre einfallende Sonnenstrahlung (engl.: *irradiance*) (**Abbildung 2-4**, gestrichelte Linie) ist, bedingt durch die Entfernung Sonne – Erdatmosphäre, geringer als die Ausstrahlung der Sonne. Sie beträgt an ihrem Maximum bei $0,49 \mu\text{m}$ etwa $2000 \text{ W m}^{-2} \mu\text{m}^{-1}$ im Vergleich zu mehr als 90 Millionen $\text{W m}^{-2} \mu\text{m}^{-1}$. Diese Verringerung erfolgt gleichmäßig über alle Wellenlängen durch Anwendung der **Gleichung (2-2)** (Schowengerdt 1997: 37).

$$M_{\lambda} = \frac{C_1}{\lambda^5 [e^{C_2/(\lambda T)} - 1]} \quad (2-1)$$

mit der Temperatur T des schwarzen Körpers in Kelvin,

der Wellenlänge λ ,

$$C_1 = 3,74151 \cdot 10^8 \text{ W m}^{-2} \mu\text{m}^4,$$

$$C_2 = 1,43879 \cdot 10^4 \mu\text{m K}.$$

$$E_{\lambda}^0 = \frac{M_{\lambda}}{\pi} \times \frac{\text{area solar disk}}{(\text{distance to earth})^2} \quad (2-2)$$




Abbildung 2-3 Die spektrale Strahlungsleistung von schwarzen Körpern verschiedener Temperaturen. Sonne = 5900 K, Erde = 273 K (verändert nach: Albertz 1991: 13).

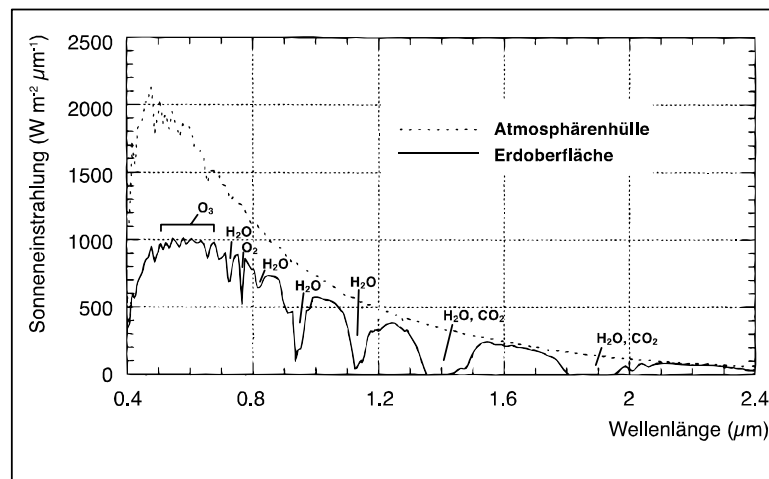


Abbildung 2-4 Vergleich der spektralen spezifischen Einstrahlung der Sonne auf die äußere Erdatmosphäre und die Erdoberfläche. Die feinen Absorptionslinien der oberen Kurve werden durch solare Gase hervorgerufen. Die breiteren Absorptionsbanden der unteren Kurve resultieren zusätzlich aus dem Einfluss der Erdatmosphäre (verändert nach: Schowengerdt 1997: 42).

Während die spektrale Information des Sonnenlichts auf dem Weg durch das All unverändert bleibt, wird sie beim Durchqueren der Erdatmosphäre wellenlängenspezifisch verändert. Eine starke Verringerung der Strahlungstransmission tritt an atmosphärischen Absorptionsbanden auf (lokale Minima in der durchgezogenen Linie in **Abbildung 2-4**). Diese werden durch Moleküle der atmosphärischen Gase (v.a. Wasserdampf, Kohlendioxid und Ozon) verursacht, die die Strahlung wellenlängenspezifisch absorbieren und in Wärme umwandeln. Eine weitere Reduktion auf dem Strahlengang Sonne – Erdoberfläche – Sensor erfolgt durch die atmosphärische Streuung an Aerosolen (genannt Mie Streuung, z.B. durch Rauch, Dunst, Nebel) und an größeren Molekülen (genannt Rayleigh Streuung, z.B. durch N_2 und O_2). Die genannten atmosphärischen Effekte führen dazu, dass das Licht, das die Erdoberfläche erreicht, nur ca. 54 % des die Erdatmosphäre erreichenden Lichts ausmacht (Gibson 2000: 25). Außerdem bewirkt die atmosphärische Streuung, dass das Licht, das ein Fernerkundungssensor misst, nicht ausschließlich aus der von der Erdoberfläche reflektierten Strahlung zusammengesetzt ist (**Abbildung 2-5**).

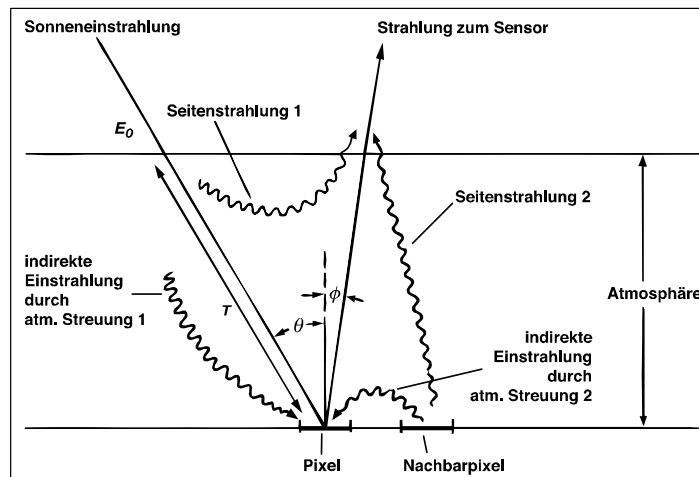


Abbildung 2-5 Wege der elektromagnetischen Strahlung durch die Erdatmosphäre. Neben dem direkten Weg Sonne – Erdoberfläche – Sensor gelangt die Strahlung bedingt durch die atmosphärische Streuung auf je zwei zusätzlichen Wegen zum Pixel im Fokus des Sensors bzw. zum Sensor ohne Kontakt mit dem Pixel (verändert nach: Richards & Jia 1999: 40).

Interaktion der elektromagnetischen Strahlung mit der Erdoberfläche

Bei ihrem Auftreffen auf der Erdoberfläche wird die elektromagnetische Strahlung reflektiert, absorbiert oder bei lichtdurchlässigen Oberflächen auch transmittiert. Da die meisten Oberflächen jedoch lichtundurchlässig sind, kann in der Regel angenommen werden, dass pro Wellenlänge die Summe aus absorbiertem und reflektiertem Strahlung gleich der eingefallenen Strahlung ist.

Wie stark die Strahlung von einer Oberfläche absorbiert wird, bestimmt dessen molekulare Zusammensetzung. Prozesse auf molekularer Ebene, die zur wellenlängenspezifischen Absorption von Strahlung führen, sind elektronische Prozesse (z.B. Erhöhung des Energieniveaus von Elektronen und Ladungstransfer zwischen Atomen bzw. Molekülen) und Vibrations- bzw. Rotationsprozesse (Clark 1999). Diese finden gleichwohl in anorganischen (Mineralen und Gesteinen, Wasser, urbane Oberflächen, usw.) wie in organischen Substanzen (Vegetation, Humus, etc.) statt. Die Position, Form, Tiefe und Breite der dadurch hervorgerufenen spektralen Absorptionsbanden wird direkt durch die chemische Zusammensetzung des Materials der Oberfläche bestimmt (van der Meer & de Jong 2001: 3ff.). Da sich eine Absorption in einer Verringerung der durch den Sensor gemessenen reflektierten Strahlung ausdrückt, enthält dieses Signal somit Informationen, die auf die chemischen Eigenschaften des Materials der Oberfläche zurückzuführen sind, und anhand derer die Oberfläche aus hyperspektralen Fernerkundungsdaten identifiziert werden kann (z.B. Clark *et al.* 1990, Boardman *et al.* 1995). Weiterhin lassen sich anhand dieser spektralen Merkmale quantitative Aussagen treffen, z.B. über den Eisen- oder Karbonatgehalt von Böden (z.B. Ben-Dor & Banin 1990, z.B. Ben-Dor 2002, Ben-Dor *et al.* 2006, Richter *et al.* 2008), den Gehalt an organischen Schwebstoffen im Wasser (Kirkpatrick *et al.* 2003, Heim *et al.* 2005, Craig *et al.* 2006) oder die Flächenanteile von Oberflächenarten in einem Mischpixel (z.B. Adams *et al.* 1993). Diese Möglichkeit der Quantifizierung unter einem chemisch-physikalischen Hintergrund ist die zentrale Eigenschaft der hyperspektralen Fernerkundung, die sie von der multispektralen unterscheidet.

Neben den chemischen Eigenschaften verändern weitere Eigenschaften einer Oberfläche die reflektierte Strahlung. Hierzu zählen die Rauigkeit und der physische Zustand (z.B. Feuchtigkeit, Verwitterung, Verschmutzung). Feuchtigkeit führt in allen Wellenlängen und besonders an den Absorptionsbanden des Wassers zu einer Absenkung der Reflexion. Von der Rauigkeit einer Oberfläche hängt die Art der Reflexion ab. Man unterscheidet die theoretischen Fälle der spiegelnden, gerichteten, diffusen und gemischten Reflexion (Albertz 1991: 18f.) (s. auch **Abbildung 2–6**). Alle Fälle außer der perfekt diffusen Reflexion vermindern die Vergleichbarkeit der Spektren in einem Fernerkundungsbild, da sie die Reflexion in Abhängigkeit zur Aufnahmegeometrie (Einfallswinkel- und Ausfallswinkel) setzen. Eine physikalisch basierte Korrektur basierend auf der bidirektionalen Reflexionsverteilungsfunktion (engl.: *bidirectional reflectance distribution function*, BRDF) ist in der Regel äußerst schwierig, da die Art der Reflexion von der Art der Oberfläche abhängt, die selten vor der eigentlichen Auswertung der Daten bekannt ist. In dieser Arbeit wird die radiometrische Variationsbreite der Oberflächen, die durch die verschiedenen Aufnahmegeometrien einer Szene entsteht, durch eine entsprechende Variationsbreite der Trainingspektren für die jeweiligen Oberflächen bei der Klassifikation zu kompensieren versucht (3.4.3).




Abbildung 2–6 Spiegelnde, gerichtete, diffuse und gemischte Reflexion (ergänzt nach: Albertz 1991: 18).

Sensorspezifische Einflüsse

Wird eine Geokodierung eines Bildes durchgeführt, bei der nicht *Nearest Neighbor* als *Resampling* Methode gewählt wird, so hat die Berechnung der geographischen Positionen der Pixel indirekt Einfluss auf die Spektren der resultierenden Pixel, da diese aus den Spektren mehrerer Pixel einer Nachbarschaft interpoliert werden. Bei der Berechnung der Pixelkoordinaten müssen dabei die Art der Trägerplattform und die Aufnahmegeometrie des Sensors berücksichtigt werden. Hyperspektrale Sensoren arbeiten nach dem Scannerprinzip, d.h. sie nehmen die Erdoberfläche Zeile für Zeile quer zur Flugrichtung der Sensorplattform (Flugzeug oder Satellit) auf. Bei flugzeuggestützten Sensoren wird während des Überflugs die Position und Lage des Sensors durch eine integrierte DGPS/INS-Einheit festgehalten. Die sechs Parameter der äußeren Orientierung (x-, y-, z-Koordinate, Rollwinkel, Neigungswinkel, Kantungswinkel) werden für jede Bildzeile festgehalten, da jede Bildzeile durch die Bewegungen des Flugzeuges eine eigene Aufnahmegeometrie aufweist. Dadurch beinhalten die Bilddaten vor einer entsprechenden Korrektur erhebliche geometrische Verzerrungen. Diese treten bei Satellitenbildern durch die stabile Umlaufbahn der Satellitenplattform nicht auf. Jedoch beeinflusst hier bei Bildern größerer Ausmaße die Erdkrümmung die räumliche Lage der Pixel. Weiterhin kann durch die Erdrotation ein Versatz zwischen den einzelnen Kanälen entstehen, wenn diese bedingt durch einen unterschiedlichen Blickwinkel zeitlich versetzt aufgezeichnet werden.

Bei den Scannersystemen werden grundsätzlich zwei Bauarten unterschieden: *Whiskbroom* Scanner (opto-mechanische Scanner) und *Pushbroom* Scanner (opto-elektronische Scanner). Da sich die Sensor-bedingten Einflüsse auf das Spektrum für beide Systeme unterscheiden, sollen die Aufnahmeprinzipien kurz erläutert werden.

Whiskbroom Scanner tasten die Erdoberfläche quer zur Flugrichtung mit einem rotierenden Spiegel ab (**Abbildung 2-7**, links), welcher das einfallende Licht des im GIFOV befindlichen Ausschnitts der Erdoberfläche über eine Optik und ein Dispersionselement (z.B. ein Prisma) auf ein Detektorarray lenkt. Das Dispersionselement spaltet das Licht entsprechend der Wellenlänge auf, so dass jedes Detektorelement (engl.: *charge coupled device*, kurz CCD) das Licht eines bestimmten Wellenlängenintervalls misst. Das Intervall wird durch die *spectral response function* (SRF) des Sensors beziehungsweise durch dessen Mittelwert (Position des Intervalls) und Halbwertsbreite (Breite des Intervalls) definiert, wobei angenommen wird, dass die Form der SRF einer Gaußkurve nahe kommt. Die Messung dieser Angaben ermöglicht eine genaue spektrale Kalibrierung der Messungen eines *Whiskbroom* Scanners. Ein räumliches Artefakt, das bei *Whiskbroom* Sensoren auftritt, ist der Panorama Effekt. Dieser bewirkt, dass bei konstantem IFOV das GIFOV der Pixel zum Flugstreifenrand hin zunehmend größer wird. Der Panorama Effekt, der bei *Pushbroom*-Systemen durch die Optik ausgeglichen werden kann, ist bei *Whiskbroom*-Systemen allerdings nur ab einem gewissen Öffnungswinkel relevant.

Ein *Pushbroom* Scanner besitzt im Gegensatz zum *Whiskbroom* Scanner für jedes Pixel der Bildzeile ein solches Detektorarray, so dass alle Pixel einer Bildzeile gleichzeitig aufgenommen werden (**Abbildung 2-7**, rechts). Dadurch kann die Integrationszeit erhöht werden mit dem Ergebnis eines deutlich höheren SNRs. Jedoch treten durch das zweidimensionale Detektorarray Artefakte auf, deren Korrektur nicht vollständig möglich ist. Diese sind durch Abbildungsfehler des einfallenden Lichts auf das Detektorarray bedingt, die sowohl entlang der spektralen Achse des Arrays (*spectral smile/frown*) als auch entlang der räumlichen Achse des Arrays (*keystone error*) entstehen. Beide Fehler sind dabei abhängig von der Wellenlänge und von der Position des Detektors auf der Bildzeile (nähere Informationen in (Mouroulis *et al.* 2000)).




Abbildung 2-7 Aufnahmeprinzip eines *Whiskbroom* und *Pushbroom* Scanners (verändert nach: Sabins 1997: 18)

Korrektur der oben beschriebenen Effekte

Die Korrektur der beschriebenen sensorbedingten Effekte wird in der Regel durch den Datenprovider durchgeführt, soweit dies möglich ist. Durch eine Kalibrierung des Sensors vor und während des Überflugs ist es möglich, die aufgezeichneten DN in die Einheit Radianz oder Strahldichte (z.B. in $\text{Wm}^{-2}\mu\text{m}^{-1}\text{sr}$) zu überführen. Je nach Wunsch des Anwenders können die nachstehenden Korrekturschritte dann von ihm selbst oder ebenfalls vom Datenprovider über-

nommen werden. Diese werden hier kurz angesprochen und in Kapitel 3.4.2 bei der Prozessierung der HyMap-Daten ausführlich beschrieben.

Da man sich in der Erdfernerkundung für die Eigenschaften der Erdoberfläche interessiert, besteht der nächste Korrekturschritt darin, den störenden Einfluss der räumlich und zeitlich variablen Atmosphäre herauszurechnen (atmosphärische Korrektur). Dieser Korrekturschritt von Radianz auf Reflexion bewirkt gleichzeitig eine Normierung der Spektren, die eine bedingte Vergleichbarkeit sowohl innerhalb eines Datensatzes, als auch mit Spektren anderer Datensätze oder spektraler Bibliotheken herstellt.

Das SNR der Kanäle eines Sensors kann mit der Wellenlänge variieren. Häufig weisen Kanäle, die sich in der Nähe atmosphärischen Absorptionsbanden befinden, ein ungenügendes SNR auf, was sich durch ein verrauscht aussehendes Bild äußert. Diese Kanäle sind für die weitere Auswertung unbrauchbar und müssen aus dem Datensatz entfernt werden.

Bei Satellitenbildern kann die Geokodierung (geometrische Korrektur) in der Regel durch eine einfache polynomiale Entzerrung mit wenigen Passpunkten vorgenommen werden. Durch die Angabe von Koordinaten einer bestimmten Projektion für die Passpunkte erfolgt der Raumbezug. Aufgrund der komplizierteren Aufnahmegeometrie bei flugzeuggetragenen Sensoren muss hier eine parametrische Geokodierung unter Verwendung der beim Überflug festgehaltenen Parameter der äußeren Orientierung jeder Bildzeile vorgenommen werden (s. Kap. 3.4.2). Dadurch wird jede Bildzeile einzeln entzerrt. Zur Berechnung von in den Orientierungsparametern enthaltenen *Offsets* können hierbei ebenfalls Passpunkte benutzt werden.

2.1.2 Anwendungsfelder und Methoden der Fernerkundung in urbanen Gebieten

Urbane Gebiete sind ein vergleichsweise junges, aber rege wachsendes Einsatzgebiet der Fernerkundung. Ein Spiegel dieser rasanten Entwicklung ist die stark ansteigende Zahl von urban geprägten Fernerkundungskonferenzen, Sonderausgaben einschlägiger wissenschaftlicher Zeitschriften und das Erscheinen der ersten Bücher mit dem Anspruch, die verschiedenen Forschungsaktivitäten zu ordnen und einen Überblick über das dynamische Feld der urbanen Fernerkundung zu vermitteln (Donnay *et al.* 2001, Jensen *et al.* 2005, Jensen *et al.* 2007, Netzband *et al.* 2007b, Weng & Quattrochi 2007, Rashed & Jürgens 2009). Ursache dieses aktuellen Wachstums sind zum einen die verschiedenen Probleme, die die zunehmende weltweite Verstädterung mit sich bringt, zum anderen eine Verbesserung der Qualität und Verfügbarkeit verschiedenster Fernerkundungsdaten, die insbesondere in den letzten zehn Jahren die neuen Anwendungsmöglichkeiten eröffnet haben. Im Folgenden werden einige typische Anwendungsfelder der urbanen Fernerkundung mit den jeweilig zum Einsatz kommenden Daten und Methoden vorgestellt. Es werden exemplarische Referenzen angegeben, die den Stand der Forschung dokumentieren. Auf Anknüpfungspunkte dieser Arbeit wird an geeigneten Stellen hingewiesen.

Eines der breitesten Anwendungsfelder ist die 2D-Kartierung von Landbedeckungen (engl.: *land cover mapping*). Die Anwendungen reichen hier von der Detektion von Siedlungsflächen (Tomowski *et al.* 2006), insbesondere zur Überwachung der Flächeninanspruchnahme von stark expandierenden (Mega-)Städten (engl.: *urban growth detection / urban sprawl*) (z.B. Sudhira *et al.* 2004, Taubenböck *et al.* 2009), bis hin zu detaillierten Kartierungen urbaner Oberflächenmaterialien (Roessner *et al.* 2001, Heiden *et al.* 2007), wie sie auch in dieser Arbeit zum Einsatz kommen (Kap. 3.4.3). Verwendet werden hierfür vor allem optische Fernerkundungsdaten mittlerer bis hoher räumlicher Auflösung. Die Anzahl der unterscheidbaren thematischen Klassen

steigt dabei mit der spektralen Auflösung der Bilddaten (Herold *et al.* 2003). Multitemporale Auswertungen ermöglichen hier ein Monitoring, eine Veränderungsanalyse (engl.: *change detection*) und eine Vorhersage des Flächenverbrauchs (z.B. Wu *et al.* 2006, Jat *et al.* 2008, Han *et al.* 2009) und der Bevölkerungszunahme, insbesondere wenn die entwickelten Vorhersagemodelle mit demographischen Daten verknüpft werden (z.B. Liverman *et al.* 1998: Kap. 6, Yin *et al.* 2005, Taubenböck *et al.* 2007).

Landnutzungskarten sind thematische Karten, die in verschiedenen Planungsprozessen verwendet werden. Die Verbindung von der aus Fernerkundungsdaten direkt ableitbaren Landbedeckung zur Landnutzung (engl.: *land use*) ist in urbanen Gebieten jedoch nicht immer einfach herzustellen, da die kleinräumig komplex vermischten urbanen Oberflächen in der Regel mehrdeutig unterschiedlichen Nutzungstypen zugeordnet werden können. Zur Lösung des Problems können kontextbasierte, mustererkennende oder objektbasierte Algorithmen eingesetzt werden, die z.B. in der Lage sind, Stadtstrukturtypen (z.B. Taubenböck *et al.* 2006) oder Stadtbiotoptypen – das Thema dieser Arbeit – zu identifizieren.

Die oben genannten Anwendungen sind besonders für die meist unkontrolliert wachsenden Mega-Städte in Entwicklungsländern von großem Nutzen. Häufig werden sie hier auch zur Abschätzung des Gefährdungspotenzials der Städte/Stadtteile durch Naturkatastrophen eingesetzt (z.B. Münich *et al.* 2006, Taubenböck *et al.* 2008).

Seit dem Start einer neuen kommerziellen Satellitengeneration ab dem Jahr 1999 (IKONOS, Quickbird, OrbView 3) sind räumlich hochauflösende Bilddaten im Meter- (multispektral) bzw. Dezimeterbereich (panchromatisch) global verfügbar. In den Folgejahren sind viele Anwendungen und Methoden aus dem Bereich der photogrammetrischen Auswertung von Luftbildern auf diese neuen Daten übertragen worden. Die räumlichen Auflösungen dieser Satellitensensoren ermöglichen es, einzelne topographische Objekte zu erkennen. Verfahren zur automatischen Extrahierung von Gebäuden und Straßen (z.B. Fraser *et al.* 2002, Mena 2003, Mayer 2008) und zur automatischen Aktualisierung topographischer Karten (z.B. Holland *et al.* 2006) oder digitaler Vektordatenbestände können dadurch global eingesetzt werden. Aus Stereobildpaaren können digitale Höhenmodelle erzeugt werden (z.B. Zhang & Gruen 2006), aus denen wiederum 3D-Stadtmodelle generiert werden (z.B. Ehlers *et al.* 2002).

Aufgrund der sich ergänzenden Informationen unterschiedlicher Datenarten werden diese häufig gemeinsam ausgewertet (Datenfusion) (z.B. Haala & Anders 1997, Bucher & Lehmann 2000, Gamba & Houshmand 2001, Sohn & Dowman 2007). Zusammen erfassen die verschiedenen Daten einen breiteren Ausschnitt der Informationsvielfalt des urbanen Raumes, die im thematischen, räumlichen und spektralen Sinne als sehr komplex bezeichnet werden kann. Dies führt zu einer Genauigkeitssteigerung vieler Untersuchungen oder macht diese erst möglich. Neben optischen Fernerkundungsdaten sind digitale Oberflächenmodelle, generiert aus LIDAR- oder SAR-Daten oder berechnet durch *Stereo Image Matching* optischer Bildpaare, eine wichtige Informationsquelle im urbanen Raum, die auch in dieser Arbeit genutzt wird (Kap. 3.3). Thermale Sensoren akquirieren wichtige Informationen z.B. für Stadtklimamodelle (Voogt & Oke 2003, Weng & Quattrochi 2006), die ebenfalls zahlreiche weitere abgeleitete Informationen, wie Geländehöhe und -rauigkeit oder das Material der urbanen Oberflächen nutzen.

Neben LIDAR-Daten gehören Hyperspektraldaten zu den wenigen Fernerkundungsdatentypen, die bisher noch nicht in einer räumlichen Auflösung aus dem All aufgenommen werden können, bei der die Geoobjekte einer Stadt nach dem Nyquist-Theorem ausreichend abgetastet werden. Smalls Untersuchungen in 12 verschiedenen Großstädten der Welt zeigen, dass die Auflösung

hierfür mindestens 5-10 Metern betragen muss (Small 2001). Da Hyperspektraldaten jedoch gegenüber optischen, multispektralen Daten eine bessere Differenzierbarkeit urbaner Oberflächenmaterialien ermöglichen (Ben-Dor *et al.* 1998, Herold *et al.* 2003), werden in dieser Arbeit Daten des flugzeuggetragenen HyMap-Sensors ausgewertet (Kap. 3.4), die mit 3,5 - 4 m das Kriterium der räumlichen Auflösung erfüllen.

Trotz der Fülle von Anwendungen monieren Kritiker häufig eine Lücke zwischen den in der Wissenschaft untersuchten Fragestellungen und den Bedürfnissen der lokalen Behörden und Stadtplaner (Netzband *et al.* 2007a: 3f., 16). Es wird ein Dialog und von Seiten der Wissenschaft eine stärkere Anwendungsbezogenheit gefordert. Die in Netzband *et al.* (2007b) dargestellten Projekte zeigen positive Beispiele hierfür, in die sich die vorliegende Arbeit einzureihen versucht.

2.2 Fuzzy Logik

Die Fuzzy Logik Theorie (Zadeh 1965) wird von ihrem Begründer Lofti A. Zadeh als Methode bezeichnet, mathematisch präzise mit Ungenauigkeiten (engl.: *imprecision*) umzugehen, analog zur Wahrscheinlichkeitstheorie, die entwickelt wurde, um mathematisch präzise mit Unsicherheiten (engl.: *uncertainty*) umzugehen (Zadeh, L. A., 2003 im Vorwort von Demicco & Klir 2004). Ungenauigkeiten in diesem Sinne werden nicht negativ als fehlender Informationsgehalt verstanden, sondern als korrekte, aber unscharf formulierte Information (z.B. ein hohes Haus; nicht weit entfernt; in ein paar Tagen). Häufig besteht diese Information aus sprachlich formuliertem menschlichen Wissen (s. Kap. 2.2.4 zu linguistischen Variablen). So ist eine der wichtigsten Funktionen der Fuzzy Logik, strukturiertes menschliches Wissen über Eigenschaften, Abläufe oder Zusammenhänge in rechnerische Modelle oder Algorithmen zu überführen, die den menschlichen Denkprozess und die Entscheidungsfindung nachahmen (Kecman 2001: XXVII). Die klassische Mathematik bietet hierfür und insbesondere zur Handhabung unscharfer Informationen kein Instrumentarium. Um mit diesen unscharfen Informationen rechnen zu können, werden sie in der Fuzzy Logik, gestützt durch Expertenwissen oder empirischen Erhebungen, durch unscharfe Mengen (engl.: *fuzzy sets*) repräsentiert. So stellt die Fuzzy Logik mathematisch gesehen eine Erweiterung der klassischen Mengenlehretheorie auf unscharfe Mengen dar.

2.2.1 Unscharfe Mengen und Zugehörigkeitsfunktionen

Eine unscharfe Menge zeichnet sich im Vergleich zu einer scharfen Menge dadurch aus, dass ihre Elemente der Menge zu einem unterschiedlichen Grad angehören können. Sie kann als finite Menge von Element-Zugehörigkeitsgrad-Wertepaaren angegeben werden oder geschrieben werden als:

$$A = \{ (x; \mu_A(x)) \mid x \in X, \mu_A \in R_+ \} \tag{2-3}$$

mit x : Element der Menge X
 $\mu_A(x)$: Zugehörigkeitsgrad des Elements x zur Menge A
 X : Grundmenge (engl. häufig: *universe of discourse; domain*)

Die Grundmenge X definiert die möglichen Werte, die eine Variable x annehmen kann. Sie kann in der Nominal-, Ordinal-, Intervall- oder Ratioskala vorliegen.

In den meisten Fuzzy Logik Anwendungen gilt zusätzlich $0 \leq \mu_A \leq 1$, so dass $\mu_A(x)$ eine Funktion von x ist, die alle x auf das Intervall $[0,1]$ abbildet. Diese Funktion wird Zugehörigkeitsfunktion (engl.: *membership function*) genannt. Sie kann obiger Bedingung genügend eine beliebige Gestalt annehmen.

Ein Beispiel für eine Zugehörigkeitsfunktion, die die Aussage „ x ist viel kleiner als 5“ widerspiegelt, ist in **Abbildung 2–8** gegeben. Die Gleichung der Funktion kann angegeben werden mit:

$$\mu(x) = \begin{cases} 1 & \text{falls } 0 \leq x \leq 1 \\ 1,25 - 0,25x & \text{falls } 1 < x < 5 \\ 0 & \text{falls } x \geq 5 \end{cases} \quad (2-4)$$




Abbildung 2–8 Eine mögliche Zugehörigkeitsfunktion für den Ausdruck „ x ist viel kleiner als 5“.




Abbildung 2–9 Typische Formen von Zugehörigkeitsfunktionen (aus: Peisker 2006: 10).

2.2.2 Operationen auf unscharfen Mengen

Die am häufigsten verwendeten Operationen zwischen zwei unscharfen Mengen A und B , die auf der gleichen Grundmenge X definiert sind, sind das Komplement A^c (logisches NOT) (**Gleichung (2-5)**), die Vereinigung $A \cup B$ (logisches OR) (**Gleichung (2-6)**), der Durchschnitt $A \cap B$ (logisches AND) (**Gleichung (2-7)**) und das algebraische Produkt $A \cdot B$ (**Gleichung (2-8)**) (Kecman 2001: Kap. 6.1.2). Vereinigung, Durchschnitt und algebraisches Produkt werden in der Fuzzy Logik auch als Fuzzy MAX-, MIN- und PROD-Operator bezeichnet, wie aus den Formeln ersichtlich ist.

$$\forall x \in X : \mu_{A^c}(x) := 1 - \mu_A(x) \quad (2-5)$$

$$\forall x \in X : \mu_{A \cup B}(x) := \max[\mu_A(x), \mu_B(x)] \quad (2-6)$$

$$\forall x \in X : \mu_{A \cap B}(x) := \min[\mu_A(x), \mu_B(x)] \quad (2-7)$$

$$\forall x \in X : \mu_{A \cdot B}(x) := \mu_A(x) \cdot \mu_B(x) \quad (2-8)$$

Neben diesen wurde eine Vielzahl weiterer Operatoren entwickelt, um je nach Anwendung eine unterschiedliche Gewichtung der eingehenden Mengen bzw. eine unterschiedliche Empfindlichkeit der Operatoren beispielsweise gegenüber Schwankungen in der Amplitude oder der Verteilung der Eingabewerte der Elemente zu erreichen. Zahlreiche Beispiele sind in (Bothe 1995: 44 ff., Kecman 2001: 373) gegeben.




Abbildung 2-10 Graphische Veranschaulichung der Anwendung der Operatoren Komplement, Vereinigung, Durchschnitt und algebraisches Produkt auf zwei Mengen A und B (ergänzt nach: The MathWorks 2006: 2-14).

2.2.3 Kartesisches Produkt, Relationen und Kompositionen als mathematische Grundbausteine von Fuzzy Logik Modellen

Die folgenden Definitionen beziehen sich auf finite, diskrete Mengen, da nur diese für den Aufbau von rechnergestützten Fuzzy Modellen von Interesse sind (Kecman 2001: 375, 376, Demicco & Klir 2004: 31). Die Datenhaltung kann dann in Form von n-dimensionalen Arrays erfolgen, mit denen sich die folgenden Operationen im Computer durchführen lassen. Nicht-finite und nicht-diskrete Mengen müssen im Vorfeld durch eine geeignete Begrenzung der Grundmengen und eine geeignete, d.h. hinreichend genaue Wertediskretisierung in finite, diskrete Mengen überführt werden, um mit ihnen in rechnergestützten Fuzzy Modellen arbeiten zu können.

Zunächst wird das kartesische Produkt zweier scharfer Grundmengen X_1 und X_2 als Menge aller geordneter Paare der Elemente der beiden Grundmengen definiert (Kecman 2001: 374):

$$X_1 \times X_2 := \{(x_1, x_2) \mid x_1 \in X_1; x_2 \in X_2\} \quad (2-9)$$

Mit Hilfe des kartesischen Produkts wird ein neuer Definitionsbereich geschaffen, in dem nun auch Mengen miteinander verglichen werden können, die auf unterschiedlichen Grundmengen definiert sind (Bothe 1998: 20). Dasselbe gilt auch für das im Folgenden definierte kartesische Produkt zwischen unscharfen Mengen (Bothe 1995: 61). Seien A_1, \dots, A_n unscharfe Mengen auf den Grundmengen X_1, \dots, X_n . Dann ist das kartesische Produkt $A_1 \otimes \dots \otimes A_n$ eine unscharfe Menge im Produktraum $X = X_1 \times \dots \times X_n$ mit

$$\mu_{KP}(x_1, \dots, x_n) := \min[\mu_{A_i}(x_i) \mid i = 1, \dots, n, x_i \in X_i] \quad (2-10)$$

Die Verwendung des MIN-Operators bedeutet, dass die entstehenden Wertetupel mit dem kleinsten beteiligten Zugehörigkeitswert zum Produktraum gehören (Bothe 1995: 62).

Auf dem kartesischen Produkt zwischen unscharfen Mengen stützt sich nun die Definition des Begriffs der unscharfen Relation zwischen scharfen oder unscharfen Mengen, die in jedem Fall eine unscharfe Menge als Ergebnis hat. Allgemein gesagt, drückt eine Relation eine Beziehung zwischen zwei Mengen aus. Im Fall einer unscharfen Relation zwischen scharfen Mengen wird jedem Wertetupel des kartesischen Produkts durch eine Zugehörigkeitsfunktion ein Zugehörigkeitswert $\mu_{SR}(x_1, \dots, x_n)$ aus dem Intervall 0-1 zugeordnet. Die Höhe des Zugehörigkeitswerts drückt die Stärke der Beziehung zwischen den Elementen eines Wertetupels (x_1, \dots, x_n) aus (Demicco & Klir 2004: 31), d.h. er gibt an, wie stark ein Wertetupel einer zur Relation gehörenden unscharfen Bedingung genügt.

Im Fall einer unscharfen Relation zwischen unscharfen Mengen gilt zusätzlich, dass die Zugehörigkeitswerte der Wertetupel im neuen Produktraum $\mu_{UR}(x_1, \dots, x_n) \leq \mu_{KP}(x_1, \dots, x_n)$ sein müssen, was bedeutet, dass die Relation eine Teilmenge des kartesischen Produkts der unscharfen Mengen ist (Bothe 1995: 105). Da das Ergebnis einer unscharfen Relation in jedem Fall eine unscharfe Menge ist, können alle Mengenoperationen für unscharfe Mengen auch auf Relationen angewendet werden (Kecman 2001: 374).

Unscharfe Relationen sind wesentliche Bausteine von Fuzzy Modellen. Jede Fuzzy Regel (*if-then*-Regel im *modus ponens*) eines Modells bildet mathematisch eine eigene Relation, in der die Input und Outputvariablen der Regel in Beziehung gesetzt werden (Kecman 2001: 389). Die oben genannte Bedingung $\mu_{UR}(x_1, \dots, x_n) \leq \mu_{KP}(x_1, \dots, x_n)$ sichert hier nun die kausale Abhängigkeit des Konsequenzteils der Regel (*then*-Teil) vom Bedingungsteil (*if*-Teil). Sie besagt, dass der Wahrheitswert des Konsequenzteils nie größer sein kann als der Wahrheitswert des Bedingungsteils. Verbreitete Operatoren für die durchzuführende Implikation (s. Beispiel in Kap. 2.2.4) der Regel, die diese Bedingung einhalten, sind der MIN-Operator (Mamdani-Implikation) und der PROD-Operator (Larsen-Implikation) (Kecman 2001: 385).

Als letzten mathematischen Baustein einer Regel wird die Komposition benötigt. Eine Komposition ist als Verkettung von Relationen definiert. Eine besondere Bedeutung bei der Fuzzy Inferenz (s. Beispiel in Kap. 2.2.4) einer Regel kommt allerdings der Komposition einer unscharfen Menge und einer unscharfen Relation zu (Kecman 2001: 380). Sei mit

$$\text{IF } x = \text{gering, THEN } y = \text{hoch} \quad (2-11)$$

eine Regel gegeben, die der linguistische Ausdruck einer Relation zwischen den unscharfen Mengen $x \in X$ und $y \in Y$ ist. Eine solche Regel könnte zum Beispiel Teil eines Fuzzy Modells zur Regelung eines Heizkörpers sein, wenn die Inputvariable die Raumtemperatur und die Outputvariable der Regler des Heizkörpers ist. Die gefühlte Temperatur für den Term „gering“ und die notwendige Reglerstufe „hoch“ zur Erreichung einer angenehmen Raumtemperatur seien weiterhin empirisch durch die diskretisierten Zugehörigkeitsfunktionen in

Abbildung 2-11 quantifiziert. Dann kann für die Implikation mit dem MIN-Operator

$$\mu_R(x, y) = \min(\mu_G(x), \mu_H(y)) \quad (2-12)$$

durch die Berechnung des kartesischen Produkts aus

$$\mu_G(x)^T \mu_H(y) = [1 \ 0,5 \ 0 \ 0 \ 0]^T [0 \ 0 \ 0,33 \ 0,67 \ 1] \quad (2-13)$$

die folgende Relationsmatrix gebildet werden:

Tabelle 2-1 Relationsmatrix $x \Rightarrow y$ der Regel aus **Gleichung (2-11)**.

	1	2	3	4	5
0	0	0	0,33	0,67	1
10	0	0	0,33	0,5	0,5
20	0	0	0	0	0
30	0	0	0	0	0
40	0	0	0	0	0




Abbildung 2-11 Zugehörigkeitsfunktionen der Ausdrücke „Raumtemperatur ist gering“ $\mu_G(x)$ und „Heizungsregler ist hoch“ $\mu_H(y)$.

Für den Anwendungsfall, dass das Thermostat eine Raumtemperatur von 10 Grad misst, berechnet sich die Komposition aus dem Input Vektor für die Temperatur von 10 Grad und der Relationsmatrix wie folgt:

$$\mu_{G \circ R}(y) = \mu_{H'}(y) = \max_{x \in X} \min(\mu_G(x), \mu_R(x, y)) = \quad (2-14)$$

$$[0 \ 1 \ 0 \ 0 \ 0] \begin{bmatrix} 0 & 0 & 0,33 & 0,67 & 1 \\ 0 & 0 & 0,33 & 0,5 & 0,5 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = [0 \ 0 \ 0,33 \ 0,5 \ 0,5]$$

Hierbei wurde eine MAX-MIN-Komposition angewendet. Alternativen stellen die MAX-PROD- und MAX-AVE-Komposition dar (Kecman 2001: 380). Das Ergebnis der Fuzzy Komposition ist eine unscharfe Menge der Outputvariablen. Diese würde in einem Fuzzy Modell zusammen mit den Ergebnismengen anderer Regeln ausgewertet und am Ende in einen scharfen Wert überführt werden. Diese Vorgänge werden im folgenden Kapitel anhand eines weiteren Beispiels erläutert.

2.2.4 Aufbau eines Fuzzy Logik Modells an einem Beispiel

Fuzzy Logik Modelle können die unterschiedlichsten Funktionen erfüllen. Typische Anwendungsgebiete sind beispielsweise Steuerungsroutinen für Regelungssysteme, technische Geräte oder ganze industrielle Produktionsabläufe, Systeme zur Entscheidungsunterstützung, Zeitreihenanalysen und -vorhersagen oder Mustererkennung und Klassifizierer (Kecman 2001: 2 f., The MathWorks 2006: 1-5). Die Schritte, die beim Aufbau eines Fuzzy Logik Modells zu unternehmen sind, sollen im Folgenden an einem Beispiel demonstriert werden. Die Abfolge orientiert sich dabei an (Kecman 2001: 405). Im Beispiel wird ein Fuzzy Logik Modell aufgebaut, das die Höhe des Trinkgeldes bei der Lieferung einer Pizza berechnen soll.

Der erste Schritt umfasst die Definition der **Inputvariablen**, auf deren Basis die Beurteilung erfolgen soll. Der Empfänger der Pizza kann zum einen die Temperatur der Pizza fühlen und zum anderen die verstrichene Zeit seit der Bestellung schätzen. Tut er dies mit einem Thermometer und einer Uhr, so kann basierend auf den quantitativen Messungen ein mathematisch-physikalisches Modell zur Berechnung des Trinkgeldes entworfen werden. In der Regel wird er diese Parameter jedoch qualitativ schätzen. Dafür muss für jede Inputvariable die Grundmenge (der Wertebereich; das *universe of discourse*) festgelegt werden – z.B. eine Beurteilungsskala von 1 bis 10. Die geschätzten Bewertungspunkte beider Inputvariablen bei Lieferung der Pizza sind die Eingangswerte für das Modell. Die **Outputvariable** des Modells steht in diesem Fall bereits fest: Das Trinkgeld.

Ein Fuzzy Logik Modell bildet die menschliche Entscheidungsfindung nach (Kecman 2001: XXVII ff.). Daher bilden **linguistische Terme** wie *lauwarm*, *warm*, *heiß* für die Temperatur und *spät*, *durchschnittlich*, *schnell* für die Lieferung Bestandteile des Modells. Auch für die Outputvariable, die Höhe des Trinkgelds, werden mit wenig, durchschnittlich, reichlich solche linguistischen Terme gebildet. In diesem Zusammenhang werden die Variablen des Modells auch als **linguistische Variablen** bezeichnet, deren Werte keine Zahlen, sondern linguistische Terme sind. Mit Hilfe der linguistischen Terme werden **Fuzzy Regeln** (*if-then*-Regeln) aufgestellt, die die Abhängigkeit der Outputvariablen von den Inputvariablen festlegen. Für jeden Term der Outputvariablen wird eine eigene Regel erzeugt. Für unser Beispiel könnten folgende Regeln festgelegt werden:

IF **Pizza** = *heiß* OR **Lieferung** = *schnell*, THEN **Trinkgeld** = *reichlich* (2-15)

IF **Pizza** = *warm* OR **Lieferung** = *durchschnittlich*, THEN **Trinkgeld** = *durchschnittlich* (2-16)

IF **Pizza** = *lauwarm* OR **Lieferung** = *spät*, THEN **Trinkgeld** = *wenig* (2-17)

Gibt es im Bedingungsteil der Regel mehrere Inputvariablen, werden diese mit **Fuzzy Operatoren** (Kap. 2.2.2) verknüpft. Dabei besteht grundsätzlich die Wahl zwischen dem MIN- (logisches AND) und dem MAX-Operator (logisches OR) bzw. einer der zahlreichen Abwandlungen (z.B. Kecman 2001: 373) von diesen. Durch MIN-Operatoren erhält die Bedingung tendenziell einen geringeren Wahrheitswert, durch MAX-Operatoren einen höheren. Die Auswahl der Operatoren ist eine wichtige Möglichkeit zur Steuerung des Verhaltens eines Modells. Zieht man es beispielsweise vor, tendenziell weniger Trinkgeld zu geben, könnte man die erste und zweite Regel mit einem logischen AND abschwächen.

Mit der Aufstellung der Regeln ist der logische Teil des Aufbaus abgeschlossen. Es folgt der numerische Teil. Hier muss zunächst für jeden linguistischen Term der Variablen eine **Zugehö-**

rigkeitsfunktion auf der entsprechenden Grundmenge definiert werden. Auf diese Weise werden die Terme quantifiziert und ein „Rechnen mit Wörtern“ wird möglich (ein anderer Name für Fuzzy Logik ist „*computing with words*“, (Kecman 2001: XXVIII)). Die Zugehörigkeitsfunktionen bilden die Inputwerte der Variablen auf das Intervall 0-1 ab. Dieser Prozess nennt sich Fuzzifizierung. **Abbildung 2–12** zeigt, wie der Bedingungsteil der ersten Regel nach Fuzzifizierung der Terme „heiß“ und „schnell“ und nach Verknüpfung der Variablen mit dem MAX-Operator auf zwei beispielhafte Inputwerte reagiert.




Abbildung 2–12 Fuzzifizierung von Inputwerten durch Zugehörigkeitsfunktionen und Verknüpfung der unscharfen Mengen der Terme „heiß“ und „schnell“ mit dem MAX-Operator (aus: Peisker 2006: 13).

Die fehlenden Schritte zum Aufbau des Modells werden unter dem Begriff **Fuzzy Inferenz** (= Folgerung, Schließen) zusammengefasst und umfassen die *Implication* (= Auswirkung auf die Outputvariable), *Aggregation* (= Zusammenfassen der Regeln) und schließlich die *Defuzzifikation* (= das Erzeugen eines finalen, scharfen Outputwertes).

Die **Implikationsmethode** legt fest, wie sich der Wahrheitswert des Bedingungsteils einer Regel auf den Konsequenzteil auswirkt. Häufig verwendet werden hier der MIN- oder der PROD-Operator, die die Zugehörigkeitsfunktion (unscharfe Menge) der Outputvariablen unter Zuhilfenahme des Wahrheitswertes des Bedingungsteils auf eine bestimmte Höhe stützen oder skalieren (s. **Abbildung 2–13**) (Kecman 2001: 385). Mathematisch ausgedrückt, bildet jede Regel eine Fuzzy Relation (s. Kap. 2.2.3) (Kecman 2001: 389). Werden Inputwerte in die Regel gegeben und die Implikation durchgeführt, findet rechnerisch eine Komposition (s. Kap. 2.2.3) statt (Kecman 2001: 385 ff.). Da das Ergebnis einer Komposition eine unscharfe Menge ist, ist das Ergebnis der Implikation der Regeln ebenfalls eine unscharfe Menge für die Outputvariable.

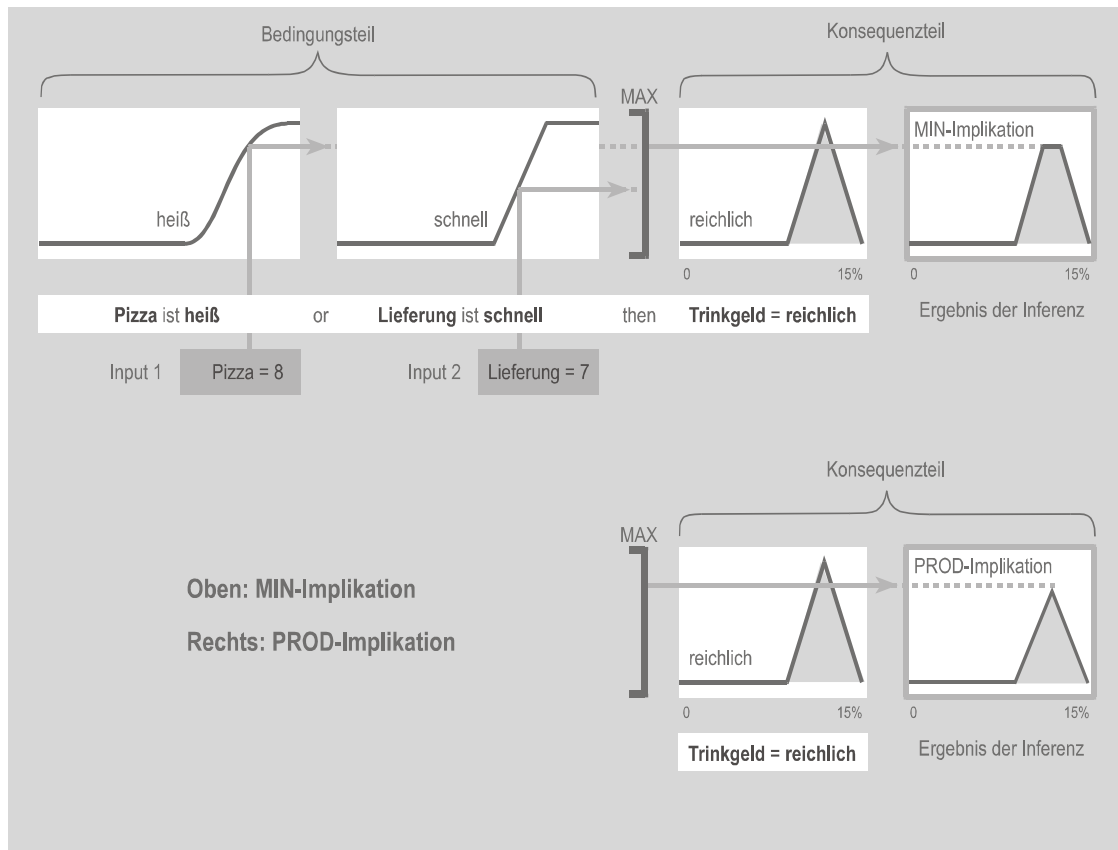


Abbildung 2–13 Implikation einer Fuzzy-Regel mit dem MIN- und dem PROD-Operator (nach: Kecman 2001: 388, Peisker 2006: 13).

Abbildung 2–14 stellt das gesamte Fuzzy Modell dar und zeigt das Verhalten des Modells bei den Bewertungspunkten 8 und 7 für die Temperatur und Lieferung der Pizza. Hier können die beiden letzten Schritte nachvollzogen werden: Die **Aggregation** der unscharfen Ergebnismengen der einzelnen Regeln mit dem Fuzzy MAX-Operator zu einer unscharfen Menge als unscharfes Ergebnis des Modells und schließlich die **Defuzzifizierung** dieser unscharfen Menge zu einem scharfen Ergebniswert des Modells – der Höhe des Trinkgelds. Für die Defuzzifizierung gibt es verschiedene Methoden. Häufig verwendet werden die Methoden *Centre-of-Area*, *Smallest-of-Maximum*, *Middle-of-Maximum* oder *Largest-of-Maximum* (The MathWorks 2006: 2-26), deren Auswirkungen in **Abbildung 2–15** dargestellt sind.

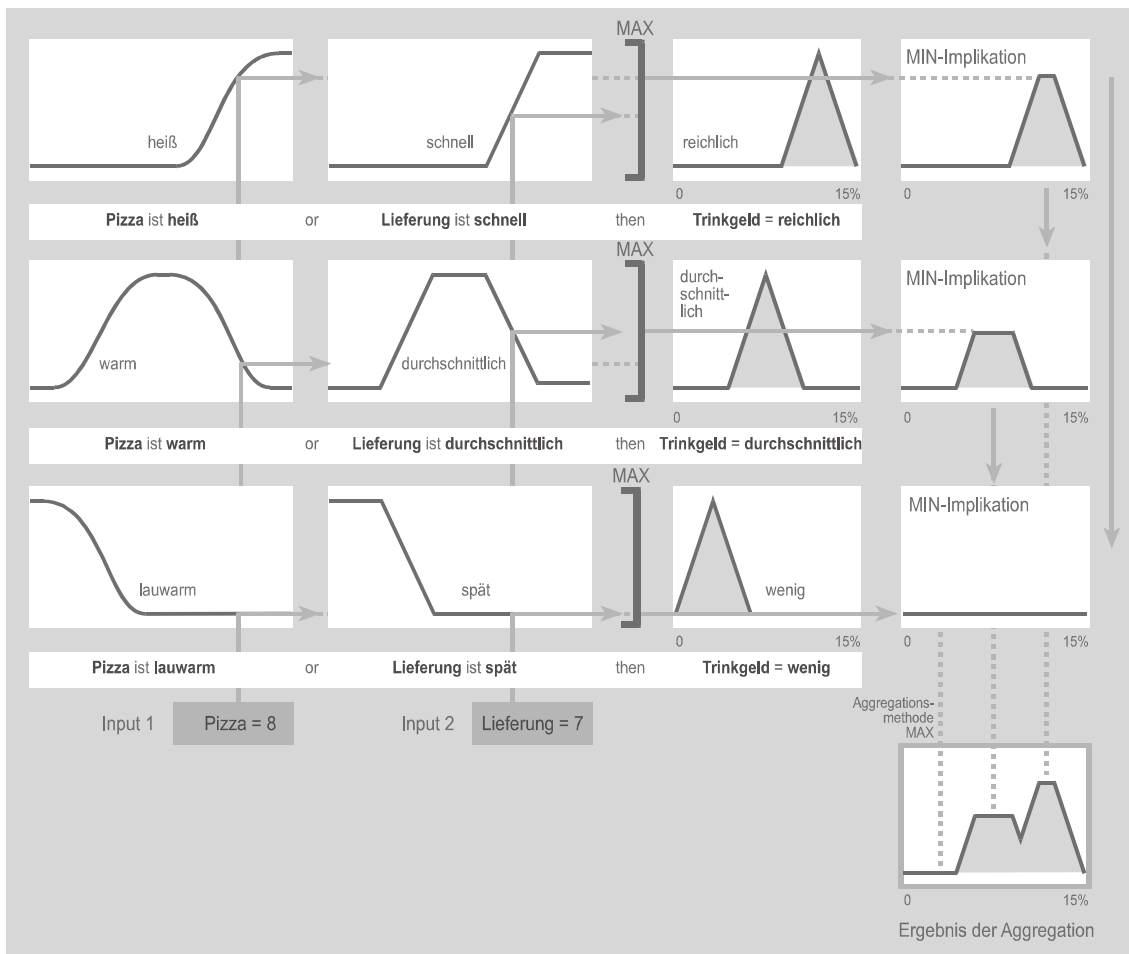


Abbildung 2-14 Schema und Funktionsweise des gesamten Fuzzy Logik Modells am Beispiel der Bewertungspunkte 8 und 7 für die Temperatur und Lieferung der Pizza (aus: Peisker 2006: 14).




Abbildung 2-15 Graphische Veranschaulichung verschiedener Defuzzifizierungsmethoden (aus: Peisker 2006: 15).

2.3 Stadtökologie und Stadtbiotopkartierungen

Die Stadtökologie ist eine recht junge, anwendungsorientierte Forschungsrichtung, die sich in den 70er Jahren herausgebildet hat. Den Entstehungsprozess und die Hintergründe schildern die folgenden Ausführungen, die im Wesentlichen Teile der Dissertation „Die Stadt: umweltbelastendes System oder wertvoller Lebensraum?“ von Monika Wächter (2003: Kap. 1.1, 3, 4, 7 u. 8) und des Buches „Stadtökologie“ von Herbert Sukopp und Rüdiger Wittig (1998: Kap. 1.1, 1.3 u. 1.4) zusammenfassen. Dabei steht die besondere Entwicklung der Stadtökologie in Deutschland im Mittelpunkt der Betrachtungen. Anschließend wird die aktuelle Praxis der Stadtbiotopkartierung in Deutschland dargestellt.

2.3.1 Entstehungsgeschichte der Stadtökologie

Die Beschäftigung mit der Natur *in* der Stadt war lange Zeit nicht naheliegend. Vor der Industrialisierung Deutschlands zur Mitte des 19. Jahrhunderts waren Stadt und Land zwei sich ausschließende Gegensätze. Die Stadt war der Ort der Bürger, des Handels und der Kultur, eng umgrenzt von Stadtmauern, die im Innern keinen Platz für die Natur ließen. Auf dem Land bestellten die Bauern ihre Felder - es war geprägt von Landwirtschaft und Natur. Mit der Industrialisierung wuchsen die Städte aus ihren Mauern heraus und in die umgebende Landschaft hinein. Die Wandlung Deutschlands von einem Agrar- zum Industriestaat ging einher mit tiefgreifenden Veränderungen des Landschaftsbildes und der Gesellschaft. Als Reaktion entstand Mitte des 19. Jahrhunderts die Naturschutzbewegung, eine in den Anfängen vor allem fortschritts- und großstadtfeindliche Bewegung, deren Anliegen zum einen der Erhalt des Landschaftsbildes (Naturschutz, Denkmalschutz), zum anderen die Wahrung kultureller Werte (Heimatschutz) waren (Wächter 2003: 2, 18 ff.). Heimat- und Naturschutz gingen zu dieser Zeit Hand in Hand und die zu schützende Natur wurde weniger durch ihre ökologische Funktion, als vielmehr durch ästhetische Aspekte und ihre Erholungsfunktion für die Stadtbewohner ausgewählt. Während der konservative, rein protektionistische Flügel der Naturschutzbewegung die Landschaft *außerhalb* der Stadt gleichsam vor der Stadt schützen wollte, formierte sich um 1900 ein reformistischer Flügel, der die bewusste Gestaltung des Fortschritts für möglich hielt. In diesen Kreisen, die von Landschafts- und Gartengestaltern dominiert waren, entstand die Vision einer ‚grünen Industriestadt‘. Nicht zuletzt durch ihren Einfluss auf die kommunale Grün- und Stadtplanung wurden beispielsweise begrünte Arbeiterviertel, Stadtparks, Kleingartenanlagen und städtische Naherholungsgebiete aktiv geplant – die Natur *innerhalb* der Stadt rückte zum ersten Mal in den Fokus der Menschen.

Diese Tendenz verstärkte sich in den 60er und 70er Jahren. Ein weiterer Industrialisierungsschub nach dem Ende des 2. Weltkrieges hatte erneut zu einem enormen Wachstum der Städte und zu diversen Umweltproblemen (Verunreinigung von Luft und Flüssen, Tankerunglücke, Diskussion um die Nutzung der Atomkraft) geführt und eine Umweltschutzbewegung entstehen lassen. Die Naturschutzbewegung, die mittlerweile realisiert hatte, dass die Devise ‚Zurück zur bäuerlichen Lebensweise‘ nicht mehr zeitgemäß war, gab ihre fortschrittsfeindliche Haltung auf und integrierte sich in die Umweltbewegung. Natur- und Umweltschutzbewegung strebten eine stärkere politische Positionierung an, um mit konkreten Forderungen Umweltprobleme einzudämmen. Wächter (2003: 34-35) schreibt hierzu: „Die Einsicht, dass ein wirksamer Landschaftsschutz ohne Einflussnahme auf die Stadtplanung wirkungslos bleiben müsse, führte dazu, dass das Thema ‚Stadt‘ seit Anfang der 1970er Jahre zum festen Bestandteil der Naturschutzprogrammatis gehörte.“ Zugleich erklärte man die Ökologie zur Leitwissenschaft der Bewegung, da

man meinte, „aus ökologischen Erkenntnissen direkt gesellschaftspolitische Konsequenzen zur Lösung der ‚ökologischen Krise‘ ableiten zu können.“

Die weltweit zunehmende Verstädterung und das besorgniserregende Wachstum von Megastädten vor allem in Entwicklungsländern – mit allen damit zusammenhängenden Problemen – veranlasste nun auch Politik und Wissenschaft zu handeln. Ziel war es, das System Stadt näher zu verstehen. Im Rahmen von internationalen Forschungsprogrammen (Wächter (2003: 78ff.) nennt vor allem das ‚Internationale Biologische Programm‘ (IBP) des ‚*International Council of Scientific Unions*‘ und das ‚*Man and the Biosphere*‘-Programm (MAB) der UNESCO) wurde ebenfalls der Wissenschaft Ökologie eine Schlüsselrolle zugeordnet, da diese durch ihren systemisch-ganzheitlichen Ansatz der Ökosystemanalyse in der Lage zu sein schien, das komplexe System Stadt zu erfassen und zu modellieren. Städte sollten analog zu natürlichen Ökosystemen als solche mit der Leitart Mensch betrachtet und untersucht werden. Man versprach sich Aussagen über funktionale Zusammenhänge, Stoff- und Energieströme und Belastungsgrenzen des Systems Stadt. Keiner Studie gelang es allerdings, die Stadt vollständig als Ökosystem zu erfassen, ohne Teilbereiche (häufig z.B. Wirtschaft oder Kultur³) auszublenden. Selten kam es zur Anwendung der erarbeiteten Modelle oder zur Ableitung konkreter Handlungsempfehlungen.

In Deutschland stand der ökosystemare Ansatz in der entstehenden Stadtökologie von Anfang an nicht hoch im Kurs. Der deutsche Stadtökologe Peter Werner bemängelte beispielsweise, dass der ökosystemare Ansatz nicht zu einem ökonomisch-ökologisch-sozialen System ausgeweitet wurde (Werner 1993, zitiert nach Wächter, 2003: 90). Herbert Sukopp begründete das Scheitern der Übertragung des Ansatzes der Ökosystemanalyse auf Städte damit, dass die zahlreichen Elemente, die das hochkomplexe System Stadt bilden, häufig in ihrer Funktion und ihren Handlungen nicht kausal voneinander abhängen (Sukopp 1987: 6, zitiert nach Wächter, 2003: 90). Statt der Betrachtung der Stadt als eines einzigen Lebensraumes mit der Hauptspezies Mensch, sah er sie vielmehr als ein Lebensraum-Mosaik mit kleinräumigen Standorten. Demzufolge entwickelte sich die Stadtökologie in Deutschland, angeführt durch die ‚Berliner Schule‘ um Professor Sukopp, in eine andere Richtung.

Ein nicht unwichtiger Impuls für diese Entwicklung kam zu dieser Zeit von Seiten des Gesetzgebers. Die im Bundesnaturschutzgesetz (BNatSchG) am 20. Dezember 1976 erstmalig festgeschriebene Verpflichtung zur Landschaftsplanung⁴ und zum Gebrauch der Eingriffsregelung⁵ brachten die Notwendigkeit mit sich, dass die Kommunen sich einen Überblick über die Ausstattung und Beschaffenheit der Natur in ihrem Planungsgebiet verschaffen mussten. Die Wissenschaft reagierte schnell und stellte als probates Mittel die Stadtbiotopkartierung bereit. Bei der Entwicklung dieser Methode konnte sie zum einen auf die Erfahrungen mit Biotopkartierungen in ländlichen Gebieten zurückgreifen, zum anderen aber auch auf zahlreiche stadtoökologische Untersuchungen, die sich in Deutschland im Gegensatz zu den Forschungen zur Ökosys-

³ Durch die Betrachtung des Menschen als biologische Spezies erfolgte häufig eine Reduktion des Menschen auf seine biologischen Eigenschaften.

⁴ Die Landschaftsplanung ist eine vorbereitende, nicht abgestimmte Fachplanung aus Sicht des Naturschutzes (geregelt in §§ 13-17 BNatSchG). Durch die Integration ihrer Forderungen in die übergreifende landesplanerische Gesamtplanung im Rahmen der Abwägung der unterschiedlichen Raumnutzungsansprüche, erlangen diese eine gesetzliche Verbindlichkeit (Kahl & Voßkuhle 1998: 197).

