

# ÄNDERUNGSANALYSE IN ZEITREIHEN HOCHAUFGELÖSTER SAR-SATELLITENBILDER

Zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS

von der Fakultät für

Bauingenieur-, Geo- und Umweltwissenschaften

des Karlsruher Instituts für Technologie (KIT)

genehmigte

DISSERTATION

von

M. Sc. Dipl.-Ing. (FH) Markus Boldt

aus Karlsruhe

Tag der mündlichen Prüfung: 01.12.2017

Referent: Prof. Dr.-Ing. Stefan Hinz

Koreferent: Prof. Dr.-Ing. Franz J. Meyer

Karlsruhe (2017)



---

## Kurzfassung

Die Detektion von Änderungen anhand fernerkundlicher Bilddaten beschreibt einen weit ausgedehnten Forschungsbereich mit vielen Verfahrensmethoden für unterschiedliche Anwendungen. Durch die rasche Verbesserung der Bildqualität im Hinblick auf die räumliche Auflösung im letzten Jahrzehnt eröffneten sich insbesondere für die Analyse urbaner, eng bebauter Räume neue Möglichkeiten. Mit Fokus auf die satellitengestützte Radarfernerkundung mit synthetischer Apertur (SAR) ist diese Entwicklung unter anderem den beiden deutschen Sensorsystemen TerraSAR-X und TanDEM-X zu verdanken, die in den Jahren 2007 und 2009 gestartet wurden und bis heute aktiv im Einsatz sind. SAR vereint im Vergleich zu Sensoren, die im sichtbaren Bereich des elektromagnetischen Spektrums operieren, multiple Vorteile. So ist SAR einerseits ein aktives Verfahren, das für die Aufzeichnung der Szene die eigene (elektromagnetische) Strahlungsquelle verwendet. Andererseits verfügen diese Strahlen über eine Wellenlänge, die die des sichtbaren Lichts um ein Vielfaches übersteigt. SAR ist in der Lage, unabhängig von der Tageszeit Bilddaten aufzuzeichnen und durch Wolken, Dunst und Nebel hindurch zu sehen. Dies macht SAR für sämtliche Anwendungen attraktiv, bei denen regelmäßige und zeitlich identische Aufnahmen notwendig sind (beispielsweise *Monitoring* beziehungsweise Überwachung und Änderungsdetektion im Allgemeinen).

Eine Änderungsdetektion vermittelt zunächst Informationen über den Ort und den Zeitpunkt der in den Bilddaten enthaltenen Änderungen. Oftmals ist diese eingeschränkte Auswertung nicht ausreichend, da der Typus oder die Klasse zur Charakterisierung der Änderungsursache auf diese Weise unerkannt bleibt. Ein Verfahren, das sowohl die einfache Detektion der Änderungen als auch eine weitergehende Untersuchung hinsichtlich der Änderungsklasse umfasst, wird in dieser Arbeit als Änderungsanalyse vorgestellt. Diese Analyse vereint zwei Hauptaspekte, die in Kombination ein hohes Maß an praktischer Relevanz bereitstellen. Den ersten Aspekt repräsentiert die Datengrundlage selbst, die sich ohne zusätzliche Referenzdaten lediglich aus einer Zeitreihe bestehend aus SAR-Amplitudenbildern zusammensetzt. Das zweite zentrale Merkmal der hier behandelten Änderungsanalyse ist durch die Verarbeitungsweise der Eingabedaten gegeben, die keinerlei detailliertes Fachwissen von Nutzerseite erfordert.

Die Methode enthält zwei zentrale Ausprägungen: Die Detektion von Änderungen sowie deren Kategorisierung und Klassifikation. Erstere erfolgt in abrupper Form, was bedeutet, dass als Eingabedaten Paare aus zeitlich aufeinander folgend aufgezeichneten Bildern verwendet werden. Aus diesen Bildpaaren werden Differenzbilder erzeugt, die mittels der unüberwachten Schwellwertmethode nach *Renyi* zu binären Änderungskarten verarbeitet werden. Die Anwendung der bi-temporalen Änderungsdetektion auf den hier primär betrachteten Zeitstapel (circa ein Jahr von November 2013 bis November 2014) aus TerraSAR-X Amplitudenbildern eröffnet die Möglichkeit zur Detektion von Bildbereichen, die sich entlang der Zeit sehr oft (hochfrequent) ändern (zum Beispiel Parkplätze oder Baustellen). Derartige Bereiche können durch sogenannte Hochaktivitätsobjekte charakterisiert werden.

Den zweiten wesentlichen Schritt der hier erörterten Vorgehensweise nimmt die kategorisierende und klassifizierende Beschreibung dieser Hochaktivitätsobjekte ein. Hierfür werden zunächst geeignete Merkmale für jedes dieser Objekte extrahiert. Entsprechend ihrer merkmalsorientierten Ausprägung erfolgt eine Gruppierung der Hochaktivitätsobjekte in Kategorien.

Für die an die Kategorisierung anschließende Klassifikation werden keine Trainingsdaten benötigt, weshalb sich die Frage nach einer möglichst optimalen Selektion passender Trainingsgebiete für sinnvolle und zielführende Klassen erübrigt. Das in dieser Arbeit eingeführte Verfahren dient vielmehr zur Unterstützung des Nutzers, wenn dessen erste Aufgabe darin besteht, für den jeweils vorliegenden Datensatz eine passende Klassenbeschreibung zur Charakterisierung von Änderungsgebieten abzuleiten.

Diese Ableitung wird in iterativer Weise durch Optimierung eines a-priori definierten Klassenkatalogs erreicht, der dem Kategorisierungsresultat gegenübergestellt wird. Diese Optimierung erfolgt mittels sukzessiver Bewertung von Kennzahlen nach jedem Iterationsschritt. Der Klassenkatalog ist optimiert, wenn die Kombination dieser Kennzahlen im Hinblick auf die vorliegenden Daten optimal ist. In diesem Zusammenhang können vorab falsch selektierte Klassen gelöscht werden, oder zu grob gewählte Klassen in feinere Einheiten aufgeteilt werden.

Der finale Schritt der Änderungsanalyse ist die Zuweisung (Klassifikation) der Änderungsobjekte zu dem durch das Verfahren ermittelten, optimierten Klassenkatalog. Um eine gute Anschaulichkeit und hohe Flexibilität in Anbetracht der Klassenbeschreibung zu gewährleisten, kommen Prinzipien der *Fuzzy*-Logik zum Einsatz.

**Stichwörter:** SAR, Zeitreihe, Änderungsdetektion, Änderungsanalyse, Kategorisierung, Klassifikation.



---

## Abstract

The detection of changes using remote sensing imagery represents a broad field of research with multiple methods for different applications. Especially for the analysis of densely built-up urban areas, the rapid enhancement of the image quality in the last decade established new opportunities. Focusing on spaceborne SAR remote sensing, this development can be primarily connected with the German sensor systems TerraSAR-X and TanDEM-X, which were launched in 2007 and in 2009 and are still operating. In contrast to sensors operating in the visible subset of the electromagnetic spectrum, SAR combines crucial benefits. On the one hand, it is an active sensing method, using its own source of (electromagnetic) radiation for scene acquisition. On the other hand, this radiation has a wavelength which is much longer than the wavelength of visible light. Consequently, SAR has the ability to acquire image data independent of the time of day and to look through clouds, dust and fog. That makes SAR attractive for all applications, where regular acquisitions of the same daytime are required (e.g. monitoring and change detection issues in general).

Such a change detection provides information on the location and moment of the changes contained in the images. Often, this two-dimensional information is not sufficient, since the type or class to model the cause of the changes remains unknown. In this work, a strategy for change analysis is presented which combines the detection and further investigations concerning the changes. This analysis unifies two main aspects, which in combination embody a high order of practical relevance, and therefore, a high potential for practical use. The first aspect is given by the dataset itself, which only comprises a time series consisting of SAR amplitude images. The second aspect is the way in which the input data is processed. Moreover, no expert knowledge is required for this step.

This is characterized by two essential points: The detection of changes and their categorization and classification. Change detection is accomplished in an abrupt manner. This means, that as input data, pairs of two successively acquired images are applied. From these image pairs, difference images are calculated, and binary change maps are created using the unsupervised thresholding method represented by Renyi's two-dimensional entropy. Applying this bi-temporal change detection on the primary test dataset in this study, consisting of a time series (approximately one year from 11/2013 to 11/2014) of TerraSAR-X amplitude images, offers the opportunity to detect very frequently changing areas (e.g., parking places and construction sites). These areas can be characterized by the so-called high activity objects.

The second main aspect of the proposed method is given by the categorization and classification of such high activity objects. For this step, suitable features are extracted for each object. According to their feature-based characteristics, the high activity objects are categorized.

The next processing step, the classification stage, does not require any training data, which avoids the question dealing with an optimal selection of training areas for meaningful classes. The presented method rather aims on supporting the user in formulating a class catalogue that is suitable for the available data.

This is managed in an iterative way by optimizing an a-priori defined class catalogue in comparison with the categorization result. Optimization is accomplished by successive analysis of pre-defined key indicators after each iteration. An optimal class catalogue is found, when the combination of key indicators is found to be optimal with respect to the categorized dataset. In this context, classes which were falsely defined might be deleted, and classes which were defined too coarsely might be split into finer units.

The final processing step is represented by the assignment (classification) of the change objects according to the resulting optimized class catalogue. To ensure an intuitive accessibility and a high flexibility, principles of Fuzzy logic are considered.

**Keywords:** SAR, time series, change detection, change analysis, categorization, classification.



---

## **Erklärung**

Hiermit erkläre ich, dass ich diese Arbeit, abgesehen von der Benutzung der von mir vollständig und genau bezeichneten Quellen und Hilfsmittel, selbstständig verfasst habe.

Die Grundsätze des Karlsruher Instituts für Technologie (KIT) zur Sicherung guter wissenschaftlicher Praxis in der jeweils gültigen Fassung habe ich beachtet.

Ettlingen, im September 2017

Markus Boldt



---

## Vorwort

Heute, im September 2017, liegen beinahe genau zehn Jahre zwischen dem Abschluß meines Studiums an der Hochschule Karlsruhe (ehemals Fachhochschule) und der Abgabe der Dissertation, die Sie gerade in Ihren Händen halten.

Nach meiner Zeit als Diplomand war ich bis zum Jahresende 2007 als technischer Mitarbeiter in der Abteilung Szenenanalyse des Fraunhofer IOSB (damals noch FGAN-FOM) Ettlingen tätig und wechselte danach mit Beginn des neuen Jahres in die Industrielle Bildverarbeitung. Obwohl die dortigen Aufgaben zugleich anspruchsvoll und interessant waren, reifte im Verlauf des Jahres 2008 der Gedanke an eine berufliche Veränderung in mir immer stärker heran. Da war dieses Gefühl, noch nicht am Ende zu sein, dieses Gefühl der Unvollständigkeit. Ich wollte mich noch detaillierter mit Forschungsthemen rund um die digitale Bildverarbeitung, Photogrammetrie und Fernerkundung auseinandersetzen, als dies im Rahmen des Hochschulstudiums möglich war. In diesem Zusammenhang war es durchaus als ein erster Wink des Schicksals zu verstehen, dass erstmalig zum Wintersemester 2008/2009 am Karlsruher Institut für Technologie KIT (ehemals Universität Karlsruhe) der Masterstudiengang im Fachbereich *Geodäsie und Geoinformatik* angeboten wurde. Mein Entschluß war schnell gefasst und die Zielsetzung klar formuliert. Ich wollte mich mit einem universitären Abschluß beruflich breiter aufstellen und auch auf dem Papier für Tätigkeiten in der Forschung und Wissenschaft qualifizieren.

In meinem Vorhaben bestärkt wurde ich vor allem von den Betreuern meiner Diplomarbeit am IOSB, Antje Thiele und Karsten Schulz, die mir ebenfalls die Gelegenheit gaben, während der folgenden Zeit als Masterstudent in ihrer Arbeitsgruppe *SAR-Bildauswertung* durch die Arbeit an studienbegleitenden Forschungsthemen den notwendigen Lebensunterhalt zu bestreiten. Natürlich ging ich die Herausforderung nicht ohne erhebliche Zweifel an, schließlich tauschte ich freiwillig das geregelte und einträgliche Berufsleben in das ungewisse und darbe Studentendasein. Diese Zweifel blieben vorerst auch trotz moralischer und finanzieller Unterstützung aus meinem privaten Umfeld bestehen.

Anfang Oktober, an meinem ersten Tag am KIT, lernte ich meinen späteren Doktorvater Prof. Stefan Hinz kennen, der ebenso wie ich eine neue berufliche Herausforderung angetreten hatte, da er zum neuen Leiter des Instituts für Photogrammetrie und Fernerkundung (IPF) berufen worden war. Auf seinem bisherigen Werdegang hatte er sich größtenteils mit der Analyse und Verarbeitung von SAR-Bilddaten auseinandergesetzt und war deshalb auch am IOSB kein Unbekannter.

Das Schicksal nahm mich somit also erneut an die Hand und gab mir nun endgültig das Gefühl, auf dem richtigen Weg zu sein. Die Zweifel, die ich noch in Anbetracht meiner Entscheidung hatte, wandelten sich um in positive Aufbruchstimmung.

Tage und Wochen vergingen, Lehrveranstaltungen und Prüfungen mussten eigens für mich, den zu diesem Zeitpunkt ersten und auch einzigen Studenten des neuen Masterstudiengangs, gefunden und angepasst werden. Ich verkörperte dementsprechend den „Prototypen“, an dem notwendige bürokratische Prozesse für nachfolgende Master-Generationen erprobt und erlernt werden konnten. Mit der Zeit wurde aus Stückwerk Routine und ehe ich mich versah, war es April 2011 geworden. Die Präsentation meiner Masterarbeit markierte gleichzeitig das Ende meiner zweiten Studienzeit. Es war vollbracht. Erfolgreich hatte ich Nebenjob, Studium und Haushalt unter einen Hut gebracht und dabei die Regelstudienzeit um nur ein Semester überschritten.

Im Juli desselben Jahres nahm ich meine bis heute andauernde Tätigkeit als wissenschaftlicher Mitarbeiter am IOSB auf, bei der ich mich fortan mit der änderungsbezogenen Analyse von SAR-Zeitreihendaten auseinandersetzte. Im Oktober 2012 machte ich mich offiziell auf meine Promotionsreise auf, die somit knapp fünf Jahre andauerte. Eine solche Reise kann nur schwerlich alleine unternommen werden. Deshalb möchte ich mich nachfolgend bei jenen Personen bedanken, die mich begleitet und auf unterschiedliche Weise inspiriert und unterstützt haben.

Herausgreifen möchte ich zunächst Prof. Berthold Pfeiffer für das Wecken der Begeisterung. Es war meine Diplomarbeit bei Ihnen, die mich letzten Endes dazu brachte, meinen beruflichen Weg so zu entdecken. Eine Freude und Ehre zugleich war es für mich, als Sie sich gerne dazu bereit erklärt, die erste sprachliche Korrektur der vorliegenden Arbeit zu übernehmen.

Maßgeblichen Anteil am Gelingen dieser Arbeit besitzen weiterhin meine langjährigen Weggefährten, Betreuer und Kollegen, Antje Thiele und Karsten Schulz. Danke für eure Unterstützung und vor allem für euer Vertrauen und euren Glauben an mich.

Einen bedeutenden Anteil trägt natürlich Prof. Stefan Hinz, der mir erst die Gelegenheit dazu gab, unter seiner Betreuung das vorliegende Thema bearbeiten zu können. Ich danke Ihnen für das entgegengebrachte

---

Vertrauen sowie für die stets sehr angenehmen und produktiven Statustreffen, die immer Gelegenheit zur gewinnbringenden Diskussion gaben.

Dankend erwähnen möchte ich ebenfalls noch Uwe Weidner, der in der Endphase fachlich unterstützend mitwirkte.

Dem Koreferenten dieser Arbeit, Prof. Franz Meyer, danke ich herzlich für die Übernahme dieser Funktion und für den unkomplizierten sowie angenehmen Austausch.

Ein großer Dank gebührt ebenfalls meinen weiteren, mir verbundenen Kollegen am IOSB. Namentlich sind dies Erich Cadario, der in der „heißen Phase“ Projektarbeit von mir fern hielt; Silvia Kuny, der ich für eine stets produktive und angenehme Büroatmosphäre danken möchte und Gisela Häufel, die im Rahmen der schriftlichen Konversation mit Herrn Pfeiffer als Briefträgerin fungierte. Ein großer Dank geht an Horst Hammer, der geduldig das fachliche und grammatischen Gegenlesen übernommen hat. Romy Wagner danke ich herzlichst für zwei stets geöffnete Ohren - insbesondere in für mich nicht leichten Situationen. Danke auch an meinen ehemaligen Kollegen Dominik Brunner, der mich während meines Masterstudiums in meiner Tätigkeit als studentischer Mitarbeiter am IOSB betreuend unterstützte.

Abschließend möchte ich noch einzelne Personen aus meinem familiären und privaten Umfeld herausgreifen, die mich in den letzten Jahren in besonderer Weise begleitet haben.

Allen voran ist das meine Sina, die mich in dunklen und schweren Zeiten an die Hand genommen hat. Seit Ende 2015 scheint unsere gemeinsame kleine Sonne Emelie, die mir immer wieder aufs Neue zeigt, was im Leben tatsächlich von Bedeutung ist. Ihr beide tragt einen gewichtigen Anteil am erfolgreichen Gelingen dieser Arbeit, weshalb ich sie euch widme. Sie soll euch immer daran erinnern, dass man alles schaffen kann. Man muss nur an sich selbst glauben.

Immer an mich geglaubt haben auch meine Eltern Regina und Günter, die mich durchweg mit Rat und Tat unterstützt haben.

Ich danke ebenso meinen Schwiegereltern Christel und Jürgen. Ihr wisst weshalb und wofür. Ich werde es euch nicht vergessen.

Meinem Vater und meinem Schwiegervater, sowie auch meiner Schwägerin Carina und meinem Schwager Daniel, danke ich herzlich für das abschließende Korrekturlesen.

Unterstützend begleitet haben mich auch meine Freunde Kevin, Nicole, Annette und Matthias, auf die jederzeit und in jeder Situation Verlass war. Insbesondere auf schwierigen Abschnitten des Wegs wusste ich euch an meiner Seite. Ich bin sehr stolz auf euch.

Zehn Jahre sind seit meiner ersten Diplomarbeit vergangen. Der Weg ähnelte nicht immer einem ebenen, geraden Pfad bei Sonnenschein. Es waren felsige und hügelige Abschnitte bei dichtem Nebel dabei, was auf mich durchaus auch einmal beunruhigend wirkte.

Ist aber nicht gerade das Beschreiten eines solchen Wegs das, was das Leben ausmacht?

Was mir für immer bleibt, ist der Stolz, bis zum Ende weitergegangen zu sein.

*Markus Boldt, im September 2017*

*Du bist tapferer als Du glaubst,  
stärker als Du scheinst  
und klüger als Du denkst.*

Alan Alexander Milne



*Für meine beiden Hauptkomponenten Sina und Emelie.*



# Inhaltsverzeichnis

<b>1. Einleitung</b>	<b>1</b>
1.1. Stand der Technik . . . . .	3
1.2. Beitrag . . . . .	14
1.3. Aufbau . . . . .	15
<b>2. Grundlagen der Fernerkundung und Bildanalyse</b>	<b>17</b>
2.1. Satellitengestützte Fernerkundung mit SAR . . . . .	18
2.2. Bildanalyse . . . . .	24
2.2.1. Morphologische Bildverarbeitung . . . . .	25
2.2.2. Entropiebasierte Schwellwertberechnung . . . . .	29
2.2.3. Texturanalyse und Grauwertmatrix . . . . .	31
2.2.4. Objektbasierte Bildanalyse . . . . .	32
2.2.5. Hochdimensionale Datensätze und deren Reduzierung . . . . .	36
2.2.6. Kategorisierung . . . . .	37
2.2.7. Klassifikation . . . . .	42
<b>3. Änderungsdetektion</b>	<b>45</b>
3.1. Abrupte Detektion . . . . .	46
3.2. Anwendung auf Zeitreihendaten . . . . .	51
3.2.1. Index- und Aktivitätskarte . . . . .	51
3.2.2. Präkategorisierung und Aktivitätscluster . . . . .	53
3.2.3. Identifikation von Hochaktivitätsobjekten . . . . .	54
<b>4. Merkmalsextraktion</b>	<b>57</b>
4.1. Überblick . . . . .	58
4.2. Verwendete Merkmale . . . . .	59
4.2.1. Kontext . . . . .	59
4.2.2. Kohärenz . . . . .	65
4.2.3. Form . . . . .	67
4.2.4. Textur . . . . .	68
4.2.5. Morphologie . . . . .	69
<b>5. Kategorisierung und Klassifikation</b>	<b>73</b>
5.1. Konzept . . . . .	74
5.2. Umsetzung . . . . .	76
5.2.1. Kategorisierung . . . . .	77
5.2.2. Initialer Klassenkatalog . . . . .	78
5.2.3. Vorprojektion . . . . .	78
5.2.4. Rückprojektion . . . . .	80
5.2.5. Optimierter Klassenkatalog und Zuweisung . . . . .	85
5.2.6. Klassenbeschreibung . . . . .	86
<b>6. Resultate und Bewertung</b>	<b>89</b>
6.1. Daten und Vorverarbeitung . . . . .	90
6.1.1. Szene „Stuttgart Flughafen“ . . . . .	90
6.1.2. Szene „Greding“ . . . . .	94
6.2. Änderungsanalyse . . . . .	96
6.2.1. Präkategorisierung und Aktivitätscluster . . . . .	96
6.2.2. Hochfrequente Änderungsobjekte . . . . .	96
6.2.3. Merkmalsextraktion, Skalierung und Reduzierung . . . . .	97
6.2.4. Kategorisierung . . . . .	101
6.2.5. Klassenkatalog, Optimierung und Klassifikation . . . . .	102
6.2.6. Klassenbeschreibung . . . . .	111

6.2.7. Diskussion . . . . .	112
6.3. Quantitative Evaluierungen und Vergleiche verschiedener Verfahren . . . . .	118
6.3.1. Änderungsdetektion . . . . .	118
6.3.2. Unüberwachte Schwellwertverfahren . . . . .	121
6.3.3. Segmentierung . . . . .	123
6.3.4. Raumzeitliche Analyse . . . . .	126
6.3.5. Anzahl dominanter Cluster . . . . .	128
6.3.6. Klassenkatalog . . . . .	129
6.3.7. Klassenzugehörigkeit . . . . .	132
6.3.8. Zusammenfassung . . . . .	133
<b>7. Zusammenfassung und Ausblick</b>	<b>137</b>
<b>Anhang</b>	<b>142</b>
<b>A. Ergänzende Abbildungen</b>	<b>143</b>
<b>Abkürzungs- und Symbolverzeichnis</b>	<b>173</b>
<b>Literaturverzeichnis</b>	<b>177</b>

# Kapitel 1.

## Einleitung

Die Fernerkundung unter Nutzung von Radarsensoren mit synthetischer Apertur (SAR) weist gegenüber der optischen Alternative gewichtige Vorteile auf. Diese Vorteile resultieren als direkte Konsequenz aus der aktiven Sensorcharakteristik eines SAR-Systems, das die jeweilige Szene mit elektromagnetischer Strahlung im Mikrowellenlängenbereich beleuchtet. SAR kann unabhängig von der Aufnahmezeit und wetterbedingten Effekten wie Dunst, Nebel oder Wolken verwendet werden. Dies ist insbesondere für Anwendungen wichtig, bei denen eine regelmäßige Szenenaufnahme zu identischen Tageszeiten gefordert ist. Derartige Anwendungen können in der Raum- und Landesplanung, im Katastrophen- und Krisenmanagement oder im Umweltmonitoring beheimatet sein. Zentraler Bestandteil aller Anwendungen mit *Monitoring*-Bezug ist die Detektion von Änderungen, die sowohl überwacht und manuell als auch unüberwacht und automatisiert erfolgen kann. Im ersten der beiden Fälle handelt es sich um die bei SAR-Auswertern weit verbreitete und äußerst aufwendige Methode, Änderungen anhand visueller Interpretationsmethoden (zum Beispiel *Flicker*-Methode) der entsprechenden Bilder zu identifizieren. Für die automatisierte Vorgehensweise wurden viele verschiedene Verfahren entwickelt. Im Regelfall enden diese Verfahren mit dem Vorliegen einer Ergebniskarte, in der die Änderungen als binäre zusammenhängende Komponenten dargestellt sind. Der in der vorliegenden Arbeit beschriebene Inhalt geht darüber hinaus und setzt sich mit der Analyse der Änderungen auseinander.

Im Jahr 2007 wurde der deutsche SAR-Satellit TerraSAR-X (TSX) gestartet, der bis heute Bilddaten mit einer Pixelgröße von unter einem Meter in Schrägsichtgeometrie zur Verfügung stellt und somit insbesondere die Auswertung urbaner Gebiete ermöglicht. Einzelne und kleinskalige, durch den Menschen geschaffene Objekte oder hervorgerufene Veränderungen können überwacht und beurteilt werden, sei es ein bestimmter Teil eines Parkplatzes oder eine Baustelle. Zu dieser neuen Generation der hochauflösenden SAR-Satelliten gehört neben TSX sowie dem 2009 gestarteten, baugleichen Satelliten TanDEM-X (TDX), die aus vier Satelliten bestehende, italienische Konstellation COSMO-SkyMed (CSK). Der sich seit 2007 im Orbit befindliche kanadische Satellit RADARSAT-2 ist im Gegensatz zu den bisher beschriebenen Missionen mit einem C-Band Radar ausgestattet und stellt Aufnahmen mit leicht größeren Pixeln bereit. Im Rahmen der vorliegenden Arbeit werden Zeitreihen aus hochauflösenden TSX-Amplitudenbildern verwendet.

Bisher verfügbare Verfahrensweisen zur unüberwachten Änderungsdetektion basierend auf SAR-Bildern beschränken sich zumeist auf die Berechnung eines Ergebnisbildes, das die Änderungen enthält. Auf diese Weise werden zweierlei Informationen zu den Änderungen vermittelt: Die Koordinaten beziehungsweise der Ort der Änderung und der Detektionszeitpunkt, der durch das entsprechende Bildpaar je nach zeitlichem Abstand mehr oder weniger eingeschränkt werden kann. Eine weiterführende, die Änderungen charakterisierende, typisierende oder klassifizierende Verarbeitung erfolgt von Seiten der Algorithmik für gewöhnlich nicht im Zusammenhang mit der Detektion. Oftmals ist es jedoch gerade diese Information, die den Anwender interessiert und ein hohes Maß an praktischem Nutzen beinhaltet.

In Anbetracht dieser praktischen Relevanz muss sowohl die Datengrundlage als auch das Verfahren selbst entsprechend aufgestellt sein. In der Praxis kommt es auf schnelle Entscheidungsfindungsprozesse an, die auf Basis wirtschaftlich günstig vorliegender Daten angestoßen werden. Die Eingabedaten sollten demzufolge möglichst gering und beschränkt in ihrem Umfang vorliegen. Ein von vielen verschiedenen Daten abhängiges Verfahren ist umso fehleranfälliger, wenn es auf Datensätze anderer Szenen aber vergleichbarer Sensorik übertragen werden soll. Eine solche gute Übertragbarkeit wird neben der geeigneten Datenbasis durch ein Verfahren sichergestellt, das so unüberwacht wie möglich eine lediglich minimale Anzahl an Parametern benötigt. Umso weniger Variablen erfasst oder eingestellt werden müssen, desto leichter ist die Bedienbarkeit der Methode.

Für die die Änderungen charakterisierende, weiterführende Auswertung existieren verschiedene Vorgehensweisen. Allen gemein ist die Notwendigkeit des Vorhandenseins zielführend nutzbarer Referenzdaten - sei es für die Erstellung einer Referenzklassifikation oder als Grundlage für die Selektion geeigneter Trainingsgebiete. In Konsequenz dazu ist ableitbar, dass das spätere Analyseresultat in direkter Weise mit den Referenz- und Trainingsdaten korreliert ist. Mit Bezug zu den Referenzdaten ergeben sich wichtige und notwendige Fragestellungen:

Befinden sich diese Datengrundlage in einem aktuellen Zustand? Welche Trainingsgebiete sind für den jeweili-  
g vorliegenden Anwendungsfall die Richtigen? Ergibt die Auswahl von Trainingsgebieten für eine bestimmte  
Klasse Sinn? Ist diese Klasse überhaupt durch den vorhandenen Datensatz abbildbar?

Ein Verfahren, das den Anwender unterstützt und ihm eine sinnvolle Klassenstruktur passend zum genutzten  
Datensatz vorschlägt, würde Abhilfe schaffen. Ein derartiges Verfahren würde keine umfassende Referenzda-  
tenbasis erfordern, sowie keine nutzerabhängige Auswahl von Trainingsgebieten und auch keine detaillierte  
Kenntnis des Szeneninhalts voraussetzen. Von Seiten des Anwenders müsste allein die Definition eines Klas-  
senkatalogs erfolgen, der aus seiner Sicht für die bearbeitete Szene passend erscheint, oder der ihm bereits fest  
vorgegeben ist.

## 1.1. Stand der Technik

Das Themengebiet der Änderungsdetektion anhand fernerkundlich erfasster Bilddaten repräsentiert einen breit gefächerten, ständig im Wandel befindlichen Forschungsbereich mit multiplen Verfahrensweisen. Typische Anwendungen sind in der Forst- und Landwirtschaft, in der Überwachung von Eis und Schnee betroffener Gebiete (Gletscher, Permafrost, etc.), sowie von Küstenregionen und in der Analyse urbaner Räume (Raum-, Landes- und Infrastrukturplanung, Krisen- und Katastrophenmanagement, etc.) angesiedelt [1].

Grundsätzlich können bei der Bildaufnahme luftgestützte oder satellitengetragene Sensorsysteme zum Einsatz kommen. Im Hinblick auf Überwachungsaufgabenstellungen vereint die Fernerkundung mit Satelliten essentielle Vorteile, da diese zueinander stabile Aufnahmen zu exakt gleichen Tageszeitpunkten ermöglichen. Weiterhin entfällt die zeitaufwendige Planung und Vorbereitung von Bildflügen ([2] und [3]). In [4] wird die satellitengestützte Überwachung von Landnutzungsänderungen in Anbetracht der hohen zeitlichen Auflösung und der gegenüber traditionellen Verfahren geringeren Kosten als leistungsstarkes Mittel beschrieben. Generell können Bilderzeugnisse passiver, optischer als auch aktiver Sensorsysteme getrennt voneinander Verwendung finden, oder auch kombiniert und komplementär genutzt werden.

Nachfolgend wird zunächst eine beschreibende Charakterisierung der verfügbaren Sensoren in der satellitengestützten Fernerkundung vorgenommen. Danach erfolgt eine für die vorliegende Arbeit geltende Definition der beiden Begriffe *Änderungsdetektion* und *Änderungsanalyse*, die für eine präzise Einordnung der vorgestellten Verfahrensweise notwendig ist. Im Anschluss daran wird eine zweckmäßige Einteilung verbreiteter Methoden zur Extraktion von Änderungsinformationen vorgenommen. Zum Ende des Abschnitts erfolgt eine Bewertung der bislang verfügbaren Ansätze zur Ableitung des Beitrags zur Forschung.

### **Sensorsysteme in der Fernerkundung**

Die in der Fernerkundung zur Anwendung kommenden Sensoren können in zwei Hauptgruppen unterteilt werden: Passive und aktive Systeme. Daneben existiert noch eine thematische Informationsebene, die im Anschluss an die beiden Hauptgruppen kurz erläutert wird.

#### **Passive, optische Systeme**

Derartige Systeme basieren auf der von der jeweiligen Szenerie reflektierten Sonneneinstrahlung, die bei der Aufnahme auf den Sensor einwirkt [2]. Je nach Anzahl und Einteilung der verfügbaren (Spektral-)Kanäle des Sensors erfolgt die Datenaufzeichnung auf multi- oder hyperspektrale Weise. Bekannte, satellitengestützte Vertreter multispektraler Sensorsysteme sind unter anderem die Missionen QuickBird, GeoEye, WorldView (WV), Pleiades und RapidEye.

Der 2009 gestartete WorldView-2 (WV-2) Sensor verfügt exemplarisch über insgesamt acht Kanäle, die den Spektralbereich von 400 (*Coastal*) bis 1040 nm (*Near-IR2*) abdecken [5]. Im Gegensatz zu multispektralen Sensoren erfolgt bei hyperspektralen Systemen die Datenaufnahme in sehr vielen, spektral eng aneinander liegenden Kanälen, um so detailliertere Informationen über das Interessengebiet und der darin befindlichen Objekte und Oberflächenmaterialien ableiten zu können. Die deutsche Mission EnMap, deren Start für das Jahr 2018 vorgesehen ist, wird mit über 200 Kanälen über eine hohe spektrale Auflösung verfügen<sup>1</sup>.

#### **Aktive Systeme**

Mit der abbildenden, aktiven Fernerkundung ist die Möglichkeit gegeben, Daten von Interessengebieten unabhängig von atmosphärischen Störeinflüssen (Nebel, Dunst und Wolken (Abbildung 1.1)), von der Sonneneinstrahlung und damit verbundenen, inkonstanten Reflektionseigenschaften diverser Oberflächenmaterialien, sowie unabhängig von der Tageszeit aufzunehmen [3]. Als Vertreter können grundsätzlich Radar (SAR)- sowie LiDAR (*Light Detection and Ranging*) Sensorsysteme genannt werden [3], von denen im Folgenden die Funktionsweise skizziert, sowie aktuelle Sensorik beschrieben wird. In Bezug auf die Fernerkundung mit SAR sind in Abschnitt 2.1 detailliertere Ausführungen zu finden.

Insbesondere im letzten Jahrzehnt hat die satellitengestützte SAR-Sensorik eine enorme Entwicklung vollzogen. Durch den Start und die Inbetriebnahme hochauflösender Systeme wie TSX, TDX, CSK (alle X-Band) und RADARSAT-2 (C-Band) eröffneten sich neue Anwendungsmöglichkeiten. Die SENTINEL-Mission als gemeinschaftliches Projekt der Europäischen Raumfahrtorganisation (*European Space Agency ESA*) und der Initiative GMES (*Global Monitoring for Environmental and Security*) der Europäischen Kommission stellen zudem eine interessante Alternative zu den etablierten Systemen dar<sup>2</sup>, da Bilddaten - allerdings mit einer vergleichsweise niedrigeren räumlichen Auflösung ( $\geq 10 \text{ m}$ ) - für alle Anwender frei verfügbar sind.

<sup>1</sup><http://www.enmap.org/>, zuletzt besucht (TT.MM.JJJJ): 09.01.2018

<sup>2</sup><https://sentinel.esa.int/web/sentinel/missions>, zuletzt besucht (TT.MM.JJJJ): 09.01.2018



Abbildung 1.1.: Gegenüberstellung eines Ausschnitts aus einem optischen Satellitenbild (hier: WV-2, links) mit einem identischen Ausschnitt aus einem SAR-Satellitenbild (hier: TSX, rechts).

Im Hinblick auf den Themenkomplex der Änderungsdetektion können mit Fokus auf SAR kohärente und inkohärente Techniken unterschieden werden [6]. Bei kohärenten Ansätzen wird die lokale Phasendekorrelation zwischen zwei komplexwertigen SAR-Bildern genutzt, um sehr feinskalige, beispielsweise durch menschliche Aktivität hervorgerufene Änderungen in ariden Gebieten zu detektieren [7]. Die Verfahren machen hierbei Gebrauch von der großen Kontrastdifferenz zwischen inkohärenten Änderungsstrukturen (zum Beispiel Fahrspuren) und einer das Signal hochkohärent zurückstreuenden, lokalen Umgebung (zum Beispiel Wüste). Im Vergleich dazu nutzen inkohärente Verfahren die Rückstreuintensität des Radarsignals zur Detektion von Änderungen ([7] und [8]). Da in der vorliegenden Arbeit hauptsächlich Änderungen in urbanen Gebieten - beispielsweise hervorgerufen durch Fahrzeuge und anderen künstlichen Objekten - behandelt werden, deren Umgebungsstrukturen (Asphalt) eine nahezu völlig inkohärente Charakteristik aufweisen (siehe auch Abschnitt 2.1), werden kohärente Verfahren nicht weiter betrachtet. Unter dem Begriff *SAR-Bild* wird deshalb - wenn nicht anders erwähnt - ein Amplitudenbild verstanden.

Im Vergleich zu SAR wird bei der Fernerkundung mit LiDAR keine Mikrowellenstrahlung, sondern sehr kurzwelliges Laserlicht beispielsweise im Bereich des nahen Infrarot (NIR) verwendet. Der LiDAR-Begriff ist eng mit dem Themenfeld des luftgestützten Laserscannings (*Airborne Laserscanning ALS*) verbunden, das häufig zur Erfassung dreidimensionaler, digitaler Oberflächen- und Geländemodelle verwendet wird [9]. Darüber hinaus finden sich auch im Umfeld der Änderungsdetektion Anwendungen, bei denen ALS beziehungsweise LiDAR in verschiedener Art und Weise eingesetzt wird. Weiter unten sind einige Anwendungsbeispiele aufgeführt.

### **Thematische Informationsebene**

Neben diesen beiden bildgebenden Sensorkategorien existiert eine weitere Datenebene, die für eine Detektion von Änderungen genutzt werden kann [10]. Diese Ebene ist besetzt durch in Geoinformationssystemen (*Geographic Information System GIS*) enthaltene, ortsbezogene Vektordaten inklusive charakterisierender Attributinformationen [3]. Mit einem GIS ist es möglich, für ein bestimmtes Interessengebiet multiple Informationen, zum Beispiel topographischer oder geologischer Natur, abzurufen. Im Hinblick auf die Detektion von Änderungen können GIS-Daten vergleichend miteinander ausgewertet werden, oder unterstützend für andere Sensorerzeugnisse herangezogen werden.

Im Jahr 2004 wurde mit *OpenStreetMap* (OSM)<sup>3</sup> ein Projekt mit dem Ziel gegründet, eine frei nutzbare Weltkarte zu erschaffen. Die Daten hierfür werden von Projektbeteiligten und Privatpersonen in Eigenregie erhoben und umfassen sämtliche Informationen, die auf Kartenmaterial sichtbar sind (zum Beispiel Straßen, Gebäude, Vegetation, etc.). Die freie Verfüg- und Nutzbarkeit macht OSM insbesondere für Projekte attraktiv, für die nur wenige Referenzdaten vorhanden sind, oder eine teure Anschaffung weiterer Referenzen nicht realisierbar ist.

### **Begrifflichkeiten und Einteilung verbreiterter Verfahren**

In Bezug auf die Begrifflichkeiten *Änderungsdetektion* und *Änderungsanalyse* existieren in der Literatur unterschiedliche Definitionen. Methoden wie *Postklassifikationsvergleich* oder *Vegetationsdifferenz* (siehe unten) erlauben indirekt Rückschlüsse auf die Änderungsklasse, obwohl diese Verfahren als Methoden zur Änderungsdetektion dargelegt werden. Vor dem Hintergrund dieser nicht einheitlichen Notationen erscheint es in Anbetracht der vorliegenden Arbeit sinnvoll, eine eindeutigere Abgrenzung vorzunehmen.

<sup>3</sup><https://www.openstreetmap.de/>, zuletzt besucht (TT.MM.JJJJ): 09.01.2018

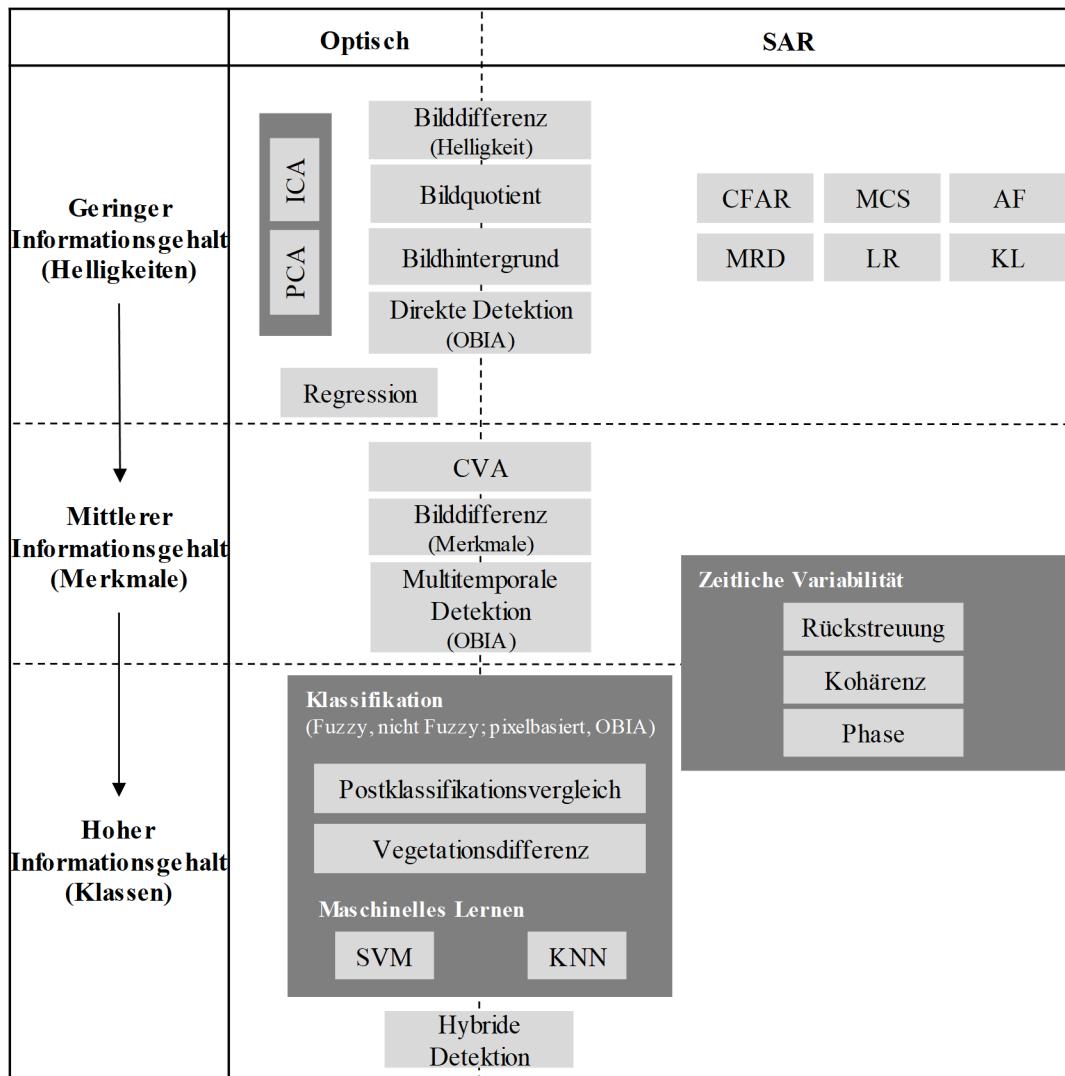


Abbildung 1.2.: Einteilung verbreiteter Verfahren zur Änderungsdetektion entsprechend des jeweilig resultierenden Informationsgehalts.

