

Universität der Bundeswehr München

Institut für Photogrammetrie und Kartographie

**Automatische Straßenextraktion aus optischen  
Satellitenbildern hoher und höchster Auflösung**

Dissertation

*Uwe Bacher*

2006



Universität der Bundeswehr München  
Fakultät für Bauingenieur- und Vermessungswesen

# **Automatische Straßenextraktion aus optischen Satellitenbildern hoher und höchster Auflösung**

*Dipl.-Ing. Uwe Bacher*

Vollständiger Abdruck der von der Fakultät für Bauingenieur- und Vermessungswesen der Universität der Bundeswehr zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs (Dr.-Ing.)

genehmigten Dissertation.

Promotionsausschuss:

- Vorsitzender: Univ.-Prof. Dr.-Ing. Friedrich S. Kröll  
1. Berichterstatter: Univ.-Prof. Dr.-Ing. Helmut Mayer  
2. Berichterstatter: Univ.-Prof. Dr.-Ing. Uwe Stilla, TU München

Diese Dissertation wurde am 31. Januar 2006 bei der Universität der Bundeswehr München eingereicht.

Tag der mündlichen Prüfung: 07. April 2006



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	1
1.1	Motivation	1
1.2	Zielsetzung und Gliederung der Arbeit	1
<b>2</b>	<b>Grundlagen</b>	5
2.1	Satellitenbilder hoher und höchster Auflösung	5
2.2	Grundlagen der Bildanalyse	6
2.3	Methoden und Verfahren	8
2.3.1	<i>Linien- und Kantenextraktion</i>	8
2.3.2	<i>Snakes</i>	9
2.3.3	<i>Fuzzy-Sets</i>	11
2.3.4	<i>Netzwerkbildung – Globale Gruppierung</i>	13
<b>3</b>	<b>Straßenextraktion – Stand der Wissenschaft</b>	18
3.1	Luftbilder	18
3.2	Höchstaufgelöste Satellitenbilddaten	21
3.3	Satellitenbilddaten hoher und mittlerer Auflösung	23
3.4	Radar- und Laserdaten	24
3.5	Fortführung von Straßendatenbasen	24
3.6	Charakterisierung von Ansätzen zur Straßenextraktion	27
<b>4</b>	<b>Straßenextraktion aus Satellitenbilddaten</b>	29
4.1	Modell für Straßen in multispektralen Satellitenbildern	29
4.2	Strategie	33
4.3	Straßenextraktion aus höchstaufgelösten Multispektral-Daten	37
4.3.1	<i>Fuzzy-Klassifikationsansatz</i>	37
4.3.2	<i>Bildung und Verifikation von Straßenhypothesen</i>	45
4.3.3	<i>Verifikation von Verbindungshypothesen</i>	48
4.4	Straßenextraktion aus hochaufgelösten Satellitenbilddaten	51
4.4.1	<i>Generierung von Straßenabschnitten durch lokale Gruppierung</i>	51
4.4.2	<i>Zusammenführung der Teilergebnisse</i>	58

<b>5</b>	<b>Experimente</b>	60
5.1	Referenzdaten	60
5.2	Genauigkeit und Zuverlässigkeit der Straßenextraktion	62
5.3	Untersuchungen für höchst aufgelöste Multispektral-Daten	63
5.3.1	<i>Experimente zum Fuzzy-Klassifikationsansatz</i>	64
5.3.2	<i>Experimente zur Straßennetzbildung</i>	79
5.4	Untersuchungen für hoch aufgelöste Satellitenbilddaten	87
5.5	Beurteilung der Ergebnisse	93
5.5.1	<i>Höchst aufgelöste Satellitenbilddaten</i>	94
5.5.2	<i>Hoch aufgelöste Satellitenbilddaten</i>	96
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	98
	<b>Literatur</b>	101

# 1 Einleitung

## 1.1 Motivation

Straßen bilden in unserer Gesellschaft einen der wichtigsten Teile der Infrastruktur. Sie verbinden Länder, Regionen, Städte, Dörfer und einzelne Häuser miteinander. Über Straßen werden Güter transportiert, Menschen bewegen sich über sie von einem Ort zum anderen und viele Menschen verbringen auf ihnen einen größeren Teil ihres Lebens. Aufgrund der großen Bedeutung von Straßen ist ihre genaue und aktuelle Kartierung und damit heutzutage die Erzeugung digitaler Straßendaten von immensm Interesse.

Aktuelle digitale Straßendaten sind eine Grundlage für Fahrzeugnavigation und Logistik, aber auch für ein effektives Katastrophenmanagement (siehe z.B. Abbildung 1) oder die Planung von friedensichernden Maßnahmen. Für viele Entwicklungsländer, und auf deren Straßen zielt die vorgelegte Arbeit ab, sind solche Daten nicht, oder nicht allgemein verfügbar. Um unabhängig aktuelle und genaue digitale Straßendaten generieren zu können, sind Datengrundlagen notwendig, die beschafft werden können, ohne die nationale Souveränität zu verletzen. Satellitenbilddaten erfüllen diese Voraussetzungen sowohl in Bezug auf Genauigkeit als auch Aktualität. Da Straßendaten in der Regel nicht vorhanden oder von untergeordneter Genauigkeit sind, ist es meist unerlässlich, die Daten komplett neu zu erfassen.

## 1.2 Zielsetzung und Gliederung der Arbeit

### Zielsetzung

Die vorgelegte Arbeit hat zum Ziel, die Extraktion von Straßendaten für den Maßstabsbereich von 1:50 000, z.B. im Rahmen des Multi-National Geospatial Co-Production Program (MGCP) der NATO, zu unterstützen. Regionen, für welche die entwickelten Ansätze eingesetzt werden sollen, sind Südosteuropa und Nordafrika. Wegen der extremen Unterschiede in der Dichte des Straßennetzes vor allem in Nordafrika – dicht besiedelte Gebiete in Küstennähe und extrem dünn besiedelte Gebiete in der Wüste – bietet sich der Einsatz von Satellitenbilddaten unterschiedlicher Auflösung an. Für Gebiete mit hoher Komplexität, d.h. vor allem Siedlungen bzw. Gebiete mit dichtem, komplexem Straßennetz, oder Gebiete in denen maximale Genauigkeit benötigt wird, sollen als Datengrundlage Satellitenbilder höchster Auflösung verwendet werden. Für Gebiete von untergeordnetem Interesse reichen dagegen Satellitenbilder hoher Auflösung aus.

Unter Satellitenbilddaten höchster Auflösung werden im Rahmen der vorgelegten Arbeit Daten mit einer Bodenauflösung im Bereich von einem Meter und besser im panchromatischen Kanal verstanden. Aktuell stehen hierfür die Bilddaten der Satelliten Quickbird, IKONOS-2 und Orbview-3 zur Verfügung (KRAMER 2002). Zusätzlich zu ihrer sehr guten geometrischen Auflösung erfassen diese Sensoren jeweils multispektrale Daten in etwas schlechterer Auflösung. Zu Satellitenbilddaten hoher Auflösung werden in dieser Arbeit Daten mit einer Auflösung im Bereich von 2 m bis ca. 5 m im panchromatischen Kanal gezählt. Dies umfasst z.B. die Bilddaten der Satelliten EROS-A1, SPOT-5 oder IRS-1C/D. Satellitenbilddaten mittlerer Auflösung, wie z.B. Landsat, ASTER oder SPOT-1/2/4,

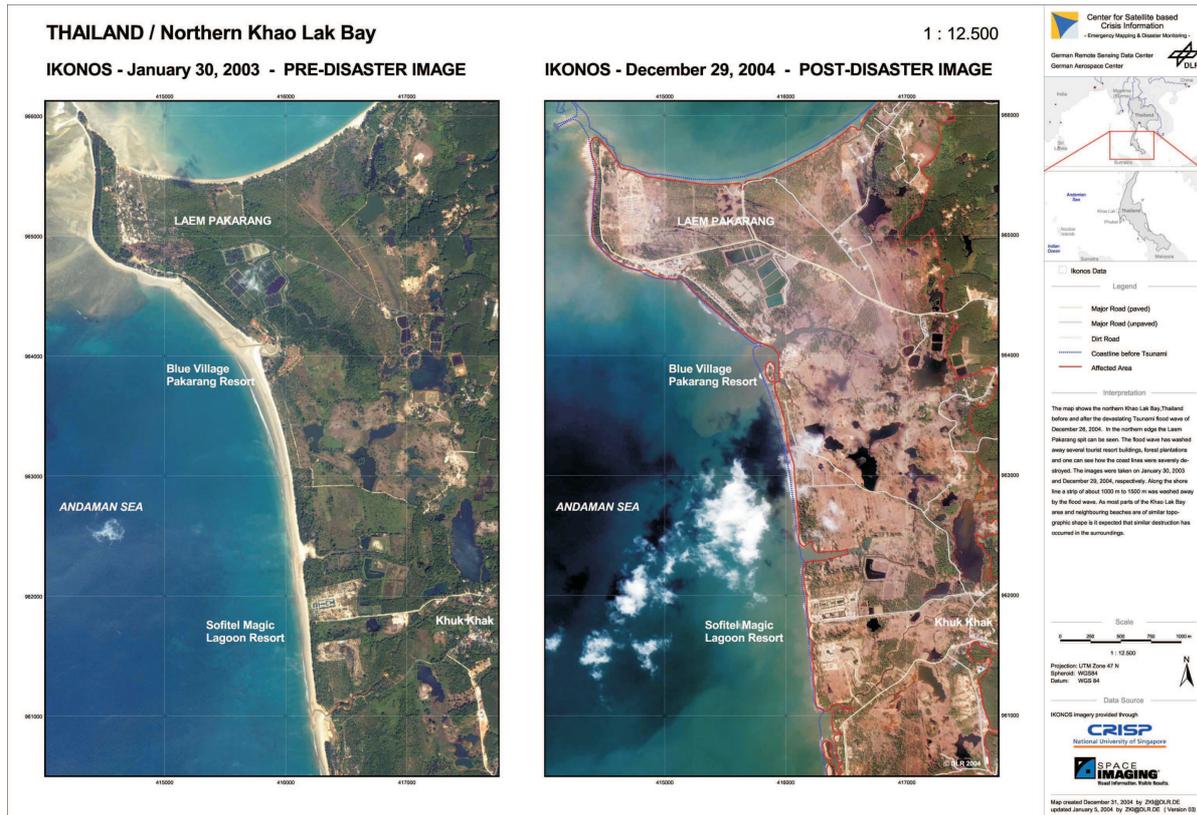


Abbildung 1. „In-time“ erstellte Satellitenbildkarte mit Schwerpunkt auf Straßen für die Katastrophenhilfe nach der Tsunami-Katastrophe in Südostasien am 26. Dezember 2004 – mit freundlicher Genehmigung des Zentrums für satellitengestützte Kriseninformation am DLR.

sind mit einer Auflösung von deutlich schlechter als 5 m für die Extraktion von Straßen nur bedingt geeignet. Mit ihnen lassen sich im Allgemeinen lediglich die großen Hauptstraßen und Autobahnen zuverlässig extrahieren. Damit sind sie für die vorgelegte Arbeit nicht von Interesse.

Grundlage für die vorgelegte Arbeit sind die an der Technischen Universität München (TU München) entwickelten Ansätze zur automatischen Straßenextraktion für ländliche Gebiete, wie z.B. (BAUMGARTNER et al. 1999, BAUMGARTNER 2003, LAPTEV et al. 2000, WIEDEMANN et al. 1998, WIEDEMANN 2002). Die Ansätze der TU München wurden bezüglich ihrer Eignung für die Straßenextraktion aus Satellitenbilddaten aus Südosteuropa und Nordafrika überprüft (JOST 2003). Im Rahmen dieser Untersuchung wurden sowohl die Schwächen, als auch die Stärken der Ansätze für diese Anwendung offenbar. Es zeigte sich die gute Eignung der von WIEDEMANN (2002) vorgestellten Verfahren zur Netzwerkbildung und globalen Gruppierung für alle verwendeten Bilddaten. Für Satellitenbilder hoher Auflösung erwies sich das auf der Extraktion und Bewertung von Linien beruhende Verfahren von WIEDEMANN et al. (1998) für Gebirgs- und Wüstengebiete als leistungsfähig. In überwiegend landwirtschaftlich genutzten Gebieten zeigte dieses Verfahren dagegen einige Schwächen und motivierte die Entwicklung eines eigenen Ansatzes für diese Gebiete. Alle Ansätze der TU München nutzen die spektrale Information der Bilddaten nur unzureichend. Wegen der hohen Qualität der höchstauflösenden Daten im multispektralen Bereich wurde ein Schwerpunkt der vorgelegten Arbeit auf die Integration dieser Information in die Extraktion in Form eines hierfür entwickelten automatischen Klassifikationsansatzes gelegt. Für die Bestimmung von Trainingsgebieten, die hier automatisch aus den vorgelegten Daten erfolgt und die Grundlage des Klassifikationsansatzes bildet, diente

(BAUMGARTNER 2003) als Inspiration.

Die Unterstützung der Erzeugung einer Straßendatenbasis im Maßstabsbereich 1:50 000 als primäres Ziel der vorgelegten Arbeit macht es, wie die Erfahrungen der Arbeit zeigen, notwendig, höchstauflöste Satellitenbilddaten als primäre Datenquelle zu nutzen. Um die Anforderung vor allem in Bezug auf die Zuverlässigkeit, die aus dem Zielmaßstab resultieren, erreichen zu können, sollten hochauflöste Satellitenbilddaten lediglich in Gebieten mit wenig Detaillierung verwendet werden. Hieraus resultiert die Gewichtung der vorgelegten Arbeit, in der die Straßenextraktion aus höchstauflösten Satellitenbilddaten einen weitaus größeren Raum einnimmt als die aus hochauflösten.

In der vorgelegten Arbeit wird davon ausgegangen, dass nach einigen vorbereitenden Schritten, vor allem der Einschränkung auf geeignete Bereiche, ein vollautomatischer Extraktionsschritt folgt. Die resultierenden Ergebnisse werden dann in einem abschließenden Schritt manuell oder auf Grundlage von Zwischenergebnissen halbautomatisch überarbeitet. Der wissenschaftliche Schwerpunkt der vorgelegten Arbeit liegt auf der vollautomatischen Extraktion von Straßen.

### Gliederung der Arbeit

Die Arbeit ist in der folgenden Weise gegliedert, wobei die eigenen Arbeiten in den Kapiteln 4 und 5 vorgestellt werden:

In **Kapitel 2** werden für das Verständnis der Arbeit notwendige Grundlagen eingeführt. Das Kapitel enthält eine Beschreibung der verwendeten Satellitenbildsensoren, eine Übersicht über relevante Themen der Bildanalyse sowie eine kurze Darstellung der verwendeten Methoden und Verfahren.

**Kapitel 3** vermittelt einen Überblick über den aktuellen Stand der Wissenschaft. Die aktuelle Forschung im Bereich Straßenextraktion wird nach der Auflösung der verwendeten Bilddaten unterteilt vorgestellt und charakterisiert. Ergänzend werden Arbeiten zur Fortführung von Straßendatenbasen dargestellt und Möglichkeiten aufgezeigt, die sich aus der Verwendung alternativer Sensoren ergeben.

**Kapitel 4** stellt die im Rahmen der vorgelegten Arbeit entwickelten Ansätze zur Straßenextraktion vor. Ein erster Teil motiviert und beschreibt das verwendete Straßenmodell sowie die genutzte Strategie. Der zweite Teil erläutert die Straßenextraktion aus multispektralen, höchstauflösten Satellitenbilddaten. Er führt angefangen mit dem Kern der Arbeit, dem Klassifikationsansatz basierend auf der automatischen Bestimmung von Trainingsgebieten aus den vorliegenden Daten, über die Bildung und Verifizierung von Straßenhypothesen inklusive Netzbildung hin zur abschließenden Verifikation von Verbindungshypothesen im Rahmen der globalen Gruppierung. Im dritten Teil wird das Verfahren zur Extraktion von Straßen aus hochauflösten Satellitenbilddaten in den drei Kontextgebieten landwirtschaftlich genutzt, Wüste und Gebirge, sowie die Zusammenführung der entsprechenden Teilergebnisse beschrieben.

**Kapitel 5** demonstriert anhand von ausführlichen Experimenten die Leistungsfähigkeit der entwickelten Ansätze. Nach einer näheren Betrachtung der Problematik der Erfassung repräsentativer Referenzdaten werden die Bewertungskriterien zur Evaluierung der Testbeispiele erläutert. Die Experimente sind aufgeteilt in die Untersuchung des Ansatzes für höchstauflöste Satellitenbilddaten, wobei der Klassifikationsansatz wegen seiner zentralen Bedeutung einen großen Raum einnimmt, und die Ansätze für hochauflöste Satellitenbilddaten. Die Beurteilung der erzielten Ergebnisse schließt

das Kapitel ab.

Den Abschluss der Arbeit bildet das **Kapitel 6** mit einer Zusammenfassung und einem Ausblick auf mögliche Weiterentwicklungen.

## 2 Grundlagen

In diesem Kapitel werden zum Verständnis der vorgelegten Arbeit hilfreiche Grundlagen dargestellt. Im Abschnitt 2.1 werden die zur Verwendung kommenden Satellitenbilddaten beschrieben. Relevante Grundlagen der Bildanalyse werden in Abschnitt 2.2 eingeführt. Verfahren und Methoden, die bei im Rahmen der vorgelegten Arbeit entwickelten Ansätzen Verwendung finden, werden in Abschnitt 2.3 vorgestellt.

### 2.1 Satellitenbilder hoher und höchster Auflösung

Die erste Aufnahme der Erde aus dem Weltall erfolgte im Jahre 1959 mittels einer TV Kamera an Bord des amerikanischen Satelliten Explorer-6. Um dieses erste „Fernsehbild“ der Erde zu übertragen, benötigte man fast 40 Minuten (KRAMER 2002). Seit dieser Zeit hat die Technik enorme Fortschritte gemacht. Die ersten operationellen Fernerkundungssatelliten die Bilddaten mit Auflösungen im Bereich von anfänglich Zehnermetern lieferten, wie z.B. Landsat, SPOT, RESURS, IRS, JERS, wurden von staatlichen Organisationen betrieben. Erst seit 1999 betreiben kommerzielle Firmen Fernerkundungssatelliten. Die Firma Space Imagine machte mit IKONOS-2 den Anfang und bietet Daten mit einer räumlichen Auflösung von 1 m kommerziell an.

Für die automatische Extraktion von Straßen sind aufgrund deren Charakteristik, insbesondere ihre Breite, nur Bilddaten mit einer räumlichen Auflösung besser als 10 m einsetzbar. In Daten mit schlechterer Auflösung lassen sich in der Regel nur noch sehr breite Straßen, wie z.B. Autobahnen, detektieren. Damit sind sie für diese Arbeit nur von untergeordnetem Interesse. Für die vorliegende Arbeit wurden Bilddaten der Satelliten IKONOS-2 und IRS-1C/D verwendet. Diese werden im Folgenden näher beschrieben.

#### Höchste Auflösung: IKONOS-2

IKONOS-2 wurde im September 1999 gestartet und wird von der Firma Space Imagine betrieben. Der Satellit bewegt sich auf einer sonnensynchronen Bahn in einer Höhe von etwa 700 km und einer Inklination von  $98.1^\circ$  in 98 min um die Erde. Weitere technische Einzelheiten des höchstauflösenden Fernerkundungssatelliten sind in Tabelle 1 zu finden.

Für die Straßenextraktion wurde in dieser Arbeit das so genannte „pan-sharpened“ Bildprodukt verwendet, bei dem der hoch aufgelöste panchromatische Kanal mit den schlechter aufgelösten multispektralen Daten (rot, grün, blau und infrarot) zu Bilddaten mit einer Pixelgröße von 1 m kombiniert wird (DIAL et al. 2001).

#### Hohe Auflösung: IRS-1C/D

Der indische Satellit IRS-1C (Indian Remote Sensing Satellite) wurde im Dezember 1995 und IRS-1D im September 1997 gestartet. Die geplante sonnensynchrone Bahn in 817 km Höhe, mit einer Inklina-

Parameter	Panchromatischer Kanal	Multispektrale Kanäle
Wellenlänge [ $\mu m$ ]	0.45 - 0.90	0.45-0.52 (blau), 0.52-0.60 (grün), 0.63-0.69 (rot), 0.76-0.90 (infrarot)
Räumliche Auflösung	$\leq 1 m$	$\leq 4 m$
Radiometrische Auflösung	11 bit	
Stereo Fähigkeit	in Flugrichtung (along-track)	
Streifenbreite, Szene	13 km, 13 km x 100 km	

Tabelle 1. Technische Parameter von IKONOS-2

tion von  $98.71^\circ$  und einer Umlaufzeit von etwa 101 Minuten wurde nur von IRS-1C erreicht. IRS-1D konnte nach Schwierigkeiten auf eine nahezu sonnensynchrone elliptische Bahn (Höhe zwischen 821 km und 737 km) gebracht werden. Die technischen Einzelheiten sind in Tabelle 2 zu finden.

Bei den hochauflösten IRS Daten ist die Forderung nach einer räumlichen Auflösung besser als 10 m für die Straßenextraktion lediglich für den panchromatischen Kanal erfüllt. Um zusätzlich die hilfreiche Farbinformation nutzen zu können, werden die Farbkanäle mit dem hochauflösten Kanal zu „pan-sharpened“ Bilddaten kombiniert. Dieses Bildprodukt wird in der Regel mit einer Pixelgröße von 5 m für die weitere Verarbeitung bereitgestellt und wurde für diese Arbeit verwendet.

Parameter	Panchromatischer Kanal	Multispektrale Kanäle
Wellenlänge [ $\mu m$ ]	0.50 - 0.75	0.52-0.59 (grün), 0.62-0.68 (rot), 0.77-0.86 (infrarot)
Räumliche Auflösung	5.8 m	23.5 m
Radiometrische Auflösung	6 bit	7 bit
Streifenbreite	70 km	142 km

Tabelle 2. Technische Parameter von IRS-1C/D

## 2.2 Grundlagen der Bildanalyse

Die Objektextraktion ist als Schwerpunkt der Bildanalyse einer der schwierigsten Arbeitsschritte innerhalb der photogrammetrischen Auswertung. Für die Extraktion von künstlichen Objekten, wie z.B. Straßen oder Gebäuden stellen digitale photogrammetrische Arbeitsstationen (DPA) bisher nur Hilfsmittel für die manuelle oder maximal halbautomatische Extraktion zur Verfügung. Um die Bearbeitungszeiten für die Extraktion von künstlichen Objekten jedoch deutlich zu verkürzen, sind effektive und robuste automatische Ansätze notwendig. Durch diese Anforderungen hat sich der Aufgabenbereich der Photogrammetrie in jüngster Zeit in Richtung Computer Vision und künstliche Intelligenz erweitert. Kurzfristige Vorhaben zielen hierbei auf die Lösung spezieller Probleme ab, wohingegen das langfristige Ziel in der Abbildung der menschlichen Wahrnehmungsfähigkeiten in Computersystemen besteht (McGLONE et al. 2004).

Die Voraussetzung aller automatischen Ansätze zur Objektextraktion ist die Kenntnis des Aussehens der gesuchten Objekte. Hieraus folgt die Notwendigkeit, die Objekte sowohl in ihrem Auftreten in der realen Welt als auch in der Abbildung durch die verwendeten Sensoren zu modellieren, d.h. das implizit gegebene Wissen in eine explizite Form zu überführen. Nach (SESTER 1995) sind an die Modellierung eine Reihe an Anforderungen zu stellen. Zunächst bestimmt das Ziel welche Art von Modell, z.B. deskriptiv oder diskriminatorisch, bereitgestellt werden muss. Die Dimension, zwei- (2-

D) oder dreidimensional (3-D), des aufzustellenden Modells sowie die verwendeten Maßstäbe müssen festgelegt werden. Von elementarer Bedeutung für die Modellierung ist die Repräsentation, mit der die Beschreibung des Modells erfolgen soll (BÄHR et al. 1995, STILLA et al. 1998). D.h., es muss eine für das System verständliche Sprache gewählt werden. Für das Modell sind nur solche Objekte sinnvoll, die selbst oder aufgrund ihrer Einflüsse beobachtbar bzw. bekannt sind. Zusätzlich zur Modellierung der eigentlich interessierenden Objekte kann auch die Modellierung deren gegenseitiger Beziehungen, sowie die Interaktion der interessierenden Objekte mit benachbarten Objekten, die zwar nicht Ziel der Auswertung sind, die jedoch einen starken Anhaltspunkt für das Vorhandensein der interessierenden Objekte geben, sinnvoll sein (MAYER 2004). Bei Letzterem, dem so genannten „Kontextwissen“ wird zwischen Objekten in der direkten Nachbarschaft zum gesuchten Objekt, dem lokalen Kontext, z.B. Fahrzeug auf Straße, und der großräumigen Einordnung von Bildbereichen, dem globalen Kontext, z.B. Wald, ländlicher Raum oder urbanes Gebiet, unterschieden (BAUMGARTNER 2003). Das Kontextwissen kann aus anderen Quellen stammen. So kann z.B. Wissen aus einer Karte oder einem Geoinformationssystem (GIS) in die Modellierung oder indirekt in den Analyseablauf einfließen (STILLA 1995).

Neben der Modellierung ist für die Bildanalyse die Strategie von entscheidender Bedeutung. Hierunter ist zu verstehen, welches Modellwissen zu welchem Zeitpunkt der Analyse eingesetzt wird und welche Methode für die Nutzung des vorhandenen Wissens verwendet wird. Nach (MAYER 1998) können bei der Strategie für den Interpretationsablauf mehr oder weniger anwendungsabhängige und anwendungsunabhängige Teile unterschieden werden. Die anwendungsabhängigen Teile umfassen hierbei in erster Linie die Methoden für die Extraktion von Merkmalen oder Objekten aus den Bilddaten, u.U. in verschiedenen Maßstäben (LINDBERG 1994). Eine weitere anwendungsabhängige Technik ist die (perzeptuelle) Gruppierung von weniger bedeutsamen Strukturen zu höherwertigeren Elementen. Z.B. werden Linienstücke zu Netzwerken gruppiert (STEGGER et al. 1997) oder zu ganzen Siedlungen (STILLA und JURKIEWICZ 1996). Unter den anwendungsunabhängigen Teilen der Strategien werden nach (MAYER 1998) allgemeine Methoden zur Schlussfolgerung und Kontrolle verstanden. Techniken der Schlussfolgerung sind z.B. die Induktion, wobei aus Einzeltatsachen auf allgemein gültige Sätze geschlossen wird, oder die Deduktion, wobei von einer allgemeinen Tatsache auf eine spezielle geschlossen wird (SESTER 1995). Strategien für die Kontrolle von Extraktionssystemen lassen sich in datengetriebene (bottom-up) und modellgetriebene (top-down) sowie gemischte, hybride Strategien (siehe Abbildung 2) unterteilen (MARR 1982, SOMMER 1992). Bei den datengetriebenen Strategien werden aus dem Bild Merkmale extrahiert und diese sukzessive zu höherwertigeren Objekten verbunden. Modellgetriebene Strategien generieren ausgehend vom Modell Hypothesen, auf deren Basis im Bild nach Strukturen gesucht wird, um die Hypothesen zu bestätigen. Bei den hybriden Strategien werden beide zuvor genannten Vorgehensweisen kombiniert.

Aus praktischer Sicht haben die hybriden Strategien zur Kontrolle eines Extraktionssystems die größte Bedeutung. Durch geschickte Wahl von „Wechselpunkten“ (HINZ 2003), d.h. des Übergangs von datengetriebener auf modellgetriebene Steuerung oder umgekehrt, lässt sich die Effizienz, z.T. aber auch die Leistungsfähigkeit, insbesondere die Zuverlässigkeit eines Systems durch gezielte Einschränkung des Suchraums oft stark verbessern. Typisch für die hybride Strategie ist das datengetriebene Aufstellen von Hypothesen und deren anschließende Verifikation oder Falsifikation mit Hilfe des Modellwissens. Von großer Bedeutung ist hierbei die Bewertung von (Teil-)Ergebnissen bzw. Hypothesen. Die verwendeten Parameter sind in der Regel keine starren Grenzwerte sondern stammen aus adaptiven Prozeduren. Als Hilfsmittel für die Bewertung werden Wahrscheinlichkeiten oder die unscharfe Logik (Fuzzy Logic) verwendet (MAYER 1998).

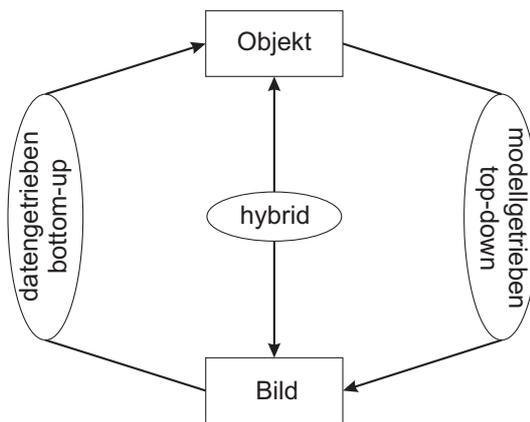


Abbildung 2. Strategien zur Kontrolle der Bildanalyse

Die Eignung verschiedener Strategien zur Objektextraktion hängt aus Sicht von SUTENS et al. (1992) von der Komplexität sowohl der Bilddaten als auch der zugrunde liegenden Modelle ab (siehe Abbildung 3). Mit zunehmender Komplexität der Bilddaten ist bei einem einfachen Modell eine modellgetriebene Strategie sinnvoll. Im umgekehrten Fall, d.h. bei einem komplexen Modell mit wenig komplexen Daten, bietet sich dagegen eine datengetriebene Strategie an. Sollen aus komplexen Daten komplexe Objekte extrahiert werden, so ist meist nur der in der Objektextraktion aus Satellitenbilddaten häufigste Fall einer kombinierten (hybriden) Strategie zielführend.

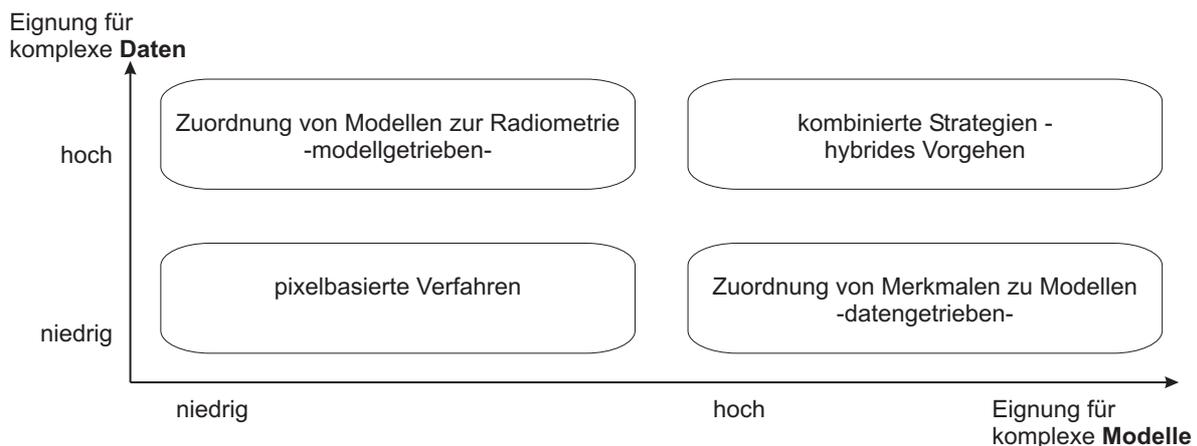


Abbildung 3. Eignung von Strategien in Abhängigkeit von der Komplexität der Daten und Modelle – nach (SUTENS et al. 1992, MAYER 1998, HINZ 2003)

## 2.3 Methoden und Verfahren

### 2.3.1 Linien- und Kantenextraktion

Die Abbildung von Straßen in Bildern besteht zu einem großen Teil aus linienhaften Strukturen in Form von Kanten, d.h. langgestreckte Grauwertübergänge, und Linien, d.h. langgestreckte Flächen mit Grauwertübergängen auf beiden Seiten der Linie. In dieser Arbeit wird der Steger Operator (STEGGER 1998a) für die Extraktion von Linien verwendet. Die Vorteile dieses Ansatzes gegenüber anderen Verfahren, wie z.B. (BUSCH 1996), sind dessen Möglichkeiten zur Handhabung von unterschiedlichen

Linienbreiten und Kontrastunterschieden auf den beiden Linienseiten, die Subpixelgenauigkeit, sowie die explizite Wiederherstellung der Topologie an Kreuzungen.

Linien, die Straßen repräsentieren, werden im Eindimensionalen (1-D) oft als Balkenprofil idealisiert. Der Steger-Linienextraktor wird ausgehend von dieser Annahme theoretisch hergeleitet. In einem ersten Schritt wird das Bild mit einem Gauß-Filter mit Filterbreite  $\sigma$  gefaltet. Linienmittelpunkte zeichnen sich durch eine verschwindende erste Ableitung  $g_{c,\sigma}$  entlang des Profils in Spaltenrichtung (c) aus. Im Normalfall ist man an deutlichen Linien, d.h. mit hohem Kontrast zum Hintergrund, interessiert. Für diesen Fall wird als zusätzliches Kriterium noch die Krümmung, d.h. die zweite Ableitung  $g_{cc,\sigma}$  des Gauß-geglätteten Profils betrachtet. Für helle Linien auf dunklem Hintergrund gilt  $g_{cc,\sigma} \ll 0$ , für dunkle Linien auf hellem Hintergrund ist  $g_{cc,\sigma} \gg 0$ .

Linien in 2-D werden als Kurven  $s(t)$  modelliert. Senkrecht zur Kurvenrichtung, d.h. in Normalenrichtung,  $n(t)$  wird hierbei wie im 1-D Fall ein balkenförmiges Profil  $g_{bar}$  erwartet. Für Linienpunkte muss die erste Ableitung in Richtung  $n(t)$  verschwinden und die zweite Ableitung einen großen Absolutwert annehmen. Um die lokale Richtung der Linie sowie die Linienstärke zu bestimmen, werden die ersten und zweiten partiellen Ableitungen in Zeilen- (r) und Spaltenrichtung (c)  $g_{r,\sigma}$ ,  $g_{c,\sigma}$ ,  $g_{rc,\sigma}$ ,  $g_{rr,\sigma}$  und  $g_{cc,\sigma}$  für jeden Bildpunkt bestimmt. Die zweiten partiellen Ableitungen bilden die Hesse-Matrix (siehe Formel (1)).

$$H(r, c) = \begin{bmatrix} g_{rr,\sigma} & g_{rc,\sigma} \\ g_{rc,\sigma} & g_{cc,\sigma} \end{bmatrix} \quad (1)$$

Die Linienstärke ergibt sich aus dem Absolutwert des größten Eigenwertes und der zugehörige Eigenvektor bestimmt die Linienrichtung, wobei der Wert für helle Linien große negative und für dunkle Linien große positive Werte annimmt. Gefundene Linienpunkte werden unter Berücksichtigung ihrer Richtung mit Hilfe von Hysterese Schwellwertbildung (CANNY 1986) zu Polygonen zusammengefasst.

Der Steger Linienextraktor kann auch für die subpixelgenaue Extraktion von Kanten genutzt werden. Hierfür wird zunächst ein Gradientenbild bestimmt, in dem sich Kanten als helle Linien abbilden. Auf dieses Gradientenbild wird der Steger-Linienextraktor angewandt. Die Filtermaske wird auf eine minimale Größe verkleinert, um eine zusätzliche Glättung und damit verbundene Verschlechterung der Korrelation zwischen der Position der Linienpunkte und den damit verbundenen Kantenpunkten zu vermeiden (STEGER 1998a).

### 2.3.2 Snakes

Snakes oder auch Active Contour Models wurden erstmals in (KASS et al. 1988) vorgestellt. Sie wurden für die halbautomatische Extraktion linienhafter Objekte vorgeschlagen und haben sich zu einem wichtigen Werkzeug im Bereich der Bildanalyse entwickelt. Die Extraktion erfolgt durch lokale Optimierung der Linie in der Nähe einer vorgegebenen Anfangsposition. Eine Snake ist eine energieminimierende Kurve. Bedingungen für die inneren Parameter der Kurve sorgen für die Forcierung von Formbedingungen, wie z.B. von Glattheit, wohingegen die äußere Kraft des Bildes, wie z.B. die Kantenstärke, eine Verschiebung der Kurve in Richtung der relevanten Bildinformation bewirken.

Für Anwendungen im Bereich der Straßenextraktion wurden spezielle Snake-Varianten, wie die Ziplock Snake (NEUENSCHWANDER 1996) oder die Ribbon Snake (LAPTEV 1997, LAPTEV et al. 2000) entwickelt.

In den folgenden Abschnitten wird die Theorie der Snakes eingeführt. Der erste Teil beschreibt die analytische Repräsentation der Snake und skizziert die Lösung der entstehenden diskreten Gleichungssysteme. Im zweiten Teil wird auf die für diese Arbeit bedeutende Ziplock-Snake näher eingegangen.

### Analytische Repräsentation

Die originale, in (KASS et al. 1988) vorgestellte Snake ist eine Kurve im 2-D Raum definiert als

$$\vec{v}(s) = (x(s), y(s)) \quad 0 \leq s \leq 1, \quad (2)$$

worin  $s$  proportional zur Bogenlänge ist und  $x$  und  $y$  die Bildkoordinaten der Kurve bezeichnen. Die Gleichgewichtslage der Snake wird mit Hilfe der Energieminimierung formuliert. Hierfür wird die Gesamtenergie der Snake als Summe von innerer ( $E_{int}$ ) und äußerer Energie ( $E_{ext}$ ) beschrieben (siehe Formel (3)).

$$E_{snake} = \int_0^1 (E_{int} + E_{ext}) ds \quad (3)$$

Die innere Energie, oft formuliert als

$$E_{int} = (\alpha(s) | \mathbf{v}_s(s) |^2 + \beta(s) | \mathbf{v}_{ss}(s) |^2) / 2 \quad (4)$$

kontrolliert die Form der Snake. Der Term der ersten Ableitung kontrolliert die Spannung bzw. Längenänderung der Kurve. Die Biegung oder Krümmung der Kurve wird durch den Term der zweiten Ableitung kontrolliert. Die Parameter  $\alpha$  und  $\beta$  gewichten Spannung gegen Biegung.

Die äußere Energie, auch Bildenergie genannt, dient dazu, die Snake an die gesuchten Bildmerkmale anzupassen. Üblicherweise werden als Bildmerkmale Kanten oder Linien verwendet. Entsprechend den gesuchten Merkmalen wird die Bildenergie unterschiedlich definiert. Für die Anpassung der Snake an Linien kann die Bildfunktion direkt als Energieterm verwendet werden

$$\begin{aligned} E_{ext}^{helle\ Linie} &= -I(x, y) \quad bzw. \\ E_{ext}^{dunkle\ Linie} &= I(x, y) . \end{aligned} \quad (5)$$

Für Kanten, d.h. Bildbereiche mit hohem Grauwertgradienten, setzt man für die Bildenergie

$$E_{ext}^{Kante} = - | \nabla I(x, y) |^2 . \quad (6)$$

Als Bildfunktion wird entweder das originale Bild, oder meist besser ein mit einem Gauß-Filter geglättetes Bild verwendet (CANNY 1986).

Die Minimierung der Gesamtenergie, d.h. die Optimierung des Verlaufs der Snake, erfolgt oft iterativ mit Verfahren der Variationsrechnung. Bei diesem Optimierungsproblem handelt es sich um ein schlecht-gestelltes Problem, da es in der Regel verschiedene lokale Minima gibt und das globale Minimum nicht unbedingt der gesuchten Lösung entsprechen muss. Hieraus folgt, dass die Ausgangsposition der Snake möglichst nahe bei der Zielfunktion liegen sollte, um das gesuchte Minimum als Ergebnis zu erhalten. Detaillierte Darstellungen der analytischen Beschreibung sowie der Optimierungsverfahren für Snakes sind z.B. in (KASS et al. 1988, FUA und LECLERC 1990, LAPTEV 1997, MEIER 2000, KERSCHNER 2003) zu finden.

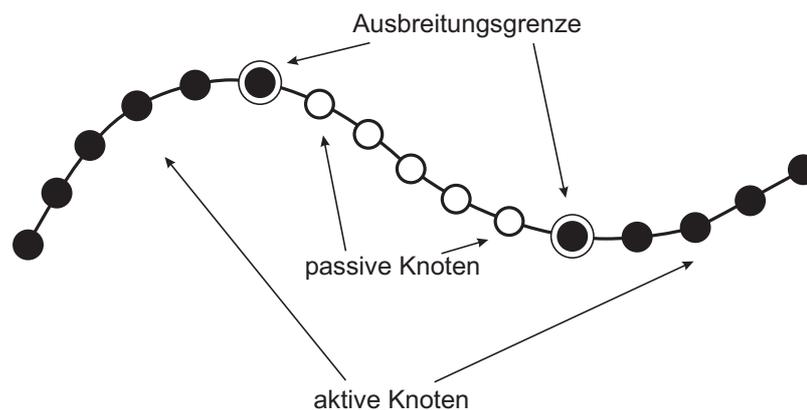


Abbildung 4. Prinzip der Energieoptimierung bei der Ziplock-Snake von außen nach innen: nur für die aktiven Knoten wird die Bildenergie berücksichtigt – nach (NEUENSCHWANDER 1996)

### Ziplock-Snakes

Wenn beide Endpunkte als richtig bekannt sind, kann, um Probleme, die bei einer schlechten Initialisierung durch die Vielzahl von möglichen Energieminimas auftreten können zu umgehen, die Snake von diesen aus optimiert werden. Hierfür wird die Snake in zwei aktive Teile und einen passiven Teil aufgeteilt. Eine Optimierung der Bildenergie erfolgt jeweils nur für die aktiven Teile, die passiven Teile steuern nur die innere Energie zur Gesamtenergie bei (siehe Abbildung 4). Durch eine iterative Verschiebung der Ausbreitungsgrenzen von außen nach innen werden auch die inneren Teile der Kurve an die Bildinformation angepasst. Diese Snake Variante wird nach (NEUENSCHWANDER et al. 1995) als Ziplock-Snake bezeichnet, da sie ähnlich einem Reißverschluss an die gesuchten Bildmerkmale herangezogen wird. Ein Beispiel für die Extraktion einer hellen Linie mittels einer Ziplock-Snake ist in Abbildung 5 zu sehen. Während eine normale Snake bei der gegebenen Initialisierung durch die Optimierung der Bildenergie entlang der gesamten Kurve sich nicht von den hellen Flächen rechts lösen könnte, wird die Ziplock-Snake von außen nach innen an die helle Linie herangezogen.

#### 2.3.3 Fuzzy-Sets

In der klassischen Mengenlehre kann ein Element nur entweder einer Menge angehören oder nicht, es gibt also nur die Zustände „wahr“ und „falsch“ aber keinen Zugehörigkeitsgrad zu einer bestimmten Menge. Anders verhält es sich bei der Fuzzy-Set (Fuzzy-Mengen) Theorie, bei der nicht mit

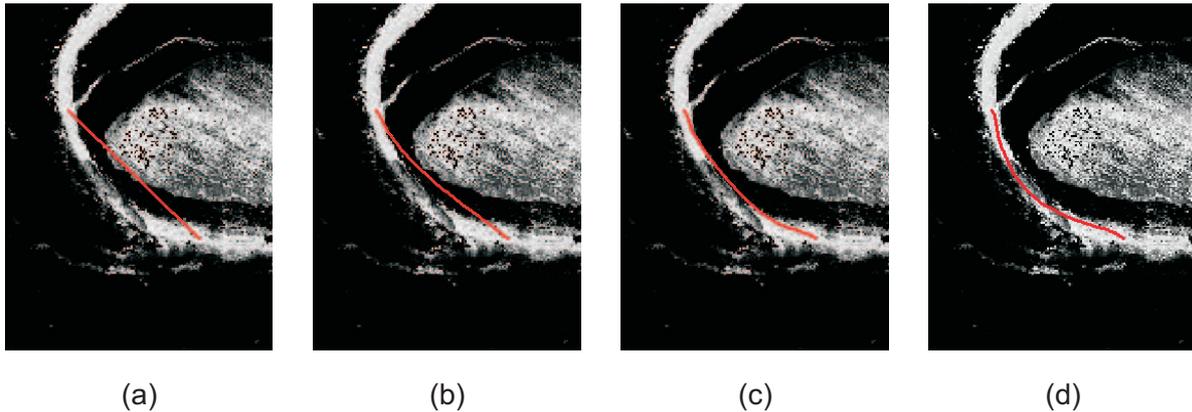


Abbildung 5. Optimierung einer Ziplock-Snake auf einer hellen Linie, hier Straße im Straßenklassenbild. (a) Initialisierung (b) und (c) Zwischenschritte (d) Ergebnis der Optimierung

strikter sondern mit unscharfer oder vager Logik gearbeitet wird. Damit ermöglicht die Fuzzy Logik die mathematische Formulierung unscharfer Begriffe, wie sie auch im normalen Sprachgebrauch verwendet werden. Beispiele für solche unscharfen Aussagen sind: Ein Mensch ist *sehr alt*, eine Stadt ist *groß* oder eine Straße ist *lang*.

Die Fuzzy-Set Theorie geht auf den Mathematiker Lofti Zadeh zurück (ZADEH 1965). Im Rahmen dieser Arbeit wird die Fuzzy-Set Theorie dazu verwendet, den Grad der Zugehörigkeit bestimmter Eigenschaften, wie z.B. Länge, Grauwert oder Kollinearität zu bestimmten Klassen, wie z.B. Straße, Straßenklasse oder Straßenabschnitt zu definieren.

Zum besseren Verständnis der Fuzzy-Set Theorie werden im Folgenden einige Definitionen eingeführt:

- (1)  $X$  sei eine Menge von Punkten (Objekten). Es gilt  $X = \{x\}$ .
- (2) Eine Fuzzy-Menge  $A$  aus  $X$  wird mit der Zugehörigkeitsfunktion (Membershipfunktion)  $\mu_A(x)$ , die jedem Element aus  $X$  einen Wert aus dem Intervall  $[0, 1]$  zuweist, beschrieben.
- (3) Der Wert von  $\mu_A(x)$  beschreibt den Grad der Zugehörigkeit von  $x$  zu  $A$ .

Als Zugehörigkeitsfunktion (siehe z.B. Abbildung 6) eignen sich möglichst einfache Funktionen, wie z.B. Trapez- oder Gauß-Funktionen, die durch wenige Parameter beschrieben werden können. Für das Zusammenführen unterschiedlicher Fuzzy-Mengen zu einer Gesamtmenge gibt es verschiedene Möglichkeiten, siehe z.B. (ZADEH 1989), von denen hier nur Vereinigung und Schnittmenge näher beschrieben werden, da nur diese im weiteren Verlauf der Arbeit genutzt werden.

**Vereinigungsmenge (ODER):** Die Vereinigung der Fuzzy-Mengen  $A$  und  $B$ ,  $A \cup B$  ist ebenfalls eine Fuzzy-Menge  $C$  und die Zugehörigkeitsfunktion  $\mu_C(x)$  ist gegeben durch:

$$\mu_C(x) = \mu_A(x) \vee \mu_B(x) = \mathbf{MAX}(\mu_A(x), \mu_B(x)) \quad (7)$$

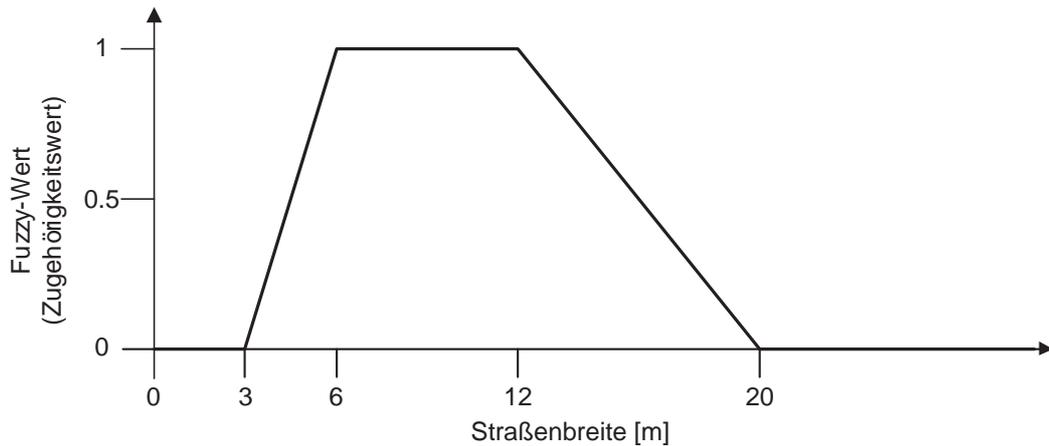


Abbildung 6. Beispiel einer Zugehörigkeitsfunktion für den Fuzzy Parameter Straßenbreite

**Schnittmenge (UND):** Die Schnittmenge der Fuzzy-Mengen  $A$  und  $B$ ,  $A \cap B$  ist ebenfalls eine Fuzzy-Menge  $C$  und die Zugehörigkeitsfunktion  $\mu_C(x)$  ist gegeben durch:

$$\mu_C(x) = \mu_A(x) \wedge \mu_B(x) = \mathbf{MIN}(\mu_A(x), \mu_B(x)) \quad (8)$$

#### 2.3.4 Netzwerkbildung – Globale Gruppierung

Ein Hauptproblem bei der automatischen Extraktion von Straßen aus Bildern besteht in der Unvollständigkeit der extrahierten Bildprimitive (STEGER et al. 1997), d.h. in Lücken. Diese treten in der Regel an Stellen auf, an denen das zu extrahierende Straßennetz, z.B. durch Änderung der spektralen Eigenschaften, Abschattung, Hindernisse oder nicht klar sichtbaren Straßenbegrenzungen, vom verwendeten, idealisierten Straßenmodell abweicht. Um die Lücken unter Berücksichtigung der globalen Netzwerkeigenschaften (MAYER 1998) von Straßen zu schließen, wird in dieser Arbeit der an der TU München (STEGER et al. 1997, WIEDEMANN 1999, WIEDEMANN und EBNER 2000, WIEDEMANN 2002) entwickelte Ansatz zur Vervollständigung von Straßennetzen verwendet. Dieser Ansatz lässt sich in zwei unabhängige Verfahren unterteilen:

**Netzwerkbildung** – Aus Straßenstücken wird ein gewichteter Graph aufgebaut und kleine Lücken werden ohne Bildinformation geschlossen.

**Globale Gruppierung** – Innerhalb des Netzwerkes werden Umwegfaktoren berechnet, auf dieser Grundlage werden mögliche Lücken im Straßennetz identifiziert, mit Hilfe von Bildinformation deren Straßenähnlichkeit, z.B. in Form von Linienhaftigkeit oder spektraler Signatur bestimmt, und diese damit verifiziert und gegebenenfalls geschlossen.

#### Netzwerkbildung

Bei der Bildung des Netzwerkes, die in Form des Aufbaus eines gewichteten Graphen erfolgt, bilden die Endpunkte der bewerteten Straßenstücke die Knoten und die Straßenstücke sowie die Verknüpfungen

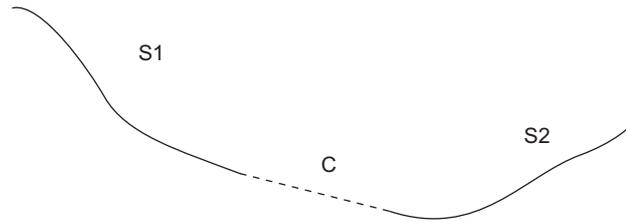


Abbildung 7. Die minimale Pfadlänge  $l_{min}$  setzt sich aus der Länge der beiden Straßensegmente S1 und S2 sowie der Länge des Verbindungsstückes C zusammen, d.h.  $l_{min} = l_{S1} + l_{S2} + l_C$  – nach (WIEDEMANN 2002).

zwischen ihnen, die eine bestimmte Länge nicht überschreiten, die Kanten. Für die Gewichtung des Graphen werden allen Kanten Kosten  $w_{i,j}$  entsprechend der Formel (9) zugewiesen.

$$w_{i,j} = \begin{cases} l_{i,j}/r_{i,j} & \text{für ein Straßensegment zwischen den Knoten } i, j \\ & \text{mit der Länge } l_{i,j} \text{ und der Bewertung } r_{i,j} > 0 \\ d_{i,j}/r_{i,j} & \text{für Verknüpfungshypothese zwischen den Knoten } i, j \\ & \text{mit dem euklidischen Abstand } d_{i,j} \text{ und der Bewertung } r_{i,j} > 0 \\ \infty & \text{sonst (d.h., es wird keine Kante in den Graphen eingefügt)} \end{cases} \quad (9)$$

Die Bewertung der Verknüpfungshypothesen ( $r_{i,j}$ ) erfolgt auf Grundlage folgender Kriterien mittels denen jeweils vorläufige Fuzzy-Werte (siehe Abschnitt 2.3.3) bestimmt werden:

- ◇ Richtungsdivergenz
- ◇ Absolute und relative Länge
- ◇ Ebenheit (wenn Höheninformation gegeben ist)
- ◇ Eine Verknüpfungshypothese darf keine bessere Bewertung erhalten als eines der beiden zu verknüpfenden Straßensegmente.