⁵ Als Eingriff sind solche (baulichen) Vorhaben definiert, deren Realisierung zu einer nachhaltigen negativen Veränderung der Bodengestalt oder -nutzung, des Landschaftsbildes oder der Leistungsfähigkeit des Naturhaushaltes führt (§ 18 BNatSchG).

temmodellierung vor allem auf die Natur in der Stadt konzentriert hatten (Wächter 2003: 91). Das folgende Kapitel skizziert die wesentlichen wissenschaftlichen Erkenntnisse, die zur Entwicklung der Stadtbiotopkartierung geführt haben.

2.3.2 Der Zusammenhang zwischen Mensch und Natur in der Stadt: Von stadtökologischen Erkenntnissen zur Entwicklung der Stadtbiotopkartierung

Die ersten stadtökologischen Untersuchungen verschiedener Städte Europas konnten eine erstaunliche Vielfalt an Standorten, Arten und Lebensgemeinschaften (Biozöosen) feststellen (z.B. für London (Fitter 1946, Gill & Bonnett 1973), Paris (Jovet 1954), Wien (Kühnelt 1955, Schweiger 1962) und Berlin (Sukopp 1973); alle Städte zitiert nach (Sukopp & Wittig 1998: 5)), die damals nicht für möglich gehalten wurde. Vor allem in ihrer Entstehungsphase waren stadtökologische Forschungen rein naturwissenschaftlich geprägte Arbeiten zur Verbreitung von Pflanzen und Tieren in der Stadt. Hinzu kamen in den 70er Jahren die im vorherigen Kapitel zitierten ökosystemaren Untersuchungen, um die Zusammenhänge und Wechselwirkungen des Systems Stadt zu modellieren. So definieren Sukopp & Wittig (1998: 2) die Stadtökologie im engeren Sinne als

„diejenige Teildisziplin der Ökologie, die sich mit den städtischen Biozöosen, Biotopen und Ökosystemen, ihren Organismen und Standortbedingungen sowie mit Struktur, Funktion und Geschichte urbaner Ökosysteme beschäftigt“.

Neuere Arbeiten beziehen immer mehr die menschliche Tätigkeit in die Untersuchungen mit ein. So können neben den Naturwissenschaften Biologie, Ökologie, Geologie, Pedologie, Hydrologie und Klimatologie auch die Geistes- und Kulturwissenschaften zur Lösung stadtökologischer Fragestellungen beitragen (Sukopp & Wittig 1998: 1ff.). Aus diesem Grund formulieren Sukopp & Wittig (1998: 2) eine erweiterte Definition der Stadtökologie:

„Stadtökologie im weiteren Sinne ist ein integriertes Arbeitsfeld mehrerer Wissenschaften aus unterschiedlichen Bereichen und von Planung, mit dem Ziel einer Verbesserung der Lebensbedingungen und einer dauerhaften umweltverträglichen Stadtentwicklung.“

Im zweiten Teil dieser Definition kommt zum Ausdruck, dass die Stadtökologie – und dies trifft vor allem aus genannten Gründen (Kap. 2.3.1) für den deutschen Weg zu – von Anfang an eine anwendungsorientierte Wissenschaft war. Sie verfolgt die von außen durch Politik und Öffentlichkeit an sie herangetragene Aufgabe, Lösungen für drängende ökologische Probleme zu liefern und konkrete Handlungsempfehlungen zu geben (Beratungsfunktion für Politik und Verwaltung) (Sukopp & Wittig 1998: 2). Dies immer vor dem anthropozentrischen Hintergrund der Verbesserung des menschlichen Wohlbefindens und der Lebensqualität in der Stadt. Somit schließt die erweiterte Definition auch die vorliegende Arbeit in vollem Umfang mit ein, die ja keine (stadt)ökologisch-theoretische, sondern eine anwendungsorientierte Arbeit aus dem Gebiet der Fernerkundung und Geoinformatik ist.

Mit dem Ziel vor Augen, eine Methode zur flächendeckenden Erfassung der Ausstattung und Beschaffenheit der Natur in der Stadt zu entwickeln, wie sie vom Gesetzgeber gefordert wurde (vgl. Kap. 2.3.1), stellten sich die Stadtökologen in Deutschland vor allem eine Frage: *Existiert ein räumlicher Zusammenhang zwischen der anthropogenen Nutzung einer Fläche bzw. dessen*

Einflusses auf die Fläche und der auftretenden Biozönose? Insbesondere durch Kartierungen und Untersuchungen der Flora erarbeitete man eine ökologische Raumlagerung der Stadt und verglich diese z.B. mit der anthropogenen Nutzungsintensität (Kunick 1974, Kunick 1982, Wittig *et al.* 1985, Kowarik 1988) (zitiert nach Wächter (2003: 93 ff.)) oder mit einer sozialgeographischen Gliederung der Stadt nach Gesellschaftsschichten (Hard 1985, zitiert nach Sukopp & Wittig, 1993: 37ff.). Besonderes Augenmerk legte man dabei auf die städtische Spontanvegetation, da diese keinem direkten (z.B. Pflanzung), sondern nur indirekten anthropogenen Einflüssen unterliegt. Es gelang nachzuweisen, dass sich die Lebensgemeinschaften in der Stadt nicht zufällig einstellen, sondern vor allem mit der Art und Intensität der Flächennutzung durch den Menschen als wichtigstem Standortfaktor korrelieren. Diesen Zusammenhang machte man sich bei der Entwicklung der Methode der Stadtbiotopkartierung zu Nutzen, indem man im Umkehrschluss davon ausging, dass von einer weniger aufwändigen Kartierung der anthropogenen Nutzung einer Fläche auf deren naturräumliche Ausstattung geschlossen werden kann. Bevor die entwickelte Methode im folgenden Kapitel ausführlich beschrieben wird, sollen hier noch die Definitionen des Biotop- und Biotoptypbegriffs gegeben werden.

Ein Biotop definiert sich nach (Ssymanck *et al.* 1993: 50) und (Pott 1996: 41) als

Lebensraum einer Lebensgemeinschaft [...] von bestimmter Mindestgröße und einheitlicher, gegen die Umgebung abgrenzbarer Beschaffenheit.

In der Ökologie besteht ein Biotop nur aus den abiotischen Standortfaktoren (z.B. Klima, Relief, Boden, Wasser) und bildet zusammen mit der Biozönose (Lebensgemeinschaft von Tieren und Pflanzen) ein Ökosystem. Knickrehm & Rommel (1995: 519) weisen darauf hin, dass die Abgrenzung eines Biotops in der Ökologie nach ökosystemfunktionalen Gesichtspunkten erfolgt, jedoch in der flächendeckenden Biotopkartierung (Definition s. Kap. 2.3.3), deren kleinste Kartiereinheiten die Biotope sind, aus pragmatischen Gründen eher räumlich-morphologische Gesichtspunkte verwendet werden (s. hierzu auch Schramm 1985: 113). Da die Vegetation häufig ein gut sichtbares Kriterium zur räumlichen Abgrenzung eines Biotops darstellt, kann diese auch als zum Biotop gehörig aufgefasst werden (Tischler 1984: 129, zitiert nach Knickrehm & Rommel, 1995, Drachenfels 2004: 6).

Aus den gemeinsamen Merkmalen der Menge aller gleichartigen oder ähnlichen Biotope lässt sich der jeweilige Biotoptyp abstrahieren. Er ist durch einheitliche Lebensbedingungen (Standortfaktoren) für die Biozönose gekennzeichnet (Ssymanck *et al.* 1993: 51). Die Typisierung erfolgt anhand von abiotischen und biotischen Merkmalen, sowie durch die anthropogene Nutzung (Ssymanck *et al.* 1993: 51, Glawion & Klink 1999: 214). Daher spricht man insbesondere in der Stadt zusammenfassend auch von Biotop- und Nutzungstypen⁶. Aus streng ökologischer Sichtweise sind viele urbane Nutzungstypen allerdings Biotop-Komplexe, d.h. sie sind aus mehreren Biotopen in wiederkehrender Typenkombination zusammengesetzt. Andere dagegen repräsentieren nur Teile von Biotoptypen Sukopp & Wittig (1998: 352).

2.3.3 Stadtbiotopkartierungen in der Praxis

Die Notwendigkeit der Durchführung von flächendeckenden Biotopkartierungen im gesamten Bundesgebiet – ausdrücklich auch im besiedelten Bereich – ergibt sich aus §1 des Bundesnatur-

⁶ In dieser Arbeit wird jedoch weiterhin der Begriff Biotoptyp verwendet.

schutzgesetzes⁷ (BNatSchG). Die Stadtbiotopkartierung ist das wichtigste Werkzeug für eine ökologisch orientierte Stadtplanung. Sie dient der ökologischen Bestandsaufnahme der Stadt (Sukopp & Wittig 1998: 405). Das Ergebnis – eine Karte der städtischen Biotop- und Nutzungstypen (s. Karten C-3 und C-4 im Anhang) – findet Berücksichtigung in vielen Fachplanungen und übergeordneten Gesamtplanungen (**Abbildung 2-16**) und vertritt dabei die Belange des Naturschutzes. So fließen ihre Inhalte beispielsweise in die Landschaftspläne ein (§16 BNatSchG), werden dadurch als Belange bei der Aufstellung der Bauleitpläne abgewogen (§1 Abs. 6, §1a BauGB) und werden bei der Eingriffsregelung (§18 BNatSchG) und Umweltverträglichkeitsprüfung (UVPG) berücksichtigt.




Abbildung 2-16 Berücksichtigung der Stadtbiotopkartierungen im deutschen Planungssystem (ins Deutsche übersetzt aus: Werner 1999).

Eine Stadtbiotopkartierung beinhaltet unter anderem eine detaillierte Kartierung der städtischen Vegetation, die es zu pflegen und zu entwickeln gilt. Der Sinn und Zweck einer Stadtbiotopkartierung entspringt daher nicht zuletzt dem vielfältigen Nutzen und den Funktionen der Stadtvegetation, die in (Schulte *et al.* 1993: 498) in drei Kategorien zusammengefasst werden:

I. Ressourcenschutz:

Die Vegetation hat einen positiven Einfluss auf das lokale Klima (Klimaregulation, Kaltluftzufuhr), den Wasserhaushalt (Reduzierung des Oberflächenabflusses, Transpiration, Interzeption) und die Luft (Sauerstoffproduktion, Schadstofffilterung) und trägt zum Schutz dieser natürlichen Ressourcen bei (s. auch Bonsignore 2003). Sie dient weiterhin als Rückzugsraum für Tiere und kann zur Biindikation von Umweltveränderungen und Schadstoffen genutzt werden.

⁷ Die hier zitierten Paragraphen beziehen sich auf die aktuelle Fassung vom 25.03.2002.

II. Naturerleben durch den Menschen, Lebensqualität des Menschen:

Diverse Studien zeigen, dass der Wohlfühlfaktor von Stadtbewohnern stark mit der in ihrem Umfeld erreichbaren Stadtnatur korreliert (s. auch Ulrich 1986, Chiesura 2004, Leeuwen *et al.* 2006). Der Mensch nutzt die Natur in der Stadt z.B. zur Erholung, zum Anbau von Gartenfrüchten und als Lärmschutz.

III. Orts- und Landschaftsbild:

Durch natürliche Elemente wird das Stadtbild gegliedert, belebt und verschönert. Zusätzlich zur vorher genannten aktiven Nutzung der Vegetation durch den Menschen, bewirkt das reine Vorhandensein bzw. die Möglichkeit der Betrachtung der Natur, dass die Psyche des Menschen positiv beeinflusst wird (s. auch Ulrich 1986, s. auch Schroeder 1989). Dadurch wird das Heimatgefühl der Menschen – die Verbundenheit mit dem Ort, an dem man lebt – gefördert.

Die Kartiereinheiten einer Stadtbiotopkartierung sind die Biotop. Jedes Biotop, d.h. jede durch bestimmte Merkmale abgrenzbare Fläche, kann in der Biotopkartierung einem bestimmten Biotoptyp zugeordnet werden. Die Kartierung wird anhand von Kartierschlüsseln durchgeführt, in denen die Biotoptypen ausführlich beschrieben sind und insbesondere Hinweise zu ihrer Erkennung im Gelände oder in Luftbildern gegeben werden. Zwei Methoden stehen sich dabei grundsätzlich gegenüber:

Die *selektive Biotopkartierung* erfasst nur schutzwürdige bzw. potenziell schutzwürdige Biotop. Dies setzt voraus, dass vor der Kartierung ein Bewertungsrahmen festgelegt wird, d.h. dass bestimmt wird, welche Biotoptypen schützenswert sind (Sukopp & Wittig 1998: 361). Nur die Biotop dieser Typen werden dann kartiert. Die Kartierung erfolgt im Gelände und umfasst eine Vielzahl strukturökologischer Eigenschaften und Parameter (z.B. artenbezogene Kartierung von Flora, Vegetation und Fauna, naturschutzrelevanter Kleinstrukturen, Durchgrünung, Versiegelungsgrad, Ausstattungspotenzial für das Naturerleben sowie prägender Elemente des Landschaftsbildes).

Bei der *flächendeckend-repräsentativen Biotopkartierung* wird das gesamte Stadtgebiet kartiert. Für jede Teilfläche, d.h. jedes Biotop, wird anhand der vorliegenden Biotopstruktur der Biotoptyp bestimmt. Eine Auswahl repräsentativer Biotop eines jeden Typs wird dann mit der Detailliertheit einer selektiven Biotopkartierung kartiert, um die Spannweite der ökologisch relevanten Parameter zu ermitteln. Diese werden dann auf alle übrigen Biotop des jeweiligen Typs übertragen (Sukopp & Wittig 1998: 361). Diese Übertragung funktioniert, da die urbanen Biotoptypen eng mit einer bestimmten anthropogenen Nutzung zusammenhängen und die Nutzung wiederum zu einer bestimmten ökologischen Ausstattung eines Biotops führt (s. Kap. 2.3.2). Das Attribut ‚flächendeckend‘ impliziert, dass *jede* Fläche, ob ökologisch wertvoll oder nicht, als Biotop betrachtet wird. Der erste Schritt – die Bestimmung des Biotoptyps – erfolgt weitestgehend durch visuelle (evtl. stereoskopische) Auswertung von CIR-Luftbildern. Die Repräsentativkartierung erfolgt entsprechend der selektiven Kartierung im Gelände.

Zur Terminologie des Begriffs Stadtbiotopkartierung bleibt zu sagen, dass eine *Biotopkartierung* eine detaillierte Aufnahme der Biotop bezeichnet, wogegen der Begriff *Biotoptypenkartierung* eine zumeist flächendeckende Überblickskartierung anspricht, bei der ausschließlich der Biotoptyp bestimmt wird. In der Stadtökologie wird sowohl bei der selektiven, als auch bei der flächendeckend-repräsentativen Kartierung von einer (Stadt-)Biotopkartierung gesprochen, da ja

auch im letzteren Fall zusätzliche ökologische Parameter für die repräsentativen Biotope aufgenommen und auf die übrigen Biotope übertragen werden.

Dass die Stadtbiotopkartierung in Deutschland seit ihrer Entstehung großen Zuspruch erfahren hat, zeigt ihre mittlerweile starke Verbreitung (**Abbildung 2–17**). Jedoch herrscht eine große Vielfalt an unterschiedlichen Kartierschlüsseln, die eine Vergleichbarkeit der Kartierungen erschwert. Auf Initiative einer Bund-Länder-Arbeitsgemeinschaft ist daher 1985 die Arbeitsgruppe ‚Methodik der Biotopkartierung im besiedelten Bereich‘⁸ (AG Methodik) gegründet worden, mit dem Auftrag, Empfehlungen für eine einheitliche, stadtoökologisch fundierte Kartiermethodik zu geben. Diese Empfehlungen wurden in Form eines vereinheitlichten Kartierschlüssels 1986 veröffentlicht und 1993 in einer überarbeiteten Version durch ein ökologisches Bewertungssystem ergänzt (Schulte *et al.* 1986, Schulte *et al.* 1993).

Die AG Methodik empfiehlt eine kombinierte Vorgehensweise aus flächendeckend-repräsentativer und selektiver Biotopkartierung. Eine flächendeckend-repräsentative Kartierung sollte in jedem Fall als Überblick erfolgen. Dafür wird zunächst der Typ aller Biotope bestimmt. Dieser Überblick ermöglicht es dann, repräsentative Biotope für jeden Biotoptyp auszuwählen und die schützenswerten Biotope zu identifizieren, welche dann gemeinsam detailliert kartiert werden (Schulte *et al.* 1993). Die flächendeckende Untersuchung der Biotope sei einer reinen Selektivkartierung vorzuziehen, da diese auf dem konservierenden Schutz wertvoller Einzelflächen verharre (Sukopp *et al.* 1979: 67, Wächter 2003: 105 f.). Im Gegensatz dazu stellt eine flächendeckend-repräsentative Stadtbiotopkartierung die Basis für gesamtstadtplanerische Aufgaben dar, wie die Abstimmung von Schutz und Nutzung aller Biotope durch die Empfehlung konkreter Entwicklungsziele und -maßnahmen für jede Einzelfläche (Stichwort ‚dynamischer, entwickelnder Naturschutz‘ statt ‚statischem, konservierendem Naturschutz‘). In diesem Sinne ist die flächendeckend-repräsentative Stadtbiotopkartierung ein aus der Sicht des Naturschutzes und der Landschaftspflege erarbeitetes, nicht abgestimmtes Fachgutachten (Schulte *et al.* 1993: 499).

Trotz der Empfehlungen der AG Methodik haben sich bis zum Jahr 2002 ca. 75 % der bis dahin 222 Städte Deutschlands mit einer Biotopkartierung für eine rein selektive Kartierung entschieden (Wächter 2003: 110). Die vorliegende Arbeit zielt darauf ab, die Anwendung in der Fläche, also die Durchführung einer flächendeckend-repräsentativen Stadtbiotopkartierung, weiter zu fördern, indem Teilprozesse objektiviert und automatisiert werden.

⁸ Genau genommen eine Unterarbeitsgruppe der Arbeitsgruppe ‚Biotopkartierung im besiedelten Bereich‘, die durch Vertreter des BfN, der Landesanstalten und -ämter für Naturschutz und Landschaftspflege sowie durch Vertretern aus der Wissenschaft gebildet wurde.



Abbildung 2–17 Zeitlich-räumliche Verbreitung der Biotopkartierungen in Deutschland. Grün: Stand 1984, blau: Stand 1993, rot: Stand 2000. Gezeigt werden alle Städte, die bis zum Stichjahr eine selektive oder flächendeckend-repräsentative Biotopkartierung durchgeführt oder begonnen haben. Quellen: (Sukopp & Weiler 1988, Schulte *et al.* 1993, Schulte & Sukopp 2000).

3 Untersuchungsgebiete und Schaffung der Datenbasis

In diesem Kapitel werden die Untersuchungsgebiete, die Ausgangsdaten und deren Prozessierung vorgestellt. Neben den Abgrenzungen der Biotope (Kap. 3.2) werden von der Fernerkundungsseite ein digitales Oberflächenmodell (Kap. 3.3) und hyperspektrale Scannerdaten (Kap. 3.4) als Ausgangsdaten benötigt. Damit aus diesen Merkmale zur Beschreibung der Biotoptypen berechnet werden können, sind zunächst umfangreiche Prozessierungsschritte notwendig. Diese umfassen die Berechnung von DGMs und nDOMs aus den digitalen Oberflächenmodellen (Kap. 3.3.2), die atmosphärische und geometrische Korrektur der HyMap-Daten (Kap. 3.4.2), die Klassifizierung der HyMap-Daten nach urbanen Oberflächenarten (Kap. 3.4.3), die thematische Gruppierung der Oberflächenarten (Kap. 3.4.4) und die Segmentierung des Klassifizierungsergebnisses (Kap. 3.4.5).

In **Tabelle 3-1** sind die verwendeten Ausgangsdaten mit ihren wesentlichen Eigenschaften für beide Untersuchungsgebiete aufgeführt. Weiterhin werden dort Zusatzdaten gelistet, die nicht in die eigentliche Auswertung eingehen, aber z.B. für Genauigkeitsuntersuchungen herangezogen werden. Einen Überblick über die erzeugte Datenbasis zur Merkmalsberechnung und Bestimmung der Biotoptypen gibt abschließend das Kapitel 3.5.

Tabelle 3-1 Übersicht über die verwendeten Ausgangs- und Zusatzdaten.

Datensatz	Eigenschaften	Verwendung
Biotypenkartierung Dresden	<i>Stand:</i> 1999 <i>Format:</i> Vektordaten (Shape-Format)	Zu aktualisierende Kartierung
Biotypenkartierung Berlin	<i>Stand:</i> 06/2006 <i>Format:</i> Vektordaten (Shape-Format)	Zu aktualisierende Kartierung
HyMap Befliegungen: Dresden, 01.08.2000, 11:47 Uhr (UTC) Dresden, 07.07.2004, 09:39 Uhr (UTC) Berlin, 20.06.2005, 09:35 Uhr (UTC)	<i>Sensortyp:</i> Opto-mechanischer Scanner <i>Spektral:</i> 126 Kanäle VIS-NIR-SWIR, FWHM 15-20 nm <i>Radiom.:</i> 16 bit <i>FOV:</i> 61,3°, 512 Pixel pro Bildzeile <i>DD2000 DD2004 BE2005</i> <i>Flughöhe:</i> 1660 m 2050 m 1960 m <i>Flugrichtung:</i> S → N S → N W → O <i>Räuml. Aufl.:</i> 3,5 m 4 m 3,5 m <i>Level der Ausgangsdaten:</i> Dresden kalibriert; Berlin atm. und geom. korr. von HU Berlin.	Ableitung von urbanen Oberflächenarten, die die Basis für die Merkmalsberechnung bilden.
DGM Dresden	<i>Räuml. Aufl.:</i> 25 m <i>Aufl. vertikal:</i> 5 dm	Atmosphärische und geometrische Korrektur der HyMap-Daten (die höher aufgelösten DOMs lagen zu diesem Zeitpunkt noch nicht vor).
Laser-DOM Dresden	<i>Technik:</i> Laserscanning Messung <i>Zeitpunkt:</i> 12/2002 <i>Räuml. Aufl.:</i> 2 m <i>Aufl. vertikal:</i> 1 dm	Berechnung von Merkmalen
DOM Dresden aus Luftbildern	<i>Technik:</i> Aerotriangulierung <i>Zeitpunkt:</i> 18.05.1999 <i>Räuml. Aufl.:</i> 3,5 m <i>Aufl. vertikal:</i> 1 dm	Berechnung von Merkmalen
DOM Berlin aus HRSC-AX	<i>Technik:</i> <i>Multi-Image Matching</i> <i>Zeitpunkt:</i> 18.08.2005 <i>Räuml. Aufl.:</i> 0,2 m <i>Aufl. vertikal:</i> 1 dm	Berechnung von Merkmalen
Luftbilder Dresden 1999	<i>Art:</i> Nicht entzerrte CIR-Luftbilder; gescannt. <i>Zeitpunkt:</i> 18.05.1999 <i>Räuml. Aufl.:</i> durchschnittlich ca. 40 cm <i>Maßstab:</i> 1:5000	DOM-Erzeugung
Luftbilder Dresden 2004/2005	<i>Art:</i> RGB Orthofotos <i>Zeitpunkt:</i> 04/2004 und 03/2005 <i>Räuml. Aufl.:</i> 20 cm <i>Maßstab:</i> 1:1000	Visueller Abgleich

Alle Daten eines Untersuchungsgebietes besitzen die gleiche Georeferenzierung. Berlin: UTM, Zone 33 Nord, Spheroid: WGS84, Datum: WGS84. Dresden: Gauß-Krüger, Spheroid: Bessel, Datum: Potsdam Rauenberg.

3.1 Untersuchungsgebiete

Dresden ist die Hauptstadt des Freistaates Sachsen und liegt im Osten Deutschlands. Auf einer Fläche von 330 km² leben ca. 500.000 Einwohner. Naturräumlich wird die Stadt durch den Elbtalkessel – einem Weltkulturerbe der UNESCO – geprägt. Dieser wird durch Ausläufer und Flanken des Osterzgebirges, des Lausitzer Berglandes und des Elbsandsteingebirges gebildet und durchzieht die Stadt von Südosten nach Nordwesten. Aufgrund zahlreicher Eingemeindungen vor und in den 90er Jahren dominiert in den Randbereichen Dresdens eine weitläufige, ländliche Stadtstruktur. Alte Dorfkerne sind häufig noch erkennbar. Die starke Bombardierung gegen Ende des 2. Weltkrieges hat dazu geführt, dass im Innenbereich nur wenige monumentale Gebäude und alte Stadtkerne erhalten geblieben sind oder restauriert werden konnten. Viele Stadtteile sind in der Zeit der Deutschen Demokratischen Republik im Stil der typischen Plattenbauten wiedererrichtet worden. Während Hochhäuser kaum anzutreffen sind, prägen weiterhin die Blockbebauung und Einzelhausbebauung – speziell die für Dresden typischen an der Neige des 19. Jahrhunderts errichteten Würfelhäuser – das Stadtbild (Baumgärtel).

Berlin, Stadtstaat und zugleich Hauptstadt der Bundesrepublik Deutschland, ist mit einer Fläche von 892 km² und 3,4 Millionen Einwohnern die drittbevölkerungsreichste Stadt in der Europäischen Union. Sie liegt in einer glazial geprägten (Weichseleiszeit), seenreichen, mäßig hügeligen bis flachen Landschaft. Die wichtigsten Flüsse sind Spree und Havel. Die Stadtentwicklung Berlins wurde wie keine andere von der Industrialisierung geprägt. In der Zeit von 1830 bis zum Beginn des 20. Jahrhunderts stieg die Bevölkerungszahl von einer Viertel- auf 2 Millionen. Um den historischen Stadtkern herum entstand der sogenannte Wilhelminische Mietskasernengürtel, der gekennzeichnet durch geschlossene Wohnhausbebauung mit 5-6 Vollgeschossen sowie Seitenflügeln und Hinterhäusern (Biotoptyp Blockbebauung oder Blockrandbebauung) den Arbeitern Quartier bot. Innerhalb dieses auch heute noch vorrangig dem Wohnen gewidmeten Gürtels befindet sich heute die City, die bedingt durch die historische Teilung Berlins eigentlich eine Doppel-City ist (der Bereich zwischen Brandenburger Tor und Alexanderplatz ehemals für Ost-Berlin, der Bereich Kurfürstendamm/Zoologischer Garten ehemals für West-Berlin). Sie befindet sich nach den Zerstörungen des 2. Weltkrieges, den erforderlichen Rekonstruktionen, der Teilung und Wiedervereinigung Berlins sowie dem Regierungsumzug auch heute noch im Wandel (relevante Stichworte sind das räumliche Strukturkonzept von 1991 oder die sog. Hauptstadtprojekte). Neben historischen Gebäuden prägen moderne Gebäude, darunter zahlreiche Hochhäuser das Stadtbild. Typische Stadtstrukturen des Stadtrandbereiches sind dagegen die in den 1970er und 80er Jahren entstandenen Großsiedlungen wie das märkische Viertel, die Gropiusstadt oder Marzahn. Diese als Satelliten- oder Trabantenstädte entstandenen Wohnsiedlungen bestehen größtenteils aus Hochhäusern und sind teilweise erst im Nachhinein zur Verbesserung der Wohnsituation mit Grünanlagen aufgelockert worden (Schwenk 2002).

In beiden Städten wurde je ein Untersuchungsgebiet festgelegt (**Abbildung 3-1**). Unter Berücksichtigung der verfügbaren Daten wurden diese so gewählt, dass die untersuchten Biotop- und Nutzungstypen in ihnen häufig vertreten sind. In Dresden bildet das Untersuchungsgebiet einen in Nord-Süd-Richtung verlaufenden Streifen mit ca. 5 km Länge und 2 km Breite. Das in Berlin gewählte Untersuchungsgebiet entspricht einem kompletten HyMap-Flugstreifen mit ca. 25 km Länge und 2 km Breite. Der Streifen verläuft in West-Ost-Richtung durch die Bezirke Steglitz, Tempelhof, Neukölln, Treptow und Köpenick.



Abbildung 3–1 Lage der Untersuchungsgebiete (HyMap-Flugstreifen) in den Städten Dresden und Berlin.

3.2 Stadtbiotopkartierungen

In diesem Kapitel werden die Kartierschlüssel für Stadtbiotopkartierungen beschrieben und die in dieser Arbeit untersuchten Biotoptypen vorgestellt. Weiterhin werden Datenquellen für die Biotopgrenzen von Stadtbiotopen angeführt, welche notwendige Eingangsdaten der in dieser Arbeit vorgestellten Methode sind.

3.2.1 Entstehung und Vergleich der Kartierschlüssel

Die Entstehung der Kartierschlüssel für Stadtbiotopkartierungen ist historisch bedingt von Stadt zu Stadt unterschiedlich. Vielerorts lehnte man sich jedoch an einen von der Bundesländer-Arbeitsgruppe ‚Methodik der Biotopkartierung im besiedelten Bereich‘ (AG Methodik) entwickelten Schlüssel an (Schulte *et al.* 1986, bzw. Schulte *et al.* 1993 in überarbeiteter Fassung), der sich als Standard herausgebildet hat. Dieser Einfluss ist auch im Kartierschlüssel Dresdens (Umweltamt Dresden 2003) erkennbar (vgl. Gegenüberstellung der Schlüssel in **Tabelle 3-4**).

Für Berlin ergibt sich aufgrund der Eigenschaft als Stadtstaat eine besondere Situation, denn auch für Kartierungen auf Bundeslandebene sind Anstrengungen für eine Vereinheitlichung der Kartierschlüssel unternommen worden (Bundesamt für Naturschutz 2002:4-7). Zudem war man aufgrund des engen Verflechtungsraums Berlin-Brandenburg und mit Blick auf eine gemeinsame Landesplanung bestrebt, den Kartierschlüssel in Abstimmung mit dem Land Brandenburg zu entwickeln. So ist der bereits existente Kartierschlüssel von Brandenburg⁹ für den Berliner Schlüssel (Senatsverwaltung für Stadtentwicklung - Referat Landschaftsplanung und Naturschutz I E & Landesbeauftragter für Naturschutz und Landschaftspflege 2005) weiterentwickelt und ergänzt worden. Die vorgenommenen Ergänzungen sind dann wiederum in die nächste Aktualisierung des Brandenburger Schlüssels eingeflossen, so dass beide Schlüssel weitgehend mit-

⁹ Dieser basiert wiederum auf (Westhus *et al.* 1990) und wurde von Zimmermann (1992, 1994) bzw. Zimmermann *et al.* (2004) weiterentwickelt.

einander konform sind. Die Gliederung der Schlüssel orientiert sich in der ersten Ebene an der Gliederung des BfN-Schlüssels (**Tabelle 3-3**).

Tabelle 3-2 zeigt exemplarisch die Untergliederung der Biotoptypen der Kategorie Wohnbebauung in einer Gegenüberstellung der unterschiedlichen Schlüssel. Es ist ersichtlich, dass sich die Schlüssel, trotz ihrer unterschiedlichen Entstehungsgeschichte und trotz der unterschiedlichen Gliederung der ersten Ebene, auf der untersten Gliederungsebene stark ähneln. Die größte Abweichung zeigt der BfN-Schlüssel, der die ersten vier Typen nach abweichenden Gesichtspunkten unterteilt (offene/geschlossene Bebauung bzw. hohe/niedrige Bebauung). In Stadtbiotopkartierungsschlüsseln werden diese Gesichtspunkte typischerweise als zusätzliche Attribute geführt, während die Untergliederung der Biotoptypen nach der Art der Bebauung, nämlich in Blockbebauung, Blockrandbebauung, Zeilenbebauung sowie Einzel- und Reihenhausbebauung erfolgt. Ein Vergleich weiterer Schlüssel der Städte Bremen, Frankfurt am Main und Potsdam (willkürlich ausgewählt) zeigte, dass diese vier Typen und zusätzlich die Großform- und Hochhausbebauung in jedem der Schlüssel präsent sind – entweder als eigenständiger Biototyp oder – wie z.B. im Falle Dresdens – teilweise zu größeren Typen zusammengefasst. Daher wurden sie für die Untersuchungen dieser Arbeit ausgewählt, um exemplarisch das Automatisierungspotenzial von Stadtbiotopkartierungen durch Nutzung von Fernerkundungsdaten zu demonstrieren. Durch die weite Verbreitung dieser Typen in vermutlich allen in Deutschland verwendeten Kartierschlüsseln ist eine generelle Anwendbarkeit der entwickelten Methode gesichert.

Tabelle 3-2 Gegenüberstellung der Biotoptypen der Wohnbebauung (zweite Gliederungsebene) aus den jeweiligen Haupttypen für Siedlung/Wohnbebauung. Diese sind in **Tabelle 3-3** und **Tabelle 3-4** grau hinterlegt. Die Namen der Biotoptypen wurden aus Gründen der Übersichtlichkeit teilweise verkürzt.

BfN (2002)	Berlin	AG Methodik (1993)	Dresden
Abweichende Untergliederung in niedrige offene, niedrige geschlossene, hohe offene und hohe geschlossene Bauweise	Blockbebauung	Blockbebauung	Block-, Blockrand- und Zeilenbebauung Einzel- und Reihenhausbebauung
	Blockrandbebauung	Blockrandbebauung	
	Zeilenbebauung	Zeilenbebauung	
	Einzel- und Reihenhausbebauung	Einzel- und Reihenhausbebauung	
Hochhausbebauung	Großformbebauung, Hochhauskomplexe	Großformbebauung und Hochhäuser	Großform- und Hochhausbebauung
Baumreiche Villenbebauung	Villenbebauung	Alte Villen mit parkartigen Gärten	–
Einzelgebäude und Anwesen	–	–	Sonstige Bebauung (Schloss, Kloster, Ruine)
Flächen gemischter Nutzung mit ländlicher Prägung	Dörfliche Bebauung / Dorfkern	Verstädterte Dorfgebiete	Landwirtschaftliche Hof- und Gebäudeflächen
	Landwirtschaft und Tierhaltung	Ländlich Wohnformen (keine Landwirtschaft, aber Kleinviehhaltung) Dörfliche Siedlungsflächen (Bauernhöfe u.ä.)	
–	Kleinsiedlung	–	–
Wochenend- und Ferienhausbebauung	–	–	–

Tabelle 3-3 Gegenüberstellung des Berliner und des BfN-Kartierschlüssels. Gezeigt wird jeweils die erste Gliederungsebene der Schlüssel (Haupttypen). Entsprechungen oder Überschneidungen zwischen den Haupttypen sind durch die waagerechten Trennlinien angedeutet.

Tabelle 3-4 Gegenüberstellung des Dresdner Kartierschlüssels und des Schlüssels der AG Methodik.

BfN (2002)	Berlin	AG Methodik (1993)	Dresden
Küstenbereich	–	Kerngebiete	Wohnbebauung und gemischte Bauflächen
Binnengewässer	Fließgewässer	Wohnbauflächen	
	Standgewässer	Dorfgebiete	
Moore; Sümpfe	Moore und Sümpfe	Industrielle und gewerbliche Bauflächen / Ver- und Entsorgungsanlagen	Industrie-, Gewerbe- und Sonderflächen
Rohbodenstandorte; Zwergstrauchheiden; Extremstandorte	Anthropogene Rohbodenstandorte und Ruderalfluren	Küstenregionen, Naturrelikte und sonstige lokale Besonderheiten	–
	Zwergstrauchheiden		Vegetationsfreie und -arme Standorte (naturnah)
	Sonderbiotope		–
Bäume; Feldgehölze; Gebüsche	Gebüsche, Baureihen und Baumgruppen	Grünflächen	Grünflächen
Wälder	Wälder und Forsten	Gewässer	Gewässer
Stark veränderte, gestörte Standorte; Ver- und Entsorgungsflächen	Bebaute Gebiete, Verkehrsanlagen und Sonderflächen	Verkehrsanlagen / Verkehrsflächen	Verkehrsanlagen und -flächen
Siedlung; Verkehr; Freizeit und Erholung	Grün- und Freiflächen	Landwirtschaftlich genutzte Flächen	Grünland
	Grünland, Staudenfluren und Rasengesellschaften		Ackerland und sonstige landwirtsch. Nutzflächen
Flächen der Landwirtschaft; Staudenfluren	–	Forste, Wälder, Gebüsche und Hecken	Kleingehölze, Gebüsche
	Äcker	Abgrabungen und Aufschüttungsflächen	Wälder
–	–	Brachflächen	Abgrabungen und Aufschüttungen
–	–	–	Brachflächen, Ruderal- und Staudenfluren
–	–	–	Vegetation naturnaher Feucht- u. Nassstandorte
–	–	–	Trockenrasen, Heiden

3.2.2 Definition der untersuchten Biotoptypen

In den Kartierschlüsseln für Stadtbiotopkartierungen sind typischerweise bis zu 100 oder mehr verschiedene urbane Biotoptypen enthalten. Um das Potenzial einer automatischen Methode für deren Erkennung aufzuzeigen, musste eine Auswahl getroffen werden. Der Schwerpunkt wurde dabei aus mehreren Gründen auf die baulich geprägten Biotoptypen gelegt, also auf solche, die zu einem größeren Teil aus künstlichen Oberflächen bestehen. Diese Schwerpunktsetzung resultiert z.B. aus der Absicht, eine automatische Methode zu entwickeln, die sich mit der Feldkar-

tierung und der visuellen Bildauswertung ergänzt (s. Kap. 1.1). So erscheint es sinnvoll, mit der automatischen Methode diejenigen Biototypen zu kartieren, die flächenmäßig stark relevant sind und gleichzeitig nicht zu den ökologisch wertvollsten Flächen gehören. Wenn mit der automatischen Methode der Großteil des Stadtgebiets kartiert werden kann (in Berlin bilden die baulich geprägten Biototypen ca. 60 % des Stadtgebiets), eröffnet dies dem Feldkartierer die Möglichkeit, sich intensiver den ökologisch wertvollen Flächen zu widmen. Ein weiterer Grund war die Annahme, dass die baulich geprägten Biototypen mit automatischen Methoden aus dem Bereich der *Computer Vision* leichter zu erkennen sind, da die Größe, Form und Anordnung der künstlichen Geoobjekte, z.B. der Hausdächer, bestimmend für den Biototyp sind. Weiterhin müssen die Grenzen der baulich geprägten Biototypen nicht automatisch abgeleitet werden, da sie in der Regel bekannt sind. Sie sind durch die Grenzen der Baublöcke festgelegt und ändern sich dadurch selten – auch nicht bei Abriss und Neubebauung eines Baublocks.

Die folgenden Beschreibungen der untersuchten Biototypen sind im Wesentlichen den Kartierschlüsseln Berlins, Dresdens und der AG Methodik (Schulte *et al.* 1993) entnommen. **Abbildung 3-3** zeigt Beispielbiotop für die 10 untersuchten Typen im Luftbild. Es wurden 5 Typen der Wohnbebauung, sowie Straßen, Industrie- und Gewerbeflächen, Kleingärten, offene Sport- und Erholungsanlagen sowie reine Scher- und Zierrasen ausgewählt. Diese decken in Berlin 55 % des Stadtgebietes ab. In Dresden wurden die Industrie- und Gewerbeflächen, Straßen, Sportanlagen und Kleingärten nicht untersucht. Die untersuchten 6 Typen decken hier etwa 40 % des Untersuchungsgebiets ab.

- Die **Einzelhausbebauung** ist eine aufgelockerte Wohnbebauung mit freistehenden Einzel- und Doppelhäusern mit 1-3 Stockwerken. Angrenzend an die Gebäude befinden sich in der Regel privat genutzte Gärten und Grünflächen. Wohnstraßen werden mit zum Baublock gerechnet und bilden kein eigens auszuweisendes Biotop.
- Bei der **Blockrandbebauung** umlaufen die Wohngebäude den Baublock bandartig und bilden einen großen Innenhof. In diesem stehen keine weiteren Gebäude mit Ausnahme von niedrigen Garagen. Typische Nutzungen des Innenhofes sind weiterhin Parkplätze, Mietergärten und Grünflächen inklusive einzelner Bäume.
- Im Gegensatz zur Blockrandbebauung ist bei der **Blockbebauung** auch der Innenbereich des Biotops (Baublocks) mit Wohngebäuden bebaut, so dass sich mehrere kleinere Innenhöfe bilden. Bei beiden ist neben der Wohnfunktion der Gebäude auch eine eingestreute gewerbliche Nutzung erlaubt. Die Zahl der Stockwerke wird mit mehrgeschossig angegeben. Typisch sind 3-8 Stockwerke, wobei die Gesamthöhe der Gebäude unter der Mindesthöhe eines Hochhauses bleibt.
- Die **Zeilenbebauung** ist durch mehrgeschossige, längliche, in Zeilen angeordnete Wohngebäude gekennzeichnet. Häufig sind die Gebäude geradlinig und stehen in einem Baublock parallel oder rechtwinklig zueinander. In Berlin sind allerdings auch Variationen anzutreffen (s. **Abbildung 3-2**). Gemeinschaftlich genutzte (Abstands-)Grünflächen komplettieren den Block.
- Als Biototyp **Hochhausbebauung** gelten Baublöcke mit Wohngebäuden mit einer Mindesthöhe. Diese wird in den Landesbauordnungen festgelegt und ist z.B. in Berlin mit einer Höhe von 22 m angegeben, bezogen auf die Fußbodenoberkante des höchstgelegenen Geschosses. Auch hier ergänzen gemeinschaftlich genutzte (Abstands-)Grünflächen den Block, häufig mit einem hohen Scherrasenanteil.

- Kennzeichnend für **Industrie- und Gewerbeflächen** sind große Fabrikgebäude sowie Lagerhallen und -plätze. Der Anteil künstlicher Oberflächen und der Versiegelungsgrad sind in der Regel hoch. Gewerbeflächen können zu einem geringen Anteil mit Wohngebäuden durchsetzt sein.
- Zum Biotoptyp **Straßen** zählt neben der reinen Fahrbahn öffentlicher Straßen auch das Straßenbegleitgrün. Dessen Qualität sowie der Versiegelungsgrad des Fahrbahnbelags und die Verkehrsfrequenz bestimmen die ökologische Wertigkeit der Straßen.
- **Kleingärten** (Schrebergärten) sind durch Hecken, Ziersträucher, Blumenbeete, Rasenflächen sowie durch Obst- und Gemüseanbauflächen geprägt. Häufig befindet sich ein kleineres Gebäude auf dem Grundstück, das nicht dauerhaft als Wohngebäude genutzt wird, sondern z.B. als Wochenendhaus oder auch als Geräteschuppen.
- **Offene Sport- und Erholungsanlagen** sind Flächen bzw. Anlagen inklusive der Infrastruktur, die der sportlichen Betätigung dienen und einen hohen Anteil unversiegelter Flächen, insbesondere Rasenflächen aufweisen. Hierzu zählen Anlagen aller Sportarten, wie z.B. Fußballplätze, Freibäder oder Reitsportanlagen.
- **Reine Scher- und Zierrasen** bilden den letzten ausgewählten Biotoptyp dieser Arbeit. Es sind öffentliche, gepflegte Rasenflächen ohne oder mit wenigen einzelnen Bäumen.




Abbildung 3–2 Variationen der Zeilenbebauung in Berlin (Quelle: GoogleEarth; © AeroWest).



Abbildung 3-3 Beispielbiotoparten der untersuchten Biotoptypen dieser Arbeit im Luftbild (Quelle: GoogleEarth; © AeroWest): a. Einzelhausbebauung, b. Industrie- und Gewerbeflächen, c. Kleingärten, d. Straßen, e. Hochhausbebauung, f. reiner Scher- und Zierrasen, g. Blockrandbebauung, h. Zeilenbebauung, i. Blockbebauung, j. offene Sport- und Erholungsanlagen.

3.2.3 Räumliche und thematische Mischbiotoparten

Bei den Untersuchungen verschiedener Biotopkartierungen und in den Diskussionen mit zuständigen Planern und Kartierern hat es sich gezeigt, dass es Biotoparten gibt, die der Beschreibung der Biotoptypen in den Kartierschlüsseln stärker oder geringer entsprechen. In strittigen, uneindeutigen Fällen kann es vorkommen, dass verschiedene Experten einen unterschiedlichen Biotoptyp vergeben (Ergebnis einer eigenen, unveröffentlichten Expertenbefragung). Im Folgenden werden diejenigen Biotoparten, die der Beschreibung der Biotoptypen besonders gut entsprechen, als **Prototypen** bezeichnet. Sie spielen eine wichtige Rolle beim Aufbau der Fuzzy Logik Modelle (Kap. 5.4) und machen ca. 30-50 % aller Biotoparten aus. Neben den Prototypen und den „normalen“ Biotoparten konnten drei Gruppen von Mischbiotoparten identifiziert werden, bei denen es zu Bestimmungsschwierigkeiten kommen kann. Ihr Anteil wird auf ca. 5-15 % geschätzt:

- I. Räumlich zu teilende Flächen: Bei diesen Flächen handelt es sich eigentlich nicht um Biotop, sondern um Fehler in der Biotopkartierung, da die Flächen nicht vollständig zu einem Biotoptyp gehören, sondern räumlich weiter unterteilt werden müssen (**Abbildung 3–4 a**). Dies tritt auf, wenn ein ganzer Straßenblock als Biotop digitalisiert wurde, der aber aus zwei oder mehr aneinandergrenzenden und dadurch räumlich trennbaren Biotopen besteht. Eine solche Fläche sollte zerteilt werden, wenn die resultierenden Biotopflächen eine definierte Mindestgröße nicht unterschreiten (Flächenfalle).
- II. Räumlich nicht teilbare Mischbiotop: Hierbei handelt es sich wie bei Punkt I um räumlich gemischte Flächen, die aber nicht räumlich aufgeteilt werden können, weil die einzelnen Biotopflächen die vorgegebene Mindestflächengröße unterschreiten würden. In diesen Biotopen sind die zu verschiedenen Biotoptypen gehörenden Bebauungstypen häufig kleinräumig gemischt oder einzelne Gebäude eines zweiten Bebauungstyps zwischen denen eines ersten eingestreut. Ein häufiges Beispiel ist ein einzelnes Hochhaus in einem Block mit Zeilenbebauung (**Abbildung 3–4 b**). In den Biotopkartierungen ist solchen Biotopen jeweils der dominierende Biotoptyp zugewiesen worden.
- III. Thematische Mischbiotop: Bei thematischen Mischbiotopen zeigen unterschiedliche Eigenschaften der Biotopflächen verschiedene Biotoptypen an. Ein typisches Beispiel ist, dass die Bauform der Gebäude für den einen Typ und ihre Anordnung im Biotop für den anderen Typ spricht (**Abbildung 3–4 e + f**). Ein weiteres Beispiel tritt auf, wenn es fließende thematische Übergänge zwischen zwei Biotoptypen gibt, wie es bei der Blockrand- und Blockbebauung der Fall ist (**Abbildung 3–4 c + d**).




Abbildung 3–4 Die Biotopflächen a und b bestehen aus Zeilenbebauung mit jeweils einem Hochhaus. Je nach vorgegebener Mindestflächengröße zählen sie also zu den Typ I oder Typ II Mischbiotopen. Biotop c gehört dagegen klar zum Typ I. Die Biotopflächen d–g gehören zum Typ III, wobei d und f eine thematische Mischung aus Zeilen- und Blockrandbebauung sowie e und g eine Mischung aus Block- und Blockrandbebauung darstellen (Quelle: GoogleEarth; © AeroWest).

Die Mischbiotope der Typen II und III werden im Folgenden zur Abgrenzung von den Prototypen als **untypische Biotope** bezeichnet. Sie spielen neben den Prototypen eine wichtige Rolle beim Aufbau der Fuzzy Logik Modelle (Kap. 5.4), wo sie beide verwendet werden, um die Grenzen der Zugehörigkeitsfunktionen festzulegen. Während bei Mischbiotopen des ersten Typs klar ist, dass diese räumlich aufzuteilen sind, fällt es bei den Typen II und III häufig schwer, eine eindeutige Entscheidung zu fällen. In Kapitel 7.3.2 wird daher näher untersucht, wie sich der entwickelte Biotopklassifizierer bei Mischbiotopen dieser Typen verhält.

3.2.4 Die Biotopfläche als Bezugsfläche der Untersuchungen

Wie in Kapitel 1.2 beschrieben wurde, setzt die automatische Bestimmung des Biotoptyps voraus, dass die Grenzen der Biotope *a priori* bekannt sind. Sowohl in Berlin als auch in Dresden sind in der Vergangenheit flächendeckend-repräsentative Stadtbiotopkartierungen durchgeführt worden (s. Karten C-3 und C-4 im Anhang). Daher sind die Grenzen bzw. Flächen der Biotope aus den alten Kartierungen bekannt. Diese liegen in georeferenzierter Form als Vektor-GIS-Layer vor. Zur einfacheren Verarbeitung wurden die Biotopflächen der untersuchten Biotoptypen in die Rasterform überführt mit der geometrischen Auflösung der HyMap-Daten. Hierbei wurde für die Biotope eines jeden Typs ein eigener Rasterlayer angelegt, in dem die zu einem Biotop gehörenden Pixel die ID des Biotops aus dem Vektorlayer tragen. Dies ermöglicht zum einen die gemeinsame Analyse der Pixel eines Biotops mit den in dieser Arbeit entwickelten Programmen und zum anderen die spätere Rückführung der berechneten Werte als Attribute in den Vektorlayer.

Die Vektor-Raster-Konvertierung der Biotopflächen kann in der Regel automatisiert erfolgen und wurde bei der Berliner Kartierung auf diese Weise durchgeführt. Bei der Dresdner Kartierung wurden leider in uneinheitlicher Weise Teilflächen von Straßenblöcken der Wohnbebauung, z.B. Stichstraßen in Wohngebiete, Rasenflächen oder Stellflächen für PKWs, als separate Biotope ausgewiesen oder aber an anderer Stelle als ein Biotop pro Straßenblock zusammengefasst. Letztere Vorgehensweise hat sich in vielen anderen Städten einheitlich durchgesetzt (s. Biotopkartierung Berlin im Vergleich zu Dresden im Anhang C) und wird auch für die vom Autor entwickelte Methode vorausgesetzt. So werden Straßenblöcke nur dann in mehrere Biotope unterteilt, wenn sie Flächen enthalten, die per Definition nicht zum Hauptbiotoptyp des Blockes gehören. In diesem Fall bestehen die Straßenblöcke dann aus mehreren, räumlich eindeutig trennbaren Biotoptypen (s. auch Kap. 3.2.3, römisch I.) wie z.B. Zeilenbebauung und Hochhausbebauung. Die oben genannten Flächen dürfen jedoch gemäß der Definitionen in (Schulte *et al.* 1993) in Biotopen der Wohnbebauung enthalten sein. Die vermeintlich genauere separate Ausweisung von Teilflächen bietet gegenüber der in dieser Arbeit entwickelten Methode keinerlei Vorteile, da mit dieser neben der Bestimmung des Biotoptyps auch die Flächenanteile der verschiedenen urbanen Oberflächen, so also auch von Straßen, Rasenflächen und versiegelten PKW-Stellplätzen, berechnet und als Attribute der Biotope verwaltet werden können. Die genannte uneinheitliche Abgrenzung der Biotopflächen in der Dresdner Kartierung machte leider eine manuelle Überarbeitung der Biotopgrenzen nach oben beschriebener Systematik notwendig.

Existiert in einer Stadt keine Erstkartierung, so können die Biotopgrenzen *baulich geprägter* Biotoptypen alternativ aus einem Vektor-Straßenlayer (z.B. aus ATKIS) abgeleitet werden, da deren Grenzen in der Regel mit denen der Straßenblöcke korrespondieren. Die Straßenflächen, die als solche eigene Biotope bilden, grenzen die übrigen baulich geprägten Biotope in Form von Straßenblöcken ab. Die Erzeugung der entsprechenden Flächen kann durch Pufferung der Vektorstraßen erfolgen, wobei der Radius des Puffers in Abhängigkeit vom Straßentyp (Straßenbrei-

te) festgelegt werden kann. Werden die Straßenpuffer an jeder Kreuzung zerschnitten, so erhält man zusätzlich zu den Polygonen der Straßenblöcke einzelne Polygone mit Straßenabschnitten als Biotopflächen. So müssen für eine vollständige Kartierung nur die Grenzen der *nicht baulich geprägten* Biotoptypen manuell hinzugefügt werden.

3.3 Digitale Höhenmodelle

In der Geoinformatik und Fernerkundung dienen digitale Höhenmodelle (DHMs) zur Speicherung und Analyse der Höheninformationen von Oberflächen, wie z.B. der Erdoberfläche. Grundbausteine der DHMs sind Punkte, Linien oder Flächen, die jeweils mit genau einem Höhenwert (z-Koordinate) attribuiert sind. Man spricht daher auch von 2,5-dimensionalen Daten im Gegensatz zu 3-dimensionalen Daten, bei denen an einem Punkt, festgelegt durch x/y-Koordinaten, mehrere z-Koordinaten existieren können. Echte 3D-Daten sind in der Welt des *computer-aided design* (CAD) bekannt und finden aktuell im Rahmen der Erzeugung von 3D-Stadtmodellen immer mehr Eingang in die Welt der Geoinformatik. Für die vorliegende Arbeit besitzen sie allerdings im Vergleich zu 2,5D-Daten keinen Mehrwert und werden nicht berücksichtigt.

DHMs stellen kontinuierliche Repräsentationen von Oberflächen dar. Dies wird erreicht, indem die z-Koordinaten von Zwischenpunkten mit definierten Interpolationsvorschriften berechnet werden können. Typische Formen von DHMs sind unregelmäßige Einzelpunkte (z.B. aus Geländemessungen), regelmäßige Einzelpunkte (typischerweise durch Fernerkundungssensoren, z.B. LIDAR oder SAR aufgenommen), Höhenlinien und *triangulated irregular networks* (TIN). Zwischen allen Formen kann durch Interpolation bzw. Approximation gewechselt werden (Bartelme 1995: 126 ff.).

Die in dieser Arbeit verwendeten DHMs liegen im Rasterformat vor und werden im Folgenden genauer beschrieben. Sie stellen wichtige Eingangsdaten für die gesamte Prozesskette dar. So werden sie bei der atmosphärischen und geometrischen Korrektur der HyMap-Daten berücksichtigt (Kap. 3.4.2), wie auch bei der Berechnung von Merkmalen zur Charakterisierung von Biotoptypen (Kap. 4). Für den letzteren Punkt sind weniger die Höhen über dem Meeresspiegel – gespeichert in einem digitalen Oberflächenmodell (DOM) oder einem digitalen Geländemodell (DGM) – von Interesse, als vielmehr die Höhen der Objekte auf der Erdoberfläche, wie z.B. Gebäudehöhen oder die Wuchshöhe der Vegetation. Das Unterkapitel 3.3.2 schildert, wie diese Informationen aus einem digitalen Oberflächenmodell abgeleitet werden können.

3.3.1 Digitale Oberflächenmodelle (DOM)

Als digitale Oberflächenmodelle (DOM) werden diejenigen DHMs bezeichnet, die die Höhenwerte der Erdoberfläche inklusive der auf ihr stehenden Objekte (z.B. Häuser und Bäume) speichern. Im Laufe des Projektes konnten für das Untersuchungsgebiet in Berlin ein DOM und für Dresden zwei DOMs akquiriert werden. In der **Tabelle 3-1** zu Beginn des Kapitels 3 sind die wichtigsten Kennwerte der drei verwendeten DOMs vergleichend zusammengestellt. Im Folgenden werden die Verfahren vorgestellt, mit denen die DOMs erzeugt wurden, und vergleichend diskutiert.

Das Berliner DOM aus dem Jahre 2005 wurde vom DLR Adlershof in Berlin prozessiert und zur Verfügung gestellt. Die Erzeugung aus Aufnahmen der flugzeuggetragenen HRSC-AX Ka-

mera basiert auf einer *Multi-Image Matching* Technik (Scholten *et al.* 1999, Wewel & Scholten 2000). Mit einem prinzipiell ähnlichen Verfahren – der Aerotriangulierung – wurde aus 71 CIR-Luftbildern aus dem Jahr 1999 ein DOM für das Untersuchungsgebiet in Dresden erstellt. Hierfür wurde die Leica Photogrammetry Suite 9.0 von Erdas Imagine verwendet. Die verarbeiteten Luftbilder wurden vom Umweltamt Dresden zur Verfügung gestellt.

Neben dem beschriebenen DOM von 1999 stand für das Untersuchungsgebiet in Dresden ein weiteres DOM zur Verfügung, das ebenfalls vom Umweltamt Dresden bereitgestellt wurde. Es handelt sich hierbei um Aufnahmen einer Laserscanner-Befliegung der Firma TopScan GmbH im Jahre 2002. Bei der Aufnahme von DOMs mit flugzeuggetragenen Laserscannern (auch LIDAR-Sensoren genannt) werden die Höhenwerte des aufgenommenen Geländes aus der Laufzeit der ausgesendeten und wieder empfangenen elektromagnetischen Strahlung (Senkrechtmessung) berechnet.

Laserscannermessungen erzeugen in der Regel und insbesondere in urbanen Gebieten genauere Oberflächenmodelle als eine Stereoauswertung von optischen Fernerkundungsdaten. So wird der vertikale RMS Fehler des Datensatzes mit 1 dm angegeben (TopScan GmbH 2003). Dennoch ist das hier verwendete Laser-DOM für die Klassifizierung bewaldeter Gebiete nicht optimal. Anstelle der Höhenwerte der Baumkronen enthält es größtenteils die Höhenwerte der Geländeoberkante (GOK) (s. **Abbildung 3–5** a für einen Vergleich des Laser-DOMs und des stereoskopisch erzeugten DOMs)). Dies ist mit einer zum Aufzeichnungszeitpunkt (Dezember 2002) geringen Belaubung der Bäume und mit der Verwendung der sogenannten *last pulse* Information zur Generierung des DOMs zu erklären. Die *first pulse* Information lag leider nicht vor.

Bei DOMs, die aus einer Stereobildauswertung hervorgehen, entstehen verfahrensbedingte Ungenauigkeiten in der Regel an Bruchkanten mit großem Höhenunterschied, wie z.B. den Umrissen von Gebäuden. Es zeigen sich bei sehr hoch aufgelösten Daten häufig ein faseriger Rand in der 2D-Ansicht und allgemein ein geglätteter Übergang der Höhenwerte in orthogonaler Richtung zu den Bruchkanten (s. **Abbildung 3–5** b). Da das DOM bei diesem Verfahren aus homologen Punkten interpoliert wird, die in den Bildpaaren automatisch gefunden werden, können solche Kanten nicht scharf abgebildet werden. Die Abbildung wird jedoch besser, je größer die Punktdichte an der Kante ist. Ein weiteres Problem stellen schmale Straßenschluchten mit beidseitig hohen Gebäuden dar. Am Grund der Straße können nur dann homologe Punkte gefunden werden, wenn die Straße von der Kamera aus mindestens zwei verschiedenen Winkeln aufgenommen wurde, unter denen der Einblick bis auf den Grund der Straße möglich ist. Jedoch wird dies unwahrscheinlicher, je größer das Verhältnis der Gebäudehöhe zur Straßenbreite ist (**Abbildung 3–6**, links). Je nach Anzahl der gefundenen homologen Punkte am Straßengrund und je nach verwendetem Interpolationsverfahren sind solche schmalen Straßen dadurch im DOM entweder gar nicht sichtbar oder mit einer zu hohen Geländehöhe versehen (**Abbildung 3–6**, rechts).

Die Höhengenaugigkeit des aus Luftbildern erzeugten DOMs von Dresden wurde durch 52 Kontrollpunkte aus dem Laser-DOM kontrolliert, dessen Höhengenaugigkeit mit 1 dm sehr genau ist. Die Kontrollpunkte wurden so gewählt, dass sie nicht an den spezifischen Problemstellen beider DOMs liegen, da dort natürlich spezifisch höhere Fehler zu erwarten sind. Der vertikale RMS Fehler des DOMs aus Luftbildern beträgt 1,8 m und der LE90 3,0 m. Die Genauigkeit des ebenfalls stereoskopisch erzeugten Berliner DOMs konnte nur visuell überprüft werden, da keine Referenzinformation vorlag. Sie wird leicht höher eingeschätzt als die des Dresdner DOMs.


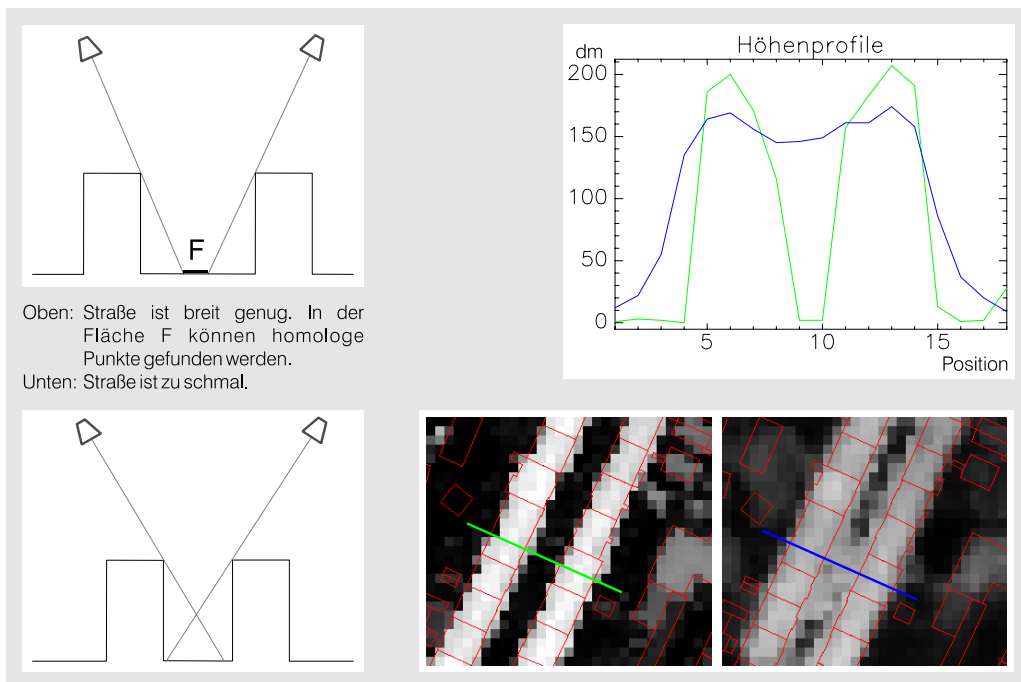


Abbildung 3-5 Spezifische Probleme unterschiedlicher DOMs. Oben: *last pulse* Laser-scannerdaten, unten: stereoskopisch erzeugtes DOM. a: Wald (mit Wegen und Lichtungen), b: Höhenprofil durch ein Gebäude (Gebäudegrenzen aus ALK).