Die Änderungsdetektion wird in [11] als ein Prozess beschrieben, der zur Identifikation von Veränderungen auf beziehungsweise der Erdoberfläche dient. Bestätigendes kann beispielsweise in [12] beziehungsweise [13] gefunden werden, wo der Begriff der Änderungsdetektion als Prozess zur Identifikation von Zustandsveränderungen eines Objektes oder Phänomens durch Beobachtung zu unterschiedlichen Zeitpunkten definiert wird. Anhand des deutschen Dudens kann festgestellt werden, dass das Verb *identifizieren* als *genaues Wiedererkennen*, beziehungsweise *die Identität, Echtheit einer Person oder Sache feststellen* beschrieben wird [14]. Übertragen auf die fernerkundlich motivierte Änderungsdetektion kann somit die Detektion als die Erkennung von Veränderungen als solche aufgefasst werden.

Der Prozess der Änderungsanalyse wird als umfassender Begriff verstanden, der sowohl die Detektion als auch die Beurteilung von Änderungen, beispielsweise hinsichtlich ihrer Klassenzugehörigkeit beinhaltet. Gegenüber der alleinigen Detektion ist diese Verfahrensweise somit als vollständigere Verarbeitung zu betrachten.

Aus allgemeiner Sicht sind verbreitet für die Änderungsdetektion zur Anwendung kommende Methoden in [12], [10], [15], [13] und [16] dargelegt, wobei die Einteilung der Verfahren auf unterschiedliche Art und Weise erfolgt. Eine weitere umfassende Übersicht - auch mit Bezug zu einigen der zuvor genannten Quellen - findet sich in [17].

In [15] werden die Ansätze hinsichtlich des jeweilig verarbeitbaren Datenumfangs in die beiden Kategorien abrupte und progressive Detektionsverfahren unterteilt. Erstere dienen zur Identifikation von Änderungen in bi-temporalen Datensätzen (Bildpaare). Im Gegensatz dazu wird die progressive, multitemporale Verfahrensweise aus konventioneller Sicht zur Ableitung von Änderungstrajektorien verwendet. Derartige Trajektorien geben Aufschluss über den Trend und den Verlauf, mit der sich eine bestimmte Landbedeckungsklasse über

einen gewissen Zeitraum ändert [18].

Eine weitere Möglichkeit zur Einteilung der Detektionsverfahren findet sich in [10], wo die Methoden nach zunehmender Komplexität in fünf Ebenen sortiert sind. Eine dazu ähnliche Darstellung ist in [19] zu finden. Darüber hinaus kann eine Unterscheidung der Methoden von der Seite der Datenprozessierung erfolgen. So findet sich in [11] ein umfassender Überblick, sowie eine Kategorisierung in überwachte und automatisierte Methoden. Überwachte Verfahren bauen auf Referenz- und Trainingsdaten auf, die im Zuge von Ortsbegehungen, durch Expertenwissen oder durch manuelle Szeneninterpretation gewonnen werden können. Werden multitemporale Datensätze wie Zeitreihen verwendet, erhöht sich dieser Aufwand entsprechend der verwendeten Anzahl an Bildstapelkomponenten, was somit überwachte Verfahren hierfür generell unpraktikabel werden lässt. Unüberwachte Methoden benötigen keinerlei Referenz- und Trainingsdaten für die Detektion und liefern hauptsächlich Informationen zur An- oder Abwesenheit von Änderungen, ohne sich explizit mit deren Typus auseinander zu setzen [11].

In Anbetracht der zu verarbeitenden Bildeinheiten können pixelbasierte von objektorientierten Methoden abgegrenzt werden. Hierzu bietet sich in [13] eine umfassende Referenz. Viele der konventionellen unüberwachten Verfahren zur Änderungsdetektion arbeiten pixelbasiert. Das bedeutet, dass räumlich nebeneinander liegende Pixel als voneinander unabhängige semantische Einheiten betrachtet werden. Änderungen werden anhand sich verändernder spektraler Rückstreuereigenschaften einzelner Pixel festgestellt. Bereits in [20] wurde darauf hingewiesen, dass ein Pixel kein wirkliches, geographisches Objekt, sondern lediglich eine zellenförmige Aufteilung eines Gitters darstellt, dessen Begrenzungen wenig Korrespondenz zur realen Welt besitzen (siehe auch [13]).

Durch den technischen Fortschritt hin zu sehr hochauflösenden Sensoren, die Bilddaten mit Pixelgrößen von unter einem Meter bereitstellen, wurden Verfahren der objektorientierten Bildanalyse (*Object Based Image Analysis OBIA*) entwickelt, die neue Möglichkeiten zur Bildauswertung eröffnen. Pixelbasierte Verfahren stoßen bei sehr hochauflösenden Bilddaten an ihre Grenzen, da dort Objekte der realen Welt wie etwa Gebäude oder Fahrzeuge durch eine Vielzahl einzelner Pixel mit unterschiedlichem Rückstreuverhalten repräsentiert werden [13]. Im Rahmen der vorliegenden Arbeit wird die OBIA-Prozessierungseinheit als ein aus einer Segmentierung hervorgehendes Bildobjekt verstanden, das bestenfalls ein *reale Welt Objekt* semantisch passend und vollständig wiedergibt.

OBIA vereint mehrere Vorteile gegenüber der klassischen, pixelbasierten Herangehensweise. Unter anderem können räumliche Beziehungen zwischen benachbarten Objekten, sowie objektbezogene formbeschreibende und statistische Parameter bei der Auswertung berücksichtigt werden ([13], [21] und [22]). Sämtliche Ansätze zur OBIA basieren auf einer räumlichen Zusammenfassung (Segmentierung) benachbarter, ähnlicher Bildelemente zu homogenen Bildobjekten (Segmenten). Eine solche Segmentierung kann wiederum auf verschiedener Art und Weise erfolgen ([23] und [24]). Generell können diese in Kantendetektions-, Schwellwert- und *Clustering*-Verfahren, regionen- und *fuzzy*-basierte Methoden und Neuronale Netze unterschieden werden. Ein regionenbasiertes Verfahren stellt die unter anderem in [25] beschriebene *Multiresolution Segmentation* (MrSeg) dar, die Teil des Softwarepaketes *eCognition Developer* der Firma *Trimble Inc.* ist. Segmentiert wird anhand eines iterativen Regionenwachstumsprozesses mit dem Ziel, die durchschnittliche Heterogenität der generierten Segmente zu minimieren. Diese Heterogenität wird anhand spektraler (*Color*) und räumlicher (*Smoothness, Compactness*) Maßzahlen beurteilt (siehe auch Abschnitt 2.2.4).

In Bezug auf die SAR-Bildanalyse hat generell für eine geeignete Segmentierung als vorverarbeitender Schritt eine entsprechende Reduzierung des die Bildqualität einschränkenden Speckle-Effekts zu erfolgen. Für diesen Schritt existieren verschiedene Methoden, die in nicht-adaptive sowie adaptive Verfahren unterschieden werden können [26]. Adaptive Filter erscheinen grundsätzlich gut geeignet, da sie die Speckle-Statistik berücksichtigen, die allerdings für unterschiedliche Objektarten, Oberflächenfeuchtegrade, Wellenlängen oder Blickwinkel variiert [27]. Eine andere Variante zur Reduzierung dieses Rauschanteils ist durch die *Multi-Look* (ML) Methode gegeben [28]. Im Fall einer Zeitreihenanalyse können die statistisch voneinander unabhängigen Aufnahmen derselben Szene für ein zeitliches ML genutzt werden [27]. Die (morphologischen) *Alternierenden Sequentiellen Filter* (ASF) stellen eine weitere Möglichkeit zur Reduzierung des Speckle dar. ASF sind insbesondere für Bilder gut geeignet, deren Rauschstruktur unterschiedliche Helligkeit und Größe aufweist [29].

In der vorliegenden Arbeit wird eine Methode zur Änderungsanalyse vorgestellt. Da hier unter dem Begriff der Änderungsanalyse die Detektion als auch die weiterführende Verarbeitung der Änderungen verstanden wird (vergleiche oben vorgenommene Definition der Begrifflichkeiten), wird für nachstehende Beschreibungen eine zu den bisher erwähnten Einteilungen abweichende Anordnung verbreiteter Verfahren hinsichtlich des resultierenden beziehungsweise ableitbaren Informationsgehalts vorgenommen. Diese erfolgt in die drei Stufen gering, mittel und hoch (Abbildung 1.2), wobei der Sortierung der Methoden in diesen drei Kategorien jeweils keine besondere Ordnung zugrunde liegt. Verfahren, die speziell zur Verarbeitung optischer

Bilderzeugnisse entwickelt wurden (zum Beispiel *Tasselled Cap* [10]) werden hier nicht betrachtet. Methoden, die LiDAR-Höheninformationen oder GIS-Vektordaten verwenden, werden weiter unten als Sonderfälle behandelt.

Die erste Kategorie enthält Methoden, die einen geringen Informationsgehalt in den Ergebnissen zur Folge haben. Die zweite Kategorie umfasst Verfahren, die beispielsweise durch die Analyse von beschreibenden Merkmalen indirekt Hinweise auf die entsprechende Änderungsklasse zur Verfügung stellen. In der dritten Kategorie sind Ansätze enthalten, die eine mehr oder weniger umfassende Klassifikation oder Typbeschreibung der detektierten Änderungen ermöglichen.

Mit Bezug zu den jeweilig vorliegenden Bildelementen als Prozessierungseinheiten ist festzuhalten, dass die Abgrenzung zwischen pixel- und objektbasierten Methoden meist nicht eindeutig ist. Beispielsweise können für klassifikationsbasierte Ansätze grundsätzlich sowohl die einzelnen Pixel als auch Bildsegmente als Eingabe dienen. Um etwaige Widersprüche zu vermeiden, wird bei der hier gegebenen Einteilung der in [13] enthaltenen Gliederung gefolgt. Verfahren, bei denen die OBIA zum Einsatz kommt, sind entsprechend markiert (Abbildung 1.2).

Nachfolgend werden die in Abbildung 1.2 gelisteten Methoden erläutert, sowie Vor-, Nachteile und praktische Anwendungsbeispiele vorgestellt.

### **Beschreibung und Bewertung verbreiteter Verfahren**

Beginnend mit der einfachsten Abstraktionsebene, die in Abbildung 1.2 jene Methoden beinhaltet, die den geringsten Informationsgehalt des Ergebnisses zur Verfügung stellen, wird zunächst die Detektion von Änderungen anhand von Helligkeitsunterschieden betrachtet.

#### ***Geringer Informationsgehalt (Helligkeiten)***

Die wohl verbreitetste und bekannteste Methode zur Änderungsdetektion ist die *Bilddifferenz*. Im Fall optischer Bilddaten ist sie (bei günstigem Signal-Rausch-Verhältnis (*Signal to Noise Ratio SNR*)) unmittelbar anwendbar, da das dort enthaltene Rauschen additive Eigenschaft besitzt und die auf diese Weise produzierte Änderungsinformation aussagekräftigen Charakter aufweist. Als Detektionsgrundlage können in direkter Weise die radiometrischen Eigenschaften (Helligkeiten) der einzelnen Bildelemente dienen. In Anbetracht der Tatsache, dass die Detektionsgüte somit direkt von der Radiometrie der Pixel abhängt, müssen die Eingabebilder entsprechend vorprozessiert werden. Dazu gehören unter anderem radiometrische Kalibrierung, geometrische Rektifizierung und Bildregistrierung [13]. Vor diesem Hintergrund erscheint es sinnvoll, idealerweise Bilddaten desselben Sensors zu verwenden, um Unterschiede in der radiometrischen und geometrischen Auflösung von vornherein zu vermeiden [3]. Praktische Anwendungen der *Bilddifferenz* finden sich in [12].

Eine uneingeschränkt unmittelbare Anwendung der *Bilddifferenz* auf SAR-Bilddaten ist nicht zielführend, da der dort enthaltene Speckle multiplikativen Charakter aufweist. Aus diesem Grunde ist dieses Verfahren in der Praxis nicht verbreitet ([30], [31], [32] und [33]). Als klassische Methode zur Änderungsdetektion in SAR-Bildern ist der *Bildquotient* zu nennen [32].

Der *Bildquotient* repräsentiert ein Verfahren, das grundsätzlich auch für optische Daten nutzbar ist [34]. Ähnlich einfach umsetzbar wie die *Bilddifferenz* besitzt das Quotientenverfahren den Vorteil, dass etwaige, im Zusammenhang mit der Szenenkalibrierung auftretende Fehlereinflüsse reduziert werden ([13] und [10]). Beispiele praktischer Anwendungen finden sich im Umfeld umweltüberwachender Analysen [13], sowie in der Landnutzungskartierung ([10] und [15]). Im Umfeld der SAR-Bildauswertung wird der *Bildquotient* auch *Mean Ratio Detector* (MRD) genannt [32]:

$$X_{MRD} = 1 - \min\left(\frac{m_{t1}}{m_{t2}}, \frac{m_{t2}}{m_{t1}}\right), \quad (1.1)$$

wobei  $m_{t1}$  beziehungsweise  $m_{t2}$  die jeweiligen, in einem lokalen Fenster um das aktuelle Pixel berechneten Mittelwerte kennzeichnen.

Eine pixelweise Erstellung des Quotientenbildes ist ebenso möglich [33]. Um eine Weiterverarbeitung des Quotientenbildes anhand diverser Filteroperationen zu erleichtern, wird häufig eine Umwandlung des multiplikativen Rauschens in einen additiven Anteil mittels dekadischem Logarithmus durchgeführt [35]. Darüber hinaus werden auf diese Weise Änderungen in der für SAR-Bilder üblichen Einheit Dezibel [dB] dargestellt ([36] und [37]). In der Literatur ist diese Verarbeitungsweise als *LogRatio*-Methode (LR) verbreitet. MRD beziehungsweise LR werden als robust gegen den Einfluß des Speckle beschrieben. Allerdings sind sie auf den Vergleich von Statistiken erster Ordnung beschränkt, was sie für klassische progressive Detektionsverfahren unbrauchbar werden lässt [32]. LR beziehungsweise MRD sowie Modifikationen davon sind bislang in einer

Vielzahl praktischer Anwendungen zum Einsatz gekommen ([38], [39], [40] und [41]).

Eine äußerst einfache Herangehensweise zur Detektion von Änderungen ist durch die Subtraktion des *Bildhintergrunds* gegeben [10]. Hierbei wird davon ausgegangen, dass sich der (unveränderte) Hintergrund aus Pixeln zusammensetzt, die eine geringe radiometrische Dynamik aufweisen. Dieser Hintergrund wird beispielsweise durch Filterung des Originalbildes geschätzt und zur Detektion von Änderungen vom ursprünglichen Eingabebild abgezogen. Der einfachen Umsetzbarkeit steht eine geringe Genauigkeit gegenüber, was letzten Endes der Grund dafür ist, dass diese Methode bislang selten verwendet wurde [10]. Eine Anwendung auf SAR-Bilder ist lediglich theoretisch durchführbar, da der stark ausgeprägte Speckle-Effekt keine eindeutige Trennung von Bildvorder- und hintergrund erlaubt.

In [13] sind insgesamt drei Verfahrensweisen zur OBIA orientierten Änderungsdetektion enthalten, von denen die *Direkte Detektion* den geringsten Informationsgehalt liefert. Hierbei werden die Segmente einzelner Bilder verschiedener Zeitpunkte miteinander direkt verglichen, was das Verfahren ähnlich zu konventionellen, pixelbasierten Ansätzen werden lässt. Änderungen werden entweder durch Vergleich der geometrischen Eigenschaften, oder der spektralen beziehungsweise anderer extrahierter Merkmale (zum Beispiel Textur) der Segmente identifiziert [13]. Grundsätzlich können hierfür zwei Vorgehensweisen unterschieden werden. Die erste Vorgehensweise beschreibt die Segmentierung des Bildes zum Zeitpunkt  $t_1$  und die Zuweisung dieser Segmente zum Bild des Zeitpunktes  $t_2$ , ohne dieses erneut segmentieren zu müssen. Nachteilig hierbei ist, dass mögliche Änderungen ausschließlich Bezug zum Bild des Zeitpunktes  $t_1$  aufweisen. Bei der zweiten Methode werden die Bildsegmente der verschiedenen Zeitpunkte miteinander verglichen [13].

Bei der *Regression* wird von der Annahme ausgegangen, dass die Bildpixel zu einem Zeitpunkt  $t_2$  als lineare Funktionen der Pixel zu einem davor liegenden Zeitpunkt  $t_1$  dargestellt werden können. Darauf basierend wird eine Regressionsfunktion aufgestellt, um die veränderten Pixelwerte zum Zeitpunkt  $t_2$  abzuschätzen und auf diese Weise Änderungen zu identifizieren. Im Umkehrschluss bedeutet dies, dass die Detektionsgenauigkeit unmittelbar von der Parametrisierung der Regressionsfunktion abhängt, für die darüber hinaus noch geeignete Spektralbänder definiert werden müssen ([13] und [10]). Angewendet wurde die Regression beispielsweise zur Identifikation von Landbedeckungsveränderungen und zur Änderungsdetektion in tropischen Wäldern [15]. Eine Eignung oder gar eine Anwendung der Regression für SAR-Bilder wurde bisher nicht beschrieben.

Das Detektionsresultat aus der Regression ist, wie zuvor erwähnt, mit der Wahl geeigneter Spektralbänder korreliert. Diese pauschal vorhandene Unsicherheit in der Vorauswahl maßgeblicher Kanäle oder Bildmerkmale haben die meisten hier erwähnten Ansätze gemein. Eine Lösung dieser Problematik stellen lineare Transformationsverfahren dar, die als vorverarbeitender Schritt für eine Änderungsdetektion zum Einsatz kommen können.

In ihrer ursprünglichen Form ist die *Hauptkomponentenanalyse* (*Principal Component Analysis* PCA) eine Methode der multivariaten Datenauswertung. Das Ziel dabei ist die Reduzierung der Redundanz im vorliegenden Datensatz bei gleichzeitiger Maximierung der Varianz, um so die ursprünglich zumeist hochdimensionalen Daten auf wenige, aber aussagekräftige Variablen zu beschränken [42]. Übertragen auf den Themenbereich der Änderungsdetektion wird davon ausgegangen, dass sich nicht ändernde Bereiche zwischen zwei Bildern durch eine hohe Korrelation beschreiben lassen. Daraus resultiert die Annahme, dass Änderungsbereiche im Bildvergleich eine niedrige Korrelation aufweisen und die PCA derartige Gebiete auffindet. Grundsätzlich existieren zwei Herangehensweisen. Im Zuge der separaten Rotation (*separate rotation*) wird auf jedes Komponentenbild des Paares einzeln und unabhängig die PCA angewandt, bevor beispielsweise eine Bilddifferenz berechnet wird. Im Gegensatz dazu werden beim kombinierten Ansatz (*merged approach*) die Bilder miteinander fusioniert und anschließend mittels PCA ausgewertet [13]. Als Vorteil gilt, dass die Redundanz im Datensatz auf diese Weise bedeutend reduziert wird. Für die Änderungsdetektion maßgebliche Spektralkanäle sind somit leicht von eher ungeeigneten zu unterscheiden. Ein Nachteil ist, dass die Resultate einer PCA-getriebenen Änderungsdetektion von der jeweiligen Szene und vom jeweiligen Aufnahmzeitpunkt abhängig und demzufolge schwer interpretierbar sind. Bislang wurde die PCA mit der Ausrichtung Änderungsdetektion in der Bewertung von Landbedeckungsarten und von urbanen Gebieten, sowie bei Anwendungen mit forstwirtschaftlichem Bezug eingesetzt [10].

Basierend auf hyperspektralen Datensätzen gilt es generell, die hochdimensional kontinuierlich erfassten spektralen Informationen möglichst gewinnbringend zu berücksichtigen [43] - beispielsweise durch Nutzung der PCA. Eine weitere, im Umfeld hyperspektraler Bildauswertung verbreitete und der PCA ähnliche Methode ist die *Independent Component Analysis* (ICA). Im Vergleich zur PCA besitzt die ICA allerdings die Vorgabe, dass keine Eingangsvariable normalverteilt vorliegen darf [44]. Nach [45] lassen sich die hyperspektral

basierten Verfahren zur Änderungsdetektion generell in zwei Kategorien einteilen. Die erste Kategorie umfasst jene Methoden, die die spektralen Differenzen zwischen Bildelementen verschiedener Aufnahmezeitpunkte auswerten. Die zweite Kategorie beinhaltet Verfahren, die unter dem Begriff der *Anomaliedetektion* zusammengefasst werden ([46], [47], [48] und [49]).

Neben den bisher genannten, aus dem Umfeld der optischen Fernerkundung stammenden Methoden existieren für die Verarbeitung von SAR-Bildern weitere, einen geringen Informationsgehalt produzierende Methoden zur Änderungsdetektion ([32] und [35]). In [35] erfolgt eine Untergliederung inkohärenter, die Rückstreuintensität betrachteten Methoden (siehe oben) in präklassifizierende und postklassifizierende Vorgehensweisen, wovon hier die erste Gruppe betrachtet wird. Vertreter sind beispielsweise der *Constant False Alarm Rate* (CFAR) Detektor, *Multi Channel Segmentation* (MCS) ([35] und [50]), sowie *Adaptive Filtering* (AF) [35].

Die Verwendung des CFAR-Detektors ist nur sinnvoll, wenn die zu detektierenden Änderungen im Vergleich zur räumlichen Auflösung der Bilddaten kleinflächig sind und nur aus wenigen Pixeln bestehen [35].

Der Vorteil von MCS liegt darin, dass gleich mehrere, statistisch voneinander unabhängige Bilder derselben Szenerie miteinander kombiniert verarbeitet werden und so der Speckle-Anteil signifikant reduziert wird (siehe auch [51]). Wie in [50] beschrieben, wird die Segmentierung auf Basis einer Kantendetektion durchgeführt, um eine mögliche Untersegmentierung zu verhindern. Das Ergebnis der Änderungsdetektion ist somit nicht nur von der Segmentierung selbst, sondern auch von der Kantendetektion abhängig.

Die AF setzt sich nach [35] aus vier Verarbeitungsschritten zusammen. Grundlage dieser Methode ist die Erstellung eines Quotientenbildes aus dem auszuwertenden Bildpaar. In einem zweiten Schritt wird der im Quotientenbild enthaltene Rauschanteil durch Logarithmieren additiv gesetzt. Das skalierte Quotientenbild wird im Anschluss daran in einer geeigneten Art und Weise gefiltert, um die mögliche Falschalarmrate zu vermindern. Das maßgebliche Resultat des Verfahrens wird durch die Anwendung eines Schwellwertverfahrens erzeugt, das die Änderungen als Vordergrund einer binären Karte hervorhebt.

Eine weitere verbreitet im SAR-Umfeld genutzte Methode zur Änderungsdetektion existiert mit der *Kullback-Leibler-Divergenz* (KLD) ([32] und [52]). KLD ist eine Methode zur Messung der Ähnlichkeit zwischen Wahrscheinlichkeitsdichtefunktionen (*Probability Density Function* PDF), wobei verschiedene Ansätze zur Berechnung möglich sind [33]. Eine Variante der KLD wird in Abschnitt 6.3.1 mit der in dieser Arbeit eingesetzten Methode zur Änderungsdetektion (Abschnitt 3.1) verglichen.

### **Mittlerer Informationsgehalt (Merkmale)**

Im Rahmen der bisher erläuterten Methoden wird eine Änderungsinformation bereitgestellt, die keine detaillierte Analyse des Änderungstypus erlaubt. In der Gruppe *Mittlerer Informationsgehalt* sind Ansätze enthalten, die im Gegensatz dazu weiterführende Hinweise vermitteln. Unter derartigen Hinweisen werden hier Merkmale oder zeitliche Verläufe verstanden.

Die *Change vector analysis* (CVA) ist wie die *Regression* eine Methode, die ursprünglich aus dem Bereich der optischen Bildverarbeitung stammt [53]. Im Gegensatz zur *Regression* ist die CVA aber auch für (voll-polarimetrische) SAR-Bilder nutzbar [54]. Die CVA erlaubt die Nutzung der vollständigen spektralen Bildinformation und produziert zwei Resultate: Den Betrag, mit dem sich ein Pixel geändert hat, sowie die Trajektorie beziehungsweise die Richtung, in der sich das Pixel im Merkmalsraum änderungsbedingt bewegt [15]. Der Vorteil der CVA gegenüber anderen, bisher erwähnten Methoden liegt darin, dass damit neben der eigentlichen Identifikation der Änderungen noch charakterisierende Informationen ableitbar sind [10]. Aus diesem Vorteil folgt allerdings implizit auch der zentrale Nachteil des Verfahrens: Zwar liegen mit den Richtungen der Änderungsvektoren pro forma Informationen über den Typus der Änderungen vor, doch sind diese ohne eine Referenzdatengrundlage unsicher beziehungsweise schwierig zu beurteilen ([12] und [13]). Bisher wurde die CVA unter anderem für *Monitoring*-Anwendungen in der Landbedeckungsanalyse und für diverse Änderungsdetektionsaufgaben im Zuge von Landnutzungs-, Wald- und Katastrophenanalysen verwendet [13].

Bei der zuvor beschriebenen Verfahrensweise der *Bilddifferenz* können neben der Helligkeit der einzelnen Bildelemente weitere Merkmale bestimmt werden, die umfassender zum Verständnis der resultierenden Änderungsinformation beitragen. Als Beispiele hierfür können die Textur, morphologische Merkmale (siehe Abschnitt 2.2.1), oder der *Normalized Difference Vegetation Index* (NDVI) genannt werden, die für die Eingabebilder berechnet und untereinander verglichen werden ([32] und [12]). Der NDVI kann ebenfalls als Eingabeparameter für eine klassifikationsbasierte Änderungsdetektion dienen (siehe unten), wobei insbesondere auf eine Datengrundlage zu achten ist, deren Bilder zu identischen phänologischen Zeiträumen

aufgenommen wurden.

Mit Bezug zur objektorientierten (segmentbasierten) Verarbeitungsweise ist die *Multitemporale Detektion* zu erwähnen, bei der multitemporale Bilddaten zu einem Stapelbild kombiniert und als Ganzes segmentiert werden [13]. Die derart detektierten Bildobjekte dienen als Grundlage für einen Abgleich mit den einzelnen Eingabebildern des Stapels. Anhand statistischer Analysen werden Ausreißer erkannt, die in Zusammenhang mit Änderungen entstanden sind. Der Vorteil bei dieser Methode liegt darin, dass Segmente mit zeitlich konsistenter Geometrie und Lokalität resultieren. Dies wiederum setzt eine exakte Registrierung der Komponentenbilder des Stapels voraus. Limitierenden Einfluß haben zeitliche Variationen in der Szenenbeleuchtung und daraus folgende verändernde Beschattungscharakteristik besitzen. Da eine einzige Segmentierung des gesamten Stapels durchgeführt wird, bleiben unter Umständen durch einzelne Änderungen zu bestimmten Zeitpunkten hervorgerufene Bildobjekte unberücksichtigt [13].

In [55] ist eine Anwendung der objektbasierten Detektion einer urbanen Region anhand zweier RADARSAT-2-Szenen beschrieben. Die Bilder werden kombiniert anhand verschiedener *Scale Parameter* (siehe Abschnitt 2.2.4) segmentiert, um sowohl kleine als auch großflächigere Änderungen berücksichtigen zu können. In [56] wird eine objektbasierte Methode auf Basis zweier TSX-Aufnahmen des Stadtgebiets von Shanghai erläutert. Im Gegensatz zu [55] werden die beiden Bilder getrennt voneinander segmentiert und zur Erstellung einer Änderungskarte miteinander verglichen. Dieser Vergleich wird anhand einer modifizierten Version des *Bildquotienten* durchgeführt.

Weiterhin existieren für SAR-Bilder Verfahren, die entlang der zeitlichen Achse mittels statistischer Analysen heterogene Strukturen (Änderungen) detektieren. Diese können in die drei Kategorien *Rückstreuung*, *Kohärenz* und *Phase* unterteilt werden (Abbildung 1.2).

In [57] ist ein Ansatz vorgestellt, der anhand der Variation des Rückstreuoeffizienten *Sigma Nought* ( $\sigma^0$ ) Erntevorgänge in Reisfeldern beurteilt.

Neben dieser zeitlichen Rückstreuvariabilität nutzt man in [58] eine Langzeit-Kohärenzanalyse (*Long-Term Coherence Features*) zur automatisierten Identifikation von Änderungen in Landbedeckungsklassen. Eine ähnliche Vorgehensweise, hier aber mit dem Ziel der urbanen Änderungsdetektion, ist in [59] und [60] beschrieben. Die Rückstreu- sowie Kohärenzvariabilität entlang der Zeitachse werden zur Erstellung eines zweidimensionalen Histogramms zweier Differenzbilder verwendet, das wiederum die Grundlage für eine schwellwertbasierte Änderungsdetektion darstellt.

In [61] wird ein Konzept zur Analyse der Varianz genutzt, um auf Basis der Amplitudeninformation entlang einer Zeitreihe verschiedene Veränderungen an Zielobjekten zu erkennen.

Aufschluss über die Frequenz beziehungsweise Dynamik, mit der sich ein einzelnes Pixel entlang einer Zeitreihe ändert, bietet der in [62] enthaltene Ansatz, der ursprünglich auf der Berechnung einer symmetrischen Änderungsdetektionsmatrix basiert, die anhand statistischer Ähnlichkeitsanalysen berechnet wird.

In [63] ist ein Verfahren vorgestellt, welches detektierte Änderungen in Anlehnung an ihre temporale Signatur in Zeitreihendaten klassifiziert. Unterschieden werden hierfür die drei Klassen *step*, *impulse* und *cycle*.

Eine ähnliche Arbeit stellt [64] dar. In einem mehrstufigen Konzept, von dem der letzte Schritt die Änderungsklassifikation und die Beschreibung des temporalen Verhaltens sich ändernder Regionen beinhaltet, werden vier Klassen voneinander unterschieden: *Abrupte Änderungen* (Urban), *evolutionäre Änderungen* (Vegetation), *keine Änderungen* und *periodische Änderungen* (Vegetationsentwicklung bezogen auf saisonale Zeiträume).

Mit der Methode der *Persistent Scatterer Interferometry* (PSI) existiert ein weiteres Verfahren zur Analyse von SAR-Zeitreihen, das zur Detektion von Veränderungen eingesetzt werden kann. PSI gehört zur Kategorie der *Differential Interferometric SAR* (DInSAR) Techniken und wird zur Detektion sowie Überwachung von Oberflächendeformationen verwendet [65]. Im Unterschied zu amplitudenbasierten Methoden wird bei der PSI die interferometrische Phase von mindestens zwei komplexwertigen SAR-Bildern ausgewertet [66]. In [67] wird ein Ansatz zur kombinierten Verwendung von PSI und einer herkömmlichen, pixelbasierten Herangehensweise zur Detektion von Veränderungen auf Objektebene (Gebäude), als auch zur Erkennung von Oberflächendeformationen beschrieben.

### **Hoher Informationsgehalt (Klassen)**

In dieser Kategorie sind Verfahren gelistet, die umfangreiche Informationen über den Typus oder die Klasse der detektierten Änderung bereitstellen.

Aus dem Umfeld des maschinellen Lernens sind mit den *Künstlichen Neuronalen Netzen* (KNN) und den *Supportvektormaschinen* (*Support Vector Machines* SVM) zwei verbreitete Vertreter zu nennen. Bei beiden handelt es sich um nichtparametrische Verfahren, die keine Annahmen bezüglich der statistischen Verteilung der Eingabedaten erfordern. Dem gegenüber steht die Forderung nach einer mehr oder weniger umfassenden und qualitativ hochwertigen Trainingsdatenbasis, deren Umfang und Güte direkte Auswirkung auf die

Qualität der Änderungsdetektion hat [13].

Weitere klassifikationsbasierte Ansätze sind der *Postklassifikationsvergleich* und die *Vegetationsdifferenz*, die eine Klassifikation der Eingabebilder entsprechend den vorliegenden Aufgabenstellungen voraussetzen. Der Vorteil dieser Ansätze liegt darin, dass neben der einfachen, binären Information (Änderung / keine Änderung) Hinweise zur Änderungsentstehung ableitbar sind. Die Güte der Klassifikation wirkt sich dabei unmittelbar auf die Qualität des Detektionsresultats aus. Die Klassifikation selbst kann überwacht oder unüberwacht durch Anwendung verschiedener Verfahrensweisen (zum Beispiel *fuzzy*-basiert, vergleiche Abschnitt 2.2.7) erfolgen.

Die überwachte Herangehensweise erfordert Trainingsdaten, deren Qualität, Genauigkeit und Vollständigkeit unmittelbar entscheidend für die Gesamtgüte der Änderungsanalyse ist. Darüber hinaus ist die Selektion geeigneter Trainingsdaten sowohl schwierig als auch zeitaufwendig [13]. Im Gegensatz dazu benötigen unüberwachte Klassifikationsverfahren keine Trainingsdaten. Auf Basis beispielsweise spektraler Eigenschaften werden die Bildelemente (Pixel oder Segmente) im Zuge automatisierter *Clustering*-Verfahren (siehe auch Abschnitt 2.2.6) geeigneten Gruppierungen (Clustern) zugeordnet. Für diese Vorgehensweise benötigt man Referenzdaten zur Interpretation der resultierenden Gruppierungen [34].

Bei der *Vegetationsdifferenz* erfolgt die Änderungsdetektion im Anschluss an eine separate Vegetationsklassifikation (zum Beispiel mittels NDVI) der beteiligten Bilder und wird anhand standardisierter Verfahren wie *Bilddifferenz* oder *Bildquotient* durchgeführt [13]. Der Vorteil der *Vegetationsdifferenz* ist die Reduzierung topografisch bedingter Einflüsse sowie Beleuchtungseffekte. Nachteilig ist die verstärkende Wirkung von in den Daten enthaltenen Rauschanteilen ([13] und [10]). Als ebenso nachteilig ist der Umstand zu erwähnen, dass diese Methode die Präsenz aktiver (grüner) Vegetation in Interessengebieten voraussetzt. Nur, wenn dies vorhanden ist, können überhaupt Änderungen detektiert werden. Dennoch existieren mehrere Anwendungsbeispiele für die *Vegetationsdifferenz* ([12], [13] und [10]). Sie ist indirekt und in abgewandelter Form auf SAR-Bilddaten übertragbar, da der Variationskoeffizient (*Coefficient of variation Cov*) zur Klassifikation von Waldgebieten genutzt werden kann [68].

Hinsichtlich des *Postklassifikationsvergleichs* findet sich beispielsweise in [69] eine Anwendung, bei der die urbane Struktur von Bukarest (Rumänien) beziehungsweise deren Entwicklung anhand multispektraler und multitemporaler Daten analysiert wird. *Ground Truth* (GT) Referenzdaten dienen als Trainingsgrundlage für eine überwachte *Maximum Likelihood* (MaLi) Klassifikation der einzelnen Eingabebilder. Die Detektion von Änderungen beziehungsweise deren Analyse erfolgt durch Vergleich der Klassifikationsergebnisse, die als effizientes Werkzeug zur Erkennung des Änderungstypus beschrieben werden. Darüber hinaus kommt der *Postklassifikationsvergleich* bei einigen weiteren Arbeiten zur Anwendung ([70], [71] und [72]).

Satellitengestützt und segmentbasiert wird in [73] vorgegangen. Die Detektion der Änderungen wird hier mittels der MAD-Methode (*Multivariate-Alteration-Detection*) anhand momentbasierter, objektorientierter Merkmale durchgeführt, die wiederum die Grundlage für die Änderungsklassifikation mit neuronalem Netz bildet.

Mit Bezug zur SAR-Bildanalyse wird in [74] die beurteilende Charakterisierung detekтирter Änderungen als oftmals bedeutender als die alleinige Detektion beschrieben. Für den dort enthaltenen Ansatz werden zwei TSX *StripMap*-Bilder zur Änderungsdetektion genutzt, wobei sowohl der *Bildquotient* als auch Kohärenzinformation berücksichtigt werden. Die Beurteilung der Änderungen erfolgt kontextbezogen anhand einer auf dem *pre-event* Bild durchgeführten segmentbasierten Landbedeckungsklassifikation (Beispielklassen *Urban*, *Wald*) die direkt abhängig von der Klassifikationsgüte ist.

In [75] wird eine Methode bestehend aus drei zentralen Schritten vorgeschlagen: Segmentierung multitemporaler, hochauflösender luftgestützter X-Band SAR-Daten in sogenannte *SLIC Superpixel* [76], objektbasierte Merkmalsextraktion und Klassifikation. Letzteres wird anhand eines überwachten *Multilayer-Perceptron*-Lernverfahrens durchgeführt, wobei folgende Klassen unterschieden werden: *Keine Änderung*, *Abholzung* beziehungsweise *Abforstung* und *andere Änderungen*. Für jede dieser Klassen wurden mit Hilfe von Expertenwissen stichprobenartig Trainingsgebiete erhoben.

Sowohl optische als auch SAR-Bilddaten können darüber hinaus kombiniert zur Änderungsanalyse genutzt werden. Beide Sensorerzeugnisse stellen durch ihre jeweils spezifischen Vorteile komplementär nutzbare Informationen zur Verfügung, die für die Ableitung präziser Änderungsaussagen verwendet werden können ([77] und [78]).

In [79] wird ein Ansatz zur postklassifizierenden Änderungsdetektion anhand multitemporaler RADARSAT-Bilder sowie einer Landsat-Aufnahme beschrieben. Zur Segmentierung der SAR-Bilder wurde die Software

*eCognition* (siehe oben) benutzt. Als Merkmale zur Klassifikation wurden sowohl radiometrische, formbeschreibende, als auch Texturparameter verwendet. Die Landsat-Szene wurde aufgrund des Fehlens von Referenzdaten zum Aufnahmezeitpunkt mit unüberwachten Methoden wie *k-means* und *ISODATA* klassifiziert. Die Detektion von Veränderungen erfolgte durch *Bilddifferenz* anhand der RADARSAT-beziehungsweise Landsat-Klassifikationsergebnisse. Obwohl die Resultate der Änderungsdetektion einen hohen Rauschanteil aufgrund von Klassifikationsfehlern besitzen, konnten bedeutende Änderungen detektiert werden.

In [80] werden die Detektionsresultate eines SAR- (ALOS PALSAR), sowie eines optischen Bildpaars miteinander fusioniert. Die Änderungsdetektion anhand des SAR-Bildpaars erfolgte mittels eines normalisierten Differenzquotienten, die der Landsat-Bilder durch *Vegetationsdifferenz*. Mittels Fusion der Detektionen wurden Veränderungen in verschiedenen Ausprägungen beurteilt (zum Beispiel *bebautes Gebiet* zu *Vegetation*). Gegenüber der separaten Nutzung konnte eine Zunahme der Detektionsgenauigkeit beobachtet werden. In [81] werden je eine SAR- (RADARSAT-1) und eine SPOT5-Aufnahme eines suburbanen Gebietes getrennt voneinander mit dem Ziel der Detektion von Landbedeckungsformen (unter anderem *Urban*, *Vegetation*, *Gewässer*) klassifiziert. Resultierende Änderungen werden in die beiden Klassen *negativ* und *positiv* unterschieden. Als Gesamtgenauigkeit hinsichtlich der Detektionsgüte wurde ein Wert von ungefähr 63 % beobachtet. Durch Anwendung hochauflösender und polarimetrischer SAR-Bilddaten (CSK und TSX) erhofft man sich eine signifikante Genauigkeitssteigerung.

In [82] wird ein Ansatz zur automatischen Detektion von sturmbedingten Waldschäden basierend auf Multispektral- und SAR-Daten beschrieben. Aufschlüsse über potentielle Waldschäden und damit einhergehende Veränderungen im Waldbestand liefert hierbei die Extraktion der entsprechenden Gebietsgrenzen. Es zeigte sich, dass die komplementäre Nutzung von optischen und SAR-Bilddaten eine schnelle Schadensabschätzung ermöglicht.