Die vorläufigen Fuzzy-Werte werden mit dem Fuzzy UND Operator zu einem Fuzzy-Wert vereinigt. Verknüpfungshypothesen werden als verifiziert angesehen, wenn sie auf dem global besten Pfad zwischen zwei Startsegmenten liegen. Startsegmente sind hierbei alle Straßensegmente, die eine bessere Bewertung als einen vorgegebenen Grenzwert haben. Zwischen Paaren von Startsegmenten wird jeweils mit Hilfe des Dijkstra Algorithmus (DIJKSTRA 1959) der optimale Pfad, d.h. der Pfad mit minimalen Kosten, bestimmt. Bei der Auswahl der Startsegmente wird die Funktion der Straßen, weit voneinander entfernte Orte zu verbinden, dadurch berücksichtigt, indem nur Punkte ausgewählt werden bei denen der resultierende Pfad eine Mindestlänge (siehe Abbildung 7) überschreitet. Eine Verifikation anhand der Bilddaten findet nicht statt. Daher wird dieses Verfahren meist lediglich für das Überbrücken kurzer Lücken verwendet.

## Globale Gruppierung

Auf Grund der Überbrückung nur kurzer Lücken ist das Ergebnis der Netzwerkbildung in der Regel unvollständig und weist noch Lücken auf. Um die verbleibenden Lücken zu schließen, wird in der vor-

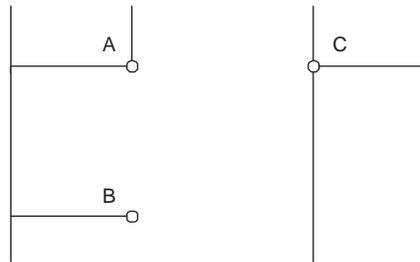


Abbildung 8. Kategorien von Lücken: Innerhalb von Zusammenhangskomponenten (A–B) und zwischen unterschiedlichen Zusammenhangskomponenten (A–C, B–C) – nach (WIEDEMANN 2002)

liegenden Arbeit der Ansatz von WIEDEMANN (2002) verwendet. Es wird zwischen zwei Kategorien von Lücken unterschieden (siehe Abbildung 8): (1) Lücken innerhalb von Zusammenhangskomponenten, d.h., topologisch zusammenhängenden Linien, und (2) Lücken zwischen unterschiedlichen Zusammenhangskomponenten. Der Ansatz lässt sich in die folgenden vier Arbeitsschritte unterteilen:

- ◇ Aufstellen von Verbindungshypothesen innerhalb von Zusammenhangskomponenten
- ◇ Generieren von Verbindungshypothesen zwischen unterschiedlichen Zusammenhangskomponenten
- ◇ Verifikation der Verbindungshypothesen
- ◇ Einfügen verifizierter Verbindungshypothesen

### Verbindungshypothesen innerhalb von Zusammenhangskomponenten

Fehlende Verbindungen im Netzwerk führen dazu, dass die Entfernung zwischen zwei Punkten, gemessen entlang der möglichen Verbindung innerhalb des Netzes, deutlich größer ist als die direkte (euklidische) Distanz zwischen den beiden Punkten (siehe Abbildung 9a – Verbindung zwischen A und D). Der Umweg, der sich durch die fehlende Verbindung ergibt, kann genutzt werden, um fehlende Teile zu lokalisieren. Hierfür werden vorläufige Verbindungshypothesen zwischen jedem Knotenpaar des Netzes definiert und jeweils Umwegfaktoren entsprechend Formel (10) berechnet (siehe auch Abbildung 9c).

$$\text{Umwegfaktor} = \frac{\text{Netzwerkentfernung}}{\text{optimaleEntfernung}} \quad (10)$$

Die Verbindungshypothesen mit lokal maximalen Umwegfaktoren werden übernommen und nach der Größe des Umwegfaktors sortiert. Die Verbindungshypothese mit dem höchsten Umwegfaktor wird an ein Modul zur Verifikation der Verbindung (s.u.) übergeben. Bei Ablehnung wird die Verbindung aus der Liste gestrichen und die nachfolgende an das entsprechende Modul übergeben. Wird eine Verbindung akzeptiert, so muss der gesamte Arbeitsschritt, von der Berechnung der Verbindungshypothesen an, von vorne begonnen werden. Das iterative Vorgehen bricht ab, wenn keine weiteren Verbindungshypothesen vorliegen.

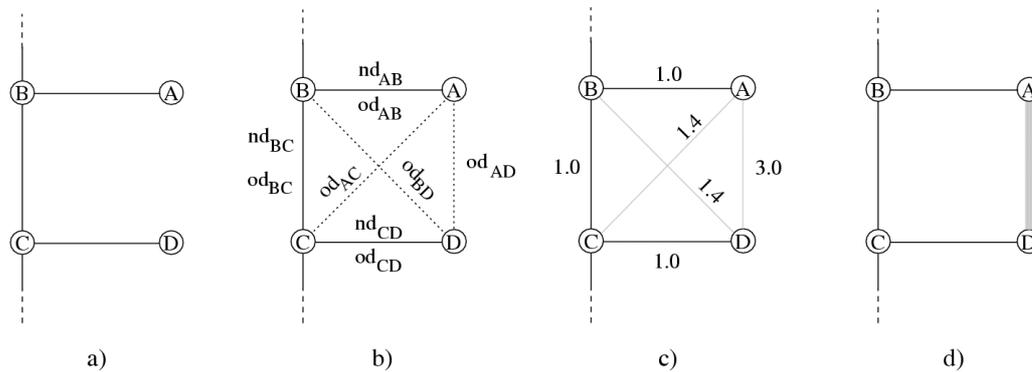


Abbildung 9. Generierung von Verbindungshypothesen innerhalb von Zusammenhangskomponenten: a) Netzwerk; b) Netzwerk Entfernungen (nd) und optimale Entfernungen (od); c) Umwegfaktoren; d) Verbindungshypothese – aus (WIEDEMANN 2002)

### Verbindungshypothesen zwischen unterschiedlichen Zusammenhangskomponenten

Die im vorangegangenen Abschnitt vorgestellte Methode kann nicht für unterschiedliche Zusammenhangskomponenten eingesetzt werden, da hier zwischen zwei Punkten kein Pfad entlang des bestehenden Netzwerkes existiert (siehe Abbildungen 8 und 10). Das von WIEDEMANN (2002) vorgeschlagene Verfahren benutzt deshalb statt des Umwegfaktors den nach Formel (11) berechneten Verbindungsfaktor.

$$\text{Verbindungsfaktor} = \frac{l}{\text{optimaleEntfernung}} \quad (11)$$

wobei

$$l = l_i \cdot l_j \quad \text{mit} \quad l_i, l_j = \text{Gesamtlänge der Zusammenhangskomponente } i \text{ bzw. } j$$

Der Verbindungsfaktor wird bei der weiteren Verarbeitung wie der im vorangegangenen Abschnitt genutzte Umwegfaktor verwendet. Der Verbindungsfaktor mit dem höchsten Wert wird an ein Verifikationsmodul (s.u.) übergeben. Kann die Verbindungshypothese verifiziert werden, so wird sie in das bestehende Netzwerk eingefügt, andernfalls wird die Hypothese mit dem nächst höheren Verbindungsfaktor an das Verifikationsmodul übergeben. Die Einfügung einer Verbindungshypothese in das Netzwerk resultiert in einer Änderung der gesamten Netzwerktopologie und führt zu einer neuen Iteration, d.h. es werden zuerst Verbindungshypothesen innerhalb von Zusammenhangskomponenten gesucht und dann erneut zwischen Zusammenhangskomponenten. Der Prozess wird beendet wenn keine neuen Verbindungshypothesen zwischen Zusammenhangskomponenten mehr gefunden werden können.

### Verifikation von Verbindungshypothesen

Die in den beiden vorangegangenen Abschnitten aufgestellten Verbindungshypothesen geben einen Hinweis auf das Vorhandensein einer Verbindung allein aufgrund der Netzwerkeigenschaften. D.h., es werden Punkte angezeigt, zwischen denen eine Verbindung zu erwarten ist bzw. sinnvoll wäre. Auf-

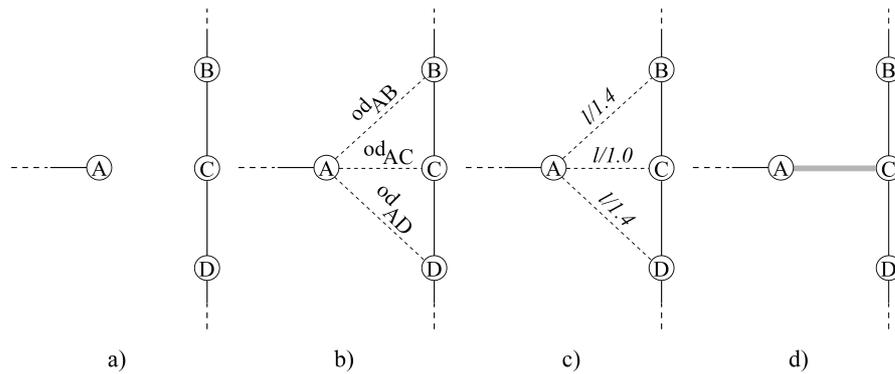


Abbildung 10. Generierung von Verbindungshypothesen zwischen unterschiedlichen Zusammenhangskomponenten: a) Netzwerk; b) Optimale Entfernungen; c) Verbindungsfaktoren für alle vorläufigen Verbindungshypothesen ( $l = l_i \cdot l_j$ ); d) Verbindungshypothese – aus (WIEDEMANN 2002)

grund verschiedener Faktoren, wie z.B. Topographie, Landnutzung oder Besitzverhältnissen, folgt die Realisierung von Straßenbauten nicht immer den vereinfachenden Kriterien für optimale Verbindungen. Hieraus folgt die Notwendigkeit, die ermittelten Verbindungshypothesen anhand der Bilddaten zu verifizieren. Hierfür kann jeder Ansatz verwendet werden, der in der Lage ist, eine Straße zwischen zwei gegebenen Bildpunkten zu extrahieren und zu bewerten, ob die gefundene Verbindung in das bestehende Netzwerk eingefügt oder verworfen werden soll.

### Einfügen verifizierter Verbindungshypothesen

Bei einer gefundenen und verifizierten Verbindungshypothese werden zuerst redundante Teilstücke entfernt. Das verbleibende Teilstück wird dann mit den am nächsten gelegenen Punkten des bestehenden Netzwerkes verbunden. Wenn einer der bestehenden Punkte kein Endpunkt einer Linie ist, wird an der betreffenden Stelle eine zusätzliche Kreuzung eingefügt.

### 3 Straßenextraktion – Stand der Wissenschaft

Einen ausführlichen Überblick über aktuelle Ansätze zur Straßenextraktion bzw. zur Extraktion von linearen Strukturen geben verschiedene Übersichtsarbeiten. In (QUACKENBUSH 2004) werden Ansätze zur Extraktion von linienhaften Objekten aus Bildern mit einem Schwerpunkt auf der Straßenextraktion untersucht. Die Ansätze werden entsprechend der verwendeten Techniken, mathematische Morphologie, Hough Transformation, Multi-Skalen, Template Zuordnung, dynamische Programmierung, Pixel Swapping, Wissensintegration, Klassifikation sowie sonstige, eingeteilt. Die verwendeten Techniken werden ohne Wertung kurz beschrieben. Einen umfassenden Überblick über den Einsatz von Wissen für die Objektextraktion wird in (BALTSAVIAS 2004) gegeben. Für die Extraktion von Straßen und Gebäuden werden Möglichkeiten der Wissensrepräsentation vorgestellt und es wird ein umfassender Überblick über die relevante Literatur gegeben. Weiterhin wird die Nutzung von bestehenden Geodaten als Basis für eine Extraktion oder eine „Entgeneralisierung“ anhand von Bilddaten dargestellt. Die Arbeit zeigt darüber hinaus, wie der Weg hin zu operationellen Systemen aussehen könnte und welche Fortschritte in den vergangenen Jahren erzielt wurden. Der aktuelle Stand der Forschung auf dem Gebiet der automatischen Extraktion von Straßen aus Luft- und Satellitenbildern wird in (MENA 2003) dargestellt. In einem ausführlichen Literaturüberblick mit mehr als 200 Referenzen werden die bestehenden Ansätze entsprechend der speziellen Ziele, der verwendeten Methoden sowie der genutzten Datenquellen eingeteilt. Die große Zahl an verwandten Arbeiten zeigt die Bedeutung des Forschungsbereichs ebenso wie eine Auflistung der an der Thematik weltweit forschenden Arbeitsgruppen. Ein weiterer kompakter Überblick über die wichtigsten Arbeiten der Straßenextraktion aus Luft- und Satellitenbildern wird in (AUCLAIR-FORTIER et al. 2000) gegeben.

Die Ansätze zur automatischen Straßenextraktion werden in dieser Arbeit entsprechend der verwendeten Bilddaten gruppiert. Die Einteilung erfolgt zunächst nach der Auflösung der verwendeten optischen Bilddaten von Luftbildern (siehe Abschnitt 3.1) über höchst aufgelöste Satellitenbilddaten (siehe Abschnitt 3.2) hin zu Satellitenbilddaten hoher und mittlerer Auflösung (siehe Abschnitt 3.3). Ergänzt wird die Übersicht mit Arbeiten zur Straßenextraktion aus Radar- und Laserdaten (siehe Abschnitt 3.4) sowie der Fortführung und Überprüfung von bestehenden Straßendatenbasen (siehe Abschnitt 3.5). Die Auswahl der vorgestellten Ansätze erfolgt entsprechend deren Neuheit und der Relevanz für die vorgelegte Arbeit. Bezüglich weiterer Arbeiten sei auf die oben vorgestellten Übersichtsarbeiten verwiesen. Die Arbeiten zur Straßenextraktion aus Luftbildern, Satellitenbilddaten mittlerer Auflösung sowie aus Daten aktiver Systeme verwenden ähnliche Modelle, Strategien oder Techniken wie die Ansätze der vorgelegten Arbeit. Ein weiterer Aspekt für die Behandlung ausgewählter Ansätze ist die Komplementarität, d.h. z.B. die Erweiterung der in dieser Arbeit entwickelten Strategie auf ergänzende Kontextgebiete, wie z.B. Städte (HINZ 2003, CLODE et al. 2004). Für eine bessere Übersicht der wichtigsten Arbeiten zur Straßenextraktion wurden Tabellen, geordnet nach der Auflösung der verwendeten Bilddaten (siehe Tabelle 3 und Tabelle 5) und nach den für die Extraktion verwendeten Techniken (siehe Tabelle 4), erstellt.

#### 3.1 Luftbilder

Wegweisende Ideen für die Straßenextraktion wurden in (FISCHLER et al. 1981) vorgeschlagen. Der dort vorgestellte Ansatz nutzt Luftbilder niedriger Auflösung. Die primäre Aufgabe ist es, zwischen

Datenquelle Auflösung [m]	Luftbilder		Satellitenbilder		Radar	LIDAR
	0.05 – 0.3	0.3 – 1	0.5 – 2	2 – 15	1 – 2	
Ansatz						
(FISCHLER et al. 1981)		x				
(HINZ 2003, HINZ und BAUMGARTNER 2003)	x					
(RUSKONÉ et al. 1994, RUSKONÉ 1996)	x	x				
(BAUMGARTNER et al. 1999, BAUMGARTNER 2003)		x				
(GRÜN und LI 1997)		x	x	x		
(HU und TAO 2004)		x	x			
(DOUCETTE et al. 2001, DOUCETTE et al. 2004)			x			
(SHI und ZHU 2002)			x			
(AMINI et al. 2002)			x			
(MOHAMMADZADEH et al. 2004)			x			
(KEATON und BROKISH 2002)			x			
(GIBSON 2003)			x			
(SONG und CIVCO 2004)			x			
(DAL POZ und DO VALE 2003, DAL POZ et al. 2004)		x	x			
(ÜNSALAN und BOYER 2005)			x			
(MENA und MALPICA 2005)			x			
(WIEDEMANN et al. 1998, WIEDEMANN 2002)			x	x		
(ZHANG und COULOIGNER 2004b)			x	x		
(GEMAN und JEDYNAK 1996)				x		
(STOICA et al. 2004)		x	x	x	x	
(WESSEL 2004)					x	
(CLODE et al. 2004)						x

Tabelle 3. Ansätze zur automatischen Straßenextraktion und genutzte Sensoren

zwei Punkten, die sicher auf einer Straße liegen, eine optimale Verbindung zu bestimmen. Hierfür werden zwei Typen von Operatoren für die Liniextraktion verwendet. Typ I Operatoren extrahieren Straßen mit sehr hoher Sicherheit mit dem Nachteil, dass kein vollständiges Ergebnis geliefert wird. Die Operatoren vom Typ II extrahieren dagegen die Straßen mit sehr hoher Vollständigkeit, produzieren jedoch z.T. viele falsche Ergebnisse. Die Strategie für die Pfadsuche besteht darin, zunächst aus den Ergebnissen der Typ I Operatoren Liniencuster zu bilden, die mit Hilfe der Ergebnisse der Typ II Operatoren verdichtet werden. Verfeinerte Weiterentwicklungen des Ansatzes auch für Bilddaten höherer Auflösung sind in (FISCHLER 1994, HELLER et al. 1998) zu finden.

Der in (HINZ 2003, HINZ und BAUMGARTNER 2003, HINZ 2004) vorgestellte Ansatz zur Extraktion urbaner Straßennetze aus höchstauflösten Luftbildern basiert in hohem Maße auf der expliziten Formulierung und anschließenden Nutzung von Modellwissen über Straßen in urbanen Gebieten sowie des lokalen und globalen Kontextes in ihrem Umfeld. Die verwendete Strategie gliedert sich in drei Phasen: In der ersten Phase wird der globale sowie der lokale Kontext untersucht, um den Suchraum einzuschränken. Hierzu werden aus einem Digitalen Oberflächenmodell (DOM) Täler extrahiert, die als potentielle Straßenhypothesen dienen. Zusätzlich werden DOM-Regionen segmentiert, die lokal starke Höhendifferenzen aufweisen und als Ausschlussregionen nicht mehr weiter verarbeitet werden. Automatisch extrahierte Fahrzeuge und Fahrzeugkolonnen dienen als zusätzliche Evidenz für Straßen.

Die zweite Phase startet mit der Detektion von homogenen Bändern in einem auflösungsreduzierten Bild sowie von Straßenmarkierungen in den Bilddaten mit höchster Auflösung. Durch Gruppierung werden aus diesen Eingangsdaten Fahrbahnen sowie Fahrspuren generiert. Das Ziel der dritten Phase ist es, aus den Fahrbahnen und Fahrspuren ein Straßennetz aufzubauen. Eine Stärke des Ansatzes ist die Nutzung von interner Bewertung von Extraktionsergebnissen, wodurch nach (HINZ und WIEDEMANN 2004) die Effizienz der Straßenextraktion gesteigert wird, indem auf die Erfolg versprechendsten Hypothesen fokussiert wird.

(RUSKONÉ et al. 1994, RUSKONÉ 1996) schlagen einen Ansatz zur Interpretation von Straßennetzen aus hochaufgelösten Luftbildern vor. Er startet mit der Bestimmung lang gestreckter homogener Flächen mittels einer Wasserscheidentransformation im Gradientenbild. Diese werden als sichere Straßenstücke betrachtet und dienen im Folgenden als Startstücke. Ausgehend von ihnen wird eine Straßenverfolgung durchgeführt, welche die Homogenität entlang des Straßenverlaufs und begrenzende parallele Kanten als Evidenz für Straßen nutzt. Aus den so gefundenen Straßenstücken wird ein topologisch korrektes Netzwerk aufgebaut. Hierfür werden benachbarte kollineare Straßenstücke in einem iterativen Prozess miteinander verknüpft. Die Überprüfung der Konsistenz der Verknüpfungen erfolgt anhand der Netzwerkeigenschaften.

(MAYER et al. 1997, BAUMGARTNER et al. 1999, BAUMGARTNER 2003) verwenden ein explizit beschriebenes Objektmodell für die vollständig automatische Extraktion von Straßen. Der Ansatz nutzt das Maßstabsverhalten von Straßen sowie globale Kontexte, d.h. Eigenschaften größerer Regionen, wie z.B. offenes Gelände, Siedlung, Wald und lokale Kontexte, d.h. Beziehungen zwischen Straßen und anderen Objekten, für die Extraktion. Auf Grundlage von Texturklassifikation wird das Bild in globale Kontexte unterteilt. Die folgende Straßenextraktion beschränkt sich daraufhin auf die Erfolg versprechendsten Gebiete, die im Bereich der (offenen) Landschaft liegen. Es werden Kanten im ursprünglichen Bild (Pixelgröße 0.2 m bis 0.5 m) und Linien im auflösungsreduzierten Bild (Pixelgröße 2 m bis 4 m) extrahiert. Auf Grundlage beider Auflösungsstufen werden Hypothesen für Straßenabschnitte gebildet und mit einem iterativen Verfahren zu langen Verbindungen gruppiert. Zum Schließen von verbleibenden Lücken werden neben Gruppierung auch so genannte „Ribbon-Snakes“ (LAPTEV 1997, MAYER et al. 1998) und Wissen über den lokalen Kontext genutzt. Durch die Verwendung unterschiedlicher Auflösungsstufen und die explizite Modellierung von Kontext ist es mit diesem Ansatz möglich, Störungen im Straßenverlauf, wie z.B. durch Fahrzeuge oder Schatten, zu überbrücken.

In (GRÜN und LI 1997) wird ein halbautomatischer Ansatz zu Extraktion von linienhaften Objekten vorgeschlagen. Es wird die Stärke eines Auswerters für die Interpretation des Bildes genutzt, indem der grobe Verlauf des gesuchten Objekts digitalisiert wird. Der exakte Verlauf wird dann mittels dynamischer Programmierung und LSB-Snakes (Least-Squares B-Spline Snakes) automatisch optimiert. Das Verfahren eignet sich für die Extraktion unterschiedlichster linienhafter Objekte, wie z.B. Straßen, Flüsse oder Bildkanten, in Bilddaten unterschiedlicher Auflösung.

Ein Verfahren zur Verknüpfung verstreuter Straßenprimitive wird in (HU und TAO 2004) vorgeschlagen. Ziel des Verfahrens ist die Extraktion von Autobahnen aus hochaufgelösten Bilddaten. Die Methode nutzt einen Ansatz zur perzeptuellen Gruppierung basierend auf Energieminimierung. Als primäre Hinweise auf die Existenz von Straßen dienen Straßenmarkierungen. Der iterative Prozess fügt schrittweise Straßenprimitive zu längeren gekrümmten Straßenachsen zusammen. Die Straßenachsen entsprechen den optimalen Pfaden, die das Energieminimierungsprinzip erfüllen. Experimente

zeigen, dass mit dem Ansatz bruchstückhafte Primitive zuverlässig zu Autobahnspuren zusammengefügt werden können.

### 3.2 Höchstaufgelöste Satellitenbilddaten

Höchstaufgelöste Satellitenbilddaten stehen seit dem Start von IKONOS-2 im Jahre 1999 fast weltweit zur Verfügung (siehe Abschnitt 2.1). Die Daten können zeitnah, wenn auch mit erheblichen Kosten, beschafft werden und sind somit eine gute Grundlage für die Erfassung und Fortführung von Straßendaten. Die Bedeutung und Eignung der höchstaufgelösten Daten zeigt sich in der stark zunehmenden Zahl an Forschungsarbeiten auf dem Gebiet der Straßenextraktion, die diese Daten als Grundlage nutzen. Die im Vergleich zu (analogen) Luftbildern schlechtere räumliche, aber erheblich verbesserte radiometrische Auflösung inklusive von vier spektralen Kanälen, führt zu einer Neuausrichtung in der Straßenextraktion hin zu einer stärkeren Nutzung der spektralen Information.

In (DOUCETTE et al. 2001) wird ein halbautomatischer Ansatz für multispektrale Bilddaten mit einer Auflösung von etwa 1 m vorgestellt. Die halbautomatische Komponente besteht in der Klassifikation der Bilddaten in die Objektklassen Straße und Nicht-Straße (Hintergrund). Das Klassifikationsergebnis dient als Grundlage für die eigentliche Extraktion von Straßen, die bei der verwendeten Auflösung als lang gezogene schmale Flächen erscheinen. Der Ansatz extrahiert Straßen unabhängig von Kanten- und Linieninformationen durch Nutzung der so genannten „selbstorganisierenden Straßenkarte“ (SORM – self-organising road map), die eine spezielle Variante von Kohensens self-organising map (SOM) neuronalem Netz darstellt. Die SORM kombiniert k-median Cluster mit einem minimum spanning tree (MST) zur Verbindung von Knoten. Ein Vorteil des Ansatzes ist die Möglichkeit, Straßenbereiche, die durch Störobjekte unterbrochen sind, überbrücken zu können. Eine Weiterentwicklung stellt der in (DOUCETTE et al. 2004) beschriebene automatische Ansatz dar, bei dem eine iterative selbstüberwachte Bayesian Maximum Likelihood Klassifizierung verwendet wird. Trainingsgebiete für die Straßenklasse werden aus einer  $3 \times 3$  Umgebung um die Knoten eines vorläufigen Straßennetzwerkes extrahiert, die für die Hintergrundklassen stammen aus einer unüberwachten Klassifizierung. Die Ergebnisse für Bilddaten aus städtischen Regionen zeigen die große Bedeutung der radiometrischen Information für die Straßenextraktion aus höchstaufgelösten Satellitenbilddaten.

Für städtische Gebiete geringerer Komplexität eignet sich der von SHI und ZHU (2002) vorgeschlagene automatische Ansatz zur Straßenextraktion. Mit der „Line Segment Match Method“ wird ein grobes Straßennetz detektiert, das mittels morphologischer Operatoren verdichtet wird. Die Straßenpixel erhält man durch Ausdünnung des pixelbasierten Straßennetzes. (AMINI et al. 2002) präsentieren einen auf Fuzzy Logic basierenden Ansatz für multispektrale IKONOS Satellitenbilddaten. Ausgehend von einer Histogramm Analyse der Bilddaten werden für die Objekte Gaußsche Zugehörigkeitsfunktionen aus den Mittelwerten und Standardabweichungen für die Objektklassen abgeleitet. Die Straßenpixel werden mittels Fuzzy Logic klassifiziert. Die Vektorisierung der Straßenpixel erfolgt durch Skelettierung der Rasterdaten. Ein ähnlicher, Fuzzy-basierter Ansatz für linienhafte Objekte in Wüstengebieten, wurde von MOHAMMADZADEH et al. (2004) vorgeschlagen.

(KEATON und BROKISH 2002) verwenden Level Sets für die halbautomatische Extraktion von Straßen aus pan-sharpened multispektralen IKONOS Daten. Ausgehend von einem manuell vorgegebenen Startpunkt werden diese für das Wachsen der Straßenregion genutzt. Als Parameter gehen Vegeta-

tionsindex, Wasserindex, spektrale und textuelle Ähnlichkeit mit dem Startpunkt sowie der lokale Gradient des Bildes ein. Aus der so gewonnenen und geglätteten Region wird mittels Skelettierung die Straßenachse bestimmt. Aufgrund der pixelbasierten Arbeitsweise beeinflusst die Form der zu extrahierenden Straßen das Ergebnis nicht.

In (GIBSON 2003) wird ein Ansatz zur Extraktion von Straßennetzen aus IKONOS Satellitenbildern vorgeschlagen. Von zentraler Bedeutung ist die Organisation der Daten in so genannten „Generalized Balanced Ternary“ (GBT), einer hexagonalen Kachelung der Bildebene. Drei Detektoren (1) Texturbasiert (2) Kanten-basiert und (3) die multispektralen Eigenschaften ausnützend, werden verwendet, um einer Kachel in verschiedenen Maßstäben Straßenausprägungen zuzuweisen. Aus den Kacheln, die der Straßenklasse zugewiesen wurden, werden Ketten gebildet, die zu einem topologischen Straßennetz erweitert werden. Den Abschluss bildet die Transformation der Hexagonketten in „Vector Shapefiles“. Der Ansatz ist für amerikanische Kleinstädte und Vororte niedriger bis mittlerer Komplexität konzipiert.

Ein halbautomatischer Ansatz für multispektrale IKONOS Bilddaten wird in (SONG und CIVCO 2004) vorgestellt. Basierend auf manuell definierten Trainingsgebieten werden die Bilddaten mittels einer „Support Vector Machine“ (SVM) in Straße und Nicht-Straße klassifiziert. Es wird gezeigt, dass die Klassifikation von Straßen mittels SVM gegenüber der Gaußschen Maximum Likelihood Klassifikation vorteilhaft ist. Das so genannte „Road Group Image“ wird mit starker Gewichtung von Form-Parametern, d.h. Straßen sind lang gestreckte, schmale Regionen mit nur kleinen Krümmungsänderungen, segmentiert. Die einzelnen Segmente werden bewertet und mittels Schwellwertbildung werden diejenigen herausgefiltert, die Straßeneigenschaften besitzen. Den Abschluss bildet die Vektorisierung der binären Rasterdaten, mittels morphologischer Verdünnung. Eine Netzbildung findet nicht statt.

Von Dal Poz et al. wurden zwei Ansätze zur Extraktion von Straßen bzw. Straßensegmenten aus höchst aufgelösten Satellitenbilddaten und Luftbildern geringer Auflösung vorgeschlagen. In (DAL POZ und DO VALE 2003) extrahieren Straßen mittels dynamischer Programmierung halbautomatisch. Startpunkte werden manuell entlang des Straßenverlaufs vorgegeben. Die Grundlage der Optimierung der so genannten „merit function“ bildet das Straßenmodell, das Straßen in der betrachteten Auflösung als lang gezogene Bänder mit lokal konstanter Breite modelliert, die durch anti-parallele Kanten begrenzt werden. Der zweite Ansatz (DAL POZ et al. 2004) beschreibt einen Ansatz zur Generierung von Straßensegmenten. Es werden zuerst Kanten extrahiert und auf Parallelität überprüft. Für parallele Kantenpaare, die nahe genug beieinander liegen, werden mit Hilfe der Senkrechten an den Endpunkten Flächen gebildet. Die Flächen müssen verschiedene Kriterien, wie z.B. einen homogenen Grauwert und hohen Kontrast zur Umgebung erfüllen, um als Straßensegmente verifiziert zu werden. Aus den Segmenten werden Straßen gebildet, indem sie nach verschiedenen Regeln gruppiert werden.

(ÜNSALAN und BOYER 2005) stellen einen Ansatz zur Detektion von Straßen und Häusern in amerikanischen Vorstädten aus multispektralen IKONOS Bilddaten vor. Die spektrale Information der Bilddaten wird dazu genutzt, um mittels des normalisierten Vegetationsindex Gebiete menschlicher Aktivität zu klassifizieren. Zusätzlich werden Gewässer und Schatten mit Hilfe eines Wasser-Schatten-Indexes lokalisiert. Ergebnis der Segmentierung des Vegetationsindexes ist ein Binärbild, in dem möglichst ausschließlich Straßen und Gebäude vorhanden sind. Ein so genannter „Ballon Algorithmus“ dient dazu, das Binärbild in Segmente zu unterteilen, die anhand ihrer Form, d.h. Kompaktheit und Größe,

entweder als Straßensegment, Haus oder Störobjekt klassifiziert werden. Abschließend werden die Störobjekte eliminiert und aus den Straßensegmenten mit Hilfe eines graphentheoretischen Ansatzes ein Straßennetz aufgebaut.

In (MENA und MALPICA 2005) wird eine Methode zur automatischen Straßenextraktion in der offenen Landschaft und in Vororten vorgestellt. Im ersten Schritt wird die so genannte „Texture Progressive Analysis“ (TPA) verwendet, um aus dem Eingabebild ein segmentiertes Binärbild zu erhalten. Die TPA vereinigt drei verschiedene Informationsquellen mittels der Evidence Theory. Das resultierende Binärbild wird im zweiten Schritt mittels Skelettierung in einen Vektordatensatz gewandelt.

### 3.3 Satellitenbilddaten hoher und mittlerer Auflösung

Die Auflösungen von Satellitenbilddaten hoher bis mittlerer Auflösung liegen im Bereich 5 m und schlechter, d.h. im Grenzbereich der Straßenextraktion. Deswegen hat sich der Fokus der aktuellen Forschung in Richtung höchstauflösender Satellitenbilddaten verschoben. Die geringe Zahl an aktuellen Arbeiten für hohe und mittlere Auflösungen belegt diese Neuausrichtung.

Der in (WIEDEMANN et al. 1998, WIEDEMANN 2002) vorgestellte Ansatz bildet die Grundlage der vorgelegten Arbeit. Details des Ansatzes werden in verschiedenen Abschnitten der vorgelegten Arbeit näher erläutert. Die Grundidee besteht in der Extraktion von linienhaften Objekten, die anhand geometrischer Merkmale bewertet werden. Aus den bewerteten Linienstücken wird ein gewichteter Graph aufgebaut, aus dem das Straßennetz abgeleitet wird. Verbleibende Lücken werden im Rahmen einer globalen Gruppierung überbrückt, bei der die Verbindungsfunktion des Netzwerkes ausgenutzt wird (siehe Abschnitte 2.3.1 bzw. 2.3.4).

Ein Ansatz zur Multi-Skalen Analyse für Satellitenbilddaten mit einer Auflösung zwischen 1 m und 6 m wird in (ZHANG und COULOIGNER 2004b) präsentiert. Um die Bilddaten in unterschiedliche Maßstäbe zu überführen, wird eine Wavelet Transformation auf den originalen Bilddaten durchgeführt. Ausgehend von der Analyse deren Charakteristik werden Kreuzungen innerhalb der Wavelet Repräsentation extrahiert. Ebenfalls in der Wavelet Repräsentation werden die Straßenmittelachsen beginnend an den Kreuzungen verfolgt. Das Straßennetz wird zuletzt mittels Gruppierung erzeugt.

(GEMAN und JEDYNAK 1996) schlagen für die zuverlässige Verfolgung von Hauptstraßen in SPOT Daten mit einer Bodenauflösung von 10 m ein „active testing model“ vor. Der Ansatz hat das Ziel, die richtigen Fragen in der richtigen Reihenfolge zu stellen, wofür die „divide and conquer“ Strategie verwendet wird. Unter „Fragen“ wird das Aufstellen von Hypothesen verstanden und die Antworten sind die Ergebnisse von Tests, die zeigen, ob die aufgestellten Hypothesen zutreffen oder nicht. Die Tests werden sequentiell durchgeführt, wobei die Auswahl des Folgetests vom Ausgang des aktuellen Tests abhängt. Für die Extraktion der Straßenhypothesen werden einfache Bildverarbeitungsoperatoren eingesetzt. Die gefundenen linienhaften Strukturen werden mit dem beschriebenen rekursiven Tests zu längeren Strukturen verbunden. Es werden teilweise mehrere Suchpfade gleichzeitig verfolgt, bis zuletzt derjenige mit der geringsten Unsicherheit ausgewählt wird.

In (STOICA et al. 2004, LACOSTE et al. 2005) wird eine objektorientierte Methode zur Straßenextraktion aus verschiedensten Fernerkundungsdaten, wie z.B. Luftbilder, Satellitenbilddaten oder Radardaten, vorgestellt. Sie basiert auf der Annahme, dass Straßen ein Netzwerk aus verbundenen

Linienstücken bilden. Für die Konstruktion solcher Netzwerke wird ein statistischer Punktprozess vorgeschlagen, der Netzwerke sowohl simulieren als auch erkennen kann. Die Bestimmung des Netzwerkes erfolgt durch Minimierung einer Energie Funktion unter Verwendung von „Simulated Annealing“ basierend auf „Reversible Jump Markov Chain Monte Carlo“ (RJMCMC). Dieser Ansatz ist sehr rechenintensiv kann aber sehr einfach auf andere netzwerkbildende Objekte, wie z.B. verzweigte Flussläufe, erweitert werden.

### 3.4 Radar- und Laserdaten

Neben passiven bildgebenden Systemen werden für die Straßenextraktion auch die Daten aktiver Systeme in Form von Radar und flugzeuggetragene Laserscanner genutzt.

In (WESSEL 2004) wird ein Ansatz für SAR (Synthetic Aperture Radar) Bilddaten vorgestellt, der ebenso wie die vorgelegte Arbeit auf dem in (WIEDEMANN 2002) beschriebenen Ansatz basiert. Wie in (BAUMGARTNER 2003) werden die Bilddaten zuerst in globale Kontextgebiete unterteilt (siehe auch Abschnitt 3.1) und die weitere Verarbeitung wird auf offenes Gelände beschränkt. Die eigentliche Extraktion beruht auf der Linienhaftigkeit von Straßen und nutzt den Steger Liniextraktor (siehe Abschnitt 2.3.1) zusammen mit (manuell) extrahierter lokaler Kontextinformation, wie z.B. Fahrzeuge, Bäume, Kreuzungen oder Brücken, durch die die Evidenz von Straßen verstärkt wird. Eine spezielle Strategie wird für die Extraktion von Autobahnen vorgeschlagen. Die Bilder werden hierbei in unterschiedlichen Maßstäben betrachtet. Im groben Maßstab, mit einer Bodenauflösung von etwa 6 m, wird die Autobahn als breite dunkle Linie abgebildet. Im feineren Maßstab mit einer Bodenauflösung zwischen 1 m und 2 m erscheinen dagegen die einzelnen Fahrbahnen als getrennte dunkle Linien mit den Leitplanken als schmale helle Linie dazwischen. Zusätzliche lokale Kontextinformation, wie z.B. große Wegweiser oder Brücken, unterstützen die Extraktion. Eine Netzbildung erfolgt durch Bildung eines gewichteten Graphen (siehe auch Abschnitt 2.3.4).

Ein Ansatz für die Straßenextraktion aus Laserscannerdaten wird in (CLODE et al. 2004) vorgestellt. Er nutzt sowohl die vom Laserscanner gelieferten Höhen- als auch die Intensitätswerte, um im Rahmen einer hierarchischen Klassifikation die Bildpunkte den Klassen Straße und Nicht-Straße zuzuweisen. Aus dem erfassten „last pulse“ DOM wird mit Hilfe von morphologischen Operatoren ein DGM (Digitales Geländemodell) generiert. Als potentielle Straßenpunkte werden Punkte ausgewählt, bei denen der Höhenunterschied zwischen DGM und DOM kleiner als ein gegebener Schwellwert bleibt. In einem nächsten Schritt wird die Nachbarschaft der ausgewählten Pixel betrachtet wobei Straßenpixel sich dadurch auszeichnen, dass innerhalb eines Kreises um die betrachteten Pixel eine Mindestanzahl weiterer Straßenpixel vorhanden ist. Aus diesem vorläufigen Ergebnis wird ein Binärbild erzeugt, aus dem mittels morphologischem Closing die Straßen generiert werden.

### 3.5 Fortführung von Straßendatenbasen

Neben der Neuerfassung von Straßen und Straßennetzen ist die Überprüfung, Verbesserung und Erweiterung bestehender Datenbestände ein wichtiges Forschungsthema. Die praktische Relevanz dieser Gruppe von Arbeiten zeigt sich darin, dass der überwiegende Teil der Ansätze, die den Sprung hin zur kommerziellen Anwendung geschafft haben, wie z.B. (GERKE et al. 2004, ZHANG 2004),

Methode	Linien(L)/ Kanten(K)- extraktion	Snakes	Kontext	Gruppie- rung	Straßen- verfolgung	Klassifi- zierung	sonstige
Ansatz							
(FISCHLER et al. 1981)	L			x	x		Typ I vs. Typ II Operator
(HINZ 2003, HINZ und BAUMGARTNER 2003)	K & L		x	x			Maßstabsraum
(RUSKONÉ et al. 1994, RUS- KONÉ 1996)	K & L	x	x	x	x		
(BAUMGARTNER et al. 1999, BAUMGARTNER 2003)	K & L	x	x	x			Maßstabsraum
(GRÜN und LI 1997)		LSB- Snkes					dynamische Pro- grammierung
(HU und TAO 2004)	L			x			
(DOUCETTE et al. 2001, DOUCETTE et al. 2004)						x	SORM
(SHI und ZHU 2002)	L						Line Segment Match
(AMINI et al. 2002)						Fuzzy	
(MOHAMMADZADEH et al. 2004)						Fuzzy	
(KEATON und BROKISH 2002)						x	Level Sets
(GIBSON 2003)	K			x		x	
(SONG und CIVCO 2004)						SVM	
(DAL POZ und DO VALE 2003, DAL POZ et al. 2004)	K			x			dynamische Pro- grammierung
(ÜNSALAN und BOYER 2005)		x		x		x	Veg.Index, Wasser-Schatten Index
(MENA und MALPICA 2005)							TPA, Evidence Theory
(WIEDEMANN et al. 1998, WIEDEMANN 2002)	L		x	x			
(ZHANG und COULOIGNER 2004b)				x	x		Wavelets
(GEMAN und JEDYNAK 1996)	L				x		Active Testing
(STOICA et al. 2004)	L			x			RJMCMC, Punktprozess
(WESSEL 2004)	L		x	x			
(CLODE et al. 2004)						x	Hierarchische Klassifikation

Tabelle 4. Ansätze zur automatischen Straßenextraktion und verwendete Methoden

hieraus stammt. Zur besseren Übersicht sind die zitierten Arbeiten in einer Tabelle geordnet nach der Auflösung der verwendeten Bilddaten zusammengefasst in Tabelle 5 dargestellt.

In (GERKE et al. 2004, GERKE und BUSCH 2005) wird ein System vorgestellt, das in Zusammenarbeit

Datenquelle Auflösung [m]	Luftbilder		Satellitenbilder		Radar	LIDAR
	0.05 – 0.3	0.3 – 1	0.5 – 2	2 – 15	1 – 2	
Ansatz						
(GERKE et al. 2004, GERKE und BUSCH 2005)		x				
(ZHANG 2003, ZHANG 2004)		x	x			
(PÉTERI und RANCHIN 2003a, PÉTERI und RANCHIN 2003b)			x			
(ZHANG und COULOIGNER 2004a)				x		
(KLANG 1998)				x		

Tabelle 5. Ansätze zur automatischen Fortführung von Straßendatenbasen und genutzte Sensoren

der Universität Hannover (Institut für Photogrammetrie und Geoinformation sowie Institut für theoretische Nachrichtentechnik und Informationsverarbeitung) mit dem Bundesamt für Kartographie und Geodäsie (BKG) entstanden ist. Ziel ist es, die Effektivität des Vergleichs von Straßenobjekten im ATKIS (Amtliches Topographisch-Kartographisches Informationssystem) DLMBasis (digitales Landschaftsmodell Basis) mit der tatsächlichen Landschaft, abgebildet in Luftbildern, zu erhöhen. Bei dem Vergleich werden die vorhandenen Daten bezüglich geometrischer Genauigkeit und thematischer Richtigkeit verifiziert und die Vollständigkeit wird überprüft. Für die Verifikation der vorhandenen DLM Daten wird um diese ein Puffer gelegt. Im Bereich des Puffers werden mit Hilfe des Ansatzes von WIEDEMANN (2002) aus digitalen Orthophotos bzw. IKONOS Bilddaten, Straßen extrahiert und mit den DLM Daten verglichen. Die verifizierten Straßenabschnitte werden in die Datenbasis übernommen, die restlichen werden manuell von einem Operateur überprüft.

Im Rahmen des Projekts ATOMI (Automated reconstruction of topographic objects from aerial images using vectorized map information) der ETH Zürich (Institut für Geodäsie und Photogrammetrie) wurde in Zusammenarbeit mit dem Bundesamt für Landestopographie der Schweiz ein System zur Überprüfung und Verbesserung von digitalisierten Vektordaten für Straßen und Gebäude im Maßstab 1:25 000 entwickelt (ZHANG 2003, ZHANG 2004). Das System nutzt farbige Stereobilddaten in Form von Luftbildern oder höchstauflösenden Satellitenbilddaten. Die bestehenden Vektordaten dienen als Näherung, in deren Umgebung in den Bilddaten nach Anhaltspunkten für Straßen gesucht wird, mit denen dann die Straßendaten wenn möglich geometrisch verbessert werden. Es werden unter anderem Kantenextraktion, verschiedene Homogenitätskriterien, Schattenextraktion, Extraktion von Straßenmarkierungen, ein Vergleich von DOM und DGM verwendet. Die verbesserten Teile des Straßennetzes werden mit den bestehenden, nicht verbesserten Daten zu einem Netzwerk zusammengeführt, das zwar nicht homogen ist, jedoch die jeweils bestmögliche Genauigkeit besitzt.

Ein Ansatz zur geometrischen Verfeinerung von Straßendaten in Stadtgebieten wird in (PÉTERI und RANCHIN 2003a, PÉTERI und RANCHIN 2003b) vorgestellt. Neben den Bilddaten werden als Vorwissen geometrisch ungenaue Straßendaten inklusive Netzwerkeigenschaften verwendet, die entweder aus einer bestehenden Datenbasis oder einem Erweiterungsmodul zur Straßendetektion stammen können. Aus dem a-priori Wissen wird ein topologisch korrekter Graph aufgebaut, der jedoch geometrische Ungenauigkeiten aufweist. Das Ziel des Ansatzes ist es, den korrekten Verlauf der Straßen sowie die Straßenränder zu rekonstruieren. Hierfür werden die Bilddaten mittels Wavelet Transformation (MALLAT 1989) in eine Multi-Skalen-Repräsentation überführt. Die Straßenränder und Kreuzungen werden innerhalb der Wavelet Repräsentation mit einer so genannten „Multiresolution-Snake“ rekonstruiert.

Ein weiteres System zur Aufdeckung von Veränderungen und zur Aktualisierung von Straßen einer Datenbasis präsentieren (ZHANG und COULOIGNER 2004a). Zunächst werden aus Satellitenbildern

Straßen mit dem in (ZHANG und COULOIGNER 2004b) vorgestellten, Wavelet-basierten Ansatz automatisch extrahiert. Zur Aufdeckung von Veränderungen gegenüber dem bestehenden Datensatz und dessen Aktualisierung wird die so genannte „Map Conflation Technik“ eingesetzt. In deren Verlauf werden zunächst Punkte und dann Linien zugeordnet und dann zusammengeführt. Abschließend werden die Attribute der Straßen von der alten auf die neue Datenbasis übertragen.

Ein System zur Überprüfung und Verbesserung bestehender Straßendatenbasen auf Grundlage von hochaufgelösten Satellitenbilddaten wird in (KLANG 1998) vorgestellt. Gegebene Kreuzungspunkte dienen als Startpunkte und werden in einem Zuordnungsprozess an die Geometrie der Bilddaten angepasst. Zwischen zwei korrigierten Startpunkten dient jeweils die bestehende Verbindung als Näherung für eine Ziplock-Snake (siehe Abschnitt 2.3.2.) mit deren Hilfe die exakte Position der Verbindung gefunden wird. Für die Optimierung der Snake wird nicht die Bildinformation als Bildenergie verwendet, sondern die maximalen negativen Eigenwerte der Hessematrix (siehe Abschnitt 2.3.1). Neue Straßen werden durch Linienverfolgung, wieder basierend auf den Eigenwerten, extrahiert und in das Netzwerk integriert. Abschließend werden die Veränderungen im Straßennetz einem Operateur zur Weiterbearbeitung angezeigt.

### 3.6 Charakterisierung von Ansätzen zur Straßenextraktion

Die Übersicht über die in der Literatur beschriebenen Ansätze zur Straßenextraktion zeigt, dass seit der Verfügbarkeit von höchst aufgelösten Satellitenbilddaten diese Daten immer stärker in den Fokus aktueller Forschungsarbeiten rücken. Die Bedeutung von Satellitenbilddaten hoher und mittlerer Auflösung hat für die Straßenextraktion durch die höchst aufgelösten Daten deutlich abgenommen (siehe Tabelle 3). Die vorgestellten Arbeiten zeigen, dass Daten mit einer Auflösung schlechter als 5 m lediglich für die Extraktion von großen, deutlich sichtbaren Straßen eingesetzt werden können. Anders verhält es sich bei Luftbildern. Sie behalten ihre Bedeutung für die Straßenextraktion durch die erheblich bessere Auflösung und damit erzielbare höhere Genauigkeit und z.T. auch Zuverlässigkeit. Insbesondere für sehr komplexe Bereiche, wie z.B. Innenstädte, zeigt etwa (HINZ 2003) die Notwendigkeit der Nutzung von Luftbildern höchster Auflösung für die Straßenextraktion. Betrachtet man die möglichen Einsatzgebiete der aktuellen Ansätze, so zeigt sich, dass der größte Anteil für offenes Gelände konzipiert ist. Einige Ansätze eignen sich zusätzlich für regelmäßige Vorortbereiche, für die Straßenextraktion im hoch komplexen Innenstadtbereich existieren dagegen nur sehr wenige Arbeiten.

Die erfolgreiche und wirtschaftliche Extraktion von Straßen ist nicht allein von den eingesetzten Bilddaten abhängig, sondern in starkem Maße von der Modellierung, der Strategie und den verwendeten Methoden. Die detaillierte Modellierung von Straßen wird umso wichtiger, je höher die Auflösung der Daten ist. So werden Straßen in Satellitenbilddaten hoher Auflösung lediglich als ausgedehnte linienhafte Strukturen modelliert. Straßenbegrenzungen in Form von Bildkanten gewinnen dagegen erst bei Verwendung von Daten mit einer Auflösung ab 1 m und besser an Bedeutung. Mit zunehmender Auflösung wird es mehr und mehr möglich, das Maßstabsverhalten der Straßen auszunutzen. Durch eine Strategie vom Groben zum Feinen lassen sich zum Einen die Suchräume und Datenmengen für die meist sehr rechenintensiven Methoden für höchste Auflösungen begrenzen und zum Anderen störende Detailobjekte, wie z.B. Fahrzeuge oder Straßenmarkierungen, herausfiltern. Eine andere oft praktizierte Vorgehensweise geht vom Einfachen zum Komplexen. Hierbei werden zuerst Straßen oder Straßenstücke gesucht, die einfach zu finden sind und somit zuverlässig extrahiert werden

können. Ausgehend von diesen Startstücken wird das Straßennetz dann immer stärker, z.B. mittels Straßenverfolgung oder Netzbildung, verdichtet. Eine ähnliche Bedeutung haben Verfahren zur Gruppierung von einfachen Strukturen zu komplexen Gebilden, wie z.B. die Gruppierung von aus Straßenmarkierungen extrahierten Linienstücken zu Straßenachsen.

Die zunehmend für die Straßenextraktion eingesetzten höchst aufgelösten Satellitenbilddaten bieten neben der guten räumlichen Auflösung die Verfügbarkeit von multispektralen Bilddaten mit sehr feiner Quantisierung als Neuerung gegenüber analogen Luftbildern. So lassen sich Straßen zusätzlich nicht nur geometrisch sondern auch spektral modellieren. Die Nutzung dieser spektralen Eigenschaften für die Extraktion erfolgt bei den vorgestellten Ansätzen in unterschiedlichster Weise. Die am häufigsten genutzte Methode ist die Klassifikation der Bilddaten. Problematisch da aufwändig ist hierbei jedoch die Bestimmung der für die Klassifikation benötigten Trainingsgebiete, bzw. der spektralen Signaturen von Straßen. Dieser Schritt wird in der größten Zahl der Ansätze entweder manuell durchgeführt oder beruht auf a-priori Wissen über die spektralen Eigenschaften von Straßen das bei den vorliegenden Beleuchtungsverhältnissen einer Aufnahme nicht immer zutrifft. Eine weitere Möglichkeit der Nutzung der spektralen Information ist der Einsatz von verschiedenen Indizes, wie z.B. Wasser-Schatten- oder Vegetationsindex, meist zur Einschränkung des Suchraums für nachfolgende Operationen. Stärker den lokalen Charakter der von unterschiedlicher Beleuchtung und Oberflächenmaterial abhängigen spektralen Straßensignatur berücksichtigenden Ansätze, die ausgehend von Startpunkten mittels „Region Growing“ Straßenregionen extrahieren. Kritisch muss für etliche Ansätze die Weiterverarbeitung der Klassifikationsergebnisse betrachtet werden. Die Vektorisierung der meist binären Ergebnisse erfolgt bei den meisten Ansätzen durch Skelettierung und berücksichtigt weder den Netzwerkcharakter der Straßen noch die durch Verdeckungen oder Störobjekte verursachten Unregelmäßigkeiten in den Straßenflächen.

Für die vorgelegte Arbeit lassen sich aus dem Studium der zitierten Arbeiten folgende Forderungen ableiten:

- (1) Wenn möglich sollten Satellitenbilddaten höchster Auflösung verwendet werden.
- (2) Die Linienhaftigkeit von Straßen soll ausgenutzt werden und Straßenbegrenzungen sollen in Form von Bildkanten als zusätzliche Evidenz eingebracht werden.
- (3) Die spektralen Eigenschaften von Straßen sollen genutzt werden, wobei die (lokalen) spektralen Signaturen automatisch bestimmt werden sollen.
- (4) Die Netzwerkeigenschaft von Straßen soll global optimiert werden.
- (5) Die Vektorisierung von Klassifikationsergebnissen soll mit hoher Genauigkeit und Zuverlässigkeit erfolgen.
- (6) Sichere Straßenstücke sollen als Grundlage für die Extraktion neuer Straßenstücke dienen.