Oben: Straße ist breit genug. In der Fläche F können homologe Punkte gefunden werden.
Unten: Straße ist zu schmal.

Abbildung 3-6 Enge Straßenschluchten in stereoskopisch erzeugten DOMs. Links: Problemskizze, rechts: Auswirkung im stereoskopisch erzeugten DOM (blau) im Vergleich zum Laser-DOM (grün).

3.3.2 Erzeugung digitaler Geländemodelle (DGM), normalisierter digitaler Oberflächenmodelle (nDOM) und Gebäudemasken

Im Gegensatz zu DOMs enthalten digitale Geländemodelle (DGMs) ausschließlich die Höhenwerte der Geländeoberkante (GOK). Die Höhenwerte eines DOMs und eines DGMs unterscheiden sich also theoretisch nur an Orten, an denen Objekte auftreten, die nicht zum Gelände gehören. Die Differenz aus beiden liefert die Höhen dieser Objekte (z.B. Gebäudehöhe) und wird in einem sogenannten normalisierten digitalen Oberflächenmodell (nDOM) gespeichert. Die eigentliche Schwierigkeit liegt allerdings in der Erzeugung der DGMs.

DGMs können von keinem Sensor direkt aufgezeichnet werden, da die Geländehöhe unter festen Objekten nicht gemessen werden kann. Sie können allerdings mit automatisierten Methoden aus DOMs abgeleitet werden. Hierfür existieren in der Literatur zahlreiche Ansätze. Zunächst sei hier diejenige Gruppe von Methoden erwähnt, die LIDAR-Daten untersucht und dabei die gesamte Informationsbreite, d.h. *first pulse*, *last pulse*, sowie Intensitätsdaten ausnutzt und in der Punktwolke statt in einem interpolierten Raster arbeitet (Kraus & Pfeifer 2001, Vosselman & Maas 2001, Pfeifer 2004). Diese hochentwickelten, robusten Methoden liefern sehr gute Ergebnisse für unterschiedlichste Geländesituationen. In der vorliegenden Arbeit konnten sie jedoch nicht verwendet werden, da ausschließlich ein interpoliertes Raster aus den *last pulse* Daten zur Verfügung stand.

Für die Ableitung eines Raster-DGMs aus einem Raster-DOM werden in der Regel filterbasierte Techniken verwendet. Aus der Fülle vorhandener Methoden wurden drei prinzipiell unterschiedliche zum Vergleich ausgewählt: Das morphologische *Opening*, das regionenbasierte Verfahren von Schiewe (2001) und das von Mayer (2000) speziell für die Anwendung in urbanen Gebieten entwickelte Verfahren. Die Funktionsweise dieser Verfahren wird im Folgenden kurz beschrieben.

Eine einfache, aber häufig verwendete Methode ist das morphologische *Opening*, bestehend aus einer *Erosion* und einer *Dilation*. Bei diesen beiden Filteroperationen wird jedes Pixel zunächst durch das Filter-Minimum und anschließend durch das Filter-Maximum des Zwischenergebnisses ersetzt. Das *Opening* hat drei Nachteile, die auch bei seiner Anwendung auf das Laser-DOM von Dresden deutlich werden:

- I. Die Filteroperationen werden auf jedes Pixel angewendet. Somit werden die Höhenwerte aller Pixel verändert.
- II. In vielen Geländesituationen führt das *Opening* insgesamt zu einer Unterschätzung der Geländehöhe (**Abbildung 3-10**; blaue Linie).
- III. Die Form des Filterfensters zeichnet sich häufig deutlich im Ergebnisbild ab (**Abbildung 3-7**).



Abbildung 3–7 Links: Mit *Opening* erzeugtes DGM. Rechts: DOM zum Vergleich.

Wie **Abbildung 3–10** und **Abbildung 3–7** zeigen, sind die Ergebnisse des *Openings* als nicht zufriedenstellend zu bewerten. Intelligentere Ansätze arbeiten mit einer zweistufigen Methode: Identifizierung von Punkten bestimmter Eigenschaften und anschließender Interpolation eines DGMs. Dadurch können die Nachteile des *Openings* häufig ausgeräumt oder stark verbessert werden. Grundsätzlich sind dabei zwei Strategien denkbar:

- I. Identifizierung von Reduktionspixeln oder -flächen (d.h. von Objekten, die nicht zum Gelände gehören) und Ersetzung dieser durch Interpolation aus den umgebenden Geländepunkten.
- II. Identifizierung von Geländepunkten, also solchen Punkten, die sicher zum Gelände gehören, und Interpolation eines DGMs aus diesen.

Theoretisch erzeugt Strategie I, wenn sie fehlerlos funktioniert, ein genaueres DGM, da alle Geländepunkte ihren Originalwert behalten und nur kleinräumige Flächen, die Reduktionsflächen, interpoliert werden müssen. Es besteht aber das Risiko, dass Objekte oder Pixel, die nicht als Reduktionsfläche/-pixel erkannt werden, vollständig im DGM erhalten bleiben. Bei der zweiten Strategie ist dieses Risiko geringer. Dafür entstehen im interpolierten DGM an allen zum Gelände gehörenden Punkten lokale Abweichungen des Höhenwertes, die vorher nicht als Geländepunkt identifiziert wurden. Dabei korreliert die Stärke dieser Abweichungen negativ mit der Fähigkeit des Algorithmus, ein möglichst dichtes Netz an Geländepunkten zu extrahieren.

Die regionenbasierte Methode von Schiewe verfolgt die erste Strategie, bei der Reduktionsflächen in Form von Bildsegmenten gesucht werden. Die Segmentierung wird nicht direkt auf dem DOM durchgeführt, sondern auf einem abgeleiteten Bild, das die Änderung der Steigung des DOMs zeigt (erzeugt durch die zweimalige Berechnung des Steigungsgradienten). Die so gewon-

nenen Segmente werden anhand ihrer mittleren und maximalen Steigungsgradienten in Reduktions- und Geländeflächen klassifiziert. Bei ihrer Anwendung auf das Laser-DOM von Dresden konnte die von Schiewe entwickelte Methode leider nicht an die Gegebenheiten des Untersuchungsgebietes angepasst werden und lieferte dadurch keine brauchbaren Ergebnisse.

Das Verfahren von Mayer verfolgt ebenfalls die erste Strategie. Durch die Normalisierung jedes Pixels mit dem Minimum im Filterfenster¹⁰ wird ein vorläufiges nDOM erzeugt. Basierend auf dieser Information erfolgt die Einteilung in GOK- und Reduktionspixel durch einfache Schwellenwertanwendung auf die vorläufige Objekthöhe. Beide Schritte können mehrfach wiederholt werden mit unterschiedlichen Filterfenstergrößen und Schwellenwerten. Dies hat den Vorteil, dass mit einem großen Filterfenster und relativ hohem Schwellenwert größere Objekte wie Häuser als Reduktionsflächen erkannt werden, während bei einem kleineren Filterfenster und kleinerem Schwellenwert kleinere und niedrigere Objekte wie z.B. Autos oder Garagen als Reduktionsflächen ausgewiesen werden. Aus den verbliebenen GOK-Punkten wird anschließend ein DGM interpoliert. Die Untersuchungen von Mayer zeigen, dass mit dem Verfahren in urbanen Gebieten gute Ergebnisse erzielt werden können, unter der Voraussetzung eines ebenen bis gering geneigten Geländes ohne Reliefsprünge. Im Untersuchungsgebiet Dresden liegen allerdings mit dem Elbufer, dem Flusstaleinschnitt der Prießnitz und leichten Hügeln am Stadtrand Geländeformen vor, die dieser Voraussetzung nicht entsprechen. Daher wurde im Rahmen der Arbeit ein neuer Ansatz für eine filterbasierte Methode entwickelt, die im Folgenden beschrieben wird.

Eine neue, filterbasierte Methode zur DGM-Erzeugung

Im Gegensatz zu den vorgestellten Methoden verfolgt der neu entwickelte Ansatz die zweite Strategie, d.h. es werden anhand von bestimmten Bedingungen Punkte auf der GOK identifiziert. Anschließend werden diese einer intensiven Überprüfung unterzogen und die verbliebenen GOK-Pixel zu einem flächendeckenden DGM interpoliert. Die Zweiteilung in eine Suche potenzieller GOK-Pixel und eine Überprüfung dieser in einem separaten Schritt erfolgt, um im ersten Schritt mit einem sehr kleinen Filterfenster (kreisförmiger Filter mit 5 Pixeln Durchmesser; entspricht ca. 20 m) arbeiten zu können. Dies erhöht die Dichte der potenziellen GOK-Pixel. Insbesondere in der Nähe von Geländebruchkanten, z.B. an befestigten Flussufern, können so noch GOK-Pixel in einem Abstand von 3 Pixeln gefunden werden. Viele andere Methoden behandeln das Gelände oberhalb solcher Bruchkanten bis zu einem Abstand von $2 d_{max} + 1$ (siehe Fußnote 10 zum Verfahren von Mayer) als Reduktionsfläche und unterschätzen so die Geländehöhe im interpolierten DGM. Damit ein Pixel als potenzieller Punkt auf der GOK erkannt wird, muss es einer der drei folgenden Bedingungen genügen:

- I. Pixel ist lokales Minimum (ArcInfo: FOCALMIN(DOM) == DOM)
- II. Pixel liegt in sehr ebenem Gelände (ArcInfo: FOCALMAX(DOM) – FOCALMIN(DOM) < 0,5 m)

¹⁰ Die Größe des Filterfensters wird auf $2 d_{max} + 1$ festgelegt (gerechnet in Pixeln), wobei d_{max} die größte Entfernung aller Objektpixel zu ihren jeweils nächstgelegenen GOK-Pixeln ist.

- III. Pixel liegt auf einem Hang. Die Hangpunkte werden anhand des Gefälles an der Stelle des Pixels (ArcInfo: SLOPE(DOM)), der Veränderung des Gefälles innerhalb eines kleinen Filterfensters (ArcInfo: FOCALRANGE des SLOPE) und der Variation der Richtungen des Gefälles im Filterfenster (ArcInfo: größter Winkel zwischen der mit ASPECT(DOM) berechneten Gefällerichtung des Pixels im Filterzentrum und der Gefällerichtungen der es umgebenden Pixel im Filterfenster) ermittelt.

Die potenziellen GOK-Pixel werden anschließend daraufhin überprüft, ob sie auf einem Objekt (z.B. einem Hausdach) liegen. Hierbei muss als einziger Parameter des Programms die Größe des Filterfensters auf $2,5 d_{max}$ gestellt werden, wobei d_{max} die größte Entfernung aller Objektpixel zu ihren jeweils nächstgelegenen GOK-Pixeln ist, oder bildlich gesprochen der Radius des größten Kreises, der vollständig in einem Gebäude oder anderem Objekt enthalten ist. Um die auf Hängen oder an Bruchkanten gelegenen potenziellen GOK-Pixel zu behalten und nur die auf Objekten liegenden Pixel zu verwerfen, erfolgt die Überprüfung richtungsabhängig. Hierzu werden 8 Filter mit der Form eines Kreissektors verwendet, die jeweils vom Filterzentrum aus gesehen die Pixel zwischen 0-45 Grad (0 Grad entspricht Norden), 45-90 Grad, 90-135 Grad usw. beinhalten (**Abbildung 3-8**). Existiert in keiner oder nur in einer Richtung ein tieferes Pixel mit einer Höhendifferenz von mehr als 3,5 m, so wird das potenzielle GOK-Pixel bestätigt. Existieren in 6-8 Richtungen tiefere Pixel, wird das Pixel verworfen, da es auf einem Objekt liegt, das ringsherum von tieferem Gelände umgeben ist. Existieren in 2-5 Richtungen tiefere Pixel, wird eine richtungsabhängige Prüfung vorgenommen (**Abbildung 3-8**): Liegen die tieferen Pixel alle in aneinandergrenzenden Kreissektoren, so liegen sie alle auf der gleichen Seite des Objektes. Es wird daher angenommen, dass das zu prüfende Pixel auf einem Hang oder an einer Bruchkante liegt. Daher wird es als GOK-Pixel bestätigt. Liegen die tieferen Pixel nicht in aneinandergrenzenden Kreissektoren wie im Fall der **Abbildung 3-8**, wird das zu prüfende Pixel verworfen. **Abbildung 3-9** zeigt einen Ausschnitt eines DOMs, über das die verworfenen und bestätigten GOK-Pixel überlagert wurden.




Abbildung 3-8 Richtungsabhängige Überprüfung eines potenziellen GOK-Pixels. Da das Pixel auf einem Gebäude liegt, werden tiefere Pixel in gegenüberliegenden Richtungen gefunden, d.h. in mehreren Kreissektoren, die nicht aneinandergrenzen. Daher kann das Pixel verworfen werden. Pixel an Hängen bleiben dagegen erhalten, da hier nur zu einer Seite tiefere Pixel gefunden werden.




Abbildung 3–9 Ausschnitt des stereoskopisch erzeugten DOMs von Dresden mit überlagerten verworfenen (rot) und bestätigten (grün) GOK-Pixeln.

Die abschließende Interpolation eines flächendeckenden DGMs aus den verbliebenen GOK-Pixeln erfolgt mit einem Verfahren, das die GOK-Pixel mit ihrer inversen Distanz zum Filterzentrum gewichtet (Methode „*inverse distance weighted interpolation*“ in ArcInfo nach (Philip & Watson 1982, Watson & Philip 1985)). Das nDOM resultiert aus der Subtrahierung des DGMs vom DOM, wobei auftretende negative Höhen im nDOM auf Null (= Geländeoberkante) rekodiert werden, da diese Artefakte der Methode sind und mit großer Sicherheit zur GOK gehören.

Um einen Vergleich der Genauigkeiten der Methoden zu erhalten, wurden der beschriebene Algorithmus und die Methode des *Openings* auf die verschiedenen DOMs dieser Arbeit angewendet. Es wurde ein visueller und ein statistischer Vergleich vorgenommen. Ein Profilschnitt (**Abbildung 3–10**) in x-Richtung durch ein Quell-DOM und die daraus abgeleiteten DGMs zeigt, dass beide Methoden eher zur Unterschätzung der Geländehöhe neigen. Diese fällt allerdings bei der neu entwickelten Methode geringer aus als beim Opening (die grüne Linie liegt dichter an den Tiefpunkten der schwarzen Linie). **Abbildung 3–10** zeigt das DOM und das mit der eigenen Methode erzeugte DGM im Vergleich.

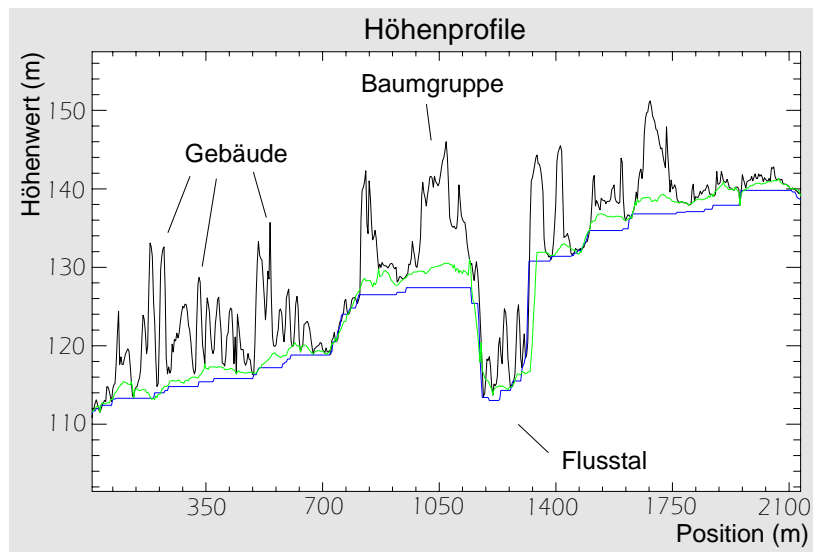


Abbildung 3–10 Höhenprofile des stereoskopisch erzeugten DOMs von Dresden (schwarz) und der daraus abgeleiteten DGMs. Blau: *Opening*, grün: eigene Methode. Die lokalen Erhöhungen entlang des Profils des DOMs werden durch Gebäude, einzelne Bäume oder Baumgruppen hervorgerufen.




Abbildung 3–11 Ausschnitt aus DOM, DGM und nDOM in 3D-Darstellung.

Die statistische Genauigkeit der beiden Methoden wird anhand von 897 (Dresden) bzw. 670 (Berlin) zufällig verteilten Kontrollpunkten auf der Geländeoberkante abgeschätzt. Hierzu werden die absoluten Differenzen der Höhenwerte zwischen DOM und DGM an den Kontrollpunkten untersucht, die bei einem guten DGM nahe Null liegen sollten. Die in **Abbildung 3–12** gezeigten Histogramme der absoluten Differenzen zeigen, dass die neu entwickelte Methode dem *Opening* überlegen ist – deutlich mehr Kontrollpunkte weisen hier eine geringere vertikale Differenz zum DOM auf. Im Bereich mittlerer Abweichungen überwiegt dagegen immer die Zahl der Kontrollpunkte für das *Opening*, während diese bei stärkeren Abweichungen für beide Methoden vergleichbar hoch ist. Da die Verteilung der absoluten Differenzen keine Gauß'sche Normalverteilung aufweist, wird als Fehlermaß nicht die Standardabweichung, sondern der *Absolute Linear Error 80* (LE80) und der LE90 verwendet, welcher die maximale absolute vertikale Abweichung

der besten 80 % bzw. 90 % aller Kontrollpunkte angibt. Die in **Tabelle 3-5** gelisteten Fehlermaße zeigen, dass insbesondere bei stereoskopisch erzeugten DOMs eine deutliche Überlegenheit der neuen Methode besteht, während sie bei den Laserdaten geringer ausfällt.




Abbildung 3-12 Histogramme der absoluten Abweichungen zwischen DOM und abgeleitetem DGM an den Kontrollpunkten. Blau: eigene Methode, rot: *Opening*. Zur übersichtlicheren Darstellung wurden bei allen Histogrammen einzelne Ausreißer mit sehr großen Werten weggelassen.

Tabelle 3-5 Vergleich der Genauigkeiten der Methoden zur DGM Berechnung (LE80 / LE90 in Dezimetern).

(dm)	Eigene Methode	<i>Opening</i>
Laser-DOM Dresden	6 / 11	8 / 13
Luftbild-DOM Dresden	11 / 16	18 / 24
HRSC-DOM Berlin	5 / 8	14 / 18

Erzeugung von Hausmasken

Durch die Anwendung eines Schwellenwertes von 18 dm auf die nDOMs können aus diesen Hausmasken erzeugt werden. Die hohe Genauigkeit der erzeugten nDOMs ermöglicht es, mit diesem sehr niedrig angesetzten Schwellenwert auch einstöckige Garagen in der Hausmaske zu erfassen. Die Hausmasken müssen allerdings kontrolliert und gegebenenfalls manuell korrigiert werden, da sie z.B. Brücken und Trassen als erhöhte Objekte enthalten. Im Hinblick auf den Verwendungszweck der Gebäudemasken in der Klassifizierung und spektralen Entmischung der Hyperspektraldaten (Kap. 3.4.3) zur Unterstützung der Trennbarkeit zwischen ebenerdigen Oberflächen und Dachmaterialien, werden Brücken und Trassen an dieser Stelle aus den Gebäudemasken entfernt, da sie mit ebenerdigen Oberflächenklassen (z.B. Asphalt, Beton etc.) klassifiziert werden sollen und nicht mit Dachmaterialien. Bäume und höhere Sträucher können je nach Quelle und Erzeugungsart des DOMs vollständig, gar nicht oder teilweise in der Maske enthalten sein. Dies muss allerdings in keinem Fall durch manuelles Editieren der Gebäudemaske geändert werden, da es durch eine entsprechende Aufteilung der Klassen bei der Klassifizierung berücksichtigt wird.



Abbildung 3–13 Veranschaulichung der Hausmaske an einem Ausschnitt des Berliner HyMap-Streifens. Die zur Hausmaske gehörenden Pixel werden unverändert dargestellt, während nicht zur Maske gehörende Pixel in matten Farben gezeigt werden.

3.4 Hyperspektrale Flugzeugscannerdaten

Wie in Kap. 1.2 dargelegt wurde, bilden die urbanen Oberflächen¹¹ die wichtigste Informationsquelle zur automatischen Bestimmung des Biotoptyps und zur Berechnung ökologischer Parameter. Viele Untersuchungen betonen die große Vielfalt urbaner Oberflächen und zeigen auf, dass diese nur unter Verwendung von Hyperspektraldaten zu differenzieren sind (Herold *et al.* 2003), (Heiden *et al.* 2007), (Ben-Dor *et al.* 1998), (Bhaskar & Datt 2000). Daher werden auch in dieser Arbeit Hyperspektraldaten verwendet. Die folgenden Kapitel zeigen deren Verarbeitung bis zur Ableitung der urbanen Oberflächenarten.

3.4.1 Der HyMap-Sensor

Der HyMap-Sensor ist ein flugzeuggetragenes abbildendes Spektrometer, das nach dem *Whiskbroom*-Prinzip arbeitet. Er zeichnet sich durch ein sehr hohes Signal-Rausch-Verhältnis von $> 500:1$ bei 50 % Reflexion aus sowie durch eine nahezu kontinuierliche Abdeckung des

¹¹ Hierunter werden alle in einer Stadt vorkommenden Oberflächen, also sowohl anthropogene Materialien (Beton, Asphalt, Hausdächer, Schotterflächen etc.), als auch natürliche Oberflächen (Vegetation, Wasser, Boden etc.) verstanden.

VIS-NIR-SWIR Bereichs des elektromagnetischen Spektrums mit insgesamt 128 Kanälen (Cocks *et al.* 1998). Die spektralen Bandbreiten (FWHM) sowie die spektralen Samplingintervalle liegen zwischen 15-20 nm. Bei einem Öffnungswinkel (FOV) von $61,3^\circ$ und 512 Pixeln pro Bildzeile ergeben sich bei Flughöhen von 2000-5000 m Pixelgrößen (GIFOV) von 4-10 m und Flugstreifenbreiten von 2300-5800 m. Die weiteren technischen Parameter des Sensors sowie die Kennwerte der Befliegungen der verwendeten Datensätze von Berlin und Dresden sind in **Tabelle 3-1** zu Beginn des Kapitels 3 gelistet.

3.4.2 Korrektur- und Vorverarbeitungsschritte

Vor der Auswertung müssen hyperspektrale Scannerdaten atmosphärisch und geometrisch korrigiert werden (s. Kap. 2.1.1). Der Berliner Datensatz wurde von Mitarbeitern der Abteilung Geomatik der Humboldt-Universität zu Berlin korrigiert. Die von ihnen verwendete Software ATCOR-4 und PARGE arbeitet nach den gleichen Prinzipien wie die unten beschriebenen GFZ-eigenen Programme, die für die Korrektur der Dresdner Datensätze verwendet wurden.

Atmosphärische Korrektur

Die atmosphärische Korrektur entfernt den Einfluss der Atmosphäre (Kap. 2.1.1) aus den vom Sensor gemessenen Radianzspektren und überführt diese in normierte Reflexionsspektren in der Einheit Prozent des reflektierten Lichts bezogen auf das einfallende Licht. Die Korrektur wurde mit dem am GFZ Potsdam von Dr. Karl Segl geschriebenen Programm ACUM_R vorgenommen, gefolgt von einer *Empirical Line* Korrektur. ACUM_R führt eine parametrische Korrektur durch, die die physikalischen Strahlungstransfermodelle von MODTRAN verwendet. Die Korrektur erfolgt für jedes Pixel in Abhängigkeit vom Scanwinkel unter Einbeziehung eines DOMs. Hierdurch wird der Einfluss der Länge des Strahlungswegs der reflektierten Strahlung durch die Atmosphäre berücksichtigt. Weitere Parameter des Modells beziehen sich auf die Zusammensetzung der Atmosphäre zum Zeitpunkt des Überflugs. Da diese Informationen selten als Messwerte vorliegen, sind in MODTRAN Standardatmosphären und Aerosolmodelle implementiert. Ein kritischer Eingabeparameter ist der Wasserdampfgehalt. Viele Korrekturprogramme verwenden Algorithmen (z.B. Gao & Goetz 1990, z.B. Schläpfer *et al.* 1998), um diesen aus den Bilddaten selbst abzuschätzen. Geringe Fehler führen jedoch bereits zu erheblichen Ausreißerwerten (engl.: *spectral spikes*) an den atmosphärischen Banden, die nachträglich durch spektrale Glättung (engl.: *spectral polishing*) reduziert werden müssen. ACUM_R hat keinen solchen Algorithmus implementiert. Die Korrektur der *spectral spikes* erfolgt hier durch eine nachgeschaltete *Empirical Line* Korrektur.

Die *Empirical Line* Methode wird häufig auch für die direkte Korrektur von Radianz in Reflexion verwendet. Ein Nachteil der direkten Anwendung ist, dass dabei die Scanwinkel- und Geländehöhenabhängigkeit nicht berücksichtigt werden kann. Bei ihrer Anwendung nach ACUM_R wird sie dazu verwendet, um die Reflexionswerte des Bildes auf im Feld gemessene Reflexionswerte anzupassen und insbesondere die *spectral spikes* zu korrigieren. Die *Empirical Line* Methode stellt hierfür pro Kanal eine lineare Regressionsgerade zur Umrechnung der Werte auf. Es wurde darauf geachtet, dass pro Datensatz die Spektren von mindestens einer sehr dunklen (z.B. Wasser) und einer sehr hellen Oberfläche (z.B. Sand) zur Aufstellung der Gleichungen benutzt wurde, um die Regressionsgeraden zu stabilisieren. Die folgenden Abbildungen dokumentieren die erzielten Ergebnisse des 2000er HyMap-Datensatzes von Dresden. Die Ergebnisse der anderen Datensätze sind vergleichbar. Neben den Oberflächenarten Wasser und Sand wur-

den hier noch Kopfsteinpflaster, Tartanbahn und roter Split (Sportplatzbelag) für die Berechnungen der in **Abbildung 3–14** gezeigten Regressionsgeraden verwendet. Die Stützpunkte der Regression liegen dicht an der Geraden. In **Abbildung 3–15** sind die Bildspektren (gemittelt über mehrere Pixel einer homogenen Fläche) nach ACUM_R und nach der *Empirical Line* Korrektur im Vergleich zu den Feldspektren dargestellt. Die Korrektur der *spikes* funktionierte nur teilweise. Als Grund hierfür wird die Variation des Wasserdampfgehaltes innerhalb der Bildszene angenommen, die bei der *Empirical Line* Korrektur nicht berücksichtigt wird. Eine visuelle Untersuchung der SNR-Qualität der Kanäle ($SNR = \text{signal-to-noise ratio}$; deutsch: Signal-Rausch-Verhältnis) zeigte allerdings, dass die entsprechenden Kanäle zu wenig Signal enthalten und daher keinen Wert für die weiteren Analysen besitzen. Die verbleibende Abweichung der übrigen Kanäle (**Abbildung 3–15**, gestrichelt) von den Feldspektren (**Abbildung 3–15**, durchgezogen) nach durchgeführter *Empirical Line* Korrektur bleibt im Wesentlichen unter 5 % und ist damit zufriedenstellend.

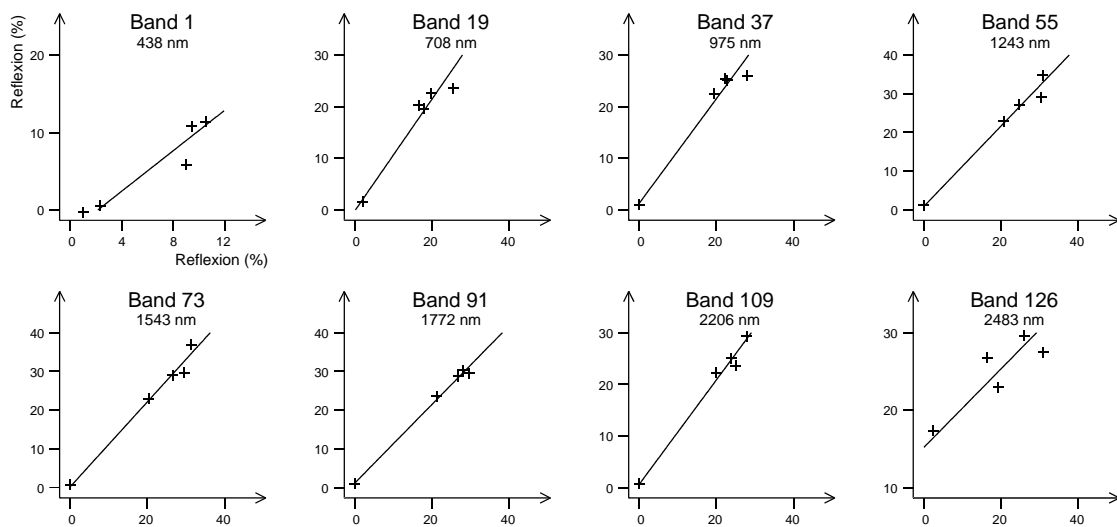


Abbildung 3–14 Regressionsgeraden der *Empirical Line* Korrektur für ausgewählte Bänder.

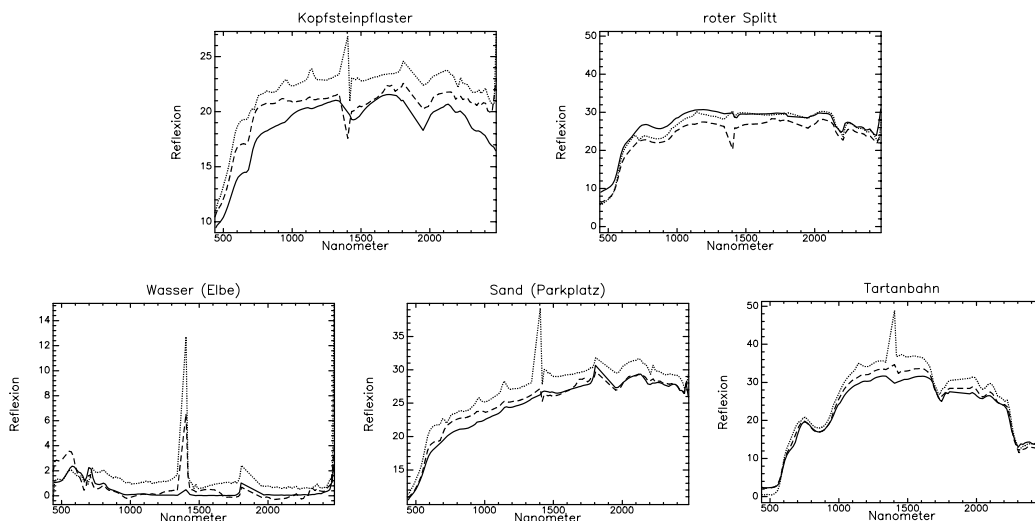


Abbildung 3–15 Vergleich der Spektren nach ACUM_R und nach der *Empirical Line* Korrektur mit den im Feld gemessenen Spektren.

Geometrische Korrektur

Sensoren, die nach dem Zeilenscannerprinzip arbeiten, nehmen die Bilddaten beim Überflug Zeile für Zeile quer zur Flugrichtung auf (**Abbildung 3–16**). Bedingt durch die Fortbewegung des Flugzeugs und die Rotationen um die drei Raumachsen (Roll-, Nick- und Gierwinkel) besitzt jede aufgenommene Bildzeile eine andere Aufnahmegeometrie. Während ein Teil der Flugzeugbewegungen durch eine kreiselstabilisierte Plattform ausgeglichen wird, wird der verbleibende Anteil durch die am Sensor montierte INS/GPS aufgezeichnet. Die für jede Bildzeile aufgezeichneten sechs Parameter der äußeren Orientierung (geographische Länge und Breite, Flughöhe, sowie die Drehwinkel um die drei Raumachsen) ermöglichen im Nachhinein eine parametrische Geokorrektur der Bilddaten, die in der Regel vor der spektralen Auswertung eines Bildes durchgeführt wird.




Abbildung 3–16 Aufnahmegeometrie eines flugzeuggetragenen Zeilenscanners.

Die parametrische Geokorrektur besteht aus zwei Teilschritten: Der Berechnung der Koordinaten für die aufgezeichneten HyMap-Pixel basierend auf der Kollinearitätsbedingung und der Übertragung ihrer Grauwerte in das Zielkoordinatensystem. Die beiden Schritte wurden mit den am GFZ Potsdam von Dr. Karl Segl entwickelten Programme *sori2igmimage* und *georesamp* durchgeführt. Für den ersten Schritt werden neben den sechs Parametern der äußeren Orientierung die Höhe des Geländes (in Form eines DOMs) sowie der Öffnungswinkel und die Kamera-konstante der Optik benötigt. Zur Berechnung und Korrektur von eventuellen konstanten *Offsets* in den übergebenen Parametern wurden Passpunkte verwendet. Als Zielkoordinatensystem wurde das Gauß-Krüger Koordinatensystem mit der Zone 5 gewählt.

Die Übertragung der Grauwerte der aufgezeichneten HyMap-Pixel in das Zielsystem erfolgt mit einer Resamplingmethode. Da die Koordinaten der Pixel des HyMap-Datensatzes kein regelmäßiges Gitternetz bilden (bedingt durch den unterschiedlichen geometrischen Versatz der einzelnen Bildzeilen; s. **Abbildung 3–17**), ergibt sich für die Interpolation eine besondere Situation, sofern mehr als ein HyMap-Pixel berücksichtigt werden soll. Dies ist zu empfehlen, da die *Nearest Neighbour* Methode mit nur einem HyMap-Pixel zur Folge hat, dass gerade Kanten von Geobjekten gezackt dargestellt werden, wobei die Kantenlänge der Zacken nicht selten 2 Pixel beträgt. Eine Resamplingmethode, die auch bei einem unregelmäßigen Gitternetz unter Berücksichtigung mehrerer Inputpixel funktioniert, ist die *Inverse Distance Weighted Interpolation*.

(Watson & Philip 1985). Der Grauwert eines Pixels im Rasterbild des Zielsystems wird gemäß **Gleichung (3-1)** aus einer festgelegten maximalen Anzahl von HyMap-Pixeln innerhalb eines definierten Suchradius interpoliert. Die Gewichtung der Grauwerte der HyMap-Pixel kann dabei wahlweise mit der Inversen ihrer Entfernung, dem inversen Quadrat ihrer Entfernung oder der inversen Wurzel aus ihrer Entfernung erfolgen. **Gleichung (3-1)** zeigt die gewählte quadratische Variante. Die Anzahl n und der Suchradius wurden auf 2 bzw. 10 m festgelegt.

$$G_{x,y} = \frac{\sum_{i=1}^n d_i^2 g_i}{\sum_{i=1}^n d_i^2} \quad (3-1)$$

mit $G_{x,y}$: Grauwert des Pixels in Zeile y und Spalte x im projizierten Rasterbild
 g_i : Grauwert des i -dichtesten HyMap-Pixels
 d_i : Euklidische Distanz des i -dichtesten HyMap-Pixels basierend auf Kartenkoordinaten
 n : Maximale Anzahl zu berücksichtigender HyMap-Pixel innerhalb eines festgelegten Suchradius




Abbildung 3-17 Die Abbildung zeigt schematisch die vorliegende Situation bei der Übertragung der Grauwerte der HyMap-Pixel in das Rasterbild im Zielsystem. Der Grauwert $G_{x,y}$ eines Pixels im Zielbild wird durch Interpolation nach **Gleichung (3-1)** aus den Grauwerten einer maximalen Menge (hier 3) von HyMap-Pixeln berechnet, die innerhalb eines Suchradius liegen.

Die Qualität der Georeferenzierung wurde mit unabhängigen Passpunkten aus hochauflösenden Orthobildern überprüft. Die RMS-Fehler der Dresdner Datensätze von 2000 und 2004 liegen mit 4,4 m bzw. 2,5 m leicht über bzw. unter der räumlichen Auflösung der beiden Datensätze (3,5 m bzw. 4 m) und sind damit sehr zufriedenstellend. Größere, jedoch nicht korrigierbare Abweichungen ergeben sich nur in Bereichen starker Flugzeugbewegungen.

3.4.3 Klassifizierung und Entmischung von urbanen Oberflächen

Die urbanen Oberflächen bilden die wichtigste Informationsquelle zur automatischen Bestimmung des Biotoptyps und zur Berechnung ökologischer Parameter (Kapitel 1.2). Bezogen auf die Ausübung ökologischer Funktionen (insbesondere der Versickerungsleistung von Niederschlagswasser) hat Heiden (2004) den urbanen Raum in einem mehrstufigen Schema unterteilt (**Abbildung 3-18**), das sich an Krause (1989) und Sandtner (1998) anlehnt. Die unterste Ebene enthält die einzelnen fernerkundlich erfassbaren urbanen Oberflächenarten. Die von Heiden in der Stadt Dresden verwendeten Oberflächenarten wurden in dieser Arbeit um weitere des Un-

tersuchungsgebiets in Berlin auf insgesamt 67 ergänzt, wobei die meisten Oberflächenarten in beiden Untersuchungsgebieten dieser Arbeit präsent sind. In der Klassenliste (**Tabelle 3-6**) ist der eindeutige Schwerpunkt dieser Arbeit zu erkennen, der auf der vollständigen Differenzierung der anthropogenen Oberflächen, speziell der Dachmaterialien liegt. Dieser Schwerpunkt ergibt sich aus der Auswahl der untersuchten Biotoptypen, bei denen es sich vor allem um baulich geprägte Biotoptypen handelt. Für eine erweiterte Ausbaustufe des entwickelten Systems auf vorrangig naturbelassene Biotoptypen müssten die natürlichen Oberflächen, insbesondere die Stadtvegetation, stärker differenziert werden. Wenige Arbeiten (z.B. Wania & Weber 2007) haben dies bisher versucht, jedoch zeigen zahlreiche Arbeiten in ländlichen Untersuchungsgebieten, dass mit Hyperspektraldaten auch bezüglich der Vegetation eine detaillierte Differenzierung erreicht werden kann (z.B. Martin *et al.* 1998, Lewis *et al.* 2001, Lewis 2001, Schmidt & Skidmore 2003, Bochow 2005, Clark *et al.* 2005, Rosso *et al.* 2005).

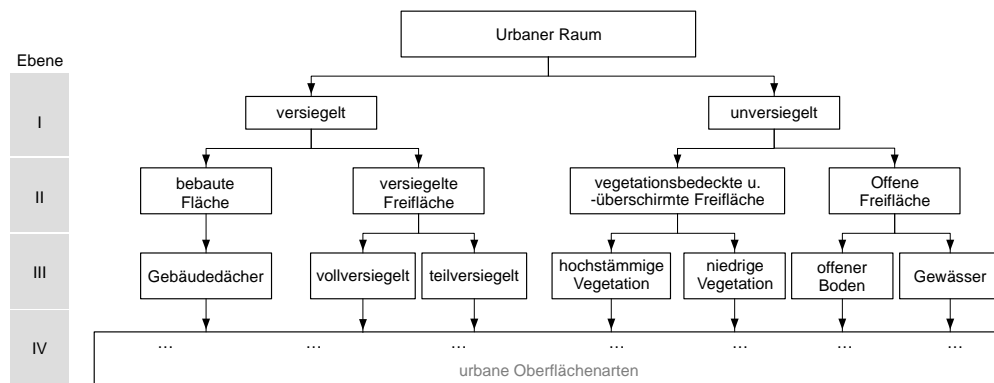


Abbildung 3-18 Hierarchische Gliederung der Oberflächenarten des urbanen Raums nach stadtoökologischen Gesichtspunkten. Die unterste Ebene enthält die fernerkundlich erfassbaren urbanen Oberflächenarten (verändert nach: Heiden 2004: 28).

Tabelle 3-6 Klassenliste der verwendeten 67 urbanen Oberflächenarten (s. auch Anhang A).

Ebene III in Abbildung 3-18	Material/Oberflächenart
Gebäudedächer	Tonziegel (rot und alt, rot und neu, dunkelrot-braun, grau), rote Betonziegel, Aluminium, Zink, Kupfer, Stahl mit Rostschutzanstrich, Well- oder Trapezblech mit PVC- oder Polyethylenbeschichtung (4 Farben), PVC, Polyethylen, Plexiglas, Glas, Gewächshausdach, Dachbitumen (hell, dunkel, rot), Teerpappe (obsolet), Schiefer, Gründach, Kies (2 Arten), 8 unbekannte aber spektral unterschiedliche Materialien
Vollversiegelte Oberflächen	Drei Arten Beton, Asphalt, Tartanbahn, Kunstrasen, Bodenplatten aus Polyethylen, blaue Bodenfarbe (Lack)
Teilversiegelte Oberflächen	Kopfsteinpflaster, Splitt (rot, hell, grau, dunkel), Betonpflastersteine, rote Tonpflastersteine, rote Asche (z.B. Tennisplatz), Bahngleise
Offener Boden	Feiner Sand, grober Bausand, Boden
Wasser	Fluss, See, Teich, Pool
Hochstämmige Vegetation	Laubbäume, Nadelbäume
Niedrige Vegetation	Rasen, Wiese, trockener Rasen
Schatten	Schatten auf Vegetation, Schatten nicht auf Vegetation
Andere	Gelbe U-Bahn von Berlin, gelbes Baumaterial aus Polyethylen

Bevor im Folgenden der verwendete Algorithmus zur automatischen Ableitung der urbanen Oberflächen bzw. deren Flächenanteile aus hyperspektralen Fernerkundungsdaten beschrieben wird, sollen hier einige grundlegende Begriffe und Konzepte erläutert werden, auf denen der Algorithmus aufbaut. Wir beginnen mit dem Begriff der **Klassifizierung**, der die Zuordnung der Pixel eines Fernerkundungsbildes anhand ihrer Grauwerte oder daraus abgeleiteter Informationen zu einer thematischen Klasse (z.B. der Art der Oberflächenbedeckung) bezeichnet. Trifft das GIFOV¹² eines Sensors bei der Abtastung der Erdoberfläche auf die Grenze zweier verschiedener Oberflächen, entsteht ein Mischpixel. Der Anteil der Mischpixel in einem Fernerkundungsbild verhält sich invers zur Größe der homogenen Oberflächen und zur räumlichen Auflösung des Sensors. Er ist jedoch nie gleich Null, sofern mehr als eine homogene Fläche im Bild existiert. Bei der Pixelgröße der vorliegenden HyMap-Daten und dem kleinräumigen Wechsel homogener Oberflächen in Städten wird der Anteil der Mischpixel auf 30-50 % geschätzt. Um die Genauigkeit der Auswertung zu erhöhen, ist es wünschenswert, diesen Mischpixeln nicht nur eine Klasse zuzuweisen, sondern die genauen Flächenanteile der darin enthaltenen Oberflächen zu bestimmen. Verfahren, die in der Lage sind, diese Messung im Subpixelbereich vorzunehmen, führen eine sogenannte **spektrale Entmischung** (engl.: *spectral unmixing*) (z.B. Richards & Jia 1999: Kap. 13.8) der Bildspektren durch. Spektrale Entmischungsverfahren werden in partielle und vollständige Verfahren unterteilt. Zu letzteren gehört die lineare spektrale Entmischung, die basierend auf einem vollständig bekannten Satz an *Endmembers* (Definition s.u.) das Spektrum eines Bildpixels BP an der Stelle ij eines Bildes nach folgender Gleichung entmischt (Stein *et al.* 1999: 188):

$$BP_{ij} = Ef_{ij} + \varepsilon_{ij} \quad (3-2)$$

mit dem $L \times 1$ Vektor f_{ij} , der die gesuchten Flächenanteile der *Endmember* enthält,
 der $K \times L$ Matrix E , die in jeder Spalte das Spektrum eines *Endmembers* mit K Kanälen enthält und
 dem Residuen-Vektor ε_{ij}

Da bei hyperspektralen Daten in der Regel mehr Gleichungen (eine Gleichung pro Kanal) als Variablen (eine Variable pro *Endmember*) existieren, wird der Residuen-Vektor im Rahmen einer Ausgleichsrechnung minimiert. Einige Verfahren führen dabei die in der Natur der Sache begründet liegenden Nebenbedingungen ein, dass die Flächenanteile der *Endmember* nicht negativ sein dürfen und sich zu 1 summieren müssen (engl.: *constrained unmixing* bzw. *non-negative least squares unmixing* (NNLS)) (Richards & Jia 1999: 335).

Bei der überwachten Klassifizierung von hyperspektralen Bilddaten und insbesondere bei der spektralen Entmischung werden die Klassen häufig durch sogenannte **Endmember** definiert. Der Begriff *Endmember* kommt ursprünglich aus der oben dargestellten Theorie der linearen spektralen Entmischung und bezeichnet dort die Vertices der konvexen Hülle der Punktwolke, die von den Pixelvektoren eines Bildes im n -dimensionalen Merkmalsraum gebildet wird (virtuelle *Endmember*) oder auch diejenigen real existierenden Pixelvektoren des Bildes, die dort in der Nähe liegen (**Abbildung 3-19**). Da die Pixelvektoren innerhalb der konvexen Hülle der Punktwolke durch lineare spektrale Mischungen dieser „extremen“ Pixelvektoren erklärt werden können, wird davon ausgegangen, dass die Pixelvektoren der *Endmember* zu „reinen Pixel“ der jeweiligen Klassen gehören, also zu solchen Bildelementen, deren GIFOV komplett von nur einer

¹² Ground instantaneous field of view = die Fläche auf der Erde, deren über die Point Spread Function (PSF) integriertes Signal Eingang in den Grauwert eines Pixels findet.

Klasse bedeckt ist, und dass die dazugehörigen Spektren „reine“ Spektren einer jeden Klasse repräsentieren (Boardman 1993). Der Sprachgebrauch des Begriffs *Endmember* hat sich dahingehend entwickelt, dass mit ihm sowohl die Pixelvektoren, als auch die dazugehörigen Pixel oder Spektren angesprochen werden können.




Abbildung 3-19 Beispiel eines zwei-dimensionalen Merkmalsraums mit drei Klassen. Die verschiedenen Dreiecke zeigen die Resultate verschiedener Methoden zur automatischen Bestimmung von *Endmembers* aus Bilddaten (verändert nach: Berman 2004, bzw. Berman *et al.* 2004). Quellen der Methoden: ICE: (Berman *et al.* 2004), Winter: (Winter 1999), Craig: (Craig 1994).

Endmember können auf verschiedenen Wegen gewonnen werden. Man unterscheidet zwischen im Labor oder Gelände gemessenen Referenz-*Endmembers* und aus einem Fernerkundungsbild selbst extrahierten Bild-*Endmembers* (z.B. Smith *et al.* 1990, Song 2005). Referenz-*Endmember* bilden die spektralen Eigenheiten einer Oberfläche in der Regel besser ab, da ihre Messung mit besseren Sensoren unter geringerem Einfluss von Störgrößen stattfinden kann. Jedoch können diverse Störgrößen wie BRDF-Effekte, Variationen der atmosphärischen Bedingungen innerhalb eines Bildes, Sensorrauschen oder spektrale Veränderungen der Oberflächenart (z.B. durch Alterung oder im Falle von Vegetation durch die Phänologie) dazu führen, dass auch nach einer intensiven Korrektur des Bildes die Referenz-*Endmember* nicht genau zu den im Bild vorhandenen *Endmembers* passen (Song 2005). Zusätzlich kann es sich negativ auswirken, wenn die Referenz-*Endmember* auf einer anderen Skalenebene gemessen werden als der des Bildes (Lu *et al.* 2007). In dieser Arbeit werden daher Bild-Trainingspixel für die Klassifizierung und Bild-*Endmember* für die Entmischung verwendet, wie es im Folgenden näher beschrieben wird. Zunächst sollen aber existierende Methoden zur Extrahierung von Bild-*Endmembers* vorgestellt werden und dargelegt werden, warum diese für die Anwendung im urbanen Raum nicht geeignet sind.

Für die Bestimmung von Bild-*Endmembers* – dem kritischsten Schritt bei der Entmischung eines Bildes (Tompkins *et al.* 1997), da sich eine ungeeignete Wahl der *Endmember* direkt auf die zu berechnenden Flächenanteile auswirkt – gibt es in der Literatur eine Reihe von Metho-

den. Mit einer manuellen Endmemberselektion nach (Bateson & Curtiss 1996) oder (Boardman *et al.* 1995) ist keine vollständige Automatisierung möglich. Eigene Versuche mit dem PPI von Boardman *et al.* haben außerdem gezeigt, dass dieser nicht in der Lage ist, alle urbanen *Endmember* zu finden. Solche *Endmember* mit besonders gerade verlaufenden Spektren ohne deutlich ausgeprägte Absorptionsbanden oder lokale Maxima wie z.B. Asphalt, liegen offensichtlich nicht exponiert genug auf der konvexen Hülle der Punktwolke und werden daher durch den PPI nicht erfasst.

Viele automatische Methoden zur Endmemberselektion wie z.B. (Bowles *et al.* 1995, Tompkins *et al.* 1997, Staenz *et al.* 1998, Winter 1999, Berman *et al.* 2004) basieren auf dem Konzept der linearen spektralen Mischung und führen die Selektion virtueller oder realer *Endmember* unter der Annahme durch, dass diese in der Nähe der Vertices der konvexen Hülle der Punktwolke liegen. Das oben beschriebene Ergebnis des PPI legt daher nahe, dass auch diese Methoden nicht alle urbanen *Endmember* finden können. Weiterhin gehen diese Methoden davon aus, dass die Punktwolke von einer *geringen* Anzahl spektral unabhängiger *Endmember* und deren Mischungen gebildet wird. So werden in den meisten Studien Szenen untersucht, die nicht mehr als 10 verschiedene *Endmember* enthalten (z.B. Tompkins *et al.* 1997, Roberts *et al.* 2002, Dennison & Roberts 2003, Bowles & Gillis 2007). Eine Inventarisierung der urbanen Oberflächenarten in beiden Untersuchungsgebieten dieser Arbeit ergab jedoch eine Gesamtzahl von 67 verschiedenen Oberflächenklassen.

Darüber hinaus schließen zwei weitere Nachteile die Verwendung der genannten Methoden in dieser Arbeit aus. Zum einen stellen auch diese Methoden keine vollständig automatischen Methoden dar, da die Identifizierung der ermittelten *Endmember*, also ihre Zuweisung zu einer urbanen Oberfläche, durch den Analysten erfolgen muss. Zum anderen zielen diese Methoden darauf ab, einen einzigen und zwar spektral extremen *Endmember* pro Klasse zu ermitteln. Aufgrund zahlreicher spektraler Variationen der Oberflächen, die z.B. durch unterschiedliche Aufnahmegeometrien der Pixel im Bild und unterschiedliche BRDF-Eigenschaften und physikalischen Beschaffenheiten der Oberflächenarten (Alter, Verschmutzung, Oberflächenrauigkeit etc.) zustande kommen, ist die Repräsentierung der Oberflächen durch einen einzigen *Endmember* nachteilig, wie folgende Untersuchung zeigt.

Die **Abbildung 3–20** zeigt spektrale Variationen zweier Dachmaterialien. Wir erzeugen aus dem jeweils niedrigeren Spektrum des einen Materials und dem höheren Spektrum des anderen Materials zwei spektrale Mischungen im Verhältnis 50:50 und entmischen diese linear mit der korrekten Kombination der Spektren beider Materialien und zusätzlich mit der jeweils anderen Kombination. Bei Anwendung der passenden *Endmember*-Kombinationen liefert die Entmischung ein Ergebnis von exakt 50:50 und sehr geringe RMS-Fehler von 0,27 bzw. 0,3. Unter Verwendung der jeweils falschen Kombination werden Anteile von 37:63 bzw. 85:15 berechnet. Die falschen Kombinationen sind an den hohen RMS-Fehlern von 171,6 und 122,8 leicht zu erkennen.

Die Abweichungen der mit den falschen Kombinationen berechneten Flächenanteile zeigen, dass es sehr wichtig ist, welche Spektren als *Endmember* in die lineare spektrale Entmischung gegeben werden und machen deutlich, dass es nicht einen einzigen *Endmember* pro Material gibt, sondern viele. In der Literatur wird in diesem Zusammenhang von Endmembersets oder Endmemberbündeln gesprochen (z.B. Roberts *et al.* 1998, Bateson *et al.* 2000). Powell *et al.* (2006) weisen insbesondere auf die hohe Variabilität urbaner Oberflächen und die dementsprechende Wichtigkeit einer passenden Auswahl von Endmembersets hin. Solche Sets von *Endmembers* für

urbane Oberflächen können mit den oben genannten Methoden zur Endmemberselktion nicht erfasst werden.




Abbildung 3–20 Variationen zweier Dachmaterialien (blau: Zink; rot: Polyethylen) und deren spektrale Mischungen (grün) im Verhältnis 50:50.

Nachdem die oben genannten Methoden zur Endmemberselktion für diese Arbeit nicht in Frage kommen, wurde eine weitere Gruppe von Methoden untersucht: Die Methode „*automated morphological endmember extraction*“ (AMEE) von Plaza *et al.* (2002), die Methode „*spatial-spectral endmember extraction*“ (SSEE) von Rogge *et al.* (2007), die „automatisierte Selektion von Referenzspektren“ (ASR) von Greiwe (2006) und die merkmalsbasierte automatische Endmemberselktion von Segl (bisher unveröffentlicht; Beschreibung s.u.). Die ersten drei Methoden berücksichtigen neben der spektralen auch eine räumliche Komponente bei der Endmembersuche. Die Methoden von Greiwe und Segl sind speziell für die Anwendung im urbanen Raum entwickelt worden.

Ein Kriterium bei der Wahl einer geeigneten Methode ist es, dass sie in der Lage sein muss, spektral ähnliche *Endmember* zu selektieren. AMEE und SSEE können dies, weil sie die spektralen Unterschiede der *Endmember* erfassbar machen, indem sie jeweils eine Teilmenge der Punktwolke betrachten. Die Teilmengen werden erzeugt, indem jeweils nur die Pixel eines räumlichen Ausschnitts des gesamten Bildes betrachtet werden. ASR ermöglicht dies ebenfalls durch eine Bildsegmentierung, sofern spektral ähnliche und unähnliche Oberflächen im räumlichen Wechsel auftreten. Auch die Methode von Segl ist dazu in der Lage. Im Vergleich zu den anderen arbeitet sie mit einer pixelbasierten, überwachten Klassifizierung, die auch spektral ähnliche Oberflächen unterscheiden kann.

Als zweite wichtige Fähigkeit muss die Methode in der Lage sein, mehrere spektrale Variationen einer Klasse, also ein Endmemberset pro Klasse zu finden. Den theoretischen Ausführungen der genannten Publikationen zu Folge ist dies mit allen vier Methoden möglich.

In einer wesentlichen Fähigkeit unterscheidet sich die Methode von Segl von den übrigen dreien: Während die anderen drei unüberwachte Methoden darstellen (die gefundenen Endmembersets müssen durch den Analytisten einer Oberflächenklasse zugeordnet werden), ist die Methode von Segl eine überwachte, d.h. die Methode kennt die gesuchten *Endmember* von vornherein und kann diese automatisch identifizieren. Dies setzt zwar im Vorfeld den Aufbau einer vollständigen spektralen Bibliothek urbaner Materialien voraus, jedoch kann die Methode danach auf eine unbekannte Szene vollständig automatisch angewendet werden. Daher wurde diese Methode bei

der Klassifizierung und spektralen Entmischung der HyMap-Daten verwendet. Sie ist damit Teil des Algorithmus zur Ableitung der Flächenanteile der urbanen Oberflächen aus hyperspektralen Bilddaten, der im Laufe der letzten Jahre am GFZ Potsdam in der Sektion Fernerkundung entwickelt wurde (Roessner *et al.* 2001, Segl *et al.* 2003, Segl *et al.* 2006). Durch die merkmalsbasierte automatische Endmemberselektion und weitere neue Merkmale hat dieser Algorithmus mittlerweile einen sehr hohen Automatisierungsgrad erreicht. Er besteht aus einer merkmalsbasierten Identifizierung von Trainings- und Endmemberspektren der urbanen Oberflächen im Bild, gefolgt von einer *Maximum Likelihood* Klassifizierung von puren Pixeln. Im letzten Schritt wird eine nachbarschaftsgestützte, iterative, lineare spektrale Entmischung der verbliebenen Mischpixel durchgeführt. Der Prozess der Klassifizierung und der spektralen Entmischung ist in **Abbildung 3–21** graphisch dargestellt. Die Berechnungen erfolgen auf den Hyperspektraldaten und werden bei allen Teilschritten von einer Gebäudemaske unterstützt, die durch Anwendung eines Schwellenwertes auf das nDOM erzeugt wurde (Kap. 3.3.2). So wird beispielsweise eine Vorauswahl der Klassen vorgenommen, so dass Pixel innerhalb der Gebäudemaske nicht mit ebenerdigen Oberflächenklassen klassifiziert werden können und solche außerhalb der Gebäudemaske nicht mit Dachmaterialien. Die aktuelle Version dieses mehrstufigen Algorithmus wird im Folgenden genauer erläutert. Sie wurde für die Prozessierung des Berliner HyMap-Streifens eingesetzt, dessen Ergebnisse gezeigt werden. Die Dresdner Daten wurden mit einer früheren Version prozessiert, die methodisch gleich, aber in Teilen weniger automatisiert war.




Abbildung 3–21 Ablaufdiagramm der Klassifizierung und spektralen Entmischung. Die Fälle 1, 2 und 3 nachbarschaftsbedingt unterschiedlicher Endmemberkombinationen werden in **Abbildung 3–27** auf Seite 83 erläutert.

3.4.3.1 Merkmalsbasierte Identifizierung von Trainingspektren und Endmemberspektren

Für die Klassifizierung von puren Pixeln (2. Schritt) werden Bild-Trainingspixel benötigt, für die Entmischung (3. Schritt) Bild-*Endmember*. Wie in Kap. 3.4.3.2 gezeigt wird, werden die *Endmember* durch Mittelung der klassifizierten und in Subklassen eingeteilten Trainingspixel erzeugt. Zur Bestimmung der Trainingspixel wurde am GFZ Potsdam der merkmalsbasierte, Paarweise-*Maximum-Likelihood*-Klassifizierer (pMLK) entwickelt (**Abbildung 3–22** und **Abbildung 3–23**). Der pMLK ist in der Lage, die Trainingspixel vollautomatisch in einer ihm

unbekannten Bildszene zu selektieren. Er stellt eine überwachte Methode dar und wurde mit einer umfangreichen Trainingsmenge aus manuell selektierten Bildspektren aus derzeit insgesamt 8 HyMap-Datensätzen von Berlin, Dresden, Potsdam und München sowie aus im Labor und im Gelände gemessenen Spektren aufgebaut, die zahlreiche klasseninterne spektrale Variationen der urbanen Oberflächen und durch die oben genannten Störgrößen in Fernerkundungsaufnahmen bedingte Variationen beinhaltet.

Der pMLK unterscheidet die urbanen Oberflächenklassen anhand von spektralen Merkmalen. Im Gegensatz zu Klassifizierungen, die direkt auf den Reflexionswerten vorgenommen werden, bringen abgeleitete spektrale Merkmale das Potenzial mit sich, robust gegenüber spektralen Variationen der Oberflächenarten und gegenüber Störeffekten zu sein (Heiden *et al.* 2007). Je größer dabei die oben genannte Vielfalt an Trainingsspektren ist, desto sicherer ist es, dass der pMLK nur aus robusten spektralen Merkmalen aufgebaut wird. Die zur Verfügung stehende Grundmenge an berechneten Merkmalen bilden dabei Ratios und Absorptionsbandentiefen sowie Koeffizienten von Polynomapproximationen, Mittelwerte und Standardabweichungen, die jeweils über verschiedene spektrale Intervalle berechnet werden.

Der Klassifizierungsprozess des pMLK besteht aus zahlreichen Einzelklassifizierungen mit ML-Klassifizierern, die jeweils nur 2 Klassen unterscheiden (**Abbildung 3–23**). Jede Klassenpaarung erhält einen eigenen ML-Klassifizierer. Dieser Aufbau macht einen zusätzlichen Schritt – die Ableitung der letztendlichen Klassifizierungsentscheidung aus den Ergebnissen der einzelnen Paarweisklassifizierer (s. S. 77) – notwendig, besitzt jedoch einen großen Vorteil gegenüber der gleichzeitigen Klassifizierung aller Klassen mit einem einzigen Klassifizierer: Jede Paarweisklassifizierung kann in einem optimierten Merkmalsraum von geringer Dimensionalität stattfinden. Dies ist besonders dann sinnvoll, wenn die Anzahl der Klassen besonders groß ist oder die Trainingsmengen der Klassen besonders klein. Da nicht alle Klassen mit den gleichen Merkmalen unterschieden werden können, steigt die Anzahl der benötigten Merkmale bei einer gleichzeitigen Klassifizierung aller Klassen mit der Anzahl dieser. Bei einer begrenzten Trainingsmenge führt dies ab einer gewissen Dimensionalität des Merkmalsraums zum Absinken der Klassifizierungsgenauigkeit (Hughes 1968). Dies kann durch eine Reduktion der Klassenanzahl auf 2 Klassen pro Teilklassifizierer vermieden werden.

Der wichtigste Schritt zum Aufbau des pMLK ist die Merkmalsselektion. Diese wird für jeden Paarweisklassifizierer einzeln durchgeführt. Aus dem berechneten Repertoire spektraler Merkmale wird in einem iterativen Prozess, basierend auf den Trainingsspektren, eine Anzahl von Merkmalen ausgewählt, anhand derer ein Klassenpaar optimal unterschieden werden kann. Dies wird für alle möglichen Paarungen von je zwei Oberflächenarten durchgeführt. Der Auswahlprozess wird mit der *Sequential Forward Selection* (SFS) Strategie (Reunanen 2006: Kap. 4.3.2) durchgeführt. Er startet (**Abbildung 3–22**), indem alle vorhandenen Merkmale einzeln für eine ML-Klassifizierung des Klassenpaares benutzt werden, also jeweils mit einem 1-dimensionalen Merkmalsraum. Das Merkmal, das den geringsten *Omission* Fehler für beide Klassen liefert (Mittelwert), wird in die Merkmalsliste des Klassenpaares geschrieben. Wenn mehrere Merkmale eine fehlerfreie Trennung der Biotoptypen liefern, wird das Merkmal ausgewählt, bei dem die Bhattacharyya Distanz zwischen den beiden Biotoptypen im Merkmalsraum am größten ist. Im zweiten Durchgang werden die verbliebenen Merkmale erneut durchlaufen und jeweils eines von ihnen mit dem ersten Merkmal aus der Merkmalsliste zu einem 2-dimensionalen Merkmalsraum kombiniert. Wiederum werden ML-Klassifizierungen des Klassenpaares durchgeführt und dasjenige Merkmal, das in Kombination mit dem zuerst ausgewählten den geringsten Fehler erzeugt, in die Merkmalsliste geschrieben. Dieser Vorgang wird mehrfach wiederholt. Am Ende steht für jedes Klassenpaar eine Merkmalsliste, mit der das Paar bezogen auf einen ML-Klassifizierer

optimal getrennt werden kann. So wird pro Klassenpaar nur eine geringe Anzahl spezifischer Merkmale benötigt im Gegensatz zu einer gleichzeitigen Klassifizierung aller 67 Oberflächenarten, bei der sich das Hughes-Phänomen negativ auf die Klassifikationsgenauigkeit auswirken würde. Der iterative Selektionsprozess der Merkmale wird durch eine der drei Abbruchbedingungen gestoppt:

- das Klassenpaar wird fehlerlos getrennt,
- die Klassifizierungsgenauigkeit verbessert sich nicht mehr von einer Iteration zur nächsten, d.h. keines der verbliebenen Merkmale ist in der Lage, die Trennbarkeit des Klassenpaares weiter zu erhöhen,
- eine maximale Anzahl an Iterationen wurde durchlaufen. Diese Anzahl sollte mit Blick auf die Menge an Trainingspektren der Klassen festgelegt werden, um das Hughes-Phänomen („the curse of dimensionality“) zu vermeiden.