In [10] werden unter Methoden zur *hybriden Detektion* Ansätze verstanden, die einfache Detektionsverfahren mit komplexeren, klassifikationsbasierten Methoden kombinieren. Hierbei liegt die Idee zugrunde, die Falschklassifikationsrate zu minimieren, da unveränderte Bildbereiche nicht in den Arbeitsablauf eingehen. Diese Minimierung erfordert somit eine möglichst präzise Detektionsentscheidung anhand eines Schwellwerts, der zuverlässig zwischen *Änderung* und *keine Änderung* unterscheidet. Die Ableitung eines solchen Schwellwerts kann sowohl manuell als auch unüberwacht erfolgen [83]. Eine detaillierte Beschreibung der gängigsten Methoden zur unüberwachten Schwellwertbestimmung findet sich in [84]. Diese lassen sich ein teilen in histogramm-, *Clustering*-, objektattribut- und entropiebasierte Verfahren. Darüber hinaus existieren noch räumlich-orientierte sowie lokale Methoden. Ein kurzer Überblick über entropiebasierte Verfahren zur Schwellwertermittlung befindet sich in Abschnitt 2.2.2 dieser Arbeit.

Zur Ermittlung eines optimalen Schwellwerts bei der SAR-basierten Änderungsdetektion existieren verschiedene Vorgehensweisen. Zeitlich weiter zurückliegende Arbeiten nutzten das Grauerthistogramm des Differenzbildes zur Ableitung des Schwellwerts, andere nutzten die Entropie als Entscheidungskriterium. Eine weitere geläufige Methode ist das nach *Kittler* und *Illingworth* benannte KI-Verfahren, das davon ausgeht, dass die statistische Verteilung der Grauwerte im Bild bekannt ist und darauf basierend den Schwellwert als Resultat einer kleinste-Fehler-Optimierung berechnet [85]. In [86] wird ein zur Detektion von Änderungen verwendeter Schwellwert durch die Methode der *Gaussian Mixture Models* bestimmt, das vereinfacht ausgedrückt die in den Daten enthaltenen Teileinformationen (*Änderung*, *keine Änderung*) aus einer statistischen Gesamtverteilung des Bildes separiert. Zwei wahrscheinlichkeitstheoretische Ansätze zur Schwellwertberechnung basierend auf der *Bayes-Statistik* sind in [87] erläutert. Der erste Ansatz beschreibt den Schwellwert als Resultat eines Schätzverfahrens zur Minimierung des gesamten Detektionsfehlers auf Grund der Annahme, dass alle Pixel statistisch voneinander unabhängig sind. Der zweite Ansatz beurteilt darüber hinaus den räumlichen Nachbarschaftskontext eines jeden Pixels anhand der MRF-Methode (*Markov Random Fields*). Da beide Ansätze die Kenntnis über die statistische Verteilung des Differenzbildes voraussetzen, wird eine iterative Version des *Expectation-Maximization*-Algorithmus verwendet, der die benötigten a-priori Wahrscheinlichkeiten sowie PDFs schätzt. Vor dem Hintergrund dieser enormen Vielfalt an Methoden zur Bestimmung eines geeigneten Schwellwerts lässt sich festhalten, dass ein für alle Datensätze nutzbares und optimales Schwellwertverfahren nicht existiert. Dieses ist vielmehr in Abhängigkeit der jeweiligen Anforderung sowie der vorliegenden Datengrundlage zu wählen.

### Sonderfälle

Neben den bisherig erläuterten Methoden zur Änderungsdetektion und -analyse anhand zweidimensionaler Bilddaten werden nachfolgend Sonderfälle beschrieben, die sich aufgrund der oben genannten sonstigen aktiven Sensorik (LiDAR) sowie der thematischen Informationsebene ergeben. Diese sollen lediglich aus

Aspekte der Vollständigkeit erwähnt werden und sind nicht Teil der in dieser Arbeit vorgestellten Verfahrensweise. Weiterhin werden ergänzend dazu noch einfache Methoden der visuellen Interpretation erwähnt.

Im Hinblick auf die Kategorie des geringen Informationsgehalts ist in [88] ein Anwendungsbeispiel gegeben. Dort werden mit LiDAR erfasste Punkt wolken genutzt, um Baumbestände in urbanem Gebiet zu modellieren und darauf bezogene Änderungen zu erkennen. Veränderungen an einzelnen Baum- sowie Waldbeständen sind in [89] thematisiert, wobei multitemporale LiDAR-Daten verschiedener Punktdichten verwendet werden. In [90] ist ein Ansatz enthalten, der durch Fusion zweidimensionaler und dreidimensionaler Information in die mittlere Kategorie eingegliedert werden kann. Dort werden Laserhöhendaten mit Luftbildern zur gemeinsamen Nutzung von geometrischen sowie spektralen Merkmalen kombiniert.

In [13] und [10] sind Methoden enthalten, die thematische Karteninformation (GIS) in den Detektionsprozess integrieren, um weiterführende Informationen über die resultierenden Änderungen zur Verfügung zu stellen. Beispiele praktischer Anwendungen sind beispielsweise in [91] und [92] gegeben. Im ersten Fall kommt eine überwachte MaLi-Klassifikation zum Einsatz. Diese erfolgt segmentbasiert anhand optischer Luftbilder mittels automatisch erfasster, GIS-basierter (ATKIS) Trainingsdaten. In [92] erfolgt die Änderungsdetektion auf Grundlage von linienförmigen, gebietsorientierten und geländebezogenen Merkmalen, wobei jeweils semantische und nicht semantische Informationen berücksichtigt werden.

Als gänzlich überwachte und manuelle Verfahrensweise zur Detektion von Änderungen dienen sämtliche Methoden zur Visualisierung anhand geeigneter Kombinationen der Eingangsbilder zu Farbkompositen, die mehr oder weniger detailliertes Wissen und Erfahrung von Seiten des Anwenders voraussetzen [10]. Eine ähnliche Vorgehensweise verfolgt die für interferometrische SAR-Bildpaare entwickelte *CovAmCoh*-Methode (exemplarisch [93], Abschnitt 2.1), bei der die drei Bildlayer Cov, Amplitude und Kohärenz zu einem RGB-Farbbild kombiniert werden. Neben der Erkennung sich verändernder, inkohärenter Bildbereichen ermöglicht *CovAmCoh* auch die wissensbasierte Klassifikation von Landnutzungs- / Landbedeckungsformen (*Land Use / Land Cover LULC*).

Neben diesen Darstellungsverfahren zur visuellen Markierung von Änderungen können entsprechende Bildbereiche ebenfalls in überwachter Art und Weise händisch durch Nutzung von *Flicker* (etwa: Flackern) und *Swipe* (etwa: Wischen) detektiert werden. Im Ersten der beiden Fälle werden Eingangsbilder in schneller Wiederholfrequenz abwechselnd am Bildschirm dargestellt, um so vorhandene Änderungen erkennen zu können. Bei der Wischmethode werden die Eingangsbilder überlagert visualisiert und das oben befindliche Bild beispielsweise durch *Drag and Drop* über das untere Bild hinweg geschoben. Beide Herangehensweisen erfordern bei hoher Fehleranfälligkeit ein relativ hohes Maß an Expertenwissen über die jeweilig genutzte Sensorik und die vorliegende Szene und sind deshalb nur als untergeordnete Detektionsverfahren zu betrachten.

### **Bewertung und Ableitung von Anforderungen**

Anhand der zuvor erläuterten Ausführungen zu den einzelnen Methoden lässt sich eine Bewertung vornehmen, die zur Beurteilung einer Eignung für eine Änderungsanalyse dient.

Als potentiell nutzbare Ansätze kommen nur jene Verfahren in Betracht, die einen hohen Informationsgehalt generieren, der für eine weiterführende und detaillierte Auswertung der Änderungskategorie oder -klasse zur Verfügung steht. Der Nutzen und die Wichtigkeit derartiger klassifikationsbasierter Ansätze wurde ebenfalls in [10] und [16] herausgestellt.

So wird die Detektion von Änderungen anhand von Klassifikationsverfahren als vorteilhaft gegenüber einfacheren, schwellwertbasierten Methoden beschrieben, da auf diese Weise Falschalarme durch variierende, phänologische Bewuchsstadien reduziert werden [10]:

... Those change detection techniques based on determination of thresholds for identification of changes from unchanged areas have a common problem: it is difficult to distinguish true changed areas from the detected change areas. For example, in agricultural lands, the change detection based on thresholds is often misleading due to the different phenological characteristics of crops. Change detection based on classification methods can avoid such problems, but requires considerable effort to implement classification ...

In derselben Arbeit werden für ein neues Verfahren zur Änderungsdetektion weiterhin zwei Kernaspekte genannt:

... For a new change detection technique, it is important to be able to implement it easily and for it to provide accurate change detection results associated with change trajectories ...

Ein solches Verfahren sollte also möglichst einfach in seiner Umsetzung sein und gleichzeitig verlässliche und präzise Detektionsergebnisse produzieren, die weiterhin Rückschlüsse auf den Typ (hier: Trajektorien, siehe auch oben die CVA-Methode) erlauben. Für eine detaillierte Detektion von LULC-Veränderungen wird der

*Postklassifikationsvergleich* als passende Methode erwähnt, allerdings nur, wenn geeignete Trainingsdaten zur Verfügung stehen [10]:

*... For a detailed 'from-to' detection, post-classification comparison is a suitable method to implement when sufficient training sample data are available ....*

Der Aufwand zur Erstellung einer Klassifikation, sowie die Berücksichtigung geeigneter Trainingsdaten sind als limitierende Aspekte zu erwähnen, die das entsprechende Verfahren sowohl komplex als auch unflexibel und schwer übertragbar werden lässt. In [3] finden sich unterstützend dazu entsprechende Ausführungen (siehe auch Abschnitt 5.1). Ergänzend ist die Erfahrung und die Expertise von Seiten des Nutzers zu nennen, die zur Erstellung einer Klassifikation notwendig ist.

Ähnliche Aussagen finden sich in [16], wo ebenfalls der *Postklassifikationsvergleich* als das Maß der Dinge zur Änderungsanalyse erachtet wird:

*... Post-classification comparison was found to be the most accurate procedure and presented the advantage of indicating the nature of the changes ...*

In den hier betrachteten Verweisen findet sich darüber hinaus die Aussage, dass es ein generell für alle Anwendungen optimales Verfahren zur Änderungsdetektion nicht gibt. Jeder Ansatz besitzt seine spezifischen Vor- und Nachteile, die in Anbetracht der jeweilig existierenden Aufgabe und der zu analysierenden Szene und der zugrunde liegenden Sensorik abgewägt werden müssen [10]:

*... Although a variety of change detection techniques have been developed, it is still difficult to select a suitable method to implement accurate change detection for a specific research purpose or study area ...*

Darauf aufbauend ergeben sich einige zentrale Anforderungen, die ein Verfahren zur Änderungsanalyse zu erfüllen hat:

- Änderungsdetektion
  - ... einfach und übertragbar (keine Nutzerinteraktion, unüberwacht)
  - ... robust (verlässliche und präzise Ergebnisse)
- Weiterführende Analyse
  - ... einfach und übertragbar (keine Trainingsdaten)
  - ... nutzerfreundlich (Fachwissen nicht erforderlich)

Zur Ableitung der Klasse oder des Typs einer Änderung scheint nach Sichtung der Literatur die Existenz mindestens einer aussagekräftigen Klassifikationsreferenz für die auszuwertende Szene dennoch unabdingbar zu sein.

Muss eine solche Klassifikation erfolgen oder vorhanden sein, um eine für die jeweilige Szene zielführende Auswertung der erkannten Veränderungen und der beteiligten Landnutzungsformen zu erlauben? Wäre es nicht bedeutend einfacher und auch praktikabler, wenn dem Anwender eine für die tatsächlich vorliegende Datengrundlage optimale Klassenstruktur auf automatischer Weise empfohlen werden würde?

Ein derartiges Verfahren wäre sowohl einfach und nutzerfreundlich, da es auch für Anwender ohne spezielles Fachwissen anwendbar wäre. Weiterhin wäre es unabhängig von der Existenz bestmöglichster Trainingsdaten, wodurch eine gute Übertragbarkeit sichergestellt wäre.

## 1.2. Beitrag

Anhand der zuvor abgeleiteten Anforderungen an ein Verfahren zur Änderungsanalyse wird in diesem Abschnitt der Beitrag dieser Arbeit mittels der Formulierung von Thesen beschrieben. Da hier unter einer Änderungsanalyse sowohl die Detektion als auch die weiterführende Analyse (zum Beispiel Typisierung) der Änderungen verstanden wird, werden beide Teilaufgaben als solche eigenständig behandelt.

### **Verfahren zur Änderungsdetektion**

Es soll eine einfache Methode zur Änderungsdetektion in Zeitreihen hochauflöster SAR-Zeitreihendaten umgesetzt werden, die gleichzeitig über eine gute Übertragbarkeit verfügt. Einfach bedeutet hierbei, dass das Verfahren über eine minimale Anzahl an Eingabeparametern verfügt und zugleich so unüberwacht wie möglich (geringer Anteil an notwendiger Nutzerinteraktion) abläuft. Eine gute Übertragbarkeit der Methode ist gegeben, wenn sie ohne umfangreiche Anpassungen auf Eingabebilder anderer Sensoren anwendbar ist. Da derartige Bilddaten selten über identische räumliche Auflösungen (Pixelgrößen) verfügen, wäre ein Verfahren sinnvoll, das eine flexible Handhabung der jeweilig gewünschten Größe der Änderungsobjekte erlaubt. Darüber hinaus ist es erstrebenswert, dass das Verfahren unabhängig von der genutzten Datengrundlage verlässliche und präzise Ergebnisse bereitstellt. Diese Eigenschaft ist nachzuweisen.

In Anbetracht dieser Forderungen kommt als Detektionsmethode das oben beschriebene und für SAR-Bilder weit verbreitete LR-Verfahren zum Einsatz. Dies besitzt den Vorteil der Anwendung ohne weitere Parametrisierung und liefert in einfacher und berechnungszeitgünstiger Art Hinweise auf sich verändernde Bildregionen. Genau genommen wird eine Modifikation des LR-Operators genutzt, die mit Bezug zu einem Bildpaar die Nutzung des Maximalwerts aus beiden möglichen Quotientenbildern darstellt. So wird sichergestellt, dass sowohl negative (verschwindende) als auch positive (erscheinende) Änderungen erkannt werden. In [94] wird diese Verarbeitung als normalisierte Messung des Kontrasts zwischen zwei Aufnahmezeitpunkten beschrieben.

Da das so berechnete Hinweisbild (maximales Quotientenbild) über einen großen Rauschanteil verfügt, der ohne Elimierung eine große Anzahl an Falschdetektion verursachen würde, kommt das für derartige Bilddaten besonders geeignete morphologische Prinzip der *Alternierenden Sequentiellen Filter* (ASF) zum Einsatz [29]. Neben ihrer rauschmindernden Eigenschaft besitzen die ASF nach geringfügiger Manipulation (Nutzung von Attributfiltern) den Vorteil, dass gezielt aus der jeweiligen Aufgabenstellung geforderte Größen der Änderungsobjekte (kleinräumige Objekte wie Fahrzeuge) detektiert werden können. Daraus folgt eine äußerst flexible Handhabung auch im Hinblick auf unterschiedlich vorliegende räumliche Auflösungen (siehe oben).

Die letzliche Detektion der Änderungen anhand des aus dem LR-Verfahren abgeleiteten Hinweisbilds (maximales Quotientenbild) und die Erstellung einer binären Änderungskarte erfolgt unüberwacht durch Anwendung des entropiebasierten Ansatzes zur Schwellwertberechnung nach Renyi [95].

Durch Nutzung einer Zeitreihe aus temporär aufeinander folgenden Daten wird die Detektion von Bildbereichen ermöglicht, die sich entlang der betrachteten Periode unterschiedlich oft verändern. Insbesondere die Erkennung sogenannter Hochaktivitätsregionen stellt den aus dem Bildstapel extrahierbaren Mehrwert dar. Die Identifikation solcher Gebiete ist mit dem Verfahren nachzuweisen.

### **Weiterführende Analyse detekter Änderungen**

Mit der im vorherigen Abschnitt dargelegten Literaturrecherche wurde gezeigt, dass die Verwendung eines Klassifikationsresultats zur Extraktion beschreibender Informationen über die detektierten Änderungen die gängige Strategie darstellt. Weiterhin wurde aufgezeigt, dass die hauptsächliche Schwierigkeit bei dieser Verfahrensweise darin besteht, geeignete Trainingsdaten zu selektieren oder bereits vorliegen zu haben. In beiden Fällen ist die Sachlage, dass auch tatsächlich zielführende Trainingsdaten verfügbar sind, nicht immer eindeutig. Sowohl der Bearbeitungsaufwand als auch die Notwendigkeit eines gewissen Maßes an Erfahrung und Wissen von Nutzerseite stehen im Widerspruch zu einem möglichst einfachen und nutzerfreundlichen Verfahren. Eine gute Übertragbarkeit solch trainierter Klassifikationen auf andere Datensätze (Szenen, Sensoren) ist ebenfalls nicht immer gegeben. Die Alternative zu derart überwachten Ansätzen heißt unüberwachte oder automatische Klassifikation, die ohne Trainingsdaten auskommt, dafür aber ein detailliertes Wissen über die jeweilige Szenerie und umfassende Referenzdaten voraussetzt (siehe auch [3]). Dies steht ebenfalls im Gegensatz zu den oben formulierten Anforderungen.

In Konsequenz daraus wird in der vorliegenden Arbeit eine Methode zur Kategorisierung und Klassifikation detekter Änderungen vorgestellt, die größtenteils ohne Referenz- und Trainingsdaten auskommt. Der entsprechende Algorithmus prozessiert weitgehend unüberwacht durch Verwendung einer gering gehaltenen Parametrisierung, um so eine gute Generalisierbarkeit sicherzustellen. Ferner wird kein detailliertes Wissen über die Daten oder die Szenerie vorausgesetzt. Die Methode ist derart konzipiert, dass der Anwender durch das Verfahren die notwendigen Erkenntnisse über den jeweilig in den Daten enthaltenen und für eine zielgerichtete Klassifikation erforderlichen Informationsgehalt vermittelt bekommt. Als Grundlage dafür dient dem Algorithmus ein durch den Nutzer beliebig definierter Klassenkatalog, der im weiteren Verlauf in Abstimmung mit der tatsächlich vorhandenen Datenrealität iterativ optimiert wird. Letztlich wird mit dieser Methode überprüft, ob eine manuell selektierte LULC-Klasse in dieser Datenrealität abgebildet wird. Der Anwender erlernt demzufolge eine zielführende Klasseneinteilung in Bezug auf die Änderungsobjekte.

Die Robustheit und Verlässlichkeit des Ansatzes ist zum Beispiel anhand variierender Klassenkataloge zu überprüfen.

## **1.3. Aufbau**

Die Arbeit ist wie folgt gegliedert.

In Kapitel 2 werden theoretische Grundlagen vermittelt, die für ein besseres Verständnis der anschließenden Ausführungen notwendig sind. Der Detailgrad dieser Ausführungen richtet sich nach der Notwendigkeit, weshalb auf umfassende Erläuterungen sämtlicher Hintergründe verzichtet wird. Dem interessierten Leser werden für eine weiterführende Recherche entsprechende Literaturverweise genannt.

Abschnitt 2.1 enthält essentielle Ausführungen zur satellitengestützten Fernerkundung mit SAR, wie beispielsweise zur Aufnahmogeometrie, zu Abbildungseffekten und Bildprodukten. In Abschnitt 2.2 sind die zur Anwendung kommenden Methoden der Bildanalyse dargestellt, die zur Merkmalsextraktion genutzt werden.

Mit Kapitel 3 beginnt die Beschreibung des Verfahrens zur Änderungsanalyse mit der Erläuterung der Methode zur Änderungsdetektion. Zunächst wird in Abschnitt 3.1 die grundlegende Vorgehensweise zur Erkennung abruper Änderungen zwischen Amplitudenbildpaaren erklärt. Im Anschluss daran erfolgt in Abschnitt 3.2 die Anwendung auf Zeitreihendaten, die in der Berechnung der Index-, sowie der Aktivitätskarteninformation mündet. Darüber hinaus wird die Vorgehensweise zur Identifikation der hochfrequenten Änderungssegmente thematisiert, die die Basis für die Kategorisierung und Klassifikation darstellen.

Die Grundlage für die Kategorisierung ist die Merkmalsextraktion, die für jedes Änderungssegment durchgeführt und in Kapitel 4 behandelt wird. Zu Beginn erfolgt in Abschnitt 4.1 ein kurzer Überblick über den Stand der Technik hinsichtlich gängiger beziehungsweise verbreiteter Merkmale. Die verwendeten Merkmale sowie deren Ausprägungen sind Gegenstand des daran anschließenden Abschnitts 4.2.

Kapitel 5 enthält das im Rahmen dieser Arbeit entwickelte Konzept zur Analyse der detektierten Änderungen (Abschnitt 5.1), das sich in zwei zentrale Schritte gliedern lässt: Der Kategorisierung der Änderungssegmente anhand der zuvor extrahierten Merkmalsausprägungen, sowie die iterative Optimierung eines vorab definierten Klassenkatalogs. Auf Basis einer optimalen Klassenstruktur erfolgt abschließend eine *fuzzy*-orientierte Klassifikation der Änderungsobjekte. Abschnitt 5.2 enthält die entsprechenden Verarbeitungsschritte.

Die Anwendung des Verfahrens auf Testdaten ist in Kapitel 6 enthalten. Neben dem primär genutzten Datensatz, der durch eine Zeitreihe aus 15 TSX-Amplitudenbildern gegeben ist und die Szene „Stuttgart Flughafen“ darstellt, wurden zur Verifikation als weiterer Testbildstapel 12 TSX-Amplitudenbilder des Ortes Greding verwendet (Datensatz „Greding“). Neben der Beschreibung der jeweiligen Szenen und Daten erfolgt weiterhin eine Darlegung der durchgeführten Vorverarbeitungsschritte (Abschnitt 6.1). In Abschnitt 6.2 werden die Ergebnisse der Änderungsanalyse für beide Testszenen behandelt, wobei der Fokus auf die Serie „Stuttgart Flughafen“ gesetzt wird. Im Anschluss werden in Abschnitt 6.3 einige Parametervariationen sowie weitere, im Zusammenhang mit der vorgestellten Thematik durchgeführte Untersuchungen geschildert.

Die Arbeit endet mit einer zusammenfassenden und bewertenden Diskussion, sowie mit der Beschreibung möglicher Anknüpfungspunkte für künftige Arbeiten (Kapitel 7).

## Kapitel 2.

# Grundlagen der Fernerkundung und Bildanalyse

Dafür, dass uns immer und überall Produkte der Geodäsie und der Geoinformatik begegnen, nehmen nur wenige Menschen bewusst davon Kenntnis. Kein Bauvorhaben könnte ohne vermessungstechnisches Wissen realisiert werden. Kein Navigationsgerät würde ohne eine entsprechende Datenbasis funktionieren. Im Gegensatz zu solch offensichtlichen Beispielen ist die Fernerkundung als Teilgebiet der Geodäsie für viele Mitmenschen noch weniger verständlich, da noch weniger ersichtlich und greifbar. Dies ist dadurch begründet, dass Objekte oder Szenen aus der *Ferne erkundet* werden, ohne mit diesen in direkten Kontakt treten zu müssen. Aus diesem Grund im Alltag praktisch unsichtbar, erheben fernerkundliche Satellitensysteme Informationen, die in vielerlei Hinsicht von essentieller Bedeutung sind. Eines der bekanntesten Anwendungsfelder ist wohl die Meteorologie, die mittels geostationärer Satelliten durchgängig Auskünfte zur aktuellen Wetterlage bereitstellt.

Neben diesen Satelliten existieren weitere bildgebende Sensoren unterschiedlicher Ausprägung (zum Beispiel passiv und aktiv), die vom Weltraum aus Daten über die Erde aufzeichnen und zur Verfügung stellen. Neben den bisher genannten Anwendungsfeldern existieren weitere, vielfältige Aufgabenbereiche, die den enormen Nutzen der Fernerkundung mit Satelliten zeigen. So werden beispielsweise in der Versicherungsindustrie fernerkundlich gewonnene Erkenntnisse zur Risikobewertung (Überflutung, Brand, etc.) eingesetzt [96].

Seit SeaSat (gestartet 1978), dem ersten Erderkundungssatelliten mit Radarsensorik [3], hat die Radarfernerkundung eine enorme technische Entwicklung vollzogen, die sich insbesondere in den letzten zehn Jahren in den europäischen X-Band Missionen TSX, TDX und CSK manifestiert hat.

TSX wurde im Jahr 2007 gestartet und ist der erste deutsche Fernerkundungssatellit, der im Rahmen eines *Public Private Partnership* zwischen dem *Deutschen Zentrum für Luft- und Raumfahrttechnik* (DLR), sowie der *EADS Astrium GmbH* realisiert wurde ([97], [98] und [99]). Für ursprünglich mindestens fünf Jahre konzipiert, stellt TSX bis heute hochauflösende Bilddaten sowohl für wissenschaftliche Zwecke der Erdbeobachtung, als auch für den kommerziellen Bedarf zur Verfügung. Basierend auf der *Active Phased Array* Technologie stehen dem Anwender in ursprünglicher Konfiguration drei Aufnahmemodi zur Verfügung: *StripMap*, *ScanSAR* und *SpotLight* (SL). Der inzwischen hinzugekommene *Staring SpotLight* Modus stellt eine Weiterentwicklung von SL dar und erlaubt die Aufnahme sehr hochauflösender Bilddaten, die aber eine vergleichsweise kleinräumigere Szenenabdeckung besitzen [100].

In diesem Kapitel werden Grundlagen zur Fernerkundung mit SAR-Satelliten am Beispiel des TSX- beziehungsweise TDX-Sensorsystems vermittelt. Nach allgemeinen Prinzipien zur Aufnahmegeometrie, zu Abbildungseffekten und Bildprodukten wird der Fokus auf die Amplitudenbildinformation gesetzt. Im Hinblick auf die Thematik der Änderungsanalyse wird unter anderem auf typische Signaturen urbaner Gebiete eingegangen, sowie Verarbeitungsschritte wie Kalibrierung, Skalierung und Speckle-Reduzierung erläutert (Abschnitt 2.1).

Abschnitt 2.2 enthält die für das Verständnis später erläuterter Zusammenhänge notwendigen theoretischen Grundlagen mit Bezug zur Bildanalyse. Unter anderem werden die bereits in Abschnitt 1.1 skizzierten Verfahren der Mathematischen Morphologie eingehender beschrieben.

Zum Abschluß des Kapitels wird ein Überblick über Verfahren zur Klassifikation fernerkundlicher Bilddaten mit Fokus auf der *Fuzzy*-Theorie gegeben.

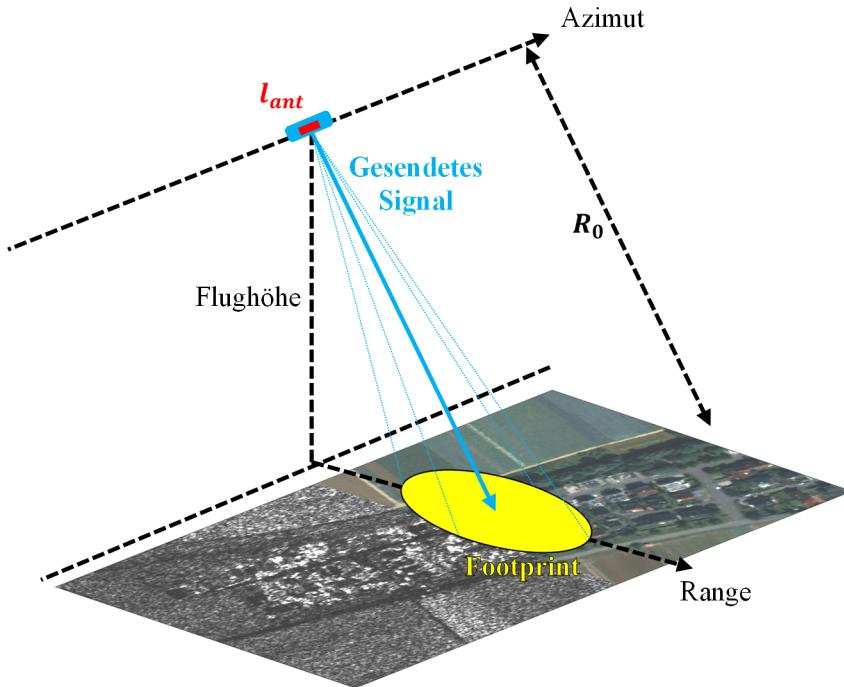


Abbildung 2.1.: Azimut-Auflösung eines Radars mit realer Apertur (RAR).

## 2.1. Satellitengestützte Fernerkundung mit SAR

Im Hinblick auf die räumliche Beschaffenheit eines auflösenden Bildelements wird in der Radarfernerkundung zwischen der Auflösung in Flugrichtung des Sensors (Azimut beziehungsweise *Azimuth*) und orthogonal dazu der Auflösung in Entfernungsrichtung (*Range*) unterschieden. Unter Auflösung ist im Allgemeinen die Fähigkeit eines Systems zu verstehen, zwei räumlich separierte Objekte als solche getrennt voneinander abilden zu können. Bei einem Radar, dessen Grundprinzip darauf basiert, die Signallaufzeiten zwischen Sensor und Objekt auszuwerten, ist hinsichtlich der Auflösung in Entfernungsrichtung weiterhin zwischen *Slant Range* (Schrägsichtentfernung) und der auf den Boden projizierten *Ground Range* zu differenzieren. Die Bildaufnahme selbst erfolgt in Schrägsichtgeometrie (*Slant*), so dass dies für die nachfolgenden Betrachtungen die Grundlage darstellt. Da diese auf das Nötigste beschränkt sind und keine detaillierte Beschreibung theoretischer Sachverhalte beinhalten, wird an dieser Stelle für weiterführende Informationen beispielsweise auf [51], [101] und [102] verwiesen.

Die Auflösung in Entfernungsrichtung ist als Funktion der Länge des ausgesendeten Pulses darstellbar. Eine Verbesserung der Auflösung kann demzufolge durch eine Verkürzung der Pulslänge erreicht werden, was allerdings den Nachteil einer reduzierten Leistung (Abstrahlenergie) nach sich zieht. Diese Energie wiederum verhält sich proportional zum Produkt der Pulsdauer und der Quadratwurzel seiner Amplitude. Da aufgrund mechanischer Limitierungen keine unbegrenzte Amplitudenerhöhung und somit eine bessere Energiebilanz bei möglichst schmaler Pulslänge erreichbar ist, wird der durch das Radar ausgesandte Puls als ein sogenannter *Chirp* moduliert. Der Vorteil eines *Chirp*-modulierten Pulses liegt darin, dass dieser nach seinem Empfang am Sensor mit einer replizierten Form seiner selbst anhand einer Korrelation verglichen werden kann. Das Resultat einer solchen Korrelation ist ein komprimierter Puls mit sehr schmaler Struktur, der letztlich zur Bestimmung der Auflösung in Entfernungsrichtung genutzt werden kann [51]. Mit dieser Form der Pulskomprimierung wird sichergestellt, dass Echos eng am Boden beieinander liegender aber verschiedener Objekte getrennt voneinander aufgelöst werden. Die *Range*-Auflösung eines Radars mit realer Apertur (RAR) entspricht der Entfernungsauflösung eines Radars mit synthetischer Apertur (SAR).

Die Azimut-Auflösung eines RAR ist direkt von der Breite der Radarkeule abhängig, die die jeweilige Szene am Boden beleuchtet (*Footprint*) (Abbildung 2.1). Die angulare Keulenbreite  $\beta_a$  der Antenne ist als Funktion der Wellenlänge  $\lambda$  und der Antennenlänge  $l_{ant}$  des Sensors beschreibbar:

$$\beta_a = \frac{\lambda}{l_{ant}} \text{ [rad].} \quad (2.1)$$

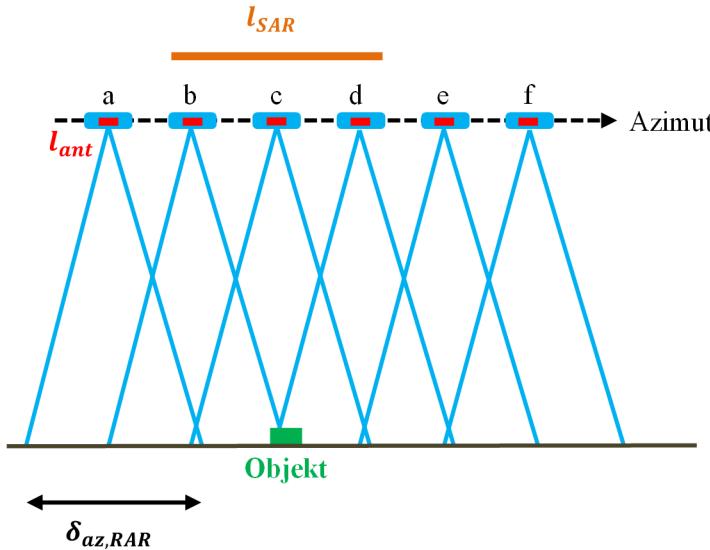


Abbildung 2.2.: SAR-Aufnahmeprinzip.

Die eigentliche Breite des Keulen-Footprints  $\delta_{az,RAR}$  ist außerdem abhängig von der Entfernung  $R_0$  zwischen Sensor und dem jeweilig beleuchteten Objekt an der Erdoberfläche:

$$\delta_{az,RAR} = \left( \frac{\lambda}{l_{ant}} \right) \cdot R_0 [\text{m}]. \quad (2.2)$$

Mit anderen Worten: Je größer der Abstand zwischen Sensor und Objekt, desto größer die Keulenbreite am Boden beziehungsweise desto schlechter ist die Auflösung in Azimut. Als direkte Konsequenz folgt daraus, dass diese Konstellation für satellitengestützte Sensorsysteme durch die Abhängigkeit von  $R_0$  untragbar ist. Darüber hinaus ist eine extreme Vergrößerung der Antennenlänge nicht realisierbar.

Im Vergleich zu RAR nutzt man bei SAR die Bewegung des Sensors entlang der Azimut-Richtung aus, um künstlich eine sehr lange Antenne herzustellen. Das Prinzip hierbei ist denkbar einfach. Die effektive synthetische Aperturlänge entspricht der Flugstrecke des Sensors für die Beleuchtungsdauer eines bestimmten Objektpunktes an der Erdoberfläche. In Abbildung 2.2 ist das SAR-Prinzip schematisch dargestellt, wobei a bis f die jeweiligen Sendepositionen entlang der Flugbahn des Sensors in Azimut-Richtung kennzeichnen. Das auf dem Erdboden befindliche Objekt wird zuerst an Position b durch das Radarsignal erfasst und gerät zu Ende der Position d außer Sichtweite. Die Wegdifferenz zwischen diesen beiden Sendepositionen entspricht der Länge der synthetischen Apertur. Nach einigen Umformungen (siehe [51]) resultiert schließlich eine Azimut-Auflösung, die der Hälfte der tatsächlichen, realen Antennenlänge entspricht:

$$\delta_{az,SAR} = \frac{l_{ant}}{2} [\text{m}]. \quad (2.3)$$

Der Mehrgewinn durch SAR resultiert aus der Tatsache, dass  $\delta_{az,SAR}$  unabhängig von der Flughöhe des Sensors ist und somit insbesondere hochauflösende Bildaufnahmen aus dem Weltraum ermöglicht. Im Fall von TSX- oder TDX-Bildern, die mittels *High Resolution SpotLight* (HS) Modus aufgenommen werden, resultiert durch die sehr lange künstliche Antenne und die damit relativ lange Beleuchtungsdauer der Szene eine Pixelgröße von circa 0,85 m in Azimut-Richtung (*Slant*). Die Pixelgröße in Entfernungsrichtung (*Range*) beträgt hier etwa 0,45 m (ebenfalls *Slant*-Geometrie). Eine quadratische Rasterung ist somit a-priori aufgrund der Schrägsicht auf die jeweilige Szene sowie der unterschiedlichen Signalverarbeitung in Entfernungs- und Azimut-Richtung nicht gegeben. Dennoch existiert die Möglichkeit, derartige *Slant Range* Bilder auf die Erdoberfläche projizierend zu transformieren (*Ground Range*, zum Beispiel [51]). Für eine Kartendarstellung der Bilddaten ist ferner eine Geokodierung, oder eine Orthorektifizierung mittels Höhenmodell (siehe Abschnitt 6.1) durchzuführen. Im Hinblick auf die Szenenanalyse hat eine quadratisch gerasterte Karte zwei zentrale Vorteile. Erstens wird auf diese Weise die kombinierte Auswertung komplementärer Datenerzeugnisse (beispielsweise GIS-Vektordaten) vereinfacht. Zweitens können aus der Realität abgeleitete geometrische Vorgaben (unter anderem Objektgrößen) direkt in den Arbeitsablauf integriert werden.

Gegenüber der optischen Fernerkundung unterscheidet sich die Aufnahmegerometrie eines Radar-Sensorsystems grundlegend. Da die Bildaufnahme auf der Messung der Signallaufzeit basiert, ergibt sich

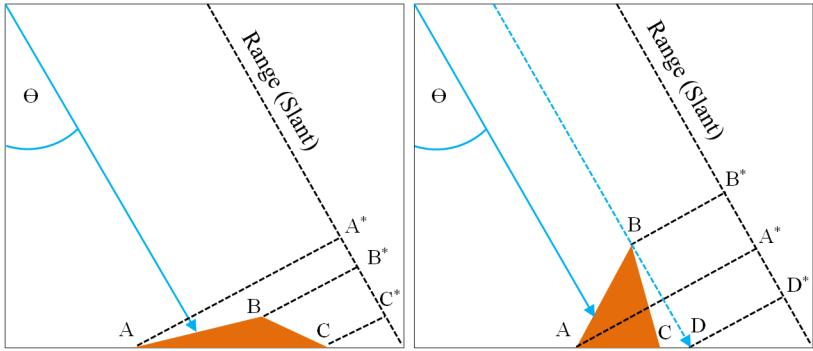


Abbildung 2.3.: *Foresighting* (links), *Layover* und *Shadow* (beide rechts).

die Bilderstellung zwangsläufig in Seitsichtgeometrie (*Side-Look*, vergleiche hierzu auch Abbildung 2.1). Als direkte Konsequenz daraus folgen die SAR-spezifischen Abbildungseffekte Verkürzung (*Foresighting*) und Überlagerung (*Layover*). Darüber hinaus existieren ähnlich zur optischen Fernerkundung Schattenbereiche (*Shadow*), die an Stellen resultieren, an denen das Radarsignal durch vorgelagerte Objekte abgeschattet wird. *Foresighting*, *Layover* und *Shadow* sind vereinfacht in Abbildung 2.3 visualisiert. *Foresighting* tritt generell an Objekten auf, deren dem Sensor zugewandte Seite eine Neigung aufweist, die kleiner dem lokalen Beleuchtungswinkels  $\theta$  des Radars ist (Abbildung 2.3, links). Die Strecke AB wird somit verkürzt abgebildet (Strecke A\*B\*).

Der *Layover*-Effekt führt dazu, dass die dem Sensor zugewandte Objektseite (Abbildung 2.3, rechts, Strecke AB) aufgrund ihrer relativ starken Neigung in der SAR-Aufnahme in umgekehrter Reihenfolge und meist stark verkürzt dargestellt wird (Abbildung 2.3, rechts, Strecke B\*A\*).

Bei derartig beschaffenen Objekten kommt es ferner zur Bildung von Radarschatten an der dem Sensor abgewandten Seite. Vereinzelte Objektpunkte werden somit nicht abgebildet (Abbildung 2.3, rechts, Objektpunkt C).

Neben Aspekten der Abbildungsgeometrie beeinflussen diese Effekte die Rückstreustärke (Amplitude) beziehungsweise die Radiometrie der einzelnen Auflösungszellen und somit der ganzen Szene.

An verkürzt abgebildeten Objekten beziehungsweise Regionen der Erdoberfläche (*Foresighting*) treten relativ hohe Rückstreuwerte auf, was diese Bereiche anhand ihrer hellen Darstellung visuell leicht detektierbar werden lässt. Vergleichbares kann in *Layover*-Bereichen beobachtet werden, da verschiedene nebeneinander befindliche Objektschnitte in derselben Auflösungszelle abgebildet werden [103]. Hohe Amplitudenwerte resultieren darüber hinaus an Objekten, die als *Corner*-Reflektor (zum Beispiel Gebäudefassaden) agieren und somit eine direkte Reflexion des gesendeten Signals hervorrufen (Abbildung 2.4, B). Zusätzlich sind generell Mehrfachreflexionen möglich (zum Beispiel an Brücken), die ebenfalls vergleichsweise hohe Amplitudenwerte zur Folge haben [104]. Hohe Amplitudenwerte können weiterhin durch harte Ziele (*hard targets*, wie Gitter, Zäune, Fahrzeuge) hervorgerufen werden, da derartige metallische Oberflächenstrukturen über eine relativ ausgeprägte elektrische Leitfähigkeit verfügen. Umfassende Ausführungen zu Rückstreuereigenschaften, Abbildungseffekten und strukturellen Parametern sind unter anderem in [105] zu finden.

Im Gegensatz dazu sind Radarschattenbereiche sichttote Gebiete, für die selbst keine Rückstreuwerte aufgezeichnet werden. Vergleichbar sind diese Bereiche mit Oberflächen, die relativ zur verwendeten Wellenlänge glatt erscheinen (*smooth surfaces*) und eine spiegelnde Reflexion bewirken (2.4, A). Mittels *Rayleigh-Kriterium* werden Oberflächen als glatt bezeichnet, wenn für ihre Höhenvariation folgender Zusammenhang gilt [51]:

$$h < \left( \frac{\lambda}{8 \cdot \cos(\alpha)} \right), \quad (2.4)$$

wobei  $\alpha_E$  der lokale Einfallswinkel der Radarstrahlung ist, der durch die örtliche Flächennormale und die Beleuchtungsrichtung eingeschlossen wird. Im Fall einer Nutzung von TSX-Daten ( $\lambda \approx 3$  cm) bei einem Einfallswinkel von  $45^\circ$  ist ableitbar, dass eine spiegelnde Reflexion an Oberflächen mit einer Höhenvariation kleiner als einem halben Zentimeter erfolgt.