## 4 Straßenextraktion aus Satellitenbilddaten

Dieses Kapitel stellt neue Ansätze zur automatischen Extraktion von Straßen aus Satellitenbildern hoher und höchster Auflösung vor. Das für die Extraktion verwendete Modell wird in Abschnitt 4.1 dargestellt. Im folgenden Abschnitt 4.2 wird die verwendete Strategie erläutert. Der Ansatz zur Extraktion von Straßen aus höchstauflösenden Satellitenbilddaten wird, eingeteilt in Fuzzy-Klassifikationsansatz (siehe Abschnitt 4.3.1), Bildung und Verifikation von Straßenhypothesen (siehe Abschnitt 4.3.2) und Verifikation von Verbindungshypothesen (siehe Abschnitt 4.3.3), in Abschnitt 4.3 präsentiert. Abschnitt 4.4 stellt den Ansatz zur Extraktion von Straßen aus hochaufgelösten Satellitenbilddaten, unterteilt in die Generierung von Straßenabschnitten durch lokale Gruppierung (siehe Abschnitt 4.4.1) und die Zusammenführung von Teilergebnissen aus unterschiedlichen Regionen (siehe Abschnitt 4.4.2) dar.

### 4.1 Modell für Straßen in multispektralen Satellitenbildern

Für die (automatische) Extraktion von Straßen aus Satellitenbilddaten unterschiedlicher Auflösung ist zunächst eine klare Vorstellung über das Objekt Straße notwendig. Dazu wird das vorhandene Wissen über das Objekt Straße zu einem Modell zusammengefasst. Aus diesem kann im Weiteren eine Strategie für die Extraktion abgeleitet und mit Hilfe von Methoden der Bildverarbeitung ein Ansatz zur Straßenextraktion entwickelt werden.

Der neue Brockhaus charakterisiert eine Straße wie folgt:

**Straße:** allgemein jeder Verkehrsweg (z.B. Land-, Luft-, Wasserstraße), im engeren Sinne ein planmäßig angelegter, befestigter, schienenunabhängiger Landweg [...] (BROCKHAUS 1980).

In dieser Definition kommen verschiedene wichtige Aspekte des Objekts Straße zum Ausdruck. Die Straße ist ein *Verkehrsweg*. D.h., sie dient dem Verkehr, indem sie die Verbindung zwischen Orten entlang des Weges herstellt. Da sich Straßen schneiden bilden sie ein Netzwerk. Ein weiterer Punkt ist die *planmäßige Anlage* von Straßen, womit zum Ausdruck kommt, dass der Verlauf von Straßen nicht zufällig ist, sondern verschiedenen Regeln gehorcht. Zuletzt wird durch *befestigt* ausgedrückt, dass eine Straße nicht eine gedachte Verbindung zwischen zwei Punkten ist, sondern eine mit unterschiedlichen Materialien und Techniken ausgebaute reale Verbindung darstellt, die sich von ihrer Umgebung abgrenzt.

Für die vorliegende Arbeit sind Straßen in offener Landschaft in semiariden Regionen von vorrangigem Interesse. Ihre Modellierung für multispektrale Bilddaten mit einer Auflösung zwischen 1 m und 5 m erfolgt in drei Ebenen: Ebene der **realen Welt – Geometrie und Material** Ebene – sowie **Bildebene** (siehe Abbildung 11). Die Abbildung stellt das Modell in Form eines semantischen Netzes auf der konzeptuellen Ebene (BRACHMAN 1979) dar, die Auswahl der verwendeten Ebenen erfolgt in Anlehnung an (TÖNJES 1996). Die Einführung der *Geometrie und Material* Ebene zusätzlich zu den Ebenen der *realen Welt* und des *Bildes* ermöglicht die Kombination von Daten verschiedener Sensoren anhand der Materialeigenschaften und der Form der abgebildeten Objekte.

In der **realen Welt** werden Straßen in erster Linie durch ihre Funktion für Fahrzeuge und damit

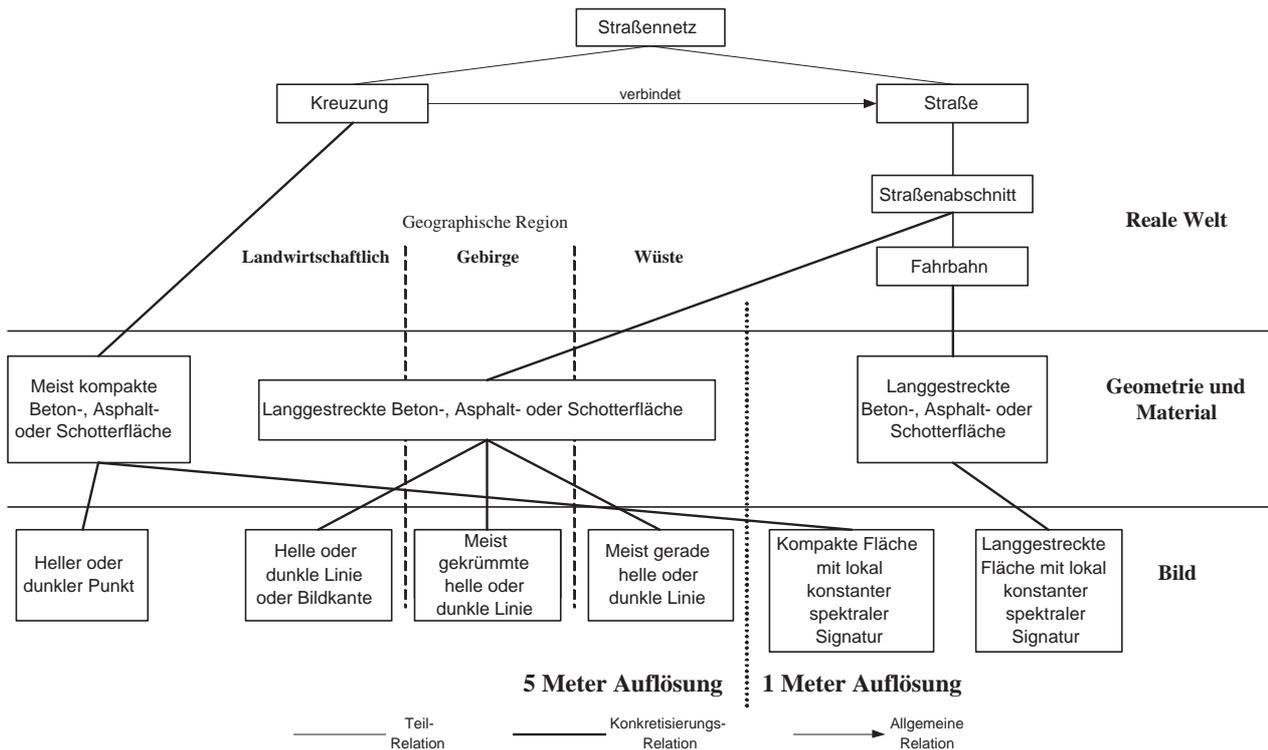


Abbildung 11. Modell für Straßen in hoch- und höchstauflösenden Satellitenbildern

für die Gesellschaft beschrieben. Straßen stellen für die Erschließung von Ortschaften, Landstrichen, Ländern und Kontinenten ein Netzwerk von mehr oder weniger gut ausgebauten Verkehrswegen dar, über die Menschen und Güter sich bewegen oder transportiert werden. Das Netzwerk ist hierarchisch gegliedert mit Hauptverbindungsstraßen zwischen den Zentren an der Spitze bis hin zu den Zufahrtsstraßen zu einzelnen Gebäuden und den Feldwegen. Aus der Bedeutung einer Straße resultiert in der Regel auch der Grad des Ausbaus. So sind die wichtigsten Straßen meist mehrspurig, sehr breit und mit gutem Fahrbahnbelag gebaut, wohingegen die Breite der Straßen mit schwindender Bedeutung in der Regel abnimmt und der Fahrbahnbelag schlechter wird. Sind Feldwege und kleine Verbindungsstraßen in ihrem Verlauf meist sehr stark an die Topographie angepasst, nimmt die Zahl der unterstützenden Bauwerke wie Brücken oder Tunnel mit zunehmender Bedeutung der Straße zu und die Anpassung an die Topographie tritt etwas in den Hintergrund. Auch die Art der Kreuzungen gibt einen Hinweis auf die Bedeutung einer Straße. So sind die Einmündungen bei großen Straßen meist kreuzungsfrei gestaltet, um den fließenden Verkehr nicht zu behindern, bei kleineren Straßen sind dagegen die Kreuzungen meist sehr einfach gehalten. Zuletzt lässt sich aus der Dichte eines Straßennetzes in einem Gebiet in der Regel auf die Dichte der Besiedlung bzw. die Intensität der Nutzung des Gebietes schließen.

In der **Geometrie und Material** Ebene werden besonders die bautechnischen Parameter von Straßen betrachtet. Die Geometrie einer Straße hängt von verschiedenen Faktoren ab, wobei die Topographie einen entscheidenden Einfluss besitzt. Eine weitere Einflussgröße sind die jeweils gültigen Bauvorschriften, die z.B. maximale Krümmungsradien oder maximale Steigungen für Straßen vorgeben, und gegen die nur in Ausnahmefällen verstoßen wird. Für die vorgelegte Arbeit von größtem Interesse ist aber die Tatsache, dass Straßen fast immer als langgestreckte relativ ebene, nicht zu stark geneigte Flächen, mit einer lokal mehr oder weniger konstanten Breite und parallelen Begrenzungen



Abbildung 12. Beispiele für Straßen in IKONOS Bilddaten

ausgebildet sind. Das für den Straßenbau verwendete Material für den Straßenbelag besteht zum überwiegenden Teil aus Asphalt, Beton oder Schotter. Lediglich Straßen mit geringerer Bedeutung, wie z.B. Feldwege oder Wüstenpisten, bestehen häufig aus in der Umgebung vorhandenem verdichtetem natürlichem Untergrund.

Das Aussehen von Straßen im **Bild** hängt vom Aufnahmesensor ab. Dieser legt die Größe der Bildelemente im Objektraum sowie die spektrale Charakteristik fest. Für die **Bildebene** sind beim vorgestellten Ansatz multispektrale Satellitenbilddaten mit Auflösungen von etwa 1 Meter sowie von 5 Metern von Interesse. Durch die Verwendung von pansharpened Bilddaten beziehen sich die genannten Auflösungen originär auf den panchromatischen Kanal, d.h. die multispektralen Daten sind unterabgetastet (siehe Abschnitt 2.1). Aufgrund der erheblichen Unterschiede im Aussehen von Straßen in den beiden Auflösungsbereichen erfolgt die Beschreibung getrennt voneinander.

In Satellitenbilddaten höchster Auflösung von ca. 1 m, wie z.B. IKONOS oder Quickbird, haben Straßen in der Regel eine Breite von 3 bis 12 Bildelementen. Sie bilden somit langgestreckte Flächen, die sich meist deutlich von der Umgebung abheben. Begrenzt werden die Flächen durch parallele Kanten. Die radiometrischen Eigenschaften der Straßenfläche sind meist lokal konstant und innerhalb der Flächen homogen. Lediglich an den begrenzenden Rändern der Flächen vereinigen sich die radiometrischen Eigenschaften der Straßen und der Umgebung und es bildet sich eine spektrale Mischsignatur. Die Erkennung von Straßen wird auch durch das Vorhandensein einzelner Hintergrundobjekte, wie z.B. Fahrzeuge, Gebäude oder Bäume gestört. Beispiele für das Aussehen von Straßen in IKONOS Bilddaten zeigt Abbildung 12.

In Bilddaten hoher Auflösung von ca. 5 m, wie z.B. IRS-1C/D, weisen Straßen meist eine Breite von 1 bis 3 Bildelementen auf. Sie werden in der Regel durch helle oder dunkle Linien mit gutem Kontrast zur Umgebung abgebildet. Schmale Straßen oder Wege können vor allem in landwirtschaftlich genutzten Gebieten oft nur indirekt in Form von Kanten, die aus der Begrenzung von Feldern resultieren, mit zusätzlichem Kontextwissen in Form der Verbindungsfunktion der Straßen erkannt werden. Die radiometrischen Eigenschaften von Straßenpixeln sind bedingt durch die Auflösung (Mischpixel) in der Regel nicht homogen. Die Erkennung von Straßen wird in dieser Auflösungsstufe nur wenig durch einzelne Hintergrundobjekte gestört. Beispiele für unterschiedliche Ausprägungen von Straßen in IRS Bilddaten sind in Abbildung 13 zu finden.

Probleme treten bei der automatischen Extraktion von Straßen an Stellen auf, an denen das genutzte



Abbildung 13. Beispiele für Straßen in IRS-1C/D Bilddaten

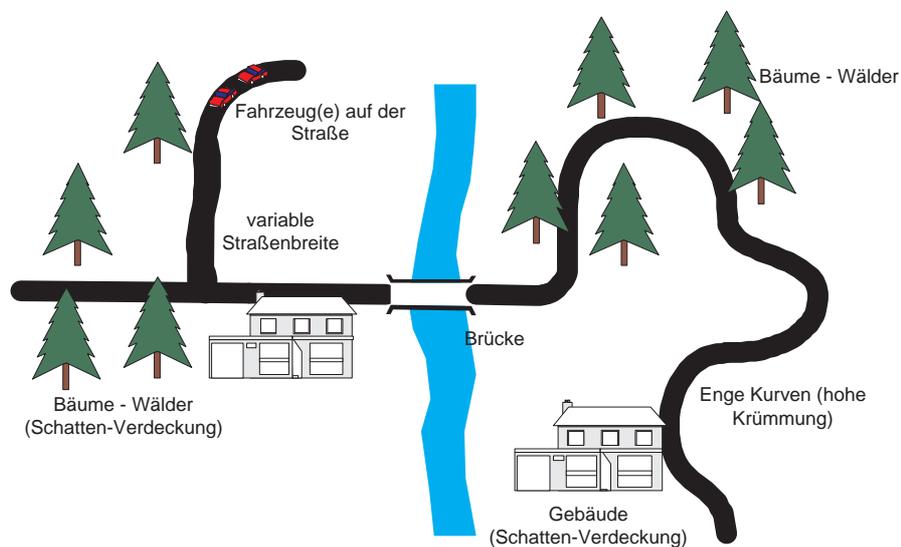


Abbildung 14. Ursachen für Abweichungen vom Straßenmodell

Modell nicht mit der Realität übereinstimmt. Die Abweichungen vom Modell sind hierbei vielfältiger Natur (siehe auch Abbildung 14):

- ◇ Verdeckung von Straßenabschnitten ganz oder teilweise oder Schattenwurf durch Bäume oder Häuser. In beiden Fällen wird die Radiometrie der Straße im Bild verändert.
- ◇ Variable Breite, hohe Krümmung im Flachland, oder fehlende eindeutige Begrenzung
- ◇ Änderung des Straßenbelags, z.B. auf Brücken
- ◇ geringer Kontrast zur Umgebung
- ◇ Fahrzeuge oder andere Objekte auf der Straße

## 4.2 Strategie

Von zentraler Bedeutung für die erfolgreiche Extraktion von Objekten aus Bildern ist neben dem Modell die verwendete Strategie. Sie bildet die im statischen Modell festgelegten Beschreibungen in unterschiedliche Arbeitsschritte ab<sup>1</sup>. Die Strategie für ein praktisch nutzbares System zur Straßenextraktion ist allerdings nicht allein von dem im Modell zusammengefassten Wissen über das Objekt Straße abhängig, sondern muss zusätzlich noch weitere, projektspezifische Rahmenbedingungen berücksichtigen. In der vorgelegten Arbeit besteht die Forderung, ein System zur Neuerfassung von Straßen zu entwerfen. Das System soll möglichst wirtschaftlich arbeiten, d.h., die für die Extraktion verwendeten Bilddaten sollten den regionalen Gegebenheiten angepasst werden, und das System soll soweit möglich automatisch arbeiten. Weitere Einschränkungen für die Strategie ergeben sich aus den geplanten Einsatzgebieten Südosteuropa und vor allem Nordafrika. Als Zielmaßstab für die extrahierten Straßen ist 1:50 000 gefordert. All diese Rahmenbedingungen führen zu der im Folgenden vorgestellten Strategie für die automatische Extraktion von Straßen.

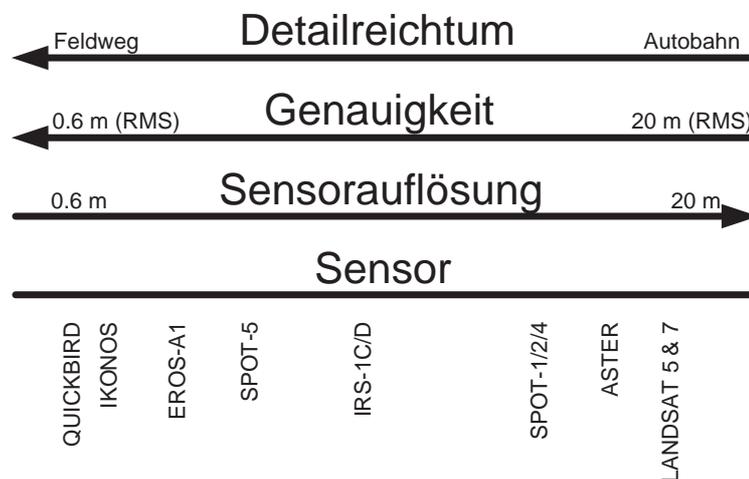


Abbildung 15. Abhängigkeiten zwischen Detailreichtum, Genauigkeit und Sensorauflösung bei der Straßenextraktion

Der erste Einflussfaktor, der die Strategie maßgeblich beeinflusst, besteht in der Auswahl geeigneter Bilddaten für das zu untersuchende Gebiet. Grundsätzlich gilt, dass umso höher aufgelöst die Bilddaten sind, desto besser ist die zu erwartende geometrische Genauigkeit des Resultates und desto mehr Details können erfasst werden. Abbildung 15 skizziert den Zusammenhang zwischen möglichem Detailreichtum, zu erwartender Genauigkeit und der Bodenauflösung verschiedener Satellitenbildsensoren. Betrachtet man neben der möglichen Genauigkeit auch die Wirtschaftlichkeit, so ist es sinnvoll, je nach dem Vorhandensein von bestimmten Objektmerkmalen und deren Dichte unterschiedliche Bilddaten auszuwählen (siehe Abbildung 16). So ist es nicht notwendig, für ein Wüstengebiet mit nur einer Verbindungsstraße, die über sehr weite Strecken durch unbewohntes Gebiet führt, teure höchst aufgelöste Bilddaten zu verwenden. Auf der anderen Seite ist es auch nicht zielführend, im dichtbesiedelten Gebiet die Extraktion aus IRS-1C/D Daten anzugehen.

Ist die Entscheidung für die Auflösung der zu nutzenden Bilddaten gefallen, wird das weitere Vorgehen vom globalen Kontext des betreffenden Gebiets bestimmt. Für Satellitenbilddaten

<sup>1</sup> Verglichen mit einem Kochrezept beschreibt die Strategie die einzelnen Arbeitsschritte und das Modell die notwendigen Zutaten.

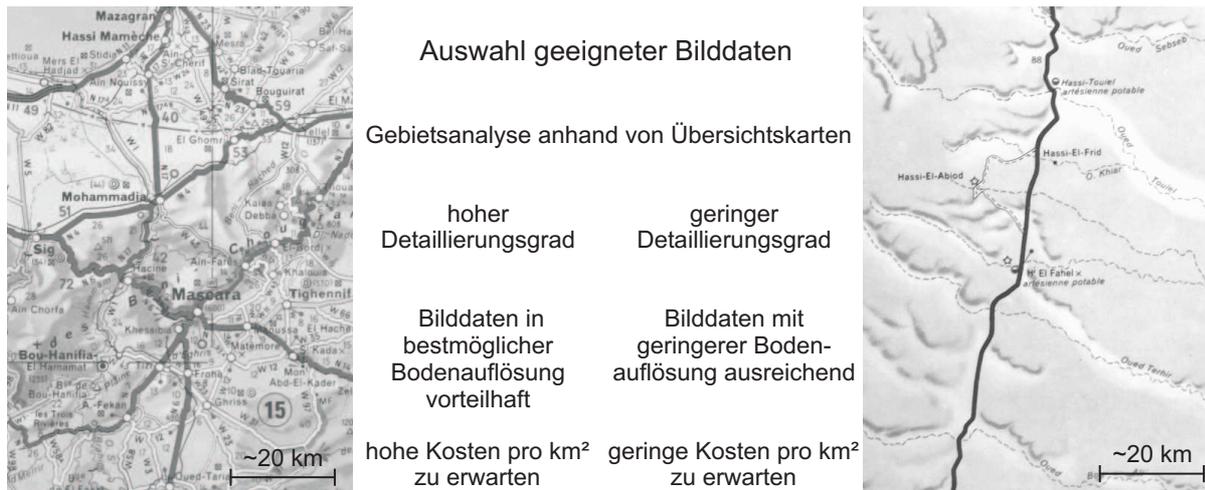


Abbildung 16. Auswahl der für die wirtschaftliche Extraktion von Straßen zu verwendenden Bilddaten. (Links) Gebiet mit sehr vielen Details; (Rechts) Wüstengebiet mit wenigen Details. Kartenausschnitte aus Michelin Straßenkarte Algerien/Tunesien Nr.: 958 Maßstab 1:1 000 000

**höchster Auflösung** werden die folgenden Kontextgebiete unterschieden (siehe auch (MAYER et al. 1997, BAUMGARTNER et al. 1999) sowie Abschnitt 3.1):

- ◇ offene Landschaft
- ◇ Wald
- ◇ Siedlung

Für die gegenseitige Abgrenzung der Kontextgebiete können verschiedene Verfahren eingesetzt werden, wie z.B. die multispektrale Klassifikation (HOFFMANN 2001, LEUKERT 2005) oder wie in (BAUMGARTNER 2003) vorgeschlagen die texturbasierte Segmentierung. In der vorgelegten Arbeit wird die automatische Abgrenzung der Kontextgebiete nicht weiter behandelt und erfolgt, wenn notwendig, manuell. Für jedes der genannten Kontextgebiete sind eigene Strategien zur Extraktion von Straßen notwendig. Aufgrund der im Vergleich zu den beiden anderen Gebieten deutlich einfacheren und damit zuverlässigeren Extraktion in der offenen Landschaft wird im Rahmen dieser Arbeit lediglich dieses Kontextgebiet betrachtet. Die Ergebnisse hierin könnten im Weiteren als Startinformation für die Extraktion im Wald oder in der Siedlung genutzt werden, worauf aber wiederum nicht weiter eingegangen wird.

Für Bilddaten **hoher Auflösung** haben entsprechend dem Modell die globalen Kontextgebiete

- ◇ landwirtschaftlich genutzt,
- ◇ Gebirge und
- ◇ Wüste

für den vorgestellten Ansatz die größte Bedeutung. Das Kontextgebiet Siedlung ist aufgrund der Vorauswahl in die unterschiedlichen Auflösungsbereiche weniger wichtig, da wegen des großen Detailreichtums Daten höchster Auflösung verwendet werden sollten. Eine Abgrenzung der übrigen drei

Kontextgebiete kann mit Hilfe eines DGM in Verbindung mit dem Infrarotkanal erfolgen. Für landwirtschaftlich genutzte Bereiche ist eine hohe Intensität im Infrarotkanal bei nur mäßigem Höhengradienten, d.h. Geländeneigung zu erwarten. In Gebirgsregionen ist der Höhengradient groß, der Infrarotkanal hat hier keinen Einfluss. Wüstengebiete zeichnen sich durch fehlende Vegetation aus, was in der Regel zu einer schwachen Intensität im nahen Infrarot führt. Die automatische Aufteilung in die beschriebenen Kontextregionen ist nicht Bestandteil der vorliegenden Arbeit und wurde für die weitere Untersuchung manuell durchgeführt.

Die eigentliche Extraktion von Straßen beginnt für alle betrachteten Bilddaten und Kontextgebiete mit dem selben datengetriebenen Vorgehen. Es wird zunächst die Linienhaftigkeit von Straßen ausgenutzt, d.h., es werden Linien aus den Bilddaten in allen spektralen Kanälen separat extrahiert. Lediglich die verwendeten Parameter werden der jeweiligen Situation, wie z.B. Linienbreite oder Kontrast zur Umgebung, angepasst. Für landwirtschaftlich genutzte Bereiche werden in hochaufgelösten Daten zusätzlich noch Kanten im Bild extrahiert, da hier Straßen häufig nur indirekt in Form von Feldgrenzen wahrgenommen werden.

Für die **höchstaufgelösten** Bilddaten werden die extrahierten Linien für zwei Aufgaben genutzt:

- (1) für die Suche nach Trainingsgebieten für einen automatischen Klassifikationsansatz
- (2) als Straßenhypothesen

Entsprechend dieser Aufgaben gliedert sich das weitere Vorgehen. Für den Klassifikationsansatz wird in der Umgebung der Linien nach parallelen Kanten gesucht. Parallele Kantenpaare dienen als Hypothese für sichere Straßenstücke, die als Trainingsgebiete genutzt werden. Aus dem Modell für Straßen folgt, dass die Grauwerte entlang der Straße homogen sind. Auf Grundlage dieser Forderung werden die Hypothesen für sichere Straßenstücke in Verbindung mit einer Breitenbedingung modellgetrieben überprüft. Die spektralen Eigenschaften der Bilddaten werden genutzt, in dem die Daten auf Grundlage der automatisch bestimmten Trainingsgebiete klassifiziert werden. Dies führt zu einem Zugehörigkeitswert eines jeden Pixels zur Klasse Straße. Das so gebildete Straßenklassenbild hat eine umso größere Intensität, je größer der Zugehörigkeitswert des entsprechenden Bildelements zur Klasse Straße ist. Das Straßenklassenbild wird wie folgt verwendet:

- ◇ als zusätzlicher Kanal für die Extraktion von Linien als Hypothese für Straßen
- ◇ für die Verifikation von Straßenhypothesen
- ◇ zur Überbrückung von Lücken im Rahmen der globalen Gruppierung

Aufgrund der bekannten Radiometrie des Straßenklassenbildes, d.h., Straßen haben hohe Intensitäten unabhängig von der Helligkeit der Straße im Originalbild und der Hintergrund wird tendenziell immer dunkel abgebildet, ist eine Trennung zwischen den gesuchten Objekten, d.h. den Straßen, und dem Hintergrund vergleichsweise einfach. Im Rahmen der vorgestellten Strategie erfolgt diese Trennung durch Nutzung des Straßenklassenbildes als zusätzlichen Kanal für die Linienextraktion.

Die extrahierten Linien bilden die Straßenhypothesen. Aus diesen werden diejenigen herausgesucht, die dem Straßenmodell entsprechen. Dazu müssen Linien eine Mindestlänge besitzen, die Breite der

Linien muss zwischen einer unteren und einer oberen Schranke liegen und die spektralen Eigenschaften im Verlauf der Linie müssen denen von Straßen entsprechen. Letzteres wird mittels des Straßenklassenbildes überprüft. Die anhand des Modellwissens verifizierten Linien dienen als Grundlage für das vorläufige Straßennetz. Aus den Parametern der Verifikation wird eine Bewertung für jedes Straßenstück abgeleitet.

Für Bilddaten **hoher Auflösung** ist die für die Daten höchster Auflösung beschriebene Vorgehensweise nicht anwendbar. Die Bodenauflösung, die panchromatisch im Bereich der Straßenbreite liegt und im spektralen Bereich meist weit darüber, führt zu Mischpixeln. Deswegen ist eine multispektrale Klassifikation nicht zielführend. In den Kontextgebieten Gebirge und Wüste werden die Straßen entsprechend dem in Abschnitt 4.1 vorgestellten Modell als helle oder dunkle Linien mit meist gutem Kontrast zur Umgebung abgebildet. Die zuvor extrahierten Linien können also direkt als Straßenhypothesen genutzt und somit kann die in (WIEDEMANN 2002) beschriebene Vorgehensweise hier direkt verwendet werden. Zur Überprüfung der Hypothesen werden die geometrischen Eigenschaften von Straßen genutzt. Die Linien müssen demnach eine bestimmte Mindestlänge, eine minimale und maximale Breite, nur wenig Breitenänderung sowie einen konstanten Grauwert aufweisen. Für Straßen in der Wüste gilt zusätzlich, dass die Linien innerhalb bestimmter Grenzen im Großen und Ganzen geradlinig verlaufen müssen. In Gebirgsregionen ist diese Bedingung wegen der Anpassung des Straßenverlaufs an die extremere Topographie nicht sinnvoll.

Für landwirtschaftlich genutzte Gebiete zeigen Straßen laut Straßenmodell z.T. ein anderes Aussehen. Teilweise werden Straßen zwar auch als meist helle Linien in den Bildern abgebildet, ein anderer Teil der Straßen ist jedoch nur mit Hilfe von Kontextwissen extrahierbar. Genutzt wird hierbei die Tatsache, dass Straßen zwar nicht direkt sichtbar sind, dass ihr Verlauf aber durch die Fortsetzung von linearen Strukturen, wie z.B. Feldgrenzen, rekonstruiert werden kann. Für die Strategie bedeutet das, dass jeweils zwei lineare Strukturen, d.h. Linien oder zusätzlich extrahierte Kanten, die zueinander kollinear sind und die im Weiteren als Startstücke bezeichnet werden, eine Straßenhypothese bilden. Für die Verifikation der Hypothese muss die Verbindung der Startstücke genügend Evidenz für das Vorhandensein einer linearen Struktur bieten. Konnten zwei Startstücke und deren Verbindung als Straßenstück verifiziert werden, so wird versucht, weitere lineare Strukturen zu finden, mit deren Hilfe das Straßenstück erweitert werden kann. Dieses Vorgehen wird sowohl auf die anfangs extrahierten Linien als auch auf die Kanten angewandt. Aufgrund der größeren Zuverlässigkeit werden die aus Linien stammenden Straßenstücke höher bewertet. Die verifizierten Straßenstücke erhalten eine aus den Parametern für die Verifikation abgeleitete Bewertung und dienen im weiteren Verlauf als Grundlage für das vorläufige Straßennetz.

Die Generierung von Straßenstücken erfolgte in den vorangegangenen Arbeitsschritten für jeden der spektralen Kanäle separat. Die einzige Ausnahme bildet die Extraktion in landwirtschaftlich genutzten Gebieten aus hochaufgelösten Daten. Hier werden die einzelnen spektralen Kanäle schon bei der Bildung von linearen Strukturen zusammengeführt, damit die komplette Information für die Bildung von Straßenhypothesen genutzt wird. Um auch für die übrigen Gebiete einen redundanzfreien Datensatz zu erhalten, werden die Ergebnisse aus den einzelnen spektralen Kanälen an diesem Punkt zu einem konsistenten Datensatz fusioniert. Im Rahmen der vorgelegten Arbeit wird hierfür die in (WIEDEMANN 2002) vorgeschlagene Vorgehensweise genutzt.

Für den Übergang von isolierten Straßenstücken zu einem topologischen Netzwerk wird aus den bewerteten Straßenstücken gemäß Abschnitt 2.3.4 ein gewichteter Graph aufgebaut. Kurze Lücken

werden ohne Nutzung von Bildinformation geschlossen. Das hierfür verwendete Verfahren wurde an der TU München entwickelt (WIEDEMANN et al. 1998, WIEDEMANN 2002) und für die vorliegende Arbeit adaptiert.

Den Abschluss bildet die globale Gruppierung. Globales Kontextwissen über die Funktion von Straßennetzen wird genutzt, um größere Lücken im vorläufigen Straßennetz zu schließen. Grundlage der Überlegungen ist die Tatsache, dass innerhalb eines Straßennetzes jeder beliebige Punkt auf einem optimalen Pfad mit minimalem Umweg entlang des Netzes erreicht werden können sollte (WIEDEMANN und EBNER 2000, WIEDEMANN 2002). Hierfür werden in einem iterativen Prozess zunächst Lücken innerhalb von Zusammenhangskomponenten geschlossen und dann die unterschiedlichen Zusammenhangskomponenten miteinander verbunden (siehe Abschnitt 2.3.4). Für die Verifikation von Verbindungshypothesen, die anhand von Umwegefaktoren generiert wurden, wird die Bildinformation bzw. das Straßenklassenbild verwendet auf deren Grundlage der bestmögliche Pfad durch Optimierung einer Ziplock-Snake (siehe Abschnitt 2.3.2) bestimmt wird.

### 4.3 Straßenextraktion aus höchstauflösenden Multispektral-Daten

Für die Extraktion von Straßen aus höchstauflösenden multispektralen Satellitenbilddaten wurde im Rahmen der vorgelegten Arbeit das von WIEDEMANN (2002) entwickelte Verfahren erweitert. Dieses wurde für Bilddaten mit einer Auflösung von 2 m oder schlechter konzipiert. Es beruht auf der Extraktion von Linien, die nach einer Bewertung zu einem gewichteten Graphen zusammengefügt werden. Ausgehend von diesem Graphen wird aus den einzelnen Linienstücken ein Netz aufgebaut. Multispektrale Information wird für den Ansatz nicht benötigt und wird, wenn sie vorhanden ist, nur indirekt, in Form der Linienextraktion parallel in den einzelnen Kanälen, verwendet. Durch die Erweiterungen der vorgelegten Arbeit (siehe Abbildung 17) werden die sehr guten radiometrischen Eigenschaften der verwendeten Bilddaten ausgenutzt (BACHER und MAYER 2003, BACHER und MAYER 2005). Von zentraler Bedeutung bei der Verwendung der radiometrischen Informationen ist der automatische Klassifikationsansatz<sup>2</sup>, wobei jedem Bildelement ein Zugehörigkeitswert zur Klasse *Straße* zugeordnet wird. Das Ergebnis des Klassifikationsansatzes wird im weiteren Verlauf als zusätzlicher spektraler Kanal, für die Bewertung von extrahierten Linien sowie für die Optimierung und Verifikation von Verbindungen im Rahmen der globalen Gruppierung genutzt. Wegen der zentralen Bedeutung des Klassifikationsansatzes wird im Folgenden zunächst dessen Ablauf erläutert und erst daran anschließend der modifizierte Ansatz zur Straßenextraktion detailliert beschrieben.

#### 4.3.1 Fuzzy-Klassifikationsansatz

Die radiometrischen Eigenschaften von Bilddaten moderner, höchstauflösender Fernerkundungssatelliten, wie z.B. IKONOS-2 oder QuickBird, machen es möglich, Straßen auch mit Hilfe von Klassifikationsverfahren zu detektieren. Etliche Arbeiten aus dem Bereich der Straßenextraktion, wie z.B. (ZHAO et al. 2002, KEATON und BROKISH 2002, AMINI et al. 2002, ZOEJ und MOKHTARZADE

<sup>2</sup> Der Begriff Klassifikation bezeichnet die Unterscheidung verschiedener Klassen auf Grundlage von Merkmalen, die in der Fernerkundung häufig von spektraler Natur sind. In der vorgelegten Arbeit erfolgt die Bestimmung der Klassen relativ implizit in Form der Verifikation von Straßenhypothesen gegen Ende des Extraktionsprozesses. Im Weiteren wird für die dafür notwendige Bestimmung eines Zugehörigkeitswertes zur Klasse *Straße* für jedes Bildelement der Begriff Klassifikationsansatz gewählt. Damit wird angedeutet, dass die spektrale Information ähnlich einer traditionellen Klassifikation genutzt wird.

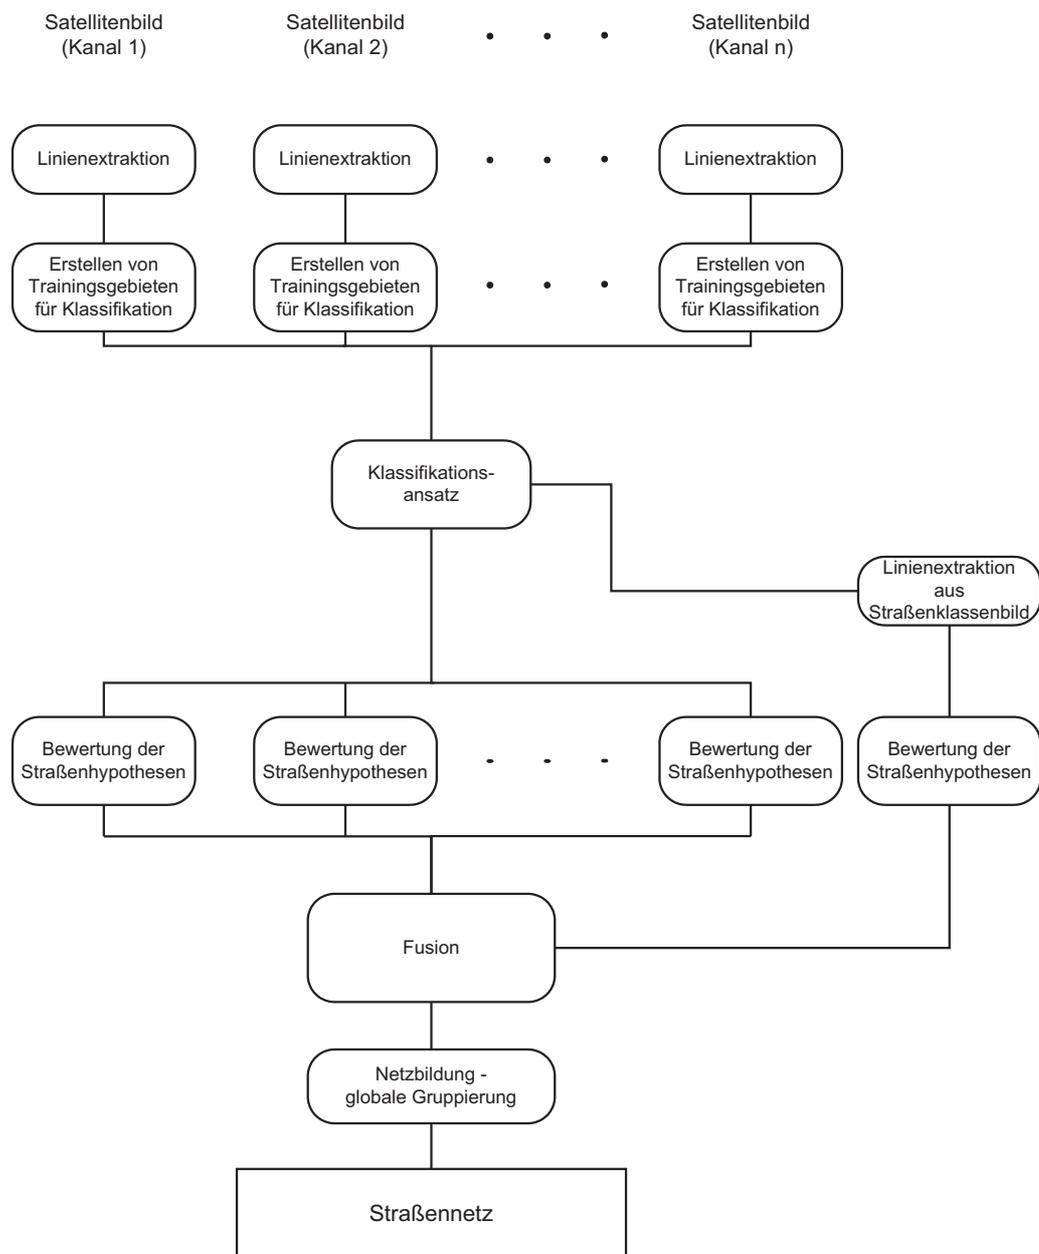


Abbildung 17. Ablauf Straßenextraktion aus höchstau aufgelösten multispektralen Satellitenbilddaten

2004, DOUCETTE et al. 2004) sowie Abschnitt 3.2, zeigen die Möglichkeiten der Nutzung von spektraler Information für die Straßenextraktion. Gemein ist den vorgestellten Ansätzen, dass Startpunkte bzw. Trainingsgebiete manuell bestimmt werden oder die Parameter der Klassifikation für bestimmte Gebiete festgelegt werden. Um diese manuellen Schritte zu umgehen, wird in der vorgelegten Arbeit ein automatischer Klassifikationsansatz für höchstau aufgelöste multispektrale Satellitenbilddaten für die Straßenextraktion verwendet, der im Weiteren vorgestellt wird. Es werden automatisch Trainingsgebiete generiert und ausgehend von diesen für jedes Bildelement ein Zugehörigkeitswert zur Klasse *Straße* bestimmt. Aus den Zugehörigkeitswerten wird das so genannte „Straßenklassenbild“

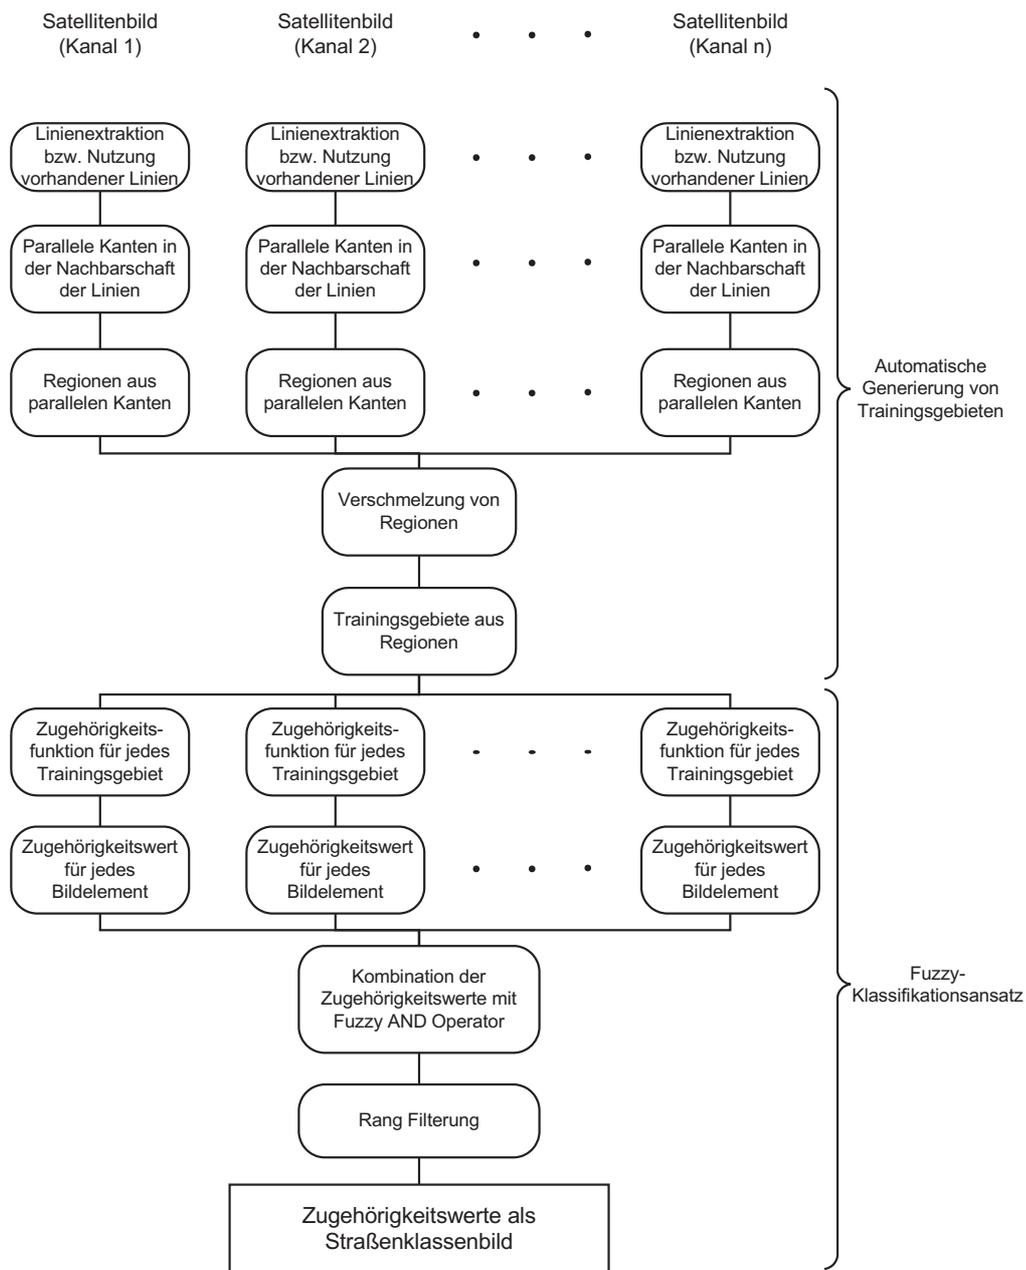


Abbildung 18. Ablauf des automatischen Fuzzy-Klassifikationsansatzes

abgeleitet. Einen Überblick über den Ablauf des Klassifikationsansatzes gibt Abbildung 18. Da er auf Fuzzy-Sets (siehe Abschnitt 2.3.3) beruht wird er als „Fuzzy-Klassifikationsansatz“ bezeichnet.

### Automatische Generierung von Trainingsgebieten

Als Grundlage für eine überwachte Klassifikation dienen Bildregionen, so genannte *Trainingsgebiete*, von denen bekannt ist, zu welcher Objektklasse sie gehören, und die die spektrale Charakteristik

der entsprechenden Klasse möglichst gut repräsentieren (ALBERTZ 2001, CAMPBELL 2002). Von der Qualität der Trainingsgebiete ist die Qualität der Klassifikation abhängig. Traditionell werden Trainingsgebiete manuell aus den Bilddaten erfasst und/oder durch einen Feldvergleich vor Ort festgelegt. Bei den so bestimmten Gebieten dient der Mensch mit seiner Erfahrung, insbesondere unter Nutzung von Kontextinformation, als Kontrollinstanz.

In der vorgelegten Arbeit werden die Trainingsgebiete automatisch bestimmt. Da man für die weitere Verarbeitung lediglich an der Klasse *Straße* interessiert ist, werden nur für diese Trainingsgebiete benötigt. Trainingsgebiete für eine Hintergrundklasse sind bei Verwendung des vorgestellten Fuzzy-Klassifikationsansatzes nicht notwendig. Für die Extraktion von Trainingsgebieten wird von einem vereinfachten Modell für ideale Straßen ausgegangen. Hiermit ist es zwar nicht möglich, das komplette Straßennetz zu extrahieren, jedoch gehören die so extrahierten Straßenabschnitte mit hoher Wahrscheinlichkeit der Klasse *Straße* an und eignen sich somit für den Klassifikationsansatz.

Die folgenden Eigenschaften in Bilddaten mit einer Auflösung im Bereich von 1 m bilden die Grundlage für das Modell einer idealen Straße:

- ◇ Straßen bilden sich im Bild als helle oder dunkle Linien ab.
- ◇ Straßen besitzen parallele Kanten mit konstantem Abstand.
- ◇ Straßen haben eine minimale und maximale Breite.
- ◇ Der Grauwert der Straßenfläche ist innerhalb bestimmter Grenzen homogen.

Der erste Schritt der automatischen Extraktion von Trainingsgebieten (siehe auch Abbildung 19) ist die Linienextraktion. Aufgrund der hohen Qualität der Ergebnisse wird hierfür der Steger-Extraktor (siehe Abschnitt 2.3.1) verwendet, mit dem sowohl helle als auch dunkle Linien extrahiert werden können. Im nächsten Schritt wird ein Puffer um die Linien gebildet und innerhalb des Puffers nach Bildkanten gesucht. Die Pufferbreite wird so gewählt, dass die Straße in jedem praktisch relevanten Fall komplett erfasst wird. Empirisch stellte sich als sinnvoller Wert für die Pufferbreite die doppelte maximale Straßenbreite heraus. Für die Extraktion von Kanten wird ebenfalls der Steger Extraktor verwendet. Die gefundenen Kanten werden auf Parallelität geprüft und liefern somit weitere Evidenz für das Vorliegen eines Straßenstückes. Wenn der Abstand der parallelen Kanten, also die Straßenbreite, innerhalb der vorgegebenen Toleranzen liegt, wird aus den gegenüber liegenden parallelen Kanten eine Region, d.h. ein vorläufiges Trainingsgebiet, gebildet. In einem abschließenden Arbeitsschritt werden die Grauwerte innerhalb der Region auf Homogenität geprüft. Hierfür wird die Standardabweichung der Grauwerte der Region betrachtet. Liegt diese unterhalb eines Grenzwertes, dann wird die Region als Trainingsgebiet betrachtet.

Für die Extraktion von Trainingsgebieten werden die spektralen Kanäle unabhängig voneinander betrachtet. Es werden in jedem Kanal Trainingsgebiete bestimmt, die dann zu einem kompletten Satz über die Vereinigungsmenge aller Trainingsgebiete kombiniert werden. Wegen lokal unterschiedlicher spektraler Eigenschaften von Straßen, unterschiedlicher Beleuchtung und unterschiedlichem Rückstrahlverhalten der Oberflächen in unterschiedlichen Richtungen, ist es nicht sinnvoll, eine Klassifizierung ausgehend von nur einem vereinigt Trainingsgebiet durchzuführen. Aus diesem Grund wird der Trainingsgebietssatz in der Art, dass jeweils zusammenhängende Regionen ein Trainingsgebiet bilden, in unabhängige Teilgebiete unterteilt.

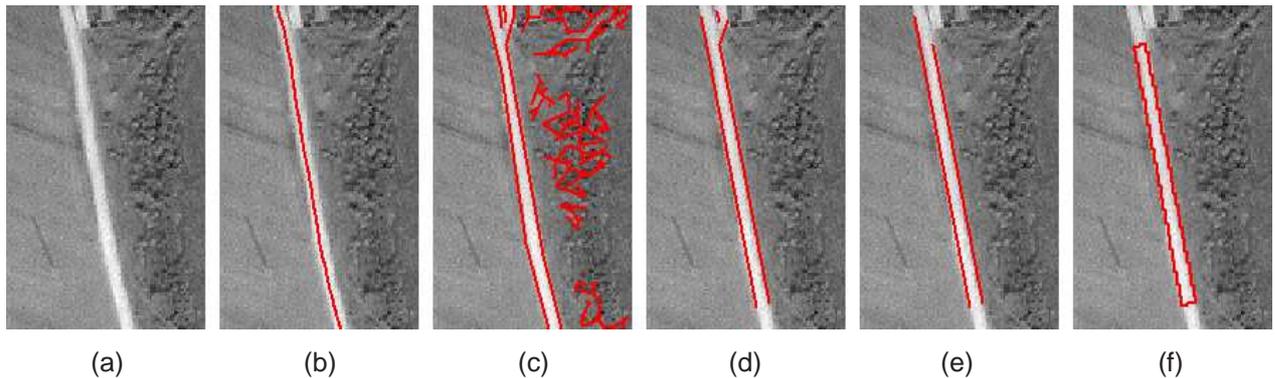


Abbildung 19. Generierung von Trainingsgebieten. (a) Ausschnitt aus IKONOS Szene (b) automatisch extrahierte Linie (c) extrahierte Kanten (d) relevante Kanten innerhalb eines Puffers (e) parallele Kanten (f) Trainingsgebiet

Die Begrenzungen der Trainingsgebiete bilden die Kanten in den Bildern. Die Bereiche an den Kanten entsprechen jedoch meist nicht den spektralen Eigenschaften von Straßen, da hier die Reflexion sowohl vom Straßenbelag, als auch von der Umgebung beeinflusst ist. Dieses Problem wird zusätzlich noch dadurch verschärft, dass die Bodenauflösung der spektralen Information in den pan-sharpened Daten deutlich geringer ist als die nominelle Bodenauflösung. Die Mischpixel werden vor der Nutzung als Trainingsgebiet entfernt (siehe Abbildung 20), um die Straßen möglichst gut rekonstruieren zu können. Die Entfernung der Mischpixel erfolgt mittels morphologischer Erosion (NISCHWITZ und HABERÄCKER 2004) der Trainingsgebiete mit einem Kreis als strukturierendem Element. Empirisch wurde für den Radius die halbe Bodenauflösung der originalen Farbkanäle, die für das pan-sharpening verwendet wurden, als sinnvoller Wert ermittelt.

Für eine zuverlässige Beschreibung der radiometrischen Eigenschaften ist eine minimale Größe der Trainingsgebiete notwendig. In (CAMPBELL 2002) wird eine Größe von 100 Pixeln als Mindestgröße vorgeschlagen. Dieser Wert konnte, für ausreichend große Testgebiete, anhand von ausgiebigen Testreihen bestätigt werden. Durch die Verwendung einer minimalen Größe für Trainingsgebiete gelingt zusätzlich auch noch eine relativ sichere Abgrenzung gegenüber Hausdächern, die zwar häufig ähnliche geometrische Eigenschaften wie Straßenabschnitte besitzen, jedoch meist in der Größe beschränkt sind.

### Klassifikationsansatz

Ziel des in dieser Arbeit vorgestellten Klassifikationsansatzes für höchstauflöste multispektrale Satellitenbilddaten ist es, für jedes Bildelement einen Zugehörigkeitswert zur Klasse *Straße* zu bestimmen. Hierbei ist es unerheblich, zu welcher Art von Straße das entsprechende Bildelement gehört. D.h., es wird nicht unterschieden, ob eine Straße z.B. aus neuem Asphalt oder aus Schotter besteht. Während bei klassischen Klassifikationsverfahren, wie z.B. Maximum-Likelihood oder Minimum-Distance Klassifikation, das Ziel eine möglichst gute explizite Separierung von Straßenklasse und der Hintergrundklasse ist (ALBERTZ 2001, CAMPBELL 2002), wird bei dem hier beschriebenen Ansatz lediglich die Information der Klasse *Straße* verwendet, um für jedes Bildelement einen Zugehörigkeitswert zu bestimmen. Um den Klassifikationsansatz flexibel zu halten und eine beliebige Zahl an Bedingungen einbeziehen zu können, wurde ein auf Fuzzy-Sets (siehe Abschnitt 2.3.3) beruhender Ansatz gewählt. Als zusätzliche, „nichtspektrale“ Bedingungen können mit dem Ansatz Kriterien, wie



Abbildung 20. Generierung von Trainingsgebieten. (a) Trainingsgebiete mit Mischpixeln (b) Trainingsgebiete ohne Mischpixel  
z.B. der Abstand des Trainingsgebiets vom jeweiligen Bildelement, d.h. eine Entfernungsbedingung oder Formparameter aus einer Segmentierung, relativ einfach integriert werden, da diese sehr einfach mit einem Fuzzy-Wert beschrieben werden können. Im Rahmen dieser Arbeit wurde die Entfernungsbedingung als „nichtspektrale“ Bedingung implementiert. Im Folgenden wird sie exemplarisch für zusätzliche Bedingungen im Klassifikationsansatz näher beschrieben.