Abbildung 3–22 Ablauf der iterativen Merkmalsselektion (n = Anzahl vorhandener Merkmale).

Der weitere Aufbau und die Funktionsweise des pMLK werden anhand eines Beispiels erklärt (**Abbildung 3–23**): Der Anwendung des pMLK auf ein Pixel eines hyperspektralen Datensatzes. Da die oben beschriebene Merkmalsselektion und die Kalibrierung der ML-Klassifizierer (Berechnung der Mittelwertvektoren und Kovarianzmatrizen der Klassen) im Vorfeld anhand von Trainingsdaten erfolgt ist, müssen an dieser Stelle nur diejenigen spektralen Merkmale aus dem Spektrum des Pixels berechnet werden, die in einer der Merkmalslisten enthalten sind. Jede Merkmalsliste spannt einen angepassten Merkmalsraum für eine ML-Klassifizierung einer Klassenpaarung auf. Als Ergebnis jeder dieser Klassifizierungen erhalten beide Klassen eine Bayes’sche Wahrscheinlichkeit. Die Gewinnerklasse wird nun durch die sukzessive Anwendung eines Minimum- und eines Maximumoperators ermittelt. Zunächst ergibt sich die Wahrscheinlichkeit, dass ein Pixel einer Klasse X angehört, aus dem Minimum der Wahrscheinlichkeiten, die die

Klasse bei den paarweise durchgeführten ML-Klassifizierungen mit den übrigen Klassen erhalten hat. Auf diese Weise werden die Zugehörigkeitswahrscheinlichkeiten des Pixels zu allen Oberflächenklassen berechnet. Die Klasse mit der höchsten Zugehörigkeitswahrscheinlichkeit (Maximumoperator) wird am Ende zusammen mit dieser als Gewinnerklasse abgespeichert.




Abbildung 3–23 Anwendung des pMLK zur Klassifizierung eines Pixels.

Die Aufgabe des pMLK ist die automatische Selektion von Bild-Trainingspixeln und Bild-*Endmembers*. Da diese entscheidend für die nachfolgende Klassifizierung und spektrale Entmischung sind, ist es wichtig, dass dieser Schritt möglichst ohne Fehlzuweisungen erfolgt¹³. Um dies sicherzustellen, wird ein Schwellenwert auf die berechneten Zugehörigkeitswahrscheinlichkeiten angewandt. Ein Schwellenwert von 51 % würde beispielsweise bewirken, dass nur diejenigen Pixel selektiert werden, bei denen die Gewinnerklasse alle paarweise getroffenen ML-Entscheidungen gewonnen hat¹⁴. Um einen sicheren Schwellenwert festzulegen, werden die in **Abbildung 3–24** gezeigten Diagramme ausgewertet. Sie zeigen auf Zehnerschritte zusammengefasste Histogramme der berechneten Zugehörigkeitswahrscheinlichkeiten der Pixel des Berliner HyMap-Datensatzes zu den entsprechenden Klassen. Jede Kurve wurde durch Division durch ihren Maximalwert normiert. Für problemlos erkannte Klassen zeigt die Kurve hohe Werte bei einer Zugehörigkeitswahrscheinlichkeit von >90 % und sinkt mit abnehmender Zugehörigkeitswahrscheinlichkeit ab (**Abbildung 3–24**, oben). Ein späterer Wiederanstieg deutet auf einen *Commission Error* in der Klassenzuweisung hin. Dies gilt es durch einen vor dem Wiederanstieg gesetzten Schwellenwert zu verhindern.

Bei den meisten Klassen (**Abbildung 3–24**, oben) erfolgt der Wiederanstieg erst bei Wahrscheinlichkeiten unter 30 %. Bei den in **Abbildung 3–24** (links unten) gezeigten Klassen erfolgt er früher, so dass sich die Festlegung eines Schwellenwerts an diesen Klassen orientieren sollte. Um den Algorithmus weitgehend automatisiert zu halten, wird darauf verzichtet, für jede Klasse einen spezifisch optimierten Schwellenwert zu finden. Bei einem Wert von 75 % treten quasi keine Fehlzuweisungen mehr auf (visuell kontrolliert) und gleichzeitig wird für jede Klasse eine mehr als ausreichende Menge an Trainingspixeln selektiert (34 % des HyMap-Streifens werden so als Bild-Trainingspixel selektiert). Somit gibt es einen großen Spielraum für eine deutlich restriktivere Anwendung des Schwellenwerts auf die Zugehörigkeitswahrscheinlichkeiten. Werte zwischen 75 % und 95 % erscheinen hier als praktikabel.

¹³ Eine Validierung der erreichbaren Genauigkeit wurde mittels einer simulierten urbanen Bildszene durchgeführt und wird am Ende dieses Kapitels beschrieben.

¹⁴ Da die Zugehörigkeitswahrscheinlichkeit einer Klasse aus dem Minimumwert der Baysschen Wahrscheinlichkeiten berechnet wird, die die Klasse bei den Paarweise-ML-Entscheidungen erhalten hat, kann es durchaus vorkommen, dass die Gewinnerklasse eines Pixels eine sehr geringe Zugehörigkeitswahrscheinlichkeit besitzt.

Bei bestimmten Klassen hat eine visuelle Überprüfung im Bild zahlreiche Fehlzuweisungen ergeben. Eine Betrachtung der zugehörigen Histogrammverläufe zeigt, dass diese Problemklassen sehr geringe Werte bei einer Zugehörigkeitswahrscheinlichkeit von $>90\%$ aufweisen oder insgesamt nur sehr wenige Pixel mit $>90\%$ Wahrscheinlichkeit erkannt wurden (**Abbildung 3–24**, rechts unten). Letzteres gilt für die Klassen `runk1` und `runk2`¹⁵ und ist in der normierten Darstellung nicht sichtbar. Die Untersuchung der Histogrammverläufe ist somit eine einfache Möglichkeit, um problematische Klassen zu identifizieren.

Viele dieser nicht erkannten Klassen (`pdlc`, `rbitr`, `rcop`, `rfac`, `rtar`) sind im Berliner Untersuchungsgebiet auch nicht präsent. Sofern der gesetzte Schwellenwert nicht ausreicht, um eine Zuweisung dieser Klassen vollständig zu verhindern, müssen sie manuell aus dem Bild entfernt werden. Bei insgesamt sechs Klassen (`rgla`, `rgla2`, `runk1`, `runk2`, `vdec` und `sveg`) hat der pMLK offensichtlich Probleme bei der Erkennung – hier wurden kaum oder keine Pixel korrekt erkannt. Die diesen Klassen zugewiesenen Pixel müssen aus dem Bild entfernt werden und korrekte Pixel in Form von manuell digitalisierten ROIs neu hinzugefügt werden. Die Klasse `sveg`, deren Histogrammkurve einen „normalen“ Verlauf zeigt, bildet eine Ausnahme. Hier wurden zwar sehr viele Pixel korrekt erkannt, jedoch wurden Wasserpflanzen (z.B. Seerosen, Schilfgürtel etc.), die nicht als eigene Klasse implementiert waren, ebenfalls als `sveg` klassifiziert. Eine Abgrenzung durch den Schwellenwert war nicht möglich, so dass auch diese Klasse aus dem Bild entfernt werden musste und korrekte Pixel in Form von manuell digitalisierten ROIs hinzugefügt werden mussten.




Abbildung 3–24 Histogramme der Zugehörigkeitswahrscheinlichkeiten. Um die Histogramme mehrerer Klassen übersichtlich in einem Diagramm darzustellen, wurde von der üblichen Darstellung als Balkendiagramm abgewichen. Weiterhin wurde jede Kurve durch Division durch ihren Maximalwert auf den Wertebereich 0-1 normiert.

¹⁵ Eine Übersicht der Klassenkürzel befindet sich im Anhang A.

Für die weitere Verarbeitung werden die durch den pMLK gefundenen Trainingspixel der Oberflächen in Subklassen eingeteilt (s.u.). Die Trainingsspektren dieser Subklassen werden dann bei der ML-Klassifizierung purer Pixel verwendet. Durch Mittelung der Subklassen werden Endmemberspektren erzeugt, die im letzten Schritt die Basis der linearen spektralen Entmischung bilden.

3.4.3.2 Maximum Likelihood Klassifizierung von reinen Pixeln

Pure Pixel sind als solche Pixel definiert, deren Fläche vollständig von einem Material bedeckt ist. In der Realität existieren solche Pixel nur selten, da die Wirklichkeit auf fast jeder Maßstabsebene eine Mischung aus einzelnen Komponenten darstellt (Clark 1999: 36). So ist die Klasse Boden beispielsweise eine Mischung aus organischen und anorganischen Bestandteilen und in Pixeln eines Hausdachs befinden sich häufig Fenster, Schornsteine und Antennen, die in der Maßstabsebene eines Fernerkundungsbildes mit 3,5 m Pixeln häufig nicht sichtbar sind bzw. vernachlässigbare Flächenanteile der Pixel bedecken. Bei einer Klassifizierung, die unter einer bestimmten Fragestellung durchgeführt wird, kann es allerdings sinnvoll sein, die Klasse Boden zu verwenden und nicht die Anteile der organischen und anorganischen Bodenbestandteile zu bestimmen, genauso wie es sinnvoll sein kann, die Fenster, Schornsteine und Antennen eines Hausdaches zu vernachlässigen und das gesamte Dach mit dem vorherrschenden Material der Dachbedeckung zu klassifizieren. Dies entscheiden die Maßstabsebene der Bilddaten und der Hintergrund der Fragestellung, so dass der Begriff „pures Pixel“ jeweils auf eine bestimmte Maßstabsebene und Fragestellung zu beziehen ist. Ein weiteres Beispiel einer urbanen Oberfläche macht dies deutlich: Die Oberflächenart Bahngleis besteht aus mehreren Materialien wie Eisen, Schotter und wahlweise Holz oder Beton für die Schwellen. Keiner dieser Bestandteile ist so groß, dass er bei der vorliegenden Maßstabsebene ein ganzes Pixel alleine bedecken könnte. Unter spektralen Gesichtspunkten gibt es also kein „pures“ Pixel der Klasse Bahngleis, da sie immer eine Mischung aus mehreren Materialien darstellt. Eine Entmischung der Bahngleispixel mit den einzelnen Materialien wäre zwar möglich, ist jedoch nicht im Sinne der Fragestellung. Daher wird in dieser Arbeit unter Berücksichtigung der Maßstabsebene und Fragestellung ein Pixel als „pur“ bezeichnet, wenn es vollständig oder nahezu vollständig von einer *thematischen* urbanen Oberflächenart bedeckt ist, auch wenn diese auf einer Maßstabsebene, die von den Fernerkundungsdaten nicht aufgelöst werden kann, eine Mischung aus einzelnen Materialien darstellt.

Die Klassifizierung der reinen Pixel wird mit einem ML-Klassifizierer umgesetzt. Dieser ist insbesondere dann eine geeignete Wahl, wenn eine für die Dimensionalität des Merkmalsraumes ausreichend große Menge an Trainingsdaten zur Verfügung steht, um die statistischen Verteilungen der Klassen abzuschätzen und wenn angenommen werden kann, dass diese Verteilungen einer Normalverteilung nahekommen. Die erste Bedingung ist nach der Anwendung des pMLK gegeben. Um die zweite Bedingung zu erfüllen, werden die Klassen einem Verteilungstest unterzogen und gegebenenfalls in Subklassen aufgeteilt (Segl 1996: Kap. 4.2.1 + 4.3). Die Existenz dieser Subklassen ist aufgrund der Vielfalt der urbanen Materialien, unterschiedlicher Herstellungsarten, Farbzusätzen, Engoben usw. zu erwarten und wird durch eine Betrachtung der Pixelvektoren der Trainingsspektren der Klassen im Merkmalsraum bestätigt. Die Subklassenbildung wird durch folgende Parameter gesteuert:

- Maximale Anzahl an Subklassen.

- Mindestanzahl benachbarter Bild-Trainingspixel. Wird diese unterschritten, werden die entsprechenden Pixel verworfen. Der Parameter schützt vor der Verwendung von Mischpixeln als Trainingspixel, da eine Mindestanzahl benachbarter Pixel der gleichen Klasse eine Mindestgröße des Geoobjekts garantiert und einzelne, verstreute Pixel ausgeschlossen werden.
- Einen Schwellenwert, der zur Annahme oder Ablehnung der Nullhypothese (Vorliegen einer Normalverteilung) führt (Segl 1996: S. 45).

Die Steuerparameter können *a priori* mit klassenbezogenem Vorwissen und damit unabhängig vom analysierten Datensatz festgelegt werden. Dadurch bleibt der Algorithmus weitgehend vollautomatisch.

Anschließend werden die Parameter der ML-Klassifizierer mit den Klassenstatistiken der in Subklassen eingeteilten Trainingspixel berechnet. Damit der Klassifizierer ausschließlich pure Pixel klassifiziert, wird ein klassenspezifischer *Purity-Check* durchgeführt (**Abbildung 3–25**). Hierbei werden automatisch berechnete Schwellenwerte auf die Mahalanobis-Distanzen der Klassen angewendet. Der maximale Schwellenwert ergibt sich aus der Mahalanobis-Distanz desjenigen Trainingspixel-Vektors einer Klasse, das im Merkmalsraum die größte Distanz zum Klassenzentrum aufweist. Um die Sensibilität dieser Berechnung gegenüber Ausreißern zu reduzieren, kann ein vom Klassenzentrum aus betrachtetes Quantil von Pixelvektoren festgelegt werden, auf dessen Basis die Berechnung des Schwellenwertes erfolgen soll. Das 80 %-Quantil lieferte hier, visuell kontrolliert, gute Ergebnisse. Diese Überprüfung auf Reinheit wird auf alle einer Klasse zugewiesenen Pixel angewendet, also auch auf die zuvor vom pMLK selektierten Pixel. Deren Überprüfung kann erst an dieser Stelle der Prozessierungskette nach der Subklassenbildung durchgeführt werden, weil die durch den pMLK gefundenen Hauptklassen häufig keine Normalverteilung aufweisen. Ein Vergleich der Zwischenergebnisbilder nach dem pMLK und nach der ML-Klassifizierung purer Pixel zeigt, dass nach der ML-Klassifizierung neue Pixel klassifiziert wurden, aber auch durch den pMLK gefundene Trainingspixel wieder verworfen wurden. Diese beiden Effekte heben sich in der Menge auf, so dass die als pur klassifizierten Pixel nach diesem Schritt weiterhin 34 % des Berliner HyMap-Streifens belegen. Die verbliebenen Mischpixel werden im folgenden Schritt spektral entmischt.

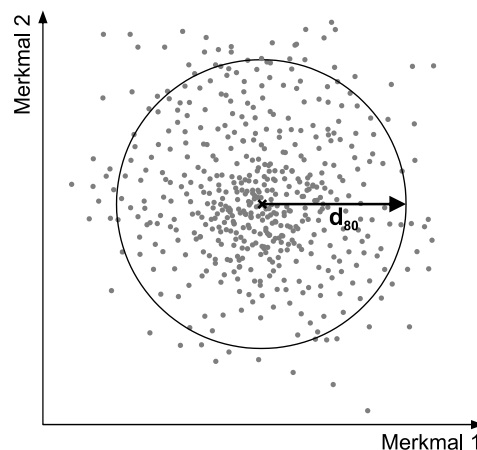


Abbildung 3–25 Prinzipskizze des *Purity-Check*, gezeigt an einem 2-dimensionalen Merkmalsraum. Zur vereinfachten Darstellung besitzt die Klasse in beiden Dimensionen die gleiche Varianz. Der gezeigte Schwellenwert d_{80} entspricht der größten Mahalanobis-Distanz des vom Klassenzentrum betrachteten 80 %-Quantils.




Abbildung 3–26 Klassifizierte Pixel nach Anwendung des pMLK und nach der ML-Klassifizierung purer Pixel im Vergleich. Die Klassen sind in der Darstellung zu thematischen Hauptklassen zusammengefasst. Eine Legende befindet sich im Anhang A.

3.4.3.3 Nachbarschaftsgestützte, iterative, lineare spektrale Entmischung

Es sind nur wenige Algorithmen bekannt, mit denen eine detaillierte spektrale Entmischung von urbanen Oberflächen möglich ist. In einem aktuellen Fachbuch publizieren Weng & Lu (2007) eine spektrale Entmischung einer urbanen Landschaft unter Verwendung von Landsat TM und ETM+ Daten mit einem 4-*Endmember*-Modell: Vegetation, hohe Albedo, niedrige Albedo und Boden. In ihrem Fazit schlagen sie 3 Punkte zur Weiterentwicklung vor: Die Verwendung von Referenz-*Endmembers*, von Endmembersets und von Hyperspektraldaten. Alle 3 Punkte sind bereits in dem von Roessner *et al.* (2001) publizierten und hier verwendeten Verfahren berücksichtigt.

Die Anwendung eines linearen spektralen Entmischungsmodells mit allen 67 *Endmembers* bei der Entmischung eines Pixels liefert keine brauchbaren Ergebnisse und ist auch unter logischen Gesichtspunkten nicht sinnvoll. Daher wurden Verfahren entwickelt, die die Anzahl der *Endmember* pro Pixel auf ein Maximum beschränken, wobei die jeweiligen *Endmember* bei der Entmischung eines Pixels aus der Gesamtmenge der zur Verfügung stehenden *Endmember* frei gewählt werden können (Roberts *et al.* 1998, Roessner *et al.* 2001). Beide genannten Verfahren unterstützen dabei auch mehrere spektrale Variationen pro *Endmember* (Endmembersets). Die oben beschriebene Entmischung der in **Abbildung 3–20** (S. 74) dargestellten Mischspektren zeigte, dass die berechneten Anteile bei der richtigen Kombination der *Endmember* korrekt waren, bei der Entmischung mit anderen spektralen Variationen der beiden *Endmember* jedoch deutlich daneben lagen. Diese Erkenntnis lässt nun einer Aufgabe große Bedeutung für die Richtigkeit der Ergebnisse zukommen: Zunächst der Auswahl der im Pixel vorkommenden *Endmember* und darüber hinaus der Auswahl derjenigen spektralen Variation der *Endmember*, die tatsächlich im Pixel vorkommt. Diese Auswahl wird auf drei Arten gesteuert:

- I. Durch die Begrenzung auf 2 *Endmember* pro Pixel bei der Entmischung. Eine solche Reduzierung der Endmemberanzahl im Mischungsmodell wird auch von anderen Autoren propagiert (z.B. Dennison & Roberts 2003). Die Festsetzung auf 2 *Endmember* bezieht sich auf Fernerkundungsdaten mit einer sehr hohen räumlichen Auflösung. Bei Pixelgrößen im Meterbereich sind selten mehr als zwei Oberflächenarten in einem Pixel enthalten. Dies wird durch die Ausführungen zur Validierung der Entmischung mit einer künstlichen Szene am Ende des Kapitels belegt.

- II. Durch eine automatisch generierte Liste erlaubter Endmemberkombinationen. Diese erlaubt es zum Beispiel, bestimmte Kombinationen, die mit geringer Wahrscheinlichkeit auftreten, auszuschließen (z.B. Wasser + Dachmaterial).
- III. Durch die Nachbarschaft des zu entmischenden Pixels. In **Abbildung 3–27** sind die Pixel A, B und C bereits als pure Pixel klassifiziert. Die Fälle 1, 2 und 3 skizzieren die drei möglichen Situationen, bei denen in der 3x3-Nachbarschaft eines zu entmischenden Pixels zwei oder mehr bereits klassifizierte Pixel, genannt Saatpixel (engl.: *seedling pixel*), existieren oder im zweiten Fall nur ein bzw. im dritten Fall kein Saatpixel existiert.

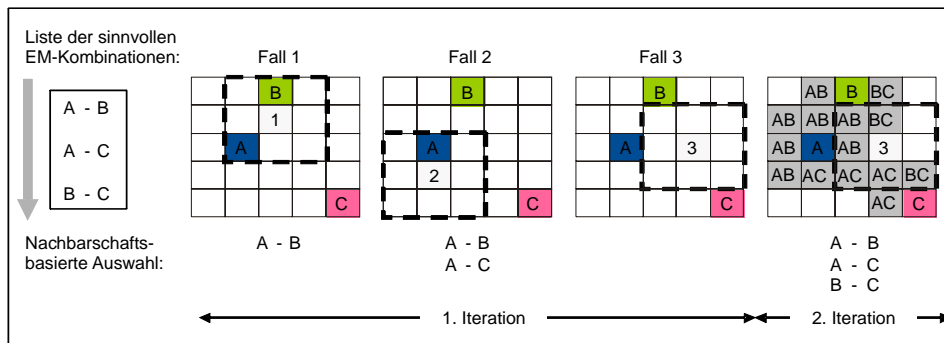


Abbildung 3–27 Drei Fälle der nachbarschaftsbasierten Auswahl von Endmemberkombinationen zur linearen spektralen Entmischung eines Pixels (ins Deutsche übersetzt aus: Roessner *et al.* 2001).

Im ersten Fall ist es sehr wahrscheinlich, dass das Mischpixel eine Mischung der beiden *Endmember* A und B ist, weshalb diese Kombination zuerst getestet wird. Kann aus den beiden *Endmembern* A und B ein linear gemischtes Spektrum erzeugt werden, dessen kleinste quadratische Abweichung (RMSE) zum Spektrum des Mischpixels den gesetzten Schwellenwert von 5 % Reflexion unterschreitet, so wird diese Mischung als Ergebnis festgehalten. Die entsprechenden Flächenanteile der beiden *Endmember* werden für dieses Pixel in die Ergebnislayer der beiden Klassen geschrieben. Genügt keine Mischung dem Kriterium, werden alle Endmemberkombinationen aus der Liste getestet, die entweder A oder B enthalten. Erst wenn auch diese Kombinationen abgelehnt wurden, werden schließlich alle übrigen Kombinationen getestet. Erfüllt keine Kombination das gesetzte Kriterium, bleibt das Pixel unklassifiziert.

Im zweiten Fall werden zunächst alle Endmemberkombinationen aus der Liste getestet, die *Endmember* A enthalten. Bei der Suche nach dem zweiten *Endmember* treten häufig Probleme in beschatteten Flächen auf. Statt dem zweiten *Endmember* Schatten wird hier oft ein Wasser-*Endmember* ausgewählt. Um dies zu vermeiden, wird die Bedingung eingeführt, dass ein Wasser-*Endmember* nicht als zweiter *Endmember* hinzugenommen werden darf, wenn keines der Nachbarpixel die Klasse Wasser bereits enthält. Diese Bedingung gilt auch für Fall 1 und Fall 3. Falls keine der Kombinationen mit *Endmember* A den gesetzten RMSE-Schwellenwert einhält, werden schließlich auch hier alle übrigen Kombinationen getestet, jedoch ohne die Wasser-*Endmember*.

Der dritte Fall wird in der aktuellen Iteration der Entmischung zurückgestellt. Auf diese Weise startet die Entmischung in der Nachbarschaft der Saatpixel und wächst von Iteration zu Iteration in den noch nicht entmischten Raum hinein. Der Fall 3 in **Abbildung 3–27** würde so bereits in der zweiten Iteration entmischert werden. Hier würden zunächst alle Kombinationen der *End-*

member getestet werden, die in den Nachbarpixeln enthalten sind, die in der ersten Iteration entmischt wurden.

Als Ergebnis der Entmischung werden die Flächenanteile der urbanen Oberflächenklassen in eigene Rasterlayer abgelegt. **Abbildung 3–28** zeigt Ausschnitte dieser *Layer*. Zur visuellen Überprüfung der Ergebnisse wurde eine Klassifizierung der Bildpixel mit der Klasse des größten Anteils durchgeführt. Diese wird in **Abbildung 3–29** gezeigt.




Abbildung 3–28 Ausschnitte der Entmischungslayer der Klassen rote Tonziegel (neu), Polyethyldach, Asphalt, Bahngleise, Fluss, Laubbäume und Schatten auf vegetationsfreien Flächen. Die Graustufen drücken die Flächenanteile der Klassen am Pixel aus. Weitere Beispiele befinden sich im Anhang C (Abb. C–6).




Abbildung 3–29 Ausschnitt einer aus den Entmischungsergebnissen abgeleiteten Klassifizierung. Abbildung C–5 im Anhang C zeigt eine Gesamtansicht für das Untersuchungsgebiet Berlin, die Abbildungen C–1 und C–2 zeigen entsprechende Darstellungen für Dresden. Im rechten, oberen Bild wurden die Klassen thematisch zu Hauptklassen zusammengefasst. Die unteren Bilder zeigen die einzelnen Klassen der Dachmaterialien (links) und der übrigen Klassen (rechts) in einer detaillierteren Aufschlüsselung, wobei die jeweils andere Gruppe grau bzw. weiß unterlegt ist. Entsprechende Legenden befinden sich im Anhang A.

3.4.3.4 Validierung der Klassifizierung und spektralen Entmischung mit einer simulierten Szene

Die Genauigkeit von Klassifizierungsergebnissen wird in der Regel durch die Berechnung einer Konfusionsmatrix ermittelt (Congalton 1991, Smits *et al.* 1999). Zur Validierung von Entmischungsergebnissen auf Subpixelebene sind grundsätzlich zwei Ansätze denkbar: Ein pixelorientierter Ansatz und ein flächenstatistischer Ansatz (Campbell 1996: 380ff.)¹⁶. Heiden (2004: 72) gibt einen Überblick über verschiedene flächenstatistische Ansätze. Diese haben den Nachteil, dass ihre Genauigkeitsaussagen lageunspezifisch sind und sich Fehler in der Fläche gegenseitig rausmitteln können. Daher werden flächenstatistische Parameter in dieser Arbeit nur als Indiz verwendet. Die eigentliche Genauigkeitsuntersuchung soll pixelbasiert und somit lagespezifisch erfolgen.

¹⁶ Bei Campbell als *site-specific and non-site-specific accuracy assessment* bezeichnet.

Die pixelbasierte Validierung von Flächenanteilen im Subpixelbereich setzt eine exakte Lokalisierung der entmischten Pixel in einem Referenzdatensatz (z.B. einem hochauflösenden Luftbild) voraus. Dies kann sich als äußerst schwierig darstellen, weshalb bisher in vielen Untersuchungen – mangels Alternative – nur flächenstatistische Parameter herangezogen wurden. Zwar ist es möglich, aus einem hochauflösenden Referenzdatensatz die Oberflächenmaterialien manuell zu digitalisieren. Bei der Überlagerung dieser mit dem entmischten Bild treten jedoch räumliche Lagefehler auf, die von der Genauigkeit der Georeferenzierung beider Datensätze abhängen. Nach dem derzeitigen Stand der Technik können flugzeuggetragene Scannerdaten mit einer Genauigkeit von etwa einem Pixel (ca. 3-5 m) georeferenziert werden (s. Kap. 3.4.2). Gerade an den Grenzen von Geoobjekten, an denen die Mischpixel liegen, kann sich die Zusammensetzung eines Mischpixels innerhalb dieser kurzen Entfernung stark ändern. Bei einem pixelorientierten Ansatz zur Validierung der berechneten Flächenanteile würden diese Abweichungen der Flächenanteile als Fehler der Entmischung interpretiert werden, obwohl es sich um Fehler in der Georeferenzierung handelt. Deshalb ist eine exakte pixelbasierte Überprüfung der Flächenanteile mit realen Datensätzen nicht möglich. Daher wird das beschriebene Verfahren zur Klassifizierung und Entmischung zwecks seiner Genauigkeitsüberprüfung auf ein simuliertes Bild mit der räumlichen, spektralen und radiometrischen Auflösung des HyMap-Sensors angewendet. Diese künstlich erzeugte Bildszene birgt gegenüber einer echten Szene den großen Vorteil, dass die Flächenanteile *aller* Pixel *exakt* bekannt sind. Dadurch wird auch eine exakte pixelorientierte Validierung der Entmischungsergebnisse möglich. Die Erzeugung der künstlichen HyMap-Szene ist in **Abbildung 3–30** skizziert und wird im Folgenden beschrieben.




Abbildung 3–30 Erzeugung einer künstlichen Stadtscene zur Validierung des spektralen Entmischungsverfahrens. $V \rightarrow R$ = Vektor-Raster-Konvertierung.

Der Grundriss der künstlichen Szene wurde durch manuelle Digitalisierung der urbanen Oberflächen einer realen Stadtlandschaft (1 km² von Dresden) aus Luftbildern erstellt. Die Mindestgröße der erfassten Objekte (Flächenfalle) wurde auf 50 x 50 cm festgelegt, also 1/49 eines 3,5 m HyMap-Pixels bzw. einem Flächenanteil von 2,04 %. Objekte, für die derzeit keine spektralen Signaturen als *Endmember* vorliegen (z.B. Autos), wurden nicht erfasst. Dachflächen mit unterschiedlicher Exposition wurden als separate Flächen digitalisiert, um ihnen später entsprechend passende Spektren zuweisen zu können. Es wurde kein Schlagschatten der erhöhten Geoobjekte einberechnet.

Zur Erzeugung der künstlichen HyMap-Szene wurde diese digitale Vektorlandschaft mit einer Auflösung von 50 x 50 cm gerastert (50cm-Rasterreferenzbild). Die Pixel enthalten als Grauwert die ID der jeweiligen urbanen Oberflächenart. In die Pixel des 50cm-Rasterreferenzbilds

wurden anschließend zufällig ausgewählte HyMap-Spektren der entsprechenden urbanen Oberflächen aus einer spektralen Bibliothek eingesetzt (50cm-Hyperspektralbild). Beide Bilder – das 50cm-Rasterreferenzbild und das 50cm-Hyperspektralbild – wurden mit einem normalverteilten Filterkernel abgetastet (**Abbildung 3–32**), der der *Point Spread Function* (PSF) des HyMap-Sensors entspricht. Als Ergebnis dieser Abtastungen erhält man zum einen die Flächenanteile der urbanen Oberflächenarten F_{HyMap} , wie sie der HyMap-Sensor unter Berücksichtigung der Sensor-PSF „sehen“ würde und die simulierte HyMap-Szene, auf die das Verfahren zur spektralen Entmischung angewendet wird. Das Ergebnis der Entmischung sind die Flächenanteile F_{unmix} . Die räumliche Auflösung von Fernerkundungsbildern wird über die *Full Width Half Maximum* (FWHM) und die *Ground Sampling Distance* (GSD) der Filterabtastung gesteuert. Die FWHM des Filterkernels und die GSD wurden bei der Abtastung auf 3,5 m, also auf 7 Pixel der 50cm-Bilder eingestellt, was der maximalen räumlichen Auflösung des HyMap-Sensors entspricht. Die volle Größe des normalverteilten Filters wurde auf 19x19 Pixel festgelegt. So enthält der Filter 99,7 % (dreifache Standardabweichung) des Signals der eigentlichen PSF, was hinreichend genau ist.

Dass sich die reflektierte Strahlung der Oberflächen in einem Pixel *linear mischt* und dass somit das spektrale Signal eines Pixels zur Bestimmung der Flächenanteile der Oberflächen *linear entmischt* werden kann, ist eine in der Realität nicht immer zutreffende, aber notwendige Annahme. Die Nichtlinearität kann z.B. durch Transmissionen oder Mehrfachreflexionen verursacht werden (Schowengerdt 1997: 447 ff.). Die Art der Mischung, d.h. auf welche Weise die Materialien miteinander vermischt sind, spielt eine große Rolle. Nach (Clark 1999: 36) findet bei einer Mischung auf molekularer Ebene (z.B. zwei Flüssigkeiten oder eine Flüssigkeit und ein poröser Feststoff) oder einer engen Mischung feinkörniger Materialien (vgl. auch Singer 1981), genannt *intimate mixture*, immer eine nichtlineare Mischung der spektralen Signaturen der einzelnen Materialien statt. Dies trifft auch auf Beschichtungen zu, wenn das bedeckende Material nicht vollständig opak ist. Die einzige Mischungsart, bei der sich die spektralen Signaturen linear mischen, ist nach Clark eine flächenhafte Mischung, bei der die einzelnen Materialien durch scharfe Grenzen räumlich voneinander getrennt sind. Dies ist in urbanen Gebieten die vorherrschende Mischungsart. Bezieht man nun jedoch den messenden Sensor in das Modell ein, so können auch für diesen Fall nichtlineare Mischungen entstehen, wenn eine asymmetrische Verteilung der Oberflächen im Pixel vorliegt (Schowengerdt 1997: 447 ff.). Diese führt durch die PSF des Sensors zu einer unterschiedlich starken Gewichtung der spektralen Signaturen der Oberflächen in Abhängigkeit von ihrer Entfernung vom Pixelmittelpunkt (**Abbildung 3–31**). Um die durch diese Effekte entstehenden Ungenauigkeiten bei einer linearen Entmischung zu quantifizieren, wurden neben den Flächenanteilen F_{HyMap} auch die wahren Flächenanteile F_{True} aus dem 50cm-Rasterreferenzbild berechnet. Diese werden durch die Abtastung des 50cm-Rasterreferenzbilds mit einem *gleichverteilten* 7x7 Filterkernel berechnet (**Abbildung 3–32**). Die GSD und die Positionen der Filtermittelpunkte wurden dabei wie bei der Abtastung mit dem normalverteilten Filter gewählt, um eine direkte Vergleichbarkeit sicherzustellen. Der gleichverteilte Filterkernel bewirkt, dass jedes der 7x7 Pixel mit gleicher Gewichtung in die Berechnung eingeht. Aus dem flächenmäßigen Verhältnis der urbanen Oberflächen innerhalb des Filterkernels ergeben sich somit die wahren Flächenanteile F_{True} der Klassen innerhalb der Grenzen des resultierenden 3,5 m Pixels.




Abbildung 3-31 Auswirkung der Umgebungspixel und der Position einer Klasse im Pixel auf ihren Flächenanteil bei der Abtastung mit einem normalverteilten Filter. Die Abbildung zeigt vier Felder mit je 19x19 Pixeln des 50cm-Rasterreferenzbilds (Größe des normalverteilten Filters). Der Kern von 7x7 Pixeln eines jeden Feldes ist die Fläche, die vom simulierten 3,5 m Pixel überdeckt wird (entspricht der FWHM der Sensor-PSF). Die graue Testklasse füllt den 7x7 Kern im ersten Feld vollständig aus, in den übrigen Feldern beträgt ihr wahrer Flächenanteil am 3,5m Pixel 44,9 % (22 von 49 Pixeln), sie wird jedoch zentral, gleichmäßig und peripher positioniert. Nach der Filterung betragen die errechneten Flächenanteile der grauen Klasse und die relativen Abweichungen zur Wahrheit 58,4 % (-41,6 %), 32,9 % (-12,0 %), 25,9 % (-19,0 %) und 19,9 % (-25,0 %).

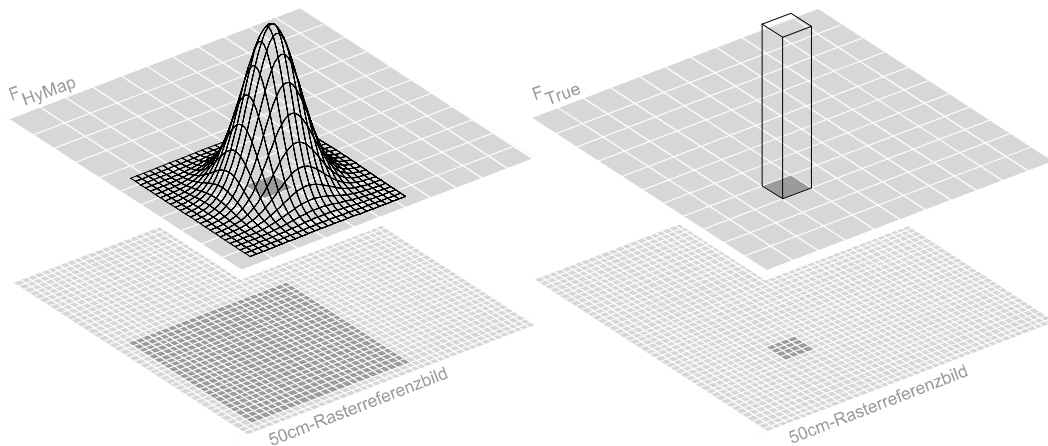


Abbildung 3-32 Abtastung des 50cm-Rasterreferenzbilds mit normal- und gleichverteiltem Filterkern zur Erzeugung von F_{HyMap} und F_{True} . Die räumliche Auflösung eines Fernerkundungsbildes entspricht der FWHM der Sensor-PSF. Dies führt dazu, dass ca. 40 % des Signals eines Pixels in seiner Umgebung aufgezeichnet wird (Fläche unter der Sensor-PSF, die nicht innerhalb der 7x7 Pixel liegt) und dass also nur 60 % von der eigentlichen Fläche des Pixels stammt.

Zusammenfassend liegen nach den Simulationsrechnungen und der Anwendung des Verfahrens zur Klassifizierung und spektralen Entmischung auf das simulierte HyMap-Bild drei Bilder mit Flächenanteilen der urbanen Oberflächen vor: F_{True} , F_{HyMap} und F_{Unmix} . Ein statistischer Vergleich der Sensorwahrheit F_{HyMap} mit der realen Wahrheit F_{True} ermöglicht nun die Quantifizierung der durch die Sensorabtastung entstehenden Fehler. Durch einen Vergleich des Entmischungsergebnisses F_{Unmix} mit der Sensorwahrheit F_{HyMap} kann dagegen die methodeninhärente Genauigkeit der Entmischungsmethode ermittelt werden. Beide Fehler tragen zu einer Verringerung der Gesamtgenauigkeit der Entmischung einer Sensoraufnahme bei. Da der hier zu erwartende Fehl-

ler nicht unbedingt die Summe aus beiden Komponenten sein muss, wird zusätzlich F_{Umix} gegen F_{True} validiert.

Wir beginnen die statistische Auswertung mit der Frage, wie viele pure und wie viele Mischpixel es in einem urbanen Fernerkundungsbild bei einer Auflösung von 3,5 m gibt. Die **Tabelle 3-7** zeigt den akkumulierten Anteil der Bildpixel der simulierten Szenen, die eine oder mehrere Oberflächenarten enthalten. Alle Pixel, bei denen eine Oberflächenart einen Flächenanteil $> 99\%$ besitzt, werden hierbei als „pur“ gezählt. Die Differenz zwischen 55,59 % und 34,64 % zeigt, dass durch die Sensorabtastung deutlich mehr Mischpixel erzeugt werden, als ein 3,5 m Raster enthalten sollte. Dieser Effekt wird auch durch ein Querprofil durch ein Gebäude dokumentiert (**Abbildung 3-33**), das die Flächenanteile des Dachendmembers für den gleich- und normalverteilten Filterkernel zeigt. Aus den Zahlen der **Tabelle 3-7** lässt sich weiterhin ableiten, wie viele *Endmember* pro Pixel im Mischungsmodell berücksichtigt werden sollten. Bezogen auf die Wahrheit (gleichverteilter Filter) deckt ein Mischungsmodell mit 2 *Endmembers* bereits 93,35 % aller Fälle ab und erscheint daher als ausreichend. **Tabelle 3-8** zeigt außerdem, dass die Flächenanteile eines eventuellen 3. *Endmembers* durchschnittlich 0,5 % betragen und damit vernachlässigbar gering sind.

Die Information über den Anteil der puren Pixel in der Szene ist weiterhin ein wichtiger Parameter bei der Klassifizierung und Entmischung. Diese kann über einen Parameter (ein Schwellenwert zur automatischen Berechnung von klassenspezifischen Schwellenwerten auf die Mahalanobis-Distanzen der Klassen; s. S. 81) so gesteuert werden, dass der Anteil der puren Pixel im Entmischungsbild in etwa dem im Referenzbild entspricht. Für das vorliegende Entmischungsergebnis beträgt dieser Wert 56,3 %.




Abbildung 3-33 Querprofil durch ein Gebäude. Gezeigt werden die Flächenanteile des Dachendmembers für F_{True} (grün; gleichverteilte Filterung) und F_{HyMap} (blau; normalverteilte Filterung).

Tabelle 3-7 Akkumulierter Flächenanteil der Pixel an den Bildern F_{True} und F_{HyMap} , die eine oder mehrere Oberflächen enthalten.

(% akkumuliert)	Gleichverteilter Filter (F_{True})	Normalverteilter Filter (F_{HyMap})
Pure Pixel:	55,59	34,64
Pixel mit 2 EM:	93,35	79,93
mit 3 EM:	99,68	97,68
mit 4 EM:	99,99	99,89
mit 5 EM:	100,0	100,0

Tabelle 3-8 Statistik der Flächenanteile des 1.-5. *Endmembers* für F_{True} und F_{HyMap} .

(Flächenanteile in %)	Gleichverteilter Filter (F_{True})				Normalverteilter Filter (F_{HyMap})			
	Min	Max	Mean	StDev	Min	Max	Mean	StDev
1. EM:	28,55	100,00	90,28	15,04	27,41	100,00	85,46	16,76
2. EM:	0,00	49,98	9,21	14,20	0,00	49,99	12,92	14,91
3. EM:	0,00	32,77	0,50	2,54	0,00	32,31	1,41	3,97
4. EM:	0,00	17,65	0,01	0,30	0,00	21,86	0,08	0,72
5. EM:	0,00	10,13	0,00	0,04	0,00	11,16	0,00	0,10

Die globalen Flächenanteile der Klassen liefern einen Hinweis auf die Güte des Entmischungsergebnisses. Sie zeigen an, ob einzelne Klassen in der Szene stark über- oder unterrepräsentiert sind, was durch bestimmte Einstellungen bei der Entmischung ausgeglichen werden könnte. Dies ist beim vorliegenden Ergebnis nicht notwendig. Die **Tabelle 3-9** zeigt weiterhin, dass ein normalverteilter Filterkernel (Sensor-PSF) kaum Auswirkungen auf die globalen Flächenanteile hat und dass die Abweichungen beim Entmischungsergebnis ebenfalls sehr gering sind. Die RMS-Fehler von 0,004 und 0,85 wurden unter Berücksichtigung der Flächenrelevanz der Klassen berechnet, um einen Aussagewert für eine typische urbane Szene zu erhalten. Hierfür wurden die quadrierten Abweichungen mit den globalen Flächenanteilen der Klassen gewichtet.

Tabelle 3-9 Globale Flächenanteile der urbanen Oberflächen und absolute Abweichungen von diesen, bedingt durch Sensorabtastung und spektraler Entmischung.

Flächenanteil der Klassen bei gleichverteiletem Filterkernel (F_{True}) (%)	Abweichung von F_{True} (%)		
	Normalvert. Kernel (F_{HyMap})	Entmischung (F_{Unmix})	
rcon	1,76	0,00053	-0,08
rtiln	8,12	0,00339	-0,10
rtilo	10,32	-0,00227	0,66
ralu	1,07	-0,00047	-0,13
rzin	0,80	0,00069	-0,06
rpol	0,26	0,00001	-0,10
rpvc	0,18	0	0,03
rbitd	7,04	0,00210	-0,52
fcon	9,79	-0,00303	0,30
fasp	17,43	-0,00073	-0,63
pcob	4,01	-0,00053	0,01
prlc	1,46	0,00087	0,00
preon	0,42	-0,00006	-0,04
bsan	6,39	-0,00202	0,15
bsoi	0,14	-0,00045	0,03
vdec	0,25	0,00181	-0,04
vcon	0,07	-0,00059	0,08
vlaw	6,34	0,00078	0,31
vdry	6,74	0,00102	-0,11
vmea	17,21	-0,00146	0,20
wriv	0,10	0,00015	0,00
wpon	0,06	-0,00027	0,00
RMS (gewichtet nach Flächenanteil):		0,004	0,85

Die Flächenanteile F_{True} , F_{HyMap} und F_{Unmix} sind in Bildern abgelegt. Der erste lagespezifische Vergleich von F_{True} (Referenzbild) und F_{HyMap} (Sensorwahrheit) soll die Verfälschung der Flächenanteile durch die Sensorabtastung quantifizieren. **Abbildung 3–34** zeigt die mittleren Abweichungen der Flächenanteile pro Klasse und Flächenanteilintervall im Referenzbild. Für alle Klassen ist klar zu erkennen, dass die Flächenanteile in F_{HyMap} durch die Sensorabtastung überschätzt werden, wenn sie im Referenzbild geringe Werte aufweisen, während sie unterschätzt werden, wenn sie im Referenzbild hohe Werte aufweisen. Die Ursache hierfür ist zum einen in den Nachbarpixeln, zum anderen in der Verteilung der Klassen im Pixel zu suchen. Beide Einflüsse werden durch **Abbildung 3–31** dokumentiert.




Abbildung 3–34 Mittlere Abweichung der Flächenanteile F_{HyMap} von F_{True} . Jede Linie zeigt eine Klasse. Die Abweichungen der Pixel einer Klasse wurden pro Flächenanteilintervall der Pixel im Referenzbild gemittelt. Der grau hinterlegte Bereich entspricht der durchschnittlichen Standardabweichung der Klassen, abgetragen von einer gemittelten Kurve der Klassen.

Die Nachbarpixel sind bei der Sensorabtastung sehr relevant, da ca. 40 % des Signals eines Pixels aus seiner Umgebung kommt. Wie oben beschrieben beträgt die Filtergröße der Sensor-PSF 19x19 Pixel im 50cm-Rasterreferenzbild. Bezogen auf das Bild mit HyMap-Auflösung schließt dies die N8-Nachbarschaft beinahe komplett mit ein. Liegt nun ein Mischpixel vor, so ist es wahrscheinlich, dass das Pixel auf der Grenze zwischen zwei Geobjekten liegt. Demnach ist es wahrscheinlich, dass es in der Nachbarschaft Pixel gibt, in denen eine im Mischpixel vorhandene Klasse größere Flächenanteile besitzt. Ist der durchschnittliche Flächenanteil der Klasse in den Nachbarpixeln höher als im Zentrumspixel unter dem Filterkernel, so führt dies zu einer Überschätzung des Flächenanteils. Diese Überschätzung tritt bei kleineren Flächenanteilen der Klasse im Zentrumspixel stärker auf, da hier die Wahrscheinlichkeit höher ist, dass der Flächenanteil der Klasse in der Umgebung größer ist. Mit steigendem Flächenanteil der Klasse im Zentrumspixel sinkt die Überschätzung und schlägt etwa ab einem Flächenanteil von 50 % in eine Unterschätzung um, da der durchschnittliche Flächenanteil der Klasse in den Nachbarpixeln an der Grenze von zwei Geobjekten im Mittel 50 % beträgt. Am stärksten unterschätzt werden Flächenanteile zwischen 80-90 %. Der Anstieg zum Intervall 90-100 % lässt sich mit den puren Pixeln erklären. Ist ein Pixel pur, so ist es wahrscheinlich, dass es von anderen puren Pixeln der gleichen Klasse umgeben ist. Daher ist die Unterschätzung bei puren Pixeln geringer und sie ziehen die Statistik nach oben. Entsprechend lässt sich die geringere Überschätzung der Flächenanteile im Intervall 1-10 % erklären. Hier liegen die Zentrumspixel bereits so weit vom ei-

gentlichen Geoobjekt der Klasse entfernt, dass in der N8-Nachbarschaft Flächenanteile anderer Klassen dominieren.

Diese Erklärungen gelten natürlich nur im Mittel und für räumliche Auflösungen von Fernerkundungsbildern, die mehrfach unter dem Durchmesser der Geoobjekte liegen. In Extremfällen sind durch den Nachbapixel-Effekt Abweichungen von $\pm 40\%$ möglich. Der grau hinterlegte Bereich in **Abbildung 3-34** entspricht der durchschnittlichen einfachen Standardabweichung von einer über alle Klassen gemittelten Kurve. Die Kurven der beiden Klassen `ydec` und `ycon` (Laub- und Nadelbäume) zeigen Extremfälle von Unterschätzungen durch den Nachbapixel-Effekt auf. Diese treten auf, weil es sich hier im gesamten Bild um Einzelbäume handelt, die nur aus 1-3 HyMap Pixeln bestehen. Trifft ein Pixel einen Baum, kommt die Baumklasse in den Nachbapixeln nur mit geringen Anteilen vor. Der Nachbapixel-Effekt bewirkt hier also fast immer eine starke Unterschätzung.

Als zweiter Effekt kommt die Position der Klasse im Zentrumpixel hinzu (Lageeffekt). Ist die Klasse gleichmäßig im Pixel verteilt, tritt keine Verfälschung des Flächenanteils auf. Ist sie jedoch überdurchschnittlich zentral oder peripher im Pixel verteilt, wird ihr Flächenanteil über- bzw. unterschätzt (s. Felder 2 bis 4 in **Abbildung 3-31**). Die Stärke des Effekts hängt vom Flächenanteil und von der Lage der Klasse im Pixel ab. Die Auswirkung ist jedoch geringer als die des Nachbapixel-Effekts.

Im urbanen Raum sollte theoretischen Überlegungen zu Folge auch beim Lageeffekt eine Beziehung zwischen dem Flächenanteil der Klasse und der Tendenz zur Über- oder Unterschätzung bestehen. Diese sollte der Tendenz des Nachbapixel-Effekts entgegen wirken, was erneut an dem Beispiel eines Mischpixels an der Grenze zweier Geoobjekte erklärt werden kann. Beträgt das Verhältnis zweier Klassen im Mischpixel 50:50, so ist es wahrscheinlich, dass die Grenze der Geoobjekte das Pixel relativ zentral schneidet. Die Klassen teilen sich das Pixel also bezogen auf die Gewichtungen der Sensor-PSF gleichmäßig auf. Es tritt keine Über- oder Unterschätzung der Flächenanteile auf. Je größer jedoch der Flächenanteil einer der beiden Klassen wird, desto stärker entfernt sich die Grenze der Geoobjekte vom Pixelmittelpunkt. Die kleinere, am Rand liegende Klasse erhält nun eine geringere Gewichtung durch die Sensor-PSF und wird dadurch flächenmäßig unterschätzt, während die größere Klasse überschätzt wird.

Die methodeninhärente Genauigkeit der Klassifizierungs- und Entmischungsmethode (Vergleich F_{Ummix} zu F_{HyMap}) kann klassenspezifisch und pro Flächenanteilintervall aus den Diagrammen der **Abbildung 3-35** abgelesen werden. Im Gegensatz zur Sensorabtastung zeigt sich hier keine über alle Klassen einheitliche Tendenz in Abhängigkeit von den Flächenanteilen im Referenzbild (hier: F_{HyMap}). Die 22 im Bild enthaltenen Klassen können anhand der mittleren Über- oder Unterschätzung in vier Gruppen eingeteilt werden:

- I. Klassen ohne Tendenz zur Über- oder Unterschätzung (7 von 22)
- II. Klassen mit Tendenz zur Unterschätzung mittlerer Flächenanteile (8 von 22)
- III. Klassen mit Tendenz zur Unterschätzung kleiner Flächenanteile (2 von 22)
- IV. Klassen mit Tendenz zur Unterschätzung großer Flächenanteile (5 von 22)




Abbildung 3-35 Mittlere Abweichung der Flächenanteile F_{Unmix} von F_{HyMap} . Jede Linie zeigt eine Klasse. Die Werte resultieren aus einer Mittelung der Pixel der Klasse pro Flächenanteilintervall im Referenzbild. Der grau hinterlegte Bereich entspricht der durchschnittlichen Standardabweichung der Klassen, abgetragen von einer gemittelten Kurve der Klassen. Die vier Diagramme zeigen die im Text genannten Gruppen I-IV.

Die Standardabweichung der Fehler (grau hinterlegte Fläche der Diagramme in **Abbildung 3-35**) ist bei allen Gruppen deutlich größer als die der Fehler, die durch die Sensorabtastung entstehen. Sie liegt meistens zwischen 15-25 % mit einigen Werten unter 10 % als Minimum und einigen über 30 % als Maximum. Bei sehr kleinen und sehr großen Flächenanteilen liegt sie bei allen Gruppen außer Nr. IV um oder unter 10 %. Da etwa die Hälfte des Bildes aus reinen Pixeln besteht, ist gerade die Genauigkeit im Flächenanteilintervall 90-100 % am wichtigsten.

Die Klassen der ersten Gruppe zeigen für alle Flächenanteile im Referenzbild (x-Achse der Diagramme in **Abbildung 3-35**) keine Tendenz zur Über- oder Unterschätzung. Die erste Gruppe ist die einzige, bei der leichte Überschätzungen in allen Flächenanteilen auftreten. Bei den anderen Gruppen sind Überschätzungen im Wesentlichen nur im Intervall 0-10 % zu beobachten.

Bei der zweiten Gruppe werden hauptsächlich die Flächenanteile im mittleren Bereich unterschätzt. Bis auf *bsol* handelt es sich hier um Klassen, mit sehr kleinen oder sehr schmalen Geoobjekten. Dadurch existiert in der direkten Nachbarschaft der zu entmischenden Pixel nicht immer ein Saapixel¹⁷. Das Diagramm bestätigt somit die Annahme, dass die Steuerung der Endmemberwahl im Mischungsmodell über die Saapixel ein wichtiger stabilisierender Faktor für die Entmischung ist. Dass die Unterschätzung der Flächenanteile von Klassen mit ihrer durchschnittlichen Segmentgröße zusammenhängt, geht aus **Abbildung 3-37** hervor. Jedoch muss es weitere Faktoren hierfür geben, da der Zusammenhang nicht besonders stark ist.

¹⁷ Zur Erläuterung des Begriffs Saapixel s. Beschreibung der Entmischungsmethode in Kapitel 3.4.3.3.

Bei der dritten Gruppe werden nur die Flächenanteile im Bereich 10-40 % unterschätzt. Die beiden Klassen dieser Gruppe sind sowohl spektral wie auch bezogen auf ihre Segmentgrößen völlig verschieden, so dass keine Erklärung für die Unterschätzung gefunden werden kann.

Die Klassen der vierten Gruppe zeigen im Bereich größerer Flächenanteile eine Unterschätzung an. Die Ursache ist vermutlich im Algorithmus zur Klassifizierung purer Pixel oder in der Verwendung der Hausmaske bei der Klassifizierung zu suchen. Auffällig ist, dass es sich in dieser Gruppe ausschließlich um Dachmaterialien handelt.




Abbildung 3–36 Mittlere Abweichung der Flächenanteile der Klassen bedingt durch die Sensorabtastung und die Entmischungsmethode (links). Das rechte Diagramm zeigt den kombinierten Fehler aus beiden.




Abbildung 3–37 Abhängigkeit der Über- und Unterschätzung der Flächenanteile der Klassen von ihrer durchschnittlichen Segmentgröße.

Mit den bisher gezeigten Statistiken wurden die Fehler klassenspezifisch und differenziert nach ihrer Ursache untersucht, um daraus zukünftige Ansatzpunkte zur Verbesserung der Methode ableiten zu können. In einer weiteren Reihe von Statistiken sollen nun zusammenfassende Aussagen – analog zur Gesamtgenauigkeit (engl.: *overall accuracy*) einer Klassifizierung – getroffen

werden, die ausdrücken, wie genau eine typische urbane Szene entmischt werden kann. Wir vergleichen dazu die Flächenanteile F_{Ummix} mit F_{True} und untersuchen 4 Gruppen von Pixeln separat, für die unterschiedliche Statistiken berechnet werden können:

- I. Pixel, die in beiden Bildern als „pur“ eingestuft wurden.
- II. Pixel, die im Referenzbild, aber nicht im Entmischungsbild als „pur“ eingestuft wurden (Fehler 1. Art).
- III. Pixel, die im Entmischungsbild, aber nicht im Referenzbild als „pur“ eingestuft wurden (Fehler 2. Art).
- IV. Pixel, die in beiden Bildern als Mischpixel eingestuft wurden.

Ein fünfter Fall tritt auf, wenn der Klassifizierer ein Pixel nicht als pures Pixel erkannt hat und bei der Entmischung keine lineare Kombination zweier *Endmember* gefunden wurde, deren Spektrum den RMSE von 1 % einhält. Der Anteil dieser nicht erkannten Pixel ist mit 0,03 % des Bildes jedoch vernachlässigbar gering.




Abbildung 3–38 Echtfarbenansicht der simulierten Szene und räumliche Verteilung der obengenannten fünf Fälle (Fall I: weiß; Fall II: rot; Fall III: grün; Fall IV: schwarz; Fall V: blau).

Der erste Schritt umfasst die Genauigkeitsuntersuchung der Pixel des ersten Falls (45,9 % des Bildes) mit einer Konfusionsmatrix. Für diese Pixel beträgt die Gesamtgenauigkeit 99,8 %. Durch den pMLK und die nachfolgende Klassifizierung von reinen Pixeln wird also beinahe die Hälfte des Bildes korrekt klassifiziert.

Für die Fehler 1. Art (Fall 2; 9,7 % des Bildes) existiert im Referenzbild ein pures Pixel (ein *Endmember* mit 100 % Flächenanteil) und im Entmischungsbild ein Mischpixel (mehrere *Endmember*). Bei 91,5 % dieser Pixel wurde bei der Entmischung der erste *Endmember*, d.h. der *Endmember* mit dem größeren Flächenanteil, richtig bestimmt. Zusätzlich ist von Interesse, wie stark die berechneten Flächenanteile des ersten *Endmembers* von der Wahrheit (=100 %) abweichen. Das Histogramm der Abweichungen zeigt die Form einer Normverteilung, so dass die

Fehler durch einen Mittelwert von -8,5 % und einer Standardabweichung von 8,6 % beschrieben werden können.

Für die Fehler 2. Art (Fall 3; 9,5 % des Bildes) existiert im Referenzbild ein Mischpixel und im Entmischungsbild ein pures Pixel. 86,8 % dieser Pixel wurden dem ersten *Endmember* des Referenzbildes vollständig zugeteilt. Hier liegt das Entmischungsbild durchschnittlich 11,4 % über der Wahrheit mit einer Standardabweichung von 11,6 %.

Die Pixel des Falls 4 sind sowohl im Referenz- wie auch im Entmischungsbild Mischpixel (34,9 % des Bildes). Da das angewendete Mischungsmodell aus 2 *Endmembers* besteht, werden die Statistiken für beide *Endmembers* berechnet. Bei 78,7 % der Pixel besteht eine Übereinstimmung im ersten *Endmember*, bei 66,5 % auch im zweiten. Die Flächenanteile des ersten *Endmembers* werden mit -4,8 % ($\pm 11,3$ %) leicht unterschätzt, während die des zweiten mit 7,0 % ($\pm 9,7$ %) leicht überschätzt werden. Die um 2,2 % ausgeprägtere Überschätzung des zweiten *Endmembers* im Vergleich zur Unterschätzung des ersten liegt vermutlich an den 6,65 % der Bildpixel mit 3 *Endmembers* im Referenzbild (s. **Tabelle 3-7**), deren Anteile vermutlich häufiger dem zweiten *Endmember* zugeschlagen werden.

Eine Betrachtung der Lage der korrekt und falsch klassifizierten bzw. entmischten Pixel zeigt die Stärken und Schwächen des Algorithmus auf (s. **Abbildung 3-39**). Die falsch klassifizierten und entmischten Pixel (schwarz und rot) liegen vor allem am Rand der Straßen. Der Grund hierfür könnte die dichte Abfolge unterschiedlicher und schmaler Geoobjekte (z.B. Vegetationsfläche, Gehweg, Straße, Gehweg, Vegetationsfläche) auf kurzer Distanz sein, was dazu führt, dass hier nur wenige pure Pixel existieren, die die Entmischung als Saatpixel steuern können.




Abbildung 3-39 Lage der korrekt (weiß) und falsch oder nicht (schwarz) klassifizierten Pixel im Bild sowie der entmischten Pixel, bei denen beide (grün) oder nur der erste (orange) *Endmember* richtig ist bzw. der erste *Endmember* nicht richtig ist (rot).

Die komplett falsch klassifizierten oder entmischten Pixel (d.h. unklassifiziert, falsch klassifiziert bei Fall 1 und falscher erster *Endmember* bei den Fällen 2-4) belegen zusammen nur 9,7 % des Bildes. Für 90,3 % des Bildes konnte also der erste *Endmember* richtig bestimmt werden. Insgesamt zeigt die Validierung, dass die am GFZ Potsdam entwickelte Methode der iterativen, linearen, spektralen Entmischung mit hoher Genauigkeit arbeitet. Für eine reale Szene ist allerdings

zu erwarten, dass die erzielbaren Genauigkeiten unter den hier gezeigten Werten liegen werden. Die hier gezeigten Werte gelten als theoretisches Optimum. Die aufgetretenen Fehler sind methodeninhärent. Die zu erwartenden zusätzlichen Fehler bei einer realen Szene können z.B. durch nicht erfasste Oberflächen hervorgerufen werden (z.B. Autos, Schrott/Müll, Menschen), durch Schattenwurf oder die Abbildung von Gebäudefassaden und die Verdeckung der hinter den Gebäuden liegenden Flächen bei Schrägsicht des Sensors.

3.4.4 Thematische Gruppierung der Oberflächenarten

Mit Blick auf die Erkennung und Unterscheidung von Biotoptypen werden die Flächenanteile der einzelnen Oberflächenklassen zu thematischen Klassengruppen zusammengefasst. Das Zusammenfassen erfolgt pro Pixel durch einfaches Aufsummieren der Flächenanteile der zu einer Klassengruppe gehörenden Oberflächenklassen. Der Grund dieser Gruppierung ist der, dass neben einzelnen Klassen auch bestimmte Gruppen von Klassen eine Aussagekraft zur Unterscheidung von Biotoptypen haben. So ist der Flächenanteil aller Gebäude im Biotop häufig aussagekräftiger als der Flächenanteil eines einzelnen Dachmaterials. Eine neue Dacheindeckung würde die aus der Einzelklasse berechnete Merkmalsausprägung stark verändern, die der Klassengruppe „Dächer“ bliebe stabil. Letzteres wäre das gewünschte Verhalten, da sich der Biotop mit einer neuen Dacheindeckung nicht verändert.