Ideale, glatte Oberflächen sowie ideale Abschattungsbereiche können zur Ableitung von Informationen bezüglich des *Noise Equivalent Sigma Zero* (NESZ) genutzt werden. Der in  $\sigma^0$  ausgedrückte NESZ kann gemeinhin als Parameter zur Kennzeichnung der Sensitivität eines SAR-Systems beschrieben werden, der den Hintergrund-Rauschanteil des Sensors darstellt [106].

An rauen Oberflächen, die eine Höhenvariation größer als den durch Formel (2.4) beschriebenen Schwellwert aufweisen, tritt für gewöhnlich eine diffuse Streuung der Radarstrahlung auf (Abbildung 2.4, C). Diese Art der

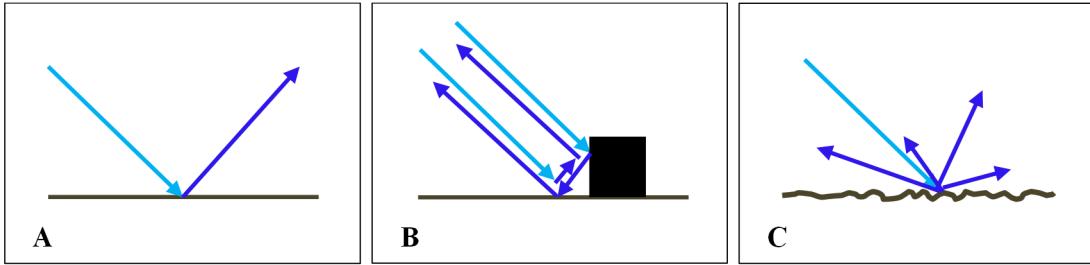


Abbildung 2.4.: Spiegelnde Reflexion (A), Rückstreuung an Gebäuden (B) und diffuse Streuung (C).

Rückstreuung ist außerdem bei Volumenstreueren (*volume scatterer*) beobachtbar, wobei hier das Radarsignal partiell in das jeweilige Objekt (zum Beispiel Baumkrone) eindringt und im Materialinneren (Äste, Zweige) diffus gestreut wird.

Das herkömmliche TSX/TDX-Bildprodukt ist ein SSC-Bild (*Single Look Slant Range Complex*), das die erfassten Daten als komplexe Zahlen, die Amplituden- und Phaseninformationen darstellen, beinhaltet [107]. Wie weiter oben beschrieben, spiegelt die Amplitudeninformation das Maß der Rückstreustärke innerhalb einer Auflösungszelle wieder, was eine unmittelbare visuelle Interpretation der Szene durch den Anwender ermöglicht. Mit Kenntnis der Zusammenhänge zwischen Aufnahmegerüttie, Radarstrahlung und Oberflächenbeschaffenheit können entsprechende Gebiete (glatte und raue Oberflächen, Schattenebereiche, etc.) leicht erkannt werden. Amplitudenbilder resultieren aus der Bildung des Absolutbetrages, wobei eine komplexe Zahl  $z_k$  wie folgt definiert ist (mit  $a, b \in \mathbb{R}$  und  $i^2 = -1$ ):

$$z_k = a + b \cdot i, \quad (2.5)$$

beziehungsweise mit dem Winkel  $\varphi$  in Polardarstellung (Euler'sche Notation), mit  $u = |z_k| = \sqrt{a^2 + b^2}$ :

$$z_k = u \cdot e^{i\varphi} = u [\cos(\varphi) + i \cdot \sin(\varphi)]. \quad (2.6)$$

Für die Amplitude  $A$  folgt somit:

$$A = u = |z_k| = \sqrt{a^2 + b^2}. \quad (2.7)$$

Das Intensitätsbild  $I$  berechnet sich aus der Multiplikation des komplexwertigen mit dem entsprechend konjugiert komplexen Bild  $z_k^*$ , beziehungsweise aus dem Quadrat des Amplitudenbildes:

$$I = z_k \cdot z_k^* = (a + b \cdot i)(a - b \cdot i) = A^2. \quad (2.8)$$

Durch die Dominanz des inhärenten Speckle folgen die Grauwerte eines Amplitudenbildes aus statistischer Sicht einer Rayleigh-Verteilung, die eines Intensitätsbildes einer exponentiellen Verteilung [28]. Diese Feststellungen spielen insbesondere bei der Speckle-Reduzierung sowie bei der verlustfreien Skalierung [108] eine Rolle.

TSX/TDX SSC-Bilder werden im uint (*unsigned integer*) 16-Bit-Format abgespeichert und besitzen eine hohe Wertedynamik ( $2^{16} = 65536$ ). Aus diesem Grund werden oftmals Amplituden- beziehungsweise Intensitätsbilder mittels dekadischem Logarithmus skaliert und in [dB] dargestellt:

$$A [\text{dB}] = 20 \cdot \log(A), \quad (2.9)$$

beziehungsweise

$$I [\text{dB}] = 10 \cdot \log(I). \quad (2.10)$$

Für ein besseres Verständnis sind in Abbildung 2.5 die Amplitudensignaturen typischer Oberflächenstrukturen visualisiert. Zu sehen sind volumenstreuende Vegetation (A), urbane Strukturen mit diversen harten Zielen (B) und abgeschatteten Bereichen (C), sowie rurale Gebiete mit rauen Feldoberflächen (D). Als Grundlage wurde hierfür die Testszene „Stuttgart Flughafen“ verwendet. Zur besseren Orientierung im Bild ist der entsprechende Ausschnitt aus dem Referenzdatensatz des optischen Sensors WV-2 dargestellt (Abbildung 2.5, rechts).

Neben den erwähnten Strukturen ist im SAR-Bildausschnitt der Speckle-Effekt anhand seiner charakterisierenden Salt-and-Pepper-Erscheinung erkennbar. Speckle entsteht durch kohärente Addition der Energie verschiedener, sich innerhalb einer Auflösungszelle befindlicher und rückstreuender Objekte [51]. Eine uneinheitliche, zufällige Grauwertwiedergabe für beliebige Auflösungszellen resultiert, was sich in der typischen



Abbildung 2.5.: Amplitudenbildsignaturen: Vegetation (A), Urban (B), Schatten (C) und raue Oberflächen (D). Links: Ausschnitt aus einem Amplitudenbild der Szene „Stuttgart Flughafen“. Rechts: Ausschnitt aus dem pangeschräften WV-2-Referenzbild.

körnigen Bildstruktur niederschlägt [28] (Abbildung 2.5, links). Im Hinblick auf eine auswertende Analyse von Amplitudenbildern repräsentiert der Speckle einen limitierenden Faktor, dessen Reduzierung oder Eliminierung für die Güte der jeweiligen Resultate maßgeblich ist [109].

Die für diesen Schritt existierenden Techniken können allgemein in räumliche Filter (adaptiv, nicht adaptiv) und die *Multi-Look*-Methode unterschieden werden. Eine umfassende Beschreibung dieser Verfahren findet sich in [28]. In Anbetracht der Tatsache, dass für die vorliegende Arbeit Zeitreihenstapel aus Amplitudenbildern betrachtet werden, eröffnet sich mit dem zeitlichen ML eine alternative und wirkungsvolle Methode zur Speckle-Reduzierung. Die klassische ML-Prozessierung macht sich die Länge der synthetischen Apertur zu eigen und teilt diese in  $N$  voneinander unabhängige Komponenten ein. Jede dieser Komponenten wird eigenständig zur Erstellung eines Amplituden- oder Intensitätsbildes genutzt. Die einzelnen Bilder werden gemittelt, was zu einer Reduzierung der Standardabweichung des Speckle um den Faktor  $\sqrt{N}$  führt. Allerdings reduziert sich auf diese Weise neben dem Rauschanteil auch die räumliche Auflösung des Bildes [28]. Bei der temporären Verarbeitungsweise repräsentieren die  $N$  Komponenten einzelne, unabhängig und zeitlich separiert aufgenommene Amplituden- oder Intensitätsbilder der identischen Szene, wodurch die volle Aperturlänge und damit die ursprüngliche Auflösung erhalten bleibt. Das Risiko, spezifische in einzelnen Bildern des Stapels enthaltene Strukturen, Objekte oder Änderungen durch die Mittelung abzuschwächen oder zu verlieren, ist hier allerdings gegeben. In dieser Arbeit bildet das zeitlich gemittelte ML-Amplitudenbild die Grundlage für die Segmentierung der lokalen Änderungsbereiche zur Ableitung semantischer Informationen. Hierzu befinden sich in Abschnitt 4.2.1 detailliertere Ausführungen.

In Bezug auf die eigentlichen Rückstreustärken der Auflösungszellen und damit auch der gesamten abgebildeten Szene werden verbreitet radiometrisch normierte Werte angegeben, um insbesondere verschiedene Bilddaten miteinander anhand einheitlicher Bezugsflächen vergleichen zu können. In [108] ist eine Beschreibung der für SAR-Bilddaten existierenden Rückstreucoeffizienten enthalten, wovon der  $\sigma^0$ -Koeffizient (siehe auch Abschnitt 1.1) der am häufigsten verwendete Vertreter ist. Als Bezugsfläche für die Berechnung der  $\sigma^0$ -Rückstreucoeffizienten dient die Erdoberfläche, was zur Berücksichtigung des lokalen Einfalls winkels  $\alpha_E$  der Radarstrahlung führt. Für die  $\sigma^0$ -Kalibrierung von TSX/TDX-Daten gilt folgender Zusammenhang [110]:

$$\sigma^0 = (k_s \cdot |DN|^2 - NEBN) \cdot \sin(\alpha), \quad (2.11)$$

mit dem Kalibrierungsfaktor  $k_s$ , den aufgezeichneten Amplitudenwerten DN (*digital numbers*) sowie dem *Noise Equivalent Beta Nought* (NEBN). Eine alternative Formulierung kann anhand des *Beta Nought* ( $\beta^0$ ) Rückstreucoeffizienten erfolgen, der die eigentliche Helligkeit beziehungsweise Rückstreuung je Auflösungszelle in der ursprünglichen *Slant Range* Geometrie wiedergibt [108]:

$$\sigma^0 = \beta^0 \cdot \sin(\alpha) - NESZ. \quad (2.12)$$

Die resultierenden radiometrisch normierten Amplitudenwerte sind Intensitätswerte, die verbreitet in [dB] wiedergegeben werden [51]:

$$\sigma^0 [\text{dB}] = 10 \cdot \log(\sigma^0). \quad (2.13)$$

Typische Intensitätswerte geläufiger Oberflächenarten beziehungsweise Objekte sind beispielsweise in [102] gelistet, wobei die Spanne von stark rückstreuenden Industriegebieten (circa [5 dB; 15 dB]) bis zu Gewässeroberflächen schwächer beziehungsweise geringer Rückstreuung (circa [-35 dB; -20 dB]) reicht. Verschiedene

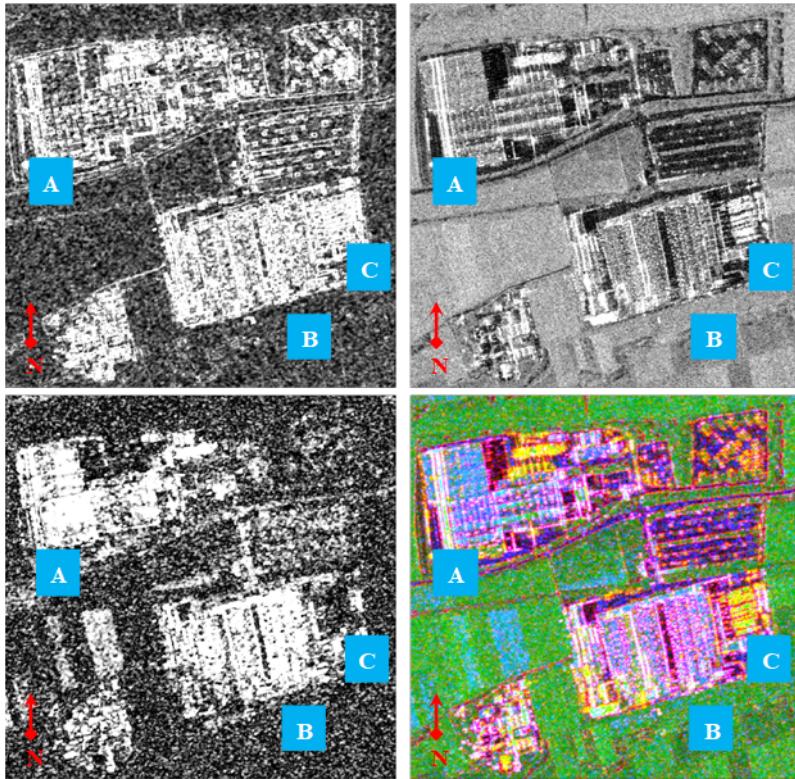


Abbildung 2.6.: CovAmCoh-Bildlayer und RGB-Darstellung eines industriellen Bildbereichs. Links oben: Cov-Bild; rechts oben: Amplitudenbild; links unten: Kohärenzbild; rechts unten: RGB-Kombination (CovAmCoh). Interferometrisches Bildpaar: SSC-Daten der Szene „Stuttgart Flughafen“ (10.11.2013 und 04.01.2014). A: Urbanes Gebiet; B: Volumentreuende Vegetation; C: Urbaner Änderungsbereich.

Bildverarbeitungsmethoden setzen Daten voraus, die auf 256 Graustufen (8 Bit) skaliert sind. Einige Visualisierungswerzeuge wie *Google Earth* erfordern ebenfalls entsprechende Grauwertbereiche. In [108] wird ein Verfahren zur verlustfreien Skalierung normierter Intensitätsbilder  $I_{norm}$  mittels der Tangens Hyperbolicus ( $\tanh$ ) Funktion erläutert. Diese Skalierung wird durch folgende Berechnungsvorschrift beschrieben:

$$I_{norm,\tanh} = \frac{I_{norm} - 1}{I_{norm} + 1} \cdot (2^{\eta-1} - 1) + 2^{\eta-1}, \quad (2.14)$$

mit der frei wählbaren Bit-Tiefe  $\eta$ .

Neben dem Amplituden- beziehungsweise Intensitätsbild existieren weitere SAR-Bildprodukte, die komplementär nutzbare Informationen über die jeweilige Szene bereitstellen. Dazu gehört beispielsweise das Variationskoeffizientenbild (Cov), das Rückschlüsse über die lokale Heterogenität beziehungsweise Homogenität einer Bildregion zulässt. Berechnet wird das Cov-Bild anhand eines über das Bild bewegten Fenster einer vorgegebenen Größe auf Basis nicht logarithmierter Amplituden- oder Intensitätsbilder mittels nachstehender Formel:

$$Cov = \frac{\sigma}{\bar{x}}, \quad (2.15)$$

wobei  $\sigma$  für die Standardabweichung und  $\bar{x}$  für den Mittelwert der Grauwerte im bewegten Fenster stehen. Für einen ideal homogenen Bildbereich ist der auf einem Intensitätsbild berechnete Cov gleich eins, in einem Amplitudenbild gleich 0,522 [111].

Liegt mindestens ein interferometrisches SAR-Bildpaar vor, können mittels Kohärenzbild Rückschlüsse auf die Schätzgenauigkeit der interferometrischen Phase abgeleitet werden [111]. Die Berechnung erfolgt ähnlich wie die des Cov-Bildes anhand eines bewegten Fensters nach der Vorschrift:

$$Coh = \left| \frac{\langle s_1 \cdot s_2^* \rangle}{\sqrt{\langle s_1^2 \rangle \cdot \langle s_2^2 \rangle}} \right|, \quad (2.16)$$

mit den Bezeichnungen  $\langle \rangle$  für den Erwartungswert und  $*$  für die konjugiert komplexe Zahl eines Wertes. Darüber hinaus stehen  $s_1$  beziehungsweise  $s_2$  für die beiden komplexwertigen Komponenten des interferometrischen Bildpaars.

Für zueinander vollkommen kohärente Rückstreuer folgt daraus  $Coh = 1$ , wohingegen ein komplett dekorriertes Signal einen Wert von  $Coh = 0$  zur Folge hat. Allgemein gilt deshalb, dass die Kohärenz mit zunehmender Volumenstreuung oder zeitlichen Veränderungen abnimmt [112].

Die *CovAmCoh*-Methode kombiniert die drei beschriebenen Bildprodukte eines interferometrischen Bildpaars zu einem RGB-Farbbild (Rot = (mittlerer) Cov; Grün = (mittlere,  $\sigma^0$ -kalibrierte) Amplitude; Blau = (mittlere) Kohärenz) und dient zur unterstützenden Szeneninterpretation. Verschiedene LULC-Klassen (zum Beispiel Urban (Abbildung 2.6, A) und rurale, volumenstreuende Vegetation (Abbildung 2.6, B)) können visuell leicht voneinander unterschieden werden. Weiterhin sind zwischen den Bildpaarkomponenten auftretende Veränderungen an künstlichen Strukturen anhand ihrer typischen gelblichen Färbung (hoher Cov-, hoher Am-Wert, niedrige Kohärenz) unmittelbar erkennbar (vergleiche auch Abbildung 2.6, C). Weiterführende, detaillierte Informationen zu diesem Verfahren und seiner Verwendung können beispielsweise in [112], [111] und [113] gefunden werden. Im Rahmen der vorliegenden Arbeit wird die *CovAmCoh*-Methode zur Ableitung der Kontextinformation in der lokalen Nachbarschaft eines Änderungsobjekts für den Fall einer Nichtverfügbarkeit von GIS-Daten verwendet (Abschnitt 4.2.1).

Die für die späteren Betrachtungen notwendigen Grundlagen zur Radarfernerkundung inklusive der entsprechenden Bildprodukte sind an dieser Stelle geschaffen. Die Verfahren zur Weiterverarbeitung der Bildprodukte mit Ziel der Merkmals- und Informationsgewinnung sind im nachfolgenden Abschnitt 2.2 enthalten.

## 2.2. Bildanalyse

In diesem Abschnitt werden Verfahren der Bildanalyse beschrieben, die zur Verarbeitung der vorliegenden Bildprodukte hinsichtlich der in dieser Arbeit beschriebenen Änderungsanalyse Anwendung finden. Generell existiert eine Vielzahl an möglichen Merkmalen, die zur Beschreibung von Änderungsobjekten genutzt werden können (vergleiche auch Kapitel 4). Für die vorliegende Bearbeitung werden verbreitet verwendete Merkmale betrachtet und hinsichtlich ihrer Eignung für die Kategorisierung der Änderungen untersucht (siehe Kapitel 4 und 6). Nachfolgend finden sich die Grundlagen zu diesen ausgewählten Merkmalen.

Im Arbeitsgebiet der Mathematischen Morphologie wurden in der Vergangenheit mit den Morphologischen Profilen (MP), Attributprofilen (AP) und den Differentiellen Attributprofilen (DAP) vielversprechende Verarbeitungsmethoden entwickelt und in vielfältiger Weise zur Informationsgewinnung auf hochauflösende Fernerkundungsbilddaten angewendet. Die ASF repräsentieren eine Verfahrensweise, die zur Speckle-Minderung in SAR-Bildern gut geeignet ist. In Abschnitt 2.2.1 werden entsprechende theoretische Grundlagen vermittelt, die für das Verständnis und die spätere Anwendung der DAP und ASF in der beschriebenen Methode von essentieller Bedeutung sind.

Die Anwendung eines ASF ist der zentrale Vorverarbeitungsschritt für die bildpaarbasierte Änderungsdetektion (Kapitel 3). Diese Detektion erfolgt anhand des unüberwachten, entropiebasierten Schwellwertverfahrens nach Renyi [95], das im Detail in Abschnitt 2.2.2 erläutert wird und in Kapitel 6 vergleichbaren Methoden gegenübergestellt wird. Durch die Verwendung eines ASF wird sowohl die verlustfreie Glättung des maximalen Quotientenbilds, als auch die variable und zielorientierte Steuerung der resultierenden Änderungsobjektgröße erreicht.

Neben den DAP werden in der vorliegenden Arbeit weitere, komplementäre Merkmale zur Kategorisierung der detektierten Änderungsobjekte hoher Aktivität (HAO) verwendet. Eine Merkmalsgruppe bilden Texturparameter, die beruhend auf der sogenannten Grauwertmatrix (*Gray-Level Co-Occurrence Matrix* GLCM) bestimmt werden und auch als Haralick-Merkmale bekannt sind. Abschnitt 2.2.3 widmet sich der Definition und der Berechnung dieser Parameter.

Die Verwendung der HAO als Grundlage der hier vorgestellten Analysemethode ermöglicht den Einsatz von Verfahren, die im Umfeld der OBIA beheimatet sind. Wie bereits in Abschnitt 1.1 erläutert wurde, weist die OBIA gegenüber der pixelbasierten Bildanalyse bedeutende Vorteile auf, insbesondere in Anbetracht räumlich hochauflösender Bilddaten. So können beispielsweise formbeschreibende, statistische und radiometrische Merkmale der Bildobjekte extrahiert und zur Auswertung genutzt werden. Darüber hinaus bietet die Analyse der segmentierten lokalen Nachbarschaft der Interessenobjekte die Möglichkeit, eine zu anderen Merkmalen komplementäre, kontextorientierte Beschreibung abzuleiten. Abschnitt 2.2.4 beinhaltet die Erläuterungen der hierfür notwendigen Grundlagen.

Die Verarbeitung hochdimensionaler Datensätze birgt den aus der Informationstheorie bekannten *Fluch der Dimensionalität*, dessen Vermeidung essentielle Bedeutung besitzt. Das Ziel ist die Reduzierung des jeweiligen

Datensatzes auf hauptsächliche, maßgebliche Merkmale, ohne einen Verlust an entscheidender Information hervorzurufen. Abschnitt 2.2.5 setzt sich mit dieser Problematik auseinander und beschreibt verfügbare Vorgehensweisen.

Als Basis für die Gruppierung zueinander ähnlicher HAO (in Anbetracht ihrer merkmalsbezogenen Ausprägung) dient die reduzierte Merkmalsmatrix. Eine Kategorisierung der Änderungsobjekte besitzt für die vorliegend beschriebene Methode essentielle Bedeutung. Sie dient als Grundlage für die spätere Prüfung, ob die durch den Anwender selektierten Klassen tatsächlich in den Daten existieren. Abschnitt 2.2.6 vermittelt einen Überblick über Methoden zur Clusteranalyse sowie die entsprechenden theoretischen Grundlagen.

Zum Abschluss wird die Klassifikation mittels *Fuzzy*-Logik erläutert, die auch in kommerziell verfügbarer Software zum Einsatz kommt (zum Beispiel *eCognition Developer*). Die Klassifikation ist der finale Verarbeitungsschritt des vorgestellten Verfahrens und dient der Zuweisung der kategorisierten HAO entsprechend eines vorab durch den Anwender definierten Klassenkatalogs.

### 2.2.1. Morphologische Bildverarbeitung

Die Mathematische Morphologie (MM), so definiert sie beispielsweise [29], ist eine Theorie zur Analyse räumlicher Strukturen, Gestalten und Formen. Ursprünglich stammt die MM von der Mengentheorie oder Mengenlehre ab. Auf den diskreten, zweidimensionalen Fall der digitalen Bildverarbeitung übertragen, spielen Begriffe wie *Vereinigungsmenge* oder *Schnittmenge* zentrale Rollen, die in grundlegenden morphologischen Prozessen wie Dilatation  $\eta$  und Erosion  $\varepsilon$  Anwendung finden. Um derartige Operatoren und deren Anwendung sowie Wirkung einordnen zu können, gilt es zunächst, einige Definitionen vorzunehmen. Für weiterführende und detailliertere Informationen zu den nachstehenden Ausführungen wird auf [29] und [114] verwiesen.

Diskrete digitale Bilder können in Binär- und Grauwertbilder unterschieden werden. Ein Binärbild  $I_{Bin}$  beinhaltet Pixelwerte  $p_i \in \{0, 1\}$ , die den Bildinhalt in Hinter- und Vordergrund (Objektpixel) aufgliedern. Im Gegensatz zu diesem eingeschränkten Wertebereich enthält ein (ganzzahliges) Grauwertbild  $I_{GW}$  Pixelwerte  $p_i \in [0, G]$ , wobei  $G$  eine nichtnegative ganze Zahl ist, die den größten Wert zur bit-codierten Bildspeicherung kennzeichnet. Allgemein gilt somit  $G = 2^n - 1$  mit  $n = 8$  für Bilder mit 256 Graustufen (8 Bit). Jedes Grauwertbild kann als kombinierte Anordnung binärer Untergraphen dargestellt werden. Derartige Untergraphen ergeben sich durch Anwendung eines Schwellwerts, der jeden beliebigen Wert  $i$  zwischen Null und  $G$  einnehmen kann. Das ursprüngliche Grauwertbild  $I_{GW}$  kann mittels der Summe seiner binären Untergraphen  $I_{Bin}^i$  dargestellt werden:

$$I_{GW} = \sum_{i=0}^G I_{Bin}^i. \quad (2.17)$$

Die beiden Transformationen  $\eta$  und  $\varepsilon$  basieren jeweils auf der Verwendung eines Strukturierenden Elements (SE) mit variabler Form (zum Beispiel kreis- oder linienförmig) und Größe, das gegen digitale Bildmengen geprüft wird [29]. Derartige Bildmengen können beispielsweise die Vordergrundpixel eines Binärbilds oder eines Grauwertbild-Untergraphen sein. Bei der Anwendung der Erosion  $\varepsilon$  bleiben lediglich Vordergrundpixel erhalten, die durch das SE vollständig abgedeckt werden, was der Schnittmenge des SE mit der Bildmenge entspricht. Im Gegensatz dazu liefert die Dilatation  $\eta$  die Vereinigungsmenge zwischen SE und Bildmenge und fügt Vordergrundpixel an Stellen hinzu, wo das SE die Bildmenge berührt.

Morphologische Öffnungen  $\Omega$  und Schließungen  $\Psi$  stellen Kombinationen von  $\eta$  und  $\varepsilon$  dar, wobei  $\Omega$  als Dilatation einer erodierten Bildmenge definiert ist:

$$\Omega(I_{Bin}) := \eta[\varepsilon(I_{Bin})]. \quad (2.18)$$

$\Psi$  sind Erosionen, angewendet auf dilatierte Bildmengen:

$$\Psi(I_{Bin}) := \varepsilon[\eta(I_{Bin})]. \quad (2.19)$$

Im Hinblick auf die Komplementierung  $C$  sind sowohl  $\varepsilon$  als auch  $\eta$  duale Transformationen, woraus sich die Dualität von  $\Omega$  und  $\Psi$  ergibt:

$$\Omega(I_{Bin}) = [\Psi(I_{Bin}^C)]^C; \quad \Psi(I_{Bin}) = [\Omega(I_{Bin}^C)]^C. \quad (2.20)$$

Weiterhin sind morphologische Öffnungen (Schließungen) steigende, anti-extensive (extensive) und idempotente Transformationen. Eine idempotente Transformation bewirkt kein verändertes Resultat, wenn sie zweimal nacheinander angewendet wird. Das Ergebnis einer anti-extensiven (extensiven) Prozessierung ist stets

kleiner oder gleich (größer oder gleich) dem ursprünglichen Originalbild. Dies bedeutet, dass das jeweilige Resultatbild eine kleinere oder gleiche (beziehungsweise größere oder gleiche) Anzahl an Vordergrundpixel wie das Originalbild enthält. Eine Transformation ist steigend, wenn zwischen zwei Bildern  $I$  und  $J$  die Ordnungsbeziehungen erhalten bleiben [29]:

$$I \leq J \Leftrightarrow \Omega(I) \leq \Psi(J); \forall I, J. \quad (2.21)$$

Derartige klassische morphologische Öffnungen und Schließungen hängen von der eingangs getroffenen Wahl eines für die jeweilige Anwendung zielführenden SE ab, was sowohl Geschick als auch ein gewisses Maß an Expertenwissen erfordert. Eine in Anbetracht des vollständigen Bildinhalts flexiblere Verfahrensweise, die auf die Nutzung von SE verzichtet, ist durch die zusammenhängende Öffnung  $\Omega_{CC}$  beziehungsweise zusammenhängende Schließung  $\Psi_{CC}$  gegeben. Die Grundlage für diese Transformationen stellen zusammenhängende Komponenten (*Connected Component(s)* CC) oder Segmente dar. Zwei Pixel sind zusammenhängend, wenn sie nach einer Konnektivitätsvorgabe (zum Beispiel 4er- oder 8er-Nachbarschaft) miteinander verbunden sind. In der vorliegenden Arbeit wird die 4er-Nachbarschaft zum Auffinden von CC genutzt, um zu vermeiden, dass räumlich nah beieinander liegende, aber kategorisch unähnliche Zielobjekte zu einer CC verbunden werden. Im Grunde sind  $\Omega_{CC}$  und  $\Psi_{CC}$  Rekonstruktionen durch Dilatation (Erosion), die auf geodätischen Dilatationen (Erosionen) basieren. Derartige Transformationen beinhalten die Prüfung eines Maskenbilds gegen ein Markerbild, das die Interessenpixel bestimmter Bildregionen enthält. Ist ein Interessenpixel Teil einer im Maskenbild enthaltenen CC, so bleibt diese CC bestehen, falls nicht, wird sie gelöscht.  $\Omega_{CC}$  und  $\Psi_{CC}$  sind ebenfalls duale Transformationen und es gilt analog zu oben:

$$\Omega_{CC}(I_{Bin}) = [\Psi_{CC}(I_{Bin}^C)]^C; \Psi_{CC}(I_{Bin}) = [\Omega_{CC}(I_{Bin}^C)]^C. \quad (2.22)$$

Eine Fortführung der Strategie zur Analyse der im Bild enthaltenen CC erfolgt mittels Attributöffnungen und -schließungen, die wiederum Kombinationen zusammenhängender Öffnungen (Schließungen) mit trivialen Öffnungen  $\Gamma_{Op,CC}$  (Schließungen  $\Gamma_{Cl,CC}$ ) darstellen. Triviale Öffnungen verwenden ein steigendes Kriterium, um die in einem Bild enthaltenen CC zu filtern. Das bedeutet, dass alle einer grundlegenden CC übergeordneten Segmente ein bestimmtes Kriterium  $T$  erfüllen - wenn es durch die grundlegende CC erfüllt wird [115]. Ein derartig steigendes Kriterium ist beispielsweise die Anzahl der zu einer CC gehörenden Pixel (Attribut *area*). Das Kriterium wäre hierfür beispielsweise die Vorgabe, dass eine CC aus mindestens zehn Pixel bestehen muss ( $T = CC_{area} \geq 10$  [Pixel]). Für jede in dem Bild enthaltene CC wird dementsprechend geprüft, ob  $T$  erfüllt wird. Falls ja, bleibt die CC nach dem Filterschritt enthalten - falls nicht, wird sie gelöscht:

$$\Gamma_{Op,CC} = \begin{cases} CC, & \text{wenn } T \text{ erfüllt,} \\ \emptyset, & \text{sonst.} \end{cases} \quad (2.23)$$

Analog zu obiger Definition sind triviale Öffnungen (Schließungen) im Hinblick auf die Komplementierung ebenfalls duale Transformationen:

$$\Gamma_{Op,CC}(I_{Bin}) = [\Gamma_{Cl,CC}(I_{Bin}^C)]^C; \Gamma_{Cl,CC}(I_{Bin}) = [\Gamma_{Op,CC}(I_{Bin}^C)]^C. \quad (2.24)$$

Aus formaler Sicht sind Attributöffnungen  $\Gamma_{Op,CC}^A$  (Attributschließungen  $\Gamma_{Cl,CC}^A$ ) auf einem zusammenhängend geöffneten (geschlossenen) Bild angewandte triviale Öffnungen (Schließungen) [115]:

$$\Gamma_{Op,CC}^A(I_{Bin}) = \Gamma_{Op,CC}[\Omega_{CC}(I_{Bin})] \text{ beziehungsweise } \Gamma_{Cl,CC}^A(I_{Bin}) = \Gamma_{Cl,CC}[\Psi_{CC}(I_{Bin})]. \quad (2.25)$$

Die bisherigen Operatoren können unmittelbar für Binärbilder  $I_{Bin}$  genutzt werden. Nach Formel (2.17) besteht generell die Möglichkeit der Anwendung auf Grauwertbilder  $I_{GW}$ , allerdings muss insbesondere im Zuge der Attributfilterung das sogenannte Überlagerungsprinzip (*superposition principle*) beachtet werden [116]. Es ist zu erwähnen, dass die Rekonstruktion des gefilterten Grauwertbilds mittels Formel (2.17) nur für steigende Attribute erfüllt wird. Kommen nicht-steigende Attribute zum Einsatz, werden Attributöffnungen (Attributschließungen) zu Attributausdünnungen (-verdickungen), um den Unterschied zur steigenden Eigenschaft der Basisoperationen zu verdeutlichen. Die wohl einfachste Möglichkeit zur Rekonstruktion von Grauwertbildern, die anhand nicht-steigender Attributfilter verarbeitet werden, ist die Invertierung der Rekonstruktionsreihenfolge [117]. Umgekehrt zu Formel (2.17) wird ausgegehend von der obersten Untergraphebene begonnen:

$$I_{GW} = \sum_{i=G}^0 I_{Bin}^i. \quad (2.26)$$

Attributöffnungen (Attributschließungen) sind als Grundpfeiler der Attributprofile (AP) sowie deren Ableitungen DAP zu bezeichnen. Durch ihre attributfilternde Eigenschaft sind sie als generalisierende Weiterentwicklung der auf SE-Grundlage operierenden Morphologischen Profile (MP) aufzufassen [116], die zu Beginn des Jahrtausends exemplarisch in [118] zur Klassifikation urbaner Gebiete auf Basis optischer Satellitenbilder Anwendung fanden. Da generell mehrere verschiedene und komplementäre Attribute zur Filterung der CC nutzbar sind, stellen AP beziehungsweise DAP im Vergleich zu MP weitaus flexiblere und auch umfassendere Methoden zur Analyse des Bildinhalts dar.

Ausgangspunkt für die Definition eines AP ist die Wahl eines Attributs  $\chi$ , sowie einer Attributwertesequenz  $\chi_i^{attr}$ , die ähnlich zu dem oben erwähnten Kriterium  $T$  zur Beurteilung der CC verwendet wird. Es sei  $\chi$  die Anzahl der Pixel (*area*) einer CC. Weiterhin sei eine Wertesequenz mit  $\chi_i^{area} = \{21; 42\}$  gegeben. Ein AP berechnet sich aus einer Abfolge von Attributöffnungen beziehungsweise -schließungen auf Grundlage eines Eingabebilds  $I$  für jeden Wert der Sequenz zu:

$$AP_{area}(I) = [\Gamma_{42,Cl,CC}^{area}(I); \Gamma_{21,Cl,CC}^{area}(I); I; \Gamma_{21,Op,CC}^{area}(I); \Gamma_{42,Op,CC}^{area}(I)]. \quad (2.27)$$

In diesem Beispiel resultiert ein fünfdimensionales AP für jedes Bildelement von  $I_{Bin}$  mit den AP-Komponentenbildern  $AP_{area}^i(I)$ . DAP sind die Ableitungen der AP und werden, dem aktuellen Beispiel folgend, mittels nachstehender Definition berechnet:

$$DAP_{area}(I) = [\Delta_1^{area}; \Delta_2^{area}; \Delta_3^{area}; \Delta_4^{area}], \quad (2.28)$$

mit

$$\Delta_1^{area} = \Gamma_{42,Cl,CC}^{area}(I) - \Gamma_{21,Cl,CC}^{area}(I) \quad (2.29)$$

$$\Delta_2^{area} = \Gamma_{21,Cl,CC}^{area}(I) - I \quad (2.30)$$

$$\Delta_3^{area} = I - \Gamma_{21,Op,CC}^{area}(I) \quad (2.31)$$

$$\Delta_4^{area} = \Gamma_{21,Op,CC}^{area}(I) - \Gamma_{42,Op,CC}^{area}(I) \quad (2.32)$$

Aufgrund ihrer Definition weisen DAP bestehend aus ihren Profilkomponenten  $DAP_{area}^i(I)$  stets eine um Eins verminderte Dimensionierung gegenüber AP auf. Als Ableitungen der AP geben DAP Aufschluß über die Sensitivität bestimmter Bildstrukturen gegenüber dem genutzten Attribut und der gewählten Wertesequenz. Hohe Differenzen (hohe DAP-Werte) weisen auf das Verschwinden der jeweiligen Struktur hin. Ein derartiges Beispiel ist in Abbildung 2.7 dargestellt, in der zwei Bildstrukturen rot und grün markiert sind. Als Grundlage für diese Visualisierung diente ein Ausschnitt mit einem LKW-Parkplatzbereich des auf 256 Grauwerte skalierten panchromatischen Bilds (WV-2) der Szene „Stuttgart Flughafen“. Als Attribut wurde *area* mit der obigen Wertesequenz verwendet. Anhand der DAP-Signaturen ist ersichtlich, dass die grün markierte Struktur eine größere Fläche besitzt als die rot markierte. Die rot markierte Struktur geht bereits mit der ersten Attributfilterung in Öffnungsrichtung verloren ( $\chi_1^{area} = 21$ ), was in der DAP-Signatur einen *Peak* an der dritten Komponentenstelle zur Folge hat (Abbildung 2.7, unten). Die größere, grün markierte Struktur reagiert erst auf den zweiten Wert der Sequenz ( $\chi_2^{area} = 42$ ), resultierend in einem *Peak* an der vierten Komponentenstelle.

Dass für diese beiden Beispielobjekte allein der rechte Teil der Profile (Öffnungen) auf die Wertesequenz reagiert, ist dadurch begründet, dass die Attributschließung auf Basis des komplementierten Eingabebilds durchgeführt wird (vergleiche hierzu auch Abbildung 2.8, unten) und somit für helle Bildstrukturen wenig bis kein Verhalten aufweist.

Mit dem oben genannten und visualisierten Beispiel zur Erstellung von AP und DAP anhand des Attributs *area* wird neben der Ableitung strukturbezogener Signaturen auch die glättende Eigenschaft der zusammenhängenden Attributfilterung ersichtlich, die je nach Filterungsschritt (Öffnung oder Schließung) auf hellen oder dunklen Bildobjekten ansetzt. Diese Eigenschaft wird bei den ASF zur Glättung verrauschter Bildinhalte genutzt. Durch sukzessive Verwendung größer werdender SE mit jedem Iterationsschritt verzeichnen ASF insbesondere bei eng aneinander liegenden Störungen unterschiedlicher Größe und Helligkeit Vorteile gegenüber einer alternierenden Filterung mittels eines vordefinierten, festen SE [29]. Diese klassische Ausprägung kann unmittelbar auf die zusammenhängenden Attributfilter übertragen werden, wenn anstelle eines in seiner Form vordefinierten SE die im Bild enthaltenen Strukturen anhand der CC betrachtet werden. Es resultiert ein die Bildstrukturen erhaltender (zusammenhängender)  $ASF_{CC}$ , der beispielsweise für das Attribut *area* wie folgt definiert ist:

$$ASF_{CC;i=1}^n := \begin{cases} I_{i,Op,CC} = \Gamma_{i,Op,CC}^{area}(I_i), & \text{zunächst,} \\ I_{i,Cl,CC} = \Gamma_{i,Cl,CC}^{area}(I_{i,Op,CC}^C), & \text{dann.} \end{cases} \quad (2.33)$$

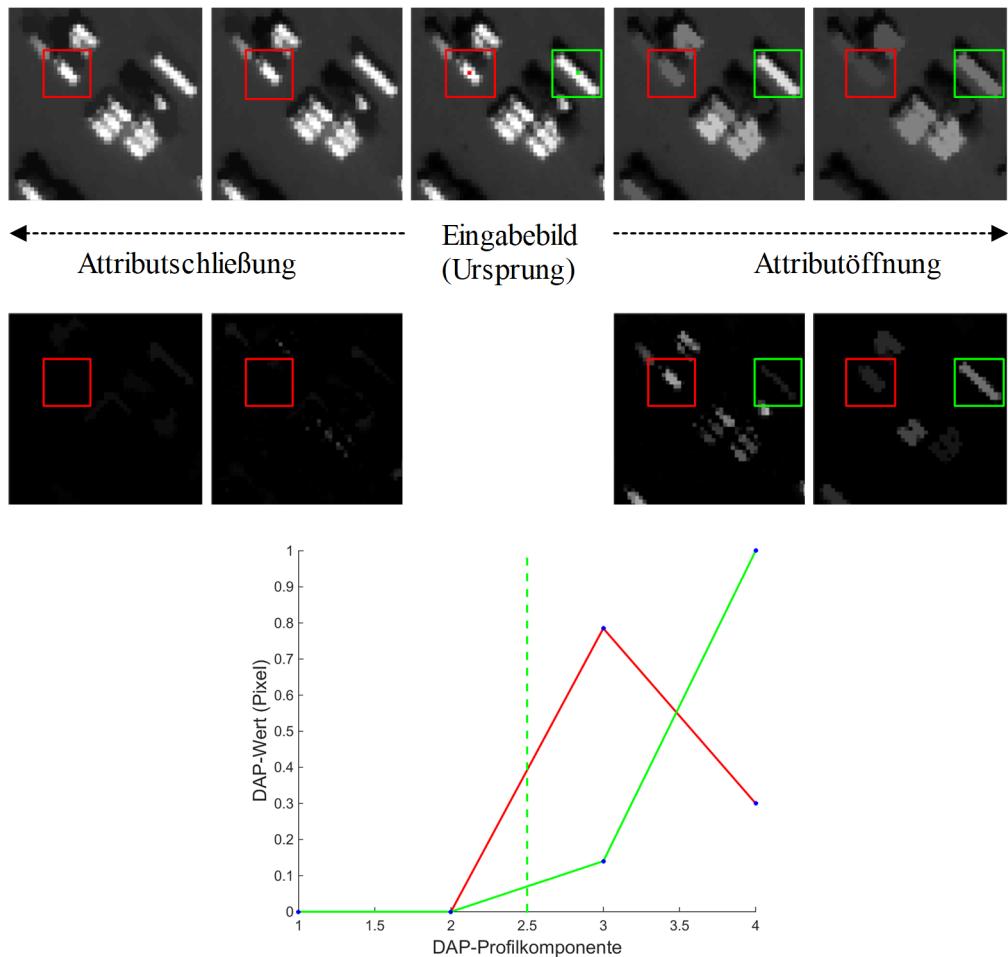


Abbildung 2.7.: AP-Komponenten (oben), DAP-Komponenten (Mitte) und DAP-Pixelsignaturen der markierten Strukturen (unten). Die gestrichelte grüne Linie kennzeichnet den Ursprung des Profils.