Die Grundlage des Klassifikationsansatzes bilden die im vorangegangenen Arbeitsschritt extrahierten Trainingsgebiete. Deren Bestimmung erfolgte nach rein geometrischen Gesichtspunkten ohne Berücksichtigung der spektralen Eigenschaften der einzelnen Gebiete. So können die Trainingsgebiete sowohl Straßen, die im Bild hell, als auch solche, die dunkel abgebildet werden, repräsentieren. Hiermit wird es möglich unterschiedliche Straßenarten in einem Klassifikationsschritt gemeinsam zu verarbeiten. Um dies auch im weiteren Verlauf des Klassifikationsansatzes zu berücksichtigen, wird aus den einzelnen Gebieten keine vereinheitlichte Region gebildet, bei der die spektralen Eigenschaften nicht nur „geglättet“ wären, sondern sich vor allem auch z.T. widersprechen würden. Stattdessen werden alle Trainingsgebiete zunächst so betrachtet, als ob sie jeweils eine eigene Klasse repräsentierten. Der Klassifikationsansatz wird mit jedem Trainingsgebiet also zunächst separat durchgeführt und erst anschließend werden die Teilergebnisse vereinigt. Der Ablauf des Klassifikationsansatzes besteht aus den folgenden vier Teilschritten (siehe Abbildung 18):

- ◇ Erstellung von Zugehörigkeitsfunktionen für jedes Trainingsgebiet
- ◇ Bestimmung von Zugehörigkeitswerten für jedes Bildelement
- ◇ Kombination der Zugehörigkeitswerte
- ◇ Rang Filterung

*Erstellung von Zugehörigkeitsfunktionen für jedes Trainingsgebiet*

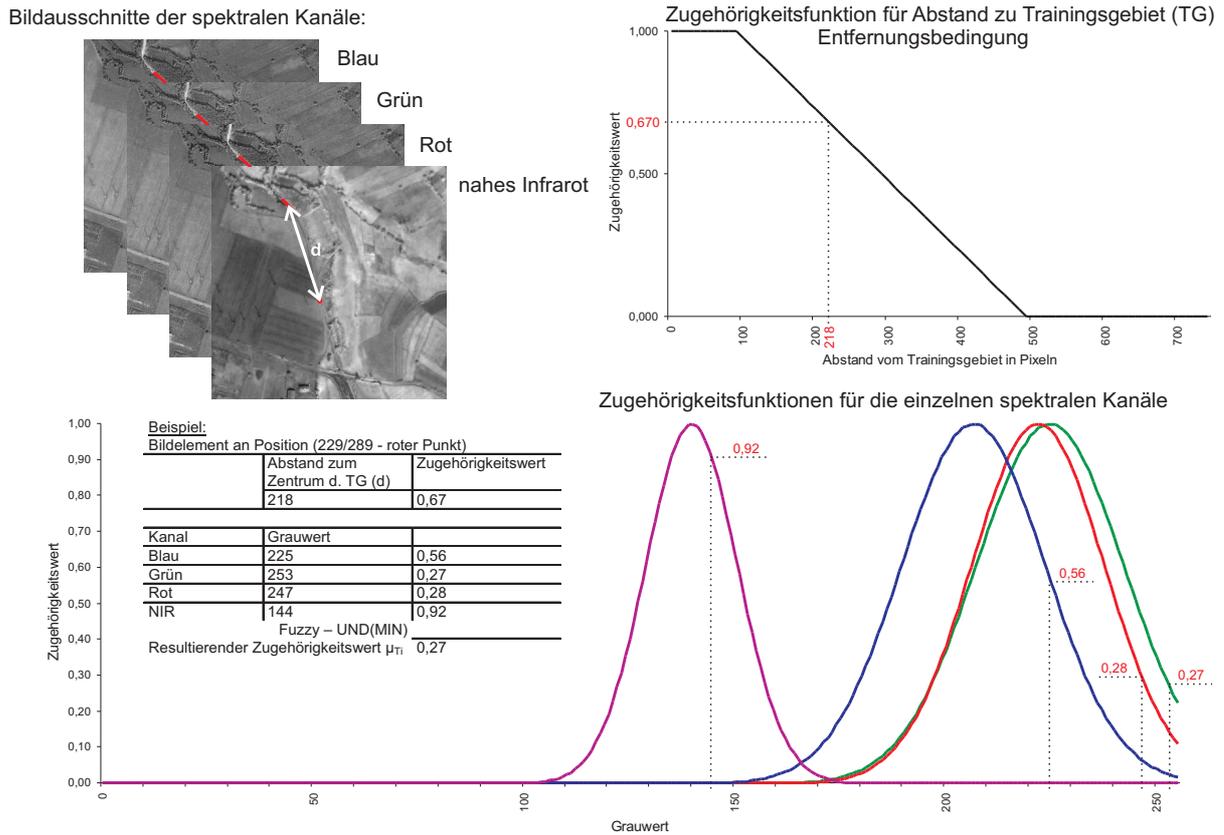


Abbildung 21. Bestimmung des Zugehörigkeitswertes eines Bildelements zu einem Trainingsgebiet bei Verwendung einer zusätzlichen Abstandsbedingung: Mit Hilfe der spektralen Eigenschaften des Trainingsgebietes oben links werden die unten rechts dargestellten Gaußschen Zugehörigkeitsfunktionen gebildet. Exemplarisch wird für ein Bildelement der Zugehörigkeitswert jedes spektralen Kanals anhand der zugehörigen Funktion ermittelt. Ein weiterer Zugehörigkeitswert wird mittels der oben rechts dargestellten Zugehörigkeitsfunktion für den Abstand  $d$  zwischen Trainingsgebiet und Bildelement bestimmt. Die Tabelle links unten listet die fünf ermittelten Zugehörigkeitswerte auf und zeigt den mit dem Fuzzy UND(MIN) Operator ermittelten resultierenden Zugehörigkeitswert des Bildelements zum gezeigten Trainingsgebiet.

Für jedes Trainingsgebiet wird pro Spektralkanal sowie für jede zusätzliche Bedingung eine Zugehörigkeitsfunktion  $\mu_i(x)$  (siehe Abschnitt 2.3.3) aufgestellt. Als Form für die Zugehörigkeitsfunktion wurde die Gaußsche Zugehörigkeitsfunktion

$$\mu(x) = e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (12)$$

gewählt, da hiermit, wie empirische Untersuchungen gezeigt haben, die Charakteristik der Grauwertverteilung innerhalb der Trainingsgebiete gut repräsentiert wird. Für die Zugehörigkeitsfunktionen der spektralen Eigenschaften werden daher Mittelwert  $m$  und Standardabweichung  $\sigma$  der Grauwerte des Trainingsgebiets benötigt. Ein Beispiel für einen Satz Gauß'scher Zugehörigkeitsfunktionen für ein Trainingsgebiet ist in Abbildung 21 unten rechts dargestellt. Die Form der Zugehörigkeitsfunktion für zusätzliche Bedingungen hängt von der Art der Bedingung ab. Die in dieser Arbeit verwendete Abstandsbedingung, die den Abstand des betrachteten Bildelements vom Zentrum des Trainingsgebiets beschreibt, wird als lineare Zugehörigkeitsfunktion realisiert, wobei die Straßeneigenschaften der näheren Umgebung stärker berücksichtigt werden als die der weiter entfernten.

### Bestimmung von Zugehörigkeitswerten für jedes Bildelement

Als Eingangswerte für die Bestimmung der Zugehörigkeitswerte für ein Bildelement zu den spektralen und lagemäßigen Eigenschaften eines jeden Trainingsgebietes, dienen die Grauwerte aus den einzelnen Spektralkanälen an der entsprechenden Stelle im Bild sowie der Abstand des betrachteten Bildelements vom Zentrum des Trainingsgebietes. Mit diesen Eingangswerten werden die Zugehörigkeitswerte aus den dazugehörigen Zugehörigkeitsfunktionen bestimmt (siehe Abbildung 21). Die Abbildung verdeutlicht die Bestimmung des Zugehörigkeitswertes eines Bildelements zu einem Trainingsgebiet bei Verwendung einer zusätzlichen Abstandsbedingung. Die spektralen Eigenschaften des Trainingsgebietes führen zu den unten rechts dargestellten Gaußschen Zugehörigkeitsfunktionen. Zusätzlich wird die oben rechts dargestellte Zugehörigkeitsfunktion für den Abstand  $d$  zwischen Trainingsgebiet und Bildelement verwendet.

### Kombination der Zugehörigkeitswerte

Für jedes Bildelement werden pro Trainingsgebiet  $k + m$  Zugehörigkeitswerte  $(\mu_{k_1}, \mu_{k_2}, \dots, \mu_{k_k}, \mu_z)$ , mit  $k = \text{Anzahl der spektralen Kanäle}$  und  $m = \text{Anzahl der zusätzlichen Bedingungen}$ , bestimmt. Jeder dieser Werte steht für eine Bedingung, die für den Klassifikationsansatz alle möglichst gut erfüllt werden müssen. Dies wird hier realisiert, indem eine logische UND Verknüpfung durchgeführt wird. In der Fuzzy-Set Theorie wird diese Verknüpfung mit dem MIN Operator (siehe Abschnitt 2.3.3) bestimmt. Die Berechnung des Zugehörigkeitswertes eines Bildelements aus den spektralen und zusätzlichen Bedingungen eines Trainingsgebietes  $\mu_{T_i}$  erfolgt gemäß Formel 13. Die Zugehörigkeitswerte aller Bildelemente für alle Trainingsgebiete werden in Vektoren gesammelt (siehe Abbildung 22). Daraus wird mit der abschließenden Rang Filterung das endgültige Straßenklassenbild bestimmt.

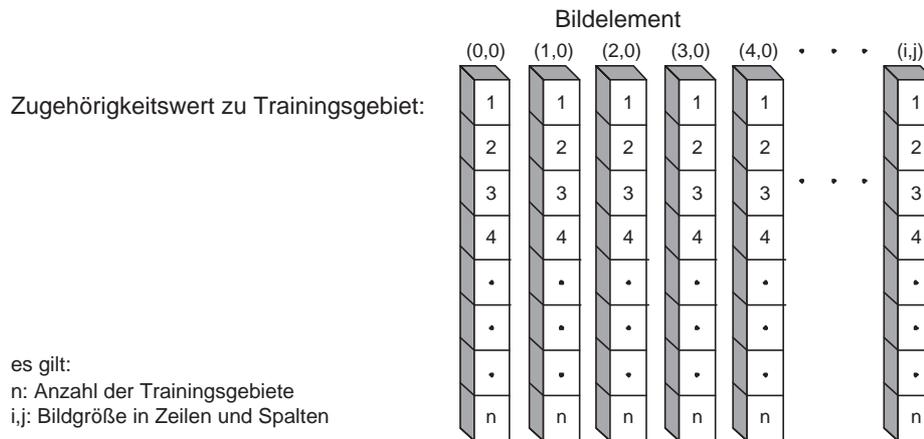


Abbildung 22. Zugehörigkeitsvektoren für die einzelnen Bildelemente

$$\mu_{T_i} = \mu_{k_1} \wedge \mu_{k_2} \wedge \dots \wedge \mu_{k_k} \wedge \mu_z = \mathbf{MIN}(\mu_{k_1}, \mu_{k_2}, \dots, \mu_{k_k}, \mu_z) \quad (13)$$

### Rang Filterung

Durch die unterschiedlichen spektralen Eigenschaften verschiedener Straßenabschnitte wird nicht mit jedem Trainingsgebiet das komplette Straßennetz an jeder Stelle gleich gut repräsentiert. Für die Straßenextraktion ist man aber auch nicht in erster Linie an den unterschiedlichen Straßeneigenschaften interessiert, sondern nur an einem möglichst verlässlichen Zugehörigkeitswert für jedes Bildelement zur Klasse *Straße*. Hierfür werden die einzelnen Zugehörigkeitsvektoren (siehe Abbildung 22) der

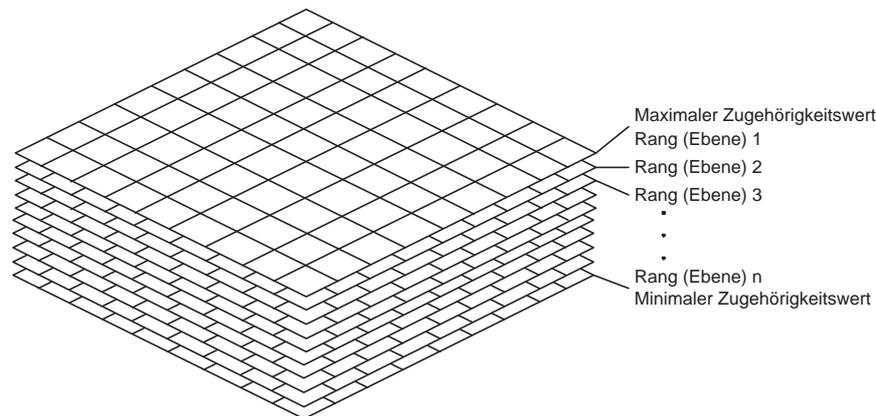


Abbildung 23. Rang Filter für die Ergebnisse des Klassifikationsansatzes. Die Zugehörigkeitswerte für jedes Bildelement werden sortiert und in die entsprechende Ebene geschrieben (n: Anzahl der verwendeten Trainingsgebiete).

Größe nach sortiert und es wird angenommen, dass die maximalen Werte für jedes Bildelement den Grad der Zugehörigkeit zur Klasse *Straße* wiedergeben (siehe Abbildung 23). Im Weiteren wird davon ausgegangen, dass ein oder einige wenige falsche Trainingsgebiete, d.h. Regionen, die nicht zur Klasse *Straße* gehören, bei Nicht-Straßenpixeln nur einen Einfluss auf die oberste bzw. die obersten Ebenen haben, da die spektralen Eigenschaften dieser Regionen nur einmal vorkommen. Die Eigenschaften von Straßen werden dagegen durch weit mehr Trainingsgebiete repräsentiert und sorgen damit für hohe Zugehörigkeitswerte nicht nur in den obersten Ebenen. Um gegenüber Ausreißern robuster zu sein, werden deswegen für die weitere Verarbeitung nicht die maximalen Werte, die auf der Ebene mit dem Rang 1 liegen, verwendet, sondern es werden die  $r$  besten Ebenen ignoriert. Die Anzahl  $r$  der ignorierten Ebenen richtet sich nach der Anzahl der verwendeten Trainingsgebiete. Erfahrungsgemäß ist für  $r$  ein Wert von etwa 5 - 10 % der Trainingsgebietsanzahl sinnvoll.

Das Ergebnis des Rangfilters ist das so genannte „Straßenklassenbild“, das für jedes Bildelement die Zugehörigkeit zur Klasse *Straße* wiedergibt. Das Straßenklassenbild nimmt Werte aus dem Intervall  $[0, 1]$  an, wobei 0 keine Zugehörigkeit und 1 volle Zugehörigkeit bedeutet. Für die weitere Verarbeitung sowie zur Visualisierung wird das Straßenklassenbild in ein Grauwertbild mit einem Grauwertumfang von 0–255 umgewandelt. Ein Beispiel für die Anwendung des Rangfilters zeigt Abbildung 24.

#### 4.3.2 Bildung und Verifikation von Straßenhypothesen

Der Schwerpunkt der Erweiterungen des Ansatzes von (WIEDEMANN et al. 1998, WIEDEMANN 2002) für die Nutzung von multispektralen, höchstauflösenden Satellitenbilddaten liegt auf der umfassenden Nutzung der spektralen Bildinformationen für die Straßenextraktion. Die Basis hierfür bildet der im vorangegangenen Abschnitt vorgestellte automatische Klassifikationsansatz. Der in Abbildung 17 dargestellte Ablauf des modifizierten Verfahrens zur Straßenextraktion wird im Folgenden ausführlich erläutert.

#### Linienextraktion

Straßen bilden sich in höchstauflösenden Satellitenbildern meist als helle oder dunkle Linien mit einer Breite von mehreren Bildelementen ab, sehr selten nur als langgestreckte „Stufen“ zwischen

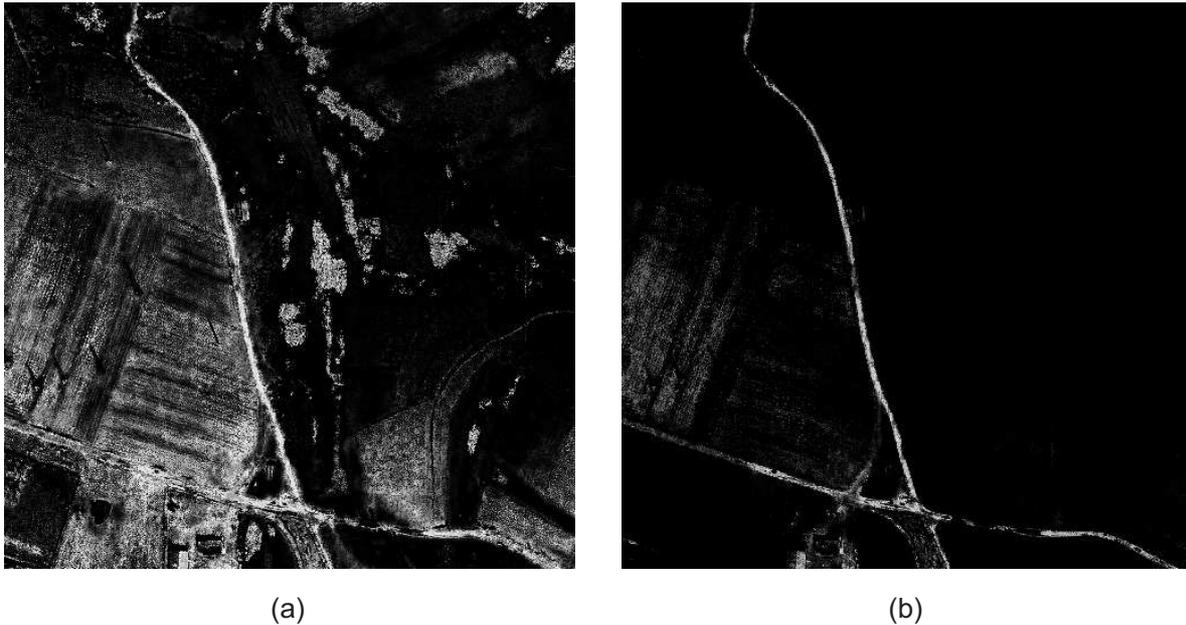


Abbildung 24. Ergebnis des Klassifikationsansatzes – Straßenklassenbild. (a) ohne Rangfilter (b) mit Rangfilter (Rang 2, Originalbild siehe Abbildung 20)

Regionen, die auf der einen Seite heller und auf der anderen Seite dunkler sind als die Straße. Für ein System zur automatischen Extraktion von Straßen in dieser Auflösung ist die Linienextraktion somit das wichtigste Werkzeug. In der vorliegenden Arbeit wird der Steger Linienextraktor (siehe Abschnitt 2.3.1) verwendet. In Satellitenbildern gibt es neben Straßen auch noch andere linienhafte Objekte, wie z.B. schmale Felder, langgestreckte Gebäude oder Flüsse, die im Rahmen der folgenden Bewertung möglichst von den Straßen getrennt werden sollen. Eine Änderung der Bedeutung von Linien findet erfahrungsgemäß meist an Stellen mit starker Krümmung statt (WIEDEMANN 2002). Deswegen werden die Linien an Stellen mit hoher Krümmung aufgeschnitten und im weiteren Verlauf jeweils als eigenständige Straßenhypothesen behandelt.

Das in Abschnitt 4.3.1 beschriebene Straßenklassenbild hat im Vergleich zu den originalen Bilddaten den Vorteil, dass Straßen hier immer als helle langgestreckte Flächen mit meist sehr deutlichem Kontrast zum dunklen Hintergrund abgebildet werden. Deshalb bietet es sich an, das Straßenklassenbild als zusätzliche Datenquelle für die Linienextraktion zu verwenden. Die Auswahl der für die Extraktion benötigten Parameter ist für diese Daten einfach und unabhängig von der lokalen Ausprägung der Straßen im Originalbild.

### Bewertung von Straßenhypothesen

Für die Bewertung von Straßenhypothesen werden in (WIEDEMANN 2002), abgesehen von der Konstanz des Grauwerts, nur rein geometrische Merkmale verwendet. Um die Bewertung der Straßenhypothesen unabhängiger vom räumlichen Verlauf, d.h. lokalen starken Richtungsänderungen, zu machen und um gleichzeitig die radiometrischen Eigenschaften der Straßen zu berücksichtigen, wurde im Rahmen dieser Arbeit die Menge der Bewertungskriterien angepasst. Die Länge sowie die durchschnittliche Breite der Linie wurden als Bewertungskriterien übernommen. Das Längenkriterium ist sinnvoll, da hiermit eine Möglichkeit geschaffen wird kurze Linienfragmente, die z.B. in

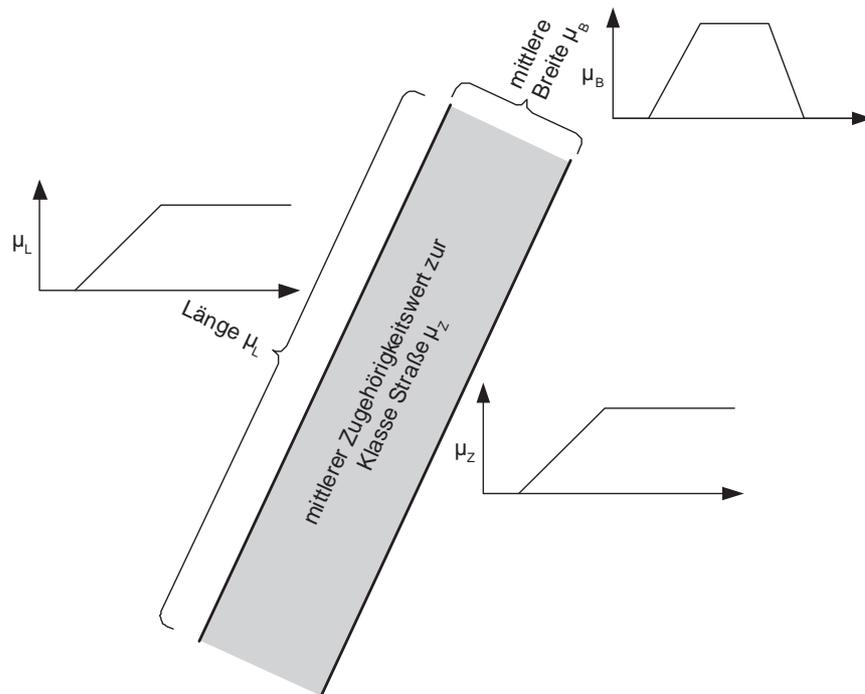


Abbildung 25. Bewertungskriterien für die Bewertung von Straßenhypothesen sowie die für die Bestimmung der Fuzzy-Werte verwendeten Zugehörigkeitsfunktionen.

bebauten Gebieten extrahiert werden, mit einem niedrigen Zugehörigkeitswert zu bewerten. Durch die durchschnittliche Straßenbreite als Bewertungskriterium wird es einerseits möglich lang gestreckte Objekte mit einer größeren Breite als für Straßen üblich, wie z.B. schmale Felder oder lang gestreckte Gebäude, schlecht zu bewerten oder andererseits den Fokus auf bestimmte Straßenklassen, wie z.B. Hauptstraßen, zu legen. Zusätzlich wird der mittlere Zugehörigkeitswert zur Klasse *Straße* entlang der Straßenhypothese als neues Maß hinzugefügt. Er berechnet sich aus den Zugehörigkeitswerten aus dem Straßenklassenbild aus Abschnitt 4.3.1 entlang des Straßenstücks, indem um die Linie ein Puffer gelegt wird und der Mittelwert aller Zugehörigkeitswerte aus dem Puffer bestimmt wird. Empirische Untersuchungen haben als sinnvollen Wert für die Puffergröße die geschätzte Straßenbreite reduziert um den Rand ergeben. Die von Wiedemann verwendeten Bewertungskriterien Konstanz der Breite und Geradlinigkeit werden nicht verwendet. Durch den Verzicht auf diese Kriterien wird es möglich, auch Straßenhypothesen, in deren Verlauf ein Teil verdeckt ist und somit die Breite nicht konstant bleibt, gut zu bewerten. Ebenso verhält es sich mit der Bewertung von Straßen mit engen Kurven, wie z.B. Gebirgsstraßen.

Im Detail werden für die Bewertung der Straßenhypothesen die folgenden Kriterien (siehe Abbildung 25) als vorläufige Fuzzy-Werte für jedes Linienstück bestimmt:

- ◇ Länge ( $\mu_L$ )
- ◇ mittlere Breite ( $\mu_B$ )
- ◇ mittlerer Zugehörigkeitswert zur Straßenklasse ( $\mu_Z$ )

Diese vorläufigen Fuzzy-Werte werden mit dem Fuzzy UND Operator (siehe Abschnitt 2.3.3) nach

Formel (14) zum Fuzzy-Wert  $\mu_S$  vereinigt

$$\mu_S = \mu_L \wedge \mu_B \wedge \mu_Z = \mathbf{MIN}(\mu_L, \mu_B, \mu_Z) \quad (14)$$

### Fusion der Linien

Straßen werden in verschiedenen spektralen Kanälen unterschiedlich gut abgebildet. Damit ein Großteil der zur Verfügung stehenden Information genutzt wird, werden die vorangegangenen Arbeitsschritte für jeden Kanal separat durchgeführt. Um für die weitere Verarbeitung zu einem konsistenten Datensatz zu kommen, werden die Linienstücke gemäß (WIEDEMANN 2002) fusioniert (siehe auch Abschnitt 4.4.1).

### Netzwerkbildung – Bildung kürzester Pfade

Die Bildung eines topologisch korrekten Straßennetzes aus den einzelnen bewerteten Straßenhypothesen erfolgt mit dem in (WIEDEMANN 2002) beschriebenen Verfahren zur Netzwerkbildung (siehe Abschnitt 2.3.4).

#### 4.3.3 Verifikation von Verbindungshypothesen

Das mit den Mitteln des vorhergehenden Abschnitts extrahierte Straßennetz ist in der Regel unvollständig. Im Rahmen der abschließenden Netzwerkbildung wurden nur kurze Lücken ohne Rückgriff auf Bildinformation überbrückt. Um verbliebene größere Lücken zu schließen, wird eine globale Gruppierung nach (WIEDEMANN 1999, WIEDEMANN und EBNER 2000, WIEDEMANN 2002) durchgeführt (siehe Abschnitt 2.3.4). Damit werden wahrscheinlich fehlende Verbindungen bestimmt und an ein Modul zur Verifikation inkl. Pfadbestimmung übergeben. Das im Rahmen der vorgelegten Arbeit entwickelte Modul für Letzteres, nutzt das Straßenklassenbild (siehe Abschnitt 4.3.1) in Verbindung mit einer Ziplock-Snake (siehe Abschnitt 2.3.3) für die Bestimmung der Verbindung sowie deren Verifikation. Dazu werden die Koordinaten der beiden Endpunkte der Verbindungshypothese sowie jeweils die Startrichtung an das Verifikationsmodul übergeben.

### Bestimmung des Pfads der Verbindung

Für die Bestimmung des Pfads einer fehlenden Verbindung sind verschiedene Verfahren sinnvoll. Bei sehr kurzen Lücken kann die Verbindung meist durch eine Gerade approximiert werden. Werden die Lücken größer, so stimmt die direkte Verbindung meist nicht mit dem tatsächlichen Verlauf der Straße überein. Somit wird es notwendig, den Verlauf anhand der Bildinformation zu bestimmen. (WIEDEMANN 2002) schlägt für die Bestimmung des Pfads das selbe Verfahren vor, das für die Extraktion des Straßennetzes genutzt wurde, allerdings mit weniger strengen Parametern. Eine andere Möglichkeit zur Überbrückung von Lücken wird in (MAYER et al. 1997) vorgestellt. Hier wird eine aus zwei parallelen Kanten bestehende, so genannte „Ribbon-Snake“, zwischen den Endpunkten der Verbindungshypothese eingepasst und basierend auf der Konstanz des Abstands zwischen den beiden Kanten verifiziert. Das Verfahren ist auf parallele Kanten beschränkt. Ebenfalls für parallele Kanten

können die so genannten „Twin-Snakes“ (KERSCHNER 2001, KERSCHNER 2003) eingesetzt werden. Hier werden zwei Kurven mit ähnlicher Form betrachtet. Das Energieminimum wird erreicht, wenn der Abstand der beiden Kurven möglichst konstant ist.

Auch das im Rahmen der vorgelegten Arbeit entwickelte Verfahren basiert auf Snakes (siehe Abschnitt 2.3.2). Es nutzt als Bildinformation das Ergebnis des Klassifikationsansatzes, d.h., das Strassenklassenbild (siehe Abschnitt 4.3.1). Zwischen den beiden an das Modul übergebenen Endpunkten der potentiellen Verbindung wird eine Ziplock-Snake eingepasst. Die Snake wird auf helle Linien optimiert. Die Nutzung des Straßenklassenbildes als Bildinformation für die Optimierung hat gegenüber der originalen Bildinformation den Vorteil, dass hier nur Bildbereiche mit der spektralen Signatur wahrscheinlicher Straßen hell dargestellt werden. Es macht somit für die Berechnung der Snake keinen Unterschied, ob sich Straßen als helle oder dunkle Linien abbilden. Ein weiterer Vorteil besteht darin, dass die Zahl der Störobjekte, zu denen die Snake hingezogen werden kann, minimiert wird, da die Umgebung der Straßen in der Regel einheitlich dunkel abgebildet wird. Der Ziplock-Snake ist gegenüber einer konventionellen Snake deshalb vorteilhaft, da durch die Optimierung von den beiden bekannten Endpunkten aus hin zur Mitte die Gefahr, an falschen Minima hängen zu bleiben, minimiert wird.

### Verifikation der Verbindung

Eine Eigenschaft von Snakes besteht darin, dass sie in jedem Fall ein Energieminimum erreichen, unabhängig davon, ob sinnvolle Bildinformation vorhanden ist oder nicht. Deswegen ist es notwendig, den Verlauf der Snake, d.h. den Pfad der neuen Verbindung, zu überprüfen. Hierfür wird die Bildinformation des Straßenklassenbildes entlang der Kurve betrachtet (siehe Abbildung 26). Für eine sinnvolle Verbindung wird folgendes gefordert:

- ◇ Die Zugehörigkeitswerte zur Klasse Straße müssen über einem festgelegten Schwellwert liegen.
- ◇ Das Profil im Straßenklassenbild senkrecht zur Richtung der Snake muss balkenförmig sein.

Mit der ersten Bedingung werden nur Ergebnisse akzeptiert, bei denen sich die Snake an ein Straßenobjekt angepasst hat. Durch die zweite Bedingung werden Verbindungen ausgeschlossen, die zwar durch ein Gebiet mit entsprechenden Zugehörigkeitswerten verlaufen, die jedoch keine Straßen repräsentieren. Dies gilt z.B. für Felder oder Felsgebiete, die spektrale Eigenschaften vergleichbar denen der benachbarten Straßen besitzen. Die Verbindung wird verworfen wenn eine der beiden Bedingungen verletzt wird.

Die erste Bedingung wird mit dem in Abschnitt 4.3.2 beschriebenen Verfahren zur Bestimmung des mittleren Zugehörigkeitswertes einer Linie zur Klasse Straße überprüft. Um hierbei der Besonderheit von Lücken, d.h., weniger deutliche Straßeninformation, gerecht zu werden, wird der Schwellwert für die Akzeptanz einer Verbindung herabgesetzt. Ist die erste Bedingung erfüllt werden für die Überprüfung der zweiten Bedingung an den Stützpunkten der Snake Grauwertprofile senkrecht zur Kurvenrichtung im Straßenklassenbild gebildet (siehe Abbildung 26). Die einzelnen Profile werden auf Balkenform hin untersucht. Hierfür wird jedes Profil zunächst mittels eines Gaußschen Filters gefaltet, um damit die „Energie“ des Profils im Bereich des Maximums zu konzentrieren (siehe Abbildung 26(d)). Für das Vorliegen einer Balkenform müssen die folgenden Kriterien erfüllt sein:

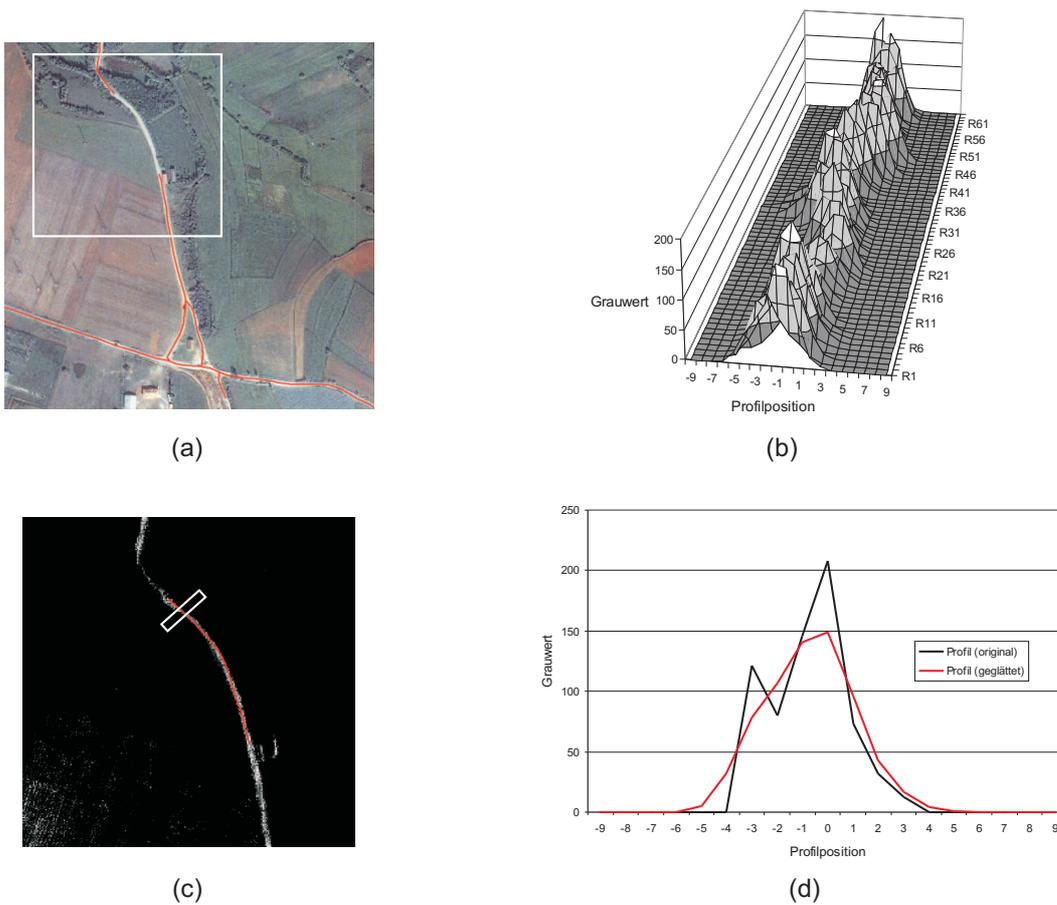


Abbildung 26. Verifikation einer Verbindungshypothese; (a) Netzwerk mit Lücke (Verbindungshypothese); (b) Grauwertprofile senkrecht zur mittels der Ziplock-Snake optimierten Verbindung; (c) optimierte Verbindung (rot) im Straßenklassenbild - Ausschnitt weißer Kasten aus (a); (d) Grauwertprofil senkrecht zur Verbindung an der Position des weißen Kastens in (c)

- ◇ Der Scheitelpunkt des Profils, d.h. der Punkt, an dem die erste Ableitung entlang des Profils Null ist, muss etwa in der Mitte liegen ( $\mu_C$ ).
- ◇ Die zweite Ableitung entlang des Profils muss im Scheitelpunkt einen großen negativen Wert aufweisen ( $\mu_D$ ).

Für die beiden Kriterien werden Fuzzy-Variablen mit einer linearen Zugehörigkeitsfunktion verwendet, die als Eingangswerte den Abstand zum Mittelpunkt des Profils bzw. den Wert der zweiten Ableitung an diesem Punkt besitzen. Aus den vorläufigen Fuzzy-Werten wird mit Hilfe des Fuzzy UND Operators (siehe Formel (15)) ein Bewertungsmaß  $\mu_{Profil}$  für das jeweilige Profil gebildet.

$$\mu_{Profil} = \mu_C \wedge \mu_D = \mathbf{MIN}(\mu_C, \mu_D) \quad (15)$$

Als Bewertung für die Snake dient der Mittelwert der Bewertungen der einzelnen Profile. Eine Verbindungshypothese wird als verifiziert angesehen, wenn die Bewertung der Snake über einem vorgegebenen Schwellwert liegt. Das Verifikationsmodul übergibt im Falle der Verifikation die Trajektorie der Snake an das Modul zur globalen Gruppierung.

## 4.4 Straßenextraktion aus hochaufgelösten Satellitenbilddaten

Bei der Extraktion von Straßen aus hochaufgelösten Satellitenbilddaten kommen gemäß des Straßenmodells (siehe Abschnitte 4.1 und 4.2 sowie Abbildung 11) für die unterschiedlichen Kontextgebiete unterschiedliche Strategien zum Einsatz (BACHER und MAYER 2004). Für landwirtschaftlich genutzte Kontextgebiete, in denen sich Straßen oft nur indirekt anhand von Feldgrenzen erkennen lassen, werden Straßenabschnitte gebildet, die dann im Rahmen der globalen Gruppierung zu einem Straßennetz zusammengeführt werden. Für die Kontextgebiete Gebirge und Wüste wird der von Christian Wiedemann an der TU München entwickelte Ansatz (WIEDEMANN 2002, WIEDEMANN et al. 1998) verwendet, wobei die maximal zulässige Krümmung den jeweiligen Verhältnissen angepasst wird.

### 4.4.1 Generierung von Straßenabschnitten durch lokale Gruppierung

In Satellitenbilddaten mit einer Auflösung von 5 m und schlechter, wie IRS-1C/D, werden oft nur die größten Straßen als linienhafte Objekte abgebildet. Kleinere Straßen oder solche, bei denen der Straßenbelag ähnliche spektrale Eigenschaften besitzt wie Teile der Umgebung, können oft nur indirekt, mit Hilfe des Kontexts, erkannt werden. Abbildung 27 zeigt beispielhaft wie der Bildinhalt erst durch die Zuhilfenahme des Kontexts klar wird. Der Inhalt des kleinen Bildausschnitts auf der linken Seite ist isoliert nur unzureichend zu verstehen. Erst wenn er im Rahmen des Gesamtbildes betrachtet wird, lässt sich erkennen, dass es sich um eine Straße handelt, die zwischen zwei Feldern verläuft. Für die Erkennung von Straßen wird im Weiteren ausgenutzt, dass in landwirtschaftlich genutzten Gebieten die Feldgrenzen in der Regel entlang von Straßen oder Wegen verlaufen. Wenn sich die Nutzung der einzelnen Felder unterscheidet, haben sie unterschiedliche spektrale Eigenschaften und werden in den einzelnen spektralen Kanälen mit unterschiedlicher Intensität abgebildet. An den Grenzen der Felder entstehen somit Kanten in den Bildern deren „Stufung“ durch den Weg oder die Straße oft vernachlässigbar ist. Der menschliche Betrachter scheint diese Kanten zu längeren Strukturen zu verbinden und somit den Verlauf von Straßen und Wegen zu erfassen. Ziel des hier vorgestellten Ansatzes ist es, diese Idee auf die automatische Extraktion von Straßen zu übertragen.

Grundlage für das vorgestellte Verfahren (siehe Abbildung 28) sind automatisch extrahierte Linien und Kanten, die im Folgenden zusammenfassend als lineare Strukturen bezeichnet werden. Aus diesen werden Hypothesen für Verknüpfungen gebildet, die mit Hilfe von Ziplock-Snakes verifiziert werden. Die verifizierten Verknüpfungen, im Weiteren Straßenabschnitte genannt, werden zu einem einheitlichen Datensatz fusioniert. Verbleibende Lücken werden abschließend im Rahmen einer Netzwerkbildung geschlossen.

### Extraktion linearer Strukturen

Für die Extraktion linearer Strukturen wird der subpixelgenaue Linien- und Kantenextraktor nach Steger (siehe Abschnitt 2.3.1) in den spektralen Kanälen unabhängig voneinander eingesetzt. Um langgestreckte Objekte mit geringer Krümmung zu erhalten, werden die linearen Strukturen an Stellen mit einer Krümmung oberhalb eines vorgegebenen Schwellwertes aufgeschnitten. Die resultierenden linearen Strukturen aller Kanäle werden zu einem einheitlichen Datensatz fusioniert. Resultate der Linien- und Kantenextraktion sind in Abbildung 29 dargestellt. Für die Gruppierung der linearen



Abbildung 27. Nutzung von Kontext für die Extraktion von Straßen im ländlichen Raum

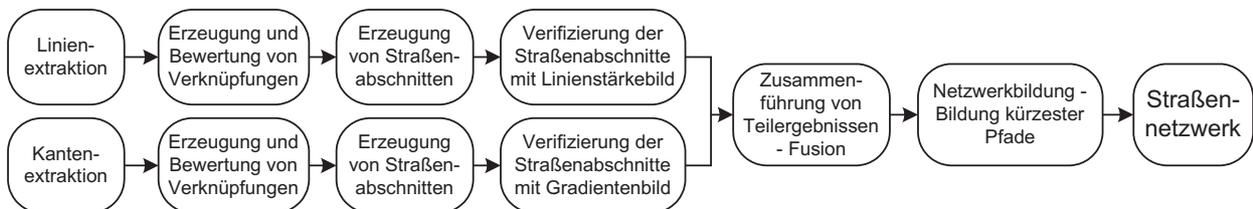


Abbildung 28. Ablauf der Straßenextraktion aus hochauflösten Satellitenbilddaten

Strukturen werden nur diejenigen verwendet, die eine vorgegebene Mindestlänge aufweisen (siehe Abbildung 30).

### Erzeugung und Bewertung von Verknüpfungshypothesen

Aus den linearen Strukturen sollen die Elemente bestimmt werden, die mit hoher Wahrscheinlichkeit Teile des Straßennetzes sind. Hierfür werden aus jeweils zwei linearen Strukturen Verknüpfungshypothesen aufgestellt. Um eine Hypothese zu bilden, müssen die linearen Strukturen die folgenden Bedingungen erfüllen (siehe auch Abbildung 31):

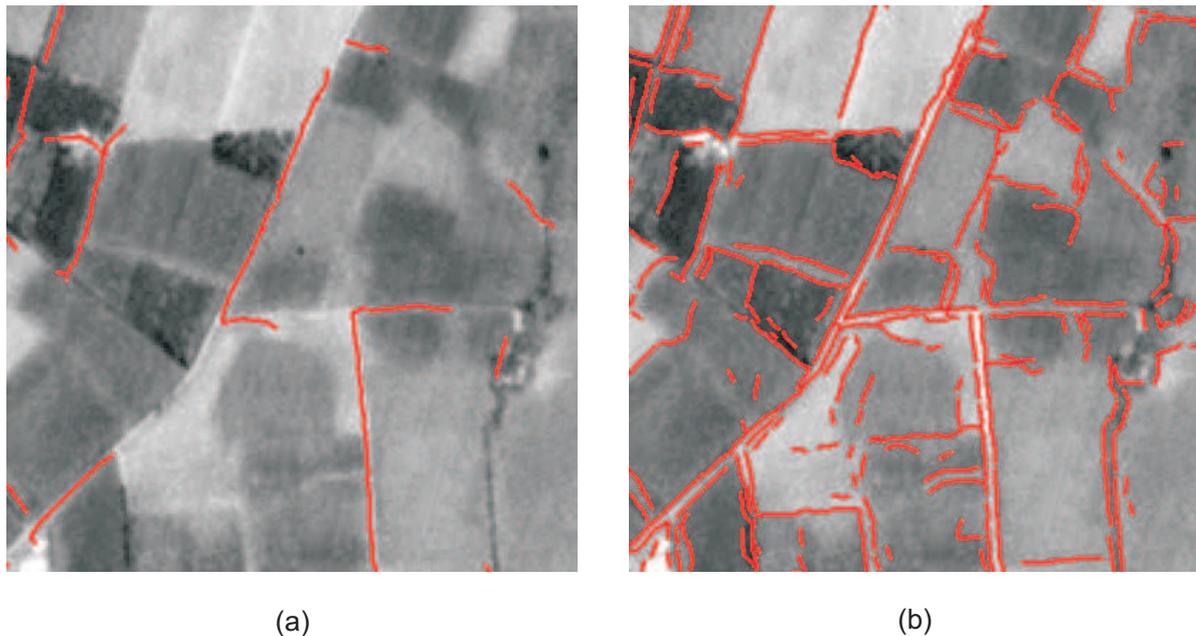


Abbildung 29. Extrahierte Linien (a) und Kanten (b). Die Bilder zeigen einen Ausschnitt des Bildes aus Abbildung 27.

- ◇ Die linearen Strukturen müssen kollinear sein ( $\mu_{C_1}$ ).
- ◇ Beide linearen Strukturen sowie die direkte Verbindung zwischen ihnen müssen kollinear sein ( $\mu_{C_{2,3}}$ ).
- ◇ Die linearen Strukturen müssen eine minimale Länge besitzen ( $\mu_{L_{1,2}}$ ).
- ◇ Die Länge der Verknüpfung muss zwischen einer unteren und einer oberen Schranke liegen ( $\mu_{L_3}$ ).

Die Bewertungsparameter für die Verknüpfungen  $\mu$  werden als Fuzzy-Werte interpretiert (siehe Abschnitt 2.3.3). Die Realisierung der Zugehörigkeitsfunktionen erfolgt als lineare ( $\mu_{C_{1-3}}$ ,  $\mu_{L_{1,2}}$ ) bzw. trapezförmige ( $\mu_{L_3}$ ) Funktion. Die einzelnen Fuzzy-Werte werden zu einem gemeinsamen Zugehörigkeitswert ( $\mu_{CON}$ ) mit dem Fuzzy UND Operator nach Formel (16) zusammengeführt. Verknüpfungen, die einen Zugehörigkeitswert  $\mu_{CON}$  größer als ein vorgegebener Schwellwert besitzen, werden für die Weiterverarbeitung selektiert.

$$\mu_{CON} = \mu_{C_1} \wedge \mu_{C_2} \wedge \mu_{C_3} \wedge \mu_{L_1} \wedge \mu_{L_2} \wedge \mu_{L_3} = \mathbf{MIN}(\mu_{C_1}, \mu_{C_2}, \mu_{C_3}, \mu_{L_1}, \mu_{L_2}, \mu_{L_3}) \quad (16)$$

### Erzeugung von Straßenabschnitten

Die Verknüpfungshypothesen wurden unter der Annahme einer direkten, d.h. geraden, Verbindung und ohne Zuhilfenahme von Bildinformation selektiert. Die Annahme einer direkten Verbindung zwischen benachbarten Startpunkten ist nur für sehr kleine Abstände, hier realisiert durch die untere Schranke von  $\mu_{L_3}$ , realistisch. Für größere Abstände muss der Verlauf der Verknüpfung auf Grundlage der Bildinformation bestimmt und der damit gebildete Straßenabschnitt verifiziert werden. Hierfür werden die gegenüberliegenden Endpunkte mit Hilfe einer Snake verbunden (siehe Abbildung 32).



Abbildung 30. Für die Gruppierung verwendete lineare Strukturen – (a) Linien und (b) Kanten. Die Bilder zeigen den selben Ausschnitt wie Abbildung 29.

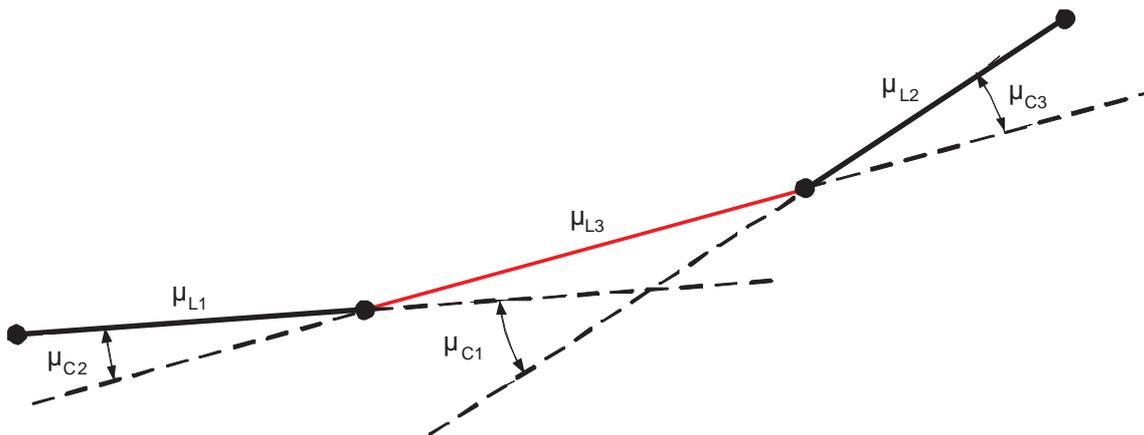


Abbildung 31. Bewertungsparameter für die Verknüpfungshypothese (rot)

Um die Probleme durch falsche Minima zu umgehen, wird wiederum (wie schon in Abschnitt 4.3.3) eine Ziplock-Snake (siehe Abschnitt 2.3.2) verwendet. Es wird nicht die originale Bildinformation sondern wie in (KLANG 1998) ein Linienstärke- bzw. Gradientenbild verwendet, je nachdem ob die Startpunkte aus der Linien- bzw. der Kantenextraktion stammen. Diese Bilder zeichnen sich für die Energieminimierung einer Snake gegenüber den originalen Bilddaten dadurch aus, dass nur die für die Anpassung relevanten Bildbereiche, d.h., Linien oder Kanten, als helle Linien dargestellt sind.

Das Linienstärkebild wird auf Grundlage der Eigenwerte der Hesse-Matrix (siehe Formel (1)) für jedes Bildelement berechnet. Die maximalen negativen Eigenwerte beschreiben die Stärke von hellen Linien, die maximalen positiven die Stärke von dunklen Linien. Experimente haben gezeigt, dass Straßen überwiegend als helle Linien abgebildet werden, weshalb nur die maximalen negativen Eigenwerte verwendet werden. Auch für Punktobjekte ergeben sich große negative Eigenwerte, die sich jedoch auf die Optimierung der Snake nicht negativ auswirken und deshalb nicht weiter betrachtet werden. Um

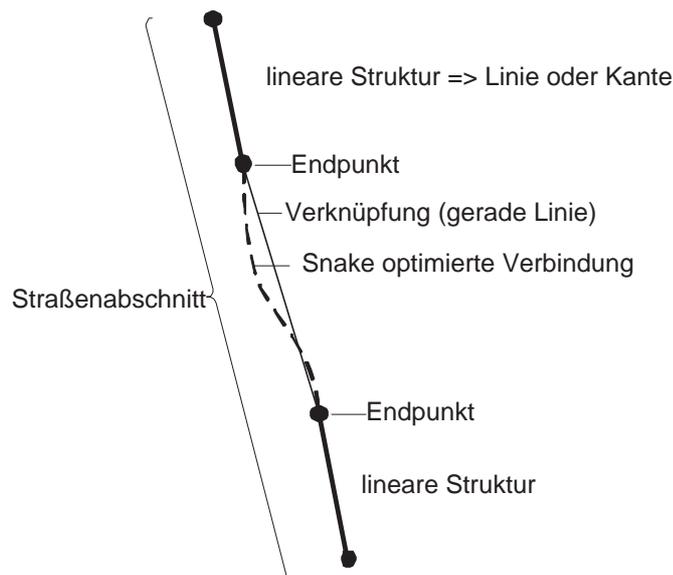


Abbildung 32. Definition eines Straßenabschnittes

die Bildinformation aller spektralen Kanäle für die Optimierung zu nutzen, werden die Linienstärken für alle Kanäle berechnet, für jedes Bildelement der höchste absolute Wert aus den einzelnen Kanälen bestimmt und im endgültigen Linienstärkebild abgelegt (siehe Abbildung 33, links).