Zusätzlich zu den Flächenanteilen der einzelnen Klassen können die Merkmale zur Identifizierung und Unterscheidung der Biotoptypen also auch auf den Flächenanteilen von Klassengruppen gerechnet werden. Es wurden insgesamt 13 thematische Klassengruppen gebildet (**Tabelle 3-10**), zwischen denen es teilweise auch Überschneidungen oder komplette Überlagerungen gibt. Bei einer Implementierung weiterer Biotoptypen in das System können nach Belieben weitere Klassengruppen gebildet werden, wenn diese die Erkennung und Unterscheidung der neuen Typen unterstützen.

Tabelle 3-10 Übersicht über die Klassengruppen (Klassenkürzel s. Anhang A).

Klassengruppe	Klassen
Vegetation	<u>v</u> dec, <u>v</u> con, <u>v</u> mix, <u>v</u> law, <u>v</u> mea, <u>v</u> dry, <u>s</u> veg
Bäume	<u>v</u> dec, <u>v</u> con, <u>v</u> mix
Böden	<u>b</u> san, <u>b</u> sanc, <u>b</u> soi
Dächer	<u>r</u> tiln, <u>r</u> tilo, <u>r</u> con, <u>r</u> tilg, <u>r</u> tila, <u>r</u> alu, <u>r</u> cop, <u>r</u> zin, <u>r</u> ste, <u>r</u> mecgr, <u>r</u> mecw1, <u>r</u> mecw2, <u>r</u> pvc, <u>r</u> pol, <u>r</u> pdc, <u>r</u> gla, <u>r</u> gla2, <u>r</u> bitd, <u>r</u> bitb, <u>r</u> bitr, <u>r</u> schi, <u>r</u> tar, <u>r</u> veg, <u>r</u> gra, <u>r</u> gra2, <u>r</u> nuk1 – <u>r</u> nuk8
Metалldächer	<u>r</u> alu, <u>r</u> cop, <u>r</u> zin, <u>r</u> ste, <u>r</u> mecgr1, <u>r</u> mecgr2, <u>r</u> mecw1, <u>r</u> mecw2, <u>r</u> gla2
Ziegeldächer	<u>r</u> tiln, <u>r</u> tilo, <u>r</u> con, <u>r</u> tilg, <u>r</u> tila, <u>r</u> schi, <u>r</u> gla2
Flachdächer	<u>r</u> pvc, <u>r</u> pol, <u>r</u> pdc, <u>r</u> gla2, <u>r</u> bitd, <u>r</u> bitb, <u>r</u> bitr, <u>r</u> tar, <u>r</u> veg, <u>r</u> gra, <u>r</u> gra2
Industriedächer	<u>r</u> alu, <u>r</u> zin, <u>r</u> ste, <u>r</u> mecgr1, <u>r</u> mecgr2, <u>r</u> mecw1, <u>r</u> mecw2, <u>r</u> pvc, <u>r</u> pol, <u>r</u> pdc, <u>r</u> gla, <u>r</u> gla2, <u>r</u> bitd, <u>r</u> bitb, <u>r</u> bitr, <u>r</u> tar, <u>r</u> gra, <u>r</u> gra2
Verkehrsflächen	<u>f</u> con, <u>f</u> asp, <u>p</u> cob, <u>o</u> sba, <u>f</u> bab, <u>d</u> rail
Sportflächen	<u>f</u> kun, <u>f</u> tar, <u>f</u> hoc, <u>p</u> rein, <u>p</u> glc
Schatten	<u>s</u> veg, <u>s</u> nov
Wasser	<u>w</u> pon, <u>w</u> poq, <u>w</u> riv, <u>w</u> lake
Hinterhöfe	Klassengruppen: Vegetation, Böden, Schatten, Dächer (nDOM < 40 dm) Klassen: <u>w</u> pon, <u>w</u> poq, <u>f</u> con, <u>f</u> asp, <u>p</u> cob, <u>p</u> rlc, <u>p</u> dlc, <u>p</u> blc, <u>p</u> rcn, <u>p</u> rla

3.4.5 Segmentierung

Bildsegmente sind Gruppen benachbarter Pixel, die aufgrund eines bestimmten Kriteriums zusammengefasst wurden. Eine Segmentierung wurde in dieser Arbeit mit dem Ziel angewendet, Segmente zu erzeugen, die mit den Geoobjekten übereinstimmen, damit auf deren Basis Merkmale wie z.B. Formparameter gerechnet werden können (Kap. 4.3), die die Erkennung der Biotoptypen unterstützen. Für die Segmentierung wurde ein recht einfaches, aber effektives Verfahren benutzt, das auf dem Entmischungsergebnis basiert. Dafür wurde aus diesem zunächst ein klassifiziertes Bild mit einem *Layer* erzeugt, indem jedem Pixel die Klasse mit dem höchsten Flächenanteil zugewiesen wurde, sofern dieser über 50 % lag. Danach wurden benachbarte Pixel (N4-Nachbarschaft) der gleichen Klasse zu Klassensegmenten zusammengefasst. Diese werden mit einer Segment-ID durchnummeriert und als Ergebnis in einem Rasterbild gespeichert (Abbildung 3–40).

Insgesamt werden mehrere Segmentierungsbilder erzeugt. Das erste Segmentierungsbild wird aus den Entmischungsergebnissen der einzelnen Klassen erzeugt. Zusätzlich wird für jede Klassengruppe ein eigenes Segmentierungsbild erzeugt, so dass die Segmentmerkmale (Kap. 4.3) für Klassensegmente und für Klassengruppensegmente berechnet werden können.



Abbildung 3–40 Ausschnitt aus dem Segmentierungsbild der Klassengruppe Gebäude und dem HyMap-Bild (RGB-Darstellung) zum Vergleich. Die Segmente besitzen im Bild eine durchnummerierte ID. Zur besseren Darstellung sind sie hier in weiß dargestellt.

3.5 Die Datenbasis im Überblick

Für jedes der beiden Untersuchungsgebiete wurden aus den in **Tabelle 3-1** gelisteten Ausgangsdaten bestimmte thematische Informationen und Datenprodukte abgeleitet, die nun Eingang in die Berechnung von Merkmalen finden (Kap. 4), auf denen wiederum die Klassifizierung der Biotope basiert. Die abgeleiteten Informationen liegen in den Untersuchungsgebieten flächendeckend vor und sind dadurch für jedes untersuchte Biotop, wie es in **Abbildung 3–41** beispielhaft gezeigt wird, verfügbar. Alle Daten sind georeferenziert und in die räumliche Auflösung der jeweiligen HyMap-Daten überführt worden. Für das Untersuchungsgebiet in Dresden liegen die Daten zudem für zwei verschiedene Zeitpunkte vor (1999/2000 und 2003/2004), da jeweils zwei HyMap-Datensätze und zwei DOMs zur Verfügung stehen. Die Fülle an vorhandenen Datensätzen ermöglicht es, die entwickelten Methoden intensiv auf ihre Robustheit und Übertragbarkeit zu testen (Kap. 7.3).




Abbildung 3-41 Datenbasis (c – f) eines Biotops (a: HyMap RGB-Darstellung, b: RGB-Luftbild) für die Berechnung von Merkmalen. c: Fläche des Biotops, d: ein exemplarisches Entmischungsergebnis für die Klasse „rote Tonziegel (neu)“, e: das nDOM, f: ein exemplarisches Segmentierungsergebnis für die Klassengruppe „Dächer“.

4 Entwicklung von Merkmalen zur Charakterisierung von Stadtbiototypen

Jeder Biototyp hat bestimmte, charakteristische Eigenschaften. Ein menschlicher Betrachter ist in der Lage, diese im Gelände und in Luftbildern zu erkennen und die Biototypen anhand ihrer Eigenschaften zu unterscheiden. Für die Automatisierung dieser Erkennung und Unterscheidung ist es notwendig, die charakteristischen Eigenschaften der Biototypen numerisch zu erfassen. In Kapitel 1.2 wurden hierzu bereits Überlegungen angestellt. So unterscheiden sich manche Biototypen zum Beispiel durch ihre Zusammensetzung aus verschiedenen Geoobjekten bzw. Oberflächenarten. Außerdem kann deren Verteilung und Anordnung im Biotop und auch die Größe, Form und Höhe der Geoobjekte ausschlaggebend sein.

Die abgeleiteten Fernerkundungsdatenprodukte (Kap. 3.5) bilden die Grundlage für die Erfassung dieser Eigenschaften durch numerische Merkmale, die in den Kapiteln 4.1 bis 4.3 ausführlich vorgestellt werden. Mit jedem Merkmal wird eine Eigenschaft aus den vier Kategorien Morphologie, Verteilung & Anordnung, Menge & Anteil oder Topologie beschrieben. Teilweise sind sie für eine ganz spezielle Aufgabe, z.B. für die Unterscheidung von zwei bestimmten Biototypen gedacht, teilweise haben sie allgemeineren Charakter. Neben den numerischen Merkmalen zur Unterscheidung der Biototypen werden in Kapitel 4.4 Parameter zur ökologischen Charakterisierung der Biotope vorgestellt. Ihre Berechnung erfolgt auf die gleiche Weise wie die der Merkmale und basiert auf den gleichen Daten.

Die Merkmale können auf drei verschiedenen Ebenen berechnet werden, die bestimmen, welche Pixel der Bezugsfläche für die Berechnungen herangezogen werden (**Abbildung 4-1**). Je nach Berechnungsebene gehen

- Biotopenebene: alle Pixel eines Biotops,
- Klassenebene: die Pixel einer Klasse oder Klassengruppe im Biotop,
- Segmentebene: die Pixel eines Segments einer Klasse oder Klassengruppe im Biotop

in die Berechnung eines Merkmals ein.




Abbildung 4-1 Drei Ebenen der Merkmalsberechnung. Die jeweils farbig dargestellten Pixel des Biotops gehen pro Ebene in die Merkmalsberechnung ein.

Die Bezugsfläche der Berechnungen ist dabei nicht immer die ganze Biotopfläche. Zur Unterscheidung bestimmter Biotoptypen, z.B. Blockbebauung und Blockrandbebauung, kann es von Nutzen sein, nur den Randbereich oder nur den Innenbereich eines Biotops zu betrachten. So kann beispielsweise der Flächenanteil der Gebäude im Biotoprandbereich und im Biotopinnenbereich separat erfasst werden. Für diese Aufgabe muss der Biotopinnenbereich so festgelegt werden, dass er bei Biotopen der Blockrandbebauung der Fläche der Innenhöfe entspricht. Aufgrund der unterschiedlichen Formen und Größen der Biotope setzt dies eine individuelle und gleichzeitig automatische Ermittlung des Biotopinnenbereichs für jedes Biotop voraus. Der entwickelte Algorithmus besteht aus zwei Teilen:

- I. Berechnung der konvexen Hülle um die Gebäudepixel eines Biotops,
- II. Erosion der Fläche, die durch die konvexe Hülle gebildet wird, bis zum Eintreten einer Abbruchbedingung.

Für die Berechnung der 2-dimensionalen konvexen Hülle um die Gebäudepixel eines Biotops wurde der Algorithmus von Jarvis (Jarvis 1973) implementiert. Die Berechnung beginnt beim untersten, rechtesten Gebäudepixel (**Abbildung 4-2**), welches gleichzeitig das erste Pixel P_1 der konvexen Hülle ist. Von hier aus wandert der Algorithmus gegen den Uhrzeigersinn um die Punktmenge der Gebäudepixel und sucht jeweils das nächste zur konvexen Hülle gehörende Gebäudepixel, bis das Startpixel wieder erreicht wird. Die konvexe Hülle im Rasterformat ergibt sich aus den gefundenen Pixeln $P_1 \dots P_n$ und den Pixeln, die durch die Verbindungsstrecken zwischen diesen geschnitten werden.




Abbildung 4-2 Prinzipskizze des Algorithmus „Jarvis March“ zur Berechnung der konvexen Hülle einer Punktmenge.

Die Suche nach dem jeweils nächsten Pixel der konvexen Hülle erfolgt durch einen Winkeltest. Beginnend bei P_1 wird als Referenzgerade g_1 die Gerade durch P_1 mit der Steigung 0 gebildet. Iterativ werden nun die Testgeraden $t_1 \dots t_m$ durch P_1 und jeweils einen der anderen Gebäudepixel gebildet und der mathematisch positive Winkel von der Referenzgeraden auf die Testgeraden berechnet. Gesucht wird der kleinste Winkel α . Das zur entsprechenden Testgeraden gehörende Gebäudepixel bildet P_2 der konvexen Hülle, die Testgerade t_i wird zur neuen Referenzgeraden für die nächste Iteration der Suche des nächsten Hüllenspixels. Ab der zweiten Iteration werden nur die Testgeraden zu den noch nicht zur Hülle gehörenden Pixeln und zum Startpixel P_1 gebildet. Ist der Winkel zur Testgeraden des Startpixels der kleinste, endet der Algorithmus.

Die Fläche, die von der konvexen Hülle gebildet wird, umschließt alle Gebäude des Biotops. Handelt es sich um ein Biotop der Blockrandbebauung, so muss diese Fläche zur Bestimmung des Biotopinnenbereichs (= Innenhof) solange erodiert werden, bis die am Rand der Fläche stehenden Gebäude entfernt sind. Dabei werden ausschließlich Gebäudepixel erodiert und die übrigen Klassen erhalten, so dass Gebäude im Innenbereich, die keinen Kontakt zu einem Ge-

bäude am Rand der Fläche haben, ebenfalls erhalten bleiben. Der iterative Prozess wird abgebrochen, wenn eine von fünf Bedingungen erreicht ist:

- I. Der Prozentanteil der Gebäudepixel der aktuellen Erosionsrunde liegt unter 3 %.
- II. Die Anzahl der Gebäudepixel der aktuellen Erosionsrunde liegt unter 25 % der Anzahl der Gebäudepixel der vorherigen Erosionsrunde.
- III. Die Flächensumme der erodierten Gebäudepixel der aktuellen Erosionsrunde liegt unter 64 m².
- IV. Eine Mindestfläche für den Biotopinnenbereich von 20 % der Fläche der konvexen Hülle wurde unterschritten.
- V. Eine Mindestfläche für den Biotopinnenbereich von 400 m² wurde unterschritten.

Das Ergebnis, die Innenbereiche der Biotope, zeigt **Abbildung 4–3**. Die Biotoprandbereiche ergeben sich aus den Komplementärflächen der Biotopinnenbereiche. Somit können alle entwickelten Basismerkmale auf drei Bezugsflächen angewendet werden, wodurch die Gesamtzahl der berechneten Merkmale verdreifacht wird.

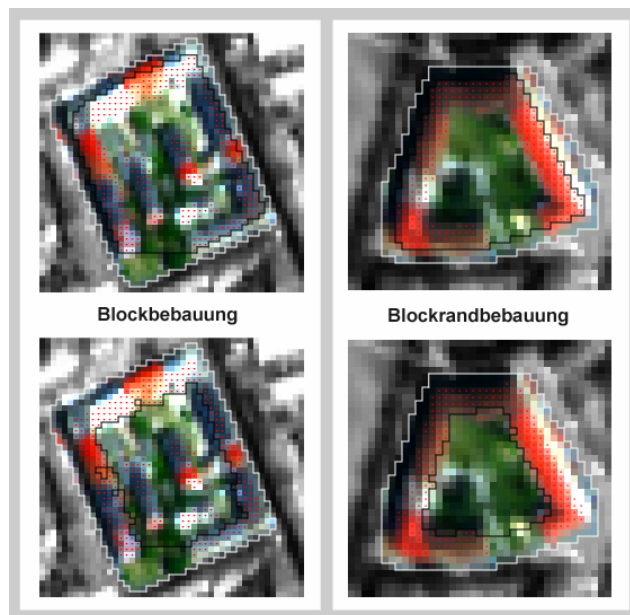


Abbildung 4–3 Konvexe Hülle, Biotopinnenbereich und Biotoprandbereich gezeigt für Beispielbiotope der Blockbebauung und Blockrandbebauung. Die helle Umrisslinie umrandet die Biotopfläche. Die roten Punkte markieren die als Hausdach klassifizierten Biotoppixel. In den oberen Bildern stellt die dunkle Linie jeweils die konvexe Hülle um die Dachpixel dar, in den unteren die Grenze zwischen Biotopinnenbereich und -randbereich.

Insgesamt wurden 7 Basismerkmale auf Biotopenebene, 7 Basismerkmale auf Klassenebene und 14 Basismerkmale auf Segmentebene entwickelt. Daneben wurden 5 ökologische Parameter implementiert. Die Anzahl der tatsächlich berechneten Merkmale ist jedoch weitaus höher. So werden alle Basismerkmale wie oben beschrieben auf drei Bezugsflächen angewendet. Alle Klassen- und

Segmentmerkmale werden darüber hinaus für jede der 67 Oberflächenklassen und 13 Klassen-
gruppen berechnet. Zusätzlich vervierfachen sich viele dieser Merkmale durch die Berechnung
der statistischen Parameter Minimum, Maximum, Mittelwert und Standardabweichung. Da-
durch werden für die Erkennung der Biototypen insgesamt über 10.000 Merkmale erzeugt.

4.1 Biotopmerkmale

Flächeninhalt

Der **Flächeninhalt** A gibt die Größe des Biotops in Quadratmetern an. Er ergibt sich aus der
Multiplikation der Anzahl der Biotoppixel mit der Fläche eines Pixels in Quadratmetern.

$$A = n \Delta^2 \quad A \in \{\mathbb{R} \mid A \geq p_x p_y\} \quad (4-1)$$

mit n : Anzahl der Biotoppixel
 Δ : räumliche Auflösung des Datensatzes in Metern

Umfang

Der **Umfang** U eines Biotops wird in Metern angegeben. Die Berechnung erfolgt nach dem Ket-
tencode von Freeman (Freeman 1961, Freeman 1974), einem Verfahren zur Extrahierung von
Linienstrukturen aus Rasterbildern und deren digitaler Repräsentierung, Speicherung und Ver-
arbeitung. Der Umfang einer Fläche in einem Rasterbild wird dabei als Sequenz von Linien
abgespeichert, die die Mittelpunkte der Randpixel der Fläche miteinander verbinden. Jede Ver-
bindung wird mit einer Zahl zwischen 0 und 7 kodiert, die die Richtung zum nächsten Pixel
angibt (**Abbildung 4-4**). Auf diese Weise gelangt man Schritt für Schritt vom Ausgangspunkt
zum Endpunkt der Kette. Die Länge der Kette (also der Umfang) ergibt sich durch Addition
der Längen der einzelnen Verbindungen unter Berücksichtigung der räumlichen Auflösung der
Bildaten (**Gleichung (4-2)**).




Abbildung 4-4 Links: Richtungszahlen für den Kettencode ausgehend vom Pixel P.
Rechts: Skizze einer Kette.

$$U = (n_x \Delta) + (n_y \Delta) + (n_d \Delta \sqrt{2}) \quad U \in \{\mathbb{R} \mid U \geq 1\} \quad (4-2)$$

mit n_x : Anzahl der Richtungen in x -Richtung
 n_y : Anzahl der Richtungen in y -Richtung
 n_d : Anzahl der diagonalen Richtungen

Kompaktheitsgrad

Aus dem Verhältnis von Fläche und Umfang ergibt sich der **Kompaktheitsgrad** K . Der Wertebereich liegt zwischen Null (exklusive) und Eins, wobei die kompakteste Fläche – der Kreis – den Wert 1 erhält.

$$K = \frac{4\pi A}{U^2} \quad K \in \{\mathbb{R} \mid 0 < K \leq 1\} \quad (4-3)$$

Lineare-Segmente-Indikator

Der **Lineare-Segmente-Indikator** LSI wurde entwickelt, um Flächen zu identifizieren, die gerade, länglich und zugleich schmal sind. Für die Erkennung der bisher implementierten Biototypen hat der auf Biotopenebene gerechnete LSI keine große Bedeutung. Er ist jedoch prädestiniert für die Erkennung linienhafter Biototypen, die Straßen, Flüsse, Flussufer oder Baumreihen enthalten. Je länger und schmaler eine Biotopfläche ist, desto höher ist ihr LSI -Wert. Krümmungen oder Knicke der Fläche schwächen den LSI dagegen ab. So würden ein Kreis oder ein Quadrat den kleinstmöglichen LSI -Wert von 1 erhalten, eine Gerade von einem Pixel Breite einen sehr hohen Wert, der mit der Länge der Geraden steigt. Der Wertebereich ist dabei nach oben offen.

Die Berechnung des LSI erfolgt durch eine Hauptkomponentenanalyse der 2-dimensionalen Biotopfläche im Bildkoordinatensystem. Die erste Hauptkomponente liegt entlang der größten Varianz, also entlang der größten Ausdehnung der Biotopfläche. Da der Merkmalsraum in diesem Fall nur zwei Dimensionen hat, ist durch die Berechnung der ersten Hauptkomponente die zweite bereits festgelegt: Sie verläuft bekanntlich orthogonal zur ersten. Der LSI ergibt sich dann aus dem Quotienten der Wurzeln der Eigenwerte λ_1 und λ_2 der beiden Hauptkomponenten:

$$LSI = \sqrt{\frac{\lambda_1}{\lambda_2}} \quad LSI \in \{\mathbb{R} \mid LSI \geq 1\} \quad (4-4)$$

Relative Lage

Da viele Städte einen historischen Stadtkern besitzen und die Stadtentwicklung in den Grundzügen konzentrisch verlaufen ist, kann die **relative Lage eines Biotops in der Stadt** L_{rel} einen Beitrag zu dessen Identifizierung leisten. Diese berechnet sich aus dem Abstand des Biotopmittelpunktes zum historischen Stadtmittelpunkt und wird normiert mit der durchschnittlichen Entfernung zwischen historischem Stadtmittelpunkt und Stadtrand. Der Biotopmittelpunkt wird entsprechend der **Gleichungen (4-5)** und **(4-6)** berechnet. Die Koordinaten des historischen Stadtmittelpunktes sowie der durchschnittliche Abstand des Stadtrands zu diesem müssen für jede untersuchte Stadt einmalig gesetzt werden. Die Berechnungen erfolgen in Kartenkoordinaten.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4-5)$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (4-6)$$

$$L_{rel} = \frac{1}{r_{Stadt}} \sqrt{(\bar{x} - m_{Stadt_x})^2 + (\bar{y} - m_{Stadt_y})^2} \quad L_{rel} \in \mathbb{R}_+ \quad (4-7)$$

mit \bar{x} : Mittelwert aller x -Koordinaten eines Biotops
 \bar{y} : Mittelwert aller y -Koordinaten eines Biotops
 m_{Stadt_x} : x -Koordinate des Stadtmittelpunkts
 m_{Stadt_y} : y -Koordinate des Stadtmittelpunkts
 r_{Stadt} : durchschnittlicher Radius der Stadt

Verhältnis spektral reine Pixel / Mischpixel

Das Merkmal *PPMP* beschreibt das **Verhältnis spektral reiner Pixel** (engl.: *pure pixels*) **zu Mischpixeln** im Biotop. Es korreliert dadurch mit der Größe der Geoobjekte im Biotop, ist allerdings auch abhängig von der räumlichen Auflösung des Eingabedatensatzes.

$$PPMP = \frac{n_{PP}}{n_{MP}} \quad n_{MP} \neq 0; \quad PPMP \in \mathbb{R}_+ \quad (4-8)$$

mit n_{PP} : Anzahl der spektral reinen Pixel im Biotop¹⁸
 n_{MP} : Anzahl der Mischpixel im Biotop

Objekthöhen

Die Standardabweichung der **Objekthöhen im Biotop**¹⁹ H_σ ist ein Merkmal, das die Höhentextur des Biotops erfasst. Die Berechnung erfolgt nach **Gleichung (4-9)**:

$$H_\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_i - \bar{h})^2} \quad H_\sigma \in \{\mathbb{R} \mid H_\sigma \geq 0\} \quad (4-9)$$

mit h_i : Objekthöhenwert des Pixels i
 \bar{h} : Mittelwert der Objekthöhenwerte aller Biotoppixel

Die separate Untersuchung der Objekthöhen im Biotoprandbereich bzw. im Biotopinnenbereich ist besonders dafür ausgelegt, die Biotoptypen Blockbebauung und Blockrandbebauung zu unterscheiden. Durch die umschließende Bebauung im Biotoprandbereich sind hier bei beiden Typen hohe Werte für H_{Mean} zu erwarten, während im Innenbereich eine Unterscheidbarkeit erwartet wird.

¹⁸ Alle Pixel mit einem Flächenanteil einer Klasse von $\geq 90\%$ werden hier als pure Pixel behandelt, die übrigen als Mischpixel.

¹⁹ Für diese Eigenschaft werden die vier statischen Parameter Minimum, Maximum, Mittelwert und Standardabweichung berechnet, die jeweils ein eigenes Merkmal ergeben. Die Berechnung von einer der vier Varianten wird hier im Text vorgestellt.

4.2 Klassenmerkmale

Flächenanteile der Klassen

Die **Flächenanteile der urbanen Oberflächenarten** F im Biotop können aus dem Entmischungsergebnis der HyMap-Daten berechnet werden. Sie ergeben sich aus der Summe der Flächenanteile der Oberflächenklassen in allen Biotoppixeln. Diese Summe wird zum einen mit der Gesamtanzahl der Biotoppixel normiert (Flächenanteil der Klasse im Biotop F_{Btk}) und zum anderen mit der Anzahl der Biotoppixel, in denen die Klasse präsent ist (durchschnittlicher Flächenanteil der Klasse pro Pixel F_{Pxk}).

$$F_{Btk} = \frac{1}{n} \sum_{i=1}^n F_{ik} \quad F_{Btk} \in \{\mathbb{R} \mid 0 \leq F_{Btk} \leq 1\} \quad (4-10)$$

$$F_{Pxk} = \frac{1}{n_k} \sum_{i=1}^{n_k} F_{ik} \quad F_{Pxk} \in \{\mathbb{R} \mid 0 \leq F_{Pxk} \leq 1\} \quad (4-11)$$

mit F_{ik} : Flächenanteil der Klasse k am Pixel i
 n_k : Anzahl der Biotoppixel, in denen die Klasse k präsent ist

Verhältnis spektral reine Pixel / Mischpixel pro Klasse

Das **Verhältnis von spektral reinen Pixeln und Mischpixeln pro Klasse** $PPMP_k$ wird gemäß der **Gleichung (4-12)** berechnet:

$$PPMP_k = \frac{n_{PPk}}{n_{MPk}} \quad n_{MPk} \neq 0; \quad PPMP_k \in \mathbb{R}_+ \quad (4-12)$$

mit n_{PPk} : Anzahl der spektral reinen Pixel pro Klasse im Biotop²⁰
 n_{MPk} : Anzahl der Mischpixel pro Klasse im Biotop

Kompaktheitsgrad einer Klasse

Der **Kompaktheitsgrad einer Klasse nach dem Newton'schen Gravitationsgesetz** G_k ist ein Maß dafür, wie dicht beisammen oder wie diffus verstreut die Pixel einer Klasse im Biotop liegen. Berücksichtigt werden alle Pixel, in denen die Klasse präsent ist. In der Newton'schen Formel werden dazu die Massen zweier Körper durch die Flächenanteile der Klasse an zwei Pixeln F_{ik} und F_{jk} ersetzt. Die Distanz zwischen den Pixeln wird im Bildkoordinatensystem berechnet. Die Gravitationskonstante entfällt. Die Berechnung wird für alle Pixelpaare einer Klasse durchgeführt und durch die Anzahl der möglichen Kombinationen dividiert (ungeordnete Stichprobe).

²⁰ Alle Pixel mit einem Flächenanteil einer Klasse von $\geq 90\%$ werden hier als pure Pixel behandelt, die übrigen als Mischpixel.

Einen Kompaktheitsgrad von 1 erreicht eine Klasse nur, wenn sie aus genau zwei direkt nebeneinander liegenden Pixeln besteht. Je diffuser die Klasse im Biotop verteilt ist, desto mehr nähert sich ihr Kompaktheitsgrad Null an.

$$G_k = \frac{2!(n_k - 2)!}{n_k!} \left(\sum_{i=1}^{n_k-1} \sum_{j=i+1}^{n_k} \frac{F_{ik} F_{jk}}{d_{ij}^2} \right) \quad G_k \in \{\mathbb{R} \mid 0 < G_k \leq 1\} \quad (4-13)$$

mit d_{ij} : Abstand zwischen Pixel i und Pixel j in Bildkoordinaten

Zentral-Peripher-Merkmal

Das **Zentral-Peripher-Merkmal** $ZEPE_k$ untersucht die Lage der Klassenpixel im Biotop bezogen auf ihren durchschnittlichen Abstand von der Zentrumsregion des Biotops (**Gleichung (4-15)**). Für die Bestimmung der Zentrumsregion werden die 3 % der innersten Biotoppixel extrahiert. Den kleinsten Wert Null erhält eine Klasse, die genau und ausschließlich im Zentrum lokalisiert ist. Ein Auftreten der Klasse in der Nähe des Biotoprandes resultiert in einem Wert um 1, da das Merkmal mit dem durchschnittlichen Abstand der Biotoprandpixel vom Zentrum D_{Rand} normiert wird. Dieser berechnet sich aus:

$$D_{Rand} = \frac{1}{n_{Rand}} \sum_{g=1}^{n_{Rand}} \sum_{j=1}^{n_z} MIN(d_{gj}) \quad (4-14)$$

mit n_z : Anzahl der Biotopzentrumspixel

d_{gj} : Abstand zwischen Biotoprandpixel g und Biotopzentrumspixel j , so dass $\sum_{j=1}^{n_z} MIN(d_{gj})$ die kürzeste Entfernung zwischen Biotoprandpixel i und dem Biotopzentrum ist.

Der durchschnittliche Abstand der Pixel einer Klasse k von der Zentrumsregion eines Biotops ergibt sich aus:

$$D_k = \frac{1}{n_k} \sum_{i=1}^{n_k} \sum_{j=1}^{n_z} MIN(d_{ij}) \quad (4-15)$$

mit d_{ij} : Abstand zwischen Klassenpixel i und Biotopzentrumspixel j , so dass $\sum_{j=1}^{n_z} MIN(d_{ij})$ die kürzeste Entfernung zwischen Klassenpixel i und dem Biotopzentrum ist.

Das Merkmal $ZEPE_k$ resultiert aus der Normierung:

$$ZEPE_k = \frac{D_k}{D_{Rand}} \quad ZEPE_k \in \mathbb{R}_+ \quad (4-16)$$

Um speziell die Lage der Wohngebäude zu untersuchen, wurde aus dem Merkmal $ZEPE_k$ durch Einführung einer Nebenbedingung das Merkmal $ZEPE_{kh}$ entwickelt. Die Nebenbedingung, dass

nur Pixel mit einer Mindestobjekthöhe ausgewertet werden, bewirkt, dass niedrigere Gebäude wie Garagen²¹ unberücksichtigt bleiben.

Klassenspezifische Objekthöhen

Neben den höhenbezogenen Merkmalen auf Biotopenebene werden die **Objekthöhen** auch **klassenspezifisch** ausgewertet. Die vier statistischen Parameter Minimum, Maximum, Mittelwert und Standardabweichung werden hier pro Klasse ermittelt.

4.3 Segmentmerkmale

Die Berechnung der Klassensegmentmerkmale ist eine Besonderheit: Da es unterschiedlich viele Segmente einer Klasse in einem Biotop geben kann und ein Segmentmerkmal für jedes Segment der Klasse berechnet wird, entstehen zunächst ein oder mehrere Werte pro Biotop. Diese werden anschließend mit den statistischen Parametern Minimum, Maximum, Mittelwert und Standardabweichung zu einem Wert pro Biotop zusammengefasst, so dass aus jedem Basissegmentmerkmal vier neue Merkmale entstehen. Dies gilt für alle Segmentmerkmale außer der Anzahl der Segmente einer Klasse $N\text{Seg}_k$ und der Orientierung $O\text{Seg}_k$ der Segmente zueinander.

Ein großer Teil der Segmentmerkmale entspricht in ihrer Berechnung den Merkmalen auf Biotopenebene, nur dass sie statt auf die Biotopfläche auf die Fläche der Klassensegmente angewendet werden. So werden wie entsprechend in Kapitel 4.1 erläutert der **Flächeninhalt**, **Umfang**, **Kompaktheitsgrad** und der **Lineare-Segmente-Indikator** berechnet. Darüber hinaus wurden die folgenden Merkmale entwickelt:

Anzahl der Segmente

Die **Anzahl der Segmente** einer Klasse $N\text{Seg}_k$ ist eines der einfacheren Merkmale. Es kann sich dazu eignen, Biototypen mit vielen freistehenden Gebäuden (z.B. Einzelhausbebauung) von solchen mit wenigen oder nicht freistehenden Gebäuden zu unterscheiden.

Volumen der Segmente

Das Volumen der Segmente setzt sich gemäß **Gleichung (4-17)** aus den Volumina der Pixel zusammen, die das Segment bilden. Das Volumen eines Pixels ergibt sich aus der Grundfläche des Pixels und dem Höhenwert des nDOM. Auf diese Weise können z.B. die Volumina von Gebäuden oder Bäumen berechnet werden.

$$\text{VolSeg}_k = \sum_{i=1}^{n_s} h_i \Delta^2 \quad (4-17)$$

mit n_s : Anzahl der Pixel des Segments
 Δ : räumliche Auflösung des Datensatzes in Metern

²¹ Garagen sind als einzige Gebäude im Innenhof der Blockrandbebauung erlaubt.

Relative Orientierung der Segmente

Die **Orientierung O_{Seg_k} der Segmente einer Klasse zueinander** ergibt sich aus dem Winkel zwischen den ersten Hauptachsen (Eigenvektoren) der Segmente. Dafür wird jedes Segment einer Hauptachsentransformation unterzogen, die entsprechend der Hauptachsentransformation der Biotopflächen beim *LSI* (Kap. 4.1) durchgeführt wird. Anschließend werden paarweise die Winkel zwischen den ersten Eigenvektoren der Segmente berechnet (**Gleichung (4-19)**) und aus ihnen ein durchschnittlicher Winkel ermittelt, der den Ergebniswert des Merkmals bildet (**Gleichung (4-20)**). Das Merkmal ist speziell dafür ausgelegt, die Zeilenbebauung zu identifizieren, die sich zumeist durch entweder parallel stehende oder rechtwinklig zueinander stehende Gebäude auszeichnet. Daher wurde die Berechnung der einzelnen Winkel dahingehend modifiziert, dass Winkel zwischen 45° und 90° auf das Intervall $0-45^\circ$ gespiegelt werden, so dass 90° auf 0° fällt und beide zu einem kleinen Merkmalswert führen.

Wenn

$$\vec{x}_i = \begin{pmatrix} x_i \\ y_i \end{pmatrix} \quad (4-18)$$

der Eigenvektor eines Segments ist, dann ergibt sich der Winkel zwischen den Eigenvektoren \vec{x}_i und \vec{x}_j zweier Segmente aus:

$$\cos \angle(\vec{x}_i, \vec{x}_j) = \frac{x_i x_j + y_i y_j}{\sqrt{x_i^2 + y_i^2} \cdot \sqrt{x_j^2 + y_j^2}} \quad (4-19)$$

Die durchschnittliche Orientierung O_{Seg_k} der Segmenten einer Klasse k zueinander berechnet sich nach:

$$O_{Seg_k} = \frac{2!(N_{Seg_k} - 2)!}{N_{Seg_k}!} \left(\sum_{i=1}^{N_{Seg_k}-1} \sum_{j=i+1}^{N_{Seg_k}} \angle(\vec{x}_i, \vec{x}_j) \right) \quad O_{Seg_k} \in \{\mathbb{R} \mid 0 \leq O_{Seg_k} \leq 45\} \quad (4-20)$$

mit \vec{x}_i : erster Eigenvektor des Klassensegments i
 $\angle(\vec{x}_i, \vec{x}_j)$: Winkel zwischen den ersten Eigenvektoren der Klassensegmente i und j

Entfernung zwischen den Segmenten

Die **Entfernungen zwischen den Segmenten** einer Klasse im Biotop werden auf unterschiedliche Weise untersucht. Berechnet wird dabei die Entfernung der Schwerpunkte zweier Segmente ($D_s Seg$) oder die kürzeste Verbindungslinie von Segmentrand zu Segmentrand ($D_p Seg$). Je nach Merkmal werden diese paarweise berechneten Entfernungen analog zu einer ungeordneten Stichprobe ohne Zurücklegen (Kombinatorik) oder analog zu einer geordneten Stichprobe ohne Zurücklegen ausgewertet. So wird zum Beispiel die durchschnittliche Entfernung $D_s Seg_{Mean_k}$ zwischen allen Segmenten einer Klasse im Biotop entsprechend der **Gleichung (4-21)** berechnet:

$$D_1Seg_{Mean_k} = \frac{2!(NSeg_k - 2)!}{NSeg_k!} \left(\sum_{i=1}^{NSeg_k-1} \sum_{j=i+1}^{NSeg_k} \sqrt{(\bar{x}_i - \bar{x}_j)^2 + (\bar{y}_i - \bar{y}_j)^2} \right) \quad (4-21)$$

$$NSeg_k \leq 2; D_1Seg_{Mean_k} \in \{\mathbb{R} \mid D_1Seg_{Mean_k} \geq 1\}$$

mit \bar{x}_i und \bar{x}_j : x -Werte der Schwerpunkte der Segmente i und j
 \bar{y}_i und \bar{y}_j : y -Werte der Schwerpunkte der Segmente i und j

Die Berechnung der Länge der kürzesten Verbindungslinie (= kürzester Abstand zwischen den Segmenträndern) zweier Segmente der gleichen Klasse im Biotop wird mit der **Gleichung (4-22)** vorgenommen. Von Interesse ist hier der für jedes Segment s_i kürzeste Abstand zu allen anderen Segmenten s_j der Klasse im Biotop, deren Berechnung der geordneten Stichprobe entspricht (**Gleichung (4-23)**). Diese kürzesten Abstände der Segmente pro Klasse können dann wiederum mit einem statistischen Parameter zu einem Wert pro Biotop zusammengefasst werden. Die in **Gleichung (4-24)** gezeigte Berechnung der Standardabweichung könnte zum Beispiel zur Erkennung der Zeilenbebauung beitragen, deren Gebäude häufig im gleichen Abstand zueinander stehen, wodurch eine geringe Standardabweichung der kürzesten Abstände zu erwarten ist.

$$D_2Seg_{Min_k}(s_1, s_2) = \underset{n=1}{MIN} \underset{m=1}{MIN} \left(\sqrt{(x_n - x_m)^2 + (y_n - y_m)^2} \right) \quad \forall n \neq m \quad (4-22)$$

mit $P(x_n, y_n)$: Pixel des Segments s_1
 $P(x_m, y_m)$: Pixel des Segments s_2
 N : Anzahl der Pixel des Segments s_1
 M : Anzahl der Pixel des Segments s_2

$$D_2Seg_{Min_k}(s_i) = \underset{j=1}{MIN} \left(D_2Seg_{Min_k}(s_i, s_j) \right) \quad \forall i \neq j \quad (4-23)$$

mit J : Anzahl der Segmente der Klasse k im Biotop

$$D_2Seg_{Min\sigma_k} = SD \left(D_2Seg_{Min_k}(s_i) \right) \quad D_2Seg_{Min\sigma_k} \in \{\mathbb{R} \mid D_2Seg_{Min\sigma_k} \geq 1\} \quad (4-24)$$

mit $SD(\dots)$: Standardabweichung der kürzesten Entfernungen

Längliche-Segmente-Indikator

Der **Längliche-Segmente-Indikator** ($LSI2_ABS$) berechnet den längstmöglichen Weg in Metern durch das Skelett (engl.: *skeleton*) eines Segments, ohne dass ein Pixel zweimal passiert wird. Im Unterschied zum LSI , der für die Erkennung von gradlinigen, länglichen Objekten ausgelegt ist, spielt die Form des Objektes beim $LSI2_ABS$ keine Rolle. Die Berechnung erfolgt durch Zählen der Pixel entlang des längsten Weges und durch Multiplikation der Pixelanzahl mit der räumlichen Auflösung des Datensatzes in Metern. Eine zweite Variante bildet der $LSI2_REL$, bei dem die Anzahl der Pixel des längsten Weges durch die Gesamtzahl der Pixel des Skeletts dividiert wird. Der Wertebereich des $LSI2_REL$ liegt dadurch zwischen 0-1, wobei die 0 ausgeschlossen ist und die 1 ein Skelett ohne Verzweigungen bedeutet. Mit dem $LSI2_ABS2$ wurde eine dritte Variante entwickelt, bei der der $LSI2_ABS$ mit dem Quadrat des $LSI2_REL$ ge-

wichtet wird. Hierdurch wird die Länge eines Skeletts mit vielen Verzweigungen relativiert, während lange Skelette mit wenigen Verzweigungen hohe Werte behalten.

Objekthöhen der Segmente

Bei der Auswertung der **Objekthöhen der Segmente** entstehen 16 neue Merkmale aus einem Basismerkmal. Die Objekthöhen der Pixel der Segmente werden zunächst pro Segment mit den vier statistischen Parametern Minimum, Maximum, Mittelwert und Standardabweichung zusammengefasst. Anschließend werden die sich daraus ergebenden Werte der Segmente eines Biotops zu einem Gesamtwert des Biotops zusammengefasst – ebenfalls mit den vier statistischen Parametern. So ergeben sich die Merkmale:

$H_{Seg_{MinMin_k}}$, $H_{Seg_{MinMax_k}}$, $H_{Seg_{MinMean_k}}$, $H_{Seg_{Min\sigma_k}}$, $H_{Seg_{MaxMin_k}}$, $H_{Seg_{MaxMax_k}}$, $H_{Seg_{MaxMean_k}}$, $H_{Seg_{Max\sigma_k}}$, $H_{Seg_{MeanMin_k}}$, $H_{Seg_{MeanMax_k}}$, $H_{Seg_{MeanMean_k}}$ und $H_{Seg_{Mean\sigma_k}}$, $H_{Seg_{\sigma Min_k}}$, $H_{Seg_{\sigma Max_k}}$, $H_{Seg_{\sigma Mean_k}}$ und $H_{Seg_{\sigma\sigma_k}}$

4.4 Quantitative ökologische Parameter und Indikatoren

Für die ökologische Charakterisierung und Bewertung von Stadtbiotopen existiert in der stadtökologischen Literatur sowie in der Praxis der Landschafts- und Bauleitplanung eine Vielzahl möglicher Parameter und integrativer Indikatoren (z.B. Berlekamp & Pranzas 1986, Böhme 1986, Krause 1989, Pohl 1991, Brenneisen 1997, Arlt *et al.* 2003). Die Parameter erfassen, inwieweit ein Biotop *spezifische* ökologische Funktionen wahrnehmen kann, beziehungsweise wie stark diese durch anthropogene Eingriffe beeinträchtigt sind. Beispiele sind die Beeinträchtigung der Grundwasserneubildung durch Versiegelung des Bodens oder der Einfluss eines Biotops auf das Stadtklima, gemessen an der thermalen Wirkung der im Biotop vorhandenen Oberflächenarten. Einige Autoren haben durch Gewichtung und Zusammenfassen ausgewählter Parameter integrative Indikatoren entwickelt (z.B. Bötticher & Fisch 1988, Rose 1991). In einer Karte dargestellt, eignen sich diese besonders zur Gewinnung eines unspezifischen Überblicks über die ökologische Wertigkeit der Stadtbioptopie bzw. der Stadtgebiete. In **Tabelle 4-1** wird eine Übersicht der quantitativen Parameter und Indikatoren gegeben, die im Rahmen einer Literaturstudie mit Schwerpunkt im deutschsprachigen Raum gefunden wurden. Es wird eine Einschätzung zur Umsetzbarkeit einer automatischen Erhebung der Parameter und Indikatoren mit Fernerkundungsdaten abgegeben. Neben den quantitativen finden auch qualitative Parameter und Indikatoren Anwendung (z.B. das Ausstattungspotenzial eines Biotops für das Naturerleben durch den Menschen (Schulte *et al.* 1993: 515)). Diese werden jedoch in dieser Arbeit nicht behandelt, da hier eine Automatisierung kaum möglich erscheint.

Tabelle 4-1 Liste ökologischer Parameter und Indikatoren. Die Spalte FE enthält eine Einschätzung, inwieweit sich die Parameter / Indikatoren anhand von hyperspektralen Fernerkundungsdaten und in Deutschland (zukünftig) flächendeckend vorhandener GIS-Daten (z.B. dem AFIS-ALKIS-ATKIS-Modell) automatisch erfassen lassen. (1): Automatische Erfassung vollständig möglich. (2a) Erfassung nur in modifizierter Form möglich, da einige urbane Oberflächenarten (z.B. Fassadenbegrünung, Rasengittersteine oder Pflasterarten mit unterschiedlichen Fugenanteilen) nicht unterschieden werden können. (2b) Erfassung nur in modifizierter Form möglich, da einzelne Faktoren (z.B. Anschluss an die Kanalisation, Schädigungsgrad der Vegetation) nicht erfassbar sind. (2c) Kombination aus 2a und 2b. (3) Automatische Erfassung nicht möglich.

	Name	P / I	FE	Beschreibung	Quelle
Boden, Versickerungsleistung, Versiegelung	Versiegelungsgrad	P	1	Flächenanteil der teil- und vollversiegelten ²² Flächen in einer Bezugsfläche ohne Gewichtung.	(Berlekamp & Pranzas 1986)
	Bodenfunktionszahl (auch: gewichteter Versiegelungsgrad)	P	2a	Die Bodenfunktionszahl wurde in Hamburg eingeführt, um in Bebauungsplänen und Flächennutzungsplänen eine minimale ökologische Leistungsfähigkeit des Bodens verbindlich festzuschreiben. Sie entspricht dem gewichteten Flächenanteil der urbanen Oberflächenarten in einer Bezugsfläche. Die Gewichtung erfolgt nach der Versiegelung bzw. Versickerungsleistung des Bodens.	(Pohl 1991, Heiden 2004: 29)
	Versiegelungszahl	I	2c	Gewichteter Flächenanteil der urbanen Oberflächenarten in einer Bezugsfläche. Anders als der Versiegelungsgrad und die Bodenfunktionszahl ist die Versiegelungszahl nach Sperber ein integrativer Indikator, da bei der Gewichtung diverse Faktoren (z.B. Grundwasserneubildung, Stadtklima, Wohnqualität) berücksichtigt werden.	(Sperber & Meyer 1989)
	Entsiegelungszahl	I	2c	Die Entsiegelungszahl gibt an, um wie viel sich die Versiegelungszahl eines Gebietes nach einer tatsächlichen oder angenommenen Entsiegelung verbessert hat. Sie ist somit eine Charakterisierungsgröße der Effektivität von Entsiegelungsmaßnahmen.	(Sperber & Meyer 1989)
	Pro Kopf Versiegelung	I	2c	Quotient aus Versiegelungszahl und Anzahl der Bewohner einer Bezugsfläche.	(Sperber &

²² Bodenversiegelung ist die anthropogene Isolierung des Bodens einschließlich des Grundwassers und des Bodenlebens von der Atmosphäre durch verdichten, abdichten oder überschütten mit der Folge, dass die vielfältigen Austauschprozesse und Bodenfunktionen beeinträchtigt oder gänzlich unterbunden werden (nach: Berlekamp & Pranzas 1986, Sperber & Meyer 1989, Blume 2004: 167)

					Meyer 1989)
Wasser	Abflussbeiwert	P	2a	Prozentualer Anteil des Niederschlagswassers, das oberflächlich abfließt. Die Berechnung basiert auf empirisch ermittelten durchschnittlichen Abflusswerten der urbanen Oberflächenarten.	(Imhoff & Imhoff 2006: 64 ff.)
	Standgewässerflächenzahl	P	1	Flächenanteil der Standgewässer in einer Bezugsfläche.	(Krause 1989)
Vegetation	Vegetationsflächendeckungsanteil	P	1	Flächenanteil der ebenerdig vegetationsbedeckten Flächen. Zur ebenerdig wachsenden Vegetation gehören z.B. Rasen-, Wiesen- und Weidengesellschaften, vegetationsbestandene Äcker und Brachen.	(Krause 1989)
	Überschirmungsanteil	P	1	Flächenanteil der vegetationsüberschirmten Flächen. Zur überschirmenden Vegetation gehören Bäume und Sträucher.	(Krause 1989)
	Gesamtvegetationsflächenanteil	P	1	Summe aus Vegetationsflächendeckungsanteil und Überschirmungsanteil = gesamter Flächenanteil der Vegetation in einer Bezugsfläche.	(Krause 1989)
	Grünvolumenzahl	P	1	Quotient aus dem Volumen der Vegetation (m ³) und der Größe der Bezugsfläche (m ²), also Grünvolumen pro Quadratmeter.	(Pohl 1991, Arlt <i>et al.</i> 2003, Meinel <i>et al.</i> 2006)
	<i>green plot ratio</i> (GPR)	P	2a	Der GPR ist das Verhältnis aus der Blattfläche der Vegetation und der Bezugsfläche. Die Berechnung entspricht demnach dem Blattflächenindex (LAI), wobei die Bezugsfläche nicht die Standfläche der Vegetation ist, sondern eine wählbare Bezugsfläche wie z.B. ein Biotop / Baublock.	(Ong 2003)
	<i>fraction of surrounding vegetation</i>	P	1	Vegetationsanteil innerhalb konzentrischer Kreise um ein Haus zur Beurteilung der Lebensqualität einer Wohngegend.	(Möller & Blaschke 2006)
Klima	Klimawertigkeitsindex	P	2a	Gewichteter Flächenanteil der urbanen Oberflächenarten in einer Bezugsfläche. Die Gewichtung erfolgt auf Basis der thermalen Eigenschaften der Oberflächenarten (von „stark erhitzen“ bis zu „stark abkühlend“).	(Möller 1997)

Naturbelas- senheit	Flächenbilanzwert	P	1	Die urbanen Oberflächenarten werden in biologisch aktive (Vegetation, Wasser) und biologisch inaktive Flächen (versiegelte Flächen) eingeteilt. Der Flächenbilanzwert ergibt sich aus der Differenz dieser beiden Größen und wird durch Division durch die Gesamtfläche auf den Wertebereich [-1,1] normiert.	(Krause 1989)
Integrative Indikatoren	KÖH-Wert	I	2c	Der klimatisch-ökologisch-hygienische Wert (KÖH-Wert) basiert auf einer Unterteilung der urbanen Oberflächenarten in Gunstflächen und Ungunstflächen. Nach Kriterien aus den Bereichen Klimawirkung, Luftschadstoff- und Lärmbelastung sowie ökologische Funktion legt Schulz für jede Gunst- und Ungunstflächenart einen Multiplikator zur Gewichtung fest. Nach Anwendung des Multiplikators auf die Flächenanteile der Gunst- und Ungunstflächen einer Bezugsfläche ergibt sich der KÖH-Wert aus dem Quotienten der Gunst- und Ungunstflächen. Es fließen auch vertikale Flächen (Fassadenbegrünung) mit ein.	(Schulz 1982)
	ökologisches Ausgleichspotential durch Dachbegrünung (ÖAP-DB)	I	2c	Bezogen auf dem KÖH-Wert wird die prozentuale Verbesserung errechnet, die durch eine hypothetische Dachbegrünung erreicht werden kann.	(Brenneisen 2008)
	KÖP-Wert	I	2c (3)	Der klimaökologisch-pedologische Wert (KÖP-Wert) berechnet sich aus dem Mittelwert der drei Komponenten Bodenfunktionswert (ähnlich der Bodenfunktionszahl von Pohl (1991)), dem gewichteten Verhältnis von Grün- und Gebäudevolumen und dem Klimatopwert (Einstufung der Klimawirksamkeit der urbanen Oberflächenarten). Es fließen auch vertikale Flächen (Fassadenbegrünung) mit ein.	(Rose 1991)
	Biotopflächenfaktor (BFF)	I	2b	Der BFF wurde in Berlin eingeführt, um in Bebauungsplänen und Flächennutzungsplänen eine minimale ökologische Leistungsfähigkeit einer Fläche verbindlich festzuschreiben. Er ergibt sich aus dem Quotienten der gewichteten Flächenanteile der urbanen Oberflächenarten und der Gesamtfläche einer Bezugsfläche. Die Gewichtung erfolgt nach der Leistungsfähigkeit für den Naturhaushalt (z.B. Wasserhaushalt, Bodenfunktionen, Mikroklima, Habitatfunktion etc.). Es fließen auch vertikale Flächen (Fassadenbegrünung) mit ein.	(Böttcher & Fisch 1988)

	ÖKO-Wert	I	2a	Der Kennwert für ökologische Flächenleistungen (ÖKO-Wert) bewertet eine Bezugsfläche nach bestimmten Kriterien aus den Kategorien Boden, Wasser, Klima/Luft, Flora und Fauna. Die Berechnung basiert auf den urbanen Oberflächenarten, die bezogen auf die Bewertungskriterien mit Gütewerten versehen werden. Für jede Oberflächenart wird ein mittlerer Gütewert aus allen Einzelkriterien berechnet und als Gewichtungsfaktor bei der Berechnung des ÖKO-Werts benutzt. Dieser ergibt sich aus der Summe der gewichteten Flächenanteile der urbanen Oberflächenarten einer Bezugsfläche und wird durch die Größe der Bezugsfläche normiert.	(Heber & Lehmann 1996: Kap. 7.2)
	ökologische Flächenleistungswerte (ÖFL)	I	2a	Der ÖFL-Indikator ist eine Weiterentwicklung des ÖKO-Werts, bei dem leichte Modifikationen in den Bewertungskriterien und den zugrunde liegenden urbanen Oberflächenarten vorgenommen wurden.	(Arlt & Lehmann 2005)

(Krause 1989) und (Sandtner 1998) heben die Relevanz urbaner Oberflächenarten für stadtökologische Aussagen hervor. So hängt die ökologische Funktion einer Fläche stark von der Art ihrer Oberflächenbedeckung ab. Diese Aussage wird durch die Beschreibungen der Parameter und Indikatoren in **Tabelle 4-1** unterstrichen, aus denen klar hervorgeht, dass die wichtigste Informationsquelle zu ihrer Berechnung eine flächendeckende Kartierung der urbanen Oberflächenarten ist. Krause entwickelte ein Gliederungsschema, das die verschiedenen urbanen Oberflächenarten nach ihrer stadtökologischen Funktion einteilt. Ein ähnliches Schema (**Abbildung 3-18** und **Tabelle 3-6** in Kap. 3.4.3) wird bei der Klassifizierung und Entmischung von Hyperspektraldaten mit dem am GFZ Potsdam entwickelten Verfahren verwendet. Ein Vergleich der Klassenliste (**Tabelle 3-6** in Kap. 3.4.3) und der in **Tabelle 4-2** gelisteten Oberflächenarten zeigt, dass die wichtigsten urbanen Oberflächenarten, auf denen die Berechnung der in **Tabelle 4-1** aufgeführten Parameter und Indikatoren basiert, mit Hyperspektraldaten unterschieden werden können. Ausnahmen bilden Tiefgaragen, die jedoch in einigen Bundesländern in ALKIS verzeichnet sind oder sein werden²³, Fassadenbegrünungen, Rasengittersteine sowie die Differenzierung der Fugenanteile bei Pflasterarten. Im letzteren Fall kann pro Pflasterart nur ein durchschnittlicher Fugenanteil als Annahme festgelegt werden.

Tabelle 4-2 Übersicht der wichtigsten Oberflächenarten, auf denen die Berechnung der in **Tabelle 4-1** aufgeführten Parameter und Indikatoren basiert (verändert nach Meinel & Netzband 1996).

anthropogen überformten Flächen	Natürliche Oberflächen
Gebäude	Offener Boden / Acker
Asphalt / Beton (vollversiegelte Freiflächen)	Bäume
Platten (teilversiegelte Freiflächen)	Sträucher, Hecken
Kleinpflaster (teilversiegelte Freiflächen)	Stauden
Wassergebundene Decken (teilversiegelte Freiflächen)	Gepflegter Rasen
Rasengittersteine	Wiesen (Grünland)
Dachbegrünung	natürliche Wasserflächen
Fassadenbegrünung	
Tiefgaragen	
künstlich angelegte Wasserflächen ohne Bodenschluss (Pool, Gartenteich)	

Die Verwendung des Schemas bei der Klassifizierung und Entmischung der Hyperspektraldaten macht es möglich, dass die Berechnung vieler ökologischer Parameter und Indikatoren direkt aus der erzeugten flächendeckenden Klassifizierung erfolgen kann. Dies zeigten Förster (2002) und Heiden (2004) am GFZ Potsdam erstmals für Untersuchungsgebiete in den Städten Potsdam und Dresden. Förster berechnete die notwendigen Eingabeparameter für den Indikator KÖP-Wert (Rose 1991) in leicht modifizierter Form. Sechs weitere ökologische Parameter wurden von Heiden abgeleitet: Der ungewichtete und gewichtete Versiegelungsgrad, der Bebauungsgrad, der Überschirmungsgrad, der Vegetationsbedeckungsgrad und der Gesamtvegetationsanteil. Durch eine Genauigkeitsuntersuchung am Beispiel des Parameters „ungewichteter Versiegelungsgrad“ konnte Heiden (2004: 92) zeigen, dass sich mit der automatischen Berechnung basierend auf den aus Hyperspektraldaten abgeleiteten urbanen Oberflächenarten eine

²³ ALKIS ist die digitale Zusammenführung von ALK und ALB und Bestandteil des AFIS-ALKIS-ATKIS-Modells, das derzeit als einheitliche Vektor-Geodatenquelle für Deutschland aufgebaut wird.

höhere Genauigkeit erzielen lässt als mit der Standarderfassungsmethode – der visuellen Schätzung aus Luftbildern. Als Referenz diente eine manuelle Digitalisierung aus Luftbildern, von der der automatisch abgeleitete Versiegelungsgrad nur um 7,1 % (+6,3 %) abwich (Mittelwert der absoluten Abweichungen \pm Standardabweichung). Fünf der Parameter von Heiden (ohne den ungewichteten Versiegelungsgrad) wurden in dieser Arbeit übernommen und in den Untersuchungsgebieten Dresdens und Berlins berechnet. Sie werden als zusätzliche Attribute während der Aktualisierungskartierung erhoben, wie es in Kapitel 7.4 näher erläutert wird.

5 Wissensbasierter Aufbau von Fuzzy Logik Modellen zur Klassifizierung von Stadtbiotopen

Dieses Kapitel zeigt die Entwicklung und Anwendung eines von zwei Klassifizierern für Stadtbiotope. Die Biotope werden nach ihrem Biotoptyp klassifiziert, d.h. der Klassifizierer soll in der Lage sein, den Typ eines Biotops automatisch zu erkennen. Der Klassifizierer besteht aus einer Gruppe von Fuzzy Logik Modellen, da jeder implementierte Biotoptyp ein eigenes Modell besitzt. Die Modelle werden unter Einbindung von Expertenwissen aufgebaut. Der Prozess des Aufbaus der Modelle und des gesamten Klassifizierers ist in **Abbildung 5–1** dargestellt. Kapitel 3 und 4 haben bereits die im oberen Teil der Abbildung gezeigte Schaffung der Datenbasis und die Berechnung der Merkmale beschrieben. Die Entwicklung der Modelle umfasst die Arbeitsschritte Konzeption der Modelle (Kap. 5.2), Auswahl von Merkmalen (Kap. 5.3) und die Modellkalibrierung (Kap. 5.4). In Kapitel 5.5 wird eine Genauigkeitsüberprüfung des Klassifizierers anhand von ausgewählten Biotoptypen im Untersuchungsgebiet Dresden durchgeführt.




Abbildung 5–1 Arbeitsschritte von den Ausgangsdaten bis zum Aufbau des Biotop-Klassifizierers.

5.1 Gründe für die Verwendung von Fuzzy Logik

Der Hauptzweck und Vorteil der Fuzzy Logik ist die Möglichkeit, vorhandenes menschliches Wissen in funktionierende computerbasierte Algorithmen zu überführen (Kecman 2001: XI). Die Grundvoraussetzung für die Verwendung der Fuzzy Logik ist also, dass menschliches Wissen über ein Problem vorhanden ist und ein Mensch auf Basis dessen mit logischem Denken eine Lösung finden kann (Kecman 2001: XXVII f.). Ist dies der Fall, kann mit Hilfe der Fuzzy Logik der menschliche Denkprozess nachgeahmt werden, indem das vorhandene (in der Regel unscharfe) Wissen über die kausalen Zusammenhänge in die Form von *if-then*-Regeln gebracht und in einen computerbasierten Algorithmus eingebettet wird (Kecman 2001: XXVII ff.). Neben dieser Grundvoraussetzung ist Fuzzy Logik immer dann eine geeignete Methode, wenn

- I. es keine klassische mathematisch-physikalisch basierte Lösung des Problems gibt (Kecman 2001: XXVIII). Dies kann der Fall sein, wenn die Zusammenhänge nicht exakt, sondern nur ungefähr bekannt sind oder die entscheidenden Parameter nicht quantitativ, sondern nur qualitativ erhoben werden können.
- II. die Grenzen zwischen Zuständen, Klassen oder Entscheidungen fließend, d.h. unscharf (engl.: *fuzzy*) sind. Dies ist in der Natur ein häufiges Phänomen und dennoch haben sich der Einfachheit halber häufig scharfe Grenzziehungen etabliert. (Demicco & Klir 2004: 12) führen als Beispiel die Korngröße der mineralischen Bodensubstanz an. Die Klassen Ton, Schluff, Sand und Kies werden durch scharfe Grenzziehungen gebildet. So gehört ein Partikel mit dem Durchmesser 1,999 mm zur Sandfraktion, während ein Partikel der Größe 2,001 mm zur Fraktion Kies gezählt wird. In der Fuzzy Logik würde eine unscharfe Modellierung der Grenzübergänge den Partikeln im Grenzbereich unterschiedliche Zugehörigkeitsgrade zu beiden Klassen zuteilen. Ein großer Vorteil der unscharfen Repräsentierung der Klassen ist die stärkere Unempfindlichkeit gegenüber Messfehlern. Während ein Partikel im Grenzbereich durch einen Messfehler komplett der falschen scharfen Klasse zugeordnet werden würde, ändern sich bei der unscharfen Repräsentierung der Klassen die Zugehörigkeitsgrade nur leicht.
- III. die Parameter (z.B. die in Kap. 4 beschriebenen Merkmale), die die Basis einer Klassifizierung bilden, in unterschiedlichen Wertebereichen und/oder Skalen (Nominal- bis Ratioskala) vorliegen. Durch die Anwendung von Zugehörigkeitsfunktionen der Klassen werden die erhobenen Parameter eines Objekts unabhängig von Skala oder Wertebereich auf das Intervall von 0-1 abgebildet, das die Zugehörigkeit des Objekts zur entsprechenden Klasse ausdrückt. Die Definition der Zugehörigkeitsfunktionen, die hauptsächlich eine semantische Wertung der Parameterausprägungen bedeutet (und somit menschliches Wissen in die Fuzzy Logik Modelle implementiert), führt gleichzeitig eine Normierung und eine Überführung der erhobenen Parameter in die Ratioskala durch, was deren gemeinsame Auswertung stark vereinfacht.
- IV. der zu modellierende Prozess nicht-linear ist. Durch die Wahl der Zugehörigkeitsfunktionen, die Verwendung verschiedener Fuzzy Operatoren und die Möglichkeit, mehrere Regeln miteinander zu kombinieren (s. Kap. 2.2), können mit Fuzzy Logik komplexe, nicht-lineare Systeme aufgebaut werden.