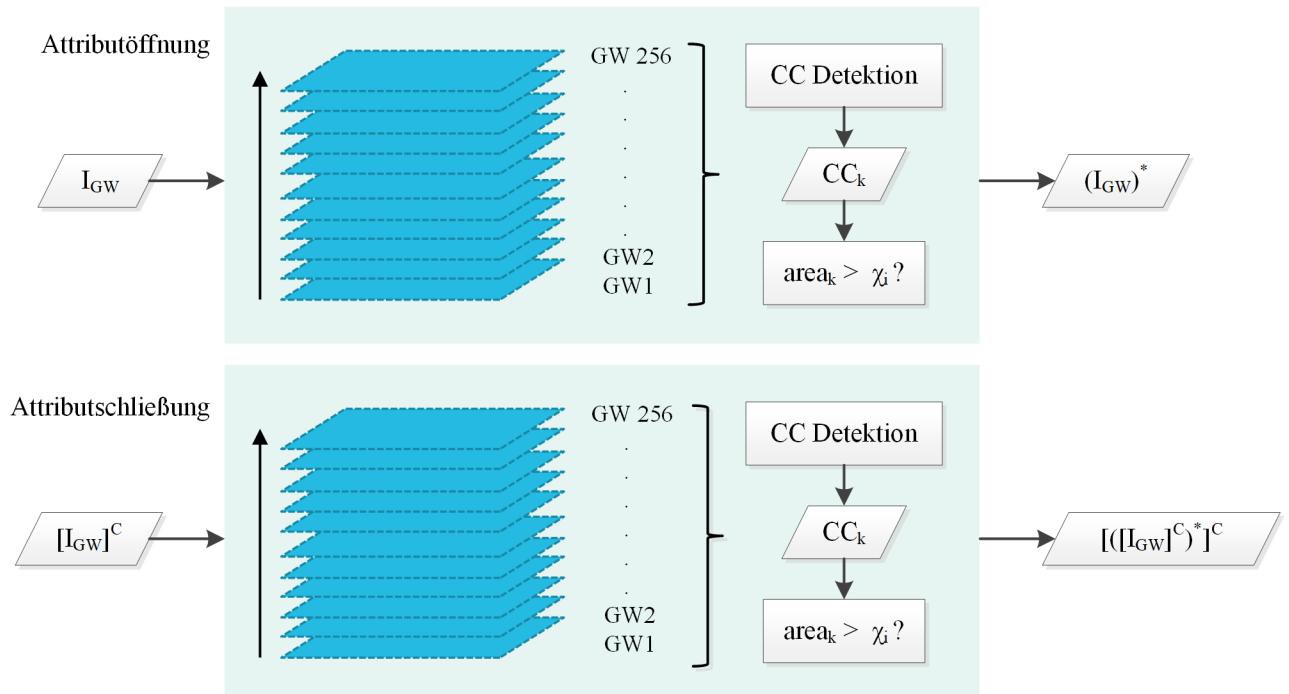


Abbildung 2.8.: Skizzierter Ablauf der Attributöffnung (oben) und -schließung (unten). Ein hochgestelltes C symbolisiert eine Komplementierung, ein hochgestelltes \* kennzeichnet ein Resultat einer Attributfilterung.

mit der Länge  $n$  der Wertesequenz  $\chi_i^{area}$  und

$$I_i = \begin{cases} \text{Eingabebild,} & \text{für } i=1, \\ I_{i-1,Cl,CC}^C, & \text{sonst.} \end{cases} \quad (2.34)$$

Im Zuge der vorliegenden Thematik kommen ASF in zweierlei Hinsicht zum Einsatz. Einerseits motiviert das stark verrauchte Quotientenbild (Abbildung 2.9, rechts) als Grundlage für die Detektion von Änderungen die ASF-Nutzung im Hinblick auf die Erkennung von Strukturen beziehungsweise Objekten bestimmter Größe. Die Vorgabe einer der jeweiligen Anwendung entsprechenden Wertesequenz  $\chi_i^{area}$  ermöglicht die gezielte Suche nach angeforderten Änderungsobjekten. Im obigen Beispiel mit  $\chi_i^{area} = [21, 42]$  gehen exemplarisch Objekte mit Flächen kleiner als 42 Pixel verloren. Andererseits ist bei der Segmentierung von SAR-Amplitudenbildern zur Ableitung eines den örtlichen Kontext beschreibenden Merkmals (Abschnitt 4.2.1) auf eine Vorverarbeitung mit einem geeigneten Filterungsverfahren zu achten, was unmittelbar eine Verwendung von ASF nahelegt.

Im nachfolgenden Abschnitt werden die Grundlagen für die spätere Erläuterung der Methode zur Änderungsdetektion basierend auf einem verrauchten Quotientenbild vermittelt.

### 2.2.2. Entropiebasierte Schwellwertberechnung

Wie bereits in Abschnitt 1.1 skizziert, existiert eine Vielzahl unterschiedlicher Verfahren zur unüberwachten Schwellwertberechnung und damit auch zur unüberwachten Detektion von Veränderungen. Alle derartigen Verfahren haben die Bestimmung eines geeigneten Schwellwerts gemein, der Vorder- und Hintergrund eines Bildinhalts voneinander abgrenzt. Im Hinblick auf die statistische Verteilung der Grauwerte kann dieser Bildinhalt allgemein in zwei zentrale Kategorien untergliedert werden: Bimodale und multimodale Verteilungen [119]. Von bimodal verteilten Bilddaten spricht man, wenn sich Objekt- und Hintergrundinformationen klar unterscheiden, was sich im Grauerthistogramm durch die typische *Zwei-Hügel-Form* zeigt. Der passende Schwellwert zur Separierung der beiden Informationsklassen ist direkt ableitbar und befindet sich im Tal zwischen den beiden Hügeln. Im Gegensatz dazu besitzen multimodale verteilte Bildinhalte verschiedene Vordergrundobjekte unterschiedlicher Grauwertausprägung, die den Einsatz sogenannter *Multilevel-Thresholding*-Techniken notwendig machen. Anstatt ein Tal zu detektieren werden mehrere Täler in verschiedenen Grauwertebenen gesucht. Aus diesem Grund werden multimodale Verfahren auch als Erweiterung bimodaler Techniken bezeichnet [119]. Neben diesen beiden Hauptkategorien können Bilddaten auch keine spezifische statistische Verteilung der Grauwerte aufweisen, die auf eine klare Trennung der beiden Informationsklassen hinweisen. Solch unimodale Verteilungen besitzen keine Täler, die Hinweise auf geeignete Schwellwerte ermöglichen. SAR-Amplituden- und Intensitätsbilder sind *rayleigh*- beziehungsweise *exponentialverteilt* und weisen, wie auch das in der vorliegenden Arbeit zur Änderungsdetektion genutzte 8-Bit-skalierte Quotientenbild, unimodale Charakteristik auf (Abschnitt 2.1 und Abbildung 2.9). Derartige Grauwertverteilungen erfordern Schwellwert-Techniken, die unabhängig von Vorgaben hinsichtlich der Form der Verteilung sind. Entropiebasierte Verfahren sind eine Variante derartiger Techniken. In [84] findet sich eine umfassende Auflistung verschiedener entropiebasierter Methoden.

Der Begriff der Entropie mit Bezug zur Bildverarbeitung besitzt seinen Ursprung in der Informationstheorie, in der diese allgemein als Unsicherheit beziehungsweise Unbestimmtheit des Informationsgehalts eines Systems beschrieben wird, die mittels Wahrscheinlichkeitsverteilungen modelliert wird [120] (siehe auch *Shannon's Entropiebegriff* [121]). Übertragen auf digitale Bilddaten bedeutet dies die Analyse der Grauwertverteilungen eines Bilds  $I_{GW}$ . Eine Möglichkeit zur Schwellwertberechnung ist durch die Maximierung der Entropie gegeben, bei der maximaler Informationsgewinn erreicht wird [84]. Andere Vorgehensweisen umfassen die Minimierung der Kreuz-Entropie, die als Maß für die Datenkonsistenz zwischen Eingabebild und resultierendem Binärbild interpretiert wird, sowie *fuzzy*-basierte Entropiemethoden, die die Zugehörigkeiten der Bildelemente zu den beiden Klassen Vorder- und Hintergrund als unscharfe, nicht binäre Verhältnismäßigkeiten auffassen [84]. Aufgrund der immensen Anzahl an unterschiedlichen entropiebasierten Methoden werden im Rahmen dieser Arbeit drei Verfahren exemplarisch ausgewählt, die nachfolgend detaillierter erläutert werden. In Abschnitt 6.3.2 findet sich eine Gegenüberstellung dieser Verfahren vor dem Hintergrund einer praktischen Anwendung auf die hier vorliegenden Daten.

Die in [95] enthaltene Schwellwertmethode basierend auf der Arbeit von Renyi [122] beurteilt die Entropien des Vorder- und Hintergrunds von  $I_{GW}$ . In dieser Arbeit wird diese Methode vereinfacht als Schwellwertverfahren nach *Renyi* bezeichnet.

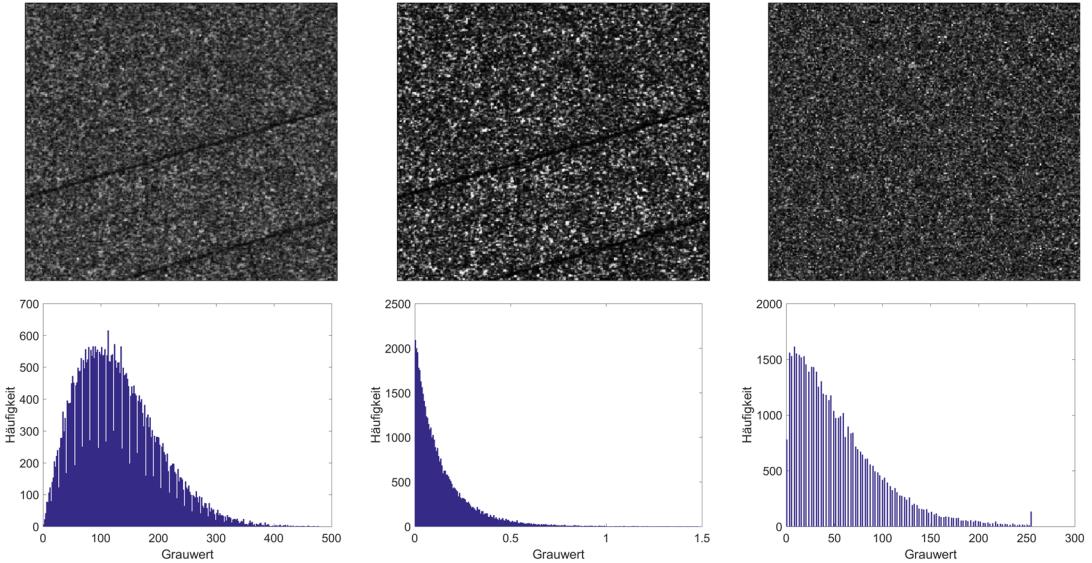


Abbildung 2.9.: Ausschnitte aus einem TSX-Amplitudenbild (oben links), einem  $\sigma^0$ -kalibrierten TSX-Intensitätsbild (oben Mitte), sowie aus einem skalierten Quotientenbild (oben rechts). In der unteren Zeile befinden sich die entsprechenden Histogramme.

Den Kern des Verfahrens bildet ein zweidimensionales Histogramm, das aus Bildvorder- und hintergrundinformation erstellt wird. Dieses Histogramm ist wiederum die Grundlage für die Berechnung der jeweiligen Entropien  $H$ . Die Entropien berechnen sich für jedes Grauwertpaar  $(i, j)$  wie folgt, wobei  $b$  den Vordergrund,  $w$  den Hintergrund und das Grauwertpaar  $(t, s)$ , die jeweils aktuellen Schranken für Vorder- und Hintergrund bezeichnen (Nomenklatur entsprechend [95]):

$$H_b^\alpha(t, s) = \frac{1}{1 - \alpha} \ln \sum_{i=0}^t \sum_{j=0}^s \left( \frac{p(i, j)}{P_2(t, s)} \right)^\alpha, \quad (2.35)$$

und

$$H_w^\alpha(t, s) = \frac{1}{1 - \alpha} \ln \sum_{i=t+1}^{255} \sum_{j=s+1}^{255} \left( \frac{p(i, j)}{1 - P_2(t, s)} \right)^\alpha, \quad (2.36)$$

mit der Häufigkeit  $p$ , mit der ein bestimmtes Grauwertpaar  $(i, j)$  im Histogramm enthalten ist und mit der a-posteriori Wahrscheinlichkeit  $P_2$ :

$$P_2(t, s) = \sum_{i=0}^t \sum_{j=0}^s p(i, j), \quad (2.37)$$

wobei  $P_2 \approx 1 - P_4$  gilt, mit:

$$P_4(t, s) = \sum_{i=t+1}^{255} \sum_{j=s+1}^{255} p(i, j). \quad (2.38)$$

Der positiv reelle Parameter  $\alpha$  mit ( $\alpha \neq 1$ ) stellt den einzigen Wert dar, der a-priori zu definieren ist. Im Rahmen dieser Arbeit wird der Parameter in Anlehnung an [95] auf  $\alpha = 0,5$  gesetzt. Ein optimales Paar an Schwellwerten  $(t^*(\alpha), s^*(\alpha))$  resultiert dann, wenn die Summe der beiden Entropien maximal ist:

$$(t^*(\alpha), s^*(\alpha)) = \operatorname{Arg} \max_{(t,s) \in G \times G} [H_b^\alpha(t, s) + H_w^\alpha(t, s)], \quad (2.39)$$

mit der Menge  $G = \{0, 1, 2, \dots, 255\}$  der möglichen Grauwerte.

Eine zur Methode nach *Renyi* ähnliche Methode mit  $\alpha \rightarrow 1$  verfolgt das Verfahren nach *Kapur* [123], mit der Ausnahme, dass kein zweidimensionales Histogramm zur Entscheidungsfindung genutzt wird ([119] und [84]). Der optimale Schwellwert zur Unterscheidung zwischen Bildvorder- und hintergrund wird analog zu *Renyi* durch Maximierung der Summe der entsprechenden Entropien berechnet. Der Nachteil der Methode

nach *Kapur* liegt beispielsweise in der Bestimmung der a-priori Entropie für den gesamten Bildinhalt  $H_T$ , die wie folgt definiert ist:

$$H_T = - \sum_{i=0}^{255} p_i \ln p_i. \quad (2.40)$$

Da es grundsätzlich möglich ist, dass  $p_i$  sehr gering oder gar Null ist, resultieren durch Anwendung des Logarithmus große Berechnungsgenauigkeiten, die den ermittelten Schwellwert nicht repräsentativ erscheinen lassen [119].

Wird  $\alpha = 2$  gewählt, ergibt sich das Verfahren nach *Yen* ([124] und [84]). Im Vergleich zu den Verfahren nach *Renyi* und *Kapur* wird hierbei der Schwellwert durch Maximierung der entropiebezogenen Korrelation berechnet. Für weiterführende Informationen sowie für detaillierte formale Definitionen zu den Methoden nach *Kapur* und *Yen* sei an dieser Stelle auf die entsprechenden, ursprünglichen Arbeiten verwiesen.

Nach dieser Beschreibung der Zusammenhänge für das genutzte Verfahren zur Änderungsdetektion wird in den nachfolgenden Abschnitten auf Grundlagen eingegangen, die für das Verständnis der späteren Kategorisierung und Klassifikation notwendig sind.

### 2.2.3. Texturanalyse und Grauwertmatrix

Der Begriff der Textur umschreibt generell eine regelmäßige Anordnung eines Elements oder Musters einer Oberfläche [125]. Im Hinblick auf die Bedeutung im Umfeld der Computergrafik definiert der Duden die Textur als die Oberflächenstruktur eines grafisch dargestellten Objekts [14]. Diese Oberflächenstruktur eines abgebildeten Objekts weist eine texturelle Ausprägung auf, wenn ihre Grauwerte keine homogene Charakteristik besitzen, was beispielsweise auf die physikalischen Eigenschaften der Oberfläche zurückzuführen ist [126]. Zur Analyse der räumlichen Anordnung der Grauwerte existiert eine Vielzahl unterschiedlicher Verfahren, wobei man grob zwischen statistischen (exemplarisch: Grauwertmatrix GLCM) und signalbasierten Methoden (zum Beispiel *Gabor*-Filter) unterscheiden kann [126]. Die auf der GLCM basierenden, in [127] definierten Merkmale repräsentieren einen bewährten Ansatz, der bereits für eine Vielzahl bildbasierter Analysen, beispielsweise auch mit SAR-Bezug verwendet worden ist [128].

Eine GLCM ist eine quadratische Matrix, die Informationen darüber enthält, wie oft ein bestimmtes Referenzpixel mit dem Grauwert  $i$  in Anbetracht einer vorgegebenen (räumlichen) Beziehung  $R$  zu einem benachbarten Pixel mit dem Grauwert  $j$  in einem Bild  $I$  oder in einem Ausschnitt daraus enthalten ist [129]. Somit sind die Elemente einer GLCM Häufigkeiten beziehungsweise relative Frequenzen  $p_{i,j}$ , mit denen zwei durch eine Distanz  $d$  voneinander getrennte Pixel mit den Grauwerten  $i$  und  $j$  in  $I$  vorliegen [127]. Mit der Anzahl an Zeilen  $M$  und Spalten  $N$  des Rasters  $I$  ergibt sich formell folgende Definition:

$$GLCM(i, j) = \sum_{x=1}^M \sum_{y=1}^N \begin{cases} 1, & \text{wenn } I(x, y) = i \text{ und } I(x + d_x, y + d_y) = j, \\ 0, & \text{sonst.} \end{cases} \quad (2.41)$$

Neben dem Abstand  $d$  ist  $R$  ferner durch die Orientierung  $o$  definiert, mit der vier verschiedene Richtungen berücksichtigt werden können:  $o = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ . Abbildung 2.10 enthält ein Beispielbild  $I$  sowie die daraus resultierende GLCM mit den Einstellungen  $d = 1$  und  $o = 0^\circ$ . Auf Grundlage der GLCM können verschiedene Maßzahlen (*Haralick*-Parameter) bestimmt werden, von denen nachfolgend in Anbetracht der vorliegenden Arbeit eine Auswahl beschrieben ist (siehe auch [130]).

Der Kontrast  $T_{Kontr}$  ist ein Maß für die Konstanz oder Ebenheit des Eingabebildes  $I$ . Den obigen Notationen folgend, berechnet sich der Kontrast mit der Menge  $G = \{0, 1, 2, \dots, 255\}$  der möglichen Grauwerte zu:

$$T_{Kontr} = \sum_{i=0}^G \sum_{j=0}^G p_{i,j} (i - j)^2, \quad (2.42)$$

und ergibt Null für ein ideal konstantes Bild.

Anhand der Homogenität  $T_{Hom}$  kann die Verteilung der Elemente der GLCM entsprechend ihrer Position zur Hauptdiagonalen der GLCM beurteilt werden. Die Homogenität wird mit der Vorschrift

$$T_{Hom} = \sum_{i=0}^G \sum_{j=0}^G \frac{p_{i,j}}{1 + (i - j)^2} \quad (2.43)$$

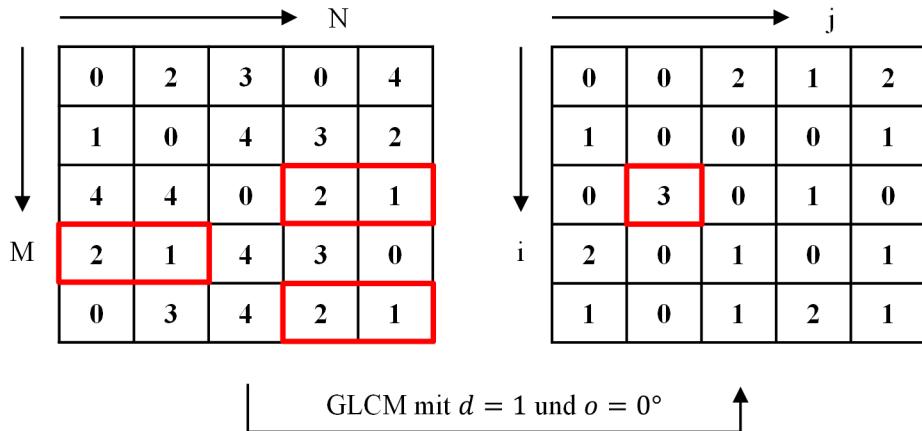


Abbildung 2.10.: Beispiel zur GLCM-Berechnung. Rot markiert:  $p_{i,j}$  mit  $(i,j) = (2,1)$ .

berechnet, und ist Eins, wenn die GLCM eine Diagonalmatrix ist.

Die Energie  $T_{En}$  ist auch als zweites angulares Moment oder Einheitlichkeit bekannt und folgt nachstehender Definition:

$$T_{En} = \sum_{i=0}^G \sum_{j=0}^G p_{i,j}^2. \quad (2.44)$$

Relativ kleine Werte für die Energie werden in einem konstanten Bild gemessen, in dem alle Grauwerte gleich sind.

Die Korrelation  $T_{Korr}$  liefert Informationen darüber, wie stark ein bestimmtes Pixel mit den benachbarten Elementen korreliert ist. Sie wird wie folgt berechnet:

$$T_{Korr} = \sum_{i=0}^G \sum_{j=0}^G p_{i,j} \left[ \frac{(i - \mu_x)(j - \mu_y)}{\sqrt{(\sigma_x^2)(\sigma_y^2)}} \right], \quad (2.45)$$

wobei  $\mu_x, \mu_y$  die Mittelwerte und  $\sigma_x, \sigma_y$  die Standardabweichungen der Zeilen und Spalten der GLCM bezeichnen.

Ähnlich zu der Definition mit Schwellwertbezug (Abschnitt 2.2.2) verkörpert die texturbasierte Entropie  $T_{Entr}$  ein Maß für die Zufälligkeit beziehungsweise Unordnung. Im Fall eines Eingabebilds  $I$  mit regelmäßiger Grauwertvariation (zum Beispiel Schachbrettmuster) resultiert eine sehr geringe texturbasierte Entropie. Diese wird wie folgt berechnet:

$$T_{Entr} = \sum_{i=0}^G \sum_{j=0}^G p_{i,j} (-\ln(p_{i,j})). \quad (2.46)$$

Diese hier vorgestellten fünf Merkmale sind die in dieser Arbeit genutzten Texturparameter. Für jedes detektierte HAO wird dementsprechend ein fünfdimensionaler Texturvektor berechnet und der Merkmalsmatrix angefügt.

Im Gegensatz zu den Texturparametern, die jeweils in Bezug zu einem Referenzpixel bestimmt werden, liefern objektbasierte Merkmale Informationen über zu Segmenten gruppierten Bildelementen. Der nachfolgende Abschnitt vermittelt hierzu einen Einblick.

#### 2.2.4. Objektbasierte Bildanalyse

Wie bereits in Abschnitt 1.1 im Hinblick auf Methoden zur Änderungsdetektion beziehungsweise Änderungsanalyse beschrieben, vereint die OBIA im Vergleich zur pixelbasierten digitalen Bildverarbeitung in Anbe tracht der räumlichen Auflösung heutiger Sensorsysteme gewichtige Vorteile. Da die OBIA ein äußerst umfangreiches Forschungsgebiet mit multiplen Verfahren darstellt, wird nachfolgend der Fokus auf die regionenbasierte Verarbeitungsweise gelegt. Als Fallbeispiel dient hierfür die MrSeg-Methode, die in Abschnitt 6.3.3 mit der in Abschnitt 4.2.1 vorgestellten Entwicklung verglichen wird. Im Anschluss erfolgt ein kurzer Abriss über bereits vorhandene Verfahren zur Segmentierung von SAR-Bilddaten.

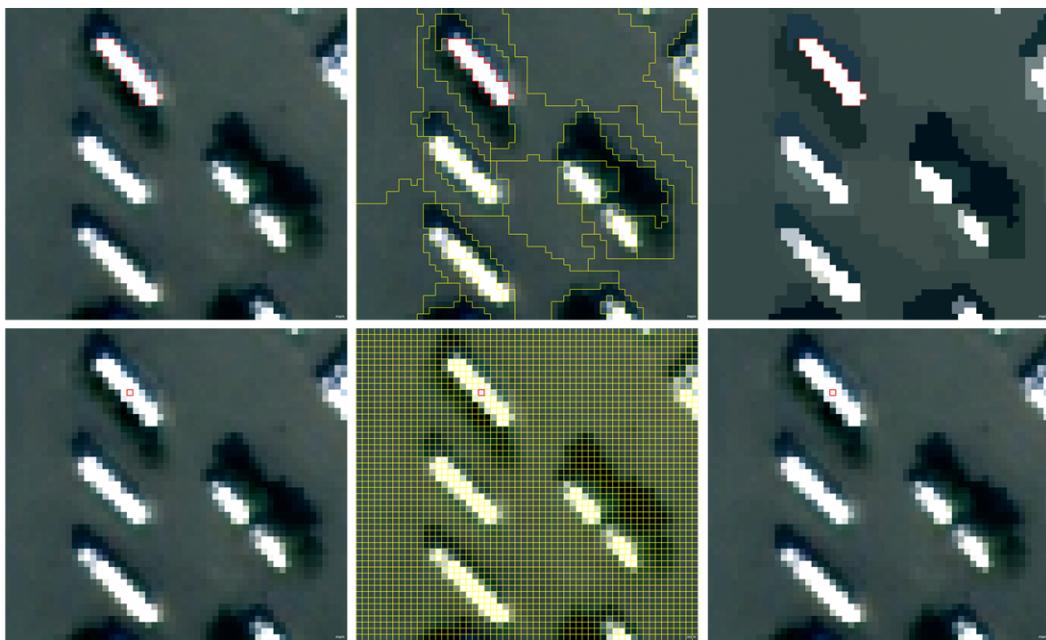


Abbildung 2.11.: Objektbasiert (oben) und pixelbasiert (unten). Jeweils von links nach rechts: Selektiertes Segment (rot), Segmentgrenzen (gelb), visualisierter mittlerer Segmentwert.

Eine umfassende und detaillierte Übersicht zur OBIA und zu ihrer historischen Entwicklung inklusive entsprechender Arbeiten ist exemplarisch in [131] enthalten. In anschaulicher Weise wird aufgezeigt, dass für eine sinnvolle Analyse auf Basis räumlich hochauflösender Bilddaten traditionelle pixelbasierte Ansätze nicht zielführend sind. Eine ähnliche Problembeschreibung der pixelbasierten Herangehensweise ist in [132] zu finden. Dort werden die Bildelemente hochauflösender Bilddaten zur Wiedergabe wahrer geographischer Objekte als ungeeignet bezeichnet.

In Abbildung 2.11 ist eine objektbasierte Visualisierung eines optischen Eingabebildes der pixelbasierten Variante gegenübergestellt. Als Bild wurde ein Ausschnitt des pangeschräften WV-2-Bilds der Testszene „Stuttgart Flughafen“ verwendet. Die Resultate wurden mit der Software *eCognition Developer* (Produktversion 9.1) durch Anwendung der MrSeg-Methode erzeugt, wobei die pixelbasierte Ausprägung mittels sehr kleinem *Scale Parameter* erreicht wurde. Es ist ersichtlich, dass aufgrund der hohen räumlichen Auflösung einzelne Objekte der realen Welt (hier: LKW) durch eine Vielzahl unterschiedlicher Pixel mit variierendem Grauwert abgebildet werden. Mittels der oberen Reihe der Abbildung, die die objektbasierte Verfahrensweise darstellt, ist unmittelbar ersichtlich, dass einzelne LKW als homogene Segmente dargestellt werden.

Werden pixelorientierte Ansätze zur Analyse (zum Beispiel Klassifikation) hochauflösender Bilder genutzt, resultiert eine Art *Salt-and-Pepper*-Effekt, der die Genauigkeit der Resultate stark einschränkt [133]. Derartige konventionelle Methoden beurteilen die spektralen Eigenschaften der einzelnen Pixel, wohingegen objektorientierte Verfahrensweisen auf Grundlage von zu Segmenten fusionierten homogenen Bildelementen operieren [134], die den Aufbau umfangreicher und komplexer Regelsysteme zur detaillierten Analyse der jeweiligen Szene ermöglichen. Die Homogenität bezeichnet den zentralen Aspekt sämtlicher Segmentierungsverfahren, die hinsichtlich ihrer Prozessierungsweise in verschiedene Kategorien untergliedert werden können [24].

Methoden des Regionenwachstums (*Region Growing*) starten auf der Ebene initialer *Seed Pixel* und fassen Pixel mit ähnlichen (zum Beispiel spektralen) Eigenschaften so lange zu größeren Einheiten zusammen, bis diese ein vorgegebenes Homogenitätskriterium nicht mehr erfüllen [25]. Der Begriff der Homogenität (auch als minimale Heterogenität verstanden (siehe [25])), ist im MrSeg-Algorithmus in eine räumliche (*Shape*) und eine spektrale (*Color*) Komponente aufgeteilt [135]. Die räumliche Heterogenität wird durch zwei formbeschreibende Attribute ausgedrückt: *Smoothness* (Glattheit) und *Compactness* (Kompaktheit). Die Glattheit ist definiert als der Quotient aus Segmentumfang und dem Umfang des Rechtecks, welches das Segment minimal approximiert (*Bounding Box*). Die Kompaktheit berechnet sich mittels des Quotienten aus Segmentumfang und der Quadratwurzel aus der Segmentfläche in der Einheit Pixel. Die spektrale Heterogenität basiert auf den Rückstreu- beziehungsweise Reflexionseigenschaften der in einem Segment enthaltenen Bildelemente [25]. Weitere zentrale Parameter der MrSeg-Methode sind der *Fusion Factor*  $f$ , der den Anstieg der Heterogenität mit jedem neu zu einem Segment hinzugefügten Pixel wiedergibt, sowie der *Scale Parameter*  $e$ , der als Schwellwert zur Fusionsentscheidung genutzt wird. Ein bestimmtes Pixel wird nur dann einem Segment hinzugefügt, wenn der berechnete Wert für  $f$  unterhalb der Vorgabe für  $e$  liegt. Auf eine detaillierte formelle Beschreibung

der MrSeg-Methode wird an dieser Stelle verzichtet und auf [136], [135] und [25] verwiesen.

Im Gegensatz dazu wird vielmehr anhand eines visualisierten Beispiels die Wirkungsweise des Algorithmus für verschiedene Parametereinstellungen aufgezeigt. Als Eingabebild dient der auch in Abbildung 2.12 dargestellte Ausschnitt des pangeschräften WV-2-Bilds, der einen LKW-Parkplatz zeigt. Anhand eines für alle Prozessierungen konstant gewählten *Scale Parameter* kann die Veränderung der Segmentformen für variierende Homogenitätseinstellungen beobachtet werden. Mit einer ansteigenden Gewichtung des *Shape*-Merkmals geht eine absteigende Gewichtung des *Color*-Werts einher, was sich generell an einer größeren Segmentierung bemerkbar macht (Abbildung 2.12, A bis E), da feine spektrale Differenzen der einzelnen Pixel weniger stark für die Segmentierung maßgeblich sind. Im Hinblick auf die Komponenten der räumlichen Homogenität ist ersichtlich, dass eine stärkere Gewichtung der *Compactness* mit einer schwächeren Gewichtung der *Smoothness* einhergeht und zu einer rechteckigeren Form der Segmente führt (Abbildung 2.12, zum Beispiel A vs. B). Allgemein festzuhalten ist, dass die Einstellungen der Segmentierungsparameter für die MrSeg-Methode im Rahmen eines *Trial-and-Error*-Prozesses zu erfolgen hat. Eine generell gültige und optimale Segmentierungseinstellung existiert somit nicht.

Wie bereits oben erwähnt, können unter anderem formbeschreibende Merkmale zur Beschreibung der Bildsegmente genutzt werden. Analog zu den Definitionen in [135] werden für die vorliegende Arbeit verschiedene derartige Merkmale verwendet, die nachfolgend ausführlicher erläutert werden.

Die Fläche  $S_{area}$  eines Segments  $S$  wird berechnet aus der Anzahl seiner Pixel  $p$  an den Stellen  $(i, j)$  und bezeichnet somit die Segmentgröße:

$$S_{area} = \sum p_{i,j}. \quad (2.47)$$

Ein weiteres formbeschreibendes Merkmal ist durch die Rundheit  $S_{round}$  gegeben, das Aufschluss über die gestaltbezogene Übereinstimmung des Segments mit einer minimal approximierenden Ellipse  $E$  gibt:

$$S_{round} = \frac{\Delta(foc_A, foc_B)}{l_{ma}}, \quad (2.48)$$

mit der Distanzfunktion  $\Delta()$  zur Berechnung des Abstands zwischen den beiden Brennpunkten  $foc_A$  und  $foc_B$  der Ellipse sowie der Länge  $l_{ma} = 2a$  der Ellipsenhauptachse (Abbildung 2.13).

Die Kompaktheit eines zweidimensionalen Segments  $S_{compact}$  basiert auf der Beurteilung der Ähnlichkeit mit einem minimal approximierenden Rechteck und kann wie folgt anhand dessen Geometrie und der Segmentfläche  $S_{area}$  berechnet werden:

$$S_{compact} = \frac{l_{BB}w_{BB}}{S_{area}}, \quad (2.49)$$

mit der Länge  $l_{BB}$  und der Breite  $w_{BB}$  des jeweiligen Rechtecks  $BB$  (Abbildung 2.13).

Eine andere Beschreibung der Segmentgestalt erfolgt durch das Dichtemerkmal  $S_{dens}$ , das die räumliche Verteilung der Segmentpixel  $p_{i,j}$  im Bild charakterisiert. Ein Segment ist ideal dicht, wenn es eine quadratische Form aufweist. Je unidichter ein Segment ist, desto mehr ähnelt seine Gestalt einer linienförmigen Struktur [135]. Die Berechnung der Dichte erfolgt anhand der folgenden Vorschrift:

$$S_{dens} = \frac{\sqrt{S_{area}}}{1 + d_e}, \quad (2.50)$$

mit dem Durchmesser  $d_e$  der Ellipse zu:

$$d_e = \frac{\sqrt{S_{area}}}{2 \cdot \sqrt{a^2b^2 / (b^2 \cos^2 \omega + a^2 \sin^2 \omega)}}, \quad (2.51)$$

wobei  $a$  die halbe Hauptachsenlänge,  $b$  die halbe Nebenachsenlänge und  $\omega$  den durch die Bildhorizontalen (x-Achse) und die Hauptachse der Ellipse eingeschlossenen Winkel kennzeichnen (Abbildung 2.13).

In Bezug auf die Segmentierung von SAR-Bildern wurde auch die MrSeg-Methode bereits genutzt und eine verstärkte Gewichtung des *Color*-Werts vorgeschlagen [137]. Als Datengrundlage dienten unter anderem multitemporale, räumlich hochauflösende TSX-Bilder, die für die Segmentierung mittels radiometrischer Kalibrierung, Speckle-Filterung und Orthorektifizierung vorverarbeitet wurden, wovon insbesondere der Filterungsschritt essentielle Bedeutung für die Qualität der Segmentierungsresultate besitzt. Neben dieser speziellen regionenbasierten Segmentierungsmethode wurde eine Vielzahl weiterer Verfahren der OBIA auf SAR-Bildern entwickelt. Diese reichen von einfachen histogrammbasierten Methoden [138] über verschiedene statistische Ansätze ([139], [140], [141] und [142]) bis hin zu morphologisch orientierten Konzepten ([143]).

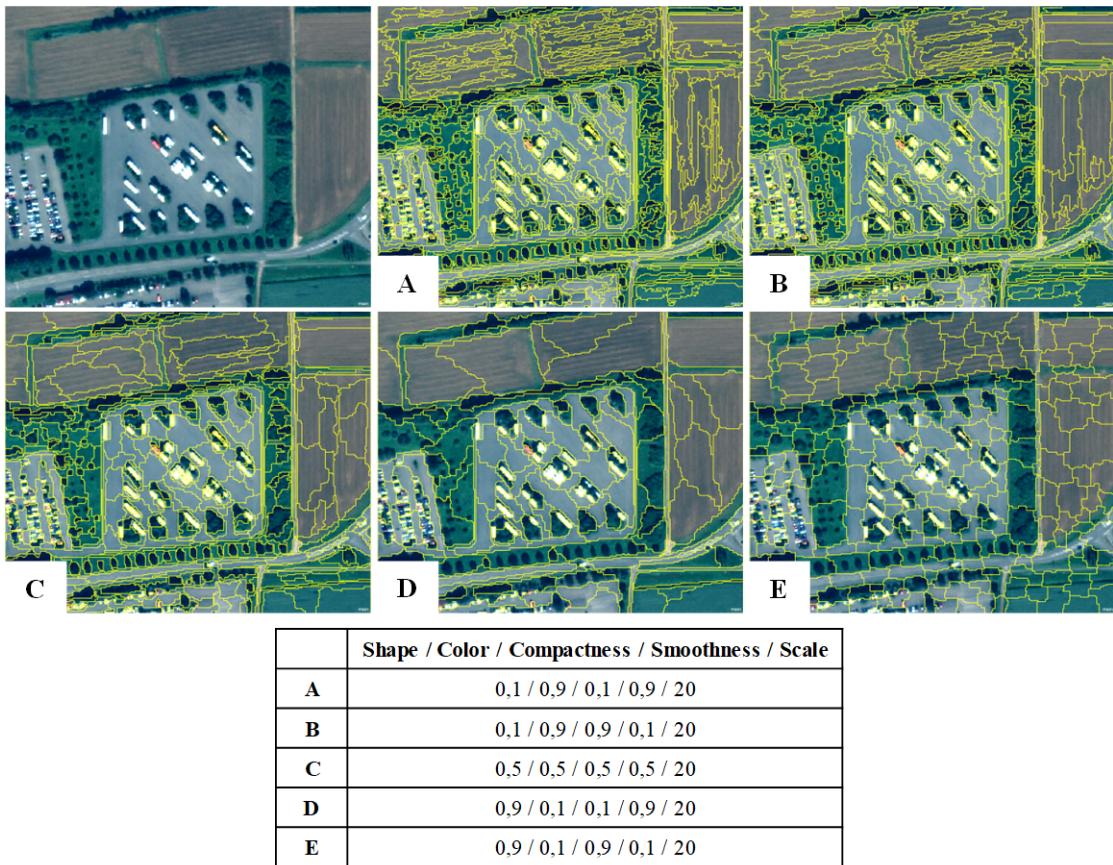
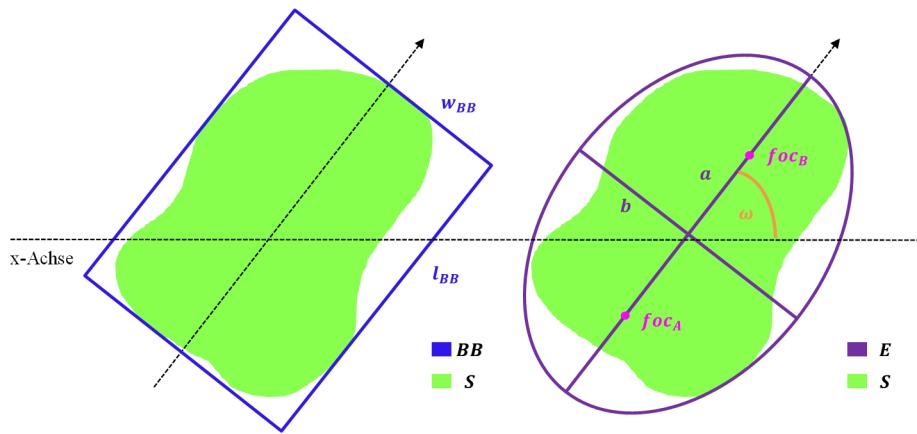


Abbildung 2.12.: MrSeg-Resultate für verschiedene Parameterkombinationen (siehe Tabelle).

Abbildung 2.13.: Darstellung der geometrischen Zusammenhänge für die Merkmale  $S_{round}$ ,  $S_{compact}$  und  $S_{dens}$ .

und [144]). Ferner wurde die in Abschnitt 2.2.2 beschriebene Entropie nach Renyi in abgewandelter Form zur Segmentierung von SAR-Bildern vorgeschlagen [145].

Die im Rahmen der vorliegenden Arbeit entwickelte, zur Ableitung kontextbezogener Aussagen genutzte Segmentierungsmethode, basiert auf den in Abschnitt 2.2.1 erläuterten DAP. Als vorverarbeitender Schritt zur Speckle-Reduzierung werden Varianten der  $ASF_{CC}$  verwendet. Eine ausführliche Beschreibung dieser Methode ist in Abschnitt 4.2.1 enthalten.