Für das Gradientenbild wird jeder spektrale Kanal mit den Sobel Filtermasken ( $S_r$  und  $S_c$ ) gefaltet und hieraus der absolute Sobelwert  $S_{abs}$  mit Formel (17) berechnet. Das maximale Gradientenbild (siehe Abbildung 33 (b)) erhält man, indem für jedes Bildelement der maximale Wert ( $grad_{max}$ ) aus den einzelnen gefilterten spektralen Kanälen ( $grad_i = S_{abs}$  – absoluter Sobelwert im Kanal  $i$ ) genommen wird (siehe Formel 18).

$$S_r = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} \quad S_c = \begin{pmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{pmatrix} \quad S_{abs} = (|S_r| + |S_c|)/2 \quad (17)$$

$$grad_{max} = \max(grad_1, grad_2, \dots, grad_n) \quad (18)$$

### Verifizierung von Straßenabschnitten

Da Snakes ein Energieminimum auch dann finden, wenn keine sinnvollen Objekte im Bild vorhanden sind, ist es notwendig, den Verlauf der Snake auf Plausibilität zu überprüfen. Dies ist im vorgestellten Ansatz gleichbedeutend mit der Validierung des Straßenabschnitts, der durch die Snake und die zwei linearen Strukturen gebildet wird. Als Kriterium für die Überprüfung dient die Linien- bzw. Kantenstärke entlang des Pfades der Snake. Ein Straßenabschnitt wird also nur übernommen, wenn genügend Evidenz für das Vorhandensein einer linearen Struktur gefunden wird.

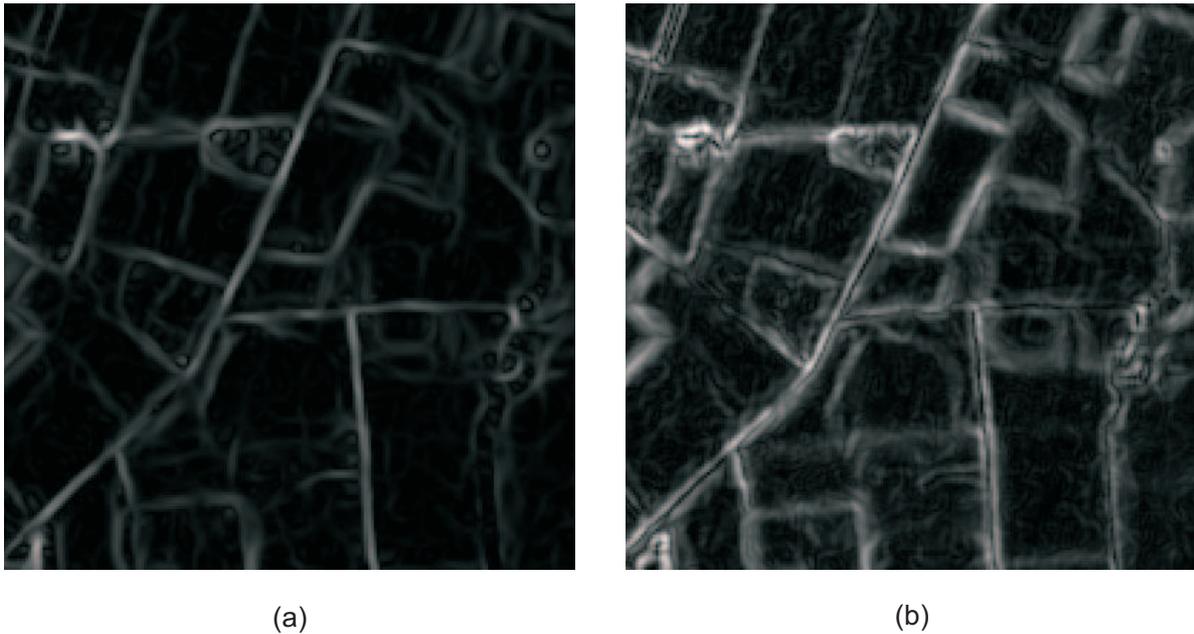


Abbildung 33. (a) Linienstärkebild, aufgebaut aus den maximalen Absolutwerten der maximalen negativen Eigenwerte der Hesse-Matrix jedes Bildelements für alle Kanäle. (b) Gradientenbild bestimmt durch Filterung des Bildes mit der Sobel-Filtermaske. Als Originalbild dient ein Ausschnitt des Bildes aus Abbildung 27 (siehe auch Abbildung 29 und 30).

Die Überprüfung der Linien- bzw. Kantenstärke entlang einer Snake wird auf Grundlage der bereits für die Optimierung der Snake verwendeten Linienstärke- bzw. Gradientenbilder (siehe z.B. Abbildung 33) durchgeführt. Es wird angenommen, dass sich die gesuchten Objekte, Linien oder Kanten, als Linien mit Gaußkurven-förmigem Profil abbilden. Im Rahmen der Validierung wird mittels verschiedener Parameter bewertet, wie gut dieses Kriterium an den Stützpunkten erfüllt ist. Hierfür werden an den Stützpunkten der Snake Profile senkrecht zur Linienrichtung ausgeschnitten (siehe Abbildung 34). Für deren Untersuchung werden die Grauwertprofile zunächst mit der Gaußschen Funktion geglättet:

$$g_{\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (19)$$

Als Wert für  $\sigma$  wird hierfür nach (STEGER 1998b) in Abhängigkeit von der Linien- bzw. Straßenbreite  $2w$ ,  $\sigma = w/\sqrt{3}$  gewählt. Für jedes Profil werden die folgenden Parameter bestimmt:

- ◇ Lage des Scheitelpunkts (Nullpunkt der ersten Ableitung)
- ◇ Wert der zweiten Ableitung im Scheitelpunkt

Für balkenförmige Profile müssen die Parameter folgende Bedingungen erfüllen:

- ◇ Der Scheitelpunkt des Profils muss in etwa in der Mitte des Profils, d.h. in der Nähe des „Snakepunkts“, liegen ( $\mu_{pos}$ ).

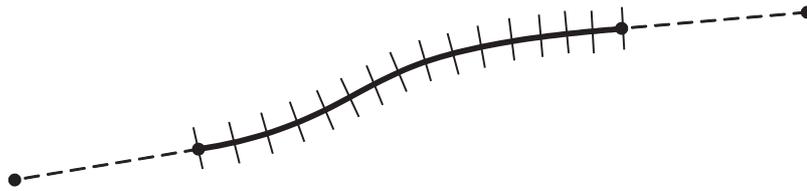


Abbildung 34. Profile senkrecht zur Snake-Richtung zur Validierung des Snake-Verlaufs

- ◇ Der Wert der zweiten Ableitung im Scheitelpunkt muss einen großen negativen Wert annehmen ( $\mu''$ ).

Die beiden Parameter sind als Fuzzy-Variablen mit linearer Zugehörigkeitsfunktion realisiert. Zusammengeführt zu einem Bewertungsmaß ( $\mu_{Profil}$ ) für das jeweilige Profil werden die Zugehörigkeitswerte mit dem Fuzzy UND Operator (siehe Abschnitt 2.3.3):

$$\mu_{Profil} = \mu_{pos} \wedge \mu'' = \mathbf{MIN}(\mu_{pos}, \mu''). \quad (20)$$

Der Verlauf der Snake wird akzeptiert, wenn die mittlere Bewertung aller Stützpunkte über einem gegebenen Schwellwert liegt und zusätzlich die Bewertungen jeweils eines Drittels der Stützpunkte oberhalb eines schwächeren Schwellwertes liegen. Ein Beispiel für die Überprüfung einer mittels Gradientenbildes optimierten Verknüpfung ist in Abbildung 35 dargestellt.

### Bewertung von Straßenabschnitten

Für die weitere Verarbeitung werden alle Straßenabschnitte mit einem Bewertungsmaß versehen. Als Maß wird die Bewertung der entsprechenden Verknüpfung verwendet. Straßenabschnitte, die aus der Verknüpfung zweier Linien stammen, haben in der Regel eine größere Bedeutung sowie eine höhere Genauigkeit als solche, die aus der Verknüpfung zweier Kanten hervorgegangen sind. Der Hauptgrund hierfür besteht darin, dass die Wahrscheinlichkeit, dass eine Linie einer Straße entspricht, sehr viel höher ist, als dass eine Kante einer Straße entspricht. Deswegen werden die Straßenabschnitte, die aus Linien resultieren, für die spätere Fusion höher gewichtet.

### Zusammenführung von Teilergebnissen - Fusion

In den bisherigen Schritten wurden Linien und Kanten sowie die daraus resultierenden Straßenabschnitte separat behandelt. Diese zwei bewerteten Datensätze werden mittels der in (WIEDEMANN 2002) vorgestellten Vorgehensweise zu einem konsistenten Datensatz fusioniert. Dazu werden alle Straßenabschnitte ihrer Bewertung nach sortiert. Der Straßenabschnitt mit der höchsten Bewertung wird direkt in das Ergebnis übernommen. Danach wird der nächstbeste Abschnitt untersucht, ob er sich mit einem bereits im Ergebnis befindlichen Abschnitt überlappt. Ist das nicht der Fall, wird der Straßenabschnitt ebenfalls in das Ergebnis übernommen. Bei überlappenden Straßenabschnitten wird nur der nicht überlappende Anteil in das Ergebnis übernommen. Die Fusion ist abgeschlossen, wenn alle Straßenabschnitte der Liste abgearbeitet sind.

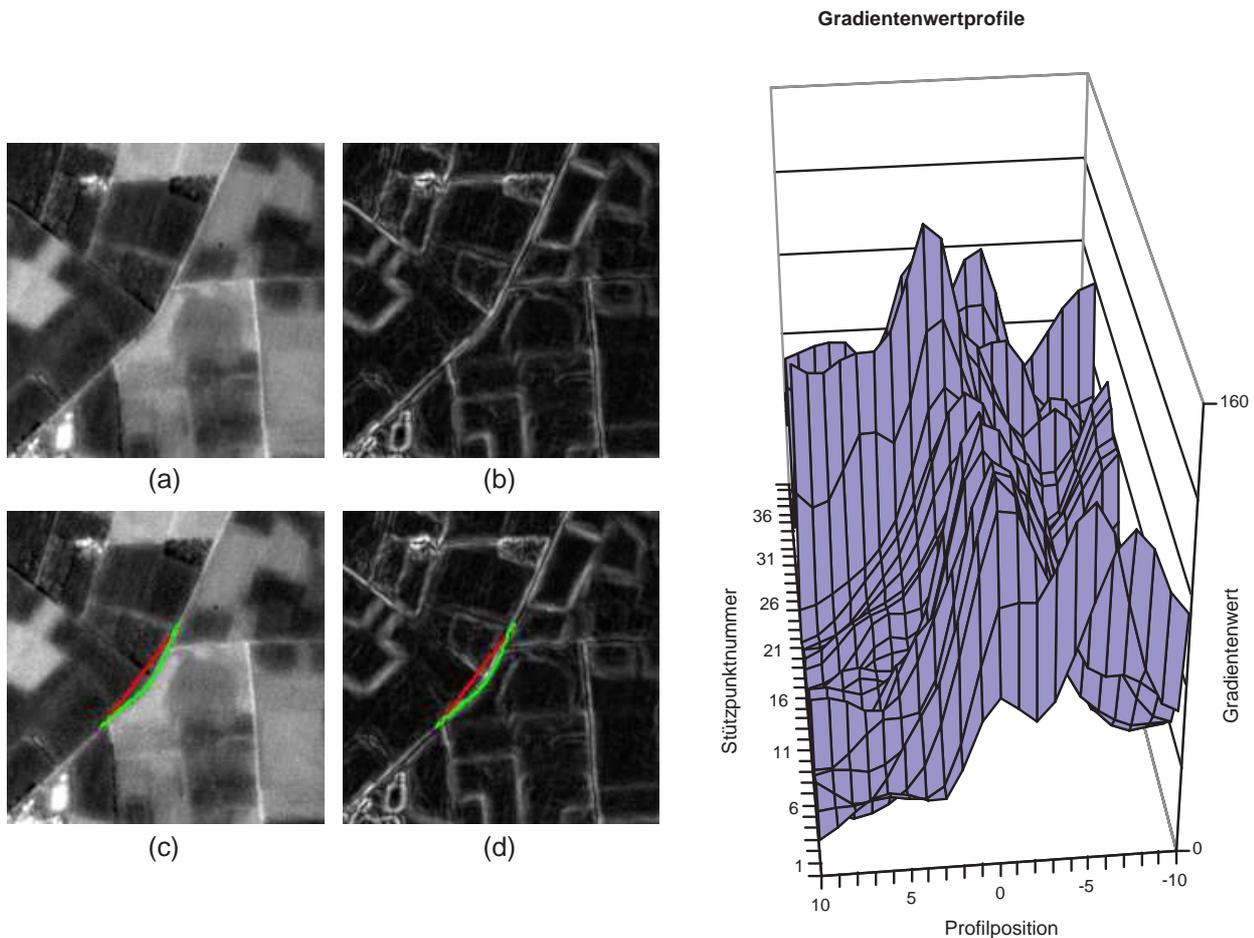


Abbildung 35. Validierung eines Straßenabschnitts anhand des Gradientenbilds. (links): (a) IRS Bilddaten, grüner Kanal (b) Gradientenbild (c und d) Initialisierung der Verknüpfung (rot) und optimierte Verknüpfung (grün). (rechts): geglättete Gradientenwertprofile in 3D Ansicht

### Netzwerkbildung – Bildung kürzester Pfade

Für die Erstellung eines topologisch richtigen Netzwerkes aus den einzelnen bewerteten Straßenabschnitten wird der an der TU München entwickelte Ansatz (WIEDEMANN 2002) verwendet (siehe Abschnitt 2.3.4). Die Netzwerkbildung erfolgt ausschließlich nach globalen Verbindungskriterien und nutzt keine Bildinformation. Es werden somit lediglich kurze Lücken innerhalb des Netzwerkes überbrückt.

#### 4.4.2 Zusammenführung der Teilergebnisse

Das im vorausgegangenen Abschnitt vorgestellte Verfahren zur Generierung von Straßenabschnitten durch lokale Gruppierung eignet sich in erster Linie für die Extraktion von Straßen in landwirtschaftlich genutzten Gebieten. Für die Extraktion von Straßen in den Kontextgebieten *Gebirge* und *Wüste* werden dagegen andere Verfahren eingesetzt.

### **Straßen in Gebirgsregionen**

Für Gebirgsstraßen wird das Verfahren aus (WIEDEMANN 2002) verwendet. Aufgrund der speziellen Charakteristik von Straßen im Gebirge wird der Parameter für die maximal zulässige Krümmung von Straßenstücken freigegeben. Hiermit wird erreicht, dass enge Kurven und Kehren extrahiert und gut bewertet werden. Umfangreiche Untersuchungen zur Nutzung des Verfahrens in Gebirgsregionen, inklusive einer Evaluierung der Ergebnisse, sind in (JOST 2003) dargestellt.

### **Straßen in Wüstenregionen**

In der Wüste wird der Ansatz von WIEDEMANN (2002) ohne besondere Anpassung genutzt. In entsprechenden Gebieten werden die Straßen in der Regel als helle oder dunkle Linien mit gutem Kontrast zur Umgebung abgebildet. Umfangreiche Untersuchungen zur Nutzung des Verfahrens in Wüstenregionen, inklusive einer Evaluierung der Ergebnisse, sind wiederum in (JOST 2003) zu finden.

### **Fusion der Teilergebnisse aus den unterschiedlichen Kontextgebieten**

Die Extraktion von Straßen erfolgt in den unterschiedlichen Kontextgebieten, *landwirtschaftlich genutzt*, *Gebirge* und *Wüste*, aufgrund der unterschiedlichen Vorgehensweise unabhängig voneinander. Um die Ergebnisse anschließend zu einem gemeinsamen Datensatz zu vereinigen, sollten die Gebiete für die Extraktion so ausgewählt werden, dass eine gewisse Überlappung zwischen den Teilgebieten vorhanden ist. Für die Zusammenführung werden die einzelnen Datensätze wiederum gemäß dem am Ende von Abschnitt 4.4.1 beschriebenen Verfahren fusioniert. Zum Abschluss werden mittels einer globalen Gruppierung (siehe Abschnitt 2.3.4) bestehende größere Lücken geschlossen und unterschiedliche Zusammenhangskomponenten miteinander verbunden.

## 5 Experimente

Die Validierung der im vorhergehenden Kapitel vorgestellten Ansätze erfolgt anhand einer Reihe von ausgewählten Datensätzen die das gesamte Spektrum der potenziellen Einsatzgebiete in den dafür sinnvollen Auflösungen abdecken. Es wurde Wert darauf gelegt, die Stärken der Ansätze herauszuarbeiten, aber auch gleichzeitig ihre Grenzen aufzuzeigen. Hierfür wurden Beispieldatensätze unterschiedlicher Schwierigkeit ausgewählt. Abschnitt 5.1 ordnet die Datensätze geographisch ein und beschreibt die Problematik der Erfassung von repräsentativen Referenzdaten für die Evaluierung der Ergebnisse. Die für die Evaluierung verwendeten Kriterien zur Beurteilung der internen und externen Genauigkeit werden in Abschnitt 5.2 näher erläutert.

Die eigentliche Untersuchung der Ansätze gliedert sich in zwei Teile: In Abschnitt 5.3 wird die Straßenextraktion aus höchst aufgelösten Multispektral-Daten mittels des in Abschnitt 4.3 vorgestellten Ansatzes untersucht. Im zweiten Teil (siehe Abschnitt 5.4) wird die Straßenextraktion in dünner besiedelten Landstrichen mit Hilfe von hoch aufgelösten IRS-1C/D Bilddaten unter Verwendung der in Abschnitt 4.4 beschriebenen Ansätze vorgestellt. Die externe Bewertung der Ergebnisse erfolgt in beiden Fällen anhand des Vergleichs mit manuell extrahierten Referenzdaten. Die Auswahl einer sinnvollen Auflösung für ein bestimmtes Gebiet sowie die Einteilung in die Kontextgebiete *landwirtschaftlich genutzt*, *Gebirge* und *Wüste*, wurde manuell durchgeführt. Das Kapitel wird mit einer Beurteilung der Ergebnisse abgeschlossen (siehe Abschnitt 5.5).

### 5.1 Referenzdaten

Ausgehend von der Zielsetzung der Arbeit werden für die Validierung der vorgestellten Ansätze Bilddaten aus Südosteuropa und Nordafrika verwendet. Für diese Arbeit standen höchst aufgelöste IKONOS pan-sharpened Daten sowohl für den Kosovo als auch für dicht besiedelte Gebiete Nordafrikas zur Verfügung. Pan-sharpened IRS Bilddaten mit einer Auflösung von 5 m waren für umfangreiche Gebiete Algeriens verfügbar. Es sind somit Tests für alle im Straßenmodell unterschiedenen Regionen (siehe Abschnitt 4.2) durchführbar. Eine Übersicht über die Verteilung der Testgebiete gibt Abbildung 36.

Für die Evaluierung von Ansätzen zur Objektextraktion ist es äußerst vorteilhaft, das *Sollergebnis* der Extraktion zu kennen, um die Ergebnisse damit vergleichen zu können. Ansonsten ist nur eine innere Bewertung möglich, die wenig aussagekräftig ist. Im Rahmen des Vergleichs mit dem Sollergebnis lassen sich Qualitätsmerkmale, für diese Arbeit Vollständigkeit, Korrektheit und geometrische Genauigkeit (siehe Abschnitt 5.2), bestimmen. Die Definition des *Sollergebnisses*, im weiteren als Referenzdaten bezeichnet, ist für die Evaluierung eine durchaus nicht unproblematische Aufgabe. Grundsätzlich sollte für die Referenzdaten gelten, dass sie von deutlich höherer Qualität sind, als die durch die Extraktion erzielten Ergebnisse. Dies wird in der vorgelegten Arbeit durch Erfassung durch einen erfahrenen menschlichen Auswerter sicher gestellt.

In Bezug auf die manuelle Auswertung durch einen Operateur ist die subjektive Definition des Ergebnisses als problematisch anzusehen. Dies wird nach (KLAUSMANN et al. 1999) als *sensed truth* bezeichnet. Auch die Auswahl der für die Erzeugung der Referenz verwendeten Datengrundlage ist



Abbildung 36. Geographische Verteilung der für die Extraktionsversuche verwendeten Testdaten (Hintergrundbild aus "Visible Earth - Blue Marble" der NASA).

ein wichtiger Punkt. Um eine möglichst vollständige und zuverlässige Referenz zu erhalten, ist es wünschenswert, Datenquellen höherer Qualität heranzuziehen, als die der Daten, die für die automatische Extraktion genutzt werden. Als höherwertigere Datenquellen kommen Luftbilder mit höherer Auflösung als die für die automatische Extraktion genutzten Bilddaten, terrestrisch meist mittels GPS erzeugte Straßendaten oder, mit Einschränkungen, Karten und GIS-Daten in Frage. Die mit derartigen Daten erzeugten Referenzen bilden die Realität möglichst gut ab und werden nach (SÖRGEL 2003) als *reale* Referenz bezeichnet. Dem gegenüber steht die *erfassbare* Referenz, die aus den selben wie für die Versuche genutzten Daten durch einen menschlichen Auswerter generiert werden.

Im Rahmen der vorgelegten Arbeit standen für die Generierung von Referenzdaten lediglich die für die Extraktionsversuche genutzten Bilddaten zur Verfügung. Das Ziel bei der Bewertung der Extraktionsergebnisse ist es, die Leistung der entwickelten Ansätze zu untersuchen. Die *erfassbare* Referenz stellt die Maximalforderung an einen automatischen Extraktionsalgorithmus dar, da angenommen werden kann, dass es nicht möglich ist, vollständigere Ergebnisse zu erzielen. Deswegen ist es für die Evaluierung der automatischen Extraktion ausreichend, eine *erfassbare* Referenz zu erfassen, das Fehlen einer *realen* Referenz ist kein größerer Nachteil. Eine Bewertung gegenüber Letzterer würde auch Fehler der Orientierungsbestimmung des Bildsensors oder von zur Projektion verwendeten Digitalen Geländemodellen (DGM) umfassen, was außerhalb der Ziele dieser Arbeit liegt.

Die Fähigkeiten des Menschen, anhand vielfältiger Information Straßen zuverlässig zu erkennen, macht ihn zu einem quasi optimalen System zur Straßenextraktion in Bezug auf die Vollständigkeit der zu erfassenden Straßen. Anders verhält es sich in Bezug auf die geometrische Genauigkeit der erfassten Straßenachsen, die z.B. nach (PÉTERI et al. 2004) erst durch mehrmaliges Digitalisieren und einer geeigneten Kombination der Ergebnisse optimal bestimmt werden. Im Rahmen der vorgelegten Arbeit wurde auf die mehrfache Erfassung der Straßenachsen zur Steigerung der geometrischen Qualität der Referenzdaten verzichtet, da der Fokus der Bewertung auf die Vollständigkeit und Korrektheit gelegt wurde.

Eine weitere, besonders bezüglich Vollständigkeit und Korrektheit bedeutende Schwierigkeit bei der Erfassung von Referenzdaten besteht darin, zu entscheiden, was als Straße zu werten ist. Hierbei spielt

der subjektive Eindruck des Operators, evtl. in Verbindung mit Bedingungen aus einer Straßendefinition für eine Anwendung, eine große Rolle. Die Entscheidung fällt leicht und ist meist praktisch eindeutig bei Hauptstraßen, die auffällig sind und bei denen die Verbindungsfunktion eindeutig ist. Anders verhält es sich bei schmalen Feldwegen oder Zufahrten zu Gebäuden, die, abhängig von der Auflösung, oft nur schwer identifiziert werden können. Um dieser Problematik Rechnung zu tragen, wurden in Anlehnung an die in (HINZ 2003) vorgeschlagene Vorgehensweise für ausgewählte Testgebiete eine *minimale* und eine *maximale* Referenz erfasst:

- ◊ Die *minimale* Referenz umfasst die Objekte, die sicher bestimmt werden können und im Rahmen der Straßenextraktion auf jeden Fall extrahiert werden sollten. Das Augenmerk liegt auf der Vollständigkeit der Extraktionsergebnisse.
- ◊ Die *maximale* Referenz besteht aus denjenigen Objekten, die zwar als Straßen erkannt werden, die jedoch keine Verbindungsfunktion besitzen und aufgrund der Breite sowie des Belags und der sich aus diesen ergebenden Sichtbarkeit im Bild vom Extraktionsalgorithmus nicht unbedingt erfasst werden müssen. Die maximale Referenz dient dazu, die Korrektheit der Extraktionsergebnisse detaillierter zu untersuchen.

## 5.2 Genauigkeit und Zuverlässigkeit der Straßenextraktion

Die Bewertung von Ergebnissen einer automatischen Objektextraktion sollte sowohl intern als auch extern erfolgen.

Die interne Bewertung gibt an, wie gut die extrahierten Objekte mit dem für die Extraktion verwendeten Modell übereinstimmen. Somit kann eine Aussage über die Sicherheit der Ergebnisse gemacht werden. Die interne Bewertung erfolgt innerhalb des Systems an verschiedenen Stellen, in der Regel im Rahmen der Überprüfung von Hypothesen. Das Ergebnis der vorgestellten Ansätze sind Bewertungsmaße für Straßenabschnitte, die z.B. für eine manuelle Überprüfung der Ergebnisse genutzt werden können. Sinnvoll ist es z.B., einem Operator die Ergebnisse farblich kodiert zur Überprüfung vorzulegen. Als zweckmäßig hat sich hierfür die von FÖRSTNER (1996) vorgeschlagene Darstellung in den Ampelfarben, das so genannte „Ampel-Paradigma“ herausgestellt, mit grün für zuverlässig, gelb für zweifelhaft und rot für unzuverlässig.

Die Zuordnung von Extraktionsergebnis, kurz „Extraktion“, und Referenzdaten, kurz „Referenz“, mit der Puffermethode (siehe Abbildung 37) ist Grundlage einer externen Bewertung von Ergebnissen der Straßenextraktion nach (HEIPKE et al. 1998, WIEDEMANN 2002). Beide Datensätze müssen hierfür als Vektordaten vorliegen. Die externe Bewertung wird in dieser Arbeit mit den drei Qualitätsmerkmalen Vollständigkeit, Korrektheit und geometrischer Genauigkeit in Form des root mean square error (RMS) beschrieben. Die möglichst objektive Bestimmung von Referenzdaten sowie deren Genauigkeit wurde in Abschnitt 5.1 näher beleuchtet. Im Folgenden werden die Parameter definiert.

Die Vollständigkeit gibt den Prozentsatz an, mit dem die Referenz mit der Extraktion übereinstimmt:

$$\text{Vollständigkeit} = \frac{\text{Länge der zugeordneten Referenz}}{\text{Länge der Referenz}}. \quad (21)$$

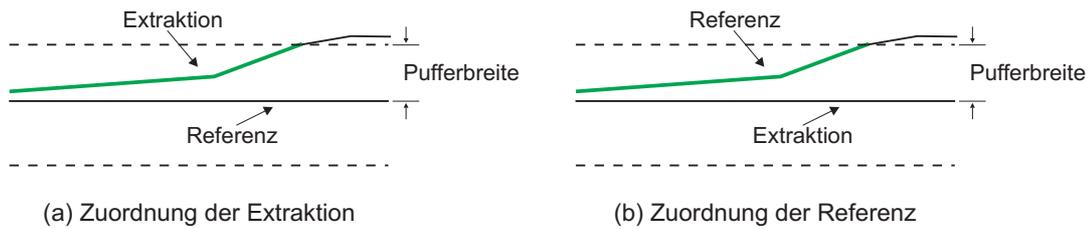


Abbildung 37. Prinzip der Zuordnung nach der Puffermethode. Die grün dargestellten Bereiche sind die zugeordneten Teile der Extraktion (a) und der Referenz (b) – nach (WIEDEMANN 2002).

Die Korrektheit zeigt den Prozentsatz an, mit dem die Extraktion mit der Referenz übereinstimmt:

$$\text{Korrektheit} = \frac{\text{Länge der zugeordneten Extraktion}}{\text{Länge der Extraktion}}. \quad (22)$$

Der RMS Wert beschreibt die geometrische Genauigkeit der Extraktion. Der Wertebereich liegt zwischen 0 und der Breite des verwendeten Puffers:

$$RMS = \sqrt{\frac{\sum_{i=1}^l d(\text{Extr}_i; \text{Ref})^2}{l}} \quad (23)$$

$l$  = Anzahl der zugeordneten Knoten der Extraktion

$d(\text{Extr}_i; \text{Ref})$  = kürzeste Entfernung zwischen dem  $i$ -ten zugeordneten Knoten der Extraktion und der Referenz

Die Wahl der verwendeten Puffergröße hat z.T. einen großen Einfluss auf die Parameter Vollständigkeit und Korrektheit. Je breiter der verwendete Puffer gewählt wird, desto größer wird die Wahrscheinlichkeit, dass falsche Ergebnisse als richtig betrachtet werden. Ist der Puffer aber zu schmal, so werden wiederum tendenziell korrekte Ergebnisse als unrichtig angesehen. Empirisch wurde festgestellt, dass ein sinnvoller Wert für die Pufferbreite die halbe durchschnittliche Straßenbreite ist (WIEDEMANN 2002).

### 5.3 Untersuchungen für höchstauflösende Multispektral-Daten

Die Untersuchung der Straßenextraktion aus höchstauflösenden Multispektral-Daten gliedert sich in zwei Teile: Zuerst wird der in Abschnitt 4.3.1 vorgestellte Fuzzy-Klassifikationsansatz anhand mehrerer Beispiele näher beleuchtet (siehe Abschnitt 5.3.1). In Abschnitt 5.3.2 folgen Experimente zur Straßennetzbildung (siehe auch Abschnitt 4.3.2) einschließlich der Verbesserung der Ergebnisse durch die in Abschnitt 4.3.3 vorgestellte globale Gruppierung.

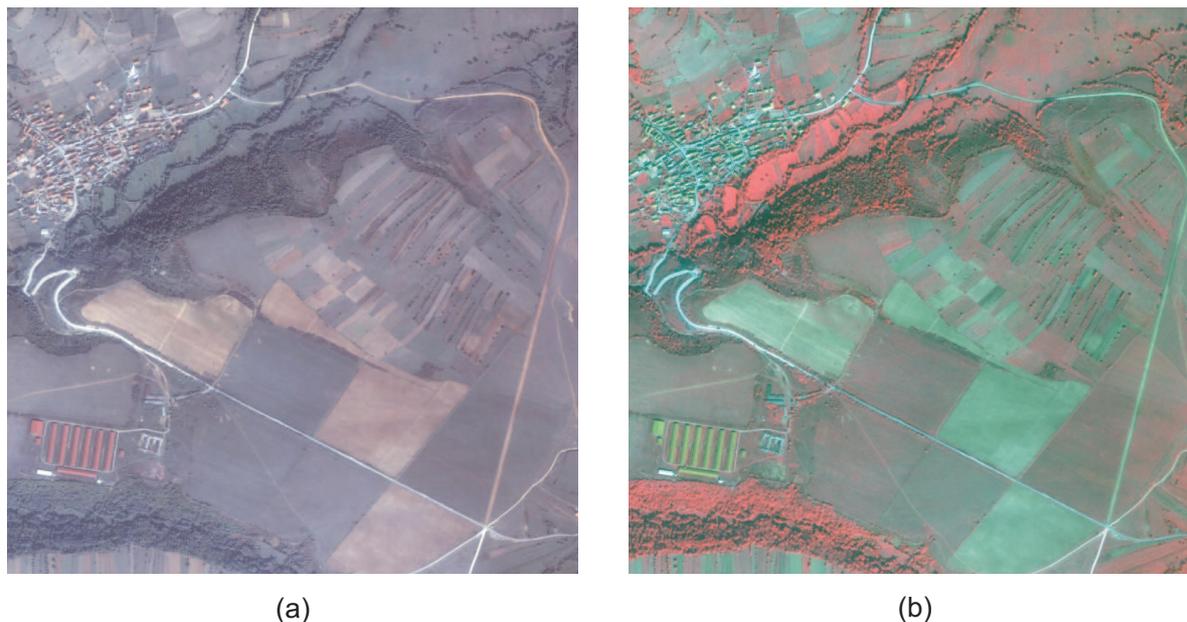


Abbildung 38. Datensatz IKONOS1 (1600×1600 Pixel) – (a) RGB-Darstellung (b) CIR-Farbinfrarotdarstellung

### 5.3.1 Experimente zum Fuzzy-Klassifikationsansatz

Die Untersuchung des Fuzzy-Klassifikationsansatzes wird anhand von vier ausgewählten Datensätzen dargestellt. Die Datensätze unterscheiden sich in der Vielfalt der Gestalt der vorkommenden Straßen sowie deren Abbildung in den Bildern (hell oder dunkel).

#### Datensatz IKONOS1

Der Datensatz IKONOS1 (siehe Abbildung 38) ist ein IKONOS pan-sharpened Bild aus der Region Prizren im Kosovo. Er stammt aus dem EuroSDR (European Spatial Data Research; [www.eurosd.org](http://www.eurosd.org)) Test "Automated Extraction, Refinement, and Update of Road Databases from Imagery and Other Data" ([www.bauw.unibw.de/institute/inst10/eurosd/](http://www.bauw.unibw.de/institute/inst10/eurosd/)). Die abgebildete Szene umfasst ein Gebiet von 1600×1600 Pixeln, was bei der vorliegenden Auflösung von 1 m 2.56 km<sup>2</sup> entspricht. Für die Auswertung wurden die ursprünglich mit 11 bit Grauwertumfang je Kanal vorliegenden Daten auf Grund programmtechnischer Einschränkungen in 8 bit konvertiert. Die durch die Konvertierung bedingte Komprimierung der Grauwertverteilung hält sich jedoch insofern in Grenzen, als für keinen der verwendeten Kanäle der tatsächliche Grauwertumfang, innerhalb dessen sich 99 % der Bildelemente befinden, mehr als 330 Grauwerte beträgt. Die dargestellte Szene enthält überwiegend landwirtschaftlich genutzte Flächen. In der linken oberen Ecke befindet sich eine kleine Ortschaft. Die Straßen und Wege erscheinen im Bild alle heller als die sie umgebenden Flächen. Der Straßenbelag und damit die spektralen Eigenschaften der Straßen und Wege variieren innerhalb der Szene. Durch das Gebiet verlaufen asphaltierte Straßen, Schotterstraßen sowie ein Erdweg. Die Breite der Straßen ist variabel und an verschiedenen Stellen uneinheitlich im Verlauf der Straße, bzw. des Weges.

Für die automatische Generierung von Trainingsgebieten (siehe Abschnitt 4.3.1) wurden für diesen Datensatz alle spektralen Kanäle separat verwendet. Die Ergebnisse für die einzelnen Kanäle sind

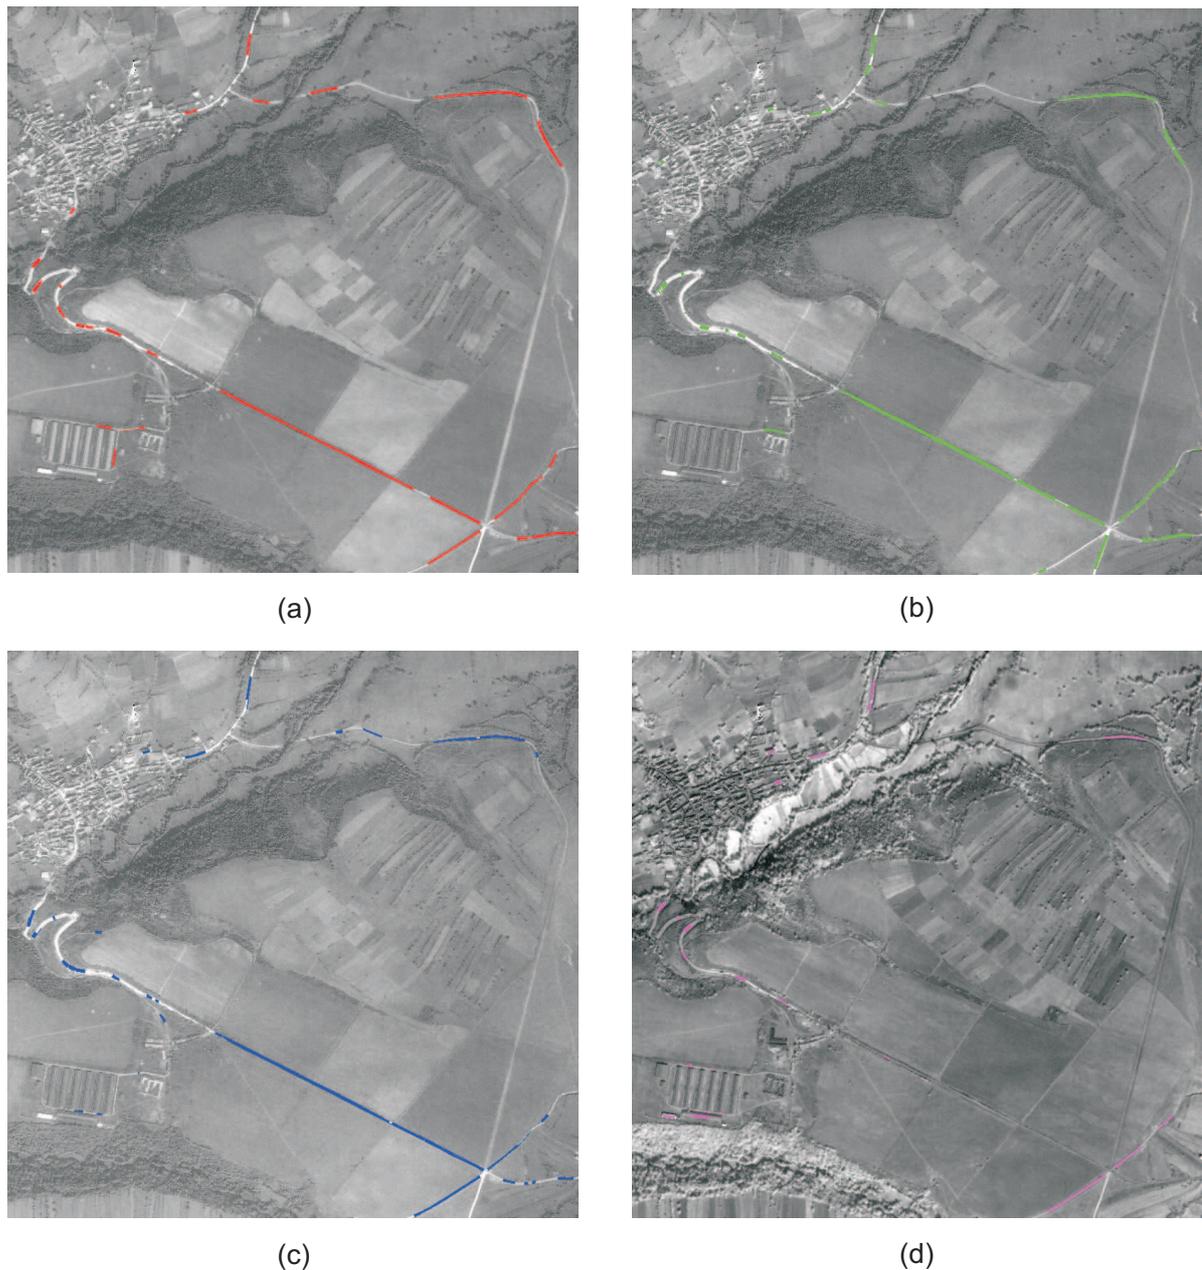


Abbildung 39. Automatisch generierte Trainingsgebiete für die vier spektralen Kanäle für den Datensatz IKONOS1 – (a) roter Kanal (b) grüner Kanal (c) blauer Kanal (d) NIR Kanal

in Abbildung 39 dargestellt. Die drei Kanäle des sichtbaren Bereichs zeigen zwar eine gewisse Korrelation, die Verteilung der Trainingsgebiete zeigt aber, dass durch separate Nutzung der einzelnen Kanäle deutlich mehr Trainingsgebiete extrahiert werden können, als wenn nur einer der drei Kanäle verwendet würde. Für die weitere Verarbeitung wurden die in den jeweiligen Kanälen bestimmten Trainingsgebiete zu einem Datensatz fusioniert (siehe Abbildung 40(a)) und, um die Mischpixelproblematik am Rand der Trainingsgebiete zu minimieren, um 2 Pixel, d.h. 2 m und damit die halbe Pixelgröße der Spektralkanäle von IKONOS, rundherum verkleinert. Für den anschließenden Klassifikationsansatz wurden alle Trainingsgebiete mit mehr als 100 Pixeln, insgesamt 27 (siehe Abbildung 40(b)) verwendet.

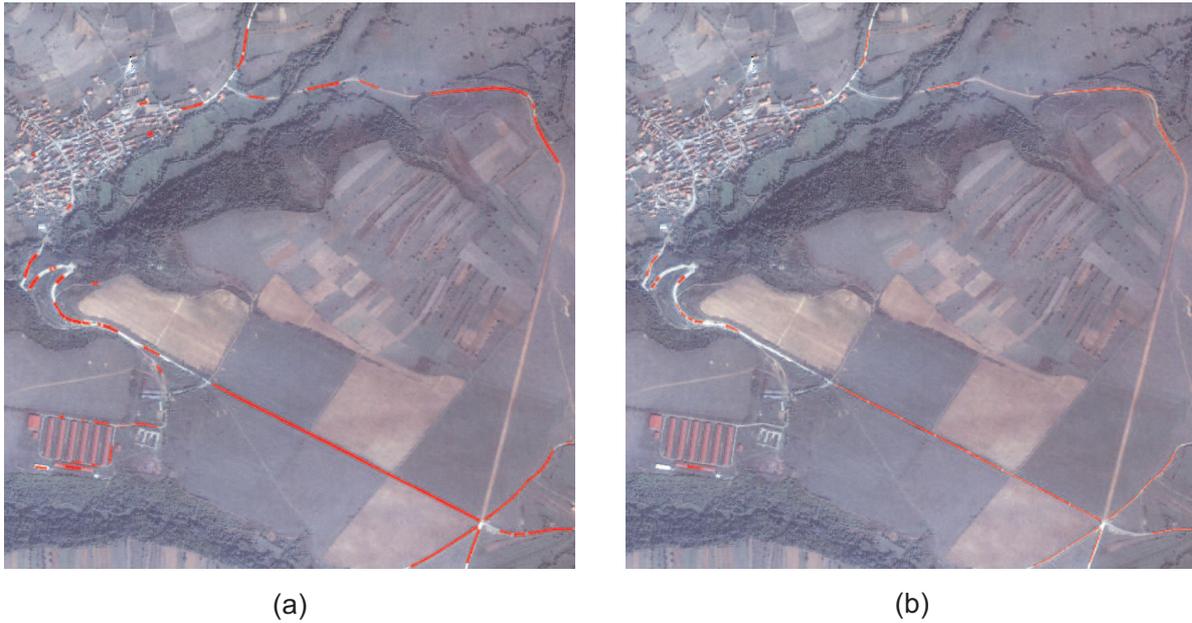


Abbildung 40. Automatisch generierte Trainingsgebiete für Datensatz IKONOS1 – (a) fusionierte Trainingsgebiete (b) 27 für Klassifikationsansatz genutzte, verkleinerte Trainingsgebiete

Abbildung 41 zeigt das Ergebnis des Klassifikationsansatzes in Form der Straßenklassenbilder. Hierfür wurden die im Rahmen des Klassifikationsansatzes bestimmten Zugehörigkeitswerte zur Klasse *Straße* in Grauwertbilder mit 256 Werten umgewandelt. Genauer gesagt, zeigt Abbildung 41 das Ergebnis für verschiedene Ebenen einer Rangfilterung, bei der jeweils die obersten, d.h. besten Werte abgeschnitten wurden. Durch diesen Schritt werden die Ergebnisse robuster gegenüber falschen Trainingsgebieten (siehe Abschnitt 4.3.1).

Das Ergebnis zeigt, dass sich für dieses Beispiel mit Hilfe des automatischen Klassifikationsansatzes die Straßen weitestgehend vom Hintergrund separieren lassen. In den Ebenen eins und zwei (siehe Abbildung 41 (a) und (b)) sind die größeren Straßen deutlich zu erkennen. Allein der von rechts unten nach rechts oben verlaufende Erdweg kann ab der dritten Ebene der Rangfilterung nur noch unbefriedigend bestimmt werden. Der Grund hierfür liegt in der geringen Zahl an Trainingsgebieten, die im Verlauf dieses Weges extrahiert wurden, was wiederum auf die ungleichmäßige Breite des Weges und die teilweise erhebliche Inhomogenität der Grauwerte in seinem Verlauf zurückzuführen ist. Weiter zeigt das Ergebnis, dass durch den Klassifikationsansatz Straßen mit unterschiedlichen spektralen Eigenschaften gemeinsam automatisch erfasst werden können. Fehlextraktionen treten bei diesem Beispiel in erster Linie in Bereichen auf, in denen das Gelände die gleichen spektralen Eigenschaften hat wie die Straßen. Dies gilt vor allem für die Felder, die sehr stark dem Erdweg gleichen.

Für eine quantitative Untersuchung der Ergebnisse des Klassifikationsansatzes wurden die Bildelemente, die anhand von Referenzdaten als zur Klasse *Straße* gehörig eingestuft werden, mit den Bildelementen des Hintergrunds verglichen. Hierfür wurden die Referenzdaten, die die Straßenachsen repräsentieren, um einen Puffer von der Breite der erwarteten mittleren Straßenbreite (hier 7 m bzw. Pixel) dilatiert (siehe Abbildung 42(a)). Die Bildelemente im Bereich des Puffers wurden der Klasse *Straße* zugeordnet, die übrigen dem Hintergrund. Die Bestimmung der intuitiv nahe liegenden Parameter, mittlerer Zugehörigkeitswert und Standardabweichung der Bildelemente von Straßenklasse

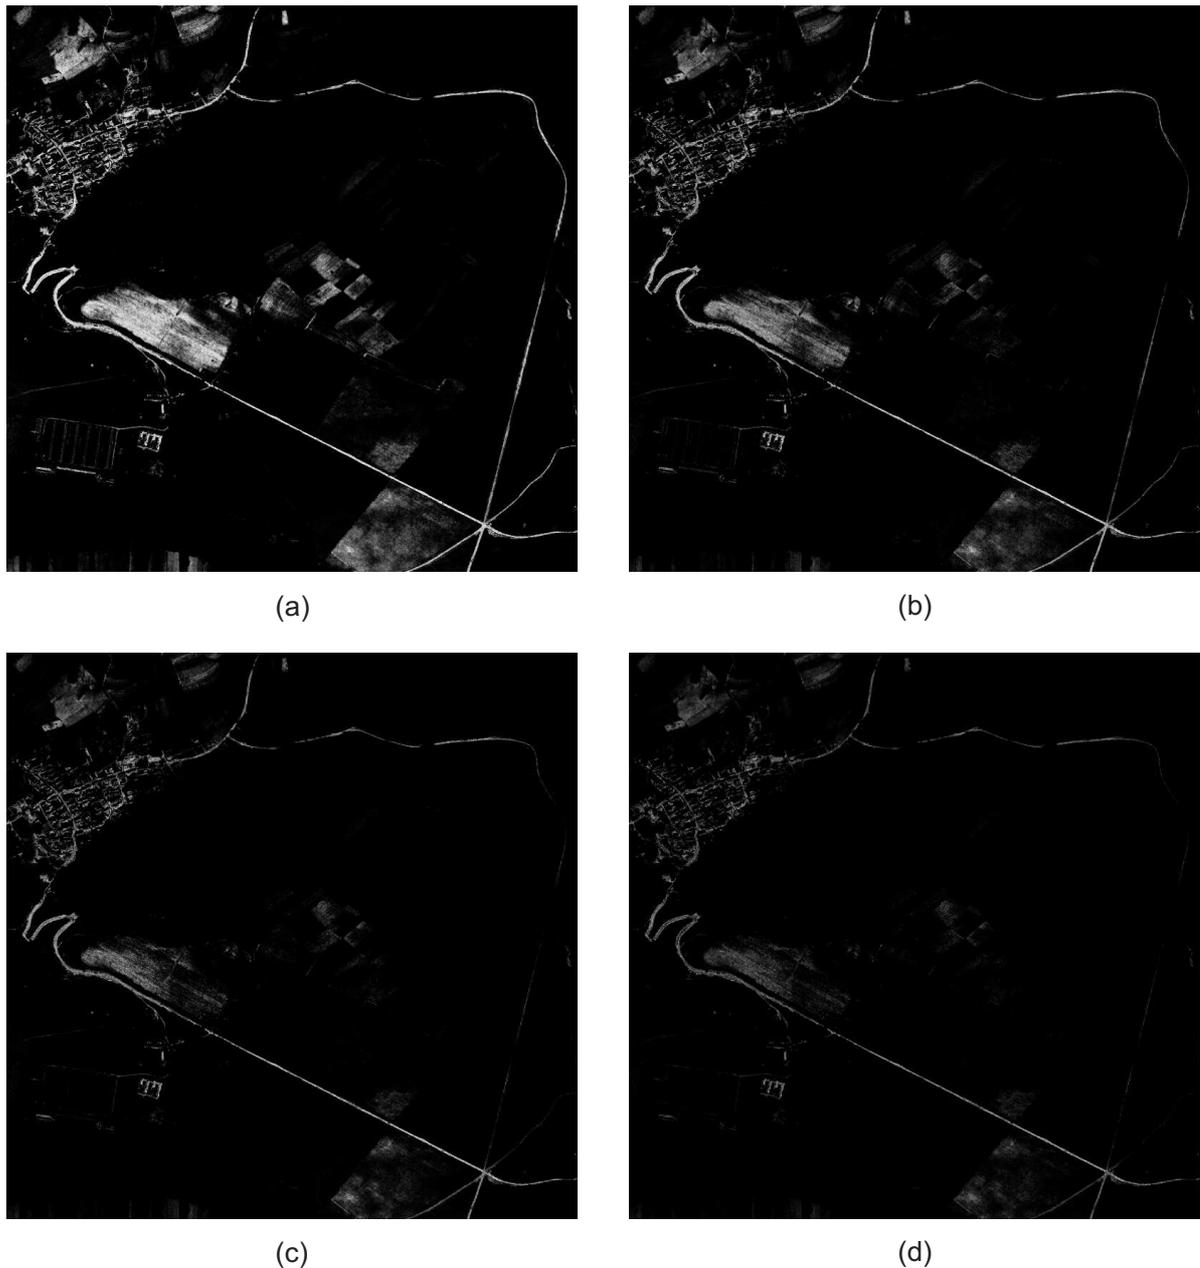


Abbildung 41. Ergebnis des Klassifikationsansatzes mit 27 Trainingsgebieten für den Datensatz IKONOS1 als Straßenklassenbilder. Dargestellt sind verschiedene Stufen der Rangfilterung. (a) erste Ebene, d.h. maximale Zugehörigkeitswerte (b) zweite Ebene (c) dritte Ebene (d) vierte Ebene

und Hintergrund liefert keine aussagekräftigen Ergebnisse. Gründe hierfür sind, dass die Referenzdaten auch abgeschattete Straßen und Straßen an den Stellen enthalten, an denen sie z.B. durch Wald oder Gebäude verdeckt sind, sowie die Wahl der Pufferbreite, die für diese Auswertung für das ganze Testgebiet gleich gewählt wurde. Somit fallen auch Hintergrundbereiche in den Pufferbereich und es kommt zu großen Streuungen der Werte für die Straßenpixel.

Um dennoch die Trennbarkeit der Klasse *Straße* vom Hintergrund zu verdeutlichen, wurden für beide Klassen die relativen Häufigkeiten der Bildelemente für die, in Schritten von 0.1 gestaffelten Zugehörig-

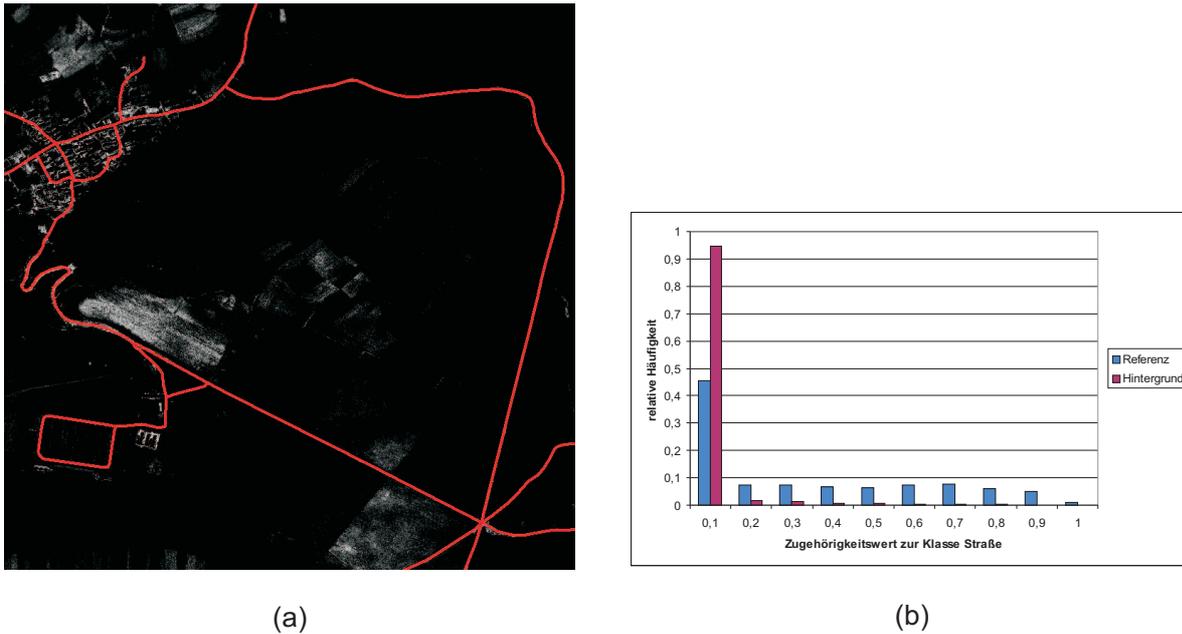


Abbildung 42. Analyse des Ergebnisses des Klassifikationsansatzes der Ebene 2 für den Datensatz IKONOS1. (a) Dilatierte Referenzdaten (b) relative Histogramme für Referenz und Hintergrund

keitswerte in Histogrammen aufgetragen (siehe Abbildung 42(b)). Die relativen Histogramme zeigen für den Hintergrund die erwartete Konzentration von etwa 95 % der Bildelemente auf Zugehörigkeitswerte bis 0,1. Etwa 5 % der Bildelemente umfassen mit einem Zugehörigkeitswert zwischen 0,1 und 0,4 die angesprochenen Fehlklassifikationen aufgrund von spektralen Ähnlichkeiten mit einem Trainingsgebiet sowie die Bildbereiche, die aufgrund einer zu kleinen Wahl des Puffers irrtümlich dem Hintergrund zugerechnet wurden. Für die der Klasse *Straße* zugeordneten Bildelemente ist zwar auch eine Häufung im Zugehörigkeitsbereich bis 0,1 zu verzeichnen, der Anteil ist mit etwa 45 % jedoch deutlich geringer als für den Hintergrund. Ein zweiter Bereich mit einer Häufung der Anteile lässt sich für diesen Datensatz nicht finden. Die zur Straßenklasse gehörenden Bildelemente sind mit etwa 8 % je Zugehörigkeitsintervall bis 0,9 nahezu gleichmäßig verteilt. Ein Grund für die große Zahl an sehr niedrigen Zugehörigkeitswerten liegt an der Inhomogenität des Erdwegs, der in der zweiten Rangebene (siehe Abbildung 41(b)) nur noch sehr schwach detektiert wird. Ein weiterer Grund sind die kleinen Waldstücke im oberen Bereich des Bildes sowie die Straßen, die in der Ortschaft am linken oberen Bildrand durch Schatten gestört werden.