Viele der oben genannten Punkte treffen auch auf die vorliegende Anwendung zu. Eine mathematisch-physikalisch basierte Lösung (Punkt I) gibt es nicht, da bei der Entscheidung für einen bestimmten Biotoptyp z.B. die Bauform der Gebäude oder das Vorkommen bestimmter Arten

und viele andere Parameter beurteilt und abgewogen werden müssen. Aus einer Fülle an Informationen die entscheidenden zu extrahieren und gegeneinander abzuwägen ist ein klassischer Vorgang, für den das menschliche Gehirn optimiert ist. Daher trifft auch die gestellte Grundvoraussetzung zu, dass Menschen die Aufgabenstellung lösen können, denn ein geschulter Luftbildauswerter ist in der Lage, viele urbane Biotoptypen in Fernerkundungsbildern zu erkennen. Das hierfür notwendige Wissen ist in zahlreichen Kartierschlüsseln festgehalten. Dieses Wissen gilt es, in Fuzzy Logik Modelle zu implementieren. Die Parameter, die die Basis der Entscheidungsfindung bilden, liegen dabei in unterschiedlichen Skalen vor (Punkt III). Die charakteristischen Wertebereiche, die von den Biotopen verschiedener Biotoptypen eingenommen werden, überlappen sich häufig und haben unscharfe Grenzen (Punkt II) (s. dazu **Abbildung 5–2** in Kap. 5.2). Auch die Nicht-Linearität (Punkt IV) trifft auf den Entscheidungsvorgang zu, denn ein Input-Parameter kann innerhalb eines charakteristischen Wertebereichs eines Biotoptyps verändert werden, ohne dass sich die Entscheidung für diesen Biotoptyp ändert. Erst wenn der typische Wertebereich verlassen wird, ändert sich die Entscheidung.

Ein weiterer Aspekt der Fuzzy Logik, der bereits in Kapitel 2.2 beschrieben wurde und in der vorliegenden Anwendung zum Vorteil genutzt werden kann, ist ihre Eigenschaft, mit Ungenauigkeiten, d.h. mit unscharfen Informationen, mathematisch rechnen zu können. Die unscharfen Informationen bei der Klassifizierung von Stadtbiotopen haben unterschiedliche Quellen. Zum einen sind hier die zumeist sprachlich formulierten Beschreibungen der Biotoptypen zu nennen, also der Klassen, in die die Stadtbiotope eingeteilt werden. Die Formulierung „Sehr dichte, meist geschlossene Bebauung des Stadtkerns“ (Schulte *et al.* 1993: 502) in der Beschreibung des Biotoptyps „Moderne Innenstadt“ impliziert beispielsweise, dass vollständig bebaute Gebiete des Stadtkerns ganz sicher zu diesem Biotoptyp gerechnet werden, aber auch, dass es einen unscharfen Bereich gibt, in dem die Zugehörigkeit eines Gebiets zu diesem Typ mit abnehmender Bebauungsdichte zügig sinkt.

Eine weitere Quelle von Ungenauigkeiten sind die Fernerkundungsdaten. Aufgrund von zahlreichen, teilweise unvermeidbaren Effekten ist bei der Auswertung von Fernerkundungsdaten selten eine Genauigkeit von 100 % zu erreichen. Die auftretenden Fehler sind zwar keine unscharfe Information im klassischen Sinne der Fuzzy Logik, sie können aber dennoch durch unscharfe Klassifikationskriterien teilweise abgefangen werden.

Als dritte Quelle von Ungenauigkeiten ist die Kombination aus den ersten beiden zu nennen, d.h. wenn eine scharf formulierte Eigenschaft der Biotoptypen, z.B. 3-8 Stockwerke der Wohngebäude, nur indirekt über die Gebäudehöhe mit Fernerkundungsdaten erfassbar ist. Hier können unterschiedliche Stockwerkshöhen (z.B. bei Altbau und Neubau) sowie unterschiedliche Dachformen (z.B. Flachdach, Spitzdach) dazu führen, dass beispielsweise ein 8-stöckiges Wohnhaus höher ist als ein 9-stöckiges. Da die Stockwerkshöhe der Gebäude nicht bekannt ist, ist kein eindeutiger, scharfer Rückschluss von der Gebäudehöhe auf die Anzahl der Stockwerke möglich. Es gibt einen unscharfen Bereich mehrerer Möglichkeiten, der mit der Fuzzy Logik modelliert werden kann.

5.2 Konzeption der Modelle

Die Konzeption der Modelle erfolgte unter dem Hintergrund folgender Anforderungen an den Klassifizierer:

- I. Der Klassifizierer muss erweiterbar sein, d.h. die Implementierung neuer Biotoptypen ermöglichen.
- II. Aufgrund diverser Variationen in der Ausstattung und baulicher Form der Biotope eines Typs, gibt es Biotope, die einem gewissen, definierten Prototyp der Biotoptypen stärker oder geringer entsprechen (s. Kap. 3.2.3). Weiterhin treten diverse Mischformen zwischen mehreren Biotoptypen auf (s. ebenfalls Kap. 3.2.3). Der Klassifizierer soll daher einen Ähnlichkeitswert liefern können, der besagt, wie stark ein bestimmtes Biotop dem Prototyp eines Biotoptyps entspricht.
- III. Aufgrund der Problematik mit den Mischformen zwischen Biotoptypen soll wählbar sein, ob der Klassifizierer die Entscheidung über den Biotoptyp einer Fläche selbstständig und automatisch treffen soll oder alternativ eine geeignete Informationsgrundlage (die Ähnlichkeitswerte der Biotoptypen) schaffen soll, auf deren Basis ein Experte (z.B. der zuständige Stadtplaner) die endgültige Entscheidung treffen kann. Ein sinnvoller Kompromiss zwischen beiden Extremen wäre die Einstellung, klare Entscheidungen automatisch treffen zu lassen und strittige Entscheidungen manuell zu tätigen.

Nachdem eine Auswahl verschiedener Programme zur Umsetzung der Modelle getestet wurde, fiel die Entscheidung auf die Fuzzy Logik Toolbox von MATLAB. Ein ausschlaggebender Punkt war hierbei die Möglichkeit, mit der Toolbox entworfene Modelle mit Hilfe einer mitgelieferten, in C programmierten Inferenzmaschine als *Stand-Alone*-Anwendung ohne eine MATLAB-Instanz starten zu können und in anderen C-Programmen aufrufen zu können.

Die Konstruktion der Modelle erfolgte vor dem Hintergrund der genannten Anforderungen an die Modelle und mit den Möglichkeiten der gewählten Software. Unter diesen Rahmenbedingungen haben die folgenden Überlegungen zum endgültigen Design der Modelle geführt. Hierbei waren zunächst grundsätzlich zwei Varianten der Umsetzung denkbar:

- I. Es wird ein einziges Fuzzy Modell entwickelt. Ein solches Modell müsste eine Outputvariable besitzen, deren linguistische Terme die einzelnen Biotoptypen wären. Die Outputvariable läge damit in einer Nominalskala vor und die Umsetzung der Terme in unscharfe Mengen müsste in Form von *Singletons* erfolgen. Ein solches Modell hätte einen Nachteil: Es kann nur die Entscheidung für *einen* Biotoptyp zum Ergebnis haben, da nach der Defuzzifikation ein scharfer Wert erzeugt werden muss, der auf genau einen der Biotoptypen auf der Nominalskala weist. Ein solches Modell wäre damit nicht in der Lage, Ähnlichkeitswerte für die Biotoptypen zu berechnen. Daher wurde diese Variante nicht umgesetzt.
- II. Es wird für jeden Biotoptyp ein eigenes Fuzzy Modell entwickelt. Der Outputwert eines jeden Modells soll als Ähnlichkeitswert interpretierbar sein, also als Wert, der die Ähnlichkeit des klassifizierten Biotops zum Biotoptyp des Modells auf einer Skala zwischen 0 und 1 ausdrückt. Werden alle Modelle aller Biotoptypen auf ein Biotop angewendet, so erhält man einen Satz von Ähnlichkeitswerten, die manuell oder automatisch ausgewertet werden können, um das Biotop endgültig zu klassifizieren. Somit wären Punkt II und III der gestellten Anforderungen erfüllt. Die Modelle aller implementierten Biotoptypen bilden zusammengekommen mit einem nachgeordneten Algorithmus zur automatischen Auswertung der Ähnlichkeitswerte den Klassifizierer (**Abbildung 5–1** zu Beginn des Kap. 5). Diese Struktur des Klassifizierers ist leicht erweiterbar (Punkt I der Anforderungen), da für neue Biotoptypen jeweils neue Modelle hinzugefügt werden können, ohne die vorhandenen Modelle verändern zu müssen.

Nach der grundsätzlichen Entscheidung für die zweite Variante, ergibt sich ein großer Teil des strukturellen Aufbaus der Modelle zwangsläufig (s. **Abbildung 5–3**). Da die Klassifizierung auf Basis der berechneten Merkmale erfolgen soll, bilden diese die Inputvariablen auf der Bedingungsseite der Regeln der Modelle. Die Outputvariable auf der Konsequenzseite der Regeln der Modelle bildet der jeweilig zum Modell gehörende Biotoptyp.

Die weitere Struktur der Modelle kann als eher untypisch bezeichnet werden, übt aber auf diese Weise ihre Funktion – die Berechnung eines Ähnlichkeitswertes – am besten aus. Für die Herleitung des strukturellen Aufbaus betrachten wir zunächst ein einzelnes Merkmal, das sich gut zur Erkennung eines bestimmten Biotoptyps eignet (**Abbildung 5–2**). Ein solches Merkmal zeichnet sich dadurch aus, dass die Merkmalswerte der Biotope des Biotoptyps in einem begrenzten, charakteristischen Wertebereich liegen, mit unscharfen Grenzen, und dass sich dieser Wertebereich mit dem von anderen Biotoptypen nur wenig überschneidet. **Abbildung 5–2** (links) zeigt ein solches Merkmal für die Biotope des Typs Blockbebauung. Für die Darstellung wurden die Biotope in prototypische und untypische Biotope (Kap. 3.2.3) aufgeteilt. Die Darstellung zeigt, dass die Merkmalswerte der untypischen Biotope stärker streuen als die der Prototypen (Minimum / Standardabweichung / Maximum: 0,14 / 0,16 / 0,76 im Vergleich zu 0,20 / 0,10 / 0,70). Dieser Effekt tritt bei vielen Merkmalen auf. Auf der rechten Seite der **Abbildung 5–2** wird ein weiteres Merkmal für die Biotope der Zeilenbebauung gezeigt. Es ist zu sehen, dass es im Wertebereich zwischen 2 und 4 eine Reihe untypischer Biotope gibt, deren Gebäude für den Typ Zeilenbebauung untypisch kurz sind (das gezeigte Merkmal berechnet das Verhältnis Länge zu Breite der Gebäude). Bei einem Merkmalswert von 2,0 wäre das Gebäude nur doppelt so lang wie breit, was eher für ein Doppelhaus als für eine Zeilenbebauung spricht.

Würde man für diese beiden Merkmale intuitiv Zugehörigkeitsfunktionen definieren, die den Biotopen des jeweiligen Typs anhand der Merkmale Zugehörigkeiten zu ihren jeweiligen Biototypen zuweisen sollen, so würde man im ersten Fall ein Plateau zwischen 0,4 und 0,7 mit der Zugehörigkeit von 1,0 definieren. Darüber hinaus gibt es offensichtlich zu beiden Seiten einen unscharfen Randbereich, in dem vorwiegend untypische Biotope liegen. Diesen Biotopen würde man eine geringere Zugehörigkeit zwischen 0 und 1 zuweisen und schließlich Biotopen mit Werten $< 0,1$ oder $> 0,8$ eine Zugehörigkeit von 0.

Im zweiten Fall würde man eine nach rechts offene Zugehörigkeitsfunktion (s. **Abbildung 5–5** in Kap. 5.4) verwenden, da sehr lange Gebäude typisch für die Zeilenbebauung sind. Das Plateau mit der Zugehörigkeit von 1,0 würde also bei einem gewissen Mindestlängenverhältnis von z.B. 4,5 beginnen und bis zum Ende des definierten Wertebereiches verlaufen. Biotopen mit Merkmalswerten zwischen 1,0 und 1,5 würde man den Zugehörigkeitswert 0 zuweisen und den zwischen 1,5 und 4,5 liegenden Biotopen eine unscharfe Zugehörigkeit zwischen 0 und 1. In Kapitel 5.4 werden zwei statistisch basierte Methoden vorgestellt, um diese intuitive Festlegung der Grenzen der Zugehörigkeitsfunktionen nachvollziehbar zu automatisieren.




Abbildung 5–2 Histogramme zweier Merkmale für die prototypischen und untypischen Biotope der Biototypen Blockbebauung (links) und Zeilenbebauung (rechts).

Zugehörigkeitsfunktionen, die auf diese Weise festgelegt werden, bilden die Merkmalswerte der Biotope auf eine Werteskala ab, die bereits als Ähnlichkeitswert interpretiert werden kann. So kann auf Basis von jedem einzelnen Merkmal bereits eine Aussage getroffen werden, ob ein zu klassifizierendes Biotop, dem Biototyp des Modells ähnlich ist oder nicht. Da zur Unterscheidung eines Biototyps von allen anderen Biototypen in der Regel mehr als ein Merkmal notwendig ist, werden die Modelle mehrere Input Merkmale enthalten. Um von den einzelnen Zugehörigkeitswerten der Inputvariablen zu einer Gesamtaussage des Modells zu gelangen, kann zunächst festgestellt werden, dass die Einzelaussagen der Inputvariablen alle gleichwertig sind und daher gleich zu gewichten sind. Sie können also alle in einer einzigen Regel zusammengefasst werden, was untypisch für Fuzzy Modelle ist. Der Operator der Regel muss ein Durchschnittsoperator, z.B. der Fuzzy MIN-Operator sein, da ein vereinigender Operator in sehr vielen Fällen auch für fremde Biotope einen sehr hohen Zugehörigkeitswert für die anschließende Inferenz des Modells liefern würde. Dies ist der Fall, da ein Merkmal, das aufgrund seiner guten Trennungseigenschaft für die Biototypen A und B im Modell des Typen A implementiert wurde, nicht gleichzeitig die Biotope des Typs C ebenfalls gut trennen muss. So ist es möglich, dass Biotope des Typs C bei diesem Merkmal im Modell des Typs A hohe Zugehörigkeitswerte erhalten können, die bei Verwendung eines vereinigenden Operators (z.B. dem Fuzzy MAX-Operator) für die Inferenz des Modells verwendet werden würden. Daher werden die Modelle so aufgebaut, dass der geringste der einzelnen Zugehörigkeitswerte der Inputvariablen (Merkmale) als Gesamtaussage des Modells verwendet wird (**Abbildung 5–3**). Dies wird durch eine MIN-MIN-Inferenz erreicht, d.h. durch die Verwendung des MIN-Operators zur Verknüpfung der Inputvariablen und bei der Implikation der Outputvariablen, deren Fuzzy Menge die Fläche unter der Geraden $f(x) = x$ ist.




Abbildung 5–3 Struktur und Funktionsweise eines Fuzzy Modells zur Erkennung eines Biototyps. Die Anzahl der Inputvariablen (Merkmale) ist nicht begrenzt. Der Ausgabewert des Modells ist als Ähnlichkeitswert interpretierbar.

5.3 Auswahl von Merkmalen

Da aus der Vielzahl der berechneten Merkmale sich nur jeweils eine geringe Anzahl zur Identifizierung eines Biotoptyps eignet, finden nur diese Eingang in das Modell des Biotoptyps. Für die Auswahl wurde ein halbautomatisches Verfahren entwickelt, das von zwei Seiten an das Problem herangeht. Zum einen wird das in den Kartierschlüsseln formulierte Wissen über die Ausstattung der Biotoptypen herangezogen. Viele Merkmale wurden speziell dafür entwickelt, bestimmte Eigenschaften bestimmter Biotoptypen numerisch zu erfassen und diese dadurch von anderen Typen zu unterscheiden. Auf Basis dieses vorhandenen Wissens können bereits viele geeignete Merkmale gefunden werden. Zum anderen können die typischen Wertebereiche der Merkmalshistogramme der Biotoptypen anhand von Trainingsbiotopen automatisch berechnet werden und in paarweise durchgeführten Vergleichen auf Überlappung geprüft werden. Die Aufteilung der Biotope in Trainings- und Testbiotope erfolgte dabei zufällig und geschichtet im Verhältnis 2:1, wobei die geschichtete Aufteilung sicherstellt, dass die Biotope jedes einzelnen Typs in diesem Verhältnis aufgeteilt werden. Besteht eine geringe Überlappung der Wertebereiche der Biotoptypen, so ist das Merkmal tendenziell geeignet, die Trennbarkeit der beiden Biotoptypen zu verbessern. Um sichere Merkmale zu erhalten, wurden diese immer von beiden Seiten her überprüft, d.h. ein wissenschaftlich selektiertes Merkmal wurde anhand der Überlappungsbereiche der Histogramme validiert, während ein automatisch selektiertes Merkmal auf Sinnhaftigkeit überprüft wurde, was bedeutet, dass die gute Trennbarkeit durch die charakteristischen Eigenschaften der Biotoptypen bedingt sein muss und nicht zufällig aufgrund der geringen Anzahl an Trainingsbiotopen zustande gekommen ist.

Als Überlappungsbereiche wurden bei den Berechnungen die Intervalle Minimum – Maximum und Mittelwert \pm Standardabweichung verwendet. Bei der Berechnung wurden nur die Merkmalswerte von prototypischen Biotopen berücksichtigt, um eine klarere Aussage zu erhalten. Weiterhin wurden die Überlappungsberechnungen paarweise für je zwei Biotoptypen durchgeführt (*One-Against-One* Strategie), da es nur sehr wenige Merkmale gibt, die einen Biotoptyp von allen anderen Biotoptypen trennen können (*One-Against-All* Strategie). Es können drei Fälle von paarweise Überlappungen unterschieden werden, nach denen entschieden wird, ob sich ein Merkmal potenziell zur Trennung der beiden Biotoptypen eignet oder nicht (**Abbildung 5–4**). Tritt Fall 1 auf, so ist das Merkmal ein Kandidat für die Modelle beider Biotoptypen (vorbehaltlich der Prüfung auf Sinnhaftigkeit). Im Fall 2 kann das Merkmal im Modell des Biotoptyps B implementiert werden, da durch das Merkmal ein großer Teil der Biotope des Typs A mit einem geringen Ähnlichkeitswert versehen wird. Im Fall drei eignet es sich dagegen nicht zur Trennung der beiden Biotoptypen. Damit ein Modell die eigenen Biotope erkennt und für die Biotope anderer Typen einen geringen Ähnlichkeitswert berechnet, müssen für jeden paarweise durchgeführten Vergleich zu einem der anderen Typen ein Merkmal des Falles 1 oder mehrere Merkmale des Falles 2 gefunden werden.




Abbildung 5–4 Überlappungsfälle der Merkmalshistogramme zweier Biotoptypen.

Die durchgeführten Untersuchungen haben gezeigt, dass Merkmale, die auf einzelnen Klassen berechnet wurden, sich schlechter zur Unterscheidung der Biotoptypen eignen als Merkmale, die auf Klassengruppen (s. Kap. 3.4.4) berechnet wurden. Selbst wenn diese eine geringe Überlappung der Trainingsbiotope aufweisen, ist die Überlappung bei den Testbiotopen häufig hoch. Dies führt dazu, dass Modelle, die Merkmale enthalten, die auf einzelnen Klassen berechnet wurden, eine sehr geringe Übertragbarkeit auf andere Biotope, Testgebiete oder gar andere Städte aufweisen. Dies kann damit begründet werden, dass die Wahl der Baumaterialien regional variieren kann. Ein Modell, das die Information enthält, dass 20-40 % der Fläche der Biotope des Typs Einzelhausbebauung mit roten Tonziegeln bedeckt ist, liefert zwangsläufig falsche Ergebnisse in Gebieten, in denen für die Dachdeckung des gleichen Typs von Häusern graue Betonziegel oder Schiefer bevorzugt werden. Um eine Übertragbarkeit der Modelle zu gewährleisten, ist also die wichtige Information, die im Modell implementiert sein sollte, dass 20-40 % der Fläche des Biotops mit Häusern bebaut ist – unabhängig von ihrer Dachdeckung. Dies wird durch die Verwendung der in Kapitel 3.4.4 beschriebenen Klassengruppen, in diesem Beispiel durch die Klassengruppe „*roofs*“ erreicht. Konsequenterweise wurde in den Modellen kein einziges Merkmal verwendet, das auf einer einzelnen Klasse berechnet wurde. Das Ergebnis der endgültigen Merkmalsselektion ist in **Tabelle 5-1** dargestellt.

Tabelle 5-1 Übersicht der in den Fuzzy Modellen verwendeten Merkmale. Die drei Blöcke unterteilen die Merkmale in Biotop-, Klassen- und Klassensegmentmerkmale. Für die letzteren beiden ist jeweils die Klassengruppe aufgeführt, die Grundlage der Berechnungen ist.

Merkmalsname, Biotopteilfläche und statistischer Parameter			Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen
Gewichteter Versiegelungsgrad	gesamt	-		x	x	x		x
Objekthöhen	gesamt	STDEV	x		x		x	x
Objekthöhen	Rand	MEAN	x	x	x	x		
Flächenanteile der Klassen im Biotop	gesamt	-	D	D	D	D	ZD	D,V
Flächenanteile der Klassen im Biotop	Rand	-	D	D,V	D,V	D,V		
Flächenanteile der Klassen im Biotop	innen	-		D	D			
Flächenanteil der Klasse pro Pixel	innen	MEAN		D				
Verhältnis spektral reine Pixel / Mischpixel	innen	-			D			
Kompaktheitsgrad der Klasse	gesamt	-					S	
Klassenspezifische Objekthöhen	gesamt	MAX	D	D	D	D	D,FD	
Klassenspezifische Objekthöhen	gesamt	MEAN					D	
Klassenspezifische Objekthöhen	innen	MAX		D				
Klassenspezifische Objekthöhen	Rand	MEAN		D	D			
Anzahl der Segmente	gesamt	-			D,V			
Anzahl der Segmente	innen	-			V			
Flächeninhalt der Segmente	gesamt	MAX	D	D	D	D		
Kompaktheitsgrad der Segmente	gesamt	MEAN	D					
Lineare-Segmente-Indikator	gesamt	MEAN	D			D		
Lineare-Segmente-Indikator	gesamt	MAX				D		
Relative Orientierung der Segmente	gesamt	MEAN				D		
Längliche-Segmente-Indikator (LSI2_ABS)	gesamt	MIN	D					
Längliche-Segmente-Indikator (LSI2_ABS)	gesamt	MAX				D		

Längliche-Segmente-Indikator (LSI2_ABS) gesamt	MEAN	D	D	D
Längliche-Segmente-Indikator (LSI2_ABS) gesamt	STDEV			D

Verwendete Kürzel:

Biotoptypen: Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung; Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen.

Klassengruppen: D = Dächer, ZD = Ziegeldächer, FD = Flachdächer, V = Vegetation, S = Schatten

5.4 Kalibrierung der Modelle

Nachdem für die Modelle die in **Abbildung 5-3** gezeigte feste Struktur entwickelt wurde und die in **Tabelle 5-1** gezeigten Merkmale implementiert wurden, stellt die Kalibrierung der Modelle den letzten Schritt vor der Anwendung dar. Dieser wird, wie auch schon die Merkmalsselektion, ebenfalls wissensbasiert durchgeführt, wobei gleichzeitig die Wertebereiche der Merkmals-histogramme der Trainingsbiotope berücksichtigt werden. Ziel der Kalibrierung ist es, die Grenzen der Zugehörigkeitsfunktionen der Inputvariablen (Merkmale) so einzustellen, dass die Biotope des eigenen Typs einen hohen Ähnlichkeitswert erhalten und die der übrigen Typen einen geringen.

Es wurden zwei verschiedene Funktionstypen für die Zugehörigkeitsfunktionen getestet, deren Grenzen mit den gleichen vier Parametern T_{min} , T_{max} , S_{min} und S_{max} einzustellen sind (**Abbildung 5-5**, links). Die Intervalle $[T_{min}, T_{max}]$ bzw. $[S_{min}, S_{max}]$ werden Toleranz (engl.: *tolerance*) und Unterstützung (engl.: *support*) genannt und definieren die Bereiche, in denen die Zugehörigkeitsfunktion auf den Wert 1 bzw. auf Werte > 0 abbildet. Die Trapezfunktion (in MATLAB trapmf genannt) besteht ausschließlich aus abschnittsweise definierten linearen Gleichungen (s. **Gleichung (5-1)**), während die *spline*-basierte Funktion (in MATLAB pimf, smf oder zmf genannt) im Wertebereich, der auf Zugehörigkeitswerte $]0, 1[$ abgebildet wird, eine *spline*-Funktion verwendet, die jeweils aus zwei abschnittsweise definierten Polynomen 2. Grades besteht (s. **Gleichung (5-2)**).




Abbildung 5-5 Trapezförmige und *spline*-basierte Zugehörigkeitsfunktionen.

$$y_{trapmf} = \begin{cases} 0, & x \leq S_{Min} \\ \frac{x - S_{Min}}{T_{Min} - S_{Min}}, & S_{Min} < x \leq T_{Min} \\ 1, & T_{Min} < x \leq T_{Max} \\ \frac{S_{Max} - x}{S_{Max} - T_{Max}}, & T_{Max} < x \leq S_{Max} \\ 0, & x > S_{Max} \end{cases} \quad (5-1)$$

$$y_{pimf} = \begin{cases} 0, & x \leq S_{Min} \\ 2 \left(\frac{x - S_{Min}}{T_{Min} - S_{Min}} \right)^2, & S_{Min} < x \leq \frac{S_{Min} + T_{Min}}{2} \\ 1 - 2 \left(\frac{x - T_{Min}}{T_{Min} - S_{Min}} \right)^2, & \frac{S_{Min} + T_{Min}}{2} < x \leq T_{Min} \\ 1, & T_{Min} < x \leq T_{Max} \\ 1 - 2 \left(\frac{x - T_{Max}}{S_{Max} - T_{Max}} \right)^2, & T_{Max} < x \leq \frac{T_{Max} + S_{Max}}{2} \\ 2 \left(\frac{x - S_{Max}}{S_{Max} - T_{Max}} \right)^2, & \frac{T_{Max} + S_{Max}}{2} < x \leq S_{Max} \\ 0, & x > S_{Max} \end{cases} \quad (5-2)$$

Die Einstellung der Parameter der Zugehörigkeitsfunktionen erfolgt basierend auf den Merkmalshistogrammen. T_{min} und T_{max} werden auf das Minimum bzw. Maximum der Merkmalshistogramme der Prototypen gesetzt. Da diese typische Biotope für ihre Typen darstellen, sollen sie den Zugehörigkeitswert 1 erhalten.

Für die Einstellung von S_{min} und S_{max} wurden zwei Strategien entwickelt (**Abbildung 5-6**), die auf den Merkmalshistogrammen aller Trainingsbiotope zusammengenommen basieren und das Ziel verfolgen, allen Biotopen eines Typs Zugehörigkeitswerte > 0 zuzuweisen. Bei der ersten Strategie werden S_{min} und S_{max} auf $\bar{x} - 3\sigma$ bzw. $\bar{x} + 3\sigma$ der Merkmalsverteilungen gesetzt. Diese Strategie funktioniert vor allem gut bei normalverteilten Merkmalen. Bei anderen Verteilungen kann die Einstellung der Unterstützung sowohl zu eng als auch zu breit sein und so dazu führen, dass das Modell eigene Biotope nicht erkennt oder zu hohe Ähnlichkeitswerte für fremde Biotope vergibt.

Bei der zweiten Strategie werden S_{min} und S_{max} auf $2x_{min} - T_{min}$ bzw. $2x_{max} - T_{max}$ gesetzt. Hierdurch erhalten die Biotope mit dem kleinsten und größten Merkmalswert (x_{min} bzw. x_{max}), die häufig zu den untypischen Biotopen gehören, einen Zugehörigkeitswert von 0,5 und somit alle Trainingsbiotope einen Zugehörigkeitswert von $\geq 0,5$. Die Strategie ist allerdings empfindlich gegenüber Ausreißern, da sie auf dem Minimum und Maximum der Merkmalshistogramme basiert.

Die Einstellung der Grenzen der Zugehörigkeitsfunktionen kann mit beiden Methoden nicht vollständig automatisiert werden und muss in jedem Fall nachkontrolliert und gegebenenfalls wissensbasiert korrigiert werden. Die Gründe hierfür wurden jeweils genannt. Hinzu kommt, dass in einigen Fällen links oder rechts offene Zugehörigkeitsfunktionen verwendet werden sollten. Diese Fälle ergeben sich aus Gründen der Logik und können durch eine automatische Analyse der Verteilungen der Merkmale nicht erkannt werden.




Abbildung 5-6 Zwei Strategien zur Einstellung der Grenzen der Zugehörigkeitsfunktionen (hier mit Trapezform) basierend auf den Merkmalshistogrammen der Trainingsbiotope.

5.5 Genauigkeitsüberprüfung der Klassifizierung

Wie in **Abbildung 5-1** gezeigt wurde, bilden alle Modelle zusammengenommen einen Klassifizierer für Biotope. Ein einfacher Algorithmus zur Klassifizierung eines Biotops ist die Zuweisung des Biotoptyps, dessen Modell den höchsten Ähnlichkeitswert berechnet. Bei Stimmgleichheit, d.h. wenn der höchste Ähnlichkeitswert für ein Testbiotop vom Modell des korrekten Biotoptyps und gleichzeitig von einem oder mehreren anderen Modellen berechnet wird, wird das Testbiotop bei der Genauigkeitsüberprüfung als falsch klassifiziert gewertet. Testbiotope, für die kein Modell einen Ähnlichkeitswert > 0 berechnet, bleiben unklassifiziert. Dies hingegen wird bei der Genauigkeitsüberprüfung nicht als Fehler gewertet, da die Güte des Klassifizierers für die Fälle

bestimmt werden soll, in denen er eine Entscheidung getroffen hat. Tut er dies nicht, so kann das entsprechende Biotop visuell klassifiziert werden.

Auf diese Weise wurden die 170 Testbiotop von 6 Biotoptypen im Untersuchungsgebiet Dresden klassifiziert. Dabei wurden vier verschiedene Varianten der Modelle getestet, die sich im Funktionstyp der Zugehörigkeitsfunktionen und in der Strategie der Einstellung ihrer Grenzen unterscheiden (s. Kap. 5.4). Für die Kombinationen *spline*-basierte Funktion/Strategie 1, *spline*-basierte Funktion/Strategie 2, Trapezfunktion/Strategie 1 und Trapezfunktion/Strategie 2 ergab eine Genauigkeitsüberprüfung mit unabhängigen Testbiotopen Gesamtgenauigkeiten und Kappawerte von 81,9 % (0,758), 82,5 % (0,765), 83,1 % (0,772) und 83,1 % (0,772). Diese Werte zeigen zum einen, dass der in dieser Arbeit entwickelte Ansatz zur merkmals- und wissensbasierten Klassifizierung von Stadtbiotopen mit guter Genauigkeit zum Erfolg führt. Zum anderen zeigen sie, dass die entscheidende Basis des Erfolgs bereits durch die grundlegende Konzeption der Modelle und die Auswahl der Merkmale gelegt wird und dass die Wahl eines Funktionstyps für die Zugehörigkeitsfunktionen sowie der Methode zur Einstellung ihrer Grenzen zweitrangig ist.

Die Betrachtung der Konfusionsmatrix und der *Omission* und *Commission Errors* (**Tabelle 5-2**) zeigt weiterhin, dass die Biotoptypen Einzelhausbebauung, Hochhausbebauung und reine Scher- und Zierrasen mit sehr guter Genauigkeit erkannt wurden und dass alle größeren Verwechslungen (fettgedruckte Werte der Konfusionsmatrix) mit dem Typ Blockrandbebauung zusammenhängen. Dieser gibt in gleichem Maße eigene Biotop an die Typen Blockbebauung und Zeilenbebauung ab, wie er Biotop dieser beiden Typen fälschlicherweise gewinnt. Zwischen den Typen Blockbebauung und Zeilenbebauung besteht dagegen keine direkte Verwechslung. Die Schlussfolgerung hieraus ist, dass bisher nicht ausreichend viele oder ausreichend gute Merkmale entwickelt werden konnten, um den Typ Blockrandbebauung von den Typen Blockbebauung bzw. Zeilenbebauung zu unterscheiden. Da jedoch zwischen allen anderen Biotoptypenpaaren die Verwechslungen sehr gering sind, kann der gewählte Ansatz grundsätzlich als aussichtsreich bezeichnet werden.

Tabelle 5-2 Ergebnis der Genauigkeitsüberprüfung für die Kombination Trapezfunktion/Strategie 2. Gezeigt werden die *Omission* und *Commission Errors* der Klassen und die Konfusionsmatrix. In der Konfusionsmatrix befinden sich die Testbiotop in den Zeilen und die Klassenzuweisungen des Klassifizierers in den Spalten.

	<u><i>Omission Error</i> (%)</u>	<u><i>Commission Error</i> (%)</u>
Einz.	7,1	7,1
Block.	24,1	26,7
B.rand.	50,0	45,8
Zeile.	29,4	36,8
Hochh.	4,6	0
Rasen	0	0

(%)	Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen	Unkl.	Summe:
Einz.	26	1	0	1	0	0	1	29
Block.	0	22	7	0	0	0	0	29
B.rand.	1	7	13	5	0	0	1	27
Zeile.	1	0	4	12	0	0	1	18
Hochh.	0	0	0	1	21	0	0	22
Rasen	0	0	0	0	0	44	1	45
Summe:	28	30	24	19	21	44	4	170

Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung; Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen

Die Gesamtgenauigkeit der Klassifizierung kann zusätzlich gesteigert werden, indem die Ähnlichkeitswerte mit einem Schwellenwert belegt werden. **Abbildung 5–7** zeigt die Gesamtgenauigkeit und den Anteil klassifizierter Biotope in Abhängigkeit vom gesetzten Schwellenwert. Ein geringerer Anteil der klassifizierten Biotope bedeutet einen Mehraufwand und damit höhere Kosten bei der visuellen Luftbildauswertung. Der gegenläufige Verlauf der beiden Kurven bedeutet, dass in der praktischen Anwendung der Modelle zur Aktualisierung einer Stadtbiotop-typenkarte zwischen der gewünschten Gesamtgenauigkeit der Klassifizierung und dem Anteil klassifizierter Biotope abgewogen werden muss. Ein Diagramm wie **Abbildung 5–7** kann dem Nutzer bzw. Auftraggeber der Aktualisierung als Entscheidungshilfe dienen, um anhand der beiden Größen einen geeigneten Schwellenwert auszuwählen.




Abbildung 5–7 Gesamtgenauigkeit und Anteil der klassifizierten Biotope in Abhängigkeit vom gesetzten Schwellenwert auf die von den Modellen berechneten Ähnlichkeitswerte.

Im folgenden Kapitel wird ein zweiter, alternativer Klassifizierer vorgestellt. Dieser wurde entwickelt, um eine noch stärkere Automatisierung zu erreichen. Beide Klassifizierer werden in Diskussion und Ausblick dieser Arbeit (Kap. 7.2) miteinander verglichen. Dort werden auch die Anwendung der Klassifizierer zur Aktualisierung einer Stadtbiotop-typenkarte und die Synthese

der neu entwickelten Methode mit der visuellen Luftbilddauswertung und Feldkartierung dargestellt (Kap. 7.4).

6 **Automatisierter Aufbau von ML-basierten Modellen zur Klassifizierung von Stadtbiotopen**

In Kapitel 5 wurde gezeigt, wie ein Klassifizierer für Stadtbiotope, der aus einem Fuzzy Logik Modell pro Biotoptyp besteht, wissensbasiert und mit einigem Arbeitsaufwand für den Analytiken aufgebaut werden kann. Steht der Klassifizierer erst einmal, so läuft die Klassifizierung anschließend vollautomatisch ab. Dennoch ist es wünschenswert, auch den Aufbau des Klassifizierers zu automatisieren, da die Interpretationsschlüssel für Stadtbiotopkartierungen teilweise 100 oder mehr verschiedene Biotoptypen enthalten, für die jeweils ein eigenes Fuzzy Logik Modell per Hand angelegt werden müsste. In diesem Kapitel wird daher die Entwicklung eines alternativen Klassifizierers beschrieben, dessen Aufbau und Anwendung vollautomatisch abläuft. Die Entwicklung erfolgte unter Verwendung der gleichen Datenbasis, der gleichen Merkmale und unter den gleichen Voraussetzungen bzw. Anforderungen, die auch für den Fuzzy Klassifizierer galten (Kapitel 5.2).

Die Parametrisierung eines vollautomatischen Klassifizierers kann anhand von Trainingsbiotopen erfolgen. Im Gegensatz zu dem Expertenwissen, das in die Fuzzy Modelle eingeflossen ist, wird hier also eine Teilmenge der Daten als Informationsquelle zur Einstellung der Parameter des Klassifizierers verwendet. In der Praxis wird sich die Menge der Trainingsbiotopen auf eine Ausdehnung von wenigen Prozent der Stadtfläche begrenzen, da ihre Erhebung mit Kosten verbunden ist, da jedes Trainingsbiotop im Feld oder im Luftbild validiert werden muss. Die Ausgangssituation ist also eine, die bei der Auswertung von Fernerkundungsdaten häufig auftritt: Einem hochdimensionalen Merkmalsraum stehen verhältnismäßig wenige Trainingsobjekte gegenüber. Mit über 10.000 berechneten Merkmalen ist diese Situation im vorliegenden Fall sogar noch extremer als in vielen anderen fernerkundlichen Anwendungen, bei denen die Kanäle eines Sensors als Merkmale dienen. Daher ist die in Kapitel 6.1 beschriebene Merkmalsselektion von besonderer Wichtigkeit.

Der in diesem Kapitel beschriebene automatisch aufgebaute Klassifizierer für Biotope ist ein Paarweise-*Maximum-Likelihood*-Klassifizierer (pMLK), wie er bereits in Kapitel 3.4.3.1 beschrieben wurde. Seine Entwicklung erfolgte zeitgleich für den Einsatz in der Klassifizierung von urbanen Oberflächen und von Stadtbiotopen. Beide pMLKs sind in ihrer Struktur und Funktionsweise identisch. Es wird jedoch in diesem Kapitel eine andere Sichtweise auf den pMLK präsentiert, indem einzelne Biotoptypmodelle als Grundbausteine des Klassifizierers dargestellt werden. Diese Sichtweise wurde gewählt, um die Ähnlichkeiten dieser automatisch aufgebauten Modelle mit den manuell erzeugten Fuzzy Logik Modellen (Kap. 5) aufzuzeigen.

Die Grundidee des pMLK ist die paarweise durchgeführte Klassifizierung zur Reduzierung der Dimensionalität des Merkmalsraums und damit zur Vermeidung des Hughes-Phänomens bei einer geringen Menge an Trainingsdaten oder bei einer großen Klassenanzahl (vgl. Kapitel 3.4.3.1). Zusätzlich zu diesem Vorteil des pMLK liegt bei der Klassifizierung von Stadtbiotopen eine Situation vor, die die Paarweiseklassifizierung unbedingt notwendig macht. Diese liegt in der Datenbasis der Merkmale begründet. Die Klassenmerkmale und Klassensegmentmerkmale

werden für jede Klasse (urbane Oberflächenart) berechnet. Wenn eine bestimmte Klasse in einem Biotop nicht vorkommt, können sämtliche Klassen- und Klassensegmentmerkmale für diese Klasse in diesem Biotop nicht berechnet werden. Die entsprechenden Merkmalswerte werden zur Erkennung auf einen ungültigen Wert (-9999) gesetzt. Merkmale mit ungültigen Werten bei einzelnen oder allen Biotopen eines Biotoptyps können nicht zur Identifizierung dieses Biotoptyps verwendet werden, da die entsprechende Klasse nicht in allen Biotopen des Typs vorkommt, sie somit nicht charakteristisch für den Biotoptyp ist und sich dadurch keine sichere Aussage zur Identifizierung des Biotoptyps ableiten lässt. Je mehr Biotoptypen im Klassifizierer implementiert sind, desto wahrscheinlicher ist es, dass eine Klasse in den Biotopen eines der implementierten Biotoptypen nicht vorkommt. Wird nun ein einziger Klassifizierer mit allen Biotoptypen aufgebaut, so dürfen nur diejenigen Merkmale verwendet werden, die bei allen Biotopen aller Biotoptypen ausschließlich gültige Werte aufweisen. Bereits bei den bisher implementierten 10 Biotoptypen würde sich dadurch die Datenbasis der verwendbaren Merkmale auf die Biotopmerkmale (Kap. 4.1) und auf wenige Klassengruppenmerkmale (z.B. Vegetation) reduzieren. Dieser Effekt kann durch die Verwendung von Paarweisklassifizierern stark reduziert werden, da pro Biotoptypenpaarung deutlich mehr Merkmale verwendbar sind. In den folgenden Kapiteln werden nun die Prozesse der Merkmalsauswahl (Kap. 6.1) und des Aufbaus der ML-basierten Modelle (Kap. 6.2) sowie die Genauigkeitsuntersuchung der Klassifizierung beschrieben (Kap. 6.3).

6.1 Auswahl von Merkmalen

Die (automatische) Auswahl von Merkmalen ist eine in vielen Bereichen von Wissenschaft und Technik verbreitete Aufgabe. Sie wird angewendet, wenn eine große Menge von Parametern / Variablen / Merkmalen erhoben wurde, von denen viele Informationen enthalten, die redundant oder für eine bestimmte Aufgabe nicht von Nutzen sind. In diesen Fällen bietet eine Merkmalsselektion folgende Vorteile (Guyon & Elisseeff 2006: 4):

- I. Einsparung von Rechenzeit und Speicherplatz,
- II. Reduzierung des Datenerhebungsaufwandes bei zukünftigen Erhebungen,
- III. Erleichterung der Interpretierbarkeit des Modells,
- IV. Verbesserung der Genauigkeit einer nachfolgenden Klassifizierung durch Vermeidung des Hughes-Phänomens.

Methoden zur Merkmalsselektion bestehen aus zwei Teilen: Der Suchstrategie und dem Evaluierungskriterium (Reunanen 2006: 119). Das Evaluierungskriterium beurteilt die Güte eines einzelnen Merkmals oder einer Gruppe von Merkmalen. Die Suchstrategie bestimmt, welche Merkmale oder Gruppen von Merkmalen geprüft werden und in welcher Reihenfolge sie geprüft werden. Wird die Merkmalsselektion im Vorfeld einer Klassifizierung durchgeführt, wird als Evaluierungskriterium häufig die mit unabhängigen Testdaten ermittelte Gesamtgenauigkeit der Klassifizierung oder der Kappa Koeffizient verwendet. Wird dabei in der Selektionsphase der gleiche Klassifizierer verwendet wie bei der endgültigen Klassifizierung, gehört die Merkmalsselektionsmethode wie die im Folgenden beschriebene Methode zur Kategorie der *Wrapper* (Guyon & Elisseeff 2006: 6). Bei der im Folgenden beschriebenen Methode wird allerdings der Mittelwert über die *Omission Errors* als Evaluierungskriterium verwendet, da dieser alle Klassen unabhängig von der Anzahl ihrer Trainingsobjekte gleichstark gewichtet. Weitere Katego-

rien von Merkmalsselektionsmethoden sind Filtermethoden (engl.: *filter methods*) (Duch 2006) und eingebettete Methoden (engl.: *embedded methods*) (Lal *et al.* 2006). Eine Filtermethode liegt vor, wenn in der Selektionsphase kein Klassifizierer, sondern ein von der endgültigen Klassifizierung unabhängiges Evaluierungskriterium (z.B. der Korrelationskoeffizient oder die Bhattacharyya Distanz) verwendet wird. Ist der Selektionsprozess dagegen in einem iterativen Lernprozess eines Klassifizierers eingebettet, spricht man von einer eingebetteten Methode.

In der vorliegenden Anwendung muss eine sogenannte suboptimale Methode als Suchstrategie gewählt werden, da bei über 10.000 Merkmalen ein erschöpfender Test aller $2^n - 1$ ($\approx 1,995 \cdot 10^{3010}$) Merkmalskombinationen eine sinnvolle Rechenlaufzeit übersteigt. Dies gilt auch, wenn die Anzahl der notwendigen Merkmale *a priori* bekannt wäre. Zwei häufig verwendete und sehr einfache suboptimale Suchstrategien sind die *Sequential Forward Selection* (SFS) und die *Sequential Backward Selection* (SBS) (Reunanen 2006: 121). Diese starten mit einer leeren bzw. mit der gesamten Menge an Merkmalen und fügen sequentiell das jeweils beste Merkmal hinzu bzw. eliminieren das jeweils schlechteste, bis ein Abbruchkriterium erreicht ist. Für die Aufgabe, wenige Merkmale aus einer sehr großen Gesamtmenge auszuwählen, eignet sich die SFS besser als die SBS, da sie hier eine deutlich geringere Laufzeit besitzt. Die gewählte Merkmalsselektionsmethode besteht somit aus der SFS als Suchstrategie, einem ML-Klassifizierer und dem Mittelwert der *Omission Errors* der Biotoptypen als Evaluierungskriterium.

Die Merkmalsauswahl wird pro Biotoptypenpaarung in einem iterativen Prozess durchgeführt (**Abbildung 6–1**). Dieser startet, indem alle vorhandenen Merkmale einzeln für eine ML-Klassifizierung des Biotoptypenpaares benutzt werden, also jeweils in einem 1-dimensionalen Merkmalsraum. Das Merkmal, das den geringsten *Omission Error* für beide Biotoptypen liefert (Mittelwert), wird in die Merkmalsliste des Klassenpaares geschrieben. Wenn mehrere Merkmale eine fehlerfreie Trennung der Biotoptypen liefern, wird das Merkmal ausgewählt, bei dem die Bhattacharyya Distanz zwischen den beiden Biotoptypen im Merkmalsraum am größten ist. Im zweiten Durchgang werden die verbliebenen Merkmale erneut durchlaufen und jeweils eines von ihnen mit dem bereits selektierten Merkmal zu einem 2-dimensionalen Merkmalsraum kombiniert. Wiederum werden ML-Klassifizierungen des Biotoptypenpaares durchgeführt und dasjenige Merkmal, das in Kombination mit dem zuerst ausgewählten den geringsten Fehler liefert, wird in die Merkmalsliste geschrieben. Dieser Vorgang wird mehrfach wiederholt. Als Ergebnis entsteht *eine* Merkmalsliste für *jede* Biotoptypenpaarung, die einen Merkmalsraum aufspannt, in dem ein ML-Klassifizierer eine gute Trennung der beiden Biotoptypen erreicht. Dabei wird der iterative Selektionsprozess durch eine der drei Abbruchbedingungen gestoppt:

- das Biotoptypenpaar wird fehlerlos getrennt,
- die Klassifizierungsgenauigkeit verbessert sich nicht mehr von einer Iteration zur nächsten, d.h. keines der verbliebenen Merkmale ist in der Lage, die Trennbarkeit des Biotoptypenpaares weiter zu erhöhen,
- eine maximale Anzahl an Iterationen wurde durchlaufen. Diese Anzahl sollte mit Blick auf die Menge an Trainingsbiotopen festgelegt werden, um das Hughes-Phänomen zu vermeiden.

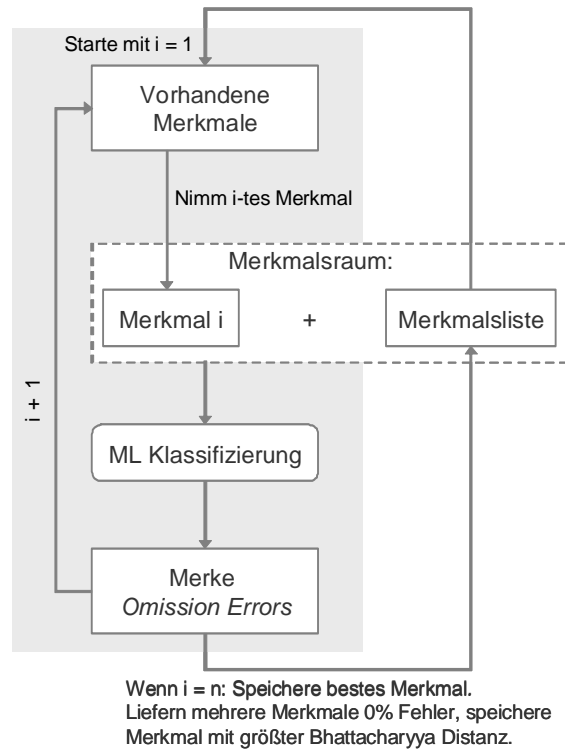


Abbildung 6–1 Ablauf der iterativen Merkmalssektion ($n =$ Anzahl vorhandener Merkmale).

6.2 Aufbau und Kalibrierung der Modelle

Die Struktur und Funktionsweise der ML-basierten Modelle sind stark an die Fuzzy Logik Modelle aus Kapitel 5 angelehnt (**Abbildung 6–2**). Auch hier erhält jeder Biotoptyp ein eigenes Modell, das in der Lage sein soll, die Biotope des eigenen Typs durch die Berechnung eines Ähnlichkeitswerts zu erkennen. Während bei den Fuzzy Modellen einzelne Merkmale unterschiedlicher Anzahl als eindimensionale Inputvariablen dienen, sind die Inputvariablen der ML-basierten Modelle mehrdimensional. Sie werden durch die aus der Merkmalssektion hervorgegangenen Merkmalslisten zur Trennung zweier Biotoptypen gebildet. Die Merkmalslisten werden dabei nach der Vorschrift implementiert, dass eine Merkmalsliste zur Unterscheidung zweier Biotoptypen nur in die Modelle von genau diesen beiden Biotoptypen implementiert wird. Dadurch ist die Anzahl der mehrdimensionalen Inputvariablen automatisch auf $b-1$ ($b =$ Anzahl der implementierten Biotoptypen) festgelegt.

Jede mehrdimensionale Inputvariable eines Modells spannt einen k -dimensionalen Merkmalsraum auf, in dem eine ML-Klassifizierung einer Biotoptypenpaarung stattfindet, wobei die Anzahl der selektierten Merkmale k für jede Inputvariable variabel ist. Die Kalibrierung der Modelle, d.h. die Berechnung der Parameter der einzelnen Paarweisklassifizierer kann dabei im Vorfeld anhand von Trainingsbiotopen vorgenommen werden. Bei der Anwendung eines kalibrierten Modells auf ein Biotop (**Abbildung 6–2**) gehen aus jeder paarweise durchgeführten ML-Klassifizierung zwei Wahrscheinlichkeitswerte hervor: Einer für den modelleigenen Biotoptyp und einer für den jeweils anderen Biotoptyp der Paarung. Der Ausgabewert des Modells ergibt sich nun ausschließlich aus den Wahrscheinlichkeitswerten, die der modelleigene Biotoptyp erhalten hat. Da diese sich mit den Wahrscheinlichkeitswerten der jeweiligen anderen Biotoptypen

einer Paarweisklassifizierung zu 100 summieren, erfüllt jede mehrdimensionale Inputvariable den Zweck, dass das Modell für Biotoppe des anderen Biotoptyps der Paarung geringe Ähnlichkeitswerte berechnet. Um dies zu gewährleisten, müssen die Wahrscheinlichkeitswerte des modelleigenen Biotoptyps analog zu den Fuzzy Modellen einer MIN-MIN Fuzzy Inferenz unterzogen werden, so dass der kleinste Wahrscheinlichkeitswert den scharfen Ausgabewert des Modells bildet. Dieser kann genau wie bei den Fuzzy Modellen als Ähnlichkeitswert interpretiert werden.




Abbildung 6-2 Struktur und Funktionsweise eines ML-basierten Modells zur Erkennung eines Biotoptyps. Aus Darstellungsgründen werden 3 2-dimensionale Inputvariablen gezeigt. Die realen Modelle besitzen $b-1$ k -dimensionale Inputvariablen, wobei b die Anzahl der implementierten Biotoptypen und k die Anzahl der selektierten Merkmale ist, die für jede Biotoptypenpaarung variabel ist. Der Ausgabewert des Modells ist als Ähnlichkeitswert interpretierbar.

6.3 Genauigkeitsüberprüfung der Klassifizierung

Wie bei den Fuzzy Modellen bilden alle Modelle zusammengenommen einen Klassifizierer für Biotoppe. Ein einfacher Algorithmus zur Klassifizierung eines Biotops ist die Zuweisung des Biotoptyps, dessen Modell den höchsten Ähnlichkeitswert berechnet. Bei Stimmgleichheit, d.h. wenn der höchste Ähnlichkeitswert für ein Testbiotop vom Modell des korrekten Biotoptyps und gleichzeitig von einem oder mehreren anderen Modellen berechnet wird, wird das Testbiotop als falsch klassifiziert gewertet.

Auf diese Weise wurden die 507 Biotoppe aus 6 Biotoptypen im Untersuchungsgebiet Dresden und die 912 Biotoppe aus 10 Biotoptypen in Berlin klassifiziert. Zunächst wurden alle Biotoppe bei der Modellkalibrierung und der Genauigkeitsberechnung verwendet (separat für Dresden und Berlin), um die grundsätzliche Funktionstüchtigkeit des Klassifizierers zu testen. Die sehr hohen Genauigkeiten (94,9 % und 95,0 %), mit denen die Trainingsbiotoppe klassifiziert wurden, zeigen, dass die verwendeten Fernerkundungsdaten, die entwickelten Merkmale und der verwendete Klassifizierer gut geeignet sind, um die untersuchten Biotoptypen automatisch zu klassifizieren. Die verbleibenden Verwechslungen reduzieren sich hier im Wesentlichen auf die Biotopptypenpaarungen Blockbebauung vs. Blockrandbebauung sowie Einzelhausbebauung vs. Schrebergärten, die in der Tat strukturell sehr ähnlich sind. Werden die Biotoppe nicht nach Städten getrennt, sondern gemeinsam für die Kalibrierung eines Klassifizierers verwendet, so liegt die Klassifizierungsgenauigkeit der Trainingsbiotoppe noch bei 90,7 %. Der Rückgang um ca. 4 % lässt auf geringfügige regionale Unterschiede in der Struktur der Biotoptypen schließen. Ein Blick in die *Omission* und *Commission Error* legt offen, dass der Rückgang der Genauigkeit hauptsächlich dem Typ Zeilenbebauung zugeschrieben werden kann. Diese Erkenntnis deckt sich mit den in **Abbildung 3-2** in Kapitel 3.2.2 gezeigten Variationen der Zeilenbebauung in Berlin. Daher wird empfohlen, für jede Stadt einen eigenen Klassifizierer zu kalibrieren.

Um eine realistische Abschätzung der Genauigkeit des Klassifizierers im Anwendungsfall zu erhalten, müssen unabhängige Biotope für die Validierung verwendet werden. Die Aufteilung der Biotope erfolgt zunächst mit der *Hold-Out*-Methode, bei der die vorhandenen Biotope im Verhältnis 50:50 in zwei Gruppen – Trainingsbiotope und Testbiotope – aufgeteilt werden. Die Gesamtgenauigkeit der Klassifizierung reduziert sich hierdurch auf 80,9 % für Dresden und 78,2 % für Berlin. Diese starke Diskrepanz der Klassifizierungsgenauigkeit (Dresden -14 %, Berlin - 16,8 %) zwischen Biotopen, die dem Klassifizierer bekannt bzw. unbekannt sind, deutet in der Regel auf eine zu kleine Menge an Trainingsbiotopen hin. Daher wurde für die folgenden Genauigkeitsuntersuchungen die Methode der Kreuzvalidierung verwendet, die die vorhandene Menge an Biotopen optimaler ausnutzt als die *Hold-Out*-Methode. Die Kreuzvalidierung wurde mit 10 Partitionen und 10-facher Repartitionierung durchgeführt. Dabei wurden zwei Varianten getestet, indem die Merkmalsdatenbasis einmal vollständig verwendet wurde und einmal eine Reduzierung durchgeführt wurde, bei der die auf individuellen Klassen berechneten Klassenmerkmale und Klassensegmentmerkmale entfernt wurden. Die Datenbasis reduziert sich so auf die Biotopmerkmale und diejenigen Merkmale, die unter Verwendung der Klassengruppen berechnet wurden (Klassengruppenvariante). Die erzielten Gesamtgenauigkeiten sind in **Abbildung 6–3** in Abhängigkeit von der maximal erlaubten Merkmalsanzahl pro Paarweisklassifizierer (Parameter der Merkmalsselektion; s. Kap. 6.1) dargestellt.




Abbildung 6–3 Gesamtgenauigkeiten der Klassifizierungen in Abhängigkeit von der maximal erlaubten Merkmalsanzahl pro Paarweisklassifizierer.

Die obige Abbildung lässt folgende Beobachtungen und Schlussfolgerungen zu:

- I. Die bessere Ausnutzung der vorhandenen Menge an Biotopen durch die Kreuzvalidierung schlägt sich nur in geringem Maße in einer im Vergleich zur *Hold-Out*-Methode höheren Gesamtgenauigkeit nieder (Dresden 83,1 % statt 80,9 %, Berlin 81,3 % statt 78,2 %).

Interpretation und Schlussfolgerung: Aus dieser Beobachtung lässt sich schlussfolgern, dass die vorhandene Menge der Biotope zumindest für die meisten Biotoptypen *nicht* zu klein ist, um den Klassifizierer zu kalibrieren. Die Hauptursache für die große Diskrepanz zwischen den Klassifizierungsgenauigkeiten bekannter und unbekannter Biotope liegt somit an anderer Stelle. Ein weiteres Indiz für die ausreichende Trainingsmenge ist, dass sich die Genauigkeit nicht verbessert, wenn die Biotope beider Städte zusammengenommen mit der Kreuzvalidierung überprüft werden. Auch hier steigt die Genauigkeit nicht durch die größere Menge an Trainingsbiotopen

an, sondern sinkt wie bei der *Hold-Out*-Methode um ca. 2 % durch die bereits angesprochene Variation der Zeilenbebauung.

- II. Die Klassengruppenvariante erzielt in beiden Städten das bessere Ergebnis (Dresden 84,3 statt 83,1; Berlin 82,0 statt 81,3).

Interpretation und Schlussfolgerung: Diese Beobachtung ist zunächst überraschend, da doch sämtliche Merkmale der Klassengruppenvariante auch in der gesamten Merkmalsdatenbasis enthalten sind. Die Ursache muss also in der Merkmalsselektionsmethode gesucht werden, da diese offensichtlich nicht die optimalen Merkmale aus der gesamten Merkmalsdatenbasis auswählt. Die Merkmalsselektionsmethode ist so programmiert, dass sie immer diejenigen Merkmale auswählt, die für die Trainingsbiotope die höchste Genauigkeit liefern. Dies bedeutet, dass es in der gesamten Merkmalsdatenbasis Merkmale geben muss, die auf individuellen Klassen berechnet wurden und die im Vergleich zu den Klassengruppenmerkmalen offensichtlich weniger gut auf die Testbiotope übertragen werden können. Diese Erkenntnis wurde bereits bei der Entwicklung der Fuzzy Modelle mit einem Beispiel plausibilisiert (Kap. 5.3) und wird nun durch die hier beschriebenen Ergebnisse untermauert. Für die Zukunft ergibt sich hieraus, dass die Merkmalsselektionsmethode mit einer Art Robustheitsprüfung erweitert werden muss, die die Übertragbarkeit der Merkmale auf unabhängige Biotope testet. Nur so kann in zukünftigen Untersuchungen der Mehrwert von Merkmalen genutzt werden, die auf individuellen Klassen berechnet wurden.

- III. Durch die Paarweisklassifizierer konnte die Dimensionalität der Merkmalsräume entscheidend reduziert und dadurch das Auftreten des Hughes-Phänomens verhindert werden.

Interpretation und Schlussfolgerung: Sofern nicht unendlich viele Trainingsdaten zur Verfügung stehen, zeigt sich in Genauigkeitskurven wie den in der **Abbildung 6-3** gezeigten normalerweise das Hughes-Phänomen. Dieses äußert sich durch die Ausbildung einer Anstiegs-, Plateau- und Verminderungsphase. In der Phase des Anstiegs reicht die Merkmalsanzahl noch nicht zur optimalen Trennung der Biotoptypen aus. In der Plateauphase heben sich die Verbesserung der Trennbarkeit und das beginnende Hughes-Phänomen gegenseitig in ihrer Wirkung auf, während letzteres in der Phase der abnehmenden Genauigkeit Überhand nimmt.

Die in **Abbildung 6-3** gezeigten Kurven enden alle in der Plateauphase. Eine Verminderung der Genauigkeit konnte somit durch die Reduzierung der Dimensionalität der Merkmalsräume und durch die Anwendung der verschiedenen Abbruchbedingungen bei der iterativen Merkmalsselektion (Kap. 6.1) erfolgreich verhindert werden.

- IV. Die Genauigkeit des ML-basierten Biotopklassifizierers (bestes Ergebnis für Dresden: 84,3%) unterscheidet sich kaum von der Genauigkeit des Fuzzy-Biotopklassifizierers (83,1 % für Dresden, ohne Schwellenwertanwendung).