Durch die Fülle der in dieser Arbeit verwendeten Merkmale (Kapitel 4) in Kombination mit der großen Anzahl an Hochaktivitätsobjekten (siehe Abschnitt 3.2.3) resultiert eine hochdimensionale Merkmalsmatrix, deren Reduzierung auf tatsächlich maßgebliche Komponenten für spätere Verarbeitungsschritte notwendig ist. Im nachfolgenden Abschnitt werden entsprechende Methoden vorgestellt.

### 2.2.5. Hochdimensionale Datensätze und deren Reduzierung

Für die vorgestellte Änderungsanalyse wird eine Vielzahl verschiedener Merkmalsgruppen zur Beschreibung der HAO verwendet (Morphologie, Textur, Form). Je Gruppe und je HAO resultiert ein Merkmalsvektor, der im kleinsten Fall eine Dimension 5 hat. Bei einer sehr großen Anzahl an HAO ergibt sich eine hochdimensionale Merkmalsmatrix, deren direkte Weiterverarbeitung ohne Reduzierung einige Probleme zur Folge hätte.

Bei der Verarbeitung hochdimensionaler Merkmalsräume ist beispielsweise das *Hughes-Phänomen* zu beobachten, das beschreibt, wie stark eine solche Datenbasis die Leistungsfähigkeit des jeweiligen Systems hinsichtlich der Klassifikationsgüte einschränkt [146]. Neben dem Hughes-Phänomen spielt bei derartigen Datensätzen der *Fluch der Dimensionalität (Curse of Dimensionality)* eine Rolle, der unter anderem die Schwierigkeit bezeichnet, einen dünn besiedelten Merkmalsraum zur Kategorisierung der Daten in Abhängigkeit eines gewählten Berechnungsverfahrens einzusetzen [147]. Bildlich beschrieben bedeutet dies, dass ein hochdimensionaler Merkmalsraum nicht homogen durch die Datenpunkte ausgefüllt ist, sondern sehr viele und große Lücken besitzt. Im Hinblick auf eine Auswertung der Distanzen in diesem Raum hat dies zur Folge, dass sich die kleinste und die größte Distanz zwischen einzelnen Datenpunkten voneinander nur noch wenig unterscheiden, was bei einer Kategorisierung zu Schwierigkeiten führen kann.

Aus diesen Gründen wird versucht, anhand von Methoden zur Reduzierung eine minimale Anzahl an Merkmalen zu generieren, die den maximalen Informationsgehalt der Daten repräsentieren. Eine übliche Vorgehensweise ist die (lineare) Transformation des durch die Eingangsmerkmale beschriebenen Raum in einen Unterraum, der durch Linearkombinationen der ursprünglichen Merkmale definiert ist. Ein in der Fernerkundung bekanntes Verfahren ist beispielsweise *Tasseled Cap*, das aus den originalen sieben Landsat-Kanälen drei neue Layer erzeugt. Nach [42] existieren zwei klassische, effektive Lineartransformationen: PCA und Diskriminanzanalyse (*Multiple Discriminant Analysis MDA*) [148].

Die PCA ermittelt eine Projektion, die die ursprünglichen Daten in einer *Kleinste-Quadrate-Repräsentation* optimal darstellt [42]. Zunächst wird anhand der Eingangsdaten eine normierte Kovarianzmatrix bestimmt, die als Grundlage zur Berechnung der Eigenwerte und Eigenvektoren dient. Die zueinander orthogonal ausgerichteten Eigenvektoren kennzeichnen die Richtungen beziehungsweise die Koordinatenachsen, in die der Datensatz die höchste Variabilität (Varianz) aufweist [148]. Mit anderen Worten ausgedrückt bedeutet dies, dass die Eigenvektoren ein zur ursprünglichen Formulierung alternatives Koordinatensystem sogenannter Hauptkomponenten (PC) aufspannen, in dem die voneinander verschiedenen Datenpunkte (*Samples*, Instanzen) maximale Separierbarkeit erfahren. Die Hauptkomponententransformation (PCT) dient der Überführung der ursprünglichen Daten in den durch die PC definierten Unterraum. Die PC sind Linearkombinationen der ursprünglichen Merkmale, was bedeutet, dass diese mehr oder weniger stark ausgeprägt an der Konstruktion der neuen Datendarstellung beteiligt sind. Das Maß dieser Ausprägung wird mittels Ladungen (*Loadings*) ausgedrückt, die als Koeffizienten der ursprünglichen Eingangsmerkmale letztlich eine qualitative Bewertung erlauben [149].

Die für die PCA anzustellende grundlegende Überlegung betrifft die Anzahl der letztlich genutzten Hauptkomponenten. Ein Ansatz zur Lösung dieser Fragestellung existiert durch die Beurteilung des kumulativen prozentualen Anteils der Gesamtvarianz der beteiligten Eigenvektoren (Hauptkomponenten). Dies bedeutet, dass beginnend mit der ersten Hauptkomponente solange die prozentualen Anteile aufsummiert werden, bis eine vorgegebene Schwelle überschritten wird. In der Praxis gängige Schwellenwerte beginnen bei mindestens 60 % [150]. Für diese Arbeit wird eine Schwelle von 80 % eingeführt.

Auf eine detaillierte Beschreibung der mathematischen Zusammenhänge und Hintergründe der PCA und der PCT wird an dieser Stelle verzichtet. Stattdessen wird auf entsprechende Quellen verwiesen ([151], [152]) und [153]).

In Abbildung 2.14 ist das Prinzip der PCA und der PCT dargestellt. In dem zugrunde liegenden, durch *Merkmal 1* sowie *Merkmal 2* definierten Koordinatensystem sind voneinander eigentlich unterschiedliche orangefarbene und blaue Instanzen schwer voneinander zu unterscheiden. Anhand der PCA werden die beiden Eigenvektoren (PC 1 und PC 2) ermittelt, die jene Richtungen darstellen, in denen die verschiedenen Datenpunkte maximal differenzierbar sind.

Die MDA verfolgt im Vergleich zur PCA eine andere Herangehensweise. Zentraler Aspekt dieser Methode ist die Suche nach einer Orientierung beziehungsweise Richtung, die Datenpunkte verschiedener Ausprägung optimal voneinander trennt. Hierfür wird eine Projektion der ursprünglichen Daten auf eine Linie genutzt und zwei verschiedene Streumatrizen (In-Klassen-Streumatrix und Zwischen-Klassen-Streumatrix) berechnet. Die MDA ist abgeschlossen, wenn eine Transformationsmatrix gefunden wurde, die die Differenz der beiden Streumatrizen maximiert [154]. Im Gegensatz zur PCA weist die MDA den Nachteil auf, dass sie

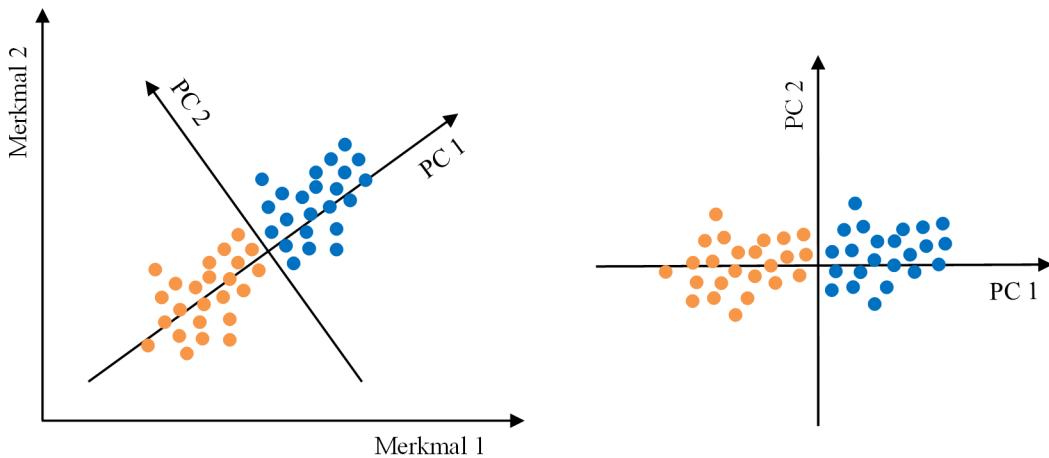


Abbildung 2.14.: Prinzip der PCA (links) und PCT (rechts). Darstellung in Anlehnung an [148].

normalverteilte Eingangsvariablen beziehungsweise Merkmale voraussetzt [148].

Weitere Methoden zur Reduzierung hochdimensionaler Datensätze sind im Umfeld der Hyperspektralen Fernerkundung entstanden, wozu die *Maximum Noise Fraction* Transformation (MNF), die ICA und die *Independent Factor Analysis* (IFA) zählen [148].

Die MNF setzt die Existenz einer Kovarianzmatrix voraus, die das in den Daten enthaltene Rauschen modelliert [155]. Im Fall einer identischen Rauschvarianz in allen Bildkanälen verfährt die MNF analog zur PCA [148].

Bei der ICA wird von der Annahme ausgegangen, dass die Eingangsmerkmale Ausprägungen weniger Komponenten sind, deren Detektion den zentralen Aspekt der Transformation darstellt. Sie funktioniert allerdings ausschließlich, wenn keine dieser Eingangsgrößen normalverteilt vorliegt ([156] und [44]).

Die IFA kombiniert unter anderem PCA und ICA und beschreibt die tatsächlichen Informationen eines Datensatzes als versteckte Quellen, die in jeweils gemischten Beobachtungen (Messungen) enthalten sind [157]. Eine derartig gemischte Beobachtung wird als Kombination normalverteilter Funktionen modelliert [148]. Darüber hinaus und im Gegensatz zur ICA wird bei der IFA der in den Daten enthaltene Rauschanteil berücksichtigt.

Die oben vermittelten Zusammenhänge werden in Abschnitt 6.2.3 mit Fokus auf die PCA und PCT wieder aufgegriffen und anhand des vorliegenden Datensatzes erläutert. Durch Analyse der *Loadings* als Resultat der PCA erfolgt darüber hinaus eine Bewertung der ursprünglich eingegangenen Merkmale.

## 2.2.6. Kategorisierung

Einen zentralen Punkt in der entwickelten Methode zur Änderungsanalyse nimmt die Kategorisierung beziehungsweise Gruppierung (*Clustering* oder *Clusteranalyse*) der Hochaktivitätsobjekte HAO ein. Entsprechend der in Abschnitt 1.1 enthaltenen Definition des Kategorisierungsbegriffs folgt, dass vorliegende Datenpunkte (hier: HAO) hinsichtlich ihrer merkmalsbasierten Ausprägung in Gruppen beziehungsweise Kategorien aufgeteilt werden. Im Gegensatz zur Klassifikation ist für diese Art der Datenanalyse die Existenz zusätzlicher Informationen in Form eines Klassenkatalogs oder von Trainingsdaten somit nicht notwendig. Eine ähnliche Definition des *Clustering* findet sich in [158], die es als das Gruppieren ungekennzeichneter (*unlabeled*) Daten bezeichnet.

Zentraler Bestandteil sämtlicher *Clustering*-Verfahren ist neben einem Optimierungskriterium das Gleichheits- beziehungsweise Distanzmaß, mit dessen Hilfe die Ähnlichkeit der Datenpunkte  $i$  bewertet wird. Häufig wird hierfür die Euklidische Distanz ( $d_{L_2}$ -Norm) als spezielle Variante der Gruppe der  $L_q$ -Normen genutzt, die unter anderem im  $k$ -means-Algorithmus Verwendung findet. Für die Elemente  $i$  einer Menge aus  $P$  vorliegenden Datenpunkten folgt mit den Punktkoordinaten  $x$  und  $y$ :

$$d_{L_2} = \sqrt{\sum_i^P (x_i - y_i)^2}. \quad (2.52)$$

In Bezug auf das oben erwähnte Optimierungskriterium wird als meistgenutzte Variante die Methode *Summe der quadratischen Fehler* genannt [154], deren Minimierung die Lösung des Optimierungsproblems bei minimaler Varianz ergibt. Dieser Vorgehensweise liegt die Bewertung der Distanzen zwischen den einzelnen Instanzen und den Clusterschwerpunkten (Prototypen) zugrunde, woraus folgt, dass Cluster mit kompakter Form eine geringe Varianz zur Folge haben und demzufolge eine gute Lösung darstellen.

Verfahren zur Clusteranalyse können nach [158] in partitionelle und hierarchische Ansätze unterteilt werden, deren genereller Vorteil in ihrer simplen Algorithmik und damit leichten Implementierbarkeit liegt.

Partitionelle (iterative) Verfahren benötigen Einstellungen (Anzahl und Ort im Merkmalsraum) in Bezug auf Initialpunkte, die als Basis für die Berechnungen dienen und somit in direkter Weise maßgeblichen Charakter für das Resultat besitzen. Im Verlauf der Prozessierung eines partitionellen *Clustering*-Verfahrens ist es möglich, dass sich aufgrund der iterativen Vorgehensweise die Kategorienzugehörigkeit eines einzelnen Datenpunktes mehrfach ändert. Bekannte und verbreitete Vertreter partitioneller Methoden sind exemplarisch *k-means* [159], *Mean-Shift* [160] und *ISODATA* [161] (siehe unten).

Hierarchische Methoden der Clusteranalyse können allgemein in aufteilende (*top-down*) und aufhäufende, beziehungsweise agglomerative (*bottom-up*) Strategien unterschieden werden. Im ersten Fall werden alle vorliegenden Datenpunkte als ein Cluster betrachtet, das sukzessive in kleinere Einheiten aufgeteilt wird. Im Gegensatz dazu beginnen die agglomerativen Methoden auf der Ebene der einzelnen Instanzen und fusionieren diese mit ähnlichen anderen Datenpunkten zu größeren Clustern zusammen. In beiden Fällen ist eine einmalig erfolgte Zuweisung zu einem bestimmten Cluster fest und im weiteren Ablauf unveränderlich, was im Vergleich zu partitionellen Ansätzen nachteilig erscheint [162]. Die Prozessierungsabfolge hierarchischer Verfahren wird anhand eines Dendogramms (Baumdiagramms) dokumentiert, das die Grundlage für die Bewertung der Resultate repräsentiert. Ein solches Resultat hängt somit davon ab, auf welcher Ebene das Dendrogramm abgeschnitten wird, was direkt zur Folge hat, dass stets eine geeignete Tiefe im Dendrogramm zur Bewertung der Ergebnisse gefunden werden muss [148].

*k-means* beginnt mit der initialisierenden Definition von  $k$  Clusterzentren  $C_i$  (Schwerpunkte, *Centroids*), wobei die Clusteranzahl  $k$  a-priori vorliegen muss. In jeder Iteration des Prozesses werden für jeden Datenpunkt die Euklidischen Distanzen zu allen verfügbaren  $C_i$  bestimmt und die Punkte dem entsprechend nächstgelegenen Zentrum zugewiesen. Nach jedem Durchlauf erfolgt eine Neubestimmung der Clusterzentren inklusive der Berechnung der Lagedifferenzen zu vorherigen Durchläufen. Diese Differenzen sind die Grundlage für die Minimierung der Summe der quadratischen Fehler (*Sum of Squared Errors SSE*). Die Beurteilung der SSE dient letztlich als Abbruch- beziehungsweise Konvergenzkriterium für das Verfahren [162]. Ein Clusterresultat liegt somit vor, wenn die SSE minimal ist und sich die  $C_i$  in ihrer Lage nicht mehr signifikant ändern. Aus dieser Vorgehensweise ergeben sich zwei Problemstellungen.

Das erste Problem stellt die a-priori Festlegung der Clusteranzahl  $k$  dar, die als Eingangsparameter vorliegen muss und somit im Widerspruch zu einer vollautomatischen Analyse steht.

Weiterhin stellt die zu Beginn jedes neuen Prozesses initialisierende, zufällige Festlegung der Positionen der Clusterzentren im Merkmalsraum eine Schwierigkeit dar, da sich so eine starke Abhängigkeit der entsprechenden Clusterresultate von dieser Einstellung ergibt. Für jeden neuen Durchlauf des Algorithmus liegen somit verschiedene Clusterzentren und dementsprechend unterschiedliche Ergebnisse vor. Darüber hinaus beinhaltet die *k-means*-Methode das Risiko, während der Prozessierung in lokale Minima zu laufen. In diesem Fall wird zwar das Konvergenzkriterium erfüllt, doch entspricht diese Lösung nicht einer eventuell vorliegenden, global optimalen Lösung.

Aufgrund der beiden zuletzt erwähnten Problematiken ist ein oft genutzter Ansatz, das Verfahren mehrmals hintereinander mit jeweils unterschiedlichen Initialisierungen für die Clusterzentren anzuwenden und das entsprechend beste Resultat als finale Lösung zu übernehmen.

Eine komplett unüberwachte Variante des *k-means*-Verfahrens wird durch eine automatisierte Schätzung des Parameters  $k$  erreicht, wofür auch hier eine Vielzahl verschiedener Methoden existiert ([163], [164] und [162]). Derartige Schätzmethoden können in lokale und globale Verfahren unterschieden werden [148], wobei die lokalen Varianten die Ähnlichkeit zweier Cluster beurteilen und globale Varianten mehrere *Clustering*-Durchläufe mittels variierenden  $k_i$  durchlaufen. Globale Schätzmethoden ähneln den Verfahren der Clustervalidierung, die wiederum in drei Gruppen untergliedert werden können ([158] und [164]): Interne, externe und relative Validierungsverfahren.

Interne Verfahren bewerten die Kompaktheit (Kohäsion beziehungsweise interne Clustervarianz) und Trennbarkeit (Separation beziehungsweise externe Clustervarianz) der Cluster, wobei diese Zusammengehörigkeit in den meisten Fällen anhand der Lage der Clusterzentren berechnet wird. Im Fall von *Clustering*-Verfahren, die auf der Zuordnung der Datenpunkte mittels abstandsbewertenden Kriterien beruhen (zum Beispiel *k-means*), ist dies sinnvoll - nicht hingegen bei Verfahren, die beispielsweise die Verteilungsdichte der Instanzen

im Merkmalsraum analysieren (zum Beispiel *Mean-Shift*) [148]. In [164] finden sich 30 verschiedene Indizes zur internen Validierung, von denen nachfolgend eine Auswahl detaillierter betrachtet wird (Nomenklatur entsprechend [148]).

Externe Methoden setzen die Existenz stimmiger Referenzdaten voraus, was sie für Analysen ohne GT Daten ungeeignet werden lässt. Relative Ansätze vergleichen zwei Clusterresultate miteinander und beurteilen, welche der beiden Lösungen die bessere Alternative darstellt.

Der *Calinski-Harabasz-Index*  $CH_k$  (siehe [165]) berechnet sich aus:

$$CH_k = \left( \frac{B_{CH}}{W_{CH}} \right) \left( \frac{n_{Beob} - k}{k - 1} \right), \quad (2.53)$$

mit der globalen externen Clustervarianz  $B_{CH}$ , der globalen internen Clustervarianz  $W_{CH}$  und der Anzahl der Beobachtungen  $n_{Beob}$ . Setzt man voraus, dass  $n_{Beob} \geq k$  erfüllt ist, so resultiert ein Indexwertebereich zu  $CH_k \in [0; \infty)$ . Ergänzend gilt:

$$B_{CH} = \sum_{i=1}^k \|m_i - m\|^2 \quad (2.54)$$

und

$$W_{CH} = \sum_{i=1}^k \sum_{x \in C_i} \|x - m_i\|^2. \quad (2.55)$$

In den beiden Formeln (2.54) und (2.55) steht  $x$  für einen spezifischen Datenpunkt,  $C_i$  für das  $i$ -te Cluster,  $m$  für den globalen Mittelpunkt der Daten, sowie  $m_i$  für das Zentrum des  $i$ -ten Clusters. Ein optimaler Wert für  $k$  resultiert aus der Maximierung von  $CH_k$ .

Das *Davis-Bouldin-Kriterium*  $DB_k$  [166] basiert auf derselben Grundidee wie  $CH_k$  [148] und ergibt sich aus:

$$DB_k = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \{D_{i,j}\}, \quad (2.56)$$

mit  $DB_k \in [0; \infty)$ . Das Verhältnis von interner zu externer Clustervarianz (Divergenz) für das  $i$ -te und  $j$ -te Cluster wird durch  $D_{i,j}$  beschrieben. Diese Divergenz berechnet sich zu:

$$D_{i,j} = \frac{\bar{d}_i + \bar{d}_j}{d_{i,j}}, \quad (2.57)$$

mit der mittleren Entfernung  $\bar{d}_i$  jedes Datenpunktes des  $i$ -ten Clusters zum Mittelpunkt dieses Clusters, der Distanz  $\bar{d}_j$  eines jeden Punktes im  $i$ -ten Cluster zum Mittelpunkt des  $j$ -ten Clusters, sowie der Entfernung  $d_{i,j}$  zwischen den Zentren der beiden Cluster  $i$  und  $j$ . Eine optimale Clusteranzahl  $k$  resultiert aus der Minimierung von  $DB_k$ . Der theoretische Optimalwert für  $DB_k$  ist dementsprechend Null.

Eine im Vergleich zu den bisher beschriebenen zwei Methoden sehr aufwendige Verfahrensweise hinsichtlich der Berechnungsdauer stellt die Silhouettenstatistik beziehungsweise der *Silhouettenindex*  $SH_k$  [167] dar [148]. Der Silhouettenwert  $s(i)$  eines Datenpunktes  $i$  in einem Cluster  $A$  ist mit nachstehender Vorschrift berechenbar:

$$s(i) = \frac{b(i) - w(i)}{\max \{w(i), b(i)\}}, \quad (2.58)$$

wobei  $s(i) \in [-1; 1]$  gilt. Die mittlere Ungleichheit (Distanz im Merkmalsraum) des Datenpunkts  $i$  zu allen anderen Datenpunkten des Clusters  $A$  wird durch  $w(i)$  dargestellt. Weiterhin berechnet sich  $b(i)$  als Minimum der mittleren Ungleichheiten zu den Datenpunkten anderer Cluster  $C$  aus:

$$b(i) = \min_{C \neq A} \{d(i, C)\}, \quad (2.59)$$

mit der mittleren Ungleichheit  $d(i, C)$  des Punktes  $i$  zu allen Punkten des Clusters  $C$ .

Wenn für  $s_i$  relativ hohe Werte vorliegen, kann dies als gute Übereinstimmung des Punktes  $i$  mit anderen

Punkten im selben Cluster sowie als schlechte Übereinstimmung mit den Punkten anderer Cluster interpretiert werden. Die Güte des *Clustering* wird mittels des Indexes  $SH_k$  auf Basis der Silhouettenwerte aller Punkte bestimmt. Es gilt:

$$SH_k = \text{mean} \left( \sum_i s(i) \right), \quad (2.60)$$

mit  $SH_k \in [-1; 1]$ . Das beste Clusterresultat folgt somit aus einem Vergleich aller, für unterschiedliche  $k$  berechneter  $SH_k$ .

Die hier zuletzt vorgestellte Methode zur Bestimmung der optimalen Clusteranzahl ist der *GAP-Index* (etwa Lückenwert)  $GAP_k$  [168], der sich wie folgt ermitteln lässt:

$$GAP_k = E_{n_{Beob}}^*(\log(W_{GAP})) - \log(W_{GAP}), \quad (2.61)$$

mit  $GAP_k \in [0; \infty)$ , der Anzahl an Beobachtungen  $n_{Beob}$ , der Clusteranzahl  $k$  und der zusammengefassten internen Clustervarianz  $W_{GAP}$ :

$$W_{GAP} = \sum_{r=1}^k \frac{1}{2n_r} D_R. \quad (2.62)$$

In dieser Gleichung stehen  $n_r$  für die Anzahl an Datenpunkten des Clusters  $R$  und  $D_R$  für die Summe der paarweisen Entfernungen aller Punkte des Clusters  $R$ .  $E_{n_{Beob}}^*(\log(W_{GAP}))$  stellt einen Erwartungswert dar, der anhand einer *Monte-Carlo-Simulation* einer Referenzverteilung ermittelt wird [148]. Der weitere Wert  $\log(W_{GAP})$  wird den Daten selbst entnommen. Eine optimale Clusteranzahl resultiert aus der Maximierung von  $GAP_k$ . Die Dauer für die Berechnung des GAP-Werts übersteigt jene der oben beschriebenen Verfahren um ein Vielfaches [148], woraus eine niedrige praktische Relevanz dieses Indexes folgt.

Neben diesen recht umfangreichen und komplexen Verfahren zur Ermittlung einer für die Daten passenden Clusteranzahl liegt mit der sogenannten *Ellbogenmethode* (*Elbow method*) ([169] und [170]) eine zugleich anschauliche und äußerst günstige Alternative in Bezug auf die Berechnungsdauer vor. Die dortige Vorgehensweise ist die Berechnung des mittleren quadratischen Fehlers  $MQF_k$  der Clusterresultate für verschiedene Anzahlen  $k_i$  [27]:

$$MQF_k = \frac{1}{N} \cdot \sum_{i=1}^N \sum_{k=1}^M \xi(x_i \in C_k) \cdot \delta(x_i - m_k), \quad (2.63)$$

mit der Anzahl  $N$  an Datenpunkten  $x$  und der Anzahl  $M$  an Clusterzentren  $C$ . Die Funktion  $\xi()$  dient zur Prüfung, ob ein spezifischer Datenpunkt  $x_i$  zum jeweils aktuellen Cluster  $C_j$  gehört ( $\xi() = 1$ ), oder nicht ( $\xi() = 0$ ). Weiterhin bezeichnet die Distanzfunktion  $\delta()$  die Berechnung der Euklidischen Distanz zwischen einem Datenpunkt und dem jeweils aktuellen Clusterzentrum  $m_k$ .

Das jeweilige *Clustering*-Verfahren wird anhand einer steigenden Anzahl an Clustern (exemplarisch:  $k_i = [1, 2, \dots, 10]$ ) nacheinander durchlaufen und für jedes Clusterresultat ein Wert für  $MQF_k$  berechnet. Dieser Wert wird in einem Diagramm gegen die Clusteranzahlen aufgetragen, woraus die für diese Methode typische Ellbogenform der resultierenden Kurve entsteht (siehe Abbildung 2.15, B, rechts). Basierend auf einem solchen Diagramm werden die Gradienten zweier aufeinander folgenden Kurvenpunkte ermittelt. Ein optimales  $k$  liegt vor, wenn die Differenz zweier Gradienten maximal ist und sich die Werte für  $MQF_k$  nicht mehr signifikant voneinander unterscheiden.

In Abbildung 2.15, B, ist exemplarisch die *Ellbogenmethode* zur Ermittlung eines geeigneten Wertes für  $k$  dargestellt. Als Grundlage für das *Clustering* dienten die Grauwerte eines Ausschnitts des über die Zeitreihe gemittelten, auf 8 Bit skalierten ML-Amplitudenbilds der Szenerie „Stuttgart Flughafen“ (Abbildung 2.15, A). Um oben erläuterte Problematiken hinsichtlich der zufälligen Initialisierung der Clusterzentren zu umgehen, wurde der *k-means*-Algorithmus zehnmal unabhängig voneinander angewendet und das beste Resultat als finale Lösung übernommen. Weiterhin galt  $k_i = [1, 2, \dots, 10]$ . Für dieses Beispiel wurde angenommen, dass mindestens drei verschiedene Kategorien von Rückstreuungstypen enthalten sind (*Rural*, *Infrastruktur* und *Urban* beziehungsweise *Industrie*). Dementsprechend wurden bei der Bewertung des  $MQF_k$  Diagramms die ersten beiden Gradienten vernachlässigt. Als optimale Clusteranzahl resultierte in diesem Fall  $k = 5$  im vierten Gradienten (Abbildung 2.15, B, rechts).

Basierend auf dem gleichen Eingabebild wurden weiterhin die  $CH_k$ - und  $DB_k$ -Werte für  $k_i = [1, 2, \dots, 10]$  bestimmt und in entsprechenden Diagrammen dargestellt (Abbildung 2.15, C und D, rechts). In Bezug

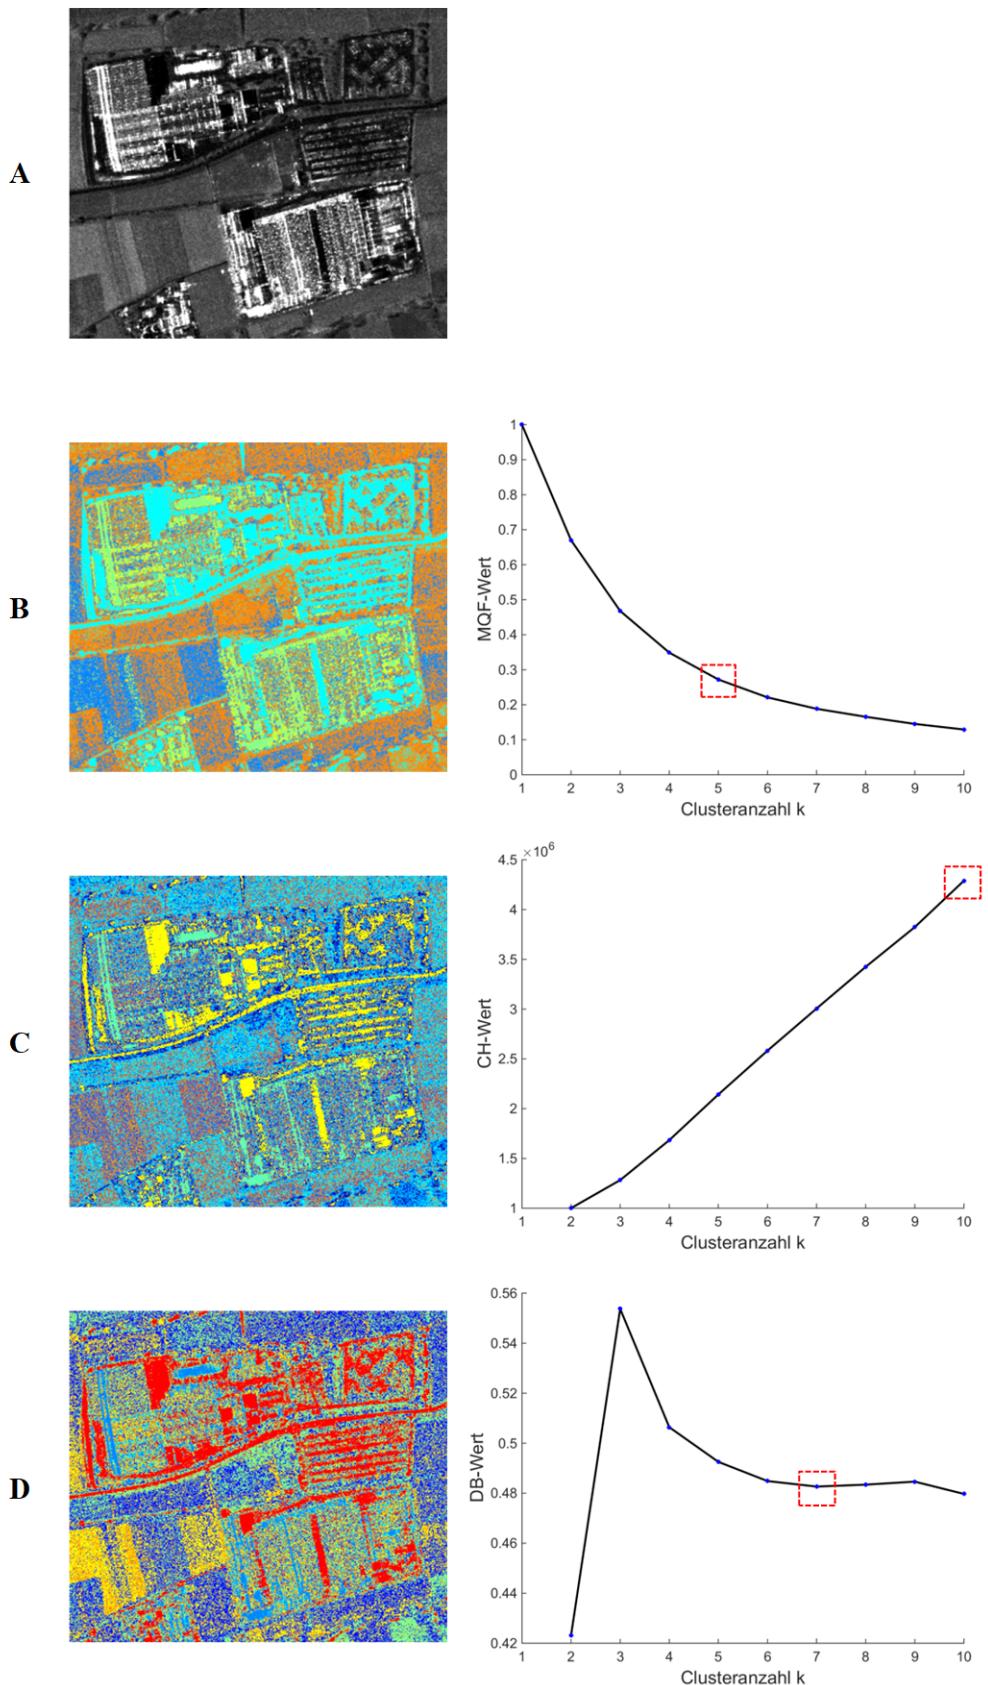


Abbildung 2.15.: Methoden zur Ermittlung einer geeigneten Clusteranzahl  $k$ . A bis D (links): Eingabebild; farbkodierte  $k$ -means-Resultate aus Anwendung der Ellbogenmethode, des Caliński-Harabasz-Indexes und des Davis-Bouldin-Kriteriums. B bis D (rechts): Entsprechend passende Diagramme mit Indexwerten. Rote Markierungen kennzeichnen den jeweiligen Optimalwert für  $k$ .

auf den *Caliński-Harabasz-Index* ergab sich ein wenig sinnvolles Resultat, da hier der entsprechende Wert linear mit ansteigendem  $k$  größer wird und im Vergleich mit dem Resultat aus der *Ellbogenmethode* stark widersprüchlich erscheint. Anhand des farbkodierten Ergebnisbilds (Abbildung 2.15, C, links) ist ersichtlich, dass  $k = 10$  eine deutliche Übersegmentierung zur Folge hat.

Die Ergebnisse für die Berechnung der unterschiedlichen  $DB_k$ -Werte (Abbildung 2.15, D, rechts) weisen ein Minimum für  $k = 7$  auf, wenn nur  $k > 3$  betrachtet wird (siehe oben). Somit liefert das  $DB_k$  wie das Ellbogenverfahren ein ähnliches Resultat. Allerdings ist ersichtlich, dass sich die  $DB_k$ -Werte für  $k = 7$  und  $k = 10$  nur wenig voneinander unterscheiden, woraus eine schwache Robustheit des Verfahrens ableitbar ist.

In Anbetracht obiger Ausführungen wird in der vorliegenden Arbeit die *Ellbogenmethode* zur Ermittlung der optimalen Clusteranzahl  $k$  genutzt. Aufgrund der langen Berechnungsdauer werden  $SH_k$  und  $GAP_k$  nicht weiter beachtet.

Neben dem weit verbreiteten und häufig genutzten *k-means*-Algorithmus verfolgt das *Mean-Shift*-Verfahren eine andere Vorgehensweise. Es beinhaltet eine dichtebasiertere Vorgehensweise, wobei anhand eines Bandbreitenparameters  $r_{BW}$  Bereiche höchster Dichte  $\rho$  identifiziert und an diesen Stellen initiale Clusterzentren markiert werden. Der detaillierte Ablauf des Verfahrens ist beispielsweise in [160] und [171] beschrieben. Prinzipiell kann *Mean-Shift* mit *k-means* verglichen werden, da beide Methoden auf einer eingangs durchgeführten Definition der Clusterzentren basieren. *Mean-Shift* besitzt darüber hinaus aber den Vorteil, dass keine Angaben zur Clusteranzahl  $k$  vorliegen müssen. Nachteilig ist hingegen die Verwendung beziehungsweise Wahl eines geeigneten Werts für den Radius  $r_{BW}$ , der unmittelbar die Güte des Clusterresultats beeinflusst.

Der *ISODATA*-Algorithmus ist ein eigenständiges *Clustering*-Verfahren, das grundsätzlich auf *k-means* basiert ([148] und [161]). Wie auch *k-means* startet *ISODATA* mit der Definition initialisierender Clusterzentren, deren Anzahl sich jedoch im Prozessierungsverlauf ändern kann. Als äußerst nachteilig erscheint die Tatsache, dass eine Vielzahl von Parametern für *ISODATA* berücksichtigt, beziehungsweise eingestellt werden müssen. Diese sind die ungefähre Clusteranzahl  $k_0$ , der Schwellwert  $\Theta_E$  für die maximale interne Standardabweichung eines Clusters, der Wert  $\Theta_C$  zur Beurteilung der minimalen Entfernung zweier benachbarter Clusterzentren, der Grenzwert  $\Theta_N$ , der festlegt, wie viele Datenpunkte ein bestimmter Cluster mindestens enthalten muss, sowie der Schwellwert  $L$ , der die maximale Anzahl an Clustern vorgibt, die je Iterationsschritt fusioniert werden dürfen. Aus dieser Menge an Parametern folgt eine große Anzahl möglicher Parameterkombinationen, was *ISODATA* für praktische Zwecke schwer umsetzbar werden lässt.

Aus den genannten Gründen wird in dieser Arbeit der *k-means*-Algorithmus zur unüberwachten Kategorisierung der HAO genutzt.

Diese kategorisierten Hochaktivitätsobjekte bilden die Eingabedaten für die spätere Zuweisung zu vorab definierten Klassen. Der nachfolgende Abschnitt beinhaltet Grundlagen zur Klassifikation fernerkundlich erfasster Bilddaten.

### 2.2.7. Klassifikation

Die Klassifikation einzelner Bildelemente oder Bildsegmente umschreibt im Allgemeinen die Zuweisung dieser Entitäten  $\epsilon_i$  zu einem vorhandenen System oder Katalog aus Klassen. Für diese Zuweisung wurden je nach Anwendungszweck und verfügbarer Datenbasis verschiedene Methoden entwickelt, die umfassend in [172] aufgelistet sind. Die Entwicklung geeigneter Verfahren begann in den achtziger Jahren des vergangenen Jahrhunderts und umfasste zunächst pixelbasierte Ansätze, die sowohl überwachte als auch unüberwachte Abläufe beinhalteten [173]. Bekannte Vertreter dieser Gruppe sind beispielsweise MaLi, *Minimum Distance* (etwa: geringste Entfernung), KNN und SVM (alle überwacht), sowie *k-means* oder *ISODATA* (beide unüberwacht), wobei letztere aus stringenter Betrachtungsweise Methoden zur Kategorisierung darstellen (vergleiche vorherigen Abschnitt).

Mit der Verbesserung der räumlichen Auflösung verloren diese konventionellen Methoden nach und nach an Bedeutung. In erster Konsequenz wurden sub-pixelbasierte Techniken entwickelt (beispielsweise *Fuzzy-Analyse* und spektrale Mischpixelanalyse), die ein einzelnes Bildelement als Mixtur spektraler Rückstreuinformation betrachten. Als Beispiel einer solchen Mixtur wird in [174] der Übergang von Gewässer zu Landoberfläche erwähnt, der je nach Größe der Auflösungszellen zu einem spektralen Gemisch aus Wasser- und Landsignaturen führt. Im Hinblick auf den entsprechenden Merkmalsraum würde ein derartiges Bildpixel entsprechend seiner spektralen Charakteristik zwischen den beiden Klassen *Gewässer* und *Land* liegen, mit einer nicht eindeutigen Zugehörigkeit zu einer der beiden Klassen. Diese Uneindeutigkeit kann mithilfe der *Fuzzy-Logik* modelliert werden.

Nachfolgend wurden objektbasierte Klassifikationsverfahren entwickelt [173], die neben der alleinigen

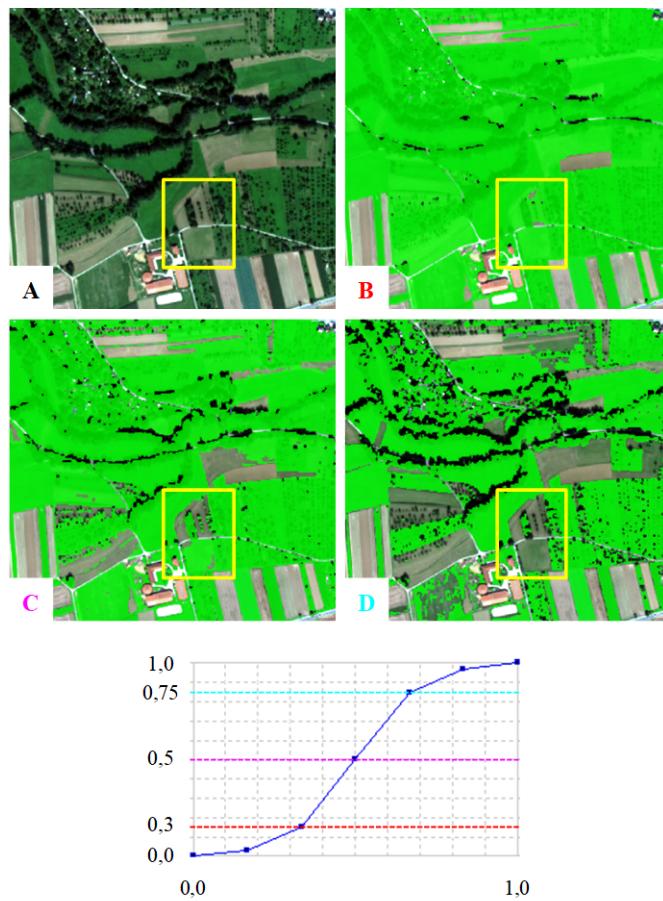


Abbildung 2.16.: Zugehörigkeitsfunktion, Zugehörigkeitswerte und Klassifikation. A: Eingabebild, B-D: Ergebnisse der Vegetationsklassifikation mit  $z = 0,3$  (B),  $z = 0,5$  (C) und  $z = 0,75$  (D). Hellgrüne Bereiche in B, C und D kennzeichnen als *Vegetation* klassifizierte Bildsegmente. Gelbe Markierung: *Ruraler Bereich*.

spektral-orientierten Verarbeitungsweise die Möglichkeit eröffnen, den räumlichen Aspekt beziehungsweise Kontext unterstützend zu nutzen. Generell können ursprünglich pixelbasierte Klassifikationsmethoden (exemplarisch: MaLi oder die *Fuzzy-Logik*) auch auf segmentierte Bilddaten angewendet werden, mit dem einzigen Unterschied, dass nicht einzelne Pixel, sondern zu Segmenten fusionierte Bildelemente die Prozessierungsgrundlage bilden. Als Beispiel hierfür kann die objektorientierte Bildanalysesoftware *eCognition Developer* (siehe auch Abschnitt 2.2.4) erwähnt werden, in der die *Fuzzy-Logik* umfangreich als Klassifikationsmethode implementiert ist [135].