## Datensatz IKONOS2

Der Datensatz IKONOS2 (siehe Abbildung 43) zeigt ein ländliches Gebiet von  $1131 \times 1090$  Pixeln in Nordafrika in der Nähe der tunesischen Hauptstadt Tunis. Die Bilder liegen als multispektrale pansharpened IKONOS Daten mit einer Bodenauflösung von 1 m vor. Die originalen 11 bit Daten wurden wiederum in 8 bit konvertiert. Die Straßen in diesem Beispieldatensatz sind markant. Verdeckungen stellen kein Problem dar. Die Auswahl dieses Gebiets erfolgte wegen der vorhandenen Straßen mit unterschiedlichen Straßenbreiten und Belägen. So führt eine asphaltierte Hauptstraße von links oben nach rechts unten. Auf diese Hauptstraße stößt eine recht kurvenreiche, schmalere Straße, die ebenfalls asphaltiert ist. In diese beiden Straßen münden etliche Wege und Zufahrten, die erheblich schmaler sind als die zuvor beschriebenen Straßen und meist aus anderen Materialien bestehen.

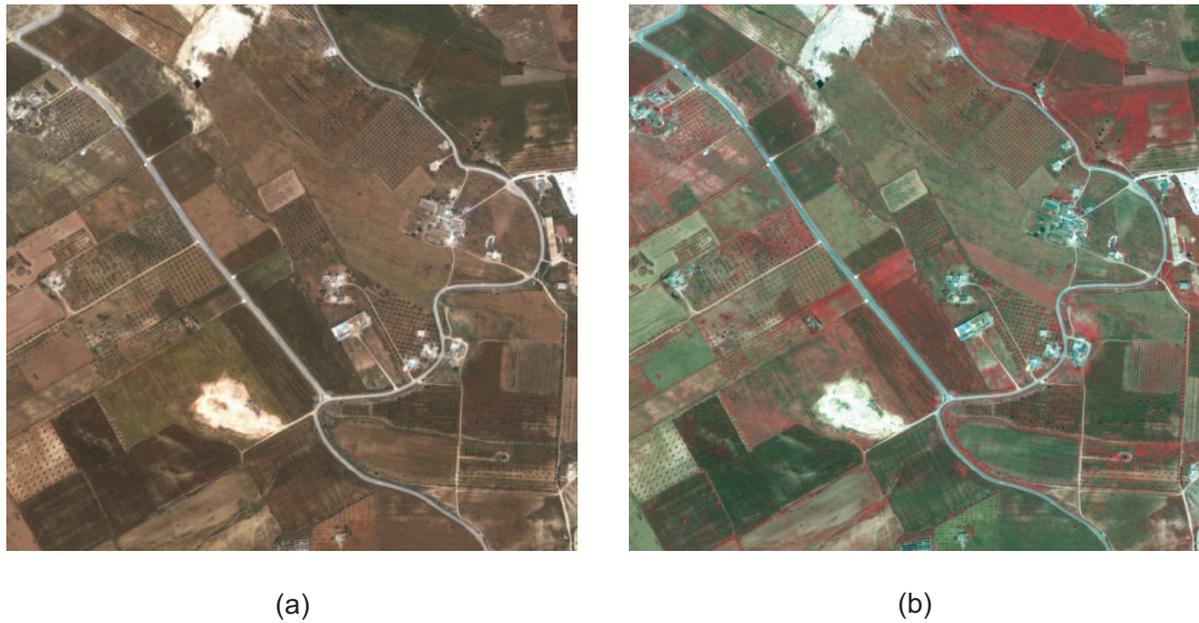


Abbildung 43. Datensatz IKONOS2 (1131×1090 Pixel) – (a) RGB-Darstellung (b) CIR-Farbinfrarotdarstellung

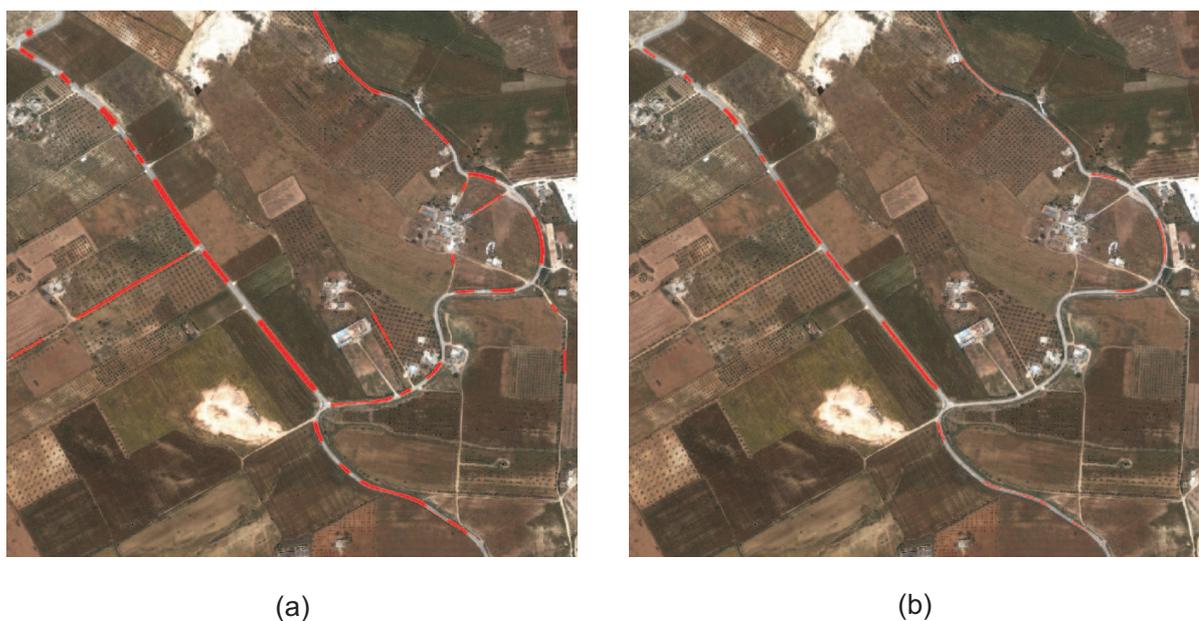


Abbildung 44. Automatisch generierte Trainingsgebiete für den Datensatz IKONOS2 – (a) fusionierte Trainingsgebiete (b) 16 für Klassifikationsansatz genutzte, verkleinerte Trainingsgebiete

Die Trainingsgebiete für den Klassifikationsansatz wurden in der selben Weise automatisch erzeugt wie für das vorangegangene Beispiel. Abbildung 44(a) zeigt alle Gebiete, wie sie gefunden wurden, und Abbildung 44(b) die verkleinerten Trainingsgebiete mit mehr als 100 Bildelementen, die für den Klassifikationsansatz verwendet wurden. Aufgrund der Anforderung von mindestens 100 Bildelementen pro Trainingsgebiet befinden sich die Trainingsgebiete mit einer Ausnahme im Bereich der asphaltierten Straßen. In diesem Testdatensatz wurden keine fehlerhaften Trainingsgebiete extrahiert.

Das Ergebnis des Klassifikationsansatzes in Form der Straßenklassenbilder ist in Abbildung 45 dar-

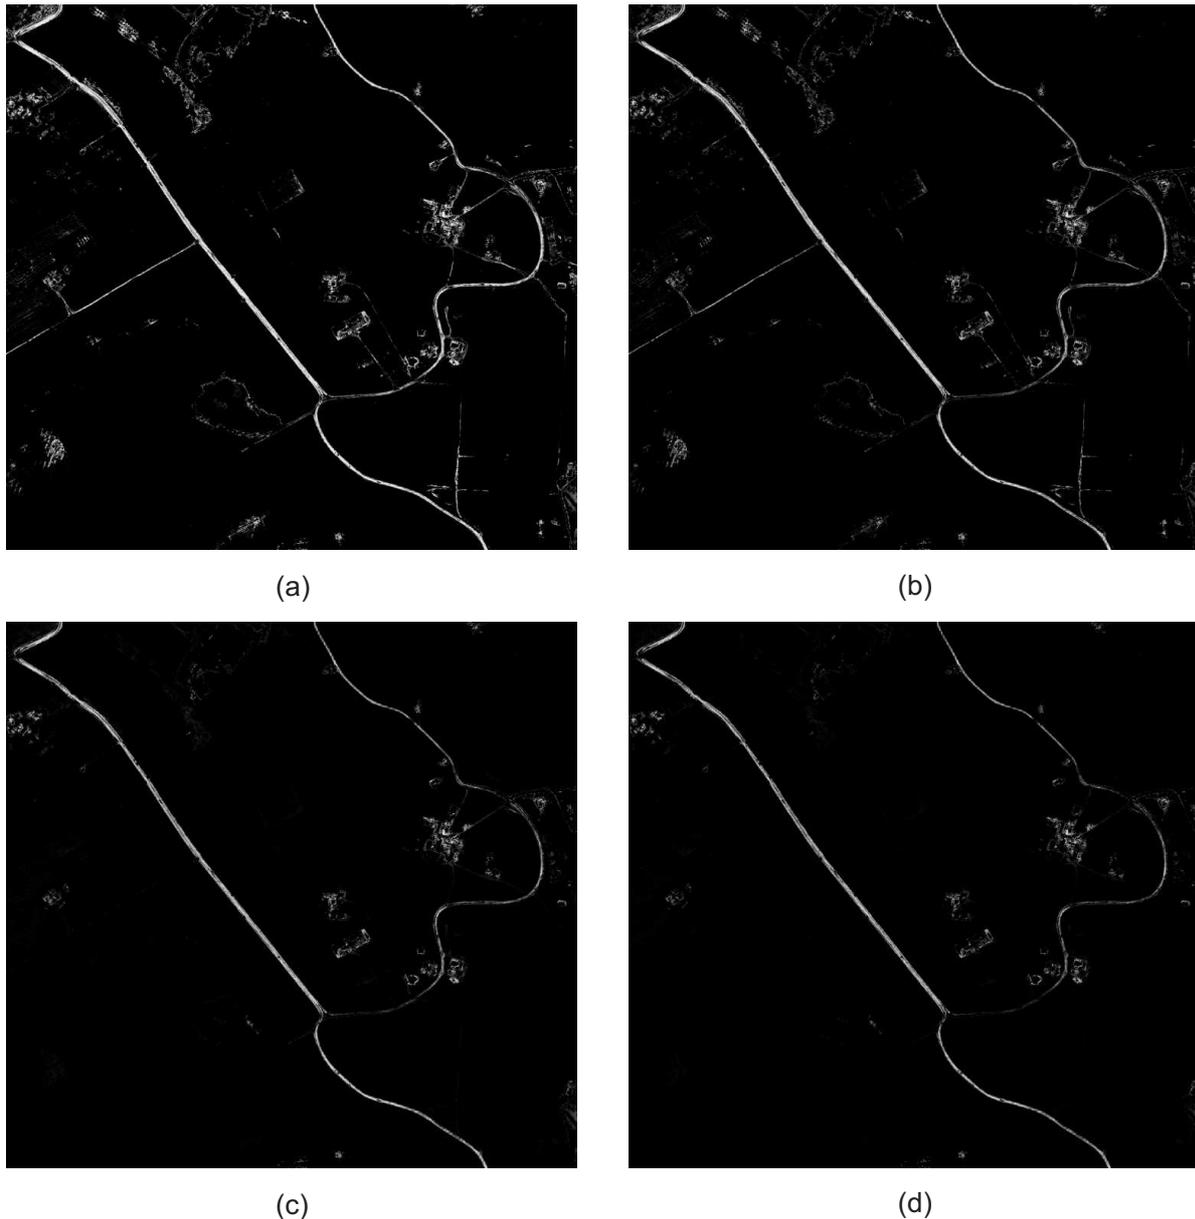


Abbildung 45. Ergebnis des Klassifikationsansatzes mit 16 Trainingsgebieten für den Datensatz IKONOS2 als Straßenklassenbilder. Dargestellt sind verschiedene Stufen der Rangfilterung. (a) erste Ebene, d.h. maximale Zugehörigkeitswerte (b) zweite Ebene (c) dritte Ebene (d) vierte Ebene

gestellt. Es zeigt sehr hohe Zugehörigkeitswerte für die durch das Gebiet verlaufenden asphaltierten Hauptstraßen. Die kleinen Wege und Zufahrten erhalten vor allem in der ersten und nur mit Einschränkungen in der zweiten Ebene nennenswerte Zugehörigkeitswerte. Die Hauptstraßen erhalten dagegen auch in der vierten Ebene noch Zugehörigkeitswerte, durch die sie vom Hintergrund getrennt werden können. Störobjekte mit spektralen Eigenschaften ähnlich denen der Straßen gibt es nur im Bereich der versiegelten Flächen im Bereich der Gebäude.

Für eine quantitative Bewertung der Ergebnisse wurden auch für diesen Datensatz die relativen Histogramme für die Zugehörigkeitswerte der Bildelemente für die Klasse *Straße* und den Hintergrund bestimmt. Als Referenz wurde ein minimaler Straßendatensatz (siehe Abschnitt 5.1 – minimale Refe-

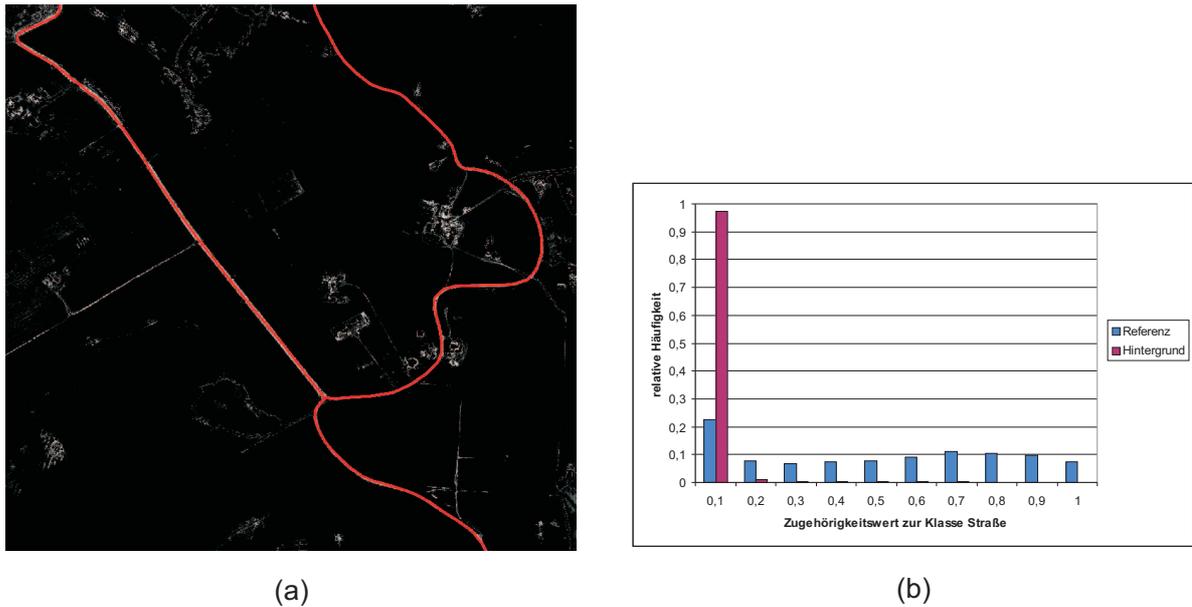


Abbildung 46. Analyse des Ergebnisses des Klassifikationsansatzes der Ebene 2 für den Datensatz IKONOS2. (a) Referenzdaten (minimale Referenz) (b) relative Histogramme für Referenz und Hintergrund

renz) bestehend aus den asphaltierten Hauptstraßen gewählt (siehe Abbildung 46(a)). Um die Straßenachsen wurde ein Puffer mit 3.5 m Breite gelegt und so die beiden Klassen separiert. Für die Auswertung wurde die zweite Ebene der Rangfilterung verwendet. Die relativen Histogramme sind in Abbildung 46(b) dargestellt. Das Histogramm für den Hintergrund zeigt eine Häufung der Bildelemente im Zugehörigkeitsintervall bis 0.1 mit etwa 98 % der Werte. Die restlichen 2 % der Bildelemente verteilen sich auf die Zugehörigkeitswerte von 0.2 bis 0.7 und liegen sowohl in den bereits erwähnten versiegelten Flächen im Bereich der Gebäude sowie entlang der schmalen Wege und Zufahrten, die in der minimalen Referenz nicht erfasst wurden. Für die Straßenklasse zeigen die Ergebnisse eine gute Trennbarkeit von der Hintergrundklasse. Lediglich 22 % der Bildelemente im Bereich des Referenzpuffers liegen im Zugehörigkeitsintervall bis 0.1. Ein schwach ausgeprägtes Maximum der Zugehörigkeitswerte befindet sich im Bereich der Zugehörigkeitswerte von 0.7 und immerhin etwa 18 % aller Bildelemente im Bereich der Referenz haben einen Zugehörigkeitswert besser als 0.8.

Für den Datensatz IKONOS2 konnten bei einer minimalen Trainingsgebietsgröße von 100 Pixeln die Hauptstraßen gut vom Hintergrund getrennt werden. Die kleineren Wege und Zufahrten wurden jedoch nur schlecht bewertet und lassen sich damit ab der zweiten Rangebene im Straßenklassenbild nur noch schlecht erkennen. Ist man auch an den kleineren Straßen interessiert, so empfiehlt es sich, die minimale Trainingsgebietsgröße zu reduzieren. Das Ergebnis des Klassifikationsansatzes mit minimal 40 Pixeln pro Trainingsgebiet zeigt die Abbildung 47. In der gezeigten zweiten Ebene werden die kleinen Straßen gut bewertet. Der Anteil an Fehlklassifikationen ist dagegen gering.

### Datensatz IKONOS3

Der Datensatz IKONOS3 (siehe Abbildung 48) zeigt einen Randbereich der tunesischen Hauptstadt Tunis. Die multispektralen pan-sharpened IKONOS Daten mit einer Bodenauflösung von 1 m decken ein Gebiet von  $1588 \times 1158$  Pixel ab. Die originalen 11 bit Daten wurden wiederum in 8 bit konvertiert. Durch das Bild verlaufen mehrere Schnellstraßen, die mit zwei großen Kreisverkehren als

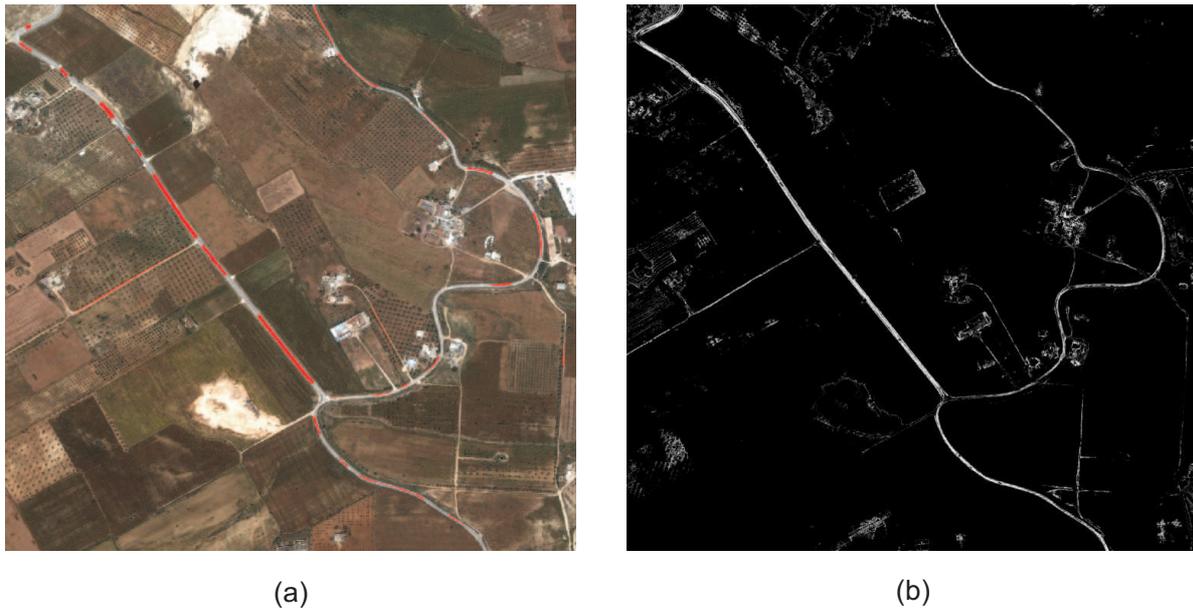


Abbildung 47. Klassifikationsansatz für Datensatz IKONOS2 mit einer **minimalen Trainingsgebietsgröße von 40 Bildelementen** – (a) 23 für Klassifikationsansatz genutzte, verkleinerte Trainingsgebiete (b) Ergebnis des Klassifikationsansatzes, zweite Ebene der Rangfilterung



Abbildung 48. Datensatz IKONOS3 (1588×1158 Pixel) – (a) RGB-Darstellung (b) CIR-Farbinfrarotdarstellung

Knotenpunkten verbunden sind. Neben den Schnellstraßen finden sich bebaute Gebiete in denen die Straßen, abgesehen von wenigen größeren, nur schwer identifiziert werden können. Im Gegensatz zu den vorangegangenen beiden Beispielen wurden für dieses Beispiel dunkle Linien für die Generierung von Trainingsgebieten genutzt (siehe Abbildung 49). Abbildung 49(a) zeigt alle Gebiete, die gefunden wurden und Abbildung 49(b) die verkleinerten Trainingsgebiete mit mehr als 100 Bildelementen, die für den Klassifikationsansatz verwendet wurden.

Die große Zahl automatisch extrahierter Trainingsgebiete zeigt, dass das gewählte Straßenmodell gut mit der Realität übereinstimmt. Die Zahl der falschen Trainingsgebiete ist in Anbetracht der Komplexität des Bildinhalts in diesem Beispiels verhältnismäßig gering. In erster Linie fallen die vier Trainingsgebiete entlang eines Bewässerungskanal (im unteren Bilddrittel von links zur Mitte hin) auf. Diese sind dadurch zu erklären, dass der Kanal durch seine linienhafte Struktur und Abbildung



Abbildung 49. Automatisch generierte Trainingsgebiete für den Datensatz IKONOS3 – (a) fusionierte Trainingsgebiete (b) 42 für Klassifikationsansatz genutzte, verkleinerte Trainingsgebiete

als dunkle Linie dem Modell für Straßen entspricht. Weitere fehlerhafte Trainingsgebiete ergeben sich entlang von heckenartigen Strukturen, die ebenfalls als dunkle Linien dem Modell für Straßen entsprechen.

Das Ergebnis des Klassifikationsansatzes ist in Form der Straßenklassenbilder in Abbildung 50 dargestellt. Die erste und zweite Ebene (siehe Abbildung 50(a) und (b)) zeigen deutlich den Einfluss fehlerhafter Trainingsgebiete, die den spektralen Eigenschaften großer Gebiete im linken unteren Bildbereich entsprechen. Die Auswirkungen sind an den hohen Zugehörigkeitswerten (helle Flächen im Straßenklassenbild) zu erkennen, sie nehmen jedoch schon von der ersten zur zweiten Ebene deutlich ab und sind in der vierten Ebene größtenteils beseitigt. Durch die große Zahl an Trainingsgebieten im Bereich der Schnellstraßen erhalten die Straßen auch nach Rangfilterung bis zur sechsten Ebene hohe Zugehörigkeitswerte, wohingegen die Störobjekte weitestgehend herausgefiltert werden. Probleme bereitet bei diesem Beispiel auch der erwähnte Bewässerungskanal. Erst durch eine Rangfilterung bis mindestens zur fünften Ebene konnte der Einfluss begrenzt werden. Ab dieser Ebene erhalten die Bildelemente des Kanals keine nennenswerten Zugehörigkeitswerte mehr (siehe z.B. Abbildung 50 (d)).

Der Datensatz IKONOS3 zeigt die Schwächen des Ansatzes in bebautem Gebiet. Dort zeigen lediglich die größeren Straßen, die spektrale Eigenschaften vergleichbar denen der Schnellstraßen aufweisen, nennenswerte Zugehörigkeitswerte (siehe z.B. die Straßen in der rechten oberen Ecke des Beispiels). Für die anderen Straßen in den Siedlungen wurden keine Trainingsgebiete extrahiert, da das verwendete Modell nicht mit dem Aussehen der Straßen in diesen Gebieten übereinstimmt.

Die quantitative Bewertung erfolgt wiederum mit Hilfe von relativen Histogrammen (siehe Abbildung 51). Es wurde die sechste Ebene der Rangfilterung verwendet, da erst ab dieser die Störobjekte zufrieden stellend herausgefiltert werden. Das Histogramm für den Hintergrund zeigt mit etwa 90 % die erwartete Konzentration der Bildelemente im Zugehörigkeitsintervall bis 0.1. Die weiteren 10 % liegen fast ausschließlich im Bereich 0.2 bis 0.5. Auch für die Klasse *Straße* ergibt sich das erwartete Ergebnis. Ein erstes Maximum mit etwa 38 % ist im Zugehörigkeitsbereich bis 0.1 zu finden. Hierbei handelt es sich in erster Linie um die Bereiche des Referenznetzes, die durch die Siedlungsgebiete verlaufen und andere spektrale Eigenschaften aufweisen als die Schnellstraßen. Eine

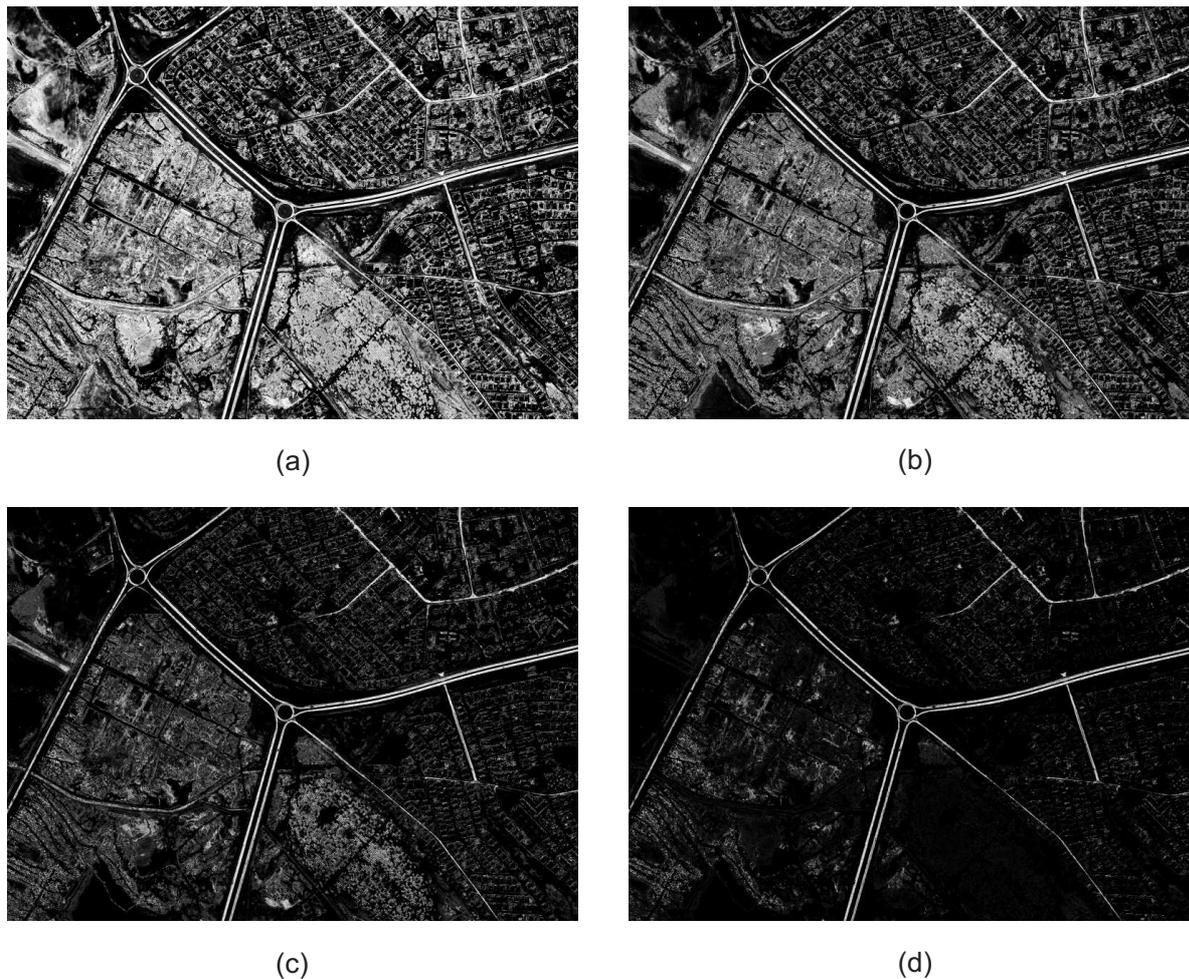


Abbildung 50. Ergebnis des Klassifikationsansatzes mit 42 Trainingsgebieten für den Datensatz IKONOS3 als Straßenklassenbilder. Dargestellt sind verschiedene Stufen der Rangfilterung. (a) erste Ebene, d.h. maximale Zugehörigkeitswerte (b) zweite Ebene (c) vierte Ebene (d) sechste Ebene

zweite ausgeprägte Häufung liegt bei Zugehörigkeitswerten zwischen 0.7 und 0.9 und bestätigt die erfolgreiche und sichere Klassifikation großer Teile des Straßennetzes.

### Datensatz IKONOS4

Für die Datensätze 1–3 wurde die in Abschnitt 4.3.1 vorgeschlagene zusätzliche Entfernungsbedingung für den Klassifikationsansatz wegen der begrenzten Größe der Testgebiete nicht genutzt. Sinnvoll ist diese Bedingung für große Datensätze, da durch sie der Einfluss von fehlerhaften Trainingsgebieten räumlich beschränkt wird. Die Funktionsweise sowie die Vorteile der Entfernungsbedingung für den Klassifikationsansatz wird anhand des vierten Datensatzes (IKONOS4) aufgezeigt. Es handelt sich um einen Ausschnitt aus einer IKONOS Szene im pan-sharpened Modus mit einem Meter Bodenauflösung. Die Bilddaten wurden wiederum von 11 bit in 8 bit Daten umgewandelt. Der Ausschnitt (siehe Abbildung 52) zeigt ein Gebiet aus dem Kosovo. Er umfasst  $2500 \times 2500$  Pixel, also  $6.25 \text{ km}^2$  und besteht zum größten Teil aus offener Landschaft. Durch das Gebiet verläuft von der Mitte des linken Bildrands zum rechten unteren eine größere Straße. In diese Straße mündet in der Bildmitte eine etwa gleichwertige Straße von der linken oberen Ecke kommend ein. Im rechten oberen Teil des

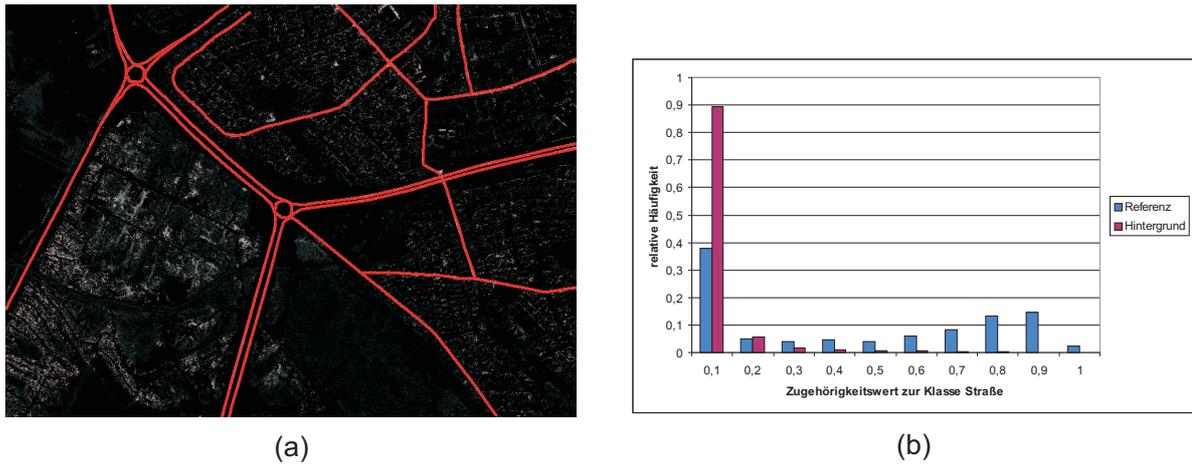


Abbildung 51. Analyse des Ergebnisses des Klassifikationsansatzes der Ebene 6 für den Datensatz IKONOS3. (a) Referenzdaten (minimale Referenz) (b) relative Histogramme für Referenz und Hintergrund

Bildes befindet sich eine Ortschaft, in deren Umfeld die Straßen nur sehr schwer zu erkennen sind, da sie meist von Baumreihen oder Hecken begleitet und nur über diese indirekt wahrgenommen werden. In der Ortschaft liegen die Straßen zum größten Teil im Schatten der Gebäude und sind auch hier nur indirekt erkennbar.

Als Grundlage für die automatische Generierung von Trainingsgebieten dienten helle Linien. Die minimale Anzahl an Bildelementen, ab dem ein Trainingsgebiet für den Klassifikationsansatz verwendet wird, wurde auf 100 gesetzt. Abbildung 52 zeigt in rot die verwendeten Trainingsgebiete, wobei offensichtlich falsche Gebiete vergrößert dargestellt sind. Die Ursachen für fehlerhafte Trainingsgebiete sind z.B.:

- ◇ helles schmales Feld mit dunklen Begrenzungen
- ◇ lang gestrecktes Hausdach mit dunkler Begrenzung
- ◇ heller Grünstreifen zwischen dunklen Baum-/Heckenreihen

Durch die Verteilung der sieben fehlerhaften und dreißig korrekten Trainingsgebiete, die etwa gleichmäßig entlang der Hauptstraßen verteilt sind, eignet sich dieser Datensatz sehr gut dazu, die Vorteile einer Entfernungsbedingung im Rahmen des Klassifikationsansatzes zu demonstrieren. Hierfür wurde der Klassifikationsansatz einmal ohne und einmal mit Entfernungsbedingung durchgeführt. Das Ergebnis des Klassifikationsansatzes ohne Entfernungsbedingung ist in den Abbildungen 53(a) und (c) dargestellt. Besonders die erste Rangstufe zeigt wie stark sich die falschen Trainingsgebiete auf das Ergebnis auswirken und damit eine Trennung der Straßenklasse vom Hintergrund erheblich erschweren. Für die zweite Ebene sieht die Trennbarkeit zwar besser aus, jedoch liegt auch hier eine erhebliche Anzahl an Störobjekten vor.

Bei der Einbeziehung der Entfernungsbedingung wurde für dieses Beispiel der Einflussbereich jedes Trainingsgebiets auf 500 bzw. 900 Pixel vom Zentrum des Trainingsgebiets beschränkt. Der erste Wert gibt den Abstand an, bis zu dem das Trainingsgebiet vollen Einfluss ausübt, der zweite Wert den Abstand, zu dem hin der Einfluss linear auf Null abfällt (siehe Abbildung 21 rechts oben). Die Bereiche mit maximalem Einfluss sind exemplarisch für die fehlerhaften Trainingsgebiete in Abbildung

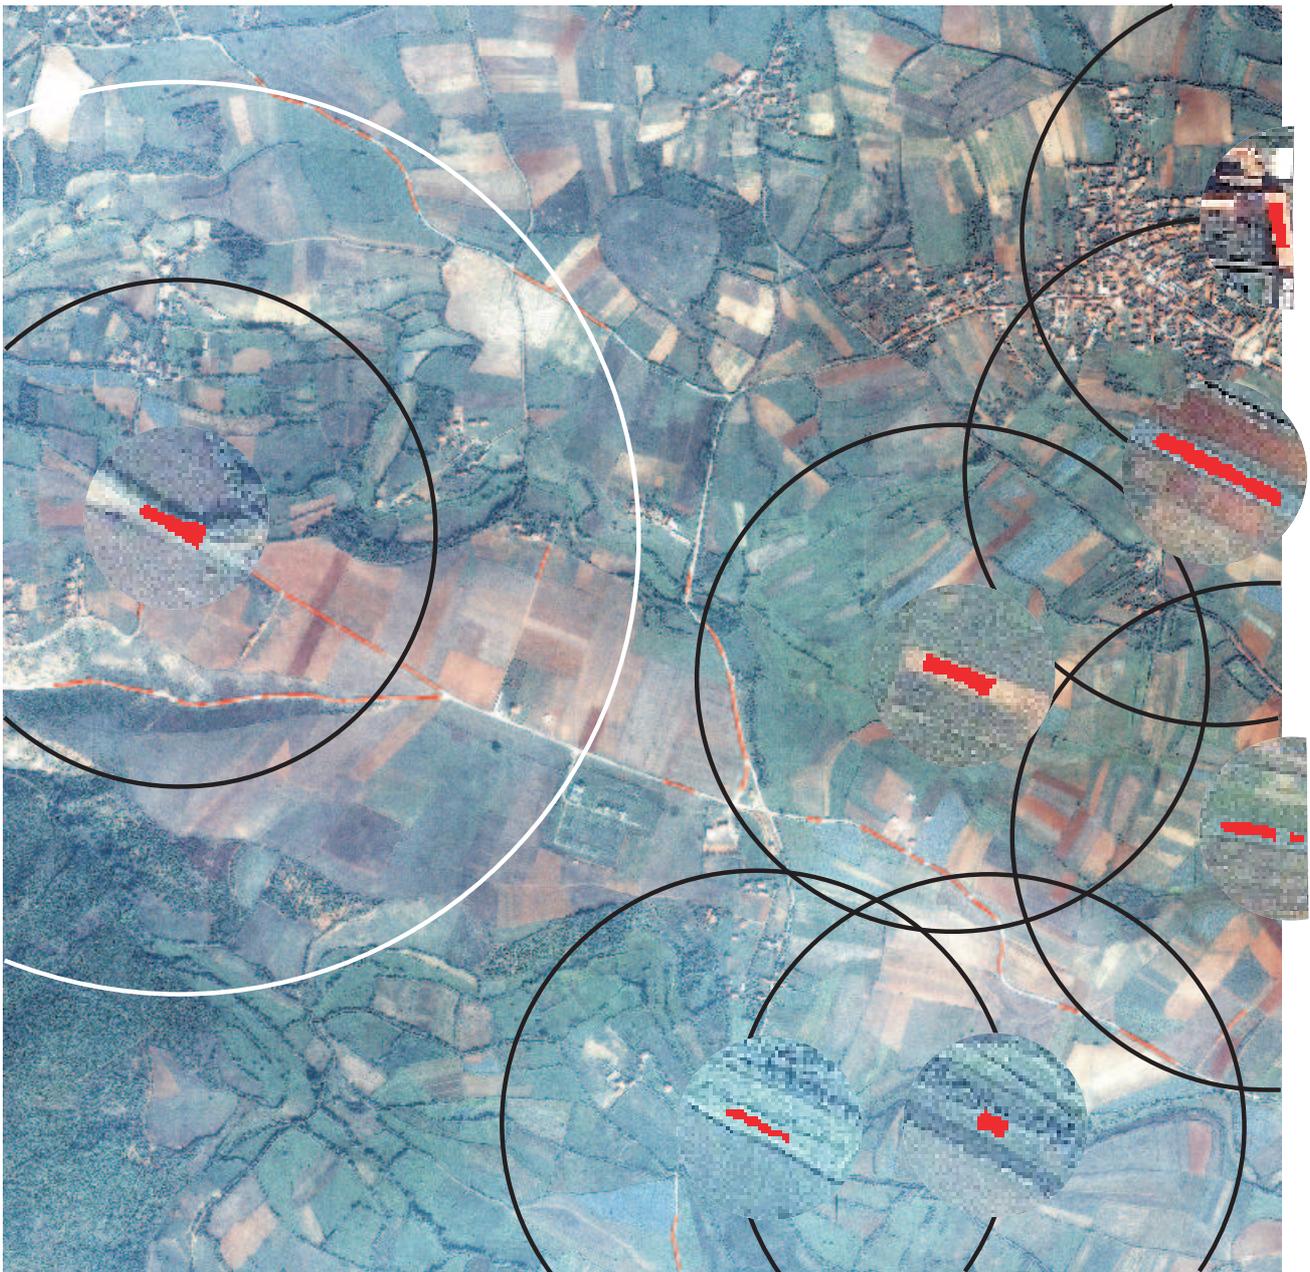


Abbildung 52. Datensatz IKONOS4 (2500×2500 Pixel) – Einflussbereich fehlerhafter Trainingsgebiete (vergrößert dargestellt im Zentrum der Kreise) bei Verwendung einer Entfernungsbedingung im Rahmen des Klassifikationsansatzes. Die schwarzen Kreise zeigen den Bereich, für den die Trainingsgebiete maximalen Einfluss haben (Radius 500 Pixel), der weiße Kreis symbolisiert die Einflussgrenze (Radius 900 Pixel). Die Einflussgrenze wird der Übersichtlichkeit halber nur für ein Gebiet angezeigt.

52 als schwarze Kreise dargestellt. Zusätzlich wird für ein Gebiet der Abstand, an dem der Einfluss auf Null abgefallen ist, gezeigt als weißer Kreis. Abbildung 53(b) und (d) zeigen, dass der Einfluss der fehlerhaften Trainingsgebiete durch die Einführung der Entfernungsbedingung erheblich reduziert wird. Die Zahl an Bildelementen mit hohen Zugehörigkeitswerten, die keinen Straßen entsprechen, konnte schon in der ersten Rangebene deutlich reduziert werden. Die Straßen sind dagegen im Straßenklassenbild weiterhin gut zu erkennen. Betrachtet man die zweite Ebene, zeigt es sich, dass die Zahl der Störobjekte stark zurück gegangen ist, was zu einer guten Trennbarkeit von Straßenpixeln

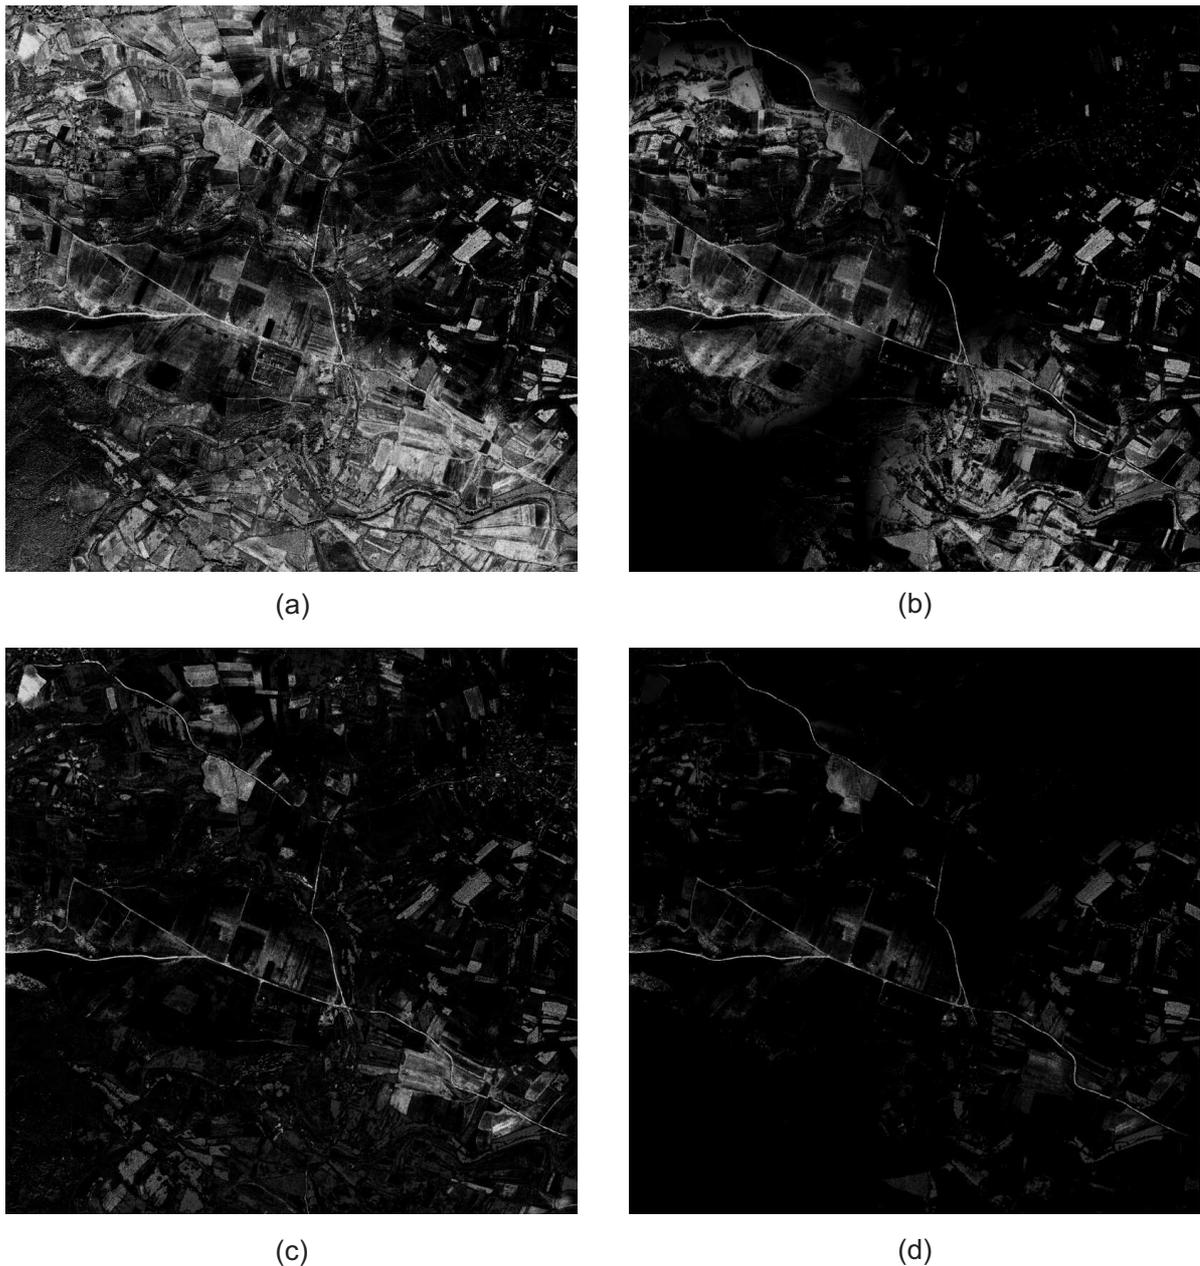


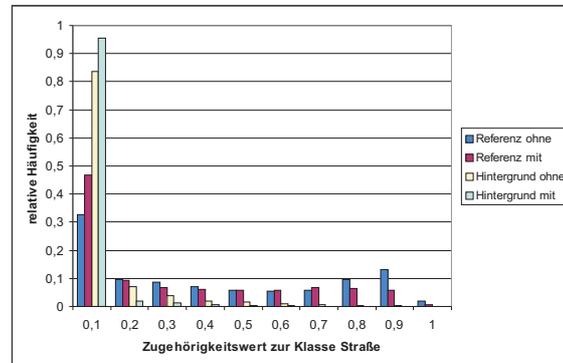
Abbildung 53. Ergebnis des Klassifikationsansatzes mit den in Abbildung 52 dargestellten Trainingsgebieten (insgesamt 37) für den Datensatz IKONOS4 als Straßenklassenbilder. (a) und (b) zeigen die erste Stufe, d.h. die maximalen Zugehörigkeitswerte, (a) ohne und (b) mit Entfernungsbegrenzung, (c) und (d) zeigen jeweils die zweite Stufe der Rangfilterung in (c) ohne und in (d) mit Entfernungsbegrenzung.

gegenüber dem Hintergrund führt.

Die quantitative Bewertung erfolgt wiederum mit Hilfe von relativen Histogrammen, jeweils für das Ergebnis der zweiten Ebene mit und ohne Entfernungsbegrenzung (siehe Abbildung 54). Eine erhebliche Reduktion an Störobjekten ist durch die Einführung der Entfernungsbegrenzung an den Anteilen der Bildelemente im Hintergrund mit Zugehörigkeitswerten bis 0.1 zu beobachten. Diese steigen von 83 % ohne auf 95 % mit Entfernungsbegrenzung. Für die Klasse *Straße* zeigt der Vergleich, dass die Zugehörigkeitswerte durch Einführung der Entfernungsbegrenzung insgesamt kleiner ausfallen. Der



(a)



(b)

Abbildung 54. Analyse des Ergebnisses des Klassifikationsansatzes der Ebene 2 für den Datensatz IKONOS4 mit und ohne Entfernungsbedingung. (a) Referenzdaten (minimale Referenz) (b) relative Histogramme für Referenz und Hintergrund jeweils mit und ohne Entfernungsbedingung

Grund liegt in der geringeren Anzahl an Trainingsgebieten, die für das jeweilige Bildelement genutzt werden, wodurch sich die Rangfilterung stärker auswirkt. Er bewirkt jedoch auch, dass durch Einführung der Entfernungsbedingung die Auswahl der zu nutzenden Ebene erleichtert wird. Die verbesserte Trennbarkeit der Straßenklasse vom Hintergrund durch Einführung der Entfernungsbedingung wird deutlich, wenn die Anteile an Bildelementen mit Zugehörigkeitswerten zwischen 0,1 und 0,5 für die Hintergrundbereiche betrachtet werden. Sie betragen 14 % ohne gegenüber 4 % mit Entfernungsbedingung.

## Zusammenfassung

Die Ergebnisse des Klassifikationsansatzes zeigen für die untersuchten Datensätze z.T. eine nicht unerhebliche Abhängigkeit von der genutzten Rangebene. Eine Aussage, welche Ebene für eine Weiterverarbeitung verwendet werden sollte, kann daher nicht generell gegeben werden, sondern hängt von den Daten und vom Ziel der Weiterverarbeitung ab. Besteht in erster Linie Interesse an Hauptstraßen, so zeigen die Untersuchungen, dass eine größere Zahl an Ebenen abgeschnitten werden kann und meist auch sollte. Auch dann liegt noch genügend Evidenz für die Hauptstraßen vor, die Störobjekte werden jedoch zu einem großen Anteil beseitigt. Die Gründe hierfür sind die in der Regel gute Sichtbarkeit von Hauptstraßen in Verbindung mit einem einheitlichen Straßenbelag, was zu einem großen Anteil an Trainingsgebieten mit einer großen Zahl von Bildelementen aus diesem Bereich führt. Soll das Straßenklassenbild dagegen der Verifikation von Verbindungshypothesen dienen, so ist es in der Regel sinnvoll, nur wenige oder keine Ebene abzuschneiden, da der entsprechende Suchraum durch die aufgestellten Verbindungshypothesen stark eingeschränkt ist. Eventuell vorhandene Störobjekte haben in diesem Fall nur einen untergeordneten Einfluss. Bei Einführung einer Entfernungsbedingung verringert sich in der Regel die Anzahl der abzuschneidenden Ebenen durch die kleinere Zahl an Trainingsgebieten, die auf die jeweiligen Bildelemente einen Einfluss haben. Diese Bedingung sollte daher

für größere Szenen im Regelfall genutzt werden.