Interpretation und Schlussfolgerung: Da die beiden Klassifizierer in vielen Teilen ähnlich aufgebaut sind, ist die wesentliche Erkenntnis bei diesem Punkt, dass Mensch und Maschine bei der Merkmalsauswahl gleich gut waren. Es wird jedoch angenommen, dass die automatische Merkmalsselektion durch die Ergänzung einer Robustheitsprüfung (s. Erläuterung zu Punkt II) noch verbessert werden kann. Ein Vergleich der ausgewählten Merkmale ergab, dass nur teilweise die gleichen Merkmale ausgewählt wurden. Aufgrund der hohen Informationsredundanz in den erzeugten Merkmalen wurden von der automatischen Methode häufig nicht exakt die gleichen Merkmale wie vom Analysten ausgewählt, aber solche mit ähnlichem semantischen Informati-

onsgeliebt. Von den 10 häufigsten wissensbasiert ausgewählten Merkmalen sind 4 auch unter den 10 häufigsten automatisch ausgewählten vertreten.

Punkt I und II deuten darauf hin, dass das größte Verbesserungspotenzial der Methode in der Merkmalsselektionsmethode zu finden ist. Mit der SFS wurde hier zunächst eine relativ simple Methode verwendet. Es ist bekannt, dass bei dieser Methode das in der Literatur viel zitierte *nesting problem* (auch genannt: *nesting effect*) (z.B. Reunanen 2006: 124) auftreten kann. Verbildlicht man sich den Merkmalsselektionsprozess als ein Durchschreiten einer Baumstruktur wie in **Abbildung 6-4**, so startet die SFS bei der Nullmenge und fügt dieser an jedem Knoten das Merkmal hinzu, das die beste Trennbarkeit liefert. Ein Merkmal, das einmal ausgewählt wurde, kann jedoch nicht wieder aus der Menge entfernt werden, ein Ast, der einmal betreten wurde, nicht wieder zurückgegangen werden. Gibt es an einer Verzweigung mehrere ähnlich gute Wege, so ist es nicht sinnvoll, sich strikt auf den an dieser Verzweigung besten zu fixieren, da die beste Kombination auf dem 2. Level nicht unbedingt das beste Merkmal des 1. Levels enthalten muss. Aus diesem Grund wurden zahlreiche komplexere Merkmalsselektionsmethoden wie z.B. *Beam Search* (Siedlecki & Sklanski 1988, Aha & Bankert 1996), *Floating Search* (Pudil *et al.* 1994) oder *Oscillating Search* (Somol & Pudil 2000) entwickelt, durch deren Implementierung in Zukunft eine weitere Verbesserung der Genauigkeit erwartet wird.




Abbildung 6-4 Der Merkmalsselektionsprozess mit der SFS Methode verbildlicht an einer Baumstruktur. Der rote Pfad zeigt eine Möglichkeit, ausgehend von der Nullmenge, zwei von vier Merkmalen zu selektieren (nach Kohavi & John 1997: 284, bzw. Guyon 2005: 3,4).

In **Tabelle 6-1** ist exemplarisch eine Konfusionsmatrix einer Klassifizierung der Biotope im Untersuchungsgebiet Berlin dargestellt. Weitere Konfusionsmatrizen befinden sich im Anhang B. Wie schon die Gesamtgenauigkeit zeigen auch die *Omission* und *Commission Errors* der Biotoptypen ähnliche Werte wie beim Fuzzy-Klassifizierer. Aus den Konfusionsmatrizen im Anhang B (**Tabelle B-2** und **B-3**) geht hervor, dass der ML-basierte Klassifizierer im Untersuchungsgebiet Dresden genau wie der Fuzzy-Klassifizierer die größten Probleme mit dem Biototyp Blockrandbebauung hat. Im Untersuchungsgebiet Berlin hängen die größten Fehler dagegen mit dem Biototyp Blockbebauung zusammen (s. fett markierte Werte in der Konfusionsmatrix). Eine zusätzliche, überdurchschnittlich hohe Verwechslung besteht punktuell zwischen den Typen Einzelhausbebauung und Schrebergärten, die sich nur anhand der Gebäudegrößen unterscheiden.

Tabelle 6-1 *Omission Error*, *Commission Error* und Konfusionsmatrix der Klassifizierung der Biotope im Untersuchungsgebiet Berlin. In der Konfusionsmatrix befinden sich die Testbiotope in den Zeilen und die Klassenzuweisungen des Klassifizierers in den Spalten. Das gezeigte Ergebnis wurde mit der Klassengruppenvariante bei Begrenzung auf maximal 14 Merkmale pro Paarweisklassifizierer erzielt. Die Gesamtgenauigkeit und der Kappa Koeffizient belaufen sich auf 82,0 % bzw. 0,789.

	<i>Omission Error (%)</i>	<i>Commission Error (%)</i>
Einz.	14,08	6,96
Block.	39,12	39,72
B.rand.	34,79	34,14
Zeile.	30,97	32,39
Hochh.	11,18	37,86
Rasen	6,56	0
Schreb.	15,14	26,64
Sport.	24,76	21,78
Indust.	30,70	32,51
Str.	4,92	3,78

	Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen	Schreb.	Sport.	Indust.	Str.	Unkl.	Sum.
Einz.	1830	12	4	42	3	0	169	14	33	23	0	2130
Block.	1	554	185	73	10	0	0	0	81	6	0	910
B.rand.	0	181	463	30	10	0	0	1	25	0	0	710
Zeile.	18	88	31	428	21	0	0	0	33	1	0	620
Hochh.	0	3	0	5	151	0	0	1	10	0	0	170
Rasen	0	0	0	0	0	299	19	0	0	2	0	320
Schreb.	74	0	0	0	2	0	628	7	2	27	0	740
Sport.	5	1	0	5	2	0	12	158	12	15	0	210
Indust.	23	74	19	39	28	0	1	11	492	23	0	710
Str.	16	6	1	11	16	0	27	10	41	2472	0	2600
Sum.	1967	919	703	633	243	299	856	202	729	2569	0	9120

Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung; Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen; Schreb. = Schrebergärten; Sport. = Offene Sport- und Erholungsanlagen; Indust. = Industrie- und Gewerbeflächen; Str. = Straßen; Unkl. = unklassifiziert; Sum. = Summe.

Wie es bereits bei den Fuzzy Modellen demonstriert wurde (Kap. 5.5), kann auch hier die Gesamtgenauigkeit der Klassifizierung weiter gesteigert werden, indem die Ähnlichkeitswerte mit einem Schwellenwert belegt werden. **Abbildung 6-5** zeigt die Gesamtgenauigkeit und den Anteil der klassifizierten Biotope in Abhängigkeit vom gesetzten Schwellenwert. Ein geringerer Anteil klassifizierter Biotope bedeutet einen Mehraufwand und damit höhere Kosten bei der visuellen Luftbildauswertung. Der gegenläufige Verlauf der beiden Kurven bedeutet, dass in der praktischen Anwendung der Modelle zur Aktualisierung einer Stadtbiotoptypenkarte zwischen der gewünschten Gesamtgenauigkeit der Klassifizierung und dem Anteil klassifizierter Biotope ab-

gewogen werden muss. Ein Diagramm wie **Abbildung 6–5** kann dem Nutzer bzw. Auftraggeber der Aktualisierung als Entscheidungshilfe dienen, um anhand der beiden Größen einen geeigneten Schwellenwert auszuwählen.




Abbildung 6–5 Gesamtgenauigkeit und Anteil der klassifizierten Biotope in Abhängigkeit vom gesetzten Schwellenwert auf die von den Modellen berechneten Ähnlichkeitswerte. Dabei wird links jeweils die Variante mit der gesamten Merkmalsdatenbasis gezeigt und rechts die Klassengruppenvariante.

7

Diskussion und Ausblick

In der vorliegenden Arbeit wurde das Automatisierungspotenzial von Stadtbiotopkartierungen durch Methoden der Fernerkundung untersucht. Der Schwerpunkt der Arbeit lag auf der Entwicklung von Biotopklassifizierern zur automatischen Erkennung des Biotoptyps von Stadtbiotopen aus Fernerkundungsdaten. Mit der automatischen Berechnung von ökologischen Parametern und Indikatoren wurde ein Nebenaspekt in die Arbeit aufgenommen, der weiteres Automatisierungspotenzial aufzeigen konnte. Dieser Aspekt stützte sich weniger auf eigene Arbeiten, sondern auf eine Literaturstudie mit Schwerpunkt im deutschsprachigen Raum. Er wird in Kapitel 7.1 abschließend diskutiert.

Die weiteren Unterkapitel befassen sich mit dem Hauptaspekt dieser Arbeit. In Kapitel 7.2 werden die beiden entwickelten Biotopklassifizierer gegenübergestellt und verglichen. Kapitel 7.3 präsentiert Untersuchungsergebnisse zur Robustheit und Übertragbarkeit der Klassifizierer. In Kapitel 7.4 wird ein Vorschlag erarbeitet, wie die automatischen Biotopklassifizierer in Kombination mit den vorhandenen Methoden der Luftbildinterpretation und Feldkartierung eingesetzt werden können, um den von der AG Methodik entwickelten Ablauf einer Stadtbiotopkartierung (Schulte *et al.* 1993) stärker zu automatisieren. Abschließend wird ein Ausblick auf zukünftige Weiterentwicklungen gegeben (Kapitel 7.5).

7.1 Automatisierungspotenzial bei der Erhebung ökologischer Parameter und Indikatoren

Quantitative ökologische Parameter und Indikatoren zur Charakterisierung und Bewertung von Stadtbiotopen bilden einen wichtigen Bestandteil von Stadtbiotopkartierungen. Als Ergebnis einer Literatursuche konnte in Kapitel 4.4 eine Vielzahl von Parametern und Indikatoren zusammengetragen werden, die in der Fachliteratur dokumentiert sind und zum Teil Einzug in die stadtplanerische Praxis gefunden haben. Es ist in der Literatur unumstritten, dass die ökologische Qualität einer Fläche stark von ihrer Oberflächenart abhängt. Somit stellt eine flächendeckende Kartierung der urbanen Oberflächen die wichtigste Informationsquelle zur automatischen Ableitung von ökologischen Parametern und Indikatoren dar. Eine solche Kartierung ist nicht Bestandteil flächendeckend vorhandener GIS-Daten wie ATKIS oder ALKIS. Der für viele Parameter und Indikatoren notwendige Detaillierungsgrad der Kartierung (s. **Tabelle 4-2** in Kap. 4.4) übersteigt die Möglichkeiten multispektraler Fernerkundungsdaten, so dass sich aus diesen Daten nur einfache Parameter und Indikatoren ableiten lassen. Als Beispiele können der häufig erfasste Vegetationsanteil oder eine indirekte Erfassung des ungewichteten Versiegelungsgrades über den Vegetationsanteil genannt werden, unter der Annahme, dass in einer Stadt sämtliche nicht von Vegetation bestandene Flächen versiegelt sind. Die am GFZ Potsdam durchgeführten Arbeiten von Förster (2002) und Heiden (2004) sowie die vorliegende Arbeit haben jedoch gezeigt, dass die meisten der notwendigen Oberflächenarten mit Hyperspektraldaten erfasst werden können. Dies eröffnet die Möglichkeit, zahlreiche quantitative Parameter und Indikatoren automatisch zu erfassen. Neben den Hyperspektraldaten wird hierfür ein digitales Oberflächenmodell benötigt, so dass sich die notwendige Datenbasis mit den für die Biotopklassifizierung notwendigen Daten deckt. Eine Stadt, die eine Aktualisierung ihrer Stadtbio-

penkarte mit der entwickelten Methode in Auftrag gibt, bekommt somit gleichzeitig eine Vielzahl ökologischer Parameter und Indikatoren mitgeliefert. Diese können nach der Erhebung miteinander verglichen und nach Bedarf anwendungsspezifisch ausgewählt werden. Dies ist ein großer Vorteil zur derzeitigen Vorgehensweise, bei der die Entscheidung für einen zu erhebenden Parameter / Indikator auf Basis von theoretischen Überlegungen im Vorfeld eines Vorhabens gefällt werden muss und dieser dann langwierig manuell erfasst werden muss.

In Kapitel 4.4 und den obigen Ausführungen konnte gezeigt werden, dass bei der Erhebung von *quantitativen* Parametern und Indikatoren zur ökologischen Charakterisierung von Stadtbiotopen ein hohes Automatisierungspotenzial besteht, wenn hierfür Hyperspektraldaten verwendet werden. Um eine vollständige Automatisierung zu gewährleisten, müssen einige Parameter und Indikatoren modifiziert werden (s. **Tabelle 4-1** in Kap. 4.4). Hierdurch sind unterschiedlich große Genauigkeitsverluste zu erwarten, die in zukünftigen Untersuchungen noch zu quantifizieren sind.

Neben dieser Aufgabe werden sich zukünftige Untersuchungen auch mit *qualitativen* Parametern und Indikatoren befassen. Ein Beispiel für einen solchen Indikator ist das Ausstattungspotenzial eines Biotops für das Naturerleben durch den Menschen (Schulte *et al.* 1993: 515). Qualitative Parameter und Indikatoren liegen in einer Nominal- oder Ordinalskala vor, d.h. die Werte, die sie annehmen können, sind abzählbar und eindeutig voneinander unterscheidbar, aber nicht quantitativ messbar. Häufig gehen sie aus einer Bewertung hervor und ihre Werte sind z.B. Güteklassen. Diese Güteklassen – oder allgemein gesprochen die Wertausprägungen einer qualitativen Variablen – können wie Klassen in einer Klassifizierungsaufgabe behandelt werden. In zukünftigen Untersuchungen soll daher herausgefunden werden, ob ein Klassifizierer entwickelt werden kann, der auf der Grundlage der Merkmale aus Kapitel 4 zu der gleichen Entscheidung kommt wie ein Experte, der einen qualitativen Parameter / Indikator manuell erhebt.

7.2 Vergleich der beiden entwickelten Biotopklassifizierer

In den Kapiteln 5 und 6 dieser Arbeit wurde die Entwicklung zweier Klassifizierer beschrieben, die dieselbe Aufgabe erfüllen: Die automatische Klassifizierung von Stadtbiotopen aus Fernerkundungsdaten. Beide Klassifizierer verwenden die gleiche Datenbasis (die Merkmale) und bestehen aus einzelnen Modellen für die Biotoptypen. Die Ausgabewerte der Modelle sind jeweils Ähnlichkeitswerte und auch der strukturelle Aufbau der Modelle ist für beide Klassifizierer nicht unähnlich. Darüber hinaus liefern beide Klassifizierer eine vergleichbare Genauigkeit. Der wesentlichste Unterschied zwischen beiden Klassifizierern ist die Art und Weise, wie sie aufgebaut werden: Zum einen manuell und wissensbasiert, zum anderen automatisch unter Verwendung von Trainingsbiotopen. Aus diesem Unterschied resultieren jeweils spezifische Vor- und Nachteile, die in **Tabelle 7-1** gegenübergestellt sind.

Tabelle 7-1 Vor- und Nachteile der beiden Biotopklassifizierer.

Wissensbasierter Fuzzy-Biotopklassifizierer	ML-basierter Biotopklassifizierer
<i>Manueller Aufbau</i> ist mit <i>viel Arbeit</i> verbunden.	Aufbau des Klassifizierers läuft <i>vollautomatisch</i> ab.
Bei der <i>Übertragung auf andere Städte</i> entsteht ein <i>erheblicher Arbeitsaufwand</i> durch die mit Sicherheit notwendige Neukalibrierung und eventuell notwendige Auswahl neuer Merkmale.	Durch die automatische Kalibrierung mit neuen Trainingsbiotopen <i>einfach auf andere Städte übertragbar</i> .
<i>Mehr Kontrolle</i> durch Einbringung des Expertenwissens bei der Merkmalsauswahl.	<i>Keine direkte Einflussnahme</i> des Analysten bei der Merkmalsauswahl möglich.
Die <i>Form der Zugehörigkeitsfunktionen ist flexibel</i> und kann auch an nicht-normalverteilte Merkmale angepasst werden.	Die <i>Wahrscheinlichkeitsdichtefunktionen sind an eine normalverteilte Form gebunden</i> und passen sich nur in ihrer Position und Breite an die Verteilung eines Merkmals an.
Die <i>Merkmalsräume</i> der Inputvariablen sind <i>eindimensional</i> .	Die <i>Merkmalsräume</i> der Inputvariablen können <i>mehrdimensional</i> sein. Eine Kombination von Merkmalen zu einem mehrdimensionalen Merkmalsraum erhöht bei einer Klassifizierung in der Regel die Trennbarkeit der Klassen.

Die beiden erstgenannten Punkte in **Tabelle 7-1** stellen klare Vorteile des ML-basierten Biotopklassifizierer dar. Auf den zweiten Aspekt wird detailliert in Kapitel 7.3.4 eingegangen. Punkt 3 und 4 sprechen zwei Vorteile des Fuzzy-Biotopklassifizierers an. Eine wissensbasierte Merkmalsauswahl ist vor allem dann von Vorteil, wenn die zur Verfügung stehende Menge an Trainingsbiotopen zu gering ist, um den ML-basierten Biotopklassifizierer präzise zu kalibrieren. Die in dieser Arbeit verwendete Menge war hierfür jedoch in beiden Städten ausreichend.

Punkt 4 – die flexible Form der Zugehörigkeitsfunktionen – käme vor allem dann zum tragen, wenn ein Merkmal keine klare Trennbarkeit zweier Biotoptypen liefert, d.h. wenn sich die Häufigkeitsverteilungen der Trainingsbiotope beider Biotoptypen überschneiden. Angepasste Zugehörigkeitsfunktionen würden dann im Überschneidungsbereich bessere Klassifizierungsergebnisse liefern. Allerdings haben die Ergebnisse der zwei in Kapitel 5.4 verwendeten Formen der Zugehörigkeitsfunktionen gezeigt, dass die Unterschiede marginal sind. Sofern die Häufigkeitsverteilungen der Trainingsbiotope im Merkmalsraum weit genug auseinander liegen, spielt die Form der Zugehörigkeits- bzw. Wahrscheinlichkeitsdichtefunktion keine Rolle. Ein adäquates Mittel um dies zu erreichen, ist erfahrungsgemäß eine Erhöhung der Dimensionalität des Merkmalsraums (Punkt 5). Hier hat der ML-basierte Biotopklassifizierer einen Vorteil, da die Merkmale zu mehrdimensionalen Inputvariablen kombiniert werden. Insgesamt schneidet somit der ML-basierte Biotopklassifizierer in diesem Vergleich deutlich besser ab, da er faktisch keine Nachteile gegenüber dem Fuzzy-Biotopklassifizierer besitzt.

7.3 Untersuchungen zur Robustheit und Übertragbarkeit der Biotopklassifizierer

7.3.1 Ablehnung von Biotopen mit unbekanntem Biotoptyp

Die Klassifizierung von bekannten Biotopen, d.h. von solchen, deren Biotoptyp im Klassifizierer implementiert ist, wurde in den Kapiteln 5.5 und 6.3 ausführlich beschrieben. Werden dem Klassifizierer nur bekannte Biotope übergeben, findet die Klassifizierung sozusagen in einer sicheren Testumgebung statt. In der operationellen Anwendung bei der Aktualisierung einer Biotoptypenkarte müssen dagegen alle Biotope auf Veränderung geprüft werden, wobei es nicht möglich sein wird, alle existierenden Biotoptypen im Klassifizierer zu implementieren. Daher ist die Fähigkeit, unbekannte Biotope abzulehnen eine elementar wichtige für die operationelle Anwendung der entwickelten Klassifizierer. Im Folgenden soll überprüft werden, inwieweit die beiden Klassifizierer hierzu in der Lage sind. Sie werden dazu auf alle Biotope in den beiden Untersuchungsgebieten angewendet, die zu Biotoptypen gehören, die nicht in den Klassifizierern implementiert sind.

Der Fuzzy-Biotopklassifizierer kann für diese Aufgabe unverändert bleiben. Liegt der Merkmalswert eines Biotops außerhalb der Zugehörigkeitsfunktionen, so erhält das Biotop für die entsprechende Input Variable den Fuzzy Wert 0, der durch die Verwendung des MIN-Operators zum Ausgabewert des Fuzzy Modells wird (Kap. 5.2). Wenn alle Modelle einen Ähnlichkeitswert von 0 berechnen, wird das Biotop nicht klassifiziert – also abgelehnt. Dies gelingt dem Fuzzy Biotopklassifizierer für 98 % der unbekannt Biotope im Untersuchungsgebiet Dresden.

Der ML-basierte Biotopklassifizierer muss in seiner Funktionalität um einen Schwellenwert ergänzt werden, um unbekannte Biotope ablehnen zu können, da die hier verwendeten Dichtefunktionen im Gegensatz zu den Zugehörigkeitsfunktionen der Fuzzy Modelle nie den Funktionswert 0 erreichen. Ein Schwellenwert auf die Wahrscheinlichkeitswerte der Klassen (Biotoptypen) ist in diesem Fall jedoch nicht geeignet, da deren Berechnung nach dem Bayes'schen Theorem (**Gleichung (7-1)**) aus einer Normierung der Dichtewerte der Klassen mit der Gesamtdichte aller Klassen hervorgeht. Wird also ein unbekanntes Biotop klassifiziert, so summieren sich die Wahrscheinlichkeitswerte der im Klassifizierer implementierten Klassen immer auf 100, unabhängig davon, wie gering die Dichtewerte der Klassen an der Stelle x im Merkmalsraum sind ($x = \text{Merkmalsvektor des unbekannt Biotops}$)²⁴. Um dies zu verhindern, werden Schwellenwerte auf die Mahalanobis Distanzen der Klassen angewendet. Diese werden automatisch anhand der Trainingsbiotope der Klassen berechnet und ergeben sich aus den jeweils größten Distanzwerten der Trainingsbiotope einer Klasse. Durch Anwendung der Schwellenwerte werden die Wahrscheinlichkeitswerte der Klassen für ein zu klassifizierendes Biotop auf 0 gesetzt, wenn der Merkmalsvektor des Biotops zu den Mittelwertsvektoren der Klassen eine größere Mahalanobis Distanz aufweist, als der berechnete Schwellenwert es zulässt. Dies geschieht bei allen Paarweisklassifizierungen der Klassen. Da der Aufbau der ML-basierten Modelle dem der Fuzzy Modelle nachempfunden ist (MIN-Operator zur Verknüpfung der Input Variablen), erhält eine Klasse den endgültigen Wahrscheinlichkeitswert 0, wenn sie diesen in mindestens einem der Paarweisklassifizierungen erhalten hat. Schlussendlich kann der ML-basierte Klassifizierer so-

²⁴ Erläuterung: Das Bayes'sche Theorem gilt nur dann, wenn dem Klassifizierer alle existierenden Klassen bekannt sind, da durch die Summe der Wahrscheinlichkeitsdichten der beteiligten Klassen dividiert wird (**Gleichung (7-1)**). So sind die ermittelten Wahrscheinlichkeiten also nur dann sinnvoll, wenn dem Klassifizierer der Biotoptyp des zu klassifizierenden Biotops bekannt ist.

mit ein Biotop ablehnen, wenn durch die Anwendung der Schwellenwerte allen Klassen ein Wahrscheinlichkeitswert von 0 zugewiesen wurde.

$$p(\omega_i | x) = \frac{p(x | \omega_i)p(\omega_i)}{\sum_{i=1}^M p(x | \omega_i)p(\omega_i)} \quad (7-1)$$

mit $p(\omega_i|x)$: *a posteriori* Wahrscheinlichkeit der Klasse ω_i bei gegebenem Merkmalsvektor x
 $p(x|\omega_i)$: Wahrscheinlichkeitsdichte der Klasse ω_i an der Stelle x im Merkmalsraum
 $p(\omega_i)$: *a priori* Wahrscheinlichkeit der Klasse ω_i
 M : Anzahl der Klassen

Der ML-basierte Klassifizierer erreicht bei der Ablehnung unbekannter Biotope eine nicht ganz so hohe Quote wie der Fuzzy Klassifizierer. Dies kann mit der Art der Merkmalsauswahl und den daraus resultierenden Merkmalsräumen zusammenhängen. Diese sind beim ML-basierten Klassifizierer darauf optimiert, bekannte Biotoptypen voneinander zu unterscheiden, nicht aber unbekannte Biotoptypen abzulehnen. Eine Implementierung von Biotoptypen, deren Biotope nicht abgelehnt werden können, könnte also durchaus dazu führen, dass diese erkannt und von den übrigen implementierten Typen unterschieden werden können.

Durch die Anwendung der Schwellenwerte auf die Mahalanobis Distanzen lehnt der ML-basierte Klassifizierer 65 % der unbekannt Biotope Dresdens und 44 % der unbekannt Biotope Berlins ab. Ergänzt durch einen moderaten Schwellenwert (bei 15 %) auf die Wahrscheinlichkeitswerte lassen sich diese Werte auf 81 % bzw. 61 % steigern. Somit besteht in diesem Punkt noch weiterer Forschungsbedarf, um eine vollständige Ablehnung zu erreichen. Eine Betrachtung der Biotope, die im Berliner Untersuchungsgebiet nicht abgelehnt werden konnten, zeigt einen Ansatzpunkt für die Weiterentwicklung auf: Sie gehören zu einem Großteil (58 %) zu Biotoptypen der Obergruppen „Grünland, Staudenfluren und Rasengesellschaften“ oder „anthropogene Rohbodenstandorte und Ruderalfluren“ und wurden von dem einzigen im Klassifizierer implementierten Biotoptyp vereinnahmt, der hauptsächlich aus naturbelassenen, nicht baulich geprägten Flächen besteht: Dem Biotoptyp „reiner Scher- und Zierrasen“. Daher wird es als vielversprechend angesehen, durch einen einfachen Schwellenwert auf den überbauten Flächenanteil eines Biotops eine Vorselektion durchzuführen und die baulich geprägten von den nicht baulich geprägten Biotopen zu trennen. Nach den bisherigen Erfahrungen erscheint es als möglich, den vorhandenen Klassifizierer um die noch fehlenden baulich geprägten Biotoptypen zu vervollständigen. Für die Klassifizierung der nicht baulich geprägten Biotope könnte dann ein zweiter, separater Klassifizierer entwickelt werden. Inwieweit dies aus heutiger Sicht machbar erscheint, wird im Ausblick dieser Arbeit (Kap. 7.5) ausgeführt.

7.3.2 Verhalten der Biotopklassifizierer bei räumlichen und thematischen Mischbiotopen

Die Problematik der Mischbiotope (Kap. 3.2.3) tritt verstärkt im Berliner Untersuchungsgebiet auf, da die Art der Bebauung in Berlin viel mehr Mischformen, Variationen und fließende Übergänge zwischen Biotoptypen zeigt als die deutlich klarer strukturierte Bebauung Dresdens. Dies spiegelt sich auch in der Genauigkeit der Klassifizierung wider (**Abbildung 6–3** in Kap. 6.3). Der Anteil der strittigen Mischbiotope ist in Berlin mit 12 % deutlich höher als in Dresden, weshalb im Folgenden nur auf das Berliner Untersuchungsgebiet eingegangen wird. Alle Mischformen sind im Wesentlichen auf Mischungen zwischen den Biotoptypen der Wohnbebauung beschränkt.

Bei den Mischbiotopen des Typs I (räumlich zu teilende Flächen; 6 % der untersuchten Biotopflächen Berlins) handelt es sich um Fehler in der Biotopkartierung. Die entsprechenden Flächen sind nicht einheitlich bebaut, sondern bestehen aus zwei oder mehr Biotopen unterschiedlichen Typs, die durch klare Grenzen voneinander getrennt sind (**Abbildung 3–4 c**). Ab einer gewissen Mindestfläche sollten die Biotope einzeln ausgewiesen werden, auch wenn dadurch Straßenblöcke zerteilt werden. Es wäre wünschenswert, dass der Biotopklassifizierer diese Aufgabe bei einer Aktualisierungskartierung automatisch vornimmt. Ein erster Schritt hierfür wäre die Ablehnung der gemischten Flächen durch den Klassifizierer. Weitere Schritte wären die Erkennung, dass es sich um Flächen des Typs I handelt, gefolgt von der Aufteilung in einzelne Biotope und deren Klassifizierung. Diese Ziele können mit der derzeitigen Variante des ML-basierten Klassifizierers nicht erreicht werden. Der Klassifizierer lehnt derzeit nur ca. 10 % dieser Flächen ab. Die Flächen werden hauptsächlich dem dominierenden Biotoptyp der Wohnbebauung zugeschlagen. Es ist möglich, dass eine detaillierte Auswertung der Ähnlichkeitswerte in Zukunft Erfolg bringen kann. Im Vergleich zum Biotoptyp „reiner Scher- und Zierrasen“ zeigen die Flächen des Typs I deutlich geringere Ähnlichkeitswerte für den Gewinnerbiotoptyp sowie eine größere Anzahl von Verliererbiotoptypen mit Ähnlichkeitswerten über 10 % (Biotope mit grau hinterlegtem Balken in **Abbildung 7–1**). Dies ist jedoch der eindeutigste Vergleich. Für die Biotope der Hochhausbebauung trifft nur noch der zweite Punkt zu und im Vergleich zu schwierigen Biotoptypen wie der Blockbebauung sind kaum signifikante Unterschiede in den Ähnlichkeitswerten zu erkennen. Hier besteht somit weiterer Forschungsbedarf.




Abbildung 7-1 Die Ähnlichkeitswerte der Flächen des Typs I im Vergleich zu ausgewählten Biotoptypen.

Die Mischbiotope des Typs II sind kleinräumige Mischungen von Bebauungstypen, die zu verschiedenen Biotoptypen gehören (**Abbildung 3–4 a und b**). Eine Aufteilung in einzelne Biotope ist hier nicht sinnvoll, da diese das Mindestflächenmaß unterschreiten würden. In der Kartierung sind diese Flächen dem flächenmäßig dominierenden Biotoptyp zugewiesen worden. Mit dieser Entscheidung stimmt der ML-basierte Biotopklassifizierer nur in 56 % der Fälle überein. Eine alternative Vorgehensweise wäre die explizite Ausweisung eines räumlichen Mischtyps unter Angabe der auftretenden Biotoptypen. Es ist jedoch fraglich, ob dieser Detaillierungsgrad von der Seite der Stadtplaner gewollt ist. Da Mischbiotope des Typs in Dresden quasi nicht vorkommen und auch in Berlin nur 4 % der Flächen betroffen sind, wird eine weitere Untersuchung dieses Aspekts im Vergleich zum Typ I als weniger wichtig erachtet.

Noch seltener treten die Flächen des Typs III auf (2 % der untersuchten Biotope Berlins). Die entsprechenden Biotope sind unter Gesichtspunkten der Form und Struktur der Bebauung als thematische Mischungen zu betrachten (**Abbildung 3–4 d-g**). Da dies die Kriterien sind, nach denen der automatische Klassifizierer seine Entscheidung fällt, stellen sie für den Klassifizierer Problemfälle dar. Die thematischen Mischungen sind anhand der Ähnlichkeitswerte nachvollziehbar. Während bei „normalen“ Biotopen klare Entscheidungen die Regel sind (d.h. ein Biotoptyp erhält einen Ähnlichkeitswert von weit über 50 %, die anderen maximal einstellige Ähnlichkeitswerte), erhalten bei thematischen Mischbiotopen häufig zwei oder drei Biotoptypen Ähnlichkeitswerte über 10 %. Die Klassifizierung nach dem höchsten Ähnlichkeitswert stimmt jedoch nur in 55 % aller Fälle mit dem Urteil des Analysten überein. Ein Luftbildinterpret hat es in diesen Fällen häufig einfacher, da er eine Reihe von „weichen“ Kriterien wie z.B. die Art der Freiflächen (private Gärten, gemeinschaftlich genutzte Grünflächen oder öffentliche Parkanlagen) heranziehen kann, um seine Entscheidung zu fällen. Es bleibt dennoch die Frage bestehen, ob eine eindeutige Entscheidung in diesen Fällen überhaupt gefällt werden kann oder ob die unter Gesichtspunkten der Bebauungsstruktur definierten thematischen Mischbiotope nicht auch ökologische Mischungen unter stadtoökologischen Gesichtspunkten darstellen.




Abbildung 7–2 Ähnlichkeitswerte der thematischen Mischbiotope (Typ III). Die Höhe des zweithöchsten Ähnlichkeitswerts ist mit einem grauen Balken hinterlegt, wenn dieser 10 % überschreitet.

7.3.3 Robustheit der Biotopklassifizierer gegenüber Fehlern in den Eingabedaten und der Prozessierungskette

Jeder Sensor besitzt eine bestimmte Messgenauigkeit, jede Datenverarbeitungsmethode ein gewisses Fehlerpotenzial. Je länger die Prozessierungskette und je zahlreicher die Eingabedaten, desto mehr Fehler können entstehen. Diese können sich dann entweder durch die gesamte Prozessierungskette durchziehen und das Endergebnis verschlechtern oder aber von einem guten Algorithmus abgefangen werden. In diesem Kapitel werden deshalb häufig auftretende Fehler beschrieben und die Robustheit der Biotopklassifizierer gegenüber diesen getestet.

Einfluss unterschiedlicher DOMs

Im Dresdner Untersuchungsgebiet wurden zwei DOMs von prinzipiell unterschiedlicher Herstellungsart verwendet (s. Kap. 3.3.1): Ein von einem Laserscanner aufgezeichnetes DOM und ein aus Luftbildern stereoskopisch erzeugtes DOM. Das DOM von Berlin wurde ebenfalls stereoskopisch erzeugt, jedoch aus Bilddaten eines multispektralen Zeilenscanners. Die spezifischen Probleme dieser DOMs wurden bereits in Kapitel 3.3.1 dargestellt. Auf die Genauigkeit der Biotopklassifizierung hat die Art des DOMs jedoch keinen Einfluss, wie die erzielten Ergebnisse beider Klassifizierer beweisen. Die spezifischen Probleme der DOMs werden insbesondere durch die Art und Weise, wie die Merkmale zur Biotoperkennung berechnet werden, abgefangen. Dies sei im Folgenden an einem Beispiel erklärt.

Ein Problem der stereoskopisch erzeugten DOMs ist es, dass die Gebäude zum Rand hin eine zu geringe Höhe aufweisen (**Abbildung 3-5 b** in Kapitel 3.3.1). Somit sind die berechnete minimale und durchschnittliche Höhe der Gebäude zu gering. Die maximale Höhe ist von diesem Effekt jedoch nicht betroffen. Da von vielen Merkmalen Varianten mit diversen statistischen Parametern berechnet werden, findet sich häufig eine Variante, die von einem spezifischen Problem nicht betroffen ist. Es ist natürlich wichtig, dass der Experte, der die wissensbasierte Merkmalsauswahl durchführt, dies berücksichtigt. Bei der automatischen Merkmalsauswahl werden solche Effekte automatisch berücksichtigt, da der Computer ein Merkmal nicht auswählen wird, wenn es, bedingt durch einen solchen Effekt, keine gute Trennbarkeit der Biotoptypen liefert. Wird zum Beispiel ein DOM gegen ein anderes ausgetauscht, kann die automatische Merkmalsauswahl neu durchgeführt und der ML-basierte Biotopklassifizierer neu kalibriert werden. Dadurch werden neue passende Merkmale gesucht und die Häufigkeitsverteilungen der Trainingsdaten neu geschätzt, um den Klassifizierer auf die veränderte Situation einzustellen. Neben den Einflüssen des DOMs ist der ML-basierten Biotopklassifizierer durch die Möglichkeit des automatischen Neuaufbaus und der Neukalibrierung auch in der Lage, andere datensatzspezifische Unterschiede zu kompensieren, wie z.B. unterschiedliche geometrische Auflösungen, unterschiedliche Sonnenstände (Schattenanteil in der Szene) oder unterschiedliche Jahreszeiten (Entwicklungsstadium der Vegetation).

Fehler in der Klassifizierung und Entmischung urbaner Oberflächenarten

Klassifizierungsfehler, die auf Störeffekte wie Sensorübersättigung, Alterung von Oberflächen oder Bedeckung von Oberflächen mit spektral unbekanntem Objekten im Subpixelbereich (Autos etc.) zurückzuführen sind, spielen bei der Biotopklassifizierung keine Rolle, da es sich hier um lokal auftretende Phänomene handelt, die im Vergleich zur gesamten Biotopfläche eher kleinflächig sind und dadurch nicht ins Gewicht fallen. Die Mehrheit der übrigen Klassifizie-

rungsfehler bestehen vor allem zwischen spektral ähnlichen Klassen. Durch die Unterstützung der Klassifizierung mit einer Gebäudemasken (s. Kap. 3.4.3 bzw. Kap. 3.3.2) werden diese Verwechslungen zusätzlich auf spektral ähnliche Klassen innerhalb oder außerhalb der Gebäudemasken begrenzt. Ein großer Teil dieser Verwechslungen kann durch das Zusammenfassen der urbanen Oberflächenarten zu thematischen Klassengruppen (Kap. 3.4.4) jedoch aufgehoben werden, da sich spektral ähnliche Klassen, z.B. rote Tonziegel und dunkelrot-braune Tonziegel oder Wiese und Rasen oder Beton und Asphalt, häufig in denselben Klassengruppen wiederfinden. So ist es die auf den Klassengruppen durchgeführte Merkmalsberechnung, die den Algorithmus besonders fehlertolerant macht. Aus diesem Grund wurde die Merkmalsuche bei der wissensbasierten Merkmalsselektion (Kap. 5.3) von vornherein auf die Biotop- und Klassengruppenmerkmale beschränkt.

Geometrische Fehler

Alle Geodaten besitzen eine bestimmte Lagegenauigkeit. Bei gemeinsamer Auswertung können Lagefehler zu Problemen führen. In der Regel ist es möglich, Fernerkundungsbilder auf eine Lagegenauigkeit von wenigen Pixeln geometrisch zu korrigieren. Daher wurde untersucht, wie die Biotopklassifizierer auf einen Versatz von wenigen Pixeln reagieren, indem in zwei Testreihen die direkten Eingabedaten der Klassifizierer (Entmischungsergebnis, Segmentierungsbild, nDOM und die Biotopgrenzen) gegeneinander verschoben wurden. Dabei sollen nur die beiden Biotopklassifizierer, die das letzte Glied der Prozessierungskette darstellen, getestet werden, um deren Robustheit zu untersuchen. Eine Untersuchung der Auswirkungen entlang der gesamten Prozessierungskette wäre weitaus aufwändiger, da insbesondere das DOM und die auf den HyMap-Daten beruhenden Produkte in vielfacher Weise miteinander verflochten sind (z.B. bei der Orthorektifizierung und der Klassifizierung und Entmischung der HyMap-Daten).

In der ersten Testreihe (SHIFT1) wurden sämtliche Fernerkundungsdaten zusammengehalten und gegenüber der Biotopkartierung schrittweise versetzt. In der zweiten Testreihe (SHIFT2) wurden das Entmischungsergebnis und das Segmentierungsbild, zwischen denen es keinen Versatz geben kann, da das Letztere aus dem Ersteren abgeleitet wird, in eine Richtung und das nDOM in die entgegengesetzte Richtung verschoben. In beiden Testreihen wurden die Daten um 1, 2, 3, 5, 7 und 10 Pixel verschoben.

Die Ergebnisse beider Testreihen sind in **Abbildung 7-3** dargestellt. Für alle Testreihen äußert sich ein steigender geometrischer Versatz in einer abnehmenden Klassifizierungsgenauigkeit. Der ML-basierte Biotopklassifizierer ist jedoch in der Lage, den Genauigkeitsverlust signifikant abzuschwächen. Weiterhin besteht für den Fuzzy-Biotopklassifizierer ein deutlicher Unterschied zwischen der SHIFT1- und SHIFT2-Testreihe. Auch diesen Unterschied kann der ML-basierte Biotopklassifizierer offensichtlich kompensieren. Die Erklärung hierfür liegt im automatischen Neuaufbau und der automatischen Neukalibrierung des ML-basierte Biotopklassifizierer, der sich dadurch auf die veränderte Situation einstellen kann. Er ist nicht nur in der Lage, die statistische Verteilung der Klassen neu zu schätzen sondern kann außerdem bestimmte Merkmale, die bei einem geometrischen Versatz nicht mehr funktionieren, aufgeben und durch andere ersetzen. Diese Möglichkeiten besitzt der Fuzzy-Biotopklassifizierer nicht. Als Schlussfolgerung ergibt sich aus diesen Ergebnissen, dass der ML-basierte Biotopklassifizierer geometrische Ungenauigkeiten in typischen Größenordnungen von 1-2 Pixeln ohne gravierenden Genauigkeitsverlust kompensieren kann. Der Fuzzy-Biotopklassifizierer zeigt schon ab dem ersten Pixel Versatz deutliche Genauigkeitseinbußen.




Abbildung 7-3 Auswirkung eines geometrischen Versatzes der Eingabedaten auf die Klassifizierungsgenauigkeit der Biotopklassifizierer (pMLK = ML-basierter Biotopklassifizierer, Fuzzy = Fuzzy-Biotopklassifizierer).

7.3.4 Übertragbarkeit der Biotopklassifizierer auf andere Untersuchungsgebiete

Bei der Übertragung des für das Dresdner Untersuchungsgebiet entwickelten Fuzzy-Biotopklassifizierers auf das Untersuchungsgebiet in Berlin sind Probleme aufgetreten, die gezeigt haben, dass der einmalige Aufbau eines universal anwendbaren Biotopklassifizierers kaum möglich sein wird. Es hat sich herausgestellt, dass die Fuzzy Modelle bei der Übertragung an die regionalen Eigenheiten der Stadtstruktur angepasst werden müssen. Dies kann bedeuten, dass die Grenzen der Zugehörigkeitsfunktionen neu eingestellt werden müssen und dass eventuell einzelne Merkmale entfernt und neue gefunden werden müssen. Während die Modelle der Biotoptypen Hochhausbebauung und „reine Scher- und Zierrasen“ ohne Anpassung funktionierten, blieben die Biotope der anderen Biotoptypen im Wesentlichen unklassifiziert. Daraus folgt, dass die Übertragung der an einer bestimmten Stadt kalibrierten Fuzzy Modelle auf andere Städte relativ aufwändig ist, da die Anpassungen manuell vorgenommen werden müssen. Durch diese Erkenntnis wurde die Entwicklung des automatischen, ML-basierten Biotopklassifizierers motiviert, dessen Aufbau und Kalibrierung wie in Kapitel 6 beschrieben automatisiert abläuft.

Durch die Automatisierung der Merkmalsauswahl und der Kalibrierung des ML-basierten Biotopklassifizierers ist dieser in der Lage, sich automatisch an neue Datensätze (z.B. ein anderes DOM; s. Kap. 7.3.3), geometrische Fehler (Kap. 7.3.3) und an regional unterschiedliche Stadtstrukturen anzupassen, indem neue passende Merkmale gesucht und die Häufigkeitsverteilungen der Trainingsbiotope neu geschätzt werden. So sind zum Beispiel einige Merkmale (beispielsweise das Verhältnis von reinen Pixeln zu Mischpixeln, *PPMP*) abhängig von der räumlichen Auflösung der HyMap-Daten, so dass bei einem neuen Datensatz mit abweichender räumlicher Auflösung eine Neukalibrierung derjenigen Paarweiseklassifizierer notwendig ist, die diese Merkmale enthalten. Weiterhin weisen einige Biotoptypen (z.B. die Zeilenbebauung in Berlin (s. **Abbildung 3-2** in Kap. 3.2.2)) regionale Besonderheiten auf. Während in Dresden das Merkmal „Orientierung der Segmente zueinander“ (*O_{Seg_k}*) sehr gut zur Erkennung der Zeilenbebauung geeignet war, kann dieses in Berlin nicht verwendet werden, da die Gebäude der Zeilenbebauung häufig nicht parallel stehen. Dieses Merkmal muss also für Berlin verworfen und durch ein ande-

res ersetzt werden. In diesem Sinne ist ein an einer Stadt aufgebauter und kalibrierter Klassifizierer zwar nicht auf eine andere Stadt übertragbar, aber durch die Automatisierung der Merkmalsauswahl und Kalibrierung kann ohne großen Arbeitsaufwand ein neuer, angepasster Klassifizierer erzeugt werden. Die Operationalität dieses Verfahrens wurde durch die Anwendung in zwei deutschen Städten bewiesen. Es wird daher davon ausgegangen, dass der ML-basierte Biotopklassifizierer weltweit auf alle Mittel- und Großstädte mit europäisch geprägter Architektur und Stadtstruktur anwendbar ist.

7.4 Ablauf der automatischen Biotopklassifizierung und Integration in den Prozess der Aktualisierung einer Stadtbioptypenkarte

Der Ablauf einer Stadtbiotopkartierung gliedert sich nach Schulte *et al.* (1993) wie in **Tabelle 7-2** gezeigt. Sie besteht neben dem Kernstück – der Kartierung der Bioptypen (Punkt 3) – aus weiteren, ebenso wichtigen Teilen. Nach Schulte *et al.* (1993: 500) soll in Abständen von ca. 5 Jahren anhand von Luftbildern und Feldkartierungen von ca. 10 % der unter Punkt 4 genannten Flächen überprüft werden, ob eine Wiederholung der Kartierung notwendig ist. Wird eine Aktualisierungskartierung als notwendig erachtet, muss Punkt 1 überprüft und die bereits vorhandene Datenbasis aus Punkt 2 durch aktuelle Daten – insbesondere neue CIR-Luftbilder – ergänzt werden. Im 3. Punkt wird die vorhandene Bioptypenkarte anhand der aktuellen Luftbilder überprüft (visuelle Luftbildinterpretation) und aktualisiert. Dieser Punkt sollte den Hauptaufwand der Aktualisierungskartierung darstellen und kann mit den Methoden dieser Arbeit zu großen Teilen automatisiert werden. Der notwendige Umfang der Arbeiten in den nachfolgenden Punkten richtet sich dann nach Art und Umfang der Veränderungen der Biotop-typenkarte.

Tabelle 7-2 Ablauf einer Stadtbiotopkartierung nach Schulte *et al.* (1993: 496).

Vorarbeiten	<ol style="list-style-type: none"> 1. Abgrenzung des Untersuchungsgebiets 2. Erfassung und Auswertung vorhandener Daten
Erhebung	<ol style="list-style-type: none"> 3. Kartierung der Bioptypen 4. Auswahl von Beispielflächen 5. Kartierung der Beispielflächen
Aufbereitung	<ol style="list-style-type: none"> 6. Aufbereitung der erhobenen Daten (Zustandsbeschreibung) 7. Zustandsbewertung der Bioptypen/Biotopstrukturen im Hinblick auf Naturschutz und Landschaftspflege, Naturerfahrung und Naturerleben sowie Stadtbild/Dorfbild/Landschaftsbild. 8. Umsetzung der Programme in Schutz-, Pflege- und Entwicklungsmaßnahmen etc. 9. Effizienzkontrollen

Die in dieser Arbeit entwickelte Methode zur automatischen Biotopklassifizierung gliedert sich in vier Phasen, die in **Abbildung 7–4** schematisch dargestellt sind. Bei einer Eingliederung dieser Phasen in den oben gezeigten Ablauf einer Stadtbiotopkartierung würden Phase A in Punkt 2 und die Phasen B, C und D in Punkt 3 eingeordnet werden. Die in Kapitel 4.4 diskutierte Berechnung ökologischer Parameter und Indikatoren würde einen eigenen Punkt im Block „Erhebungen“ erhalten. Es wird vorgeschlagen, das DOM stereoskopisch aus Luftbildern zu erzeugen, da die Genauigkeit der automatischen Biotopklassifizierung mit beiden DOM-Quellen (Laserscanner und Luftbilder) identisch war und die Luftbilder ohnehin zur visuellen Interpretation aufgenommen werden müssen. So müssen im Vergleich zur klassischen Kartierung nur die Hyperspektraldaten zusätzlich erhoben werden. Dies kann unter Umständen sogar mit derselben Befliegung erfolgen, da es möglich ist, zwei Sensoren in einem Flugzeug zu montieren.

Die entwickelte automatische Biotopklassifizierung ist potenziell in der Lage, den baulich geprägten Teil einer Stadt (ca. 40-60 %) automatisch zu überprüfen und zu aktualisieren. Zusätzlich können möglicherweise in Zukunft ausgewählte vegetationsdominierte Biotoptypen ebenfalls automatisch erkannt werden (s. dazu Kap. 7.5). Der verbleibende Teil der Stadt kann anschließend mit den klassischen Methoden (CIR-Luftbildinterpretation und Feldbegehung) kartiert werden. Der durch die Automatisierung gewonnene Zeitvorteil kann zum Beispiel dazu eingesetzt werden, die ökologisch wertvollen Flächen im Rahmen der Kartierung der Beispielflächen (Punkte 4 + 5) intensiver zu untersuchen.

Das in **Abbildung 7–4** gezeigte Schema zum Ablauf der automatischen Biotopklassifizierung gilt in der dargestellten Form für den ML-basierten Klassifizierer. Für den Fall des Fuzzy-Klassifizierers fließt in Phase C neben den Trainingsbiotopen noch Expertenwissen mit in den Aufbau der Modelle ein. Die Arbeitsschritte der Phase A sind ausführlich in Kapitel 3 beschrieben, die Berechnung der Merkmale (Phase B) in Kapitel 4 und der Aufbau und die Genauigkeitsüberprüfung der Biotopklassifizierer (Phase C) in den Kapiteln 5 bzw. 6. Bei der Anwendung des Klassifizierers (Phase D) werden für jedes Biotop die Merkmalswerte der in den Modellen implementierten Merkmale eingelesen und an die Modelle übergeben. Diese berechnen daraus Ähnlichkeitswerte für die Biotoptypen, aus denen die Klassifizierungsentscheidung abgeleitet wird. Der ermittelte Biotoptyp, die Ähnlichkeitswerte und die ökologischen Parameter / Indikatoren der Biotope werden in eine DBF-Tabelle exportiert, die über die während der gesamten Prozesskette mitgeführten Biotop-IDs an die ursprüngliche Biotoptypenkarte im Shape-Format angehängt werden kann. Als Ergebnis der automatischen Biotopklassifizierung liegen die neuen Informationen somit als zusätzliche Attribute der alten Vektorflächen der Biotope vor.




Abbildung 7-4 Ablauf der automatisierten Biotopklassifizierung. Sie besteht aus 4 Phasen: A. Datenerhebung und Vorbereitung, B. Merkmalsberechnung, C. Aufbau und Genauigkeitsüberprüfung des Klassifizierers, D. Anwendung des Klassifizierers. Einige zur Phase A gehörende und in den Kapiteln 3.3.2 und 3.4.2 beschriebene Datenvorverarbeitungsschritte werden aus Gründen der Übersichtlichkeit nicht dargestellt.

Der Schritt der Informationsübertragung in die Vektordaten kann bereits als Aktualisierung der alten Biotoptypenkarte betrachtet werden. Hier ermöglichen nun zahlreiche GIS-Funktionen weitere Analysen. Zum Beispiel können Biotope, die einen geringen Ähnlichkeitswert für den zugewiesenen Biotoptyp aufweisen oder bei denen eine Veränderung des Biotoptyps im Vergleich zur alten Kartierung festgestellt wurde, selektiert und zur Kontrolle visuell überprüft werden. Ab der zweiten Aktualisierungskartierung können die berechneten Ähnlichkeitswerte unterschiedlicher Jahre miteinander verglichen werden und eventuell dazu eingesetzt werden, die Robustheit des Biotopklassifizierers noch weiter zu steigern. Eine Untersuchung der raumzeitlichen Veränderung der ökologischen Parameter und Indikatoren kann dabei helfen, lokale oder globale Trends aufzeigen. Natürlich können von sämtlichen Ergebnissen kartographische Darstellungen erzeugt und geplottet werden.

7.5 Ausblick

In dieser Arbeit wurde das Potenzial von Fernerkundungsdaten und Methoden untersucht, um Stadtbioptypenkarten automatisch zu aktualisieren. Die zu diesem Zweck entwickelten Biotopklassifizierer ermöglichen erstmals die automatische Erkennung des Biotoptyps von Stadtbiotopen. Aufgrund des automatisierten Aufbauprozesses des ML-basierten Biotopklassifizierers, seiner größeren Fehlertoleranz (Kap.7.3.3) und der vereinfachten Übertragbarkeit (Kap. 7.3.4) wird dieser in Zukunft vorrangig weiterentwickelt werden. Aus methodischer Sicht sind Verbesserungen in folgenden Punkten denkbar bzw. notwendig:

- **Merkmalsselektion:** Wie es in Kapitel 6.3 erörtert wurde, muss die Merkmalsselektionsmethode durch eine Art Robustheitsprüfung erweitert werden, damit auch Merkmale genutzt werden können, die auf individuellen Klassen berechnet werden. Des Weiteren sollen kom-

plexere Merkmalsselektionsmethoden getestet werden, um das Auftreten des *nesting problems* zu verhindern.

- Ablehnung unbekannter Biotope: Die Ergebnisse in Kapitel 7.3.1 zeigen, dass der ML-basierte Klassifizierer unbekannte Biotope weniger gut ablehnen kann als der Fuzzy Klassifizierer. Als Gründe wurden angeführt, dass der Funktionswert einer Wahrscheinlichkeitsdichtefunktion nie Null sein kann und dass das Bayes'sche Theorem im Fall eines nicht implementierten Biotoptyps nicht gilt. Weiterhin sind die Merkmalsräume nicht für die Ablehnung unbekannter Biotope optimiert, sondern für die Unterscheidung der bekannten Biotoptypen. Es ist wahrscheinlich, dass unbekannte Biotope, die nicht abgelehnt werden können, korrekt klassifiziert werden würden, wenn ihre Biotoptypen im Klassifizierer implementiert wären und sie dadurch also zu „bekannten“ Biotopen werden würden. Da es nicht machbar erscheint, alle Biotoptypen zu implementieren, zielt die künftige Strategie darauf ab, die Biotope durch eine Vorselektion anhand des Bebauungsgrades in baulich geprägte und nicht baulich geprägte Biotope aufzuteilen. Für beide Gruppen soll dann ein eigener Klassifizierer entwickelt werden, wobei es machbar erscheint, die baulich geprägten Biotoptypen vollzählig zu implementieren.
- Aufbau eines Klassifizierers für nicht baulich geprägte Biotoptypen: Das Gros der nicht baulich geprägten Biotoptypen wird flächenmäßig vorwiegend durch Vegetation dominiert. Daher hängt der Aufbau eines entsprechenden Klassifizierers vom Potenzial der verwendeten Fernerkundungsdaten ab, urbane Vegetationstypen (z.B. Wiesen, Zierrasen, Buschwerk, Hecken, Baumreihen, Wäldchen) bzw. Nutzungstypen (z.B. private Gärten, öffentliche Parkanlagen, Friedhöfe) zu differenzieren. Arbeiten in nicht-urbanen Gebieten haben gezeigt, dass mit Hyperspektraldaten eine detaillierte Differenzierung der Vegetation möglich ist, die in bestimmten Anwendungen bis hin zur Unterscheidung einzelner Arten gehen kann. Zu nennen sind hier zum Beispiel (Martin *et al.* 1998, Bochow 2005, Clark *et al.* 2005) für Waldgebiete bzw. Baumarten, (Schmidt & Skidmore 2003, Rosso *et al.* 2005) für küstennahe Feuchtgebiete oder (Lewis *et al.* 2001) für Vegetation in ariden Klimaten. Neben diesen spektralen Untersuchungen lassen sich vor allem die Nutzungstypen auch aufgrund ihrer räumlichen Struktur identifizieren. Hierfür eignen sich sehr hoch auflösenden Fernerkundungsdaten im Submeterbereich wie z.B. Quickbird oder Ikonos (z.B. Li *et al.* 2006, Zhang *et al.* 2007, Zhang & Fan 2007, Ouma & Tateishi 2008).
- Mischbiotope: In Kapitel 7.3.2 wurde das Verhalten des ML-basierten Klassifizierers bei räumlichen und thematischen Mischbiotopen untersucht. Es konnte aufgezeigt werden, dass der größte Forschungsbedarf bei der Ablehnung von Flächen besteht, die räumlich in mehrere Biotope aufgeteilt werden müssen. Die Implementierung dieser Funktion ist von besonderer Wichtigkeit im Hinblick auf einen typischen Anwendungsfall bei der Aktualisierung einer Stadtbioptypenkarte. Wenn Ackerland in Bauland umgewandelt wird oder von einer neuen Straße zerschnitten wird, so ändern sie die Grenzen der Biotope. Die Flächen der alten Biotoptypenkarte werden bei der Aktualisierung vom Biotopklassifizierer überprüft. Da diese nun mehrere Biotope enthalten, sollte der Klassifizierer sie zumindest ablehnen können. In einer weiteren Ausbaustufe sollen sie automatisch als Flächen des Typs I erkannt werden, gefolgt von der Aufteilung in einzelne Biotope inklusive deren Klassifizierung. Dies schließt eine Modifizierung des in Kapitel 7.4 beschriebenen Ablaufs der Aktualisierungskartierung mit ein, in dem ein Modul zur Flächenaufteilung bzw. Grenzfindung eingebaut werden muss.

Das vermutlich größte Hindernis auf dem Weg zu einer operationellen Anwendung der entwickelten Methode ist die Verfügbarkeit der Hyperspektraldaten. Da es derzeit nicht absehbar ist, ob und wann Hyperspektraldaten mit ausreichender räumlicher Auflösung kommerziell verfügbar sein werden, wird in Zukunft die Übertragbarkeit der Methode auf multispektrale Satellitendaten geprüft. Erste Ergebnisse mit simulierten Ikonos-Daten zeigen hier bereits vielversprechende Ergebnisse bezüglich der Biotopklassifizierung von baulich geprägten Biotopen (Bochow *et al.* 2008).

Literaturverzeichnis

- Adams J.B., M.O. Smith & A.R. Gillespie (1993): Imaging spectroscopy: Interpretation based on spectral mixture analysis. In: Pieters C.M. & P. Englert (eds.): *Remote geochemical analysis: Elemental and mineralogical composition*, Cambridge Univ. Press, New York, pp. 145-166.
- Aha D.W. & R.L. Bankert (1996): A comparative evaluation of sequential feature selection algorithms. In: Fisher D. & H.J. Lenz (eds.): *Learning from data. Artificial intelligence and statistics V*, Lecture notes in statistics, Springer, Berlin, pp. 199-206.
- Albertz J. (1991): *Grundlagen der Interpretation von Luft- und Satellitenbildern - Eine Einführung in die Fernerkundung*. Wissenschaftliche Buchgesellschaft, Darmstadt, 204 p.
- Arlt G. & I. Lehmann (2005): Ökologische Flächenleistungen - Methodische Grundlagen, Analyse und Bewertung teilstädtischer Gebiete in Dresden. *IÖR-Texte*, 147.
- Arlt G., J. Hennersdorf, I. Lehmann, W. Socher & N. Xuan Thinh (2003): Basisindikator Vegetationsvolumen. *Stadtforschung und Statistik*, 2/03: 38-45.
- Bartelme N. (1995): *Geoinformatik. Modelle, Strukturen, Funktionen*. Springer Verlag, Berlin, 415 p.
- Bateson A. & B. Curtiss (1996): A method for manual endmember selection and spectral unmixing. *Remote Sensing of Environment*, 55(3): 299-243.
- Bateson A., G.P. Asner & C.A. Wessman (2000): Endmember bundles: A new approach to incorporating endmember variability into spectral mixture analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 38(2): 1083-1094.
- Baumgärtel S.: *Dresden Lexikon*. Website, letzter Zugriff: 04.03.2008, <http://www.dresden-lexikon.de/Lexikon/W.htm#Wuerfelhaeuser>.
- Ben-Dor E. (2002): Quantitative remote sensing of soil properties. *Advances in Agronomy*, 75: 173-243.
- Ben-Dor E. & A. Banin (1990): Near-infrared reflectance analysis of carbonate concentration in soils. *Applied Spectroscopy*, 44(6): 1064-1069.
- Ben-Dor E., N. Levin & H. Saaroni (1998): Utilization of imaging spectroscopy in urban areas: A case study over Tel-Aviv, Israel using the CASI sensor. In: *Proc. of the 1st EARSeL Workshop on Imaging Spectroscopy*, Zürich, pp. 473-479.
- Ben-Dor E., N. Levin, A. Singer, A. Karnieli, O. Braun & G.J. Kidron (2006): Quantitative mapping of the soil rubification process on sand dunes using an airborne hyperspectral sensor. *Geoderma*, 131(1-2): 1-21.
- Berlekamp L.-R. & N. Pranzas (1986): Methoden zur Erfassung der Bodenversiegelung von städtischen Wohngebieten. Ein Beitrag zum Hamburger Landschaftsprogramm. *Natur und Landschaft*, 61(3): 92-95.
- Berman M. (2004): *A new endmember estimation algorithm*. CSIRO-CMIS, Website, letztes Update: 30.09.2004, letzter Zugriff: 16.01.2008, www.cmis.csiro.au/IAP/RecentProjects/hyspec_eg.htm.
- Berman M., H. Kiiveri, R. Lagerstrom, A. Ernst, R. Dunne & J.F. Huntington (2004): ICE: A statistical approach to identifying endmembers in hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 42(10): 2085-2095.
- Bhaskar S. & B. Datt (2000): Sub-pixel analysis of urban surface materials. A case study of Perth, W. Australia. In: *Proc. of the International Geoscience and Remote Sensing Symposium, IGARSS 2000*, Vol. 4, pp. 1535-1537.
- Blume H.-P. (2004): *Handbuch des Bodenschutzes*. 3. Aufl., ecomed Verlagsgesellschaft, Landsberg am Lech, 916 p.