Die *Fuzzy-Logik* ([175], [176] und [3]) stellt eine relativ junge Verfahrensweise mit Anwendungen in verschiedenen Bereichen dar, von denen Musterkennung und Klassifikation zwei Repräsentanten sind [176]. Der zentrale Aspekt und gleichzeitig der Vorteil dieser Methode im Vergleich zu anderen Herangehensweisen ist im Hinblick auf das Bildelement oder Bildsegment der Verzicht auf eine klare und eindeutige Klassenzugehörigkeit. Diese weiche Form der Klassenzugehörigkeit ermöglicht weiterhin die Verarbeitung und Analyse von Daten oder Klassen, die selbst unpräzise beziehungsweise unklar erfasst oder formuliert wurden [174]. Komplexe Aufgabenstellungen wie etwa die Klassifikation fernerkundlicher Bilddaten können mit Hilfe der *Fuzzy-Logik* anhand sprachlich formulierter Regeln, die die natürlichen unscharfen Zusammenhänge wiedergeben, auf effiziente Art und Weise beschrieben werden [175]. Zur Formulierung dieser Regelsysteme kann unterstützend auch Expertenwissen einfließen ([176] und [175]).

Im Gegensatz zu einer binären Zuweisung (ja oder nein) erfolgt die *fuzzy*-basierte Klassifikation mittels Zugehörigkeitsfunktionen zur Modellierung des jeweiligen Merkmalsraums. Anhand dieser Funktionen wird die Wahrscheinlichkeit dargestellt, mit der eine Bildeinheit (Pixel oder Segment) zu einer bestimmten Klasse gehört ([175], [174] und [72]). Der Grad einer solchen Zugehörigkeitswahrscheinlichkeit zu einer bestimmten Klasse  $K_j$  wird mit dem Wertebereich  $v = [0; 1]$  ausgedrückt [174]. Mit Fokus auf *eCognition Developer* können derartige Funktionen die Form verschiedener, bekannter Verteilungen besitzen (normalverteilt, sigmoid, etc.), oder auch variabel dem jeweiligen Anwendungszweck entsprechend angepasst, beziehungsweise gewählt werden [135]. Die finale Klassifikation, die die Zuweisung der  $\epsilon_i$  zu einer Klasse  $K_j$  vornimmt, wird mittels eines Zugehörigkeitswerts oder einer Zugehörigkeitsschwelle  $z$  erreicht. Befindet sich der jeweilige

Merkmalswert  $\epsilon_{i,mw}$  einer Bildeinheit oberhalb dieser grundsätzlich vorgegebenen Schwelle, wird  $\epsilon_i$  der Klasse  $K_j$  zugewiesen. Im Fall der Existenz mehrerer Klassen  $K_j$  mit  $j > 1$ , für die zur Formulierung das gleiche Merkmal genutzt wurde, entscheidet der jeweils höhere Merkmalswert  $\epsilon_{i,mw}$  einer Bildeinheit über eine passende Zugehörigkeit.

Zur Veranschaulichung dieser Zusammenhänge ist in Abbildung 2.16 exemplarisch die anhand des NDVI-Merkals formulierte Klasse *Vegetation*  $K_{Veg}$  visualisiert. Die zu klassifizierenden Einheiten  $\epsilon_i$  waren in diesem Fall Bildsegmente eines Ausschnitts des WV-2-Bilds der Testszene „Stuttgart Flughafen“. Zur Segmentation und Klassifikation wurde *eCognition Developer* verwendet und zur Modellierung des NDVI-Merkals sowie der Klassenzugehörigkeit eine rechtsseitig aufsteigende Sigmoidfunktion (Abbildung 2.16, unten) gewählt. Die Zugehörigkeitswerte  $z$  sind auf der Abszisse, die Merkmalswerte  $\epsilon_i$  der jeweiligen Bildeinheit auf der Ordinate abgetragen. Für die Klassifikation wurden drei verschiedene  $z$  betrachtet: 0,3; 0,5 und 0,75. Es ist erkennbar, dass eine höhere Zugehörigkeitsschwelle zu einer verringerten Anzahl an als *Vegetation* klassifizierten Segmenten führt. Vor allem in ruralen Bildbereichen werden in diesem Fall Segmente nicht berücksichtigt, die bei einer Klassifikation mit dem Wert  $z = 0,3$  noch der Klasse *Vegetation* zugewiesen worden waren (Abbildung 2.16, gelb markierter Bereich). Dieses veränderliche Verhalten in Abhängigkeit der funktionellen Merkmalsmodellierung und des Zugehörigkeitswerts symbolisiert den Kern der *fuzzy*-basierten Klassifikation.

In dieser Arbeit wird die *fuzzy*-basierte Klassifikation zur Klassenzuweisung der Bildeinheiten genutzt (siehe Kapitel 5). Als Zugehörigkeitsfunktionen werden dem jeweiligen Klassenbereich im Merkmalsraum angepasste normalverteilte Kurven verwendet.

# Kapitel 3.

## Änderungsdetektion

Mit diesem Kapitel beginnt die Beschreibung des entwickelten Verfahrens zur inkohärenten Änderungsanalyse, die sich in die Hauptaufgaben *Detektion* (Kapitel 3) und *Kategorisierung / Klassifikation* (Kapitel 4 und 5) aufgliedert. In den entsprechenden Kapiteln und Abschnitten werden basierend auf zuvor erläuterten Grundlagen die Konzepte und Verarbeitungsschritte vermittelt, die in Kapitel 6 auf zwei Testdatensätze übertragen werden.

Mit Bezug zu der vorliegenden Aufgabenstellung ist ergänzend zu erwähnen, dass die Anwendung kohärenter Verfahren zur Änderungsdetektion hier nicht geeignet ist. Es werden durch den Menschen verursachte Veränderungen mit kleinräumiger Ausdehnung analysiert, wie sie beispielsweise zwischen zwei zeitlich aufeinanderfolgenden Aufnahmen durch bewegte Fahrzeuge hervorgerufen werden. Da sich derartige Zielobjekte im Regelfall auf asphaltiertem Untergrund befinden, der durch sehr schwache Rückstreuung des Radarsignals eine niedrige Kohärenz besitzt, würden diese Objekte unter Nutzung kohärenter Verfahren unentdeckt bleiben.

Dieses Kapitel ist wie folgt aufgebaut. Der folgende Abschnitt 3.1 beinhaltet die entwickelte Methode zur inkohärenten Detektion abruper Änderungen in SAR-Bildpaaren, die insbesondere durch die Nutzung einer neuen Variante der ASF hohe praktische Relevanz beinhaltet.

Die abrupte Änderungsdetektion wird in Abschnitt 3.2 auf als Zeitreihe vorliegende Amplitudenbilder übertragen und ist somit generell auch für Anwendungen nutzbar, in denen *Monitoring*-Aufgabenstellungen betrachtet werden. Den zentralen Aspekt nimmt die pixelbasierte Berechnung der Index- und Aktivitätskarte ein (Abschnitt 3.2.1), die als Basis zur präkategorisierenden Berechnung von Aktivitätsclustern (Abschnitt 3.2.2) und zur Identifikation von Hochaktivitätsobjekten HAO dienen (Abschnitt 3.2.3), welche wiederum die Prozessierungsgrundlage für die in den anschließenden Kapiteln beschriebenen Analysen bilden.

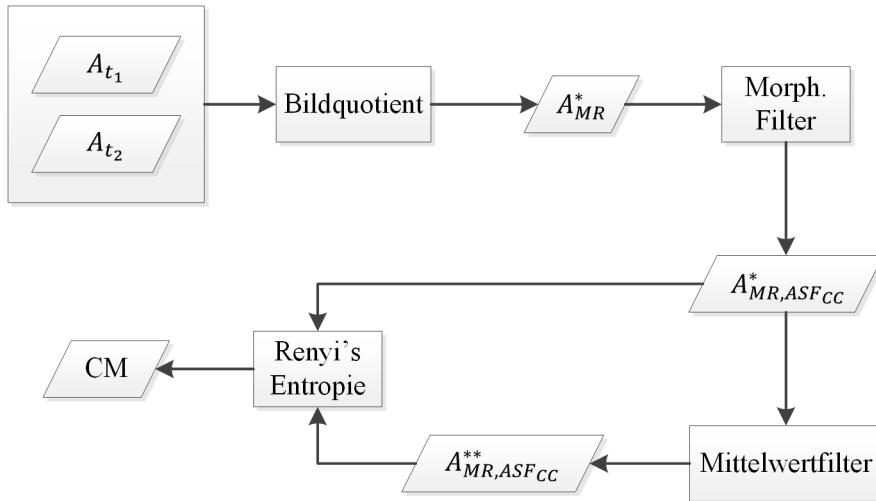


Abbildung 3.1.: Schematischer Ablauf zur abrupten Änderungsdetektion.

### 3.1. Abrupte Detektion

In den nachstehenden Betrachtungen wird unter einer abrupten Änderungsdetektion ein Verfahren verstanden, das basierend auf einem beliebigen bi-temporalen Bildpaar Veränderungen identifiziert. Eine abrupte Detektion steht somit der klassisch progressiven Verarbeitung gegenüber, die temporale Trends oder Trajektorien der sich verändernden Bereiche betrachtet. Nachfolgend wird die Methode zur abrupten Änderungsdetektion schrittweise erläutert. Eine schematische Darstellung des Verfahrens ist in Abbildung 3.1 enthalten. In Abbildung 3.2 sind die Grauerthistogramme der einzelnen Produkte der Prozesskette dargestellt. Als Grundlage diente hierzu ein  $3000 \times 3000$  Pixel großer Ausschnitt der Szene „Stuttgart Flughafen“. Zur Veranschaulichung der sich aus der Prozesskette ergebenden Produkte wird der einen LKW-Parkplatz enthaltende und bereits mehrfach genutzte Bildausschnitt verwendet (Abbildung 3.3). Ausführungen zur Genauigkeit des vorgestellten Verfahrens sind in Abschnitt 6.3.1 zu finden.

Zu Beginn jeden Verfahrens zur bildbasierten Änderungsdetektion steht die Auswahl beziehungsweise die Eingabe der entsprechenden Bilddaten. Aus diesem Grund werden begleitend zur Methodenbeschreibung etwaige Vorgaben oder gar Einschränkungen im Hinblick auf die Eingabebilder erörtert. Im Rahmen dieser Arbeit werden zur abrupten Änderungsdetektion zwei hochauflösende, zu verschiedenen Zeitpunkten  $t_1$  und  $t_2$  im HS-Modus aufgezeichnete SAR-Amplitudenbilder  $A_{t_1}$  und  $A_{t_2}$  des TSX-Sensorsystems genutzt, wobei das Verfahren nicht speziell diese Daten als Eingabe erfordert. Generell sind auch Amplitudenbilder anderer Sensoren bei vergleichbarer oder anderer geometrischer Auflösung einsetzbar.

Die einer Rayleigh-Verteilung folgenden Grauwerte dieser Bilder (Abbildung 3.2, A, B) liegen eingangs im uint16 (*unsigned integer 16 Bit*) Format vor, woraus sich die Grauwertmenge  $G_{\text{uint16}} = \{0, 1, 2, \dots, 2^{16} - 1\}$  ergibt.

Die Erstellung des Differenzbilds aus  $A_{t_1}$  und  $A_{t_2}$  erfolgt mit einer robusteren, abgewandelten Variante der klassischen LR-Methode, die symmetrische Veränderungen zwischen den beiden Bildern berücksichtigt (verschwindende und erscheinende). Diese ist wie folgt definiert ([94] und [177]):

$$A_{MR}^* = \log \left[ \max \left( \frac{A_{t_1}}{A_{t_2}}, \frac{A_{t_2}}{A_{t_1}} \right) \right], \quad (3.1)$$

wobei  $A_{MR}^*$  das pixelweise berechnete (maximale) Quotientenbild ist, welches Änderungen beinhaltet, die sowohl in Richtung von  $A_{t_1}$  nach  $A_{t_2}$  als auch umgekehrt auftreten können. Entsprechend seiner Definition beinhaltet  $A_{MR}^*$  Grauwerte mit einer Spannweite, die  $G_{\text{uint16}}$  entspricht und einer rayleigh-ähnlichen Verteilung folgen (Abbildung 3.2, C).

Aus der pixelbasierten Verarbeitung folgt die erste Vorgabe an die verwendeten Eingabebilder, die somit pixelgenau aufeinander registriert sein müssen. Diese Koregistrierung erfolgt hier aus Gründen der Praktikabilität (siehe unten) als Orthorektifizierung mittels Höhenmodell (hier: *Digital Terrain Elevation Data DTED*, siehe Abschnitt 6.1.1) auf ein quadratisches Raster ( $1 \times 1$  Meter) in einem einheitlichen Bezugssystem (hier: *Universal Transverse Mercator UTM, World Geodetic System 1984 WGS84-Ellipsoid*). Als absolut erreichbar geometrische Genauigkeit für TSX-Bilddaten wird 1 m angegeben [178], in [179] wurden für HS-Daten sogar absolute Genauigkeiten im Submeterbereich beobachtet. In Kombination mit der Tatsache, dass sämtliche hier genutzten TSX-Bilder im *Science-Orbit* (Genauigkeit besser als 4,2 cm [180]) aufgezeichnet wurden, ist diese Form

der Koregistrierung im Hinblick auf die kombinierte Analyse mit ortsbbezogenen Referenzdaten (zum Beispiel GIS-Vektordaten etc.) ausreichend. Sollte eine subpixelgenaue Koregistrierung notwendig sein, müssen Methoden zur Feinregistrierung [181] verwendet werden. Eine subpixelgenaue Registrierung der Eingabedaten muss insbesondere für eine interferometrische Verarbeitung (zum Beispiel Berechnung von Kohärenzbildern) vorliegen ([105] und [182]).

In Vorbereitung des nächsten Prozessierungsschritts (Morph. Filter, Abbildung 3.1), der eine morphologische Operation darstellt, erfolgt eine Skalierung des Quotientenbildes in die uint8-Grauwertmenge  $G_{\text{uint8}} = \{0, 1, 2, \dots, 2^8 - 1\}$ . Diese Skalierung wird mittels Logarithmierung (Abbildung 3.2, D) und anschließender linearer Anpassung an  $G_{\text{uint8}}$  (Abbildung 3.2, E) vollzogen. Anhand der Grauerthistogramme ist zu beobachten, dass sich die ursprüngliche Rayleigh-Verteilung in eine Art Normalverteilung wandelt (Abbildung 3.2, C bis G).

An dieser Stelle kann die Frage geklärt werden, ob zwingend Amplitudenbilder vorliegen müssen, oder auch eine Verwendung von Intensitätsbildern, die im Fall von TSX beziehungsweise TDX beispielsweise nach  $\sigma^0$ -Kalibrierung resultieren, möglich ist. Grundsätzlich ist eine derartige Verarbeitungsweise denkbar, nur müssen hierbei die Eingabebilder entsprechend den formellen Zusammenhängen vorverarbeitet werden. Da die Existenz kalibrierter Daten in der Praxis nicht immer pauschal gegeben ist und um in Bezug zu der hier behandelten Zielsetzung einen möglichst hohen praktischen Nutzen sicherzustellen, werden als Eingabedaten Amplitudenbilder verwendet.

Die morphologische Filterung nimmt im Schema zentrale Bedeutung ein, da diese die Glättung des skalierten Quotientenbilds ( $\text{uint8}[20 \log(A_{MR}^*)]$ ) vornimmt. In seiner ursprünglichen Variante enthält das Quotientenbild stark ausgeprägtes Rauschen, das sich aus Bildelementen heller und dunkler Intensität zusammensetzt (Abbildung 3.3, C). Dieses Rauschen würde unbehandelt zu Falschdetektionen führen und muss dementsprechend möglichst unter Erhalt der original vorliegenden Bildstrukturen beseitigt werden. Als besonders geeignetes Filterverfahren haben sich die  $ASF_{CC}$  mit dem *area* Attribut herausgestellt, die in Anbetracht der jeweils gewählten Wertesequenz  $\chi_i^{area}$  in flexibler Art und Weise die gewünschten Zielobjekte betonen beziehungsweise hervorheben (siehe auch Abschnitt 2.2.1).

In dieser Arbeit bilden kleinräumige Änderungen, wie sie beispielsweise durch Fahrzeuge auf Parkplätzen oder Baustellenabschnitte hervorgerufen werden, die Grundlage. Dieser Vorgabe entsprechend wurde eine Wertesequenz zu  $\chi_i^{area} = [8]$  gewählt, woraus sich als Konsequenz ergibt, dass alle im Quotientenbild enthaltenen CC kleiner als acht Pixel entfernt werden. Im Umkehrschluss folgt daraus, dass Änderungsobjekte mit einer räumlichen Ausdehnung vorliegen, die mindestens der Größe eines Kompaktwagens der PKW-Mittelklasse entsprechen. Das Resultat der morphologischen Filterung ist für das aktuell betrachtete Beispiel in Abbildung 3.3, D, dargestellt.

Die Tatsache, dass in dem vorgestellten Schema Bilder genutzt werden, die eingangs auf ein quadratisches Raster referenziert werden, erleichtert die zuvor getroffenen Annahmen hinsichtlich einer geeigneten Wertesequenz für den  $ASF_{CC}$ . Im Hinblick auf derartige Vorgaben zur Zielobjektgröße und zur Ableitung einer geeigneten Filtereinstellung spielt generell der (räumliche) Auflösungsbegriff eine Rolle. Im Fall der vorliegenden Arbeit werden hochauflösende Bilddaten mit Pixelgrößen von unter einem Meter verwendet, was allgemein die Analyse relativ kleinflächiger Objekte ermöglicht. Ein PKW beispielsweise wird im Bildraster durch mehrere einzelne Pixel dargestellt und kann durch passende Filterung (siehe oben) modelliert beziehungsweise ausgewertet werden. Liegen Bilddaten mit deutlich größerer räumlicher Auflösung vor, können Objekte wie ein PKW nicht mehr in individueller Weise betrachtet werden, da ein einzelnes Bildelement neben dem PKW auch noch die Signaturen der lokalen Umgebung (zum Beispiel Parkplatz) enthält. Würden in diesem Fall nach wie vor Dinge in Dimension eines PKW die Zielobjekte der Änderungsdetektion repräsentieren, so würden diese unter Umständen nicht erkannt werden. Die Wahl der für eine Änderungsdetektion geeigneten Zielobjekte hat demzufolge stets in Anbetracht der räumlichen Auflösung der zur Verfügung stehenden Eingangsbilder zu erfolgen. Bezogen auf das hier vorgestellte Schema bedeutet dies, dass generell auch Bilder mit größeren Pixeln genutzt werden können, nur muss man sich vorher über die gewünschten Zielobjekte und einer entsprechend geeigneten Wertesequenz zur Konfiguration des  $ASF_{CC}$  im Klaren sein.

Die Änderungsdetektion erfolgt durch Anwendung des in Abschnitt 2.2.2 dargelegten entropiebasierten Verfahrens nach Renyi zur unüberwachten Identifikation eines geeigneten Schwellwerts. Zentraler Bestandteil dieser Verfahrensweise ist die Berechnung eines zweidimensionalen Histogramms, das wiederum die Grundlage für die Ermittlung der Entropien für Bildvorder- und Hintergrund bildet. Zur Simulation des Bildhintergrunds ( $A_{MR, ASF_{CC}}^{**}$ ) wird hier eine Glättung des morphologisch gefilterten Quotientenbilds  $A_{MR, ASF_{CC}}^*$  anhand einer Mittelwertberechnung in einem  $3 \times 3$  Pixel großen Fenster durchgeführt (Abbildung 3.3, E). Die Berechnung des optimalen Schwellwertpaars ( $t, s$ ), erfolgt entsprechend den Formeln (2.35) bis (2.39) auf Basis der beiden Bilder  $A_{MR, ASF_{CC}}^*$  und  $A_{MR, ASF_{CC}}^{**}$ . Der einzige manuell vorzugebende Parameter  $\alpha$  wurde

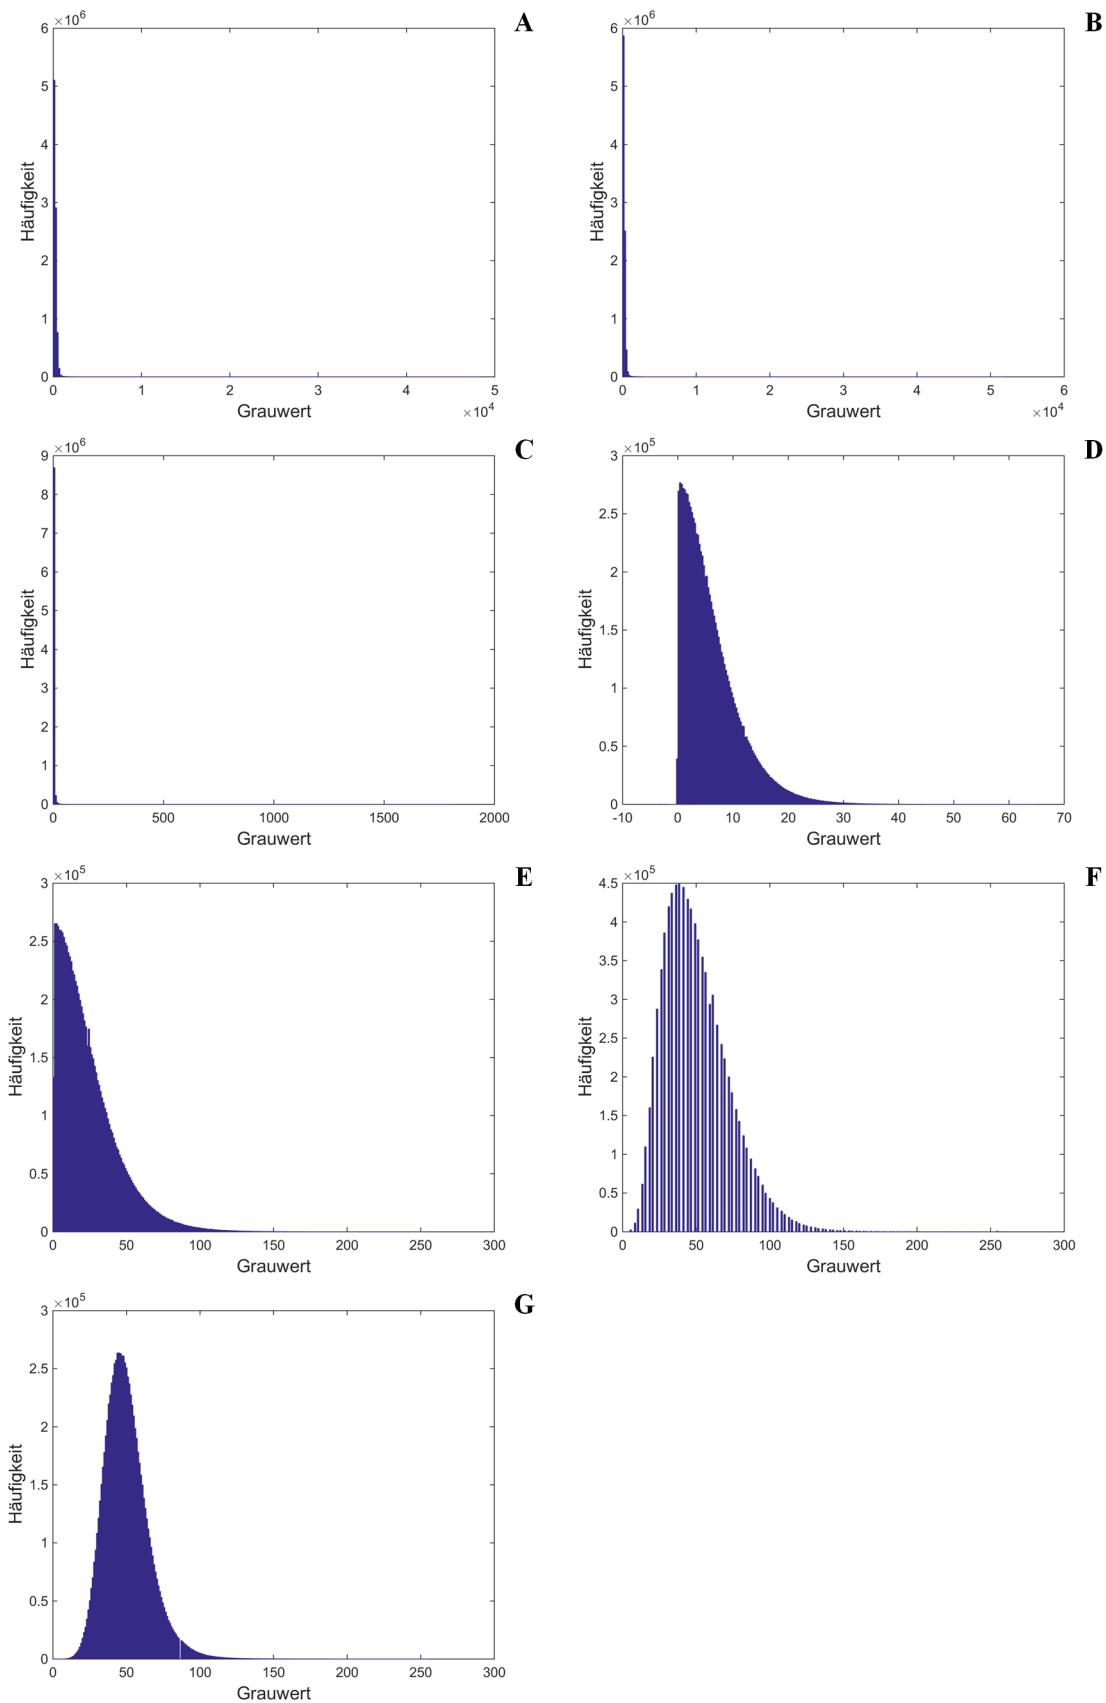


Abbildung 3.2.: Grauertherhistogramme. A: Amplitude zum Zeitpunkt  $t_1$ ; B: Amplitude zum Zeitpunkt  $t_2$ ; C: (maximales) Quotientenbild; D: logarithmiertes Quotientenbild; E: Auf 256 Grauwerte skaliertes, logarithmiertes Quotientenbild; F: ASF-gefiltertes Bild aus E; G: Mittelwert-gefiltertes Bild aus F.

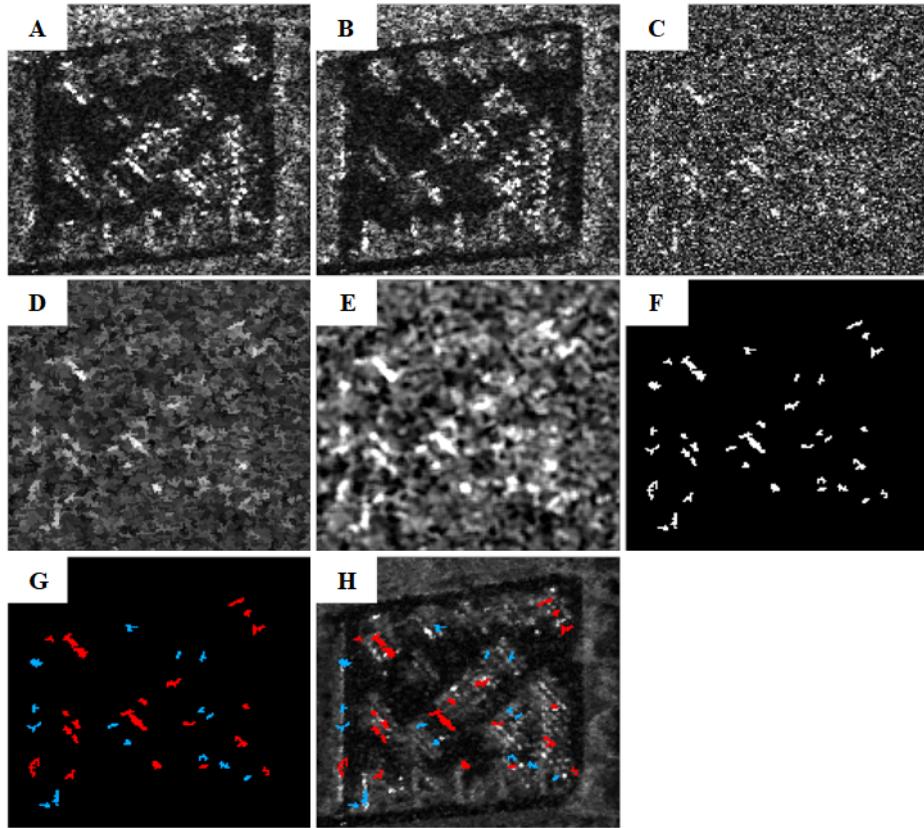


Abbildung 3.3.: Eingabe-, Zwischenresultat- und Ergebnisbilder zur abrupten Änderungsdetektion. A:  $A_{t_1}$ , B:  $A_{t_2}$ , C:  $A_{MR}^*$ , D:  $A_{MR,ASF_{CC}}^*$ , E:  $A_{MR,ASF_{CC}}^{**}$ , F: Änderungskarte CM, G: Farbkodierte CM, H: Dem mittleren Amplitudenbild der Zeitreihe überlagerte, farbkodierte CM.

in Anlehnung an [95] mit  $\alpha = 0.5$  gewählt (vergleiche auch Abschnitt 2.2.2). Für den abgebildeten Ausschnitt resultierte  $(t, s) = [119, 142]$ , wobei der erste Wert als Schwelle auf das Vordergrundbild angewendet wurde.

In Bezug auf das genutzte Verfahren nach *Renyi* ist ergänzend zu erwähnen, dass ein aus dem Grauwert Null bestehender Rahmen um die eigentliche Bildinformation (entstanden zum Beispiel durch Orthorektifizierung) keinen Einfluss auf die Berechnung des optimalen Schwellwerts hat.

Zur Untersuchung einer möglichen Abhängigkeit wurde ein aus drei Fällen bestehendes Testszenario betrachtet. Im ersten Fall wurde ein orthorektifiziert vorliegendes Amplitudenbildpaar wie oben beschrieben analysiert (Abbildung 3.4, Zeile I). Weiterhin wurde ein orthorektifiziertes Amplitudenbildpaar mit simulierter doppelter Anzahl an Rahmenpixeln mit dem Wert Null als Eingabe genommen (Abbildung 3.4, Zeile II). Der letzte Fall (Abbildung 3.4, Zeile III) repräsentiert die Anwendung des Schwellwertverfahrens auf das orthorektifizierte Amplitudenbildpaar, wobei die Rahmenpixel ausmaskiert wurden. Zur Veranschaulichung der Ergebnisse aus der Methode nach *Renyi* wurden die Entropien für Bildvorder- und Hintergrund entlang eines fortlaufenden, auf die Einträge des zweidimensionalen Histogramms verweisenden Indexes abgetragen (Abbildung 3.4, Zeilen I-III, Spalten A und B). Jedem Index von  $[1; 256^2]$  ist ein eindeutiges Grauwertpaar zugeordnet. Die jeweils sich aus den beiden Entropien ergebende Summe ist in Abbildung 3.4, Zeilen I-III, Spalte C, aufgeführt. Es ist ersichtlich, dass für alle betrachteten Fälle derselbe Index (gestrichelte rote Linie), also dasselbe Schwellwertpaar vorliegt, woraus die Unabhängigkeit des Verfahrens gegenüber der Anzahl der Rahmenpixel mit dem Wert Null folgt.

Dieser Effekt basiert auf der Struktur des zweidimensionalen Histogramms in Kombination mit den in Abschnitt 2.2.2 enthaltenen Formeln zur Berechnung der Entropien. Im Fall eines schwarzen Bildhintergrunds befindet sich an der Stelle  $(0, 0)$  (Pixelwert Null in beiden Bildern an gleicher Stelle) des Histogramms eine lokale Anhäufung mit dem Wert  $p_0$ , der nach den Formeln (2.35) bis (2.39) mit der a-posteriori Wahrscheinlichkeit  $P_2$  identisch ist. Aus Bildung des Quotienten dieser beiden Werte resultiert der Wert Eins, der logarithmiert den Wert Null ergibt. Somit folgt für alle Entropiesummen mit Beteiligung des Eintrags an Stelle  $(0, 0)$  des Histogramms der Wert Null, die dementsprechend zu einer geringen Entropiesumme führt, die stets kleiner der maximalen Summe ist. Eine entsprechende Darstellung ist in Abbildung 3.5 zu finden, wo die Entropiesummen farbkodiert für jede Kombinationen aus Grauwerten  $i, j$  eingetragen sind. Es zeigt sich, dass

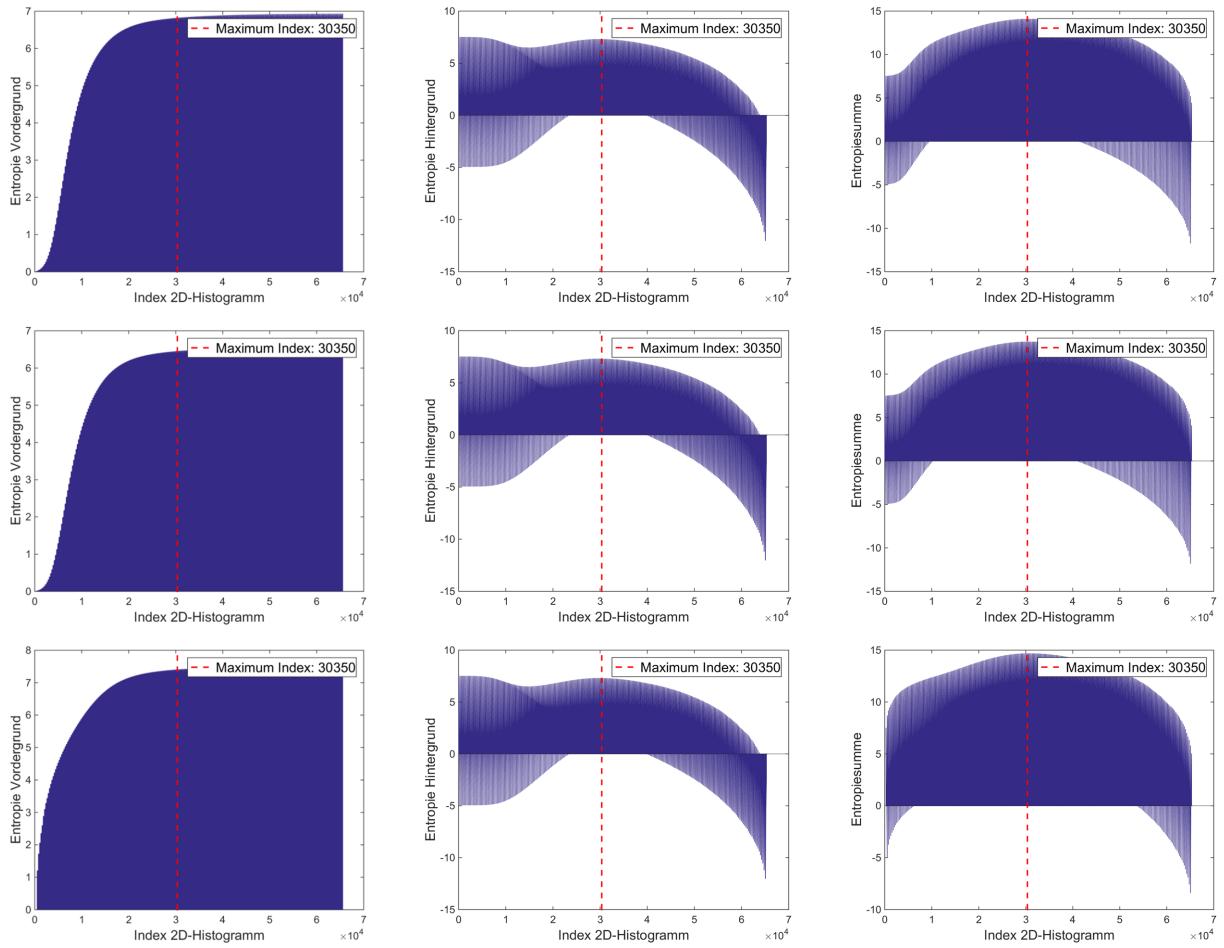


Abbildung 3.4.: Testlauf zur Überprüfung der Abhängigkeit von der Anzahl an Hintergrundpixel. Zeilen (von oben nach unten): Ursprüngliche Anzahl an Rahmenpixeln; doppelte Anzahl an Rahmenpixeln; keine Rahmenpixel. Spalten (von links nach rechts): Vordergrundentropien; Hintergrundentropien; Entropiesummen.

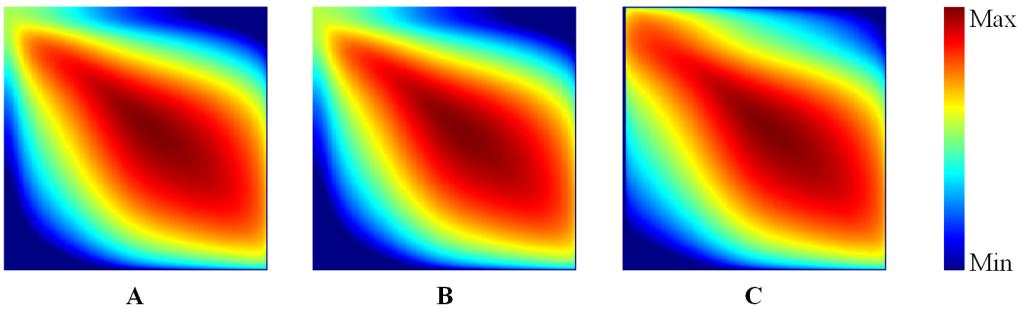


Abbildung 3.5.: Visualisierung der Entropiesummen. Linkes oberes Eck: Entropiesumme für das Grauwertpaar  $(i, j) = (0, 0)$ . Rechtes unteres Eck: Entropiesumme für das Grauwertpaar  $(i, j) = (255, 255)$ . A: Datenbasis nach Fall 1; B: Datenbasis nach Fall 2; C: Datenbasis nach Fall 3.

der Bereich der maximalen Summen (dunkelrot) für alle drei Fälle übereinstimmt.

Als finales Ergebnis des Ablaufplans zur abrupten Änderungsdetektion liegt nach Anwendung des Schwellwerts auf  $A_{MR,ASF_{CC}}^*$  eine binäre Karte mit den Änderungssegmenten im Vordergrund vor (Abbildung 3.3, F). Diese *ChangeMap* (CM, Abbildung 3.1) enthält  $i$  Segmente  $cs_i$  mit einer Flächengröße  $cs_{i,area}$  von mindestens acht Pixel (siehe oben). Um in Anbetracht der hier geforderten Zielobjektgrößen sinnvolle Resultate zu erhalten, wird eine Filterung der CM durchgeführt, so dass Änderungssegmente mit  $8 \leq cs_{i,area} \leq 400$  Pixel vorliegen. Die Fläche von 400 Pixel ergibt sich aus der ungefähr halben durchschnittlichen Grundstücksfläche

eines Einfamilienhauses [183], die in Anbetracht der gesuchten Zielobjekte (siehe oben) eine gute vergleichbare Größe darstellt.

Nach dieser Filterung der CM wird ein *Labeling* (Kennzeichnung) unter Nutzung der 4er-Nachbarschaft der darin enthaltenen  $cs_i$  durchgeführt, um diese eindeutig zu indizieren und so die spätere Auswertung der Änderungssegmente zu erleichtern.

Abbildung 3.3 enthält darüber hinaus zwei weitere Darstellungen der binären CM (G, H). Beides sind Farbkodierungen der  $cs_i$ , wobei Segmente, die in Richtung  $A_{t_1}$  nach  $A_{t_2}$  erscheinen, blau markiert sind. Verschwindende Änderungssegmente von  $A_{t_1}$  nach  $A_{t_2}$  sind rot eingefärbt. Abbildung 3.3, H, zeigt die farbkodierten  $cs_i$  als Überlagerung auf dem gemittelten Amplitudenbild der Zeitreihe. Die abrupte Änderungsdetektion auf Basis von Zeitreihendaten, die als Basis für die Detektion der Hochaktivitätsobjekte dient, ist Gegenstand des folgenden Abschnitts.