### 5.3.2 Experimente zur Straßennetzbildung

Eine Beurteilung der Leistungsfähigkeit des in Abschnitt 4.3.2 vorgestellten Verfahrens zur Extraktion von Straßen aus höchst aufgelösten Satellitenbilddaten erfolgt anhand der im vorangegangenen Abschnitt im Rahmen des Klassifikationsansatzes untersuchten Datensätze IKONOS1–4. Für eine externe Bewertung der Extraktionsergebnisse stehen für die Datensätze IKONOS2–4 jeweils eine minimale und eine maximale Referenz (siehe Abschnitt 5.1) zur Verfügung. Für IKONOS1 wurden die Referenzdaten des EuroSDR Tests verwendet, um die erzielten Ergebnisse mit den Ergebnissen anderer Gruppen im Rahmen des Tests vergleichen zu können.

#### Datensatz IKONOS1

Für den Datensatz IKONOS1 (siehe Abbildung 38) wurden Linien in allen vier spektralen Kanälen und im Straßenklassenbild der zweiten Ebene (siehe Abbildung 41(b)) extrahiert. Für die Bewertung der Linien wurde ebenfalls das Straßenklassenbild der zweiten Ebene verwendet. Die Parameter der Zugehörigkeitsfunktionen für die Bewertung gemäß Abschnitt 4.3.2 (siehe auch Abbildung 25) sind in Tabelle 6 zusammengefasst. Die Parameter für die Bewertung der Länge wurden so gewählt, dass die in der Ortschaft zu erwartenden kurzen Linienstücke eine schlechte Bewertung erhalten, da es sich hierbei in der Regel um Hausdächer oder Einfahrten handelt, die für die Straßenextraktion nicht relevant sind. Die oberen Parameter für die Breite wurden relativ hoch angesetzt, da der Erdweg als sehr breite linienhafte Struktur abgebildet wird (siehe Abschnitt 5.3.1) und für das Gesamtnetz von großer Bedeutung ist. Die Parameter für die mittlere Zugehörigkeit zur Straßenklasse sind so gewählt, dass der Großteil der Hintergrundpixel kleinere Werte erhält, die Straßenpixel jedoch auch im Mittel noch in den gut bewerteten Bereich fallen.

Parameter	untere Schranken		obere Schranken	
Länge [m]	12	25	–	
mittlere Breite [m]	1	3	13	18
mittlerer Zugehörigkeitswert	0.1	0.2	–	

Tabelle 6. Bewertungsparameter für den Datensatz IKONOS1

Die manuell digitalisierte Referenz ist in Abbildung 55(a) dargestellt. Die Extraktion wurde zweigeteilt durchgeführt. In einem ersten Schritt wurde aus den bewerteten Linien mittels Netzwerkbildung ein gewichteter Graph aufgebaut, wobei kleine Lücken geschlossen wurden (siehe Abbildung 55(b) die in grau dargestellten Linien). Dieses vorläufige Ergebnis wurde mittels globaler Gruppierung (siehe Abschnitt 2.3.4) verbessert indem größere Lücken identifiziert und mit dem in Abschnitt 4.3.3 beschriebenen Verfahren überbrückt und verifiziert wurden. Die so geschlossenen Lücken sind in Abbildung 55(b) in schwarz dargestellt.

Der Vergleich der Extraktionsergebnisse mit der Referenz erfolgte für alle Datensätze mittels der in Abschnitt 5.2 beschriebenen Puffermethode mit einer Pufferbreite von 5 m. Das Ergebnis der Evaluierung des verbesserten Ergebnisses ist in Abbildung 56 (links) in graphischer Form dargestellt, wobei die korrekt extrahierten Straßen in grün, fehlende Straßen in der Extraktion in rot und fehlerhaft

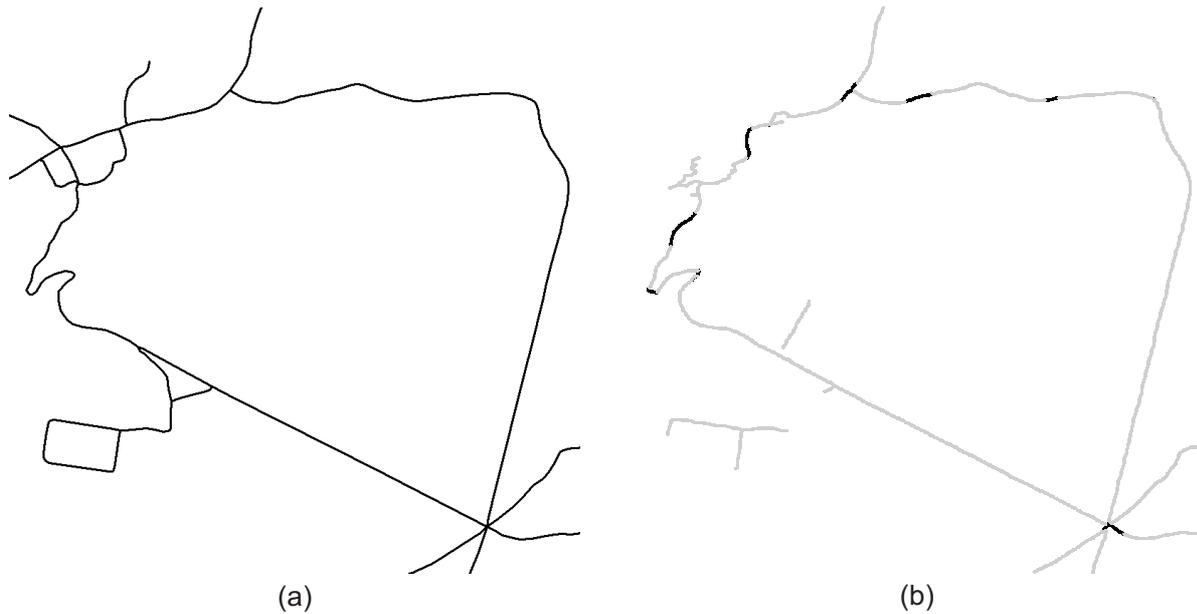


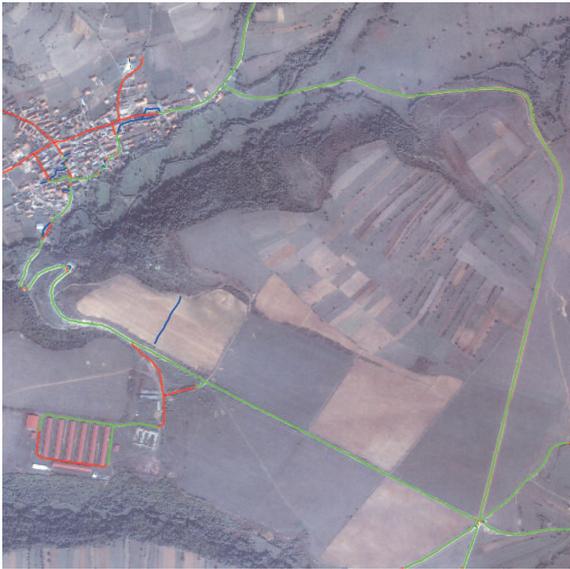
Abbildung 55. Datensatz IKONOS1 – (a) Manuell digitalisierte Referenzdaten (b) Ergebnis – grau: Ergebnis ohne Verbesserung, schwarz: Lücken die im Rahmen der globalen Gruppierung geschlossen wurden

extrahierte Straßen in blau dargestellt sind. Die Ergebnisse in Form der Bewertungsmaße Vollständigkeit, Korrektheit und RMS zeigt die Tabelle im rechten Teil der Abbildung 56 sowohl ohne als auch mit Verbesserung. Sie machen die Bedeutung der globalen Gruppierung für die Straßenextraktion deutlich. Die erzielte Vollständigkeit konnte von 0.72 auf 0.78 bei etwa gleich bleibender Korrektheit gesteigert werden. Daneben konnte die Topologie korrekt hergestellt werden, indem die isolierten Teile miteinander verbunden wurden.

Die weitere Analyse der Ergebnisse zeigt sehr gute Werte für die Korrektheit für dieses Beispiel. Der auffallendste verbleibende Fehler ist ein heller Streifen im Bereich des großen Feldes im linken Bildbereich, der als Straße extrahiert wurde. Die weiteren fehlerhaft als Straße identifizierten Linien befinden sich im Bereich der Siedlung. Ähnlich verhält es sich mit den fehlenden Straßen, die sich einerseits ebenfalls im Bereich der Siedlung befinden, andererseits im Umfeld der langgestreckten parallelen Gebäude im linken unteren Bildbereich. Letztere sind auch für einen erfahrenen Auswerter nur schwer zu identifizieren und ergeben sich in erster Linie aus der Verbindungsfunktion zu den Gebäuden. Mit einer geometrischen Genauigkeit von besser als 1 m bzw. 1 Bildelement wurde die zu erwartende Genauigkeit etwas überschritten. Die Verschlechterung der Genauigkeit durch die globale Gruppierung erklärt sich durch die Approximation des Straßenverlaufs in den abgeschatteten bzw. teilweise verdeckten Bereichen durch die Ziplock-Snake, die nicht die hohe Qualität der Linienextraktion hat.

## Datensatz IKONOS2

Für den Datensatz IKONOS2 (siehe Abbildung 43) wurden ebenfalls die Bilddaten aller vier spektralen Kanäle sowie das Straßenklassenbild der zweiten Ebene (siehe Abbildung 45(b)) für die Extraktion von Linien verwendet. Die Parameter für die Bewertung der Linien sind in Tabelle 7 zusammengefasst. Die Zugehörigkeitswerte zur Straßenklasse wurden dem Straßenklassenbild der zweiten Ebene entnommen und die Auswahl der Bewertungsparameter erfolgte analog zum vorangegangenen Bei-



	ohne Verbesserung	mit Verbesserung
Vollständigkeit	0.72	0.78
Korrektheit	0.91	0.90
RMS [ <i>Pixel</i> ]	0.80	0.89

Abbildung 56. Evaluierung des Datensatzes IKONOS1 – links: Bild mit überlagerter Evaluierung (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive)), rechts: Bewertungsmaße

spiel. Kleine Änderungen ergaben sich durch das Fehlen größerer Siedlungsflächen. Deswegen wurden auch kürzere Linienstücke akzeptiert. Die manuell extrahierte Referenz wurde in eine minimale Referenz, d.h. nur die Hauptstraßen, und eine maximale Referenz, die zusätzlich Feldwege und Zufahrten enthält (siehe Abbildung 57(a)), unterteilt.

Parameter	untere Schranken		obere Schranken	
Länge [ <i>m</i> ]	10	20	–	
mittlere Breite [ <i>m</i> ]	1	2	12	16
mittlerer Zugehörigkeitswert	0.1	0.2	–	

Tabelle 7. Bewertungsparameter für den Datensatz IKONOS2

Die Extraktion wurde für diesen Datensatz analog zum vorangegangenen Beispiel zweigeteilt durchgeführt. Da es keine wesentlichen Verdeckungen oder sonstige Störungen im Bereich der Hauptstraßen gibt, brachte die globale Gruppierung hier keine Verbesserung. Das Ergebnis ist in Abbildung 57(b) dargestellt. Die Evaluierung mit der minimalen Referenz (siehe Abbildung 58 (links)) zeigt, dass die wichtigsten Straßen sehr zuverlässig extrahiert werden konnten (siehe auch Tabelle in Abbildung 58 (rechts)). Die unbefriedigende Korrektheit von 0.77 relativiert sich bei genauerer Untersuchung der im Vergleich zur minimalen Referenz falsch extrahierten Straßen. Hier zeigt es sich, dass der größte Teil davon zur maximalen Referenz gehört. Verdeutlicht wird dies durch die Korrektheit für die maximale Referenz, die mit 0.94 einen guten Wert erreicht.

Das Beispiel macht deutlich, dass Straßen in der offenen Landschaft sehr zuverlässig extrahiert werden können. Es zeigt sich auch, dass durch geschickte Parameterwahl gesteuert werden kann, welche Straßenklassen in das Ergebnis einfließen. Durch die Veränderung der Bewertungsparameter für die mittlere Straßenbreite (untere Schranken 4 m bzw. 7 m) konnte ein Ergebnis erzielt werden, bei dem die kleinen Wege fast vollständig herausgefiltert werden und lediglich die Hauptstraßen sehr sicher extrahiert werden (siehe Abbildung 59). Die geometrische Genauigkeit der Ergebnisse liegt mit 1.20 m im Bereich dessen, was für Bilddaten dieser Auflösung erwartet werden kann.

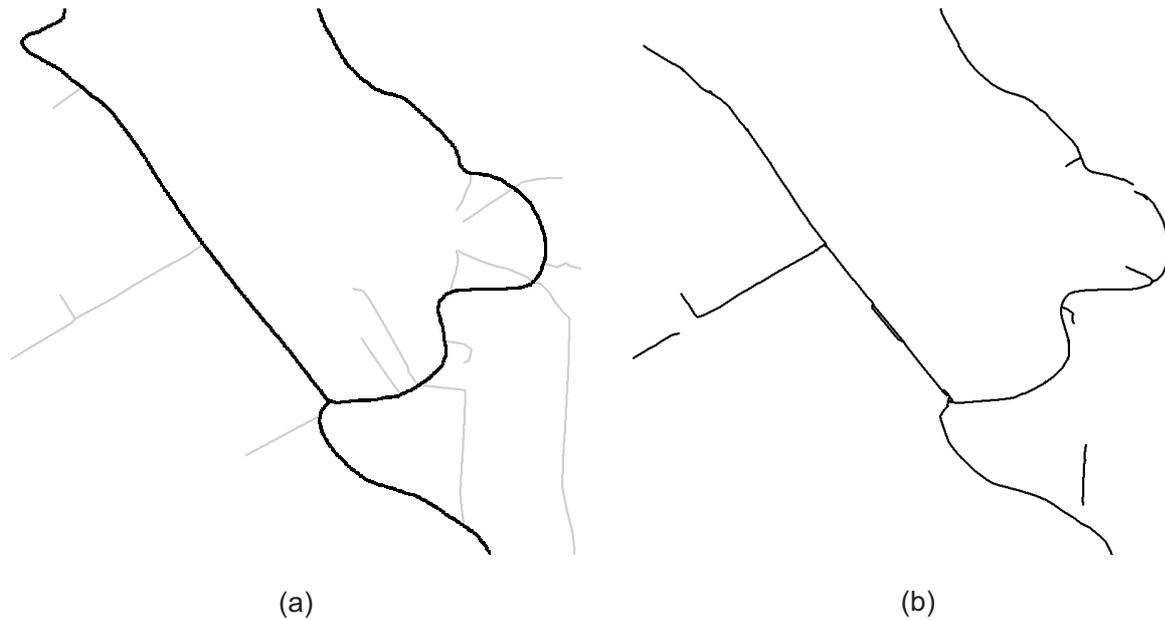
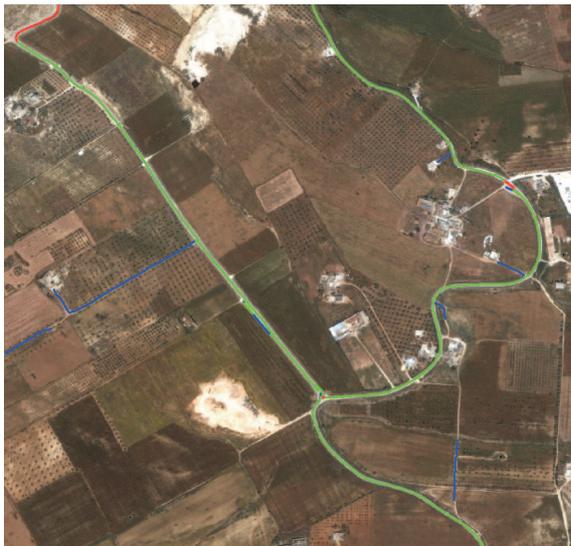


Abbildung 57. Datensatz IKONOS2 – (a) Manuell digitalisierte Referenzdaten schwarz: minimale Referenz, schwarz + grau: maximale Referenz (b) Ergebnis



	minimale Referenz	maximale Referenz
Vollständigkeit	0.95	0.60
Korrektheit	0.77	0.94
RMS [ <i>Pixel</i> ]	1.22	1.20

Abbildung 58. Evaluierung des Datensatzes IKONOS2 – links: Bild mit überlagelter Evaluierung für minimale Referenz (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive)), rechts: Bewertungsmaße

### Datensatz IKONOS3

Als Grundlage für die Straßenextraktion im Datensatz IKONOS3 (siehe Abbildung 48) dienten die Bilddaten aller vier Kanäle sowie das Straßenklassenbild der sechsten Ebene (siehe Abbildung 50(d)). Aus den genannten Daten wurden jeweils Linien extrahiert, die im Weiteren als Straßenhypothesen dienen. Für die Bewertung der Straßenhypothesen wurden die in Tabelle 8 aufgeführten Parameter und wiederum das Straßenklassenbild der sechsten Ebene verwendet. Vergleichbar mit dem Vorgehen für den ersten Datensatz wurden auch hier aufgrund der Siedlungsbereiche kurze Linienstücke

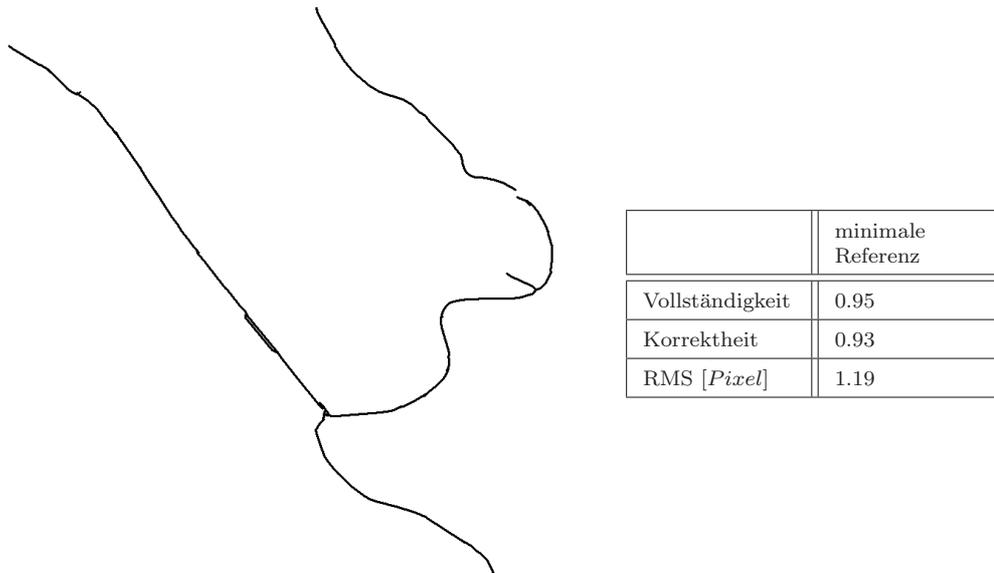


Abbildung 59. Ergebnis des Datensatzes IKONOS2 mit Konzentration auf die Hauptstraßen (Parameter für mittlere Breite 4-7-12-16) – links: resultierendes Straßennetz, rechts: Bewertungsmaße für die minimale Referenz

schlecht bewertet. Die im Vergleich zu den vorangegangenen Testbeispielen niedrigeren Werte für die mittlere Zugehörigkeit zur Klasse *Straße* begründen sich durch die starke Filterung bis zur sechsten Ebene im Rahmen des Klassifikationsansatzes und die damit zu erwartenden niedrigeren Zugehörigkeitswerte für Straßen. Die manuell extrahierte Referenz teilt sich in eine minimale und eine maximale auf (siehe Abbildung 60(a)). Die minimale Referenz enthält die Hauptstraßen sowie die wichtigsten Straßen innerhalb der Siedlungsgebiete, die maximale Referenz zusätzlich die kleineren Straßen im Siedlungsbereich.

Parameter	untere Schranken		obere Schranken	
Länge [ <i>m</i> ]	10	30	–	
mittlere Breite [ <i>m</i> ]	2	3	12	16
mittlerer Zugehörigkeitswert	0.07	0.15	–	

Tabelle 8. Bewertungsparameter für den Datensatz IKONOS3

Die Ergebnisse für den Datensatz IKONOS3 (siehe Abbildung 60(b)) zeigen, dass große Straßen mit parallelen Fahrbahnen und komplexen Kreuzungen gut extrahiert werden. Dies gilt, obwohl die Straßen in diesem Beispiel als dunkle Linien im Bild abgebildet werden. Für die Straßen innerhalb der Siedlungsbereiche ergibt sich ein anderes Bild. Hier wurde das Straßennetz nur fragmentiert rekonstruiert. Abbildung 61 zeigt die Evaluierung des Ergebnisses mit der minimalen Referenz (links) sowie die tabellarische Übersicht der Bewertung (rechts). Es zeigt sich auch in diesem Beispiel, dass ein Teil der gegenüber der minimalen Referenz als fehlerhaft bewerteten Straßen zur maximalen Referenz gehören (Korrektheit von 0.88 für minimale und von 0.92 für maximale Referenz). Die Vollständigkeit von 0.44 für die maximale Referenz verdeutlicht die Schwächen des Ansatzes im Bereich von Siedlungsflächen. Die globale Gruppierung brachte für dieses Beispiel keine nennenswerte Verbesserung und wird deshalb nicht näher betrachtet. Die geometrische Genauigkeit der Ergebnisse ist für dieses Beispiel mit etwa 1.6 m etwas schlechter als erwartet. Ein Grund hierfür sind die Straßen in den Siedlungsbereichen. Hier wurden die Straßen zwar teilweise extrahiert, die extrahierten Straßenachsen stimmen durch Verdeckungen jedoch oft nicht mit den tatsächlichen überein.

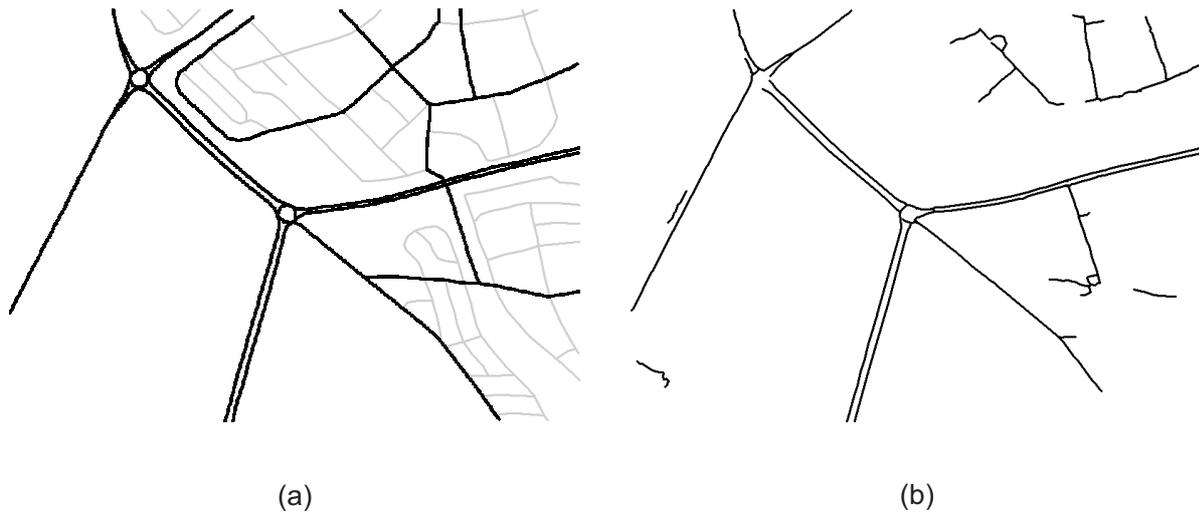


Abbildung 60. Datensatz IKONOS3 – (a) Manuell digitalisierte Referenzdaten schwarz: minimale Referenz, schwarz + grau: maximale Referenz (b) Ergebnis



	minimale Referenz	maximale Referenz
Vollständigkeit	0.77	0.44
Korrektheit	0.88	0.92
RMS [ <i>Pixel</i> ]	1.60	1.65

Abbildung 61. Evaluierung des Datensatzes IKONOS3 für minimale Referenz – links: Bild mit überlagelter Evaluierung (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive)), rechts: Bewertungsmaße

## Datensatz IKONOS4

Die Versuche für den größten Datensatz IKONOS4 (siehe Abbildung 52) wurden mit den beiden im vorangegangenen Abschnitt beschriebenen Vorgehensweisen für den Klassifikationsansatz, d.h., mit und ohne Entfernungsbedingung, durchgeführt. Abgesehen vom Ergebnis des Klassifikationsansatzes wurden für den kompletten Extraktionsprozess die selben Parameter genutzt (siehe Tabelle 9). Zur Linienextraktion wurden wiederum die Biddaten aller vier spektralen Kanäle sowie das jeweilige Straßenklassenbild der Ebene 2 (siehe Abbildungen 50(c) und (d)) verwendet. Die Parameter wurden analog zum zweiten Datensatz für offenes Gelände gewählt. Lediglich der untere Parameter für die mittlere Zugehörigkeit zur Straßenklasse wurde etwas niedriger gewählt, da durch die Entfernungsbedingung die Zugehörigkeitswerte insgesamt etwas niedriger ausfallen. Für die Evaluierung



Abbildung 62. Manuell digitalisierte Referenzdaten für Datensatz IKONOS4 – schwarz: minimale Referenz, schwarz + grau: maximale Referenz

standen manuell extrahierte Straßendaten in Form einer minimalen und einer maximalen Referenz zur Verfügung (siehe Abbildung 62). Die minimale Referenz enthält die gut sichtbaren Hauptstraßen, die maximale Referenz zusätzlich die kleineren Straßen, sowie einige Straßen in der Ortschaft und die nur schwer zu identifizierenden Hauptstraßen, die durch Bäume sehr stark verdeckt sind.

Parameter	untere Schranken		obere Schranken	
Länge [m]	10	20	–	
mittlere Breite [m]	2	3	10	16
mittlerer Zugehörigkeitswert	0.08	0.2	–	

Tabelle 9. Bewertungsparameter für den Datensatz IKONOS4

Die in Abbildung 63 vorgestellten Ergebnisse zeigen das Resultat nach der globalen Gruppierung, die für dieses Beispiel einige kleine Verbesserungen brachte. Dieses Beispiel zeigt den Vorteil der Entfernungsbedingung für größere Datensätze. Sie resultiert in einer deutlichen Verringerung der Fehlextraktionen, was sich auch in den Werten für die Korrektheit niederschlägt (siehe Tabelle 10): Der Wert verbessert sich für die minimale Referenz von 0.47 auf 0.74. Die Vollständigkeit der Ergebnisse wird dagegen durch die Entfernungsbedingung nur unwesentlich beeinflusst und liegt für die minimale Referenz bei etwa 0.82. Die Verteilung der Fehlextraktionen zeigt sich am deutlichsten in der Evaluierungsdarstellung in Abbildung 64. Wie auch schon in den ersten beiden Beispielen liegt die geometrische Genauigkeit der Ergebnisse mit etwa 1.2 m im Bereich der Bodenauflösung der Bilddaten.

	ohne Entfernungsbedingung		mit Entfernungsbedingung	
	min. Ref.	max. Ref.	min. Ref.	max. Ref.
Vollständigkeit	0.82	0.53	0.83	0.49
Korrektheit	0.47	0.58	0.74	0.81
RMS [Pixel]	1.20	1.35	1.16	1.17

Tabelle 10. Evaluierung der Ergebnisse für den Datensatz IKONOS4




Abbildung 63. Ergebnis für Datensatz IKONOS4 – (a) ohne Entfernungsbedingung (b) mit Entfernungsbedingung

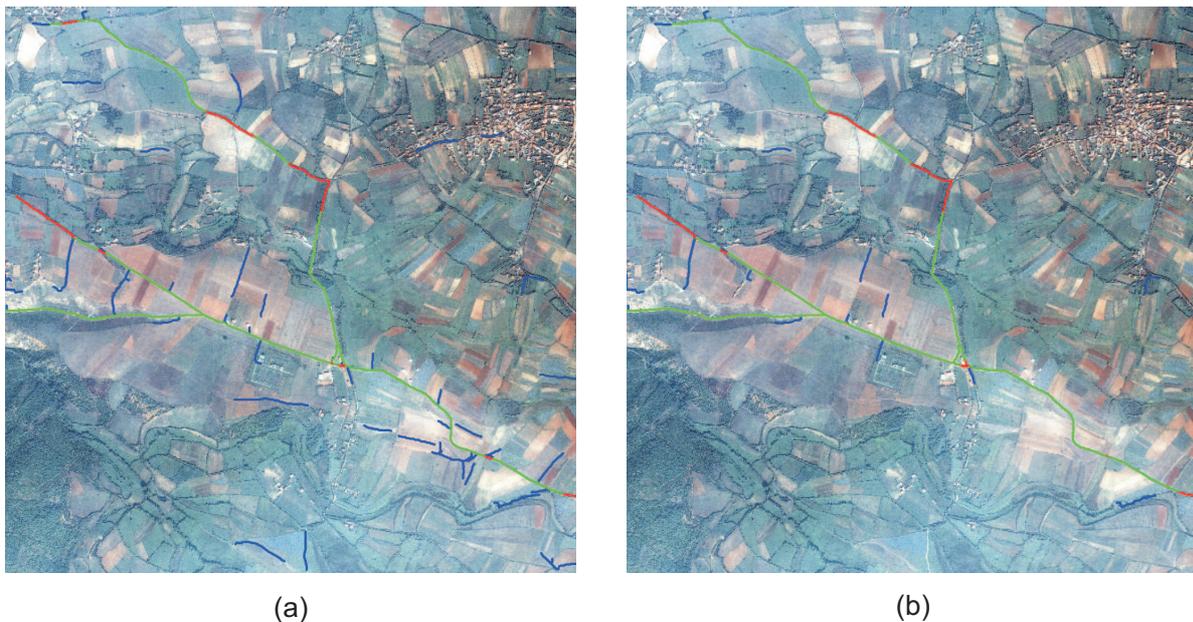


Abbildung 64. Evaluierung des Datensatzes IKONOS4 für die minimale Referenz – (a) ohne Entfernungsbedingung (b) mit Entfernungsbedingung; grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive)

## Zusammenfassung

Die Experimente zur Straßenextraktion aus höchstauflösenden multispektralen Satellitenbilddaten zeigen, dass Daten dieser Auflösung für die Extraktion in der offenen Landschaft gut geeignet sind. In allen Testbeispielen konnten die Hauptstraßen mit befriedigender Vollständigkeit extrahiert werden. Bei kleineren Straßen und Wegen ist die Vollständigkeit dagegen deutlich geringer. Der Hauptgrund hierfür ist im Ergebnis des Klassifikationsansatzes, d.h. im Straßenklassenbild, zu suchen. Hier sind die schmalen Straßen und Wege aufgrund der gewählten Mindestgröße der Trainingsgebiete sowie

häufigen spektralen Unterschieden zu den Hauptstraßen, meist nur unzureichend repräsentiert. Sie werden zwar als Linie extrahiert, der Bewertungsparameter für die mittlere Zugehörigkeit fällt meist jedoch sehr gering aus. Ist der Auswerter nur an den größeren Straßen interessiert, so können die kleinen durch die Bewertungsparameter für die mittlere Straßenbreite einfach herausgefiltert werden. Die Versuche zeigen weiter, dass die Werte für die Korrektheit, d.h. die Zuverlässigkeit, der Extraktion in erster Linie durch die Nutzung der spektralen Eigenschaften auf ein befriedigendes Maß von meist über 0.90 gebracht werden konnte.

Bezüglich der Einstellung der für die Extraktion notwendigen Parameter zeigt sich, dass die Unterschiede der Werte nur sehr gering sind. Für die Parameter Länge und mittlere Breite der Linienstücke hängen sie stark vom geforderten Ergebnis ab. Selbst relativ kleine Veränderungen am Parameter für die Länge hat in besiedeltem Gebiet erhebliche Auswirkungen auf das Ergebnis. Im offenen Gelände wirken sich solche Parameterveränderungen dagegen nur gering aus. Der Parameter für den mittleren Zugehörigkeitswert zur Klasse *Straße* hängt vom genutzten Ergebnis des Klassifikationsansatzes ab. Hier gilt, je stärker die Rangfilterung, desto niedriger sind die mittleren Zugehörigkeitswerte und entsprechend niedriger müssen die Parameter eingestellt werden. Die globale Gruppierung zur Verbesserung der vorläufigen Extraktionsergebnisse hat sich in Gebieten der offenen Landschaft bewährt, in denen die Sichtbarkeit der Straßen durch partielle Verdeckungen gestört wird. Wie der letzte Datensatz, IKONOS4 zeigt, ist der Einsatz der Entfernungsbedingung im Rahmen des Klassifikationsansatzes für große Datensätze zu empfehlen. Hiermit kann der lokale Charakter von Straßen stärker berücksichtigt und die Auswirkung von fehlerhaften Trainingsgebieten begrenzt werden, wodurch insgesamt die Zahl von Fehlextraktionen erheblich verringert wird.

#### 5.4 Untersuchungen für hochaufgelöste Satellitenbilddaten

Die Untersuchung der Ansätze zur Straßenextraktion aus hochaufgelösten Satellitenbildern erfolgt anhand von vier IRS-1C/D pan-sharpened Bildausschnitten (siehe Abschnitt 2.1). Die Bildausschnitte zeigen unterschiedliche Regionen in Algerien und decken die in Abschnitt 4.1 beschriebenen Kontextregionen, *landwirtschaftlich genutzt*, *Wüste* und *Gebirge*, ab. Die Datensätze IRS1 und IRS2 sind Beispiele für landwirtschaftliche genutzte Regionen, IRS3 und IRS4 repräsentieren jeweils ein Beispiel aus einer Wüsten- und einer Gebirgsregion. Vertiefte Untersuchungen zur Eignung der in Abschnitt 4.4.2 vorgeschlagenen Vorgehensweise für Wüste und Gebirge sind in (JOST 2003) zu finden. Für eine externe Bewertung der automatisch erzielten Extraktionsergebnisse stehen für alle Datensätze Referenzdaten zur Verfügung, die manuell aus den auch für die Extraktion genutzten Bilddaten erfasst wurden.

##### Datensatz IRS1

Der Datensatz IRS1 zeigt eine landwirtschaftlich genutzte Region mit einem Straßennetz von durchschnittlicher Komplexität (siehe Abbildung 65(a)). Der Ausschnitt umfasst ein Gebiet von  $587 \times 451$  Pixel mit einer Bodenauflösung von 5 m, d.h.  $6.6 \text{ km}^2$ . Die Straßen sind in diesem Beispiel einerseits als helle Linien mit wechselndem Hintergrund zu erkennen, andererseits bilden sie sich indirekt anhand von fortgesetzten Feldgrenzen ab. Die Art der Straßen ist sehr unterschiedlich und reicht von breiten Straßen, wie z.B. die von links nach rechts verlaufende Straße am unteren Bildrand, bis



Abbildung 65. Datensatz IRS1 (587×451 Pixel) – (a) Bilddaten in CIR-Farbinfrarotdarstellung (b) Referenzdaten

zu etlichen schmalen Wegen, die zwischen den Feldern verlaufen. Für dieses Beispiel wurde der in Abschnitt 4.4.1 vorgestellte Gruppierungsansatz für die Extraktion verwendet. Als Grundlage für die Extraktion dienen alle drei spektralen Kanäle. Die Basis für die Gruppierung bildeten die linearen Strukturen, die sowohl aus einer Linien- als auch einer Kantenextraktion stammen. Die eigentliche Gruppierung zu Straßenabschnitten wurde für Linien und Kanten separat voneinander durchgeführt. Die resultierenden verifizierten Straßen wurden zu einem Datensatz fusioniert und im Rahmen der Netzbildung (siehe Abschnitt 2.3.4) zu einem topologischen Straßennetz vereinigt. Die für die Evaluierung verwendeten Referenzdaten zeigt Abbildung 65(b).

Das Ergebnis der Straßenextraktion für den Datensatz IRS1 ist in Abbildung 66(a) dargestellt. Die in Abbildung 66(b) zusammengestellte Evaluierung des Ergebnisses macht klar, dass für diesen Datensatz die Hauptstraßen (Straße diagonal von links oben nach rechts unten und Piste von links nach rechts am unteren Bildrand) fast komplett extrahiert wurden. Die kleineren Straßen und Wege wurden zum größten Teil erfasst. Bei ihnen treten nur, wie auch schon bei den großen Straßen, hauptsächlich in den Randbereichen Probleme auf. Es wurden sowohl die Straßen extrahiert, die im Bild als helle Linien abgebildet sind als auch solche, die lediglich indirekt anhand der Feldgrenzen zu erkennen sind. Das insgesamt befriedigende Ergebnis verdeutlichen die in Tabelle 11 zusammengefassten Bewertungsmaße. Der Wert für die Vollständigkeit zeigt mit 0.78, dass ein Großteil der Straßen erfasst wurde. Der Wert von 0.67 für die Korrektheit zeigt auf der anderen Seite wie anfällig Daten dieser Art für Fehlextraktionen sind. So wurden einige Feldgrenzen, an denen keine Wege zu erkennen sind und die auch keine Verbindungsfunktion aufweisen, fälschlicherweise als Straße extrahiert.

Vollständigkeit	0.78
Korrektheit	0.69
RMS [ <i>Pixel</i> ]	1.59

Tabelle 11. Evaluierung der Ergebnisse des Datensatzes IRS1

## Datensatz IRS2

Der Datensatz IRS2 zeigt ebenfalls ein Gebiet mit vorherrschend landwirtschaftlicher Nutzung (siehe Abbildung 67(a)). Das Bildbeispiel hat eine Größe von 800×800 Pixeln bzw. 16 km<sup>2</sup>. Das Straßennetz

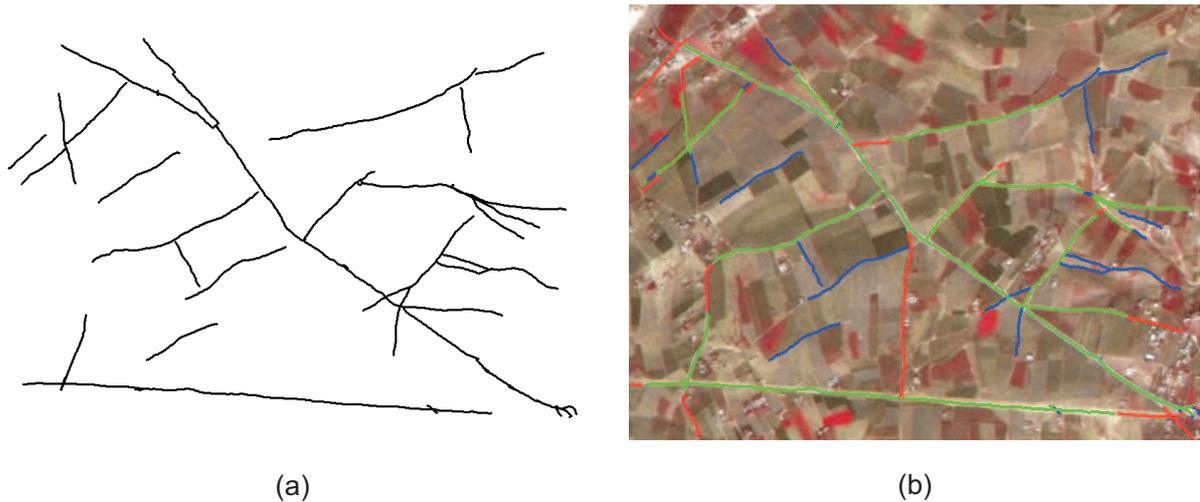


Abbildung 66. Datensatz IRS1 – (a) Ergebnis (b) Bild mit überlagerter Evaluierung (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive))

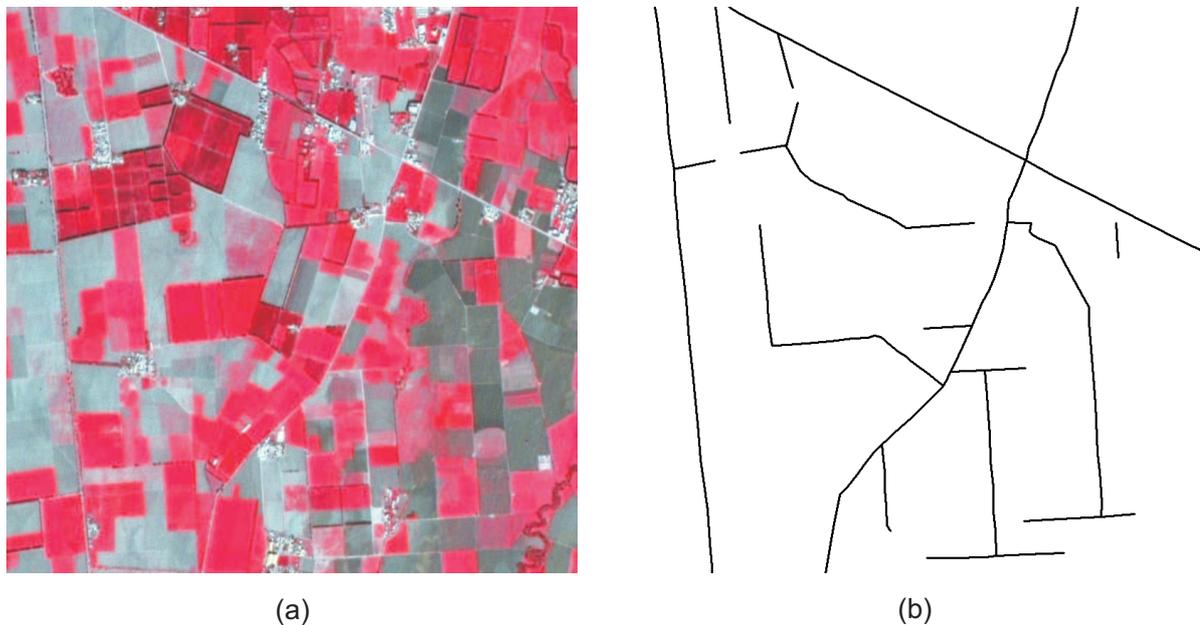


Abbildung 67. Datensatz IRS2 (800×800 Pixel) – (a) Bilddaten in CIR-Farbinfrarotdarstellung (b) Referenzdaten

ist im Vergleich mit dem vorangegangenen Datensatz erheblich komplexer und selbst für einen Auswerter schwer zu erfassen (siehe auch Referenzdaten in Abbildung 67(b)). Die Straßen bilden sich nur teilweise als helle Linien ab. Zu einem großen Anteil sind sie dagegen nur anhand von Feldgrenzen zu erkennen. Eine weitere Schwierigkeit stellt die am linken Bildrand von oben nach unten verlaufende Straße dar, die zu einem großen Teil von Baumreihen begleitet und dadurch verdeckt wird. Die Vorgehensweise bei der Extraktion war für diesen Datensatz die gleiche wie für den vorangegangenen.

Das Ergebnis ist in Abbildung 68(a) dargestellt, Abbildung 68(b) zeigt die Evaluierung des Ergebnisses mit den Referenzdaten. Das Ergebnis verdeutlicht die zuvor genannten Schwierigkeiten. Die Vollständigkeit (siehe Tabelle 12) ist bei diesem Beispiel mit 0.61 gerade noch befriedigend, wohinge-

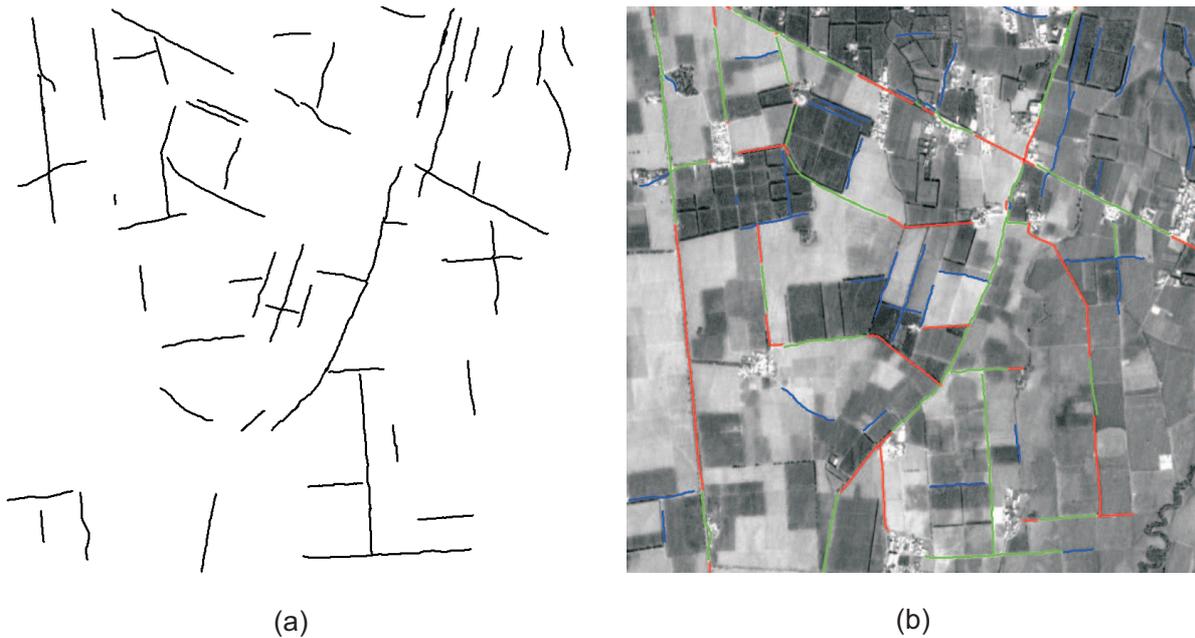


Abbildung 68. Datensatz IRS2 – (a) Ergebnis (b) Bild (grüner Kanal) mit überlagerter Evaluierung (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive))

gen die nicht ausreichende Korrektheit mit 0.53 den großen Anteil an Fehlextraktionen widerspiegelt. Letztere kommt auch hier von Feldgrenzen, die als Straßen bzw. Wege interpretiert, vom Auswerter im Rahmen der Erfassung der Referenz jedoch nicht als solche angesehen wurden. Fehlende Straßenstücke sind z.B. Teile der bereits erwähnten von Baumreihen begleitete Straße am linken Bildrand, sowie Straßen mit nur sehr wenig Evidenz, die vom Auswerter größtenteils anhand der Verbindungsfunktion, d.h. des Kontextes, erfasst wurden.

Vollständigkeit	0.61
Korrektheit	0.53
RMS [ <i>Pixel</i> ]	1.54

Tabelle 12. Evaluierung der Ergebnisse des Datensatzes IRS2

### Datensatz IRS3

Der Datensatz IRS3 zeigt ein Wüstengebiet in der algerischen Sahara (siehe Abbildung 69(a)) und hat eine Größe von  $1594 \times 1146$  Pixel bzw. ca  $47 \text{ km}^2$ . Die dazu gehörenden Referenzdaten sind in Abbildung 69(b) dargestellt. Der weitestgehend eintönige Bildinhalt besteht zum größten Teil aus erodierten Gesteinsformationen. Durch das Gebiet verlaufen drei Straßen, die sich an zwei Kreuzungen treffen und im Bild als dunkle Linien abgebildet sind. Gemäß der in Abschnitt 4.2 entwickelten Strategie wird für dieses Gebiet der Extraktionsansatz der TU München verwendet. Als Grundlage für die Extraktion dienten wieder alle drei spektralen Kanäle.

Das Ergebnis der Extraktion ist in Abbildung 70(a) dargestellt und zeigt ebenso wie die dazugehörige Evaluierung (siehe Abbildung 70(b)) die sehr gute Eignung des Ansatzes für diesen Datensatz. Die Extraktion wurde für dieses Wüstengebiet mit einer Vollständigkeit von 0.94 bei einer Korrektheit von 0.97 durchgeführt (siehe auch Tabelle 13). Zwei kurze Straßenstücke im Verlauf der etwas kleineren

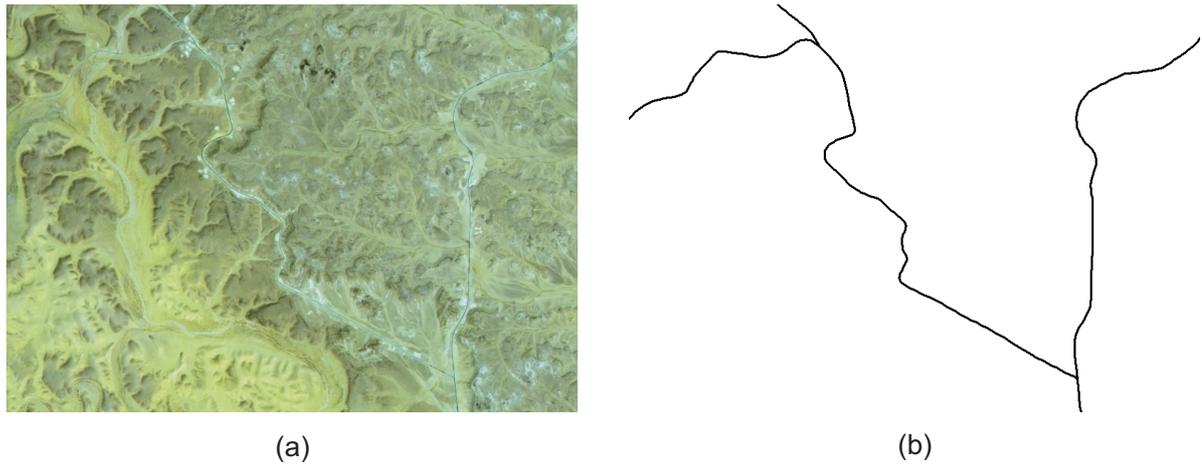


Abbildung 69. Datensatz IRS3 (Wüste – 1594×1146 Pixel) – (a) Bilddaten in CIR-Farbinfrarotdarstellung (b) Referenzdaten



Abbildung 70. Datensatz IRS3 – (a) Ergebnis (b) Bild (roter Kanal) mit überlagerter Evaluierung (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive))

Straße links oben im Bild wurden nicht extrahiert. Wie das Ergebnis zeigt, haben die linienhaften Strukturen an den Erosionskanten keine negativen Auswirkungen auf das Ergebnis.

Vollständigkeit	0.94
Korrektheit	0.97
RMS [ <i>Pixel</i> ]	1.03

Tabelle 13. Evaluierung der Ergebnisse des Datensatzes IRS3

#### Datensatz IRS4

Beim Datensatz IRS4 (siehe Abbildung 71(a)) handelt es sich um einen Ausschnitt aus einer Gebirgsregion. Die Bildgröße des Beispiels beträgt 1000×1000 Pixel oder 25 km<sup>2</sup>. Die manuell erfassten Referenzdaten sind in Abbildung 71(b) dargestellt. Durch das Testgebiet verlaufen zwei Straßen, die an einer Kreuzung zusammentreffen. Der Verlauf der Straßen ist in hohem Maße an der Topographie orientiert. Die Straßen besitzen sehr enge Kurven und Kehren. Der größte Teil der längeren Straße ist als helle Linie gut sichtbar. Lediglich im linken unteren Bereich, in dem die Straße durch bewaldetes

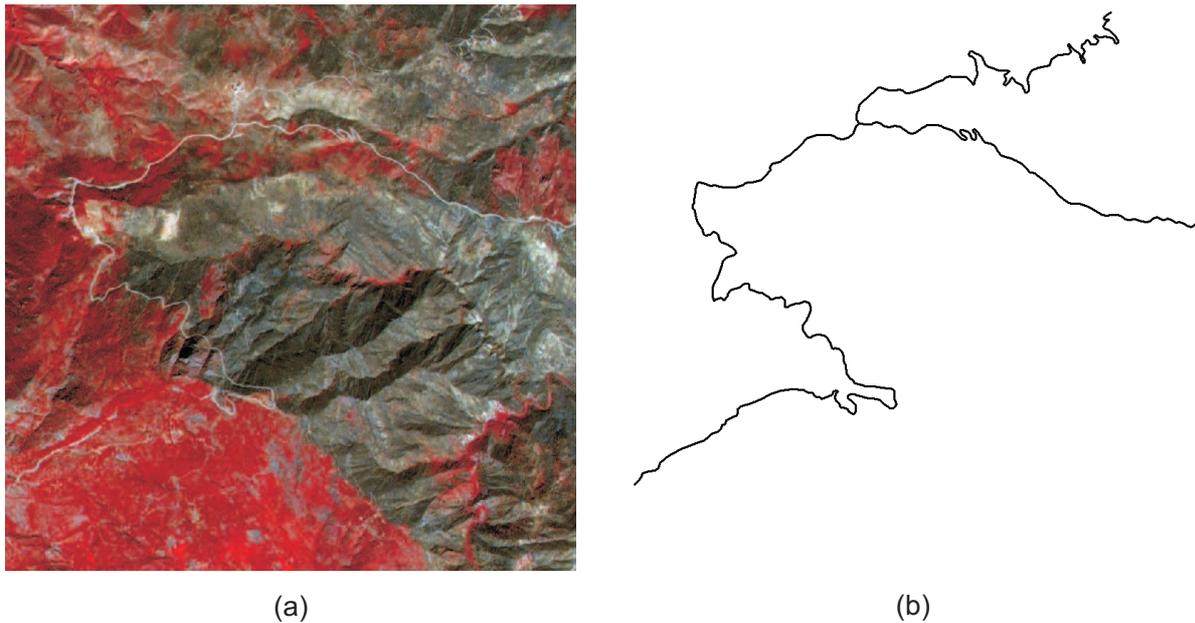


Abbildung 71. Datensatz IRS4 (Gebirge – 1000×1000 Pixel) – (a) Bilddaten in CIR-Farbinfrarotdarstellung (b) Referenzdaten

Gebiet verläuft, ist die Sichtbarkeit deutlich eingeschränkt. Die kleinere Straße im rechten oberen Bildbereich ist ebenfalls als helle Linie im Bild abgebildet, jedoch an etlichen Stellen nur schwer zu erkennen. Gemäß der in Abschnitt 4.2 entwickelten Strategie wird für dieses Gebiet der Extraktionsansatz der TU München verwendet, wobei die Parameter für die maximal zulässige Krümmung von Straßenabschnitten freigegeben werden. Auch für diesen Datensatz werden alle drei spektralen Kanäle für die Extraktion verwendet.