-
- Boardman J.W. (1993): Automating spectral unmixing of AVIRIS data using convex geometry concepts. In: *Proc. of the 4th Annual JPL Airborne Geoscience Workshop*, Vol. JPL Publication 93-26, Pasadena, CA, USA.
- Boardman J.W., F.A. Kruse & R.O. Green (1995): Mapping target signatures via partial unmixing of AVIRIS data. In: *Proc. of the 5th Annual JPL Airborne Earth Science Workshop*, Vol. 1, Pasadena, CA, USA, pp. 23-26.
- Bochow M. (2005): Improving class separability - a comparative study of transformation methods for the hyperspectral feature space. In: Zagajewski B. & M. Sobczak (eds.): *Proc. of the 4th Workshop on Imaging Spectroscopy "Imaging Spectroscopy – New Quality in Environmental Studies"*, Warsaw, Poland, pp. 497-507.
- Bochow M., K. Segl & H. Kaufmann (2008): Comparison of multi- and hyperspectral remote sensing data for use in comprehensive urban biotope mapping. In: *Proc. of the International Geoscience and Remote Sensing Symposium, IGARSS 2008*, July 6-11, 2008, Boston, Massachusetts, USA, pp. V 5-8.
- Böhme S. (1986): Zum Zusammenhang von Oberflächenversiegelung und Vegetationsvolumen städtischer Teilgebiete - dargestellt am Beispiel der Stadt Erfurt. *Landschaftsarchitektur*, 15(2): 38-40.
- Bonsignore R. (2003): *Urban green space: effects on water and climate*. Design Brief, No. 3, Metropolitan Design Center, University of Minnesota, electronic article, letztes Update: 08/2003, letzter Zugriff: 05.04.2009, http://www.designcenter.umn.edu/reference_ctr/publications/pdfs/db3.pdf.
- Bothe H.-H. (1995): *Fuzzy Logic. Einführung in Theorie und Anwendungen*. 2., erw. Aufl., Springer, Berlin, 255 p.
- (1998): *Neuro-Fuzzy-Methoden: Einführung in Theorie und Anwendungen*. Springer, 305 p.
- Bötticher M. & R. Fisch (1988): Zur Einführung des Biotopflächenfaktors (BFF) in die Landschafts- und Bauleitplanung. *Das Gartenamt*, 37: 26-30.
- Bowles J., P.J. Palmadesso, J.A. Antoniadis, M.M. Baumback & L.J. Rickard (1995): Use of filter vectors in hyperspectral data analysis. In: Scholl M.S. & B.F. Andresen (eds.): *Proc. of the SPIE Conference: Infrared Spaceborne Remote Sensing III*, Vol. 2553, pp. 148-157.
- Bowles J.H. & D.B. Gillis (2007): An optical real-time adaptive spectral identification system (ORASIS). In: Chang C.-I. (ed.): *Hyperspectral data exploitation. Theory and applications*, John Wiley & Sons, New Jersey, pp. 77-106.
- Brenneisen S. (1997): Der KÖH-Wert heute - Plädoyer für eine integrative Methode in der stadtökologischen Bewertung. *Die Erde*, 128: 89-103.
- (2008): Anwendung eines Modells zu stadtklimatischen Wirkungen von Dachbegrünungen. In: *Proc. of the 6. Internationales FBB-Gründachsymposium 2008 -Vortragsreihe zu aktuellen Themen der Dachbegrünung*, 14. Feb. 2008, Ditzingen, pp. 33-39.
- Bucher T. & F. Lehmann (2000): Fusion of HyMap hyperspectral with HRSC-A multispectral and DEM data for geoscientific and environmental applications. In: *Proc. of the International Geoscience and Remote Sensing Symposium, IGARSS 2000*, Vol. 7, pp. 3234-3236.
- Bundesamt für Naturschutz (2002): Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Standard-Biotoptypen und Nutzungstypen für die CIR-Luftbildgestützte Biotoptypen- und Nutzungstypenkartierung für die Bundesrepublik Deutschland. *Schriftenreihe für Landschaftspflege und Naturschutz*, 73.
- Campbell J.B. (1996): *Introduction to remote sensing*. 2nd ed., The Guilford Press, New York.
- Chiesura A. (2004): The role of urban parks for the sustainable city. *Landscape and Urban Planning*, 68: 129-138.

-
- Clark M.L., D.A. Roberts & D.B. Clark (2005): Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sensing of Environment*, 96(3-4): 375-398.
- Clark R.N. (1999): Spectroscopy of rocks and minerals, and principles of spectroscopy. In: Rencz A.N. (ed.): *Manual of remote sensing*, John Wiley and Sons, New York, pp. 3-58.
- Clark R.N., A.J. Gallagher & G.A. Swayze (1990): Material absorption band depth mapping of imaging spectrometer data using a complete band shape least-squares fit with library reference spectra. In: *Proc. of the 2nd AVIRIS Earth Science Workshop*, Vol. 90-45, Pasadena, pp. 176-186.
- Cocks T., R. Jensen, A. Stewart, I. Wilson & T. Shields (1998): The HyMap airborne hyperspectral sensor: the system, calibration and performance. In: *Proc. of the 1st EARSeL Workshop on Imaging Spectroscopy*, Zürich.
- Congalton R.G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37: 35-46.
- Craig M.D. (1994): Minimum Volume Transforms for Remotely Sensed Data. *IEEE Transactions on Geoscience and Remote Sensing*, 32: 542-552.
- Craig S.E., S.E. Lohrenz, Z. Lee, K.L. Mahoney, G.J. Kirkpatrick, O.M. Schofield & R.G. Steward (2006): Use of hyperspectral remote sensing reflectance for detection and assessment of the harmful alga, *Karenia brevis*. *Applied Optics*, 45(21): 5414-5425.
- Demicco R.V. & G.J. Klir (2004): *Fuzzy logic in geology*. Elsevier, San Diego.
- Dennison P.E. & D.A. Roberts (2003): Endmember selection for multiple endmember spectral mixture analysis using endmember average RMSE. *Remote Sensing of Environment*, 87: 123-135.
- Donnay J.P., M.J. Barnsley & P.A. Longley (2001): *Remote sensing and urban analysis*. Taylor and Francis, London, 268 p.
- Drachenfels O.v. (2004): *Kartierschlüssel für Biotoptypen in Niedersachsen unter besonderer Berücksichtigung der nach § 28a und § 28b NNatG geschützten Biotope sowie der Lebensraumtypen von Anhang I der FFH-Richtlinie*. 6. Aufl., Naturschutz Landschaftspfl. Nieders., Vol. A/4, Niedersächsisches Landesamt für Ökologie, Hildesheim, 240 p.
- Duch W. (2006): Filter methods. In: Guyon I., S. Gunn, M. Nikravesh & L.A. Zadeh (eds.): *Feature Extraction - Foundations and Applications*, Studies in Fuzziness and Soft Computing, Springer, pp. 89-117.
- Ehlers M., J. Schiewe & M. Möller (2002): Ultra high resolution remote sensing for urban information systems and 3D city modeling. In: Anson M., J.M. Ko & E.S.S. Lam (eds.): *Proc. of the Int. Conf. on Advances in Building Technology*, Vol. 2, Amsterdam, pp. 1619-1627.
- Fitter R.S.R. (1946): *London's natural history*. reprint of 1st ed., The New Naturalist, Vol. 3, Collins, London, 282 p.
- Förster S. (2002): *Ableitung und Analyse stadtoökologisch relevanter Parameter auf der Basis von hyperspektralen Flugzeugscannerdaten am Beispiel der Stadt Potsdam*. Diplomarbeit, Institut für Geoökologie, Universität Potsdam, Potsdam, 106 p.
- Fraser C.S., E. Baltsavias & A. Gruen (2002): Processing of Ikonos imagery for submetre 3D positioning and building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56(3): 177.
- Freeman H. (1961): On the encoding of arbitrary geometric configurations. *IRE Trans. on Electr. Comp. or TC*, 10(2): 260-268.
- (1974): Computer processing of line drawing images. *ACM Computing Surveys*, 6: 57-97.
- Gamba P. & B. Houshmand (2001): Integration of hyperspectral and IFSAR data for improved 3D urban profile reconstruction. *Photogrammetric Engineering & Remote Sensing*, 67(8): 947-956.

-
- Gao B.-C. & A.F.H. Goetz (1990): Column atmospheric water vapor and vegetation liquid water retrievals from airborne imaging spectrometer data. *Journal of Geophysical Research*, 95(D4): 3549–3564.
- Gibson P.J. (2000): *Introductory remote sensing. Principles and concepts*. Routledge, London, 184 p.
- Gill D. & P. Bonnett (1973): *Nature in the urban landscape: A study of city ecosystems*. York Press, Baltimore.
- Glawion R. & H.-J. Klink (1999): Vegetation. In: Zepp H. & M.J. Müller (eds.): *Landschafts-ökologische Erfassungsstandards*, Forschungen zur deutschen Landeskunde, Band 244, Deutsche Akademie für Landeskunde, Flensburg, pp. 211-234.
- Greiwe A. (2006): *Detektion von Referenzspektren in multisensoralen Bilddaten*. Dissertation, Fachbereich Mathematik/Informatik, Universität Osnabrück, Osnabrück, 187 p., http://deposit.d-nb.de/cgi-bin/dokserv?idn=980110319&dok_var=d1&dok_ext=pdf&filename=980110319.pdf.
- Guyon I. (2005): *Lecture 8: Wrappers*. PPT-Slides for the feature extraction course, winter semester 2005/2006, at ETH Zürich, letzter Zugriff: 31.03.2009, <http://clopinet.com/isabelle/Projects/ETH/lecture8.pdf>.
- Guyon I. & A. Elisseeff (2006): An introduction to feature extraction. In: Guyon I., S. Gunn, M. Nikravesh & L.A. Zadeh (eds.): *Feature Extraction - Foundations and Applications*, Studies in Fuzziness and Soft Computing, Springer, pp. 1-26.
- Haala N. & K.H. Anders (1997): Acquisition of 3D urban models by analysis of aerial images, digital surface models and existing 2D building information. In: *Proc. of the SPIE Conference*, Vol. 3072, 21-23 April 1997, Orlando, FL, pp. 212-222.
- Han J., Y. Hayashi, X. Cao & H. Imura (2009): Application of an integrated system dynamics and cellular automata model for urban growth assessment: A case study of Shanghai, China. *Landscape and Urban Planning*, in press, corrected proof (doi:10.1016/j.landurbplan.2008.12.002).
- Hard G. (1985): Vegetationsgeographie und Sozialökologie einer Stadt. Ein Vergleich zweier "Stadtpläne" am Beispiel von Osnabrück. *Geographische Zeitschrift*, 73: 125-144.
- Heber B. & I. Lehmann (1996): *Beschreibung und Bewertung der Bodenversiegelung in Städten*. IÖR-Schriften, Vol. 15, Leibnitz-Institut für ökologische Raumentwicklung (IÖR), Dresden.
- Heiden U. (2004): *Analyse hyperspektraler Flugzeugscannerdaten zur ökologischen Charakterisierung städtischer Biotope*. Dissertation, Fakultät VII - Architektur Umwelt Gesellschaft, TU Berlin, Berlin, 136 p.
- Heiden U., K. Segl, S. Roessner & H. Kaufmann (2007): Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment*, 111(4): 537-552.
- Heim B., H. Oberhaensli, S. Fietz & H. Kaufmann (2005): Variation in Lake Baikal's phytoplankton distribution and fluvial input assessed by SeaWiFS satellite data. *Global and Planetary Change*, 46(1): 9-27.
- Herold M., M.E. Gardner & D.A. Roberts (2003): Spectral resolution requirements for mapping urban areas. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9): 1907-1919.
- Holland D.A., D.S. Boyd & P. Marshall (2006): Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60(3): 212.
- Hughes G.F. (1968): On the mean accuracy of statistical pattern recognizes. *IEEE Transactions on Information Theory*, 14(1): 55-63.
- Imhoff K. & K.R. Imhoff (2006): *Taschenbuch der Stadtentwässerung*. 30. verb. Aufl., Oldenbourg Industrieverlag, 508 p.

-
- Jarvis R.A. (1973): On the identification of the convex hull of a finite set of points in the plane. *Information Processing Letters*, 2: 18-22.
- Jat M.K., P.K. Garg & D. Khare (2008): Monitoring and modelling of urban sprawl using remote sensing and GIS techniques. *International Journal of Applied Earth Observation and Geoinformation*, 10(1): 26-43.
- Jensen J.R. (2007): *Remote sensing of the environment: an earth resource perspective*. 2, Prentice Hall series in geographic information science, Pearson Prentice Hall, Upper Saddle River, NJ, 592 p.
- Jensen R.R., J.D. Gatrell & D.D. McLean (2007): *Geo-spatial technologies in urban environments: policy, practice and pixels*. 2, Springer, Berlin; New York, 240 p.
- Jensen R.R., J.D. Gatrell & D. McLean (eds.) (2005): *Geo-spatial technologies in urban environments*. Springer, Berlin; London, 176 p.
- Jovet P. (1954): Paris, sa flore spontanée, sa végétation. In, Notices botaniques et itinéraires commentés publiés a l'occasion du Ville congrès International de Botanique Paris-Nice, pp. 21-60.
- Kahl W. & A. Voßkuhle (1998): *Grundkurs Umweltrecht: Einführung für Naturwissenschaftler und Ökonomen*. 2 Aufl., Spektrum Akademischer Verlag, Heidelberg, Berlin.
- Kecman V. (2001): *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models*. The MIT Press, 608 p.
- Kirkpatrick G.J., C. Orrico, M.A. Moline, M. Oliver & O.M. Schofield (2003): Continuous hyperspectral absorption measurements of colored dissolved organic material in aquatic systems. *Applied optics*, 42(33): 6564-6568.
- Knickrehm B. & S. Rommel (1995): Biotoptypenkartierung in der Landschaftsplanung. *Natur und Landschaft*, 70(11): 519-528.
- Kohavi R. & G.H. John (1997): Wrappers for feature subset selection. *Artificial Intelligence*, 97(1-2): 273-324.
- Kowarik I. (1988): *Zum menschlichen Einfluss auf Flora und Vegetation. Theoretische Konzepte und ein Quantifizierungsansatz am Beispiel von Berlin (West)*. Landschaftsentwicklung und Umweltforschung. Schriftenreihe des FB 14 der TU Berlin, Vol. 56, Berlin, 241 p.
- Kraus K. & N. Pfeifer (2001): Advanced DTM generation from LIDAR data. In: *Proc. of the WGIII/3-6 Workshop "Land surface mapping and characterization using laser altimetry"*, International Archives of Photogrammetry and Remote Sensing, Vol. XXXIV-3/W4, 24.10.2001, Annapolis, Maryland, pp. 23-30.
- Krause K.-H. (1989): Zur Erfassung der Oberflächenarten für eine stadtoökologische Zustandsbeschreibung. *Hallesches Jahrbuch für Geowissenschaften*, 14: 124-130.
- Kühnelt W. (1955): Gesichtspunkte zur Beurteilung von Großstadtfauna (mit besonderer Berücksichtigung der Wiener Verhältnisse). *Österr. Zool. Z.*, 6: 30-54.
- Kunick W. (1974): *Veränderungen von Flora und Vegetation einer Großstadt; dargestellt am Beispiel von Berlin (West)*. Dissertation, Fachbereich Landschaftsbau, TU Berlin, Berlin, 457 p.
- (1982): *Zonierung des Stadtgebietes von Berlin West - Ergebnisse floristischer Untersuchungen*. Landschaftsentwicklung und Umweltforschung. Schriftenreihe des FB 14 der TU Berlin, Berlin, 164 p.
- Lal T.N., O. Chapelle, J. Weston & A. Elisseeff (2006): Embedded methods. In: Guyon I., S. Gunn, M. Nikravesh & L.A. Zadeh (eds.): *Feature Extraction - Foundations and Applications*, Studies in Fuzziness and Soft Computing, Springer, pp. 139-167.
- Leeuwen E.S.v., R. Vreeker & C.A. Rodenburg (2006): A framework for quality of life assessment of urban green areas in Europe: an application to District Park Reudnitz Leipzig. *International Journal of Environmental Technology and Management*, 6(1/2): 111-122.

-
- Lewis M., V. Jooste & A.A. De Gasparis (2001): Discrimination of arid vegetation with airborne multispectral scanner hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7): 1471-1479.
- Lewis M.M. (2001): Discriminating vegetation with hyperspectral imagery - What is possible? In: *Proc. of the International Geoscience and Remote Sensing Symposium, IGARSS 2001*, Vol. 6, pp. 2899-2901.
- Li L., W.Q. Zhang, B.F. Wu & J. Xiong (2006): Urban Vegetation Estimation Derived from QuickBird Based on Object-oriented Method. In: *Proc. of the International Geoscience and Remote Sensing Symposium, IGARSS 2006*, Jul 31-Aug 04, Denver, CO, pp. 1160-1163.
- Lillesand T.M. & R.W. Kiefer (1999): *Remote sensing and image interpretation*. 4th ed., Wiley & Sons, New York, 736 p.
- Liverman D.M., E.F. Moran, R.R. Rindfuss & P.C. Stern (1998): *People and pixels: linking remote sensing and social science*. National Academy Press, Washington, D.C., 244 p.
- Lu D., M. Batistella, P. Mausel & E. Moran (2007): Mapping and monitoring land degradation risks in the western Brazilian amazon using multitemporal Landsat TM/ETM+ images. *Land Degradation & Development*, 18: 41-54.
- Martin M.E., S.D. Newman, J.D. Aber & R.G. Congalton (1998): Determining forest species composition using high spectral resolution remote sensing data. *Remote Sensing of Environment*, 65(3): 249-254.
- Mayer H. (2008): Object extraction in photogrammetric computer vision. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63: 213-222.
- Mayer S. (2000): Retrieving object borders and height from high-resolution digital surface models. In: *Proc. of the World Multiconference on Systems, Cybernetics and Informatics*, Vol. 5, Orlando, FL, USA, pp. 433-438.
- Meinel G. & M. Netzband (1996): Erarbeitung von Übersichtskarten zur Versiegelungsintensität. In: Breuste J., T. Kreidel, G. Meinel, B. Münchow, M. Netzband & M. Schramm (eds.): *Erfassung und Bewertung des Versiegelungsgrades befestigter Flächen*, UFZ-Bericht 12/1996 - Stadtökologische Forschungen Nr. 7, UFZ Leipzig-Halle, pp. V1-V60.
- Meinel G., R. Hecht & W. Socher (2006): Städtisches Grünvolumen - neuer Basisindikator für die Stadtökologie? Bestimmungsmethodik und Ergebnisbewertung. In: Schrenk M. (ed.): *Proc. of the CORP 2006 & Geomultimedia06*, 13.-16. Feb. 2006, Wien, pp. 685-694.
- Mena J.B. (2003): State of the art on automatic road extraction for GIS update: a novel classification. *Pattern Recognition Letters*, 24(16): 3037.
- Möller M. (1997): Veränderungsanalyse stadtklimatologischer Einflussfaktoren mit Hilfe multitemporaler Satellitenbilddaten. Beispiel einer Frischluftproduktionsfläche der Stadt Osnabrück. *Zeitschrift für Photogrammetrie und Fernerkundung*, 65(2): 60-67.
- Möller M. & T. Blaschke (2006): GIS-gestützte Bildanalyse der städtischen Vegetation als ein Indikator urbaner Lebensqualität. *Photogrammetrie - Fernerkundung - Geoinformation*, 1/2006: 19-30.
- Mouroulis P., R.O. Green & T.G. Chrien (2000): Design of pushbroom imaging spectrometers for optimum recovery of spectroscopic and spatial information. *Applied Optics*, 39(13): 2210-2220.
- Münich C., H. Taubenböck, L. Stempniewski, S. Dech & A. Roth (2006): Remote sensing and engineering: An interdisciplinary approach to assess vulnerability in urban areas. In: *Proc. of the 1st European Conference on Earthquake Engineering and Seismology (ECEES)*, 09.03.2006 - 09.08.2006, Geneva, Switzerland.
- Netzband M., W.L. Stefanov & C.L. Redman (2007a): Remote sensing as a tool for urban planning and sustainability. In: Netzband M., W.L. Stefanov & C.L. Redman (eds.): *Applied remote sensing for urban planning, governance and sustainability*, Springer, Berlin, Heidelberg, pp. 1-23.

-
- (eds.) (2007b): *Applied remote sensing for urban planning, governance and sustainability*. Springer, Berlin, Heidelberg, 278 p.
- Ong B.L. (2003): Green plot ratio: an ecological measure for architecture and urban planning. *Landscape and Urban Planning*, 63(4): 197-211.
- Ouma Y.O. & R. Tateishi (2008): Urban-trees extraction from Quickbird imagery using multiscale spectex-filtering and non-parametric classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(3): 333-351.
- Peisker T. (2006): *Klassifizierung von Stadtbiootypen mit wissensbasierten Fuzzy-Logik-Modellen basierend auf hyperspektralen Flugzeugscannerdaten*. Diplomarbeit, Institut für Kartographie, TU Dresden, Dresden, 80 p.
- Pfeifer N. (2004): Oberflächenmodelle aus Laserdaten. *VGI, Österreichische Zeitschrift für Vermessung & Geoinformation*, 91(4): 243-252.
- Philip G.M. & D.F. Watson (1982): A precise method for determining contoured surfaces. *Australian Petroleum Exploration Association Journal*, 22: 205-212.
- Plaza A., P. Martinez, R. Perez & J. Plaza (2002): Spatial/spectral endmember extraction by multidimensional morphological operations. *IEEE Transactions on Geoscience and Remote Sensing*, 40(9): 2025-2041.
- Pohl W. (1991): Werte für die Landschafts- und Bauleitplanung. Bodenfunktionszahl - Grünvolumenzahl. *NNA-Mitteilungen*, 4/91: 2-6.
- Pott R. (1996): *Biootypen: schützenswerte Lebensräume Deutschlands und angrenzender Regionen*. Ulmer Verlag, Stuttgart (Hohenheim), 448 p.
- Powell R.L., D.A. Roberts, P.E. Dennison & L.L. Hess (2006): Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil. *Remote Sensing of Environment*, 106: 253-267.
- Pudil P., J. Novovicova & J. Kittler (1994): Floating search methods in feature selection. *Pattern Recognition Letters*, 15(11): 1119-1125.
- Rashed T. & C. Jürgens (eds.) (2009): *Remote sensing of urban and suburban areas*. Remote Sensing and Digital Image Processing, Vol. 10, Springer, Berlin.
- Rees W.G. (2001): *Physical principles of remote sensing*. 2nd ed., Cambridge University Press, Cambridge, 372 p.
- Reunanen J. (2006): Search Strategies. In: Guyon I., S. Gunn, M. Nikravesh & L.A. Zadeh (eds.): *Feature Extraction - Foundations and Applications*, Studies in Fuzziness and Soft Computing, Springer, Berlin, pp. 119-137.
- Richards J.A. & X. Jia (1999): *Remote sensing digital image analysis: an introduction*. 3rd, revised and enlarged, Springer, Berlin, 363 p.
- Richter N., T. Jarmer, S. Chabrillat, H. Kaufmann & P. Hostert (2008): Free iron oxide determination in Mediterranean soils using diffuse reflective spectroscopy. *Soil Science Society of America Journal*, (in review).
- Roberts D.A., M.E. Gardner, R. Church, S.L. Ustin, G. Scheer & R.O. Green (1998): Mapping chaparral in the Santa Monica Mountains using multiple endmember spectral mixture analysis. *Remote Sensing of Environment*, 65: 267-279.
- Roberts D.A., I. Numata, K. Holmes, G. Batista, T. Krug, A. Monteiro, B. Powel & O.A. Chadwick (2002): Large area mapping of land-cover change in Rondônia using multitemporal spectral mixture analysis and decision tree classifiers. *Journal of Geophysical Research*, 107(D20): LBA 40-41 - LBA 40-48.
- Roessner S., K. Segl, U. Heiden & Kaufmann (2001): Automated differentiation of urban surface based on airborne hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7): 1523-1532.

-
- Rogge D.M., B. Rivard, J. Zhang, A. Sanchez, J. Harris & J. Feng (2007): Integration of spatial-spectral information for the improved extraction of endmembers. *Remote Sensing of Environment*, 110(3): 287-303.
- Rose H. (1991): *Der KÖP-Wert in der ökologisch orientierten Stadtplanung*. Mannheimer Geographische Arbeiten, Vol. 33, Mannheim.
- Rosso P.H., S.L. Ustin & A. Hastings (2005): Mapping marshland vegetation of San Francisco Bay, California, using hyperspectral data. *International Journal of Remote Sensing*, 26(23): 5169-5191.
- Sabins F.F. (1997): *Remote sensing: Principles and interpretation*. 3 ed., Freeman Press, San Francisco, 494 p.
- Sandtner M. (1998): Die Erfassung von städtischen Oberflächen mittels EDV-gestützter Luftbildauswertung. *Geographica Helvetica*, 2: 69-76.
- Schiewe J. (2001): Ein regionen-basiertes Verfahren zur Extraktion der Geländeoberfläche aus digitalen Oberflächen-Modellen. *Photogrammetrie - Fernerkundung - Geoinformation*, 2/2001: 81-90.
- Schläpfer D., C.C. Borel, J. Keller & K.I. Itten (1998): Atmospheric precorrected differential absorption technique to retrieve columnar water vapor. *Remote Sensing of Environment*, 65: 353-366.
- Schmidt K.S. & A.K. Skidmore (2003): Spectral discrimination of vegetation types in a coastal wetland. *Remote Sensing of Environment*, 85(1): 92-108.
- Scholten F., S. Sujew, F. Wewel, J. Flohrer, R. Jaumann, F. Lehmann, R. Pischel & G. Neukum (1999): The high resolution stereo camera (HRSC) - digital 3D-image acquisition, photogrammetric processing and data evaluation. In: *Proc. of the ISPRS Joint Workshop "Sensors and Mapping from Space"*, Vol. 18, 27.09. - 30.09.1999, Hannover.
- Schowengerdt R.A. (1997): *Remote Sensing. Models and methods for image processing*. 2nd, rev. and ext. ed., Academic Press, London, 525 p.
- Schramm E. (1985): Theoretische und ökologehistorische Bemerkungen zum Ökosystem- und Biotopbegriff. *Natur und Landschaft*, 60(3): 112-114.
- Schroeder H.W. (1989): Environment, behavior, and design reseach on urban forests. In: Zube E.H. & G.T. Moore (eds.): *Advances in environment, behavior, and design*, Plenum Press, New York, pp. 87-117.
- Schulte W. & H. Sukopp (2000): Stadt- und Dorfbiotopkartierungen. Erfassung und Analyse ökologischer Grundlagen im besiedelten Bereich der Bundesrepublik Deutschland - ein Überblick. *Naturschutz und Landschaftsplanung*, 32(5): 140-147.
- Schulte W., H. Sukopp, P. Werner & Arbeitsgruppe "Methodik der Biotopkartierung im besiedelten Bereich" (1993): Flächendeckende Biotopkartierung im besiedelten Bereich als Grundlage einer am Naturschutz orientierten Planung. *Natur und Landschaft*, 68(10): 491-526.
- Schulte W., H. Sukopp, V. Voggenreiter, P. Werner & Arbeitsgruppe "Methodik der Biotopkartierung im besiedelten Bereich" (1986): Flächendeckende Biotopkartierung im besiedelten Bereich als Grundlage einer ökologisch bzw. am Naturschutz orientierten Planung. *Natur und Landschaft*, 61(10): 371-389.
- Schulz A. (1982): Der KÖH-Wert, Modell einer komplexen, planungsrelevanten Zustandserfassung. *Informationen zur Raumentwicklung*, 10: 847-863.
- Schweiger H. (1962): Die Insektenfauna des Wiener Stadtgebietes als Beispiel einer kontinentalen Großstadtfauna. In: *Proc. of the Verh. 11. Intern. Kongr. Entomologie*, Vol. 3, pp. 184-193.
- Schwenk H. (2002): *Lexikon der Berliner Stadtentwicklung*. Haude & Spener, Wissenschaftsverlag Volker Spiess GmbH, Berlin, 390 p.

-
- Segl K. (1996): *Integration von Form- und Spektralmerkmalen durch künstliche neuronale Netze bei der Satellitenbildklassifizierung*. Doktorarbeit, Fakultät für Bauingenieur- und Vermessungswesen, Universität Fredericiana zu Karlsruhe (TH), Karlsruhe, 78 p.
- Segl K., S. Roessner, U. Heiden & H. Kaufmann (2003): Fusion of spectral and shape features for identification of urban surface cover types using reflective and thermal hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(1-2): 99-112.
- Segl K., M. Bochow, S. Roessner, H. Kaufmann & U. Heiden (2006): Feature-based identification of urban endmember spectra using hyperspectral HyMap data. In: Hostert P., S. Schiefer & A. Damm (eds.): *Proc. of the 1st Workshop of the EARSeL Special Interest Group Urban Remote Sensing*, Berlin.
- Senatsverwaltung für Stadtentwicklung - Referat Landschaftsplanung und Naturschutz I E & Landesbeauftragter für Naturschutz und Landschaftspflege (2005): *Biotopkartierung Berlin - Grundlagen - Standards - Bewertung*. 2. veränderte Auflage, Version 2.1, (Juni 2005).
- Siedlecki W. & J. Sklanski (1988): On automatic feature selection. *International Journal of Pattern Recognition and Artificial Intelligence*, 2(2): 197-220.
- Singer R.B. (1981): Near-infrared spectral reflectance of minerals: systematic combinations of pyroxenes, olivine, and iron oxides. *Journal of Geophysical Research*, 86(B9): 7967-7982.
- Small C. (2001): Multiresolution analysis of urban reflectance. In: *Proc. of the IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*, Rome, Italy.
- Smith M.O., S.L. Ustin, J.B. Adams & A.R. Gillespie (1990): Vegetation in deserts: I. A regional measure of abundance for multispectral images. *Remote Sensing of Environment*, 31: 1-26.
- Smits P.C., S.G. Dellepiane & R.A. Schowengerdt (1999): Quality assessment of image classification algorithms for land-cover mapping: a review and a proposal for a cost-based approach. *International Journal of Remote Sensing*, 20(8): 1461-1486.
- Sohn G. & I. Dowman (2007): Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62(1): 43.
- Somol P. & P. Pudil (2000): Oscillating search algorithms for feature selection. In: *Proc. of the 15th Int. Conf. on Pattern Recognition*, Barcelona, Spain, pp. 406-409.
- Song C.H. (2005): Spectral mixture analysis for subpixel vegetation fractions in the urban environment: How to incorporate endmember variability? *Remote Sensing of Environment*, 95(2): 248-263.
- Sperber H. & H.H. Meyer (1989): Vorstellung eines Schemas zur Erfassung und Bewertung der Ver- und Entsiegelungsintensität in Siedlungsbereichen. *Das Gartenamt*, 38.
- Szymank A., U. Riecken & U. Ries (1993): Das Problem des Bezugssystems für eine Rote Liste Biotope. *Schriftenreihe für Landschaftspflege und Naturschutz*, 38: 47-58.
- Staenz K., T. Szeredi & J. Schwarz (1998): ISDAS - A system for processing/analysing hyperspectral data. *Canadian Journal of Remote Sensing*, 24: 99-113.
- Statistisches Bundesamt (2005): Rund 15% der Bevölkerung Deutschlands leben auf dem Land. Pressemitteilung, No. 237, Wiesbaden.
- (2006): *Datenreport 2006. Zahlen und Fakten über die Bundesrepublik Deutschland*. Vol. 544, Bundeszentrale für politische Bildung (Hrsg.), 678 p.
- Stein A., F.D. van der Meer & B. Gorte (1999): *Spatial statistics for remote sensing*. Remote sensing and digital image processing, Vol. 1, Kluwer Academic Publishers, 325 p.
- Sudhira H.S., T.V. Ramachandra & K.S. Jagadish (2004): Urban sprawl: metrics, dynamics and modelling using GIS. *International Journal of Applied Earth Observation and Geoinformation*, 5(1): 29-39.
- Sukopp H. (1973): Die Großstadt als Gegenstand ökologischer Forschung. *Schr. Ver. Verbreitung naturwiss. Kenntnisse in Wien*, 113: 90-140.

-
- (1987): Stadtökologische Forschung und deren Anwendung in Europa. *Düsseldorfer Geobotanisches Kolloquium*, 4: 3-28.
- (2008): Mündliche Mitteilung auf der Konferenz Urbio2008 in Erfurt. Erfurt, 20.05.2008.
- Sukopp H. & S. Weiler (1988): Biotope Mapping and Nature Conservation Strategies in Urban Areas of the Federal Republic of Germany. *Landscape and Urban Planning*, 15: 39-58.
- Sukopp H. & R. Wittig (1998): *Stadtökologie*. 2 Aufl., Gustav Fischer Verlag, Stuttgart, 474 p.
- Sukopp H., W. Kunick & C. Schneider (1979): Biotopkartierung in der Stadt. *Natur und Landschaft*, 54(3): 66-68.
- Taubenböck H., T. Esch & A. Roth (2006): An urban classification approach based on an object-oriented analysis of high resolution satellite imagery for a spatial structuring of urban areas. In: *Proc. of the 1st Workshop of the EARSeL Special Interest Group Urban Remote Sensing*, Berlin, Germany.
- Taubenböck H., A. Roth & S. Dech (2007): Linking structural urban characteristics derived from high resolution satellite data to population distribution. In: Coors V., M. Rumor, E. Fendel & S. Zlatanova (eds.): *Urban and Regional Data Management*, Taylor and Francis Group, London, pp. 35 - 45.
- Taubenböck H., M. Wegmann, A. Roth, H. Mehl & S. Dech (2009): Urbanization in India - Spatiotemporal analysis using remote sensing data. *Computers, Environment and Urban Systems*, in press, corrected proof (doi:10.1016/j.compenvurbsys.2008.09.003).
- Taubenböck H., J. Post, A. Roth, K. Zosseder, G. Strunz & S. Dech (2008): A conceptual vulnerability and risk framework as outline to identify capabilities of remote sensing. *Natural Hazards and Earth System Sciences*, 8: 409 - 420.
- The MathWorks (2006): *Fuzzy logic toolbox. User's guide*. 2nd.
- Tischler W. (1984): *Einführung in die Ökologie*. 3. Aufl., Stuttgart, New York.
- Tomowski D., M. Ehlers, U. Michel & G. Bohmann (2006): Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten. *gi-reports@igf*, 3.
- Tompkins S., J.F. Mustard, C.M. Pieters & D.W. Forsyth (1997): Optimization of endmembers for spectral mixture analysis. *Remote Sensing of Environment*, 59(3): 472-489.
- TopScan GmbH (2003): Projektbericht bezüglich der Laserscannermessung Dresden im Auftrag der Landeshauptstadt Dresden - städtisches Vermessungsamt -. Projektbericht, TopScan - Gesellschaft zur Erfassung topographischer Information mbH, 8 p.
- Ulrich R.S. (1986): Human responses to vegetation and landscape. *Landscape and Urban Planning*, 13: 29-44.
- Umweltamt Dresden (2003): Biotoptypenschlüssel/Datenstruktur Stadtbiotopkartierung Dresden - Stand 06/2003. Umweltamt Dresden, Naturschutzbehörde.
- van der Meer F.D. & S.M. de Jong (2001): *Imaging spectrometry - Basic principles and prospective applications*. Kluwer Academic Publishers, 403 p.
- Voogt J.A. & T.R. Oke (2003): Thermal remote sensing of urban climates. *Remote Sensing of Environment*, 86(3): 370-384.
- Vosselman G. & H.-G. Maas (2001): Adjustment and filtering of raw laser altimetry data. In: *Proc. of the OEEPE Workshop on Airborne Laser Scanning and Interferometric SAR for Detailed Digital Elevation Models*, 01.-03.03.2001, Stockholm.
- Wächter M. (2003): *Die Stadt: umweltbelastendes System oder wertvoller Lebensraum? Zur Geschichte, Theorie und Praxis stadtökologischer Forschungen in Deutschland*. Dissertation, Fakultät VII - Architektur, Umwelt, Gesellschaft, TU Berlin, Berlin, 200 p.
- Wania A. & C. Weber (2007): Hyperspectral imagery and urban green observation. In: *Proc. of the URBAN / URS 2007 Joint Conference*, 11.-13.04.2007, Paris, France.
- Watson D.F. & G.M. Philip (1985): A refinement of inverse distance weighted interpolation. *Geo-Processing*, 2: 315-327.

-
- Weng Q. & D.A. Quattrochi (2006): Thermal remote sensing of urban areas: An introduction to the special issue. *Remote Sensing of Environment*, 104(2): 119-122.
- (2007): *Urban remote sensing*. CRC Press, Boca Raton, Fla., 412 p.
- Weng Q. & D. Lu (2007): Subpixel analysis of urban landscapes. In: Weng Q. & D.A. Quattrochi (eds.): *Urban remote sensing*, CRC Press, Boca Raton, Fla., pp. 71-90.
- Werner P. (1993): Einige (Gedanken-)Thesen zur Situation der stadtoökologischen Forschung in Deutschland. Beitrag zur 1. Sitzung des AK-Stadtoökologie der GfÖ in Osnabrück am 12.-13. November 1993. Unveröff. Manuskript, 14 p.
- (1999): Why biotope mapping in populated areas? In: Reumer J.W.F. & M.J. Epe (eds.): *Proc. of the Conference "Biotope Mapping in the Urban Environment"*, DEINSEA, Vol. 5, pp. 9-26.
- (2008): Mündliche Mitteilung auf der Konferenz Urbio2008. Erfurt, 20.05.2008.
- Westhus W., L. Jeschke & U. Voigtländer (1990): Liste ökologisch bedeutsamer Bereiche auf dem Territorium der DDR. Bund für Natur und Umwelt beim Kulturbund, ZFA Botanik, Berlin, 16 p.
- Wewel F. & F. Scholten (2000): Erstellung von digitalen Oberflächenmodellen mit dem Mehrzeilen-Stereoscanner HRSC-A. *Photogrammetrie - Fernerkundung - Geoinformation*, 8/2000: 57-66.
- Winter M.E. (1999): N-FINDR: An algorithm for fast autonomous spectral endmember determination in hyperspectral data. In: Descour M.R. & S.S. Shen (eds.): *Proc. of the Proceedings of SPIE: Imaging Spectrometry V*, Vol. 3753, pp. 266-275.
- Wittig R., D. Diesing & M. Gödde (1985): Urbanophob - Urbanoneutral - Urbanophil. Das Verhalten der Arten gegenüber dem Lebensraum Stadt. *Flora*, 177: 265-282.
- Wu Q., H.-q. Li, R.-s. Wang, J. Paulussen, Y. He, M. Wang, B.-h. Wang & Z. Wang (2006): Monitoring and predicting land use change in Beijing using remote sensing and GIS. *Landscape and Urban Planning*, 78(4): 322-333.
- Yin Z.-Y., D.J. Stewart, S. Bullard & J.T. MacLachlan (2005): Changes in urban built-up surface and population distribution patterns during 1986-1999: A case study of Cairo, Egypt. *Computers, Environment and Urban Systems*, 29(5): 595-616.
- Zadeh L.A. (1965): Fuzzy sets. *Information and Control*, 8(3): 338-353.
- Zhang L. & A. Gruen (2006): Multi-image matching for DSM generation from IKONOS imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60(3): 195.
- Zhang X.Y., X.Z. Feng & K. Wang (2007): Integration of classifiers for improvement of vegetation category identification accuracy based on image objects. *New Zealand Journal of Agricultural Research*, 50(5): 1125-1133.
- Zhang Y.J. & H.T. Fan (2007): Identification scales for urban vegetation classification using high spatial resolution satellite data. In: *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2007*, Jul 23-27, Barcelona, Spain, pp. 1472-1475.
- Zimmermann F. (1992): Ziele, Methodik und Stand der Biotopkartierung in Brandenburg. *Naturschutz und Landschaftspflege in Brandenburg*, 1(1): 9-12.
- (1994): Biotopkartierung Brandenburg - Erfassungsstand und Umsetzung. *Naturschutz und Landschaftspflege in Brandenburg*, 3(2): 4-8.
- Zimmermann F., M. Düvel, A. Herrmann, A. Steinmeyer, M. Flade & H. Mauersberger, Landesumweltamt Brandenburg (2004): *Biotopkartierung Brandenburg. Band 1. Kartierungsanleitung und Anlagen.*, 312 p.

Abkürzungsverzeichnis und Glossar

AFIS	Amtliches Festpunktinformationssystem
AFIS-ALKIS-ATKIS	Das AFIS-ALKIS-ATKIS-Modell (kurz: AAA-Modell) wird derzeit durch eine Zusammenführung und Harmonisierung von AFIS, ALKIS und ATKIS als einheitliche Vektor-Geodatenbasis für Deutschland aufgebaut.
AG	Arbeitsgruppe
ALB	Automatisiertes Liegenschaftsbuch
ALK	Automatisierte Liegenschaftskarte
ALKIS	Amtliches Liegenschaftskatasterinformationssystem. ALKIS ist die digitale Zusammenführung von ALK und ALB.
AML	<i>Arc-Macro-Language</i>
ATCOR	<i>Atmospheric and Topographic Correction</i> . Software zur atmosphärischen Korrektur von Fernerkundungsbildern.
ATKIS	Amtliches Topographisch-Kartographisches Informationssystem
BE	Berlin
BfN	Bundesamt für Naturschutz
BNatSchG	Bundesnaturschutzgesetz
BRDF	<i>Bidirectional Reflectance Distribution Function</i> = bidirektionale Reflektanzverteilungsfunktion. Funktion für das Reflexionsverhalten einer Oberfläche in Abhängigkeit von der Beleuchtungs- und Beobachtungsgeometrie und der Wellenlänge.
CAD	<i>computer-aided design</i>
CCD	<i>Charge-coupled device</i> = lichtempfindliches Bauteil eines Sensors.
CIR-Luftbild	Color-Infrarot-Luftbilder, auch Falschfarben-Infrarot-Luftbild
DD	Dresden
DGM	Digitales Geländemodell
DGPS	<i>Differential Global Positioning System</i> = Globales Positionssystem mit Differenzialsignal
DHM	Digitales Höhenmodell
DLR	Deutsches Zentrum für Luft- und Raumfahrt e.V.
DN	<i>Digital number</i> = Wert eines Pixels eines digitalen Bilds.
DOM	Digitales Oberflächenmodell
EM	<i>Endmember</i>
FOV	<i>Field of view</i> = Sichtfeld (auch: Öffnungswinkel) eines Sensors
FWHM	<i>Full width at half maximum</i> = Halbwertsbreite. Angabe zur Breite spektraler Kanäle.
GFZ Potsdam	Helmholtz Zentrum Potsdam – GFZ deutsches GeoForschungsZentrum
GIFOV	<i>Ground Instantaneous Field of View</i>
GIS	Geographisches Informationssystem
GOK	Geländeoberkante
GPS	<i>Global Positioning System</i> = Globales Positionssystem
GSD	<i>Ground sampling distance</i>
HRSC	<i>High Resolution Stereo Camera</i> . Eine multispektrale digitale Kamera, die technisch gesehen ein Zeilenscanner ist. Zwei weitere Modelle mit veränderten Spezifikationen sind die HRSC-A und HRSC-AX.
HU	Humboldt-Universität zu Berlin

HyMap	Hyperspectral Mapper. Ein flugzeuggetragener, hyperspektraler Whiskbroom Scanner.
ICE	<i>Iterated constrained endmembers</i>
ID	Identifikationsnummer
IFOV	<i>Instantaneous Field of View</i>
IKONOS	Ein hochauflösender multispektraler Satellitensensor.
INS	inertiales Navigationssystem
Landsat ETM+	Landsat <i>Enhanced Thematic Mapper</i> . Ein multispektraler Satellitensensor.
Landsat TM	Landsat <i>Thematic Mapper</i> . Ein multispektraler Satellitensensor.
LE80, LE90	<i>Absolute linear error 80</i> , <i>Absolute linear error 90</i> . Maximale Abweichung des 80 % bzw. 90 % Quantils.
LIDAR	<i>Light Detection and Ranging</i>
ML	<i>Maximum Likelihood</i>
MODTRAN	Moderate resolution atmospheric Transmission. Software zur Modellierung des Strahlungsflusses der elektromagnetischen Strahlung durch die Erdatmosphäre.
nDOM	normalisiertes digitales Oberflächenmodell
NIR	<i>Near infrared</i> = Nahes Infrarot
PARGE	<i>Parametric Geocoding</i> . Software zur parametrischen Geokorrektur.
pMLK	Merkmalsbasierter, Paarweise- <i>Maximum-Likelihood</i> -Klassifizierer
PPI	<i>Pixel purity index</i>
PSF	<i>Point spread function</i>
PVC	Polyvinylchlorid
RGB-Darstellung	Rot-Grün-Blau = Echtfarbendarstellung eines optischen Fernerkundungsbildes.
RMSE	<i>Root Mean Square Error</i>
ROI	<i>Region of interest</i> , auch AOI = <i>area of interest</i>
SAR	<i>Synthetic Aperture Radar</i>
SNR	<i>Signal-to-noise ratio</i> = Verhältnis von Signal zu Rauschen
SPOT	Systeme Probatoire d'Observation de la Terre. Ein multispektraler Satellitensensor.
SBS	<i>Sequential backward selection</i> . Methode zur Merkmalsauswahl.
SFS	<i>Sequential forward selection</i> . Methode zur Merkmalsauswahl.
SRF	<i>Spectral response function</i>
SWIR	<i>Shortwave infrared</i> = Kurzwelliges Infrarot
TIN	<i>triangulated irregular network</i>
TIR	<i>Thermal infrared</i> = Thermales Infrarot
UNESCO	United Nations Educational, Scientific and Cultural Organization
UTC	<i>Coordinated Universal Time</i>
UTM	<i>Universal Transverse Mercator coordinate system</i> .
UVP, UVPG	Umweltverträglichkeitsprüfung, Gesetz über die Umweltverträglichkeitsprüfung
VIS	Sichtbarer Bereich der elektromagnetischen Strahlung.

Anhänge

Anhang A Klassenliste und Legende

Anhang B Konfusionsmatrizen der Biotopklassifizierungen

Anhang C Karten und kartenverwandte Darstellungen

Anhang A: Klassenliste und Legende

Klassenliste

Dachbedeckungen

<u>rtiln</u>	Rote Tonziegel (neu)	
<u>rtilo</u>	Rote Tonziegel (alt)	
<u>rtila</u>	Dunkelrot-braue Tonziegel	
<u>rtilg</u>	Graue Tonziegel	
<u>rcon</u>	Rote Betonziegel	
<u>ralu</u>	Aluminium	
<u>rzin</u>	Zink	
<u>rcop</u>	Kupfer	
<u>rste</u>	Stahl mit Rostschutzanstrich	
<u>rmecgr1</u>	mit PVC oder Polyethylen beschichtetes Well- oder Trapezblech	(Grünton 1)
<u>rmecgr2</u>		(Grünton 2)
<u>rmecw1</u>		(Weiß 1)
<u>rmecw2</u>		(Weiß 2)
<u>rpvc</u>	PVC	
<u>rpol</u>	Polyethylen	
<u>rple</u>	Plexiglas	
<u>rgla</u>	Glasdach oder großes Dachfenster (ohne spektrale Charakteristika von Vegetation)	
<u>rgla2</u>	Gewächshausdach aus Glas (mit spektralen Charakteristika von Vegetation)	
<u>rbith</u>	helles Dachbitumen	
<u>rbitd</u>	dunkles Dachbitumen	
<u>rbitr</u>	rotes Dachbitumen	
<u>rtar</u>	Teerpappe (obsolet)	
<u>rschi</u>	Schiefer	
<u>rveg</u>	Gründach	
<u>rgra</u>	Kies (grau)	
<u>rgra2</u>	Kies (leicht rötlich)	
<u>runkX</u>	8 unbekannte aber spektral unterschiedliche Materialien	

Vollversiegelte Oberflächen

<u>fcon</u>	Beton
<u>fbab</u>	Betonfahrbahn (Autobahn)
<u>fhoc</u>	betonierte Eishockey Spielfläche (ohne Eis)
<u>fasp</u>	Asphalt
<u>ftar</u>	Tartanbahn
<u>fkun</u>	Kunstrasen
<u>fpol</u>	Bodenplatten aus Polyethylen
<u>fcob</u>	blaue Bodenfarbe (Lack) auf Beton

Teilversiegelte Oberflächen

<u>pcob</u>	Kopfsteinpflaster
<u>prlc</u>	roter Splitt (in der Regel eine wassergebundene Decke)
<u>pble</u>	heller Splitt (in der Regel eine wassergebundene Decke)
<u>prlc</u>	grauer Splitt (in der Regel eine wassergebundene Decke)
<u>pdle</u>	dunkler Splitt (in der Regel eine wassergebundene Decke)
<u>prcon</u>	rote Betonpflastersteine
<u>prcla</u>	rote Tonpflastersteine
<u>prcin</u>	rote Asche (z.B. Tennisplatz)
<u>prail</u>	Bahngleise

Offener Boden

<u>bsan</u>	Feiner Sand
<u>bsanc</u>	grober Bausand mit Kiesanteil
<u>bsoi</u>	Boden

Wasser

<u>wriv</u>	Fluss
<u>wlake</u>	See
<u>wpon</u>	Teich
<u>wpoo</u>	Pool

Hochstämmige Vegetation

<u>vdec</u>	Laubbäume
<u>vcon</u>	Nadelbäume

Niedrige Vegetation

<u>vlaw</u>	Rasen
<u>vmea</u>	Wiese
<u>vdry</u>	trockener Rasen

Schatten

<u>sveg</u>	Schatten auf Vegetation
<u>snoy</u>	Schatten nicht auf Vegetation

Andere

<u>osba</u>	Gelbe U-Bahn von Berlin
<u>opoly</u>	gelbes Baumaterial aus Polyethylen

Klassengruppen

Klassengruppe Klassen

Vegetation	<u>vdec</u> , <u>vcon</u> , <u>vmix</u> , <u>vlaw</u> , <u>vmea</u> , <u>vdry</u> , <u>vfie</u> , <u>vfal</u> , <u>sveg</u>
Bäume	<u>vdec</u> , <u>vcon</u> , <u>vmix</u>
Böden	<u>bsan</u> , <u>bsanc</u> , <u>bsoi</u>
Dächer	<u>rtiln</u> , <u>rtilo</u> , <u>rcon</u> , <u>rtilg</u> , <u>rtila</u> , <u>ralu</u> , <u>rcop</u> , <u>rzin</u> , <u>rste</u> , <u>rmecgr</u> , <u>rmecw1</u> , <u>rmecw2</u> , <u>rpvc</u> , <u>rpol</u> , <u>rple</u> , <u>rgla</u> , <u>rgla2</u> , <u>rbitd</u> , <u>rbitb</u> , <u>rbitr</u> , <u>rschi</u> , <u>rtar</u> , <u>rveg</u> , <u>rgra</u> , <u>rgra2</u> , <u>runk1</u> – <u>runk8</u>
Metалldächer	<u>ralu</u> , <u>rcop</u> , <u>rzin</u> , <u>rste</u> , <u>rmecgr1</u> , <u>rmecgr2</u> , <u>rmecw1</u> , <u>rmecw2</u> , <u>rgla2</u>
Ziegeldächer	<u>rtiln</u> , <u>rtilo</u> , <u>rcon</u> , <u>rtilg</u> , <u>rtila</u> , <u>rschi</u> , <u>rgla2</u>
Flachdächer	<u>rpvc</u> , <u>rpol</u> , <u>rple</u> , <u>rgla2</u> , <u>rbitd</u> , <u>rbitb</u> , <u>rbitr</u> , <u>rtar</u> , <u>rveg</u> , <u>rgra</u> , <u>rgra2</u>
Industriedächer	<u>ralu</u> , <u>rzin</u> , <u>rste</u> , <u>rmecgr1</u> , <u>rmecgr2</u> , <u>rmecw1</u> , <u>rmecw2</u> , <u>rpvc</u> , <u>rpol</u> , <u>rple</u> , <u>rgla</u> , <u>rgla2</u> , <u>rbitd</u> , <u>rbitb</u> , <u>rbitr</u> , <u>rtar</u> , <u>rgra</u> , <u>rgra2</u>
Verkehrsflächen	<u>fcon</u> , <u>fasp</u> , <u>pcob</u> , <u>osba</u> , <u>fbab</u> , <u>prail</u>
Sportflächen	<u>fkun</u> , <u>ftar</u> , <u>fhoc</u> , <u>prcin</u> , <u>pglc</u>
Schatten	<u>sveg</u> , <u>snoy</u>
Wasser	<u>wpon</u> , <u>wpoo</u> , <u>wriv</u> , <u>wlake</u>
Hinterhöfe	Klassengruppen: Vegetation, Böden, Schatten, Dächer (nDOM < 40 dm) Klassen: <u>wpon</u> , <u>wpoo</u> , <u>fcon</u> , <u>fasp</u> , <u>pcob</u> , <u>prlc</u> , <u>pdlc</u> , <u>pblc</u> , <u>prcon</u> , <u>prcla</u>

Legenden der Klassifizierungsergebnisse der Hyperspektraldaten nach urbanen Oberflächenarten





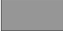




















Aggregierte Hauptklassen

	Ziegeldächer		Bahngleise
	Metалldächer		Sportbeläge (keine Vegetation)
	PVC, Polyethylen, Plexiglas und Glas		Bäume, Wald
	Dachbitumen		niedrige Vegetation
	Kiesdach		offener Boden
	Dachbegrünung		natürliche Gewässer
	Fassade		Schatten
	unbekannte Dachbedeckungen		sonstige
	befestigte Straßen und Plätze		unklassifizierte Pixel
	wassergebundene Decken		

Dachmaterialien

	rote Tonziegel		Polyethylen
	rote Betonziegel		Plexiglas
	graue Tonziegel		Glas
	rot-braune Tonziegel		Dachbitumen
	Aluminium		Dachbegrünung
	Kupfer		Kiesdach
	Zink		Fassade
	Stahl mit Rostschutz (blau-grau)		unbekannte Dachbedeckungen
	beschichtete Blechdächer		U-Bahn von Berlin
	PVC		unklassifizierte Pixel

ebenerdige Oberflächenarten und Bäume

	blaue Farbe		Boden
	gelbe Kunststoffrohre (Baumaterial)		Sand
	Beton		grober Bausand
	Asphalt		natürliche Gewässer
	Tartanbahn		Swimming Pool
	Kunstrasen		Laubbäume
	Bodenplatten aus Polyethylen		Nadelbäume
	Kopfsteinpflaster		Rasen
	Schotter-, Splittfläche (häufig wassergebundene Decke)		Wiese
	rote Betonpflastersteine		trockener Rasen
	rote Tonpflastersteine		Schatten
	rote Asche (z.B. Tennisplätze)		unklassifizierte Pixel
	Bahngleise		

Anhang B: Konfusionsmatrizen der Biotopklassifizierungen

Gezeigt werden *Omission Errors*, *Commission Errors* und Konfusionsmatrizen der Klassifizierungen mit dem ML-basierten Biotopklassifizierer entsprechend der **Tabelle 6-1**. In der Konfusionsmatrix befinden sich die Testbiotope in den Zeilen und die Klassenzuweisungen des Klassifizierers in den Spalten.

Tabelle B-1 Untersuchungsgebiet Berlin, alle Klassen, maximal 12 Merkmalen pro Paarweisklassifizierer.

	<i>Omission Error (%)</i>	<i>Commission Error (%)</i>
Einz.	13,29	8,29
Block.	39,45	41,2
B.rand.	37,04	38,68
Zeile.	36,29	33,61
Hochh.	17,65	44,66
Rasen	6,25	0
Schreb.	17,57	24,32
Sport.	21,9	24,07
Indust.	28,73	30,49
Str.	5,69	3,54

	Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen	Schreb.	Sport.	Indust.	Str.	Unkl.	Sum.
Einz.	1847	13	7	42	11	0	154	14	25	17	0	2130
Block.	2	551	198	82	17	0	0	0	54	6	0	910
B.rand.	0	198	447	31	11	0	0	1	22	0	0	710
Zeile.	15	94	56	395	26	0	0	0	32	2	0	620
Hochh.	0	1	0	4	140	0	0	0	23	2	0	170
Rasen	0	0	0	0	0	300	15	4	1	0	0	320
Schreb.	92	0	0	0	0	0	610	5	6	27	0	740
Sport.	9	2	0	5	0	0	6	164	10	14	0	210
Indust.	20	69	21	27	28	0	0	17	506	22	0	710
Str.	29	9	0	9	20	0	21	11	49	2452	0	2600
Sum.	2014	937	729	595	253	300	806	216	728	2542	0	9120

Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung; Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen; Schreb. = Schrebergärten; Sport. = Offene Sport- und Erholungsanlagen; Indust. = Industrie- und Gewerbeflächen; Str. = Straßen; Unkl. = unklassifiziert; Sum. = Summe.

Gesamtgenauigkeit: 81,3 %

Kappa Koeffizient: 0,775

Tabelle B-2 Untersuchungsgebiet Dresden, Klassengruppenvariante, maximal 11 Merkmalen pro Paarweisklassifizierer.

	<u>Omission Error (%)</u>	<u>Commission Error (%)</u>
Einz.	8,59	8,8
Block.	27,59	17,21
B.rand.	33,83	32,41
Zeile.	26,25	38,36
Hochh.	5,94	11,08
Rasen	1,72	0

	Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen	Unkl.	Summe:
Einz.	777	11	25	36	1	0	0	850
Block.	9	630	125	69	37	0	0	870
B.rand.	30	88	536	133	23	0	0	810
Zeile.	31	17	90	413	9	0	0	560
Hochh.	5	15	15	3	602	0	0	640
Rasen	0	0	2	16	5	1317	0	1340
Summe:	852	761	793	670	677	1317	0	5070

Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung; Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen

Gesamtgenauigkeit: 84,3 %

Kappa Koeffizient: 0,809

Tabelle B-3 Untersuchungsgebiet Dresden, alle Klassen, maximal 11 Merkmalen pro Paarweisklassifizierer.

	<u>Omission Error (%)</u>	<u>Commission Error (%)</u>
Einz.	9,06	8,84
Block.	28,28	19,69
B.rand.	35,06	35,7
Zeile.	31,43	40
Hochh.	8,44	11,88
Rasen	1,34	0

	Einz.	Block.	B.rand.	Zeile.	Hochh.	Rasen	Unkl.	Summe:
Einz.	773	7	30	40	0	0	0	850
Block.	12	624	140	59	35	0	0	870
B.rand.	29	94	526	137	24	0	0	810
Zeile.	31	25	104	384	16	0	0	560
Hochh.	3	25	17	9	586	0	0	640
Rasen	0	2	1	11	4	1322	0	1340
Summe:	848	777	818	640	665	1322	0	5070

Einz. = Einzelhausbebauung; Block. = Blockbebauung; B.rand. = Blockrandbebauung; Zeile. = Zeilenbebauung;
Hochh. = Hochhausbebauung; Rasen = reine Scher- und Zierrasen

Gesamtgenauigkeit: 83,1 %

Kappa Koeffizient: 0,794

Anhang C: Karten und kartenverwandte Darstellungen

- C-1 Klassifizierungsergebnis des HyMap-Flugstreifens 2000 in Dresden
- C-2 Klassifizierungsergebnis der HyMap-Flugstreifens 2004 in Dresden
- C-3 Ausschnitt der Biotoptypenkarte Dresdens
- C-4 Ausschnitt der Biotoptypenkarte Berlins
- C-5 Klassifizierungsergebnis des HyMap-Flugstreifens 2005 in Berlin
- C-6 Exemplarische Entmischungslayer des HyMap-Flugstreifens 2004 in Dresden




Abbildung C-1 Klassifizierungsergebnis des HyMap-Flugstreifens 2000 in Dresden. Links: aggregierte Hauptklassen, Mitte: Dachmaterialien, rechts: ebenerdige Oberflächenmaterialien. Legenden im Anhang A.





Abbildung C-2 Klassifizierungsergebnis des HyMap-Flugstreifens 2004 in Dresden. Links: aggregierte Hauptklassen, Mitte: Dachmaterialien, rechts: ebenerdige Oberflächenmaterialien. Legenden im Anhang A.

Karte C-3



Ausschnitt der Biotoptypenkarte Dresdens

Die Karte zeigt die Biotoptypenkarte Dresdens innerhalb der Grenzen des gewählten Untersuchungsgebiets. Für den Haupttyp der Wohnbebauung werden die einzelnen Biotoptypen gezeigt. Die übrigen Haupttypen sind nicht weiter untergliedert und in matten Farben dargestellt.

Legende

Biotoptypen der Wohnbebauung

- Einzel- und Reihenhausbebauung
- Block-, Blockrand- und Zeilenbebauung
- Großform- und Hochhausbebauung
- Öffentl. und halböffentl. Einrichtungen
- Sonstige Bebauung
- Kerngebiet / City

Weitere Haupttypen

- Industrie-, Gewerbe- und Sonderflächen
- Verkehrsanlagen und -flächen
- Grünflächen und Erholungsanlagen
- Gewässer und Uferzonen
- Grünland
- Ackerland
- Kleingehölze, Gebüsch
- Aufschüttungen und Abgrabungen
- Ruderal- und Staudenfluren sowie Brachflächen
- Trockenrasen, Heiden
- Wälder

Koordinatensystem: Gauß-Krüger, Zone 5

Bezugsellipsoid: Bessel

Datum: DHDN

Datengrundlage: Biotopkartierung Dresden (1999)

Eigentümer: Umweltamt Dresden

Erstellungsdatum der Karte: 11.05.2009


Bearbeitung und Kartographie: Mathias Bochow, GFZ Potsdam

Vervielfältigung und Verarbeitung unter Verwendung elektronischer Systeme nur mit schriftlicher Genehmigung des Eigentümers.

1.000 500 0 1.000
Meter

Maßstab 1:23.000

Karte C-4



Ausschnitt der Biotoptypenkarte

Die Karte zeigt die Biotoptypenkarte Berlins innerhalb der Grenzen des gewählten Untersuchungsgebiets, die mit der Ausdehnung des entsprechenden HyMap-Flugstreifens korrespondieren. Für den Haupttyp der Wohnbebauung werden die einzelnen Biotoptypen gezeigt. Die übrigen Haupttypen sind nicht weiter untergliedert und in matten Farben dargestellt.

Koordinatensystem: UTM, Zone 33 Nord
Bezugseilipsoid: WGS84
Datum: WGS84

Datengrundlage: Biotopkartierung Berlin (Stand: 06/2006)
Herausgeber: Senatsverwaltung für Stadtentwicklung Berlin
Urheber: Büro Luftbild+Vegetation

Erstellungsdatum der Karte: 13.05.2009
Bearbeitung und Kartographie: Mathias Bochow, GFZ Potsdam

Dieser Kartenausschnitt wurde mit Erlaubnis des Herausgebers hergestellt. Er darf nur für den eigenen Gebrauch vervielfältigt werden.

Legende

Biotoptypen der Wohnbebauung

- Einzel- und Reihenhausbebauung
- Blockbebauung
- Blockrandbebauung
- Zeilenbebauung

- Großformbebauung, Hochhauskomplexe
- Villenbebauung
- Kerngebiet / City

Weitere Haupttypen

- Industrie-, Gewerbe-, Handels- und Dienstleistungsflächen, Gemeinbedarfsflächen

- Verkehrsflächen
- Ver- und Entsorgungsanlagen
- sonstige bebaute Flächen
- Fließgewässer
- Ständgewässer

- Moore und Sümpfe
- Wälder und Forsten
- Gebüsche, Baumreihen und Baumgruppen
- Grün- und Freiflächen
- Grünland, Staudenfluren und Rasengesellschaften

- Anthropogene Rohbodenstandorte und Ruderaifluren
- Äcker
- Sonderbiotope





Abbildung C.5 Klassifizierungsergebnis des HyMap-Flugstreifens von Berlin.



Oben: aggregierte Hauptklassen
Mitte: Dachmaterialien
Unten: ebenerdige Oberflächenmaterialien




Abbildung C-6 Exemplarische Entmischungslayer des HyMap-Flugstreifens 2004 in Dresden.