Das Ergebnis der automatischen Extraktion ist in Abbildung 72(a) dargestellt. Die Evaluierung des Ergebnisses (siehe Abbildung 72(b)) zeigt die sehr gute Zuverlässigkeit der Extraktion mit einem Wert für die Korrektheit von 0.93 (siehe Tabelle 14). Der Wert für die Vollständigkeit ist mit 0.76 bei der erwähnten sehr guten Korrektheit akzeptabel. Das Ergebnis zeigt, dass die Extraktion von Straßenabschnitten mit großer Krümmung keine Schwierigkeiten bereitet. Die fehlenden Straßenabschnitte resultieren in erster Linie aus Bereichen, in denen die Straßen wegen Verdeckungen, z.B. Waldgebiet links unten, oder schwachem Kontrast zur Umgebung, z.B. kleine Straße am oberen Bildrand, selbst für einen erfahrenen Auswerter nur schwer zu erkennen sind.

Vollständigkeit	0.76
Korrektheit	0.93
RMS [ <i>Pixel</i> ]	0.83

Tabelle 14. Evaluierung der Ergebnisse des Datensatzes IRS4

## Zusammenfassung

Die Ergebnisse der Versuche zur Straßenextraktion aus Satellitenbilddaten hoher Auflösung zeigen, dass die vorgeschlagenen Ansätze für Gebiete mit geringem Detaillierungsgrad zufriedenstellende Ergebnisse liefern können. Das zeigt sich vor allem in den vorgestellten Ergebnissen für Wüste und Gebirge. Die Ergebnisse für die landwirtschaftlich genutzten Gebiete mit deutlich höherer Detail-

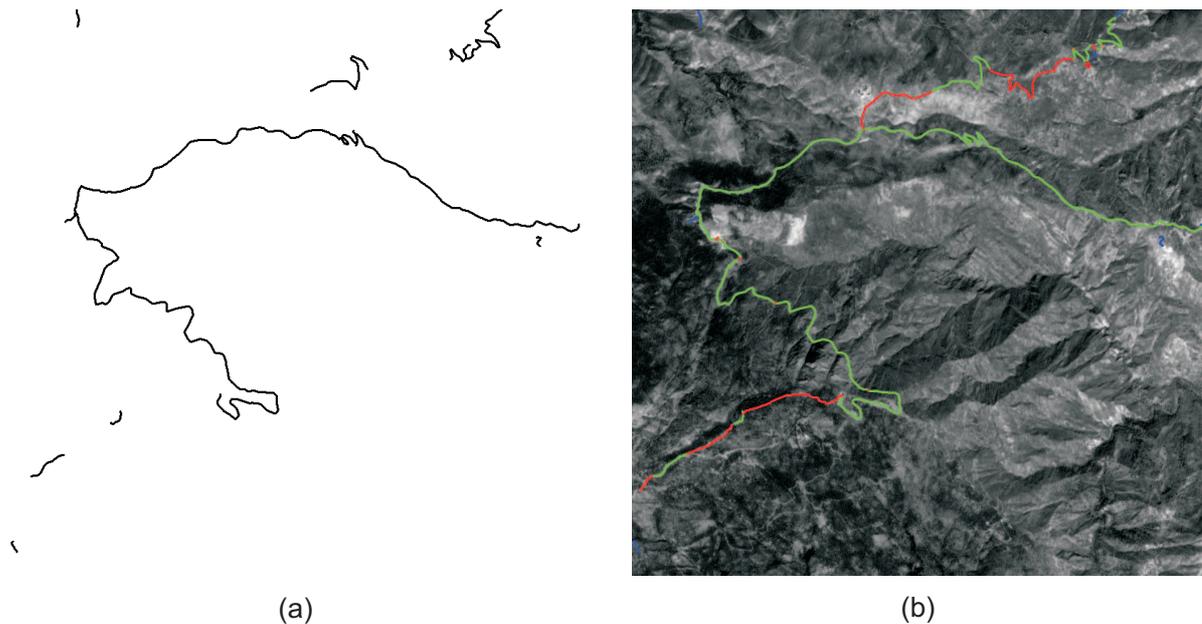


Abbildung 72. Datensatz IRS4 – (a) Ergebnis (b) Bild (roter Kanal) mit überlagertem Ergebnis (grün: korrekt extrahiert, rot: fehlt in der Extraktion, blau: fehlerhaft extrahiert (false positive)) – aus (JOST 2003)

lierung zeigen dagegen deutlich die Grenzen der vorgestellten Ansätze auf. In der Regel ist es für diese möglich, die Hauptstraßen zuverlässig zu extrahieren. Bei der Extraktion von kleineren Straßen und Wegen sinkt die Erfolgsquote aber erheblich ab und im Gegenzug müssen durch Aufweichen der Parameter inakzeptabel kleine Werte für die Korrektheit der Ergebnisse in Kauf genommen werden. Bezüglich der geometrischen Genauigkeit der Ergebnisse ergibt sich bei Verwendung des Ansatzes der TU München meist eine Genauigkeit von besser als 1 Pixel. Beim Gruppierungsansatz, der im Rahmen der vorgelegten Arbeit entwickelt wurde, sind die Werte mit gut 1.5 Pixel etwas schlechter, was durch die Nutzung von Kantenelementen, die sich mehr auf den Straßenrand beziehen, zu erklären ist. Für den Gruppierungsansatz konnte gezeigt werden, dass das Snake-basierte Verfahren zur Überbrückung von schwachen Linien und Kanten auch an Stellen, an denen der Linien- bzw. Kantenextraktor keine Ergebnisse liefert, Straßenabschnitte erzeugen kann. Allerdings ist der Preis hierfür, zumindest bei den verwendeten weichen Parametern (s.o.) eine nicht akzeptable niedrige Korrektheit, so dass der Gruppierungsansatz für eine praktische Verwendung sehr restriktiv gehandhabt werden sollte.

## 5.5 Beurteilung der Ergebnisse

Ziel der vorgelegten Arbeit ist es, ausgehend von den Ansätzen zur Straßenextraktion der TU München (BAUMGARTNER et al. 1999, BAUMGARTNER 2003, LAPTEV et al. 2000, WIEDEMANN et al. 1998, WIEDEMANN 2002) ein Verfahren für die großräumige (Neu-)Erfassung von Straßendaten zu entwickeln. Aufgrund der Auflösung der für die vorgelegte Arbeit in Frage kommenden Sensoren im Bereich von 1 – 5 m ist (BAUMGARTNER 2003) nur von untergeordneter Bedeutung. Im Wesentlichen dienen (WIEDEMANN et al. 1998, WIEDEMANN 2002) als Basis für die Entwicklungen.

Das im Rahmen der vorgelegten Arbeit entwickelte Verfahren ist in zwei wesentliche Bereiche unter-

teilt: die Extraktion aus Satellitenbilddaten höchster sowie hoher Auflösung. Hiermit soll der unterschiedlichen Detaillierung verschiedener Regionen Rechnung getragen werden: Viele Details erfordern die Nutzung von Daten höchster Auflösung wohingegen für detailarme Regionen hochaufgelöste Daten ausreichend sind. Für beide Auflösungen wurde die Leistungsfähigkeit der jeweiligen Ansätze anhand einer Reihe von Beispielen untersucht.

Die Nutzung verschiedener Verfahren für Gebiete mit unterschiedlichem Detaillierungsgrad bietet sich für großräumige Auswertungen als wirtschaftliche Lösung an. Speziell für Nordafrika mit großen Wüstengebieten erscheint der Einsatz von Satellitenbilddaten höchster Auflösung lediglich für den erweiterten Küstenstreifen sowie punktuell für Oasen bzw. sonstige größere Ansiedlungen notwendig. In den Wüstengebieten sind Straßen in der Regel in hochaufgelösten Satellitenbilddaten gut als linienhafte Objekte zu erkennen, so dass diese Daten aufgrund der sehr geringen Dichte des Straßennetzes in den meisten Fällen ausreichend sind.

### 5.5.1 Höchstaufgelöste Satellitenbilddaten

Bei Daten höchster Auflösung besteht der erste Schritt der Extraktion aus dem automatischen Klassifikationsansatz, der eine der wichtigsten Neuerungen der vorgelegten Arbeit darstellt. Die hierfür durchgeführte Generierung von Trainingsgebieten verwendet Ideen aus (BAUMGARTNER 2003) für die Erzeugung von Straßenabschnitten. Die Untersuchungen haben gezeigt, dass es mit der in Abschnitt 4.3.1 beschriebenen Methode möglich ist, genügend Trainingsgebiete mit ausreichender Zuverlässigkeit zu extrahieren. Dies gilt sowohl für Straßen, die im Bild hell, als auch für Straßen, die dunkel abgebildet werden.

Die Ergebnisse des im Rahmen der Arbeit entwickelten Fuzzy-Klassifikationsansatzes zeigen weiterhin, dass er die Straßen gut vom Hintergrund separiert. Die zusätzliche Möglichkeit, Bedingungen, wie z.B. die Entfernung eines Pixels vom Trainingsgebiet, mit zu verwenden, machen den Klassifikationsansatz flexibel für zukünftige Anforderungen. Die Entfernungsbedingung selbst verringert die Auswirkung von fehlerhaften Trainingsgebieten für große Bilder. Diese Robustheit wird zusätzlich durch die Rangfilterung erhöht. Das Straßenklassenbild zeigt als Ergebnis des Klassifikationsansatzes keine starre Trennung zwischen der Klasse *Straße* und dem Hintergrund, sondern berücksichtigt den Grad der Zugehörigkeit eines Pixels zur Straßenklasse in Form von Zugehörigkeitswerten.

Als Schwäche des Fuzzy-Klassifikationsansatzes ist die Abhängigkeit guter Ergebnisse von der richtigen Wahl der Parameter zu sehen. Dies gilt vor allem für die minimale Größe der Trainingsgebiete und die Tiefe der Rangfilterung. Die Trainingsgebietsgröße bewirkt indirekt eine unterschiedliche Bewertung der Straßenklassenarten. So führt ein kleinerer Wert dazu, dass auch kleinere Straßen bzw. Wege eine vergleichsweise gute Bewertung erhalten, allerdings verbunden mit dem Nachteil, dass die Zugehörigkeitswerte für fehlerhafte Gebiete oft größer ausfallen. Ein hoher Wert bewirkt dagegen eine Konzentration auf größere Straßen, da in der Regel nur für diese die extrahierten Gebiete groß genug sind. Die Tiefe der Rangfilterung steuert die Robustheit gegenüber fehlerhaften Trainingsgebieten. Dies gilt vor allem dann, wenn auf die Entfernungsbedingung verzichtet wird. Zusätzlich wird über die Rangfilterung auch Einfluss auf die Bewertung verschiedener Straßenklassenarten genommen. Eine tiefe Filterung bewirkt in der Regel, dass weniger gut sichtbare und damit meist auch weniger wichtige Straßen schlechter bewertet werden, da hier die Anzahl an Trainingsgebieten geringer ist, als bei wichtigen, gut sichtbaren Straßen.

Die Untersuchungen haben gezeigt, dass die Nutzung des (Fuzzy-)Klassifikationsansatzes für die Integration der spektralen Information in die Straßenextraktion die folgenden Vorteile bringt:

- ◇ Der Wert der Zugehörigkeit zur Klasse *Straße* wird in dem Straßenklassenbild abgelegt, das die spektrale Information aller Kanäle konzentriert.
- ◇ Der Straßenbelag oder die Beschaffenheit einer Straße sind nicht von Bedeutung. Sie werden implizit durch die Verwendung verschiedener Trainingsgebiete modelliert.
- ◇ Das Straßenklassenbild kann als zusätzlicher „Kanal“ für die Linienextraktion verwendet werden. Hierbei sind die Eigenschaften der Straßen sehr gut bekannt, da Straßen hier stets helle Linien vor einheitlich dunklem Hintergrund sind.

Die Straßenextraktion, die im Rahmen der vorgelegten Arbeit entwickelt wurde, baut auf (WIEDEMANN 2002) auf. Ausführliche Untersuchungen im Vorfeld der eigentlichen Arbeit zeigten Schwächen auf, die sich zu großen Teilen mit den in (WIEDEMANN 2002) aufgezählten decken. Die größten Schwächen bei der Nutzung des Verfahrens von Wiedemann, für multispektrale höchstauflösende Satellitenbilddaten sind:

- ◇ Schwache Ausnutzung von Multispektralinformation
- ◇ Gemeinsame Extraktion von hellen und dunklen Straßen problematisch
- ◇ Keine Verifikation von Verbindungshypothesen auf Grundlage der Bilddaten
- ◇ Anzahl der einzustellenden Parameter und Abhängigkeit der Ergebnisse von kleinen Parameteränderungen zu hoch
- ◇ Interne Bewertung unbefriedigend

Bei der Entwicklung der Ansätze für die vorgelegte Arbeit wurde darauf geachtet, diese Schwächen möglichst zu beseitigen und gleichzeitig die Stärken zu übernehmen. Für die Nutzung von Multispektralinformation wurde der Fuzzy-Klassifikationsansatz entwickelt, der für die weitere Verarbeitung das Straßenklassenbild zur Verfügung stellt. Die gemeinsame Extraktion heller und dunkler Straßen wird erreicht, indem beide Arten von Straßen in Form von Trainingsgebieten verwendet werden. Eine Linienextraktion aus dem Straßenklassenbild berücksichtigt daraufhin ohne spezielle Parameteranpassungen sowohl helle als auch dunkle Straßen. Für die Verifikation von Verbindungshypothesen wurde ein Ziplock-Snake-basiertes Verfahren entwickelt, das sowohl die spektralen als auch die geometrischen Eigenschaften einer möglichen Verbindung anhand der Bilddaten überprüft. Die Zahl der notwendigen Parameter wurde für die Bewertung von Straßenhypothesen auf drei reduziert. Deren Einstellung ist jedoch nach wie vor problematisch. Vor allem der Parameter für die Länge einer Straßenhypothese zieht in besiedelten Gebieten selbst bei kleinen Änderungen z.T. erhebliche Auswirkungen auf das Ergebnis nach sich. Die interne Bewertung der Extraktionsergebnisse erfolgt in der vorliegenden Arbeit, sowohl für die extrahierten Linien als auch für die eingefügten Verbindungen, anhand radiometrischer und geometrischer Kriterien und resultiert somit in einer zumindest z.T. verlässlichen Bewertung der erzielten Ergebnisse.

Die im Rahmen der vorgelegten Arbeit durchgeführten Experimente zeichnen sich durch eine hohe Zuverlässigkeit der Ergebnisse, d.h. große Werte für die Korrektheit, aus. Vor allem durch die Nutzung der spektralen Information bei der Bewertung von Straßenhypothesen konnte die Zahl von Fehlextraktionen deutlich reduziert werden. Diese Vorgehensweise zeigt lediglich Schwächen für Gebiete in denen Straßen z.T. aus Materialien gebaut sind, die sich auch in der Umgebung der Straßen wiederfinden. Dort liegende Flächen, die eine ähnliche spektrale Signatur wie die Straßen besitzen, erhalten einen hohen Zugehörigkeitswert. Das führt dazu, dass Linien, z.B. im Rahmen der Verifikation von Verbindungshypothesen, eine gute Bewertung erhalten können. Eine mögliche Lösung für dieses Problem ist die Einführung von Formparametern im Rahmen des Klassifikationsansatzes: Zusammenhängende Gebiete müssen sowohl eine homogene spektrale Signatur besitzen als auch langgezogen sein, um als Straße klassifiziert zu werden.

Die Experimente zeigen insgesamt, dass der Ansatz für die offene Landschaft sehr gute Ergebnisse liefert. In besiedelten Bereichen sind die Ergebnisse durch die starke Texturierung dagegen in der Regel unbefriedigend und bestätigen damit die vorgenommene Beschränkung des Einsatzgebietes des Ansatzes auf die offene Landschaft. Für Waldgebiete können mit dem vorgestellten Verfahren z.T. zufriedenstellende Ergebnisse erzielt werden. Dies gilt dann, wenn zumindest Teile der Straße sichtbar sind und eine spektrale Signatur besitzen, die anderen Teilen des Straßennetzes entsprechen. Die abgeschatteten oder verdeckten Bereiche lassen sich überbrücken, wenn sie sich nicht isoliert im Bild oder am Bildrand befinden, sondern als Lücke im Netzwerk identifiziert werden können.

### 5.5.2 Hochaufgelöste Satellitenbilddaten

Die Eignung von (WIEDEMANN 2002) für die Extraktion von Straßen aus Bilddaten des IRS-1C/D Satelliten mit einer Auflösung von etwa 5 m wurde in umfangreichen Experimenten untersucht (JOST 2003). Die Ergebnisse zeigen, dass die Ansätze für Gebiete, in denen sich Straßen durch guten Kontrast von der Umgebung unterscheiden, und wenn die Auswertung auf die größeren Straßen beschränkt wird, zufriedenstellende Ergebnisse liefern. Die in Abschnitt 5.5.1 genannten Schwächen von (WIEDEMANN 2002) gelten weitestgehend auch für die Straßenextraktion aus Satellitenbilddaten hoher Auflösung. Hier ist allerdings die Nutzung von spektraler Information nicht möglich. Der wesentliche Grund ist die um den Faktor 4 geringere Auflösung in den Farbkanälen. Damit liegt die Pixelgröße weit oberhalb der zu erwartenden Straßenbreite. Durch Mischung unterschiedlicher spektraler Signaturen (Mischpixel) kann keine eindeutige Signatur für Straßen festgelegt werden. Somit ist eine Multispektral-Klassifikation nicht sinnvoll. Zudem ist das in Abschnitt 4.3.1 vorgeschlagene Verfahren zur automatischen Erzeugung von Trainingsgebieten, das auf parallelen Kanten basiert, wegen der geringen Auflösung nicht verwendbar.

Die angesprochene hohe Zahl an Parametern für die Extraktion sollte für die rein geometrische Bewertung von Straßenhypothesen beibehalten werden, um ein Höchstmaß an Zuverlässigkeit bei der Bewertung zu erhalten. Eine gemeinsame Extraktion heller und dunkler Straßen ist prinzipiell möglich. Sie erscheint jedoch wegen der schon (WIEDEMANN 2002) angesprochenen Anfälligkeit gegenüber Fehlextraktionen durch die Extraktion deutlich mehr linearer Strukturen, die keine Straßen darstellen, als unpraktikabel. Die interne Bewertung erfolgt anhand der für die Bewertung der Straßenhypothesen genutzten Parameter und erlaubt somit nur eine schwache Aussage über die Zuverlässigkeit von Straßenstücken. Eine Verifikation von Verbindungshypothesen kann mit dem in Abschnitt 4.4.1 vorgestellten Verfahren erfolgen, wobei jedoch besser nur Linieninformation verwendet werden sollte.

Die Ergebnisse der Experimente für hochaufgelöste Satellitenbilddaten zeigen, dass eine Aufteilung der offenen Landschaft in die Kontextgebiete *landwirtschaftlich genutzt*, *Wüste* und *Gebirge* sinnvoll ist. Der wesentliche Grund ist die gute Eignung des vorhandenen Ansatzes von WIEDEMANN (2002) für Wüste und Gebirge, wodurch für diese Kontextgebiete Neuentwicklungen nicht notwendig wurden. Auf der anderen Seite zeigten die Voruntersuchungen die absolut unbefriedigende Eignung des Verfahrens für kleinräumige landwirtschaftlich genutzte Gebiete. Durch die in Abschnitt 4.4.1 vorgeschlagene Vorgehensweise konnten die Ergebnisse in diesem Bereich deutlich verbessert werden. Das gilt besonders für kleinere Straßen, die im Bild nicht als Linie, sondern als Folge von Feldgrenzen abgebildet sind. Durch die benötigten Zufahrten zu den Nutzflächen gibt es in diesen Gebieten jedoch meist etliche kleine Straßen und Wege. Zudem sind Felder z.T. sehr schmal. All dies führt dazu, dass die Ergebnisse bezüglich der Korrektheit zumindest bei den für die Experimente verwendeten eher weichen Parametern für einen praktischen Einsatz inakzeptabel sind. Bei strenger Einhaltung der in Abschnitt 4.2 vorgeschlagenen Strategie sollten demnach für die Auswertung dieser Gebiete Bilddaten höherer Auflösung verwendet werden. Liegen jedoch keine höchstauflösten Satellitenbilddaten vor oder ist für kleinere, begrenzte Gebiete eine Beschaffung solcher Daten unwirtschaftlich, so stellt das neu entwickelte Verfahren bei Verwendung härterer Parameter eine Option dar. Darüber hinaus bietet es eine viel versprechende Grundlage für weitere Entwicklungen.

## 6 Zusammenfassung und Ausblick

### Zusammenfassung

Die vorgelegte Arbeit stellt ein Verfahren für die Extraktion von Straßen in der offenen Landschaft in Südosteuropa und Nordafrika vor, das die Erfassung von Straßennetzen für große Gebiete unterstützt. Ein besonderes Augenmerk liegt auf der Nutzung von Satellitenbilddaten unterschiedlicher Auflösung, um eine Neuerfassung des Straßennetzes für ganze Länder mit einem ausgewogenen Verhältnis zwischen erzielbarer Genauigkeit und Wirtschaftlichkeit durchführen zu können. Der Einsatz bzw. die Beschaffung der Satellitenbilddaten richtet sich bei dem vorgeschlagenen Verfahren nach der Detaillierung der Landschaft und damit des Straßennetzes in einer Region: Je dichter das Straßennetz ist, desto höher sollte die Auflösung der für die Extraktion verwendeten Bilddaten sein. Dementsprechend sind die Ansätze zur Straßenextraktion bei dem vorgeschlagenen Verfahren in zwei Teile unterteilt: Die Extraktion von Straßen aus multispektralen Satellitenbilddaten höchster Auflösung und aus hochaufgelösten Satellitenbilddaten.

Bei Satellitenbilddaten höchster Auflösung wird die spektrale Information mit Linienextraktion kombiniert und führt zur Generierung von Straßenhypothesen. Die Nutzung der spektralen Information erfolgt mittels eines automatischen (Fuzzy-)Klassifikationsansatzes mit dem Ziel, für jedes Bildelement den Zugehörigkeitswert zur Klasse *Straße* zu ermitteln. Dies führt zum Straßenklassenbild. Die spektralen Signaturen der im Bild auftretenden Straßen werden, was eine der zentralen Neuerungen der Arbeit darstellt, durch die automatische Generierung von Trainingsgebieten auf Grundlage paralleler Kanten ermittelt. Der Klassifikationsansatz bietet die Möglichkeit, neben den spektralen Eigenschaften von Straßen zusätzliche Bedingungen, wie z.B. den Abstand eines Trainingsgebiets vom betrachteten Pixel, zu nutzen. Die Grundlage des Straßennetzes bilden Straßenhypothesen, die in Form von Linienstücken extrahiert werden. Die Verifikation der Straßenhypothesen erfolgt durch Bewertung mit geometrischen (Länge und Breite der Linie) und radiometrischen (mittlerer Zugehörigkeitswert der Linie zur Klasse *Straße*) Kriterien. Aus den verifizierten Straßenhypothesen wird ein topologisches Netzwerk aufgebaut. Für die Überbrückung von größeren Lücken wird im Rahmen der globalen Gruppierung, und das ist eine weitere bedeutende Neuerung der vorgelegten Arbeit, ein auf Ziplock-Snakes basierendes Verfahren verwendet. Dieses optimiert den Verlauf einer neu eingeführten Verbindung und überprüft ihn auf Plausibilität auf Grundlage des Straßenklassenbildes.

Für hochaufgelöste Satellitenbilddaten wird ein dreigeteilter Ansatz verwendet. Die Entscheidung, welcher Ansatz verwendet wird, hängt vom Kontextgebiet *landwirtschaftlich genutzt*, *Wüste* oder *Gebirge* ab. Für Wüste und Gebirge wird in der vorgelegten Arbeit der Ansatz von WIEDEMANN (2002) verwendet. Der Unterschied zwischen den beiden Kontextgebieten besteht lediglich in der Wahl des Bewertungsparameters für die maximale Krümmung im Verlauf einer Straße. Dieser wird für Gebirge, in denen sich Straßen oft sehr stark an die z.T. sehr bewegte Topographie anpassen, freigegeben und liegt für Wüste innerhalb gewisser Grenzen. Für landwirtschaftlich genutzte Gebiete, in denen Straßen häufig nur indirekt anhand von Feldgrenzen wahrgenommen werden, wurde ein Gruppierungsansatz entwickelt, der eine Neuerung der vorgestellten Arbeit bildet. Paare von Linien- und Kantenstücken, d.h. lineare Strukturen, werden auf Kollinearität überprüft und gegebenenfalls durch eine Ziplock-Snake verbunden. Die so entstandenen Straßenabschnitte werden zu einem topologischen Netzwerk verknüpft.

Anhand ausführlicher experimenteller Untersuchungen wird die Leistungsfähigkeit aber auch Schwächen des Verfahrens aufgezeigt. Hierfür werden Daten aus Gebieten unterschiedlicher Detaillierung und aus allen Kontextgebieten verwendet. Die Güte der erzielten Ergebnisse wird anhand von Referenzdaten bewertet. Während die Ergebnisse für die höchst aufgelösten Daten vor allem durch die Nutzung der multispektralen Information durchwegs als praktisch verwendbar oder zumindest vielversprechend bewertet werden können, müssen die Ergebnisse für die hoch aufgelösten Daten differenzierter bewertet werden. Für Wüsten und Gebirge sind die Ergebnisse als akzeptabel anzusehen. Für landwirtschaftlich genutzte Gebiete stellt der vorgestellte Gruppierungsansatz zwar eine große Verbesserung dar, allerdings sind die Ergebnisse in der jetzigen Form praktisch nicht brauchbar. In diesen Gebieten sollten für eine Automatisierung höchst aufgelöste Daten verwendet werden.

## Ausblick

Das vorgestellte Verfahren wurde für die automatische Straßenextraktion konzipiert. Bei einer praktischen Nutzung erscheint es sinnvoll, dass vor der automatischen Extraktion verschiedene Arbeitsschritte vom Bearbeiter durchgeführt werden. Dazu gehören die grundlegende Entscheidung, welche Art von Daten verwendet werden sollen, die vor allem durch manuelle Interpretation von Übersichtskarten erfolgt, und die Aufteilung in Kontextgebiete. Letztere könnte für Gebiete, in denen Satellitenbilddaten bereits vorliegen, mit Hilfe der Bilddaten (Vegetationsklassifikation) und eines DGM (Rauigkeit) bis zu einem gewissen Grad automatisiert werden.

Die vorgestellten Ergebnisse der automatischen Straßenextraktion zeigen, dass eine Nachbearbeitung für die Bereitstellung von zuverlässigen und vollständigen Resultaten absolut notwendig ist. Hierfür ist es wichtig, dass die Ergebnisse mit einer möglichst zuverlässigen inneren Bewertung versehen werden. Hauptdefizit des vorgestellten Verfahrens für die praktische Nutzung ist das Fehlen der für die interaktive Weiterverarbeitung notwendigen Umgebung und Funktionalität. Aufgrund der hohen Komplexität einer effizienten Nachbearbeitung der Ergebnisse erscheint es vorteilhaft, für diese Aufgabe auf ein bestehendes System zurückzugreifen. Denkbar sind hierfür Systeme aus dem Bereich der Fernerkundung, die eine Vektordatenverarbeitung ermöglichen, oder aber ein GIS mit einer Verbindung zu einem Fernerkundungssystem. Insgesamt sollte eine optimale Nachbearbeitung die Charakteristiken und vor allem die interne Bewertung der Ergebnisse berücksichtigen. Letztere könnte genutzt werden, um den Operateur gezielt zu Problemfällen zu führen, wohingegen als hochgradig vertrauenswürdig eingestufte Bereiche nicht mehr überprüft werden.

Die Charakteristik der Ergebnisse könnte für die Nachbearbeitung hilfreich sein, indem z.B. topologisch komplexe Bereiche, als häufig fehlerhaft und schlecht zu verbessernd von vornherein für eine manuelle Neuerfassung vorgesehen werden. Im Rahmen der automatischen Generierung von Trainingsgebieten wäre eine interaktive Komponente sinnvoll, um fehlerhafte Trainingsgebiete vor der eigentlichen Klassifikation zu eliminieren oder zusätzliche zu definieren. Als weitergehende Vorgehensweise könnten für schwierige Bereiche automatisch erzielte Ergebnisse auch dazu genutzt werden, einen Operateur während der halbautomatischen Straßenextraktion zu unterstützen, indem z.B. nur sehr wenige Punkte digitalisiert und die Bereiche dazwischen mit den automatisch erzeugten Ergebnissen aufgefüllt werden.

Eine Erfolg versprechende Integration des Ansatzes für höchst aufgelöste Satellitenbilddaten in eine praxisrelevante Lösung erscheint für das System zur Qualitätskontrolle von digitalen Straßendaten

(GERKE und BUSCH 2005) möglich. In diesem könnte der bisher verwendete Ansatz von WIEDEMANN (2002) ergänzt oder ersetzt werden. Bestehende Straßendaten könnten entweder durch einen Vergleich mit den extrahierten Straßen oder durch direkte Bewertung mit Informationen aus dem Straßenklassenbild verifiziert werden.

Neben der Erweiterung zu einem praxistauglichen Verfahren bieten auch die Ansätze selbst Potential für Weiterentwicklungen. Hier ist vor allem der Klassifikationsansatz zu nennen, der bisher die Form von Regionen mit hoher Zugehörigkeit zur Straßenklasse nicht berücksichtigt. Mit der Berücksichtigung von Langgestrecktheit könnten flächenhafte Gebiete mit einer spektralen Signatur, die der von Straßen ähnlich ist, wie z.B. Felder, herausgefiltert werden. Ein weiterer Punkt ist die Modellierung von Kreuzungen, die im Rahmen der vorgelegten Arbeit mit den in (WIEDEMANN 2002) vorgestellten Ansätzen erfolgt. Die verwendete Modellierung ist für Satellitenbilddaten hoher Auflösung zufriedenstellend. Sie ist jedoch für höchstauflösende Daten in Form einer detaillierten Beschreibung der Topologie für breite Straßen u.U. sogar auf Fahrspurebene erweiterbar. So könnten im Kreuzungsbereich nicht nur die extrahierten Linien betrachtet, sondern wo sichtbar zusätzlich die Straßenränder in die Modellierung einbezogen werden.

## Literatur

- ALBERTZ, J. (2001): *Einführung in die Fernerkundung*, Wissenschaftliche Buchgesellschaft, Darmstadt.
- AMINI, J., LUCAS, C., SARADJIAN, M., AZIZI, A. und SADEGHIAN, S. (2002): Fuzzy Logic System for Road Identification Using IKONOS Images, *Photogrammetric Record* **17**(99): 493–503.
- AUCLAIR-FORTIER, M.-F., ZIOU, D., ARMENAKIS, C. und WANG, S. (2000): Survey of Work on Road Extraction in Aerial and Satellite Images, *Technical Report 247*, Département de mathématiques et d'informatique, Université de Sherbrooke.
- BACHER, U. und MAYER, H. (2003): Fuzzy-Classification and Ziplock Snakes for Road Extraction from IKONOS Images, *ISPRS / EARSeL Joint Workshop on High Resolution Mapping from Space*.
- BACHER, U. und MAYER, H. (2004): Automatic Road Extraction from IRS Satellite Images in Agricultural and Desert Areas, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 1055–1060.
- BACHER, U. und MAYER, H. (2005): Automatic Road Extraction from Multispectral High Resolution Satellite Images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (36) 3/W24, 29–34.
- BÄHR, H.-P., QUINT, F. und STILLA, U. (1995): Modellbasierte Verfahren der Luftbildanalyse zur Kartenfortführung, *Zeitschrift für Photogrammetrie und Fernerkundung* **6/95**: 224–234.
- BALTSAVIAS, E. (2004): Object Extraction and Revision by Image Analysis Using Existing Geodata and Knowledge: Current Status and Steps Towards Operational Systems, *ISPRS Journal of Photogrammetry and Remote Sensing* **58**: 129–151.
- BAUMGARTNER, A. (2003): *Automatische Extraktion von Straßen aus digitalen Luftbildern*, Deutsche Geodätische Kommission (C) 564, München.
- BAUMGARTNER, A., STEGER, C., MAYER, H., ECKSTEIN, W. und EBNER, H. (1999): Automatic Road Extraction Based on Multi-Scale, Grouping, and Context, *Photogrammetric Engineering & Remote Sensing* **65**(7): 777–785.
- BRACHMAN, R. (1979): On the Epistemological Status of Semantic Networks, *Associative Networks*, Academic Press, New York, USA, 191–215.
- BROCKHAUS (Herausgeber) (1980): *Der Neue Brockhaus*, F.A. Brockhaus, Wiesbaden.
- BUSCH, A. (1996): A Common Framework for the Extraction of Lines and Edges, *International Archives of Photogrammetry and Remote Sensing*, Band (31) B3/III, 88–93.
- CAMPBELL, J. B. (2002): *Introduction to Remote Sensing*, Taylor & Francis, London.
- CANNY, J. (1986): A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **8**(6): 679–698.

- CLODE, S., KOOTSOOKOS, P. und ROTTENSTEINER, F. (2004): The Automatic Extraction of Roads from Lidar Data, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 231–236.
- DAL POZ, A., DO VALE, G. und ZANIN, I. (2004): Automated Road Segment Extraction by Grouping Road Objects, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 436–439.
- DAL POZ, A. und DO VALE, G. (2003): Dynamic Programming Approach for Semi-Automated Road Extraction from Medium- and High-Resolution Images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (34) 3/W8, 87–91.
- DIAL, G., GIBSON, L. und POULSEN, R. (2001): IKONOS Satellite Imagery and Its Use in Automated Road Extraction, *Automatic Extraction of Man-Made Objects from Aerial and Space Images (III)*, Balkema Publishers, Lisse, Niederlande, 357–367.
- DIJKSTRA, E. (1959): A Note on Two Problems in Connexion with Graphs, *Numerische Mathematik* **1**: 269–271.
- DOUCETTE, P., AGOURIS, P., STEFANIDIS, A. und MUSAVI, M. (2001): Self-Organized Clustering for Road Extraction in Classified Imagery, *ISPRS Journal of Photogrammetry and Remote Sensing* **55**: 347–358.
- DOUCETTE, P., AGOURIS, P. und STEFANIDIS, A. (2004): Automated Road Extraction from High Resolution Multispectral Imagery, *Photogrammetric Engineering & Remote Sensing* **70**(12): 1405–1416.
- FISCHLER, M. (1994): The Perception of Linear Structure: A Generic Linker, *Image Understanding Workshop*, 1565–1579.
- FISCHLER, M., TENENBAUM, J. und WOLF, H. (1981): Detection of Roads and Linear Structures in Low-Resolution Aerial Imagery Using a Multisource Knowledge Integration Technique, *Computer Graphics and Image Processing* **15**: 201–223.
- FÖRSTNER, W. (1996): 10 Pros and Cons Against Performance Characterization of Vision Algorithms, *European Conference on Computer Vision, Workshop on Performance Characteristics of Vision Algorithms*, 13–29.
- FUA, P. und LECLERC, Y. (1990): Model Driven Edge Detection, *Machine Vision and Applications* **3**: 45–56.
- GEMAN, D. und JEDYNAK, B. (1996): An Active Testing Model for Tracking Roads in Satellite Images, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **18**(1): 1–12.
- GERKE, M., BUTENUTH, M., HEIPKE, C. und WILLRICH, F. (2004): Graph-Supported Verification of Road Databases, *ISPRS Journal of Photogrammetry and Remote Sensing* **58**: 152–165.
- GERKE, M. und BUSCH, A. (2005): Verification of a Digital Road Database Using Ikonos Imagery, *ISPRS Hannover Workshop 2005 – High-Resolution Earth Imaging for Geospatial Information*.
- GIBSON, L. (2003): Finding Road Networks in IKONOS Satellite Imagery, *ASPRS 2003 Conference*, Anchorage, Alaska.

- GRÜN, A. und LI, H. (1997): Semi-Automatic Linear Feature Extraction by Dynamic Programming and LSB-Snakes, *Photogrammetric Engineering & Remote Sensing* **63**(8): 985–995.
- HEIPKE, C., MAYER, H. und WIEDEMANN, C. (1998): External Evaluation of Automatically Extracted Road Axes, *Photogrammetrie – Fernerkundung – Geoinformation* **2/98**: 81–94.
- HELLER, A., FISCHLER, M., BOLLES, R., CONNOLLY, C., WILSON, R. und PEARSON, J. (1998): An Integrated Feasibility Demonstration for Automatic Population of Geospatial Databases, *Image Understanding Workshop*.
- HINZ, S. (2003): *Automatische Extraktion urbaner Straßennetze aus Luftbildern*, Deutsche Geodätische Kommission (C) 580, München.
- HINZ, S. (2004): Automatic Road Extraction in Urban Scenes and Beyond, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 349–355.
- HINZ, S. und BAUMGARTNER, A. (2003): Automatic Extraction of Urban Road Networks from Multi-View Aerial Imagery, *ISPRS Journal of Photogrammetry and Remote Sensing* **58**: 83–98.
- HINZ, S. und WIEDEMANN, C. (2004): Increasing Efficiency of Road Extraction by Self-Diagnosis, *Photogrammetric Engineering & Remote Sensing* **70**: 1457–1466.
- HOFFMANN, A. (2001): *Neue Ansätze zur Auswertung und Klassifizierung von sehr hochauflösenden Daten – Methoden der Segmentierung, der hierarchischen Klassifizierung und der per-Parcel-Methode mit Daten der digitalen Kamera HRSC-A und ihre Anwendbarkeit für die Aktualisierung topographischer Karten*, Dissertation, Humboldt-Universität zu Berlin.
- HU, X. und TAO, C. (2004): Automatic Highway Extraction from High Resolution Imagery by an Energy Minimizing Based Perceptual Grouping Method, *GEOMATICA* **58**(1): 41–50.
- JOST, M. (2003): *Straßenextraktion aus IRS Satellitenbilddaten und ihre Bewertung*, Diplomarbeit, Institut für Photogrammetrie und Kartographie, Universität der Bundeswehr München.
- KASS, M., WITKIN, A. und TERZOPOULOS, D. (1988): Snakes: Active Contour Models, *International Journal of Computer Vision* **1**(4): 321–331.
- KEATON, T. und BROKISH, J. (2002): A Level Set Method for the Extraction of Roads from Multispectral Imagery, *31st Applied Imagery Pattern Recognition Workshop (AIPR'02)*.
- KERSCHNER, M. (2001): Seamline Detection in Colour Orthoimage Mosaicking by Use of Twin Snakes, *ISPRS Journal of Photogrammetry and Remote Sensing* **56**(1): 53–64.
- KERSCHNER, M. (2003): *Snakes für Aufgaben der digitalen Photogrammetrie und Topographie*, Dissertation, Institut für Photogrammetrie und Fernerkundung der Technischen Universität Wien.
- KLANG, D. (1998): Automatic Detection of Changes in Road Databases Using Satellite Imagery, *International Archives of Photogrammetry and Remote Sensing*, Band (32) 4/1, 293–298.
- KLAUSMANN, P., FRIES, S., WILLERSINN, D., STILLA, U. und THÖNNESSEN, U. (1999): Application-Oriented Assessment of Computer Vision Algorithms, in B. JÄHNE (Herausgeber), *Handbook of Computer Vision and Applications. Band 3. Systems and Applications*, Academic Press, San Diego, 133–152.

- KRAMER, H. (2002): *Observation of the Earth and Its Environment – Survey of Missions and Sensors*, Springer-Verlag, Berlin.
- LACOSTE, C., DESCOMBES, X. und ZERUBIA, J. (2005): Point Processes for Unsupervised Network Extraction in Remote Sensing, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **27**(10): 1568–1579.
- LAPTEV, I. (1997): *Road Extraction Based on Snakes and Sophisticated Line Extraction*, Master Thesis, Computational Vision and Active Perception Lab (CVAP), Royal Institute of Technology, Stockholm, Schweden.
- LAPTEV, I., MAYER, H., LINDBERG, T., ECKSTEIN, W., STEGER, C. und BAUMGARTNER, A. (2000): Automatic Extraction of Roads from Aerial Images Based on Scale-Space and Snakes, *Machine Vision and Applications* **12**(1): 22–31.
- LEUKERT, K. (2005): *Übertragbarkeit der objektbasierten Analyse bei der Gewinnung von GIS-Daten aus Satellitenbildern mittlerer Auflösung*, Dissertation, Universität der Bundeswehr München.
- LINDBERG, T. (1994): *Scale-Space Theory in Computer Vision*, Kluwer Academic Publishers, Boston, USA.
- MALLAT, S. (1989): A Theory for Multiresolution Signal Decomposition: the Wavelet Representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **11**(7): 674–693.
- MARR, D. (1982): *Vision*, Freeman and Company, New York, USA.
- MAYER, H. (1998): *Automatische Objektextraktion aus digitalen Luftbildern*, Deutsche Geodätische Kommission (C) 494, München.
- MAYER, H. (2004): Object Extraction for Digital Photogrammetric Workstations, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B2, 414–422.
- MAYER, H., LAPTEV, I., BAUMGARTNER, A. und STEGER, C. (1997): Automatic Road Extraction Based on Multi-Scale Modeling, Context, and Snakes, *International Archives of Photogrammetry and Remote Sensing*, Band (32) 3-2W3, 106–113.
- MAYER, H., LAPTEV, I. und BAUMGARTNER, A. (1998): Multi-Scale and Snakes for Automatic Road Extraction, *Fifth European Conference on Computer Vision*, Band II, 720–733.
- MCGLONE, J., BETHEL, J. und MIKHAIL, E. (Herausgeber) (2004): *Manual of Photogrammetry*, American Society of Photogrammetry and Remote Sensing, Bethesda, USA.
- MEIER, S. (2000): Zur Qualität snakes-approximierter Höhenprofile mit Diskontinuitäten, *Photogrammetrie – Fernerkundung – Geoinformation* **6/00**: 399–409.
- MENA, J. (2003): State of the Art on Automatic Road Extraction for GIS Update: A Novel Classification, *Pattern Recognition Letters* **24**: 3037–3058.
- MENA, J. und MALPICA, J. (2005): An Automatic Method for Road Extraction in Rural and Semi-Urban Areas Starting from High Resolution Satellite Imagery, *Pattern Recognition Letters* **26**: 1201–1220.

- MOHAMMADZADEH, A., TAVAKOLI, A. und ZOEJ, M. (2004): Automatic Linear Feature Extraction of Iranian Roads from High Resolution Multi-Spectral Satellite Imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 764–767.
- NEUENSCHWANDER, W. (1996): *Elastic Deformable Contour and Surface Models for 2-D and 3-D Image Segmentation*, Hartung-Gorre Verlag, Konstanz.
- NEUENSCHWANDER, W., FUA, P., SZÉKELY, G. und KÜBLER, O. (1995): From Ziplock Snakes to Velcro<sup>TM</sup> Surfaces, *Automatic Extraction of Man-Made Objects from Aerial and Space Images*, Birkhäuser Verlag, Basel, Schweiz, 105–114.
- NISCHWITZ, A. und HABERÄCKER, P. (2004): *Masterkurs Computergrafik und Bildverarbeitung*, Vieweg Verlag, Wiesbaden.
- PÉTERI, R. und RANCHIN, T. (2003a): Multiresolution Snakes for Urban Road Extraction from Ikonos and Quickbird, *EARSeL Symposium*, Milpress, Rotterdam, Niederlande, 69–76.
- PÉTERI, R. und RANCHIN, T. (2003b): Urban Street Mapping Using Quickbird and Ikonos Images, *International Geoscience and Remote Sensing Symposium*, Band III, 1721–1723.
- PÉTERI, R., COULOIGNER, I. und RANCHIN, T. (2004): Quantitatively Assessing Road Extracted from High-Resolution Imagery, *Photogrammetric Engineering & Remote Sensing* **70**(12): 1449–1456.
- QUACKENBUSH, L. (2004): A Review of Techniques for Extracting Linear Features from Imagery, *Photogrammetric Engineering & Remote Sensing* **70**(12): 1383–1392.
- RUSKONÉ, R. (1996): *Road Network Automatic Extraction by Local Context Interpretation: Application to the Production of Cartographic Data*, Thèse de Doctorat, Université de Marne-La-Vallée, Noisy-le-Grand, Frankreich.
- RUSKONÉ, R., AIRAULT, S. und JAMET, O. (1994): A Road Extraction System Using the Connectivity Properties of the Network, *Zeitschrift für Photogrammetrie und Fernerkundung* **5/94**: 174–180.
- SESTER, M. (1995): *Lernen struktureller Modelle für die Bildanalyse*, Deutsche Geodätische Kommission (C) 441, München.
- SHI, W. und ZHU, C. (2002): The Line Segment Match Method for Extracting Road Network from High-Resolution Satellite Images, *IEEE Transactions on Geoscience and Remote Sensing* **40**(2): 511–514.
- SOMMER, G. (1992): Wissensverarbeitung in der Bildanalyse – Teil I, II, III, *bild&ton* **45**(5/6, 7/8, 11/12): 103–110, 151–156, 314–321.
- SONG, M. und CIVCO, D. (2004): Road Extraction Using SVM and Image Segmentation, *Photogrammetric Engineering & Remote Sensing* **70**(12): 1365–1371.
- SÖRGE, U. (2003): *Iterative Verfahren zur Detektion und Rekonstruktion von Gebäuden in SAR- und InSAR-Daten*, Dissertation, Universität Hannover.

- STEGER, C. (1998a): An Unbiased Extractor of Curvilinear Structures, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **20**: 113–125.
- STEGER, C. (1998b): *Unbiased Extraction of Curvilinear Structures from 2D and 3D Images*, Herbert Utz Verlag, München.
- STEGER, C., MAYER, H. und RADIG, B. (1997): The Role of Grouping for Road Extraction, *Automatic Extraction of Man-Made Objects from Aerial and Space Images (II)*, Birkhäuser Verlag, Basel, Schweiz, 245–256.
- STILLA, U. (1995): Map-Aided Structural Analysis of Aerial Images, *ISPRS Journal of Photogrammetry and Remote Sensing* **50**: 3–10.
- STILLA, U., GEIBEL, R., QUINT, F. und STIES, M. (1998): Analyse von Luft und Satellitenbildern zur automatischen Ermittlung der Bodenversiegelung städtischer Siedlungsbereiche (III), *FIM Bericht 284*, Forschungsinstitut für Informationsverarbeitung und Mustererkennung, Ettlingen.
- STILLA, U. und JURKIEWICZ, K. (1996): Structural 3D-Analysis of Urban Scenes from Aerial Images, *International Archives of Photogrammetry and Remote Sensing*, Band (31) B3/III, 832–838.
- STOICA, R., DESCOMBES, X. und ZERUBIA, J. (2004): A Gibbs Point Process for Road Extraction from Remotely Sensed Images, *International Journal of Computer Vision* **57**(2): 121–136.
- SUETENS, P., FUA, P. und HANSON, A. (1992): Computational Strategies for Object Recognition, *ACM Computing Surveys* **24**(1): 5–60.
- TÖNJES, R. (1996): Knowledge Based Modelling of Landscapes, *International Archives of Photogrammetry and Remote Sensing*, Band (31) B3/III, 868–873.
- ÜNSALAN, C. und BOYER, K. (2005): A System to Detect Houses and Residential Street Networks in Multispectral Satellite Images, *Computer Vision and Image Understanding* **98**: 423–461.
- WESSEL, B. (2004): Road Network Extraction from SAR Imagery Supported by Context Information, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 360–365.
- WIEDEMANN, C. (1999): Automatic Completion of Road Networks, *ISPRS Joint Workshop 'Sensors and Mapping from Space 1999'*, Hannover.
- WIEDEMANN, C. (2002): *Extraktion von Straßennetzen aus optischen Satellitenbilddaten*, Deutsche Geodätische Kommission (C) 551, München.
- WIEDEMANN, C., HEIPKE, C., MAYER, H. und HINZ, S. (1998): Automatic Extraction and Evaluation of Road Networks from MOMS-2P Imagery, *International Archives of Photogrammetry and Remote Sensing*, Band (30) 3/1, 285–291.
- WIEDEMANN, C. und EBNER, H. (2000): Automatic Completion and Evaluation of Road Networks, *International Archives of Photogrammetry and Remote Sensing*, Band (33) B3/2, 979–986.
- ZADEH, L. (1965): Fuzzy sets, *Information and Control* **8**: 338–353.
- ZADEH, L. (1989): Knowledge Representation in Fuzzy Logic, *IEEE Transactions on Knowledge and Data Engineering* **1**(1): 89–100.

- ZHANG, C. (2003): *Updating of Cartographic Road Databases by Image Analysis*, Dissertation, Institute of Geodesy and Photogrammetry, ETH, Zürich, Schweiz.
- ZHANG, C. (2004): Towards an Operational System for Automated Updating of Road Databases by Integration of Imagery and Geodata, *ISPRS Journal of Photogrammetry and Remote Sensing* **58**(3-4): 166–186.
- ZHANG, Q. und COULOIGNER, I. (2004a): A Framework for Road Change Detection and Map Updating, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B2, 729–734.
- ZHANG, Q. und COULOIGNER, I. (2004b): A Wavelet Approach to Road Extraction from High Spatial Resolution Remotely-Sensed Imagery, *GEOMATICA* **58**(1): 33–39.
- ZHAO, H., KUMAGAI, J., NAKAGAWA, M. und SHIBASAKI, R. (2002): Semi-Automatic Road Extraction from High-Resolution Satellite Image, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (34) 3A, 406–411.
- ZOEJ, M. und MOKHTARZADE, M. (2004): Road Detection from High Resolution Satellite Images Using Artificial Neural Networks, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Band (35) B3, 387–392.

## Dank

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Photogrammetrie und Kartographie der Universität der Bundeswehr München.

Meinen beiden Berichterstatlern Prof. Dr.-Ing. Helmut Mayer und Prof. Dr.-Ing. Uwe Stilla möchte ich für die gute Unterstützung danken. Zahlreiche fruchtbare Diskussionen und Anregungen haben wesentlich zum Gelingen der Arbeit beigetragen. Prof. Dr.-Ing. Egon Dorrer danke ich für die Übernahme des Vorsitzes des Promotionsverfahrens bis zu seiner Erkrankung kurz vor Abschluss des Verfahrens und die stets anregenden Gespräche. Prof. Dr.-Ing. Friedrich S. Kröll danke ich für die spontane Übernahme des Vorsitzes des Promotionsverfahrens kurz vor dessen Abschluss.

Mein Dank geht auch an das Amt für Geoinformationswesen der Bundeswehr (AGeoBw), welches das Projekt „Wissenschaftliche Begleitung eines automatischen Extraktionsverfahrens zur Erfassung bzw. Fortführung von Verkehrsnetzdaten in objektstrukturierten MilGeo-Datenbasen aus höchstaflösenden Satellitenaufnahmen“ gefördert hat. Im Rahmen dieses Projektes konnten die vorgestellten Ansätze entwickelt und praktische Experimente mit den zur Verfügung gestellten Satellitenbilddaten durchgeführt werden. Die Ergebnisse des Projektes machen einen wesentlichen Teil der Dissertation aus.

Besonderer Dank geht an alle Korrekturleser und Kollegen, die mich unterstützt haben. Weiter danke ich allen meinen Kollegen am Institut für Photogrammetrie und Kartographie und der AGIS für die angenehme Arbeitsatmosphäre und die gute Zusammenarbeit.

Zu guter Letzt gilt mein besonders herzlicher Dank meinen Eltern und meiner Freundin Petra für die Unterstützung und Motivation während der Ausarbeitung und Fertigstellung meiner Dissertation.

# Lebenslauf

Uwe Bacher

geboren am 15. August 1969 in Heidenheim/Brenz

## Ausbildung

1976 - 1980    Grundschule in Heidenheim bzw. Steinheim am Albuch

1980 - 1989    Werkgymnasium in Heidenheim

1989 - 1990    Wehrdienst in Ellwangen/Jagst

1990 - 1996    Studium der Geodäsie an der Universität Karlsruhe (TH)  
Abschluss: Diplom Vermessungsingenieur

## Beruflicher Werdegang

08/96 - 11/99    Wissenschaftlicher Mitarbeiter am Institut für Photogrammetrie und  
Kartographie an der Universität der Bundeswehr München

12/99 - 04/02    Projektingenieur für Lokortungssysteme bei der Tiefenbach GmbH, Sprockhövel

06/02 - 10/05    Wissenschaftlicher Mitarbeiter am Institut für Photogrammetrie und  
Kartographie an der Universität der Bundeswehr München

seit 11/05        Supportingenieur bei der GEOSYSTEMS GmbH, Germering