## 3.2. Anwendung auf Zeitreihendaten

Die im vorangegangenen Abschnitt erläuterte Methode zur Detektion abruper Veränderungen in bi-temporalen Datensätzen kann zur Identifikation von Bereichen verwendet werden, die sich entlang einer vorgegebenen Zeitspanne sehr häufig beziehungsweise hochfrequent ändern. Anstelle eines koregistrierten Bildpaars  $D_{bi} = [A_{t_1}, A_{t_2}]$  werden nachstehend die  $n$  Bilder einer gegebenen Zeitreihe  $D_{ts} = [A_{t_1}, A_{t_2}, \dots, A_{t_n}]$  betrachtet. Alle genutzten Eingabebilder müssen wie oben beschrieben pixelgenau aufeinander registriert vorliegen.

Der nachfolgende Abschnitt 3.2.1 beinhaltet die Vorgehensweise zur Detektion abgebildeter Bereiche, die sich entlang einer Zeitreihe niedrig-, mittel- und hochfrequent verändern. Es wird aufgezeigt, dass das zuvor beschriebene bi-temporale Verfahren zur abrupten Detektion durch Anwendung auf  $n$  zeitlich nacheinander entstandener Amplitudenbilder für eine quasi-progressive Detektion genutzt werden kann. Im Kontrast zur bi-temporalen Verarbeitung verkörpert insbesondere die Identifikation hochfrequenter Änderungsbereiche und der darin enthaltenen Änderungsobjekte HAO den analytischen Mehrwert für praktische Anwendungszwecke (*Monitoring* beziehungsweise Überwachungsanalysen der Raum- und Landesplanung).

Als Grundlage für die pixelbasierte Präkategorisierung der entlang der Zeitachse detektierten Änderungen (Abschnitt 3.2.2) und die daran anschließende Extraktion der HAO (Abschnitt 3.2.3) dient die Berechnung der Index- und Aktivitätskarte.

### 3.2.1. Index- und Aktivitätskarte

Aus  $n$  Amplitudenbildern folgen  $n - 1$  binäre Änderungskarten, die aufsummiert eine Karte mit Indizes ergeben, die wiederum Aufschluß über die Änderungsfrequenz einzelner Bildbereiche gibt. Eine solche Indexkarte (*IndexMap IM*) wird wie folgt berechnet:

$$IM = \sum_{i=1}^{n-1} CM_i. \quad (3.2)$$

In Abbildung 3.6 ist das Schema zur Berechnung der IM grafisch dargestellt, inklusive eines Ergebnisbeispiels (Abbildung 3.6, D). Dieses Beispiel zeigt einen vergrößerten Ausschnitt des im vorherigen Abschnitt behandelten Bildbereichs eines LKW-Parkplatzes. Die magenta-farbenen Nummern kennzeichnen die an den jeweiligen Orten enthaltenen Indizes. Der Index 6 steht beispielsweise für ein Pixel, das entlang der Zeitreihe in sechs CM als Vordergrundpixel enthalten ist. Der Wert Null in der IM markiert Bildbereiche, die in der beobachteten Zeitspanne unverändert blieben. Als Zeitreihe wurde der in Kapitel 6 beschriebene Bildstapel, bestehend aus 15 TSX-Amplitudenbildern, verwendet.

Anhand der in der IM enthaltenen Information über die Änderungsfrequenz einzelner Bereiche kann eine weitere, etwas anschaulichere Darstellung berechnet werden. Die Aktivitätskarte (*ActivityMap AM*) enthält die farbkodierten Indizes der IM und vermittelt dem Anwender einen unmittelbaren Überblick über die in der jeweiligen Szene enthaltenen (zeitlichen) Änderungscharakteristiken. Die Farbkodierung der IM-Pixel erfolgt aus der Analyse des IM-Histogramms (Abbildung 3.7) und wird für die Zeitreihe wie folgt definiert:

$$p_{i,AM} = \begin{cases} \text{gelb,} & \text{wenn } p_{i,IM} = 1, \\ \text{orange,} & \text{wenn } 1 < p_{i,IM} \leq 3, \\ \text{rot,} & \text{wenn } p_{i,IM} > 3, \end{cases} \quad (3.3)$$

wobei  $p_{i,IM}$  der Wert des Pixels  $i$  in der Indexkarte ist. Für das aktuell betrachtete Beispiel resultiert die in Abbildung 3.7 gegebene Darstellung (unten rechts). Die entsprechenden Ergebnisse für den betrachteten

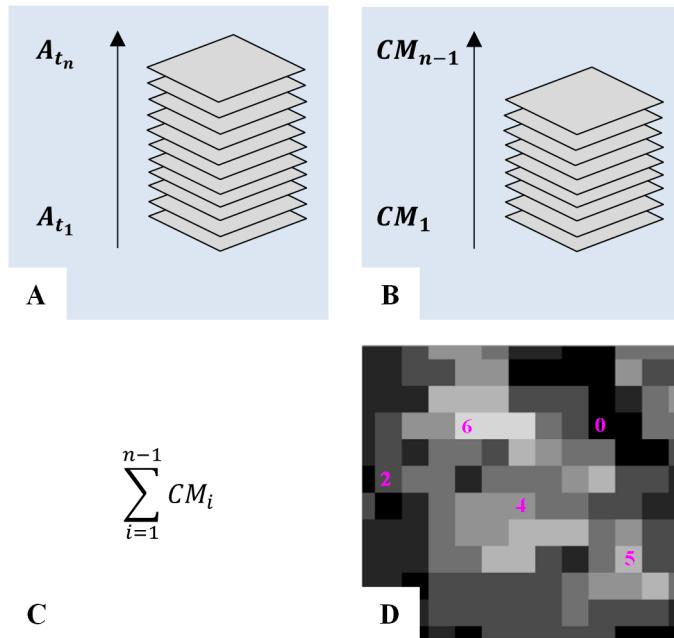


Abbildung 3.6.: Ablauf zur Berechnung der *IndexMap*. A: Zeitstapel aus  $n$  Amplitudenbildern; B: Zeitstapel aus  $n - 1$  CM; C: Pixelweise Aufsummierung der  $n - 1$  CM; D: Ausschnitt aus der IM.

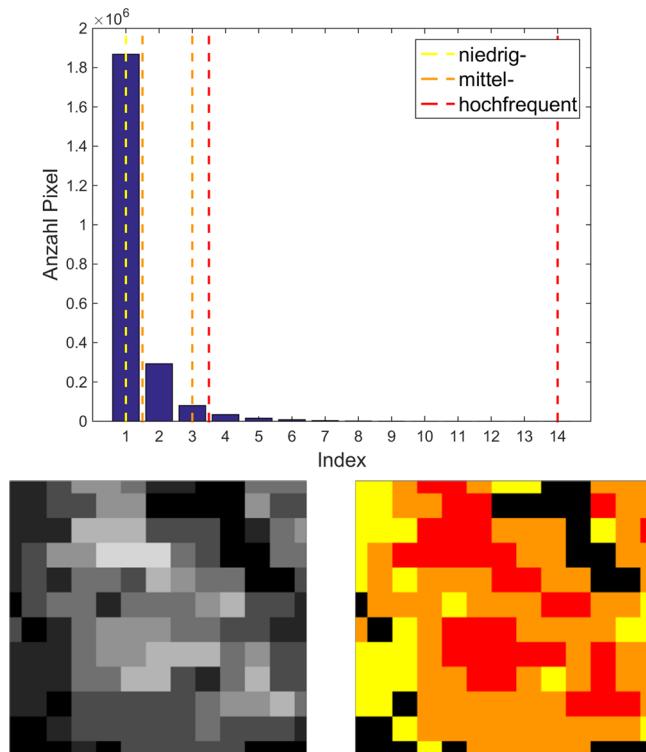


Abbildung 3.7.: Erstellung der *ActivityMap*. Oben: IM-Histogramm; unten links: IM; unten rechts: AM.

Bildausschnitt des Parkplatzbereichs befinden sich in Abbildung 3.8.

Im Vergleich zur abrupten Änderungsdetektion ist in direkter Weise der Mehrwert ersichtlich, der durch die Anwendung auf einen Zeitreihenstapel entsteht. Neben der alleinigen Detektion des Änderungsorts, verbunden mit der eindimensionalen Information hinsichtlich des Änderungszeitpunkts, lässt sich mit dieser Methode für jedes Bildelement der Szene eine charakteristische Aktivitätssignatur ableiten. Der nachfolgende Abschnitt handelt von diesen Signaturen und der pixelbasierten Kategorisierung der in der AM beziehungsweise

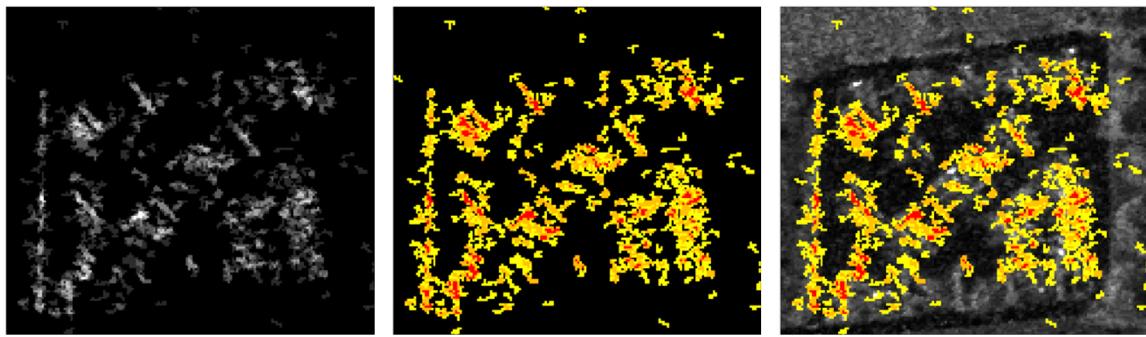


Abbildung 3.8.: Ausschnitt LKW-Parkplatz. Links: IM; Mitte: AM; rechts: Dem mittleren Amplitudenbild der Zeitreihe überlagerte AM.

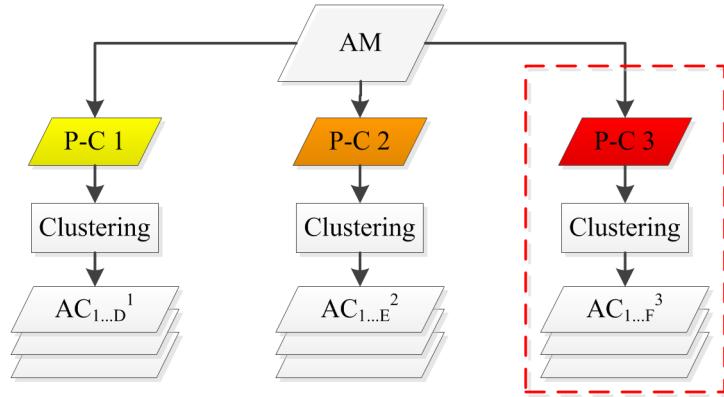


Abbildung 3.9.: Prækategorisierung.

IM enthaltenen Änderungen. Einen besonderen Stellenwert nehmen hierbei die  $p_{i,IM} > 3$  ein, die entlang der Zeitspanne jene Bereiche darstellen, die eine hohe Änderungsfrequenz aufweisen.

### 3.2.2. Prækategorisierung und Aktivitätscluster

In der AM sind all jene Bildelemente  $p_{i,AM}$  rot markiert, für die  $p_{i,IM} > 3$  gilt. Diese Hochaktivitätspixel (HAP) kennzeichnen Gebiete, die sich über die zur Verfügung stehende Zeitperiode sehr häufig verändern. Die HAP bilden die Grundlage für die nachfolgenden Betrachtungen zur Ableitung charakteristischer Zeitverläufe, sowie zur Identifikation der Hochaktivitätsobjekte (HAO) im nachfolgenden Abschnitt 3.2.3. Anhand der Extraktion der zeitlichen Verläufe beziehungsweise der Aktivitätssignaturen je HAP (siehe auch Abbildung 3.10, E) soll in dieser Arbeit geprüft werden, ob einzelne Kategorien oder auch Klassen typische Verläufe beinhalten (siehe Abschnitt 6.3.4).

Die Extraktion der zeitlichen Verläufe für alle zu einer Aktivitätskategorie gehörenden Bildelemente in Kombination mit anschließender Cluster-Berechnung wird hier als Prækategorisierung bezeichnet, deren schematischer Ablauf in Abbildung 3.9 skizziert ist. Mit Bezug zu Formel (3.3) können in der AM drei Aktivitätskategorien (P-C 1, P-C 2, P-C 3) unterschieden werden, wobei im Folgenden nur die HAP berücksichtigt werden. Im ersten Prozessierungsschritt wird für jedes der  $j$  HAP in der P-C 3 Kategorie die jeweilige Zeitreihen- beziehungsweise Aktivitätssignatur  $HAP_{ts}$  (Abbildung 3.10, D) bestimmt, die in binärer Form Informationen darüber enthält, ob das HAP in einer  $CM_i$  ein Vordergrundpixel ist ( $HAP_{ts,i} = 1$ ) oder nicht ( $HAP_{ts,i} = 0$ ). Das daran anschließende *Clustering* dient zur Einteilung der HAP in die  $F$  Aktivitätscluster  $AC^3$ , wobei in einem derartigen Cluster HAP mit identischem Zeitverlauf zusammengefasst werden.

Das Ergebnis der Prækategorisierung für das aktuelle Bildbeispiel ist in Abbildung 3.10, B, C, visualisiert. Links befindet sich das in Grauwerten formulierte *Label*-Bild (B), wobei jedem der  $AC_{1..F}^3$  ein eindeutiges *Label* zugewiesen ist, rechts davon ist die entsprechende Farbdarstellung enthalten (C). Auf den ersten Blick scheint eine Häufung an Instanzen des hier grün dargestellten Clusters vorzuliegen. Dies ist jedoch in Relation der großen Anzahl an vorliegenden HAP (hier: 63.396) und *Label* (hier: 7.056) der Gesamtszene zu betrachten, von der das gezeigte Beispiel nur ein Ausschnitt ist. In diesem Zusammenhang resultiert eine Kodierung der *Label* mit Farben, die im RGB-Farbraum sehr nah beieinander liegen und demzufolge für das menschliche Auge schwer zu unterscheiden sind. Eine genauere Prüfung des gelabelten Bilds ermöglicht sein Histogramm

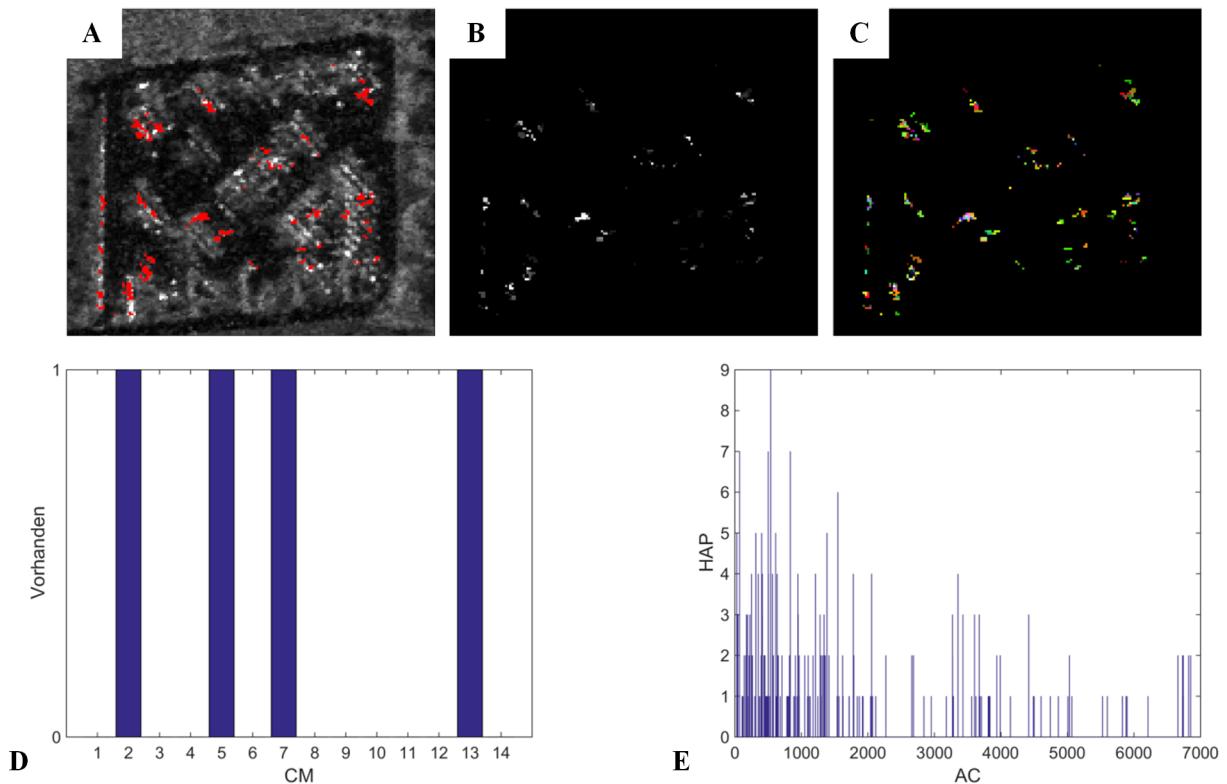


Abbildung 3.10.: HAP und Kategorisierung anhand von Aktivitätssignaturen. A: Dem mittleren Amplitudenbild der Zeitreihe überlagerte HAP; B: Kategorisierte, als Grauwerte dargestellte HAP (Label); C: Kategorisierte, farbkodierte HAP; D: Exemplarische HAP-Aktivitätssignatur; E: Histogramm des gelabelten Bilds in B.

(Abbildung 3.10, E), in dem tatsächlich das ein oder andere AC häufiger als ein anderes enthalten ist. Ein global dominierendes AC kann nicht identifiziert werden, was als eine erste Erkenntnis hinsichtlich der AC-Nutzung für die Änderungsanalyse (Abschnitt 6.3.4) betrachtet werden kann.

Alle bisher in diesem Kapitel beschriebenen Zusammenhänge und Darstellungen erfolgten pixelbasiert. Im Anschluß wird die Pixelebene verlassen und die Identifikation von Hochaktivitätsobjekten beschrieben.

### 3.2.3. Identifikation von Hochaktivitätsobjekten

Für die Identifikation der Hochaktivitätsobjekte (HAO) auf Grundlage der HAP ist zu beachten, dass sich generell jedes Segment aus mehreren Bildelementen zusammensetzt. Um im Hinblick auf die spätere Kategorisierung der HAO eine mehrfache Merkmalsextraktion für ein spezifisches HAO zu vermeiden, hat die Detektion eines bestimmten HAO in eindeutiger und einmaliger Weise zu erfolgen. Aufgrund des Resultats aus der Präkategorisierung ist zu erwähnen, dass ein bestimmtes HAO Element verschiedener Aktivitätscluster (AC) sein kann. Dieser Zusammenhang ist in Abbildung 3.11 dargestellt.

Die hier fünf räumlich nebeneinander befindlichen HAP (a bis e) gehören zu zwei verschiedenen AC (1 und 2), die aus unterschiedlicher zeitlicher Abfolge verschiedener HAO (1 bis 5) resultieren. Vertikal sind die Änderungskarten CM (hier: 1 bis 14) aufgetragen. Es ist ersichtlich, dass HAP eines bestimmten AC (zum Beispiel a bis c, Abbildung 3.11, blauer Kasten) zu mehreren verschiedenen HAO gehören können (zum Beispiel HAO 1 und HAO 3). Weiterhin können bestimmte HAO (zum Beispiel HAO 1 und HAO 4) HAP verschiedener AC (c bis e) beinhalten (Abbildung 3.11, grüner Kasten). Die eindeutige Extraktion der HAO wird deshalb wie nachfolgend erläutert durchgeführt.

Zunächst werden zu jedem Pixel eines bestimmten AC die entsprechend beteiligten HAO gesucht, wobei ein individuelles HAO lediglich einmalig extrahiert wird. Im Anschluß daran wird über die Grenzen einzelner AC hinaus geprüft, ob ein bestimmtes HAO mehrfach enthalten ist. Trifft dies zu, wird das HAO nur einmalig der zu erstellenden Objektliste zugewiesen. In dieser Liste liegt nach der Extraktion der HAO jedes dieser Objekte mit eigener Identifikationsnummer und den individuellen Bildkoordinaten vor. Weiterhin sind die jeweils kennzeichnenden Nummern aus dem *Labeling* der binären Änderungskarten, sowie die Nummer der CM gelistet, in der das HAO enthalten ist. Um jedes HAO wird weiterhin die kontextgebende lokale

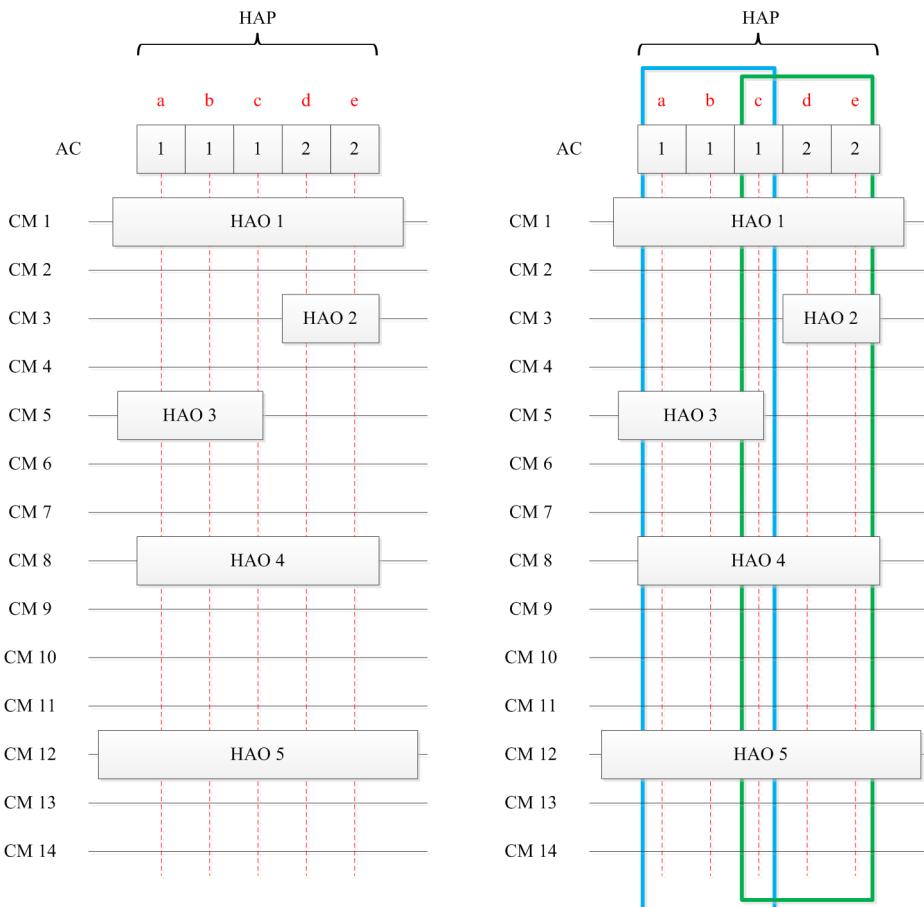


Abbildung 3.11.: HAP und HAO in Anbetracht verschiedener Zeitverläufe beziehungsweise AC-Zugehörigkeiten.

Nachbarschaft ( $400 \times 400$  Pixel) ausgeschnitten, die die Grundlage für die in Abschnitt 4.2.1 vorgestellte Segmentierungsmethode bildet.

Eine ergänzende Form der raumzeitlichen Analyse kann erfolgen, wenn die sich an gleichem Ort befindlichen HAO ihrer zeitlichen Abfolge entsprechend übereinander angeordnet betrachtet werden (siehe auch Abbildung 3.11). Es resultieren sogenannte Hochaktivitätsstapel, die entsprechend den getroffenen Annahmen hinsichtlich der Hochaktivitätsobjekte, mindestens vier HAO beinhalten (durch  $p_{i,IM} > 3$ ). An späterer Stelle dieser Arbeit wird geprüft, ob statistische, merkmalsorientierte Eigenschaften derartiger Stapel zur Unterscheidung verschiedener LULC-Klassen zielführende Hinweise liefern (siehe Abschnitt 6.3.4).



## **Kapitel 4.**

### **Merkmalsextraktion**

Die im vorherigen Kapitel erläuterte Identifikation der HAO stellt den ersten Schritt für ihre Kategorisierung und Klassifikation dar. Bezugnehmend zu den Ausführungen in Abschnitt 2.2.6 erfolgt eine Kategorisierung mittels Merkmalen, die zuvor für die zu gruppierenden HAO abgeleitet werden müssen. Diese Ableitung erfolgt in Anbetracht der Existenz der HAO in objektbasierter Weise, was unter anderem die Berechnung formbeschreibender Merkmale beinhaltet (Abschnitte 2.2.4 und 4.2.3).

Da aus genereller Sichtweise mehrere verschiedene Merkmale nutzbar sind, wird zunächst in einem einführenden Abschnitt ein Abriss über das Themengebiet der Merkmalsextraktion und eine Übersicht über verbreitete Merkmale in der Bildanalyse gegeben (Abschnitt 4.1).

In dem darauf folgenden Abschnitt 4.2 werden die genutzten Merkmale sowie die entsprechenden Berechnungsweisen beschrieben.

## 4.1. Überblick

Nach [184] kann ein *Merkmal* als eine spezifische Ausprägung oder Eigenschaft bezeichnet werden, die zur Beschreibung der jeweils vorliegenden Daten verwendet werden kann. Übertragen auf die zweidimensionale Bildverarbeitung ist ein Merkmal typischerweise eine visuelle, spezifische Eigenschaft entweder des gesamten Bildes (globales Merkmal) oder eines darin enthaltenen Objekts (lokales Merkmal). Als gängig genutzte Eigenschaften werden die Merkmale Intensität, Form, Größe, Orientierung und Textur erwähnt. Unter Berücksichtigung der in Abschnitt 2.2.4 enthaltenen Ausführungen sind insbesondere Form, Größe und Orientierung charakteristische, objektbasierte Merkmale. Allgemein kann hierbei zwischen kontur- und regionenorientierten Eigenschaften unterschieden werden, wobei letztere zur Informationsgewinnung anhand von Objekten oder Regionen innerhalb geschlossener Umrandungen (zum Beispiel zusammenhängende Komponenten CC) zur Anwendung kommen [184].

Eine ähnliche Darstellung ist in [185] enthalten, wo neben den einfachen zweidimensionalen Merkmalen wie Radiometrie, Textur und Form auch kontextbasierte Merkmale genannt werden, die zur Modellierung semantischer Zusammenhänge dienen. Generell ist allerdings zu erwähnen, dass eine klare Abgrenzung von einfacher und kontextbasierter Merkmalsextraktion nicht möglich ist. So wird beispielsweise in [184] die Texturanalyse als eine lokale Charakterisierung der Intensitätseigenschaften zur Unterscheidung semantisch unterschiedlicher Bildregionen beschrieben, was letztlich eine Art kontextbasierte Auswertung darstellt.

Die Orientierung eines Bildobjekts ist eng verbunden mit dem Themenbereich der momentenbasierten Bildauswertung [186], bei der charakteristische Eigenschaften von Regionen in Relation zu ihrem Schwerpunkt (Moment erster Ordnung) ausgedrückt werden. In [187] finden sich die sogenannten normierten *Hu-Momente*, die weitestgehend invariant gegenüber Rotationen, Translationen und Skalierungen sind (siehe auch [186]). Das erste *Hu-Moment* kann näherungsweise als Massenträgheitsmoment (*moment of inertia moi*) beschrieben werden, das die Ausdehnung einer CC relativ zu ihrem Massenschwerpunkt kennzeichnet [116]. Klassische, morphologische Filteroperationen können als strukturorientierte Methoden betrachtet werden, die zur Löschung oder Erhaltung beziehungsweise Rekonstruktion bestimmter Inhalte genutzt werden können (siehe auch Abschnitt 2.2.1), woraus in indirekter Weise den Bildinhalt beschreibende Informationen abgeleitet werden können. Hierfür dient die Anwendung eines strukturierenden Elements SE, das in Form und Größe initial vorgegeben wird und somit letztlich nur diese zweidimensionalen Eigenschaften über den Bildinhalt bereitstellt. Eine umfassendere Möglichkeit zur Informationsgewinnung bieten die morphologischen Attributfilter, die als Bestandteil zur Berechnung der Attributprofile AP eine vollständigere Szenenauswertung erlauben (Abschnitt 2.2.1). Als Attribute ist eine Vielzahl unterschiedlicher Merkmale denkbar, wobei auf eine komplementäre und demzufolge gegenseitig unterstützende, sowie unkorrelierte Anwendung geachtet werden sollte. Die eingangs erwähnten Merkmale können zur Definition von Attributprofilen genutzt werden, wobei im Vergleich zur herkömmlichen Verarbeitungsweise nicht nur ein Wert, sondern ein signaturgebender Wertevektor abgeleitet wird. Attributprofile sind in der Analyse optischer Fernerkundungsbilder weit verbreitet ([188], [116], [189] und [190]), wurden bisher allerdings für die SAR-Bildanalyse relativ wenig genutzt.

In [191] findet sich eine Anwendung der morphologischen Profile (MP) auf ein TSX *StripMap*-Amplitudenbild zur Klassifikation urban genutzter Flächen. Um die Eingeschränktheit eines fest gewählten SE zu umgehen, werden acht verschiedene dreiecksförmige SE mit unterschiedlicher Orientierung zur Berechnung der MP eingesetzt. Die eigentliche Klassifikation der Szene erfolgt mittels KNN. In [192] ist basierend auf einer Nutzung von Attributfiltern eine Methode zur Detektion stationärer Fahrzeuge beschrieben. Als Eingabebilder werden luftgestützt erfasste, sehr hochauflöste SAR-Amplitudenbilder des Sensors PAMIR mit Pixelgrößen von 0,15 m (Entfernung) und 0,07 m (Azimut) verwendet. Die Detektion selbst erfolgt durch lokale Auswertung von Korrelationsmasken. Die Resultate werden nur als leicht schlechter als jene Ergebnisse beschrieben, die durch Klassifikationsverfahren wie SVM und *Random Forest* erreicht wurden.

Im Hinblick auf weitere in der SAR-Bildauswertung zum Einsatz kommende Merkmale kann prinzipiell auf die in Abschnitt 1.1 erläuterten Ansätze verwiesen werden, da jede Klassifikation (Landnutzung, Landbedeckung, oder Änderung) eine vorab durchgeführte Ableitung geeigneter Merkmale erfordert. In [58] werden Rückstreuereigenschaften und Kohärenzwerte entlang einer Zeitreihe betrachtet. Eine zeitliche Signatur wird in [64] zur Charakterisierung von Änderungen eingesetzt.

Eine Gegenüberstellung verschiedener statistischer Verfahren zur Merkmalsextraktion ist in [193] zur Klassifikation von TSX-Bildern enthalten. Als Grundlage für die Analyse dienen dort die mittels GLCM und *Gabor*-Filter (auch in [194]) abgeleiteten Texturmerkmale. GLCM-basierte, Haralick-Texturparameter werden auch in [128] zur Identifikation schuttähnlicher Bildstrukturen, sowie in [75] zur Änderungsanalyse genutzt. Textur und Radiometrie werden neben Wavelet-Merkmalen und polarimetrischen Eigenschaften ebenfalls

in [195] zur Landbedeckungsklassifikation auf Grundlage von ALOS PALSAR-Bildern verwendet. Hinsichtlich der *Wavelet*-Transformation und deren Anwendung auf SAR-Bilder findet sich beispielsweise in [108] eine umfassende Zusammenstellung. Geometrische, radiometrische und texturbasierte *Haralick*-Merkmale werden in [196] genutzt, um basierend auf ENVISAT ASAR-Bildern Öltepiche auf Gewässeroberflächen zu klassifizieren.

In Anbetracht der in diesem Abschnitt enthaltenen Ausführungen ist eine große Anzahl an verschiedenen Merkmalen ableitbar. Für die Bearbeitung der vorliegenden Aufgabenstellung wird eine Sammlung aus verbreiteten Merkmalen eingesetzt (siehe nachfolgende Abschnitte). Es wird geprüft, welches die für eine Kategorisierung der HAO am Besten geeigneten Merkmale beziehungsweise Merkmalsgruppen sind. Diese datengetriebene Beurteilung befindet sich in Abschnitt 6.2.3.

## 4.2. Verwendete Merkmale

In den nachfolgenden Unterabschnitten werden die für die in Kapitel 5 thematisierte Kategorisierung der Hochaktivitätsobjekte HAO eingesetzten Merkmale, inklusive ihrer Extraktionsweise, erläutert. Die Anwendung auf hier zur Verfügung stehende Testdatensätze und die damit verbundene Berechnung einer Merkmalsmatrix über alle HAO ist Inhalt von Kapitel 6.

Der nachstehende Unterabschnitt 4.2.1 beinhaltet Vorgehensweisen zur Extraktion von Merkmalen, die die lokale Umgebung eines HAO hinsichtlich einer darin vorherrschenden LULC-Klasse sowie der dort vorhandenen strukturellen Anordnung der HAO beurteilen. Im Gegensatz zu den weiteren hier betrachteten Merkmalen wie Kohärenz (4.2.2), Form (4.2.3), Textur (4.2.4) und Morphologie (4.2.5) werden diese (semantischen) Eigenschaften mit binärem Wertebereich  $W_{bin} = \{0, 1\}$  modelliert. Aus diesem Grund wird die semantische Information im Zuge der unüberwachten Kategorisierung mittels statistischem *Clustering*-Verfahren nicht berücksichtigt. Sie dient vielmehr als weiterführende Information, die den Anwender bei der postklassifizierenden Bewertung des Ergebnisses unterstützt (Abschnitt 6.2.6).

In Unterabschnitt 4.2.5 werden die genutzten morphologischen Merkmale beschrieben. Da hierfür die zuvor erwähnten, differentiellen Attributprofile DAP (Abschnitt 2.2.1) verwendet werden, können mehrere verschiedene Attribute eingesetzt werden, wovon insbesondere die Betrachtung SAR-spezifischer Eigenschaften wie die kalibrierte Radiometrie ( $\Sigma$  Nought  $\sigma^0$ , siehe Abschnitt 2.1) und die lokale Statistik in Form des Variationskoeffizienten Cov als Neuerung genannt werden kann.

### 4.2.1. Kontext

Die Berücksichtigung des lokalen Kontextes einer bestimmten Region oder eines bestimmten Bildobjekts ermöglicht die Ableitung semantischer Informationen, die für eine Klassifikation zielführenden Charakter besitzen können. Übertragen auf die Änderungsanalyse bedeutet dies, dass die Kontextklasse einer Änderung Erkenntnisse bereitstellt, die für eine detailliertere Bewertung des Änderungstypus herangezogen werden können. Von Anwenderseite ist keinerlei spezifisches Fachwissen hinsichtlich der verwendeten Datengrundlage oder des Szeneninhalts erforderlich.

Den Hauptbestandteil der nachfolgend beschriebenen Methode zur Extraktion der änderungsbezogenen Kontextklasse nimmt die Segmentierung der räumlich lokalen Nachbarschaft eines Änderungsobjekts ein, die die Ableitung formbeschreibender Merkmale ermöglicht, welche zur Beurteilung des lokalen Kontextes dienen. Diese räumlich lokale Nachbarschaft wird im Folgenden als Hochaktivitätsregion (HAR) bezeichnet.

Als Prozessierungseinheit für die Zuweisung zu einer Kontextklasse wird jenes Segment verwendet, welches das jeweilige HAO beinhaltet beziehungsweise umschließt. Die Klassenzuweisung selbst erfolgt anhand von frei verfügbaren *OpenStreetMap* (OSM) GIS-Layern in Zusammenspiel mit vorab im Zuge einer überwachten Klassifikation extrahierten LULC-Klassen (*eCognition Developer*). Dies besitzt den Vorteil, dass zwei voneinander unabhängige Informationsquellen in gegenseitiger Überprüfung eingesetzt werden. Darüber hinaus erfolgt auf diese Weise eine Klassenzuweisung auch in Regionen, die in der OSM-Datenbank noch nicht flächendeckend hinterlegt sind, oder auch im Fall einer Nichtexistenz von OSM-Daten. Grundsätzlich sind sämtliche in Rasterform erhältliche LULC-Kartierungen als Eingabedaten vorstellbar, wobei auf eine gewisse Aktualität der Daten zu achten ist, da nur so die Ableitung aussagekräftiger Informationen erfolgen kann. Neben der Aktualität ist darauf zu achten, dass die Referenzdaten in identischer Projektion und mit identischer Pixelgröße wie die Amplitudenbilddaten vorliegen.

In Abbildung 4.1 ist der Ablauf schematisch visualisiert. Im Folgenden wird auf die einzelnen Verarbeitungsschritte eingegangen.

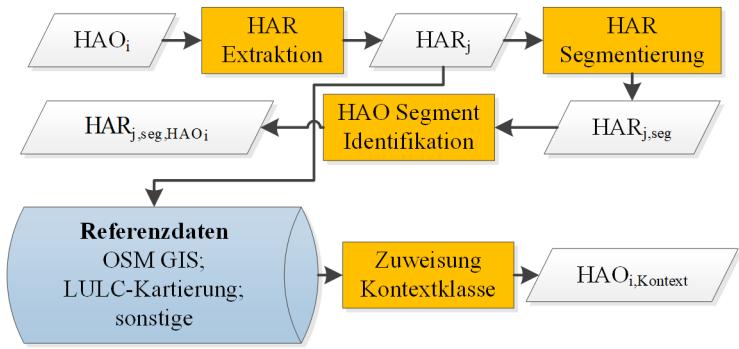


Abbildung 4.1.: Schematischer Ablauf zur Extraktion des Kontextmerkmals. Gelbe Rechtecke beinhalten Prozessierungsschritte, Rauten stellen Daten dar. Blau: Datenbank.

### **Extraktion von Hochaktivitätsregionen (HAR):**

Jedem als HAO identifiziertem Änderungsobjekt wird als erster Vorverarbeitungsschritt eine lokale Nachbarschaft zugeordnet. Diese Zuordnung beinhaltet die Erstellung von Bildausschnitten, wobei das jeweilige HAO im Zentrum des Ausschnittes liegt. Ein derartiger Ausschnitt ist  $400 \times 400$  Pixel groß und umfasst im vorliegenden Bildraster mit  $1 \times 1$  Meter Pixelgröße eine Fläche von  $400^2$  Quadratmetern.

Als Eingabebilder für die HAR-Erstellung werden zwei Datensätze genutzt: Die über die Zeitreihe gemittelte,  $\sigma^0$ -kalibrierte Amplitude  $\hat{A}_{\sigma^0}$  und die auf 256 Graustufen skalierte Amplitude  $\hat{A}_{\sigma^0,8b}$ , wobei gilt:

$$\hat{A}_{\sigma^0} = \frac{1}{n} \sum_{i=1}^n A_{t_i, \sigma^0}, \quad (4.1)$$

beziehungsweise

$$\hat{A}_{\sigma^0,8b} = \tanh_{scale} [\hat{A}_{\sigma^0}], \quad (4.2)$$

mit der Anzahl  $n$  an verfügbaren Amplitudenbildern und der (verlustfreien)  $\tanh_{scale}$ -Skalierung (Formel (2.14)).

### **Segmentierung von HAR:**

Für die Segmentierung der lokalen Nachbarschaft einer Änderung kommt generell eine Vielzahl verschiedener Verfahren in Betracht. Die in Kapitel 1 beschriebenen Anforderungen hinsichtlich einer praxisrelevanten Methode, die gleichzeitig kein explizites Fachwissen von Bedienerseite erfordert, schließt von vornherein den Einsatz beispielsweise des kommerziell verfügbaren MrSeg-Verfahrens (Abschnitt 2.2.4) aus. Andere zur Segmentierung nutzbare Methoden wie *k-means* kommen ebenfalls nicht in Frage, da sie mit jedem neuen Prozessierungsdurchlauf ein abweichendes Segmentierungsergebnis produzieren. Dementsprechend wird hier ein morphologisches Segmentierungsverfahren vorgestellt (siehe vereinfachte Abbildung 4.2), das in unüberwachter Weise robuste Resultate erstellt (siehe auch Abschnitt 6.3.3).

In der SAR-Bildverarbeitung ist der Begriff der Segmentierung eng mit der Reduzierung des die Bildqualität einschränkenden Speckle verbunden. Durch die Berechnung der HAR aus den zuvor beschriebenen Eingabebildern  $\hat{A}_{\sigma^0}$  und  $\hat{A}_{\sigma^0,8b}$  wird aufgrund des zeitlichen ML eine für eine Segmentierung gut geeignete Datengrundlage verwendet. Da dennoch ein mehr oder weniger großer Rauschanteil enthalten sein kann und auch um eine Übertragbarkeit auf Zeitreihendaten zu ermöglichen, die aus weniger als der hier verfügbaren Anzahl an Bildern bestehen, wird eine weitere Glättung dieser Eingabebilder durchgeführt.

Diese Glättung erfolgt basierend auf homogenen (zum Beispiel rural) und heterogenen (zum Beispiel urban) Bildinhalten getrennt durch die Anwendung geeigneter Attributwerte für zwei ASF mit dem Attribut *area* (Abschnitt 2.2.1). Auf diese Weise wird sichergestellt, dass alle im Bild enthaltenen, wesentlichen Strukturen bei gleichzeitig optimaler Glättung erhalten bleiben. Die Unterscheidung von homogenen und heterogenen Strukturen erfolgt durch einen Schwellwert, basierend auf der Berechnung eines Cov-Bilds mittels eines  $5 \times 5$  Pixel großen, bewegten Fensters. Die Wahl dieses Schwellwerts erfolgt anhand der Statistik gemittelter Intensitätsbilder (hier:  $\hat{A}_{\sigma^0}$ ) hinsichtlich der Bestimmung des Cov-Quotienten und ist nach [197]:

$$Cov_{ideal,ML,N} = \frac{1}{\sqrt{N}}, \quad (4.3)$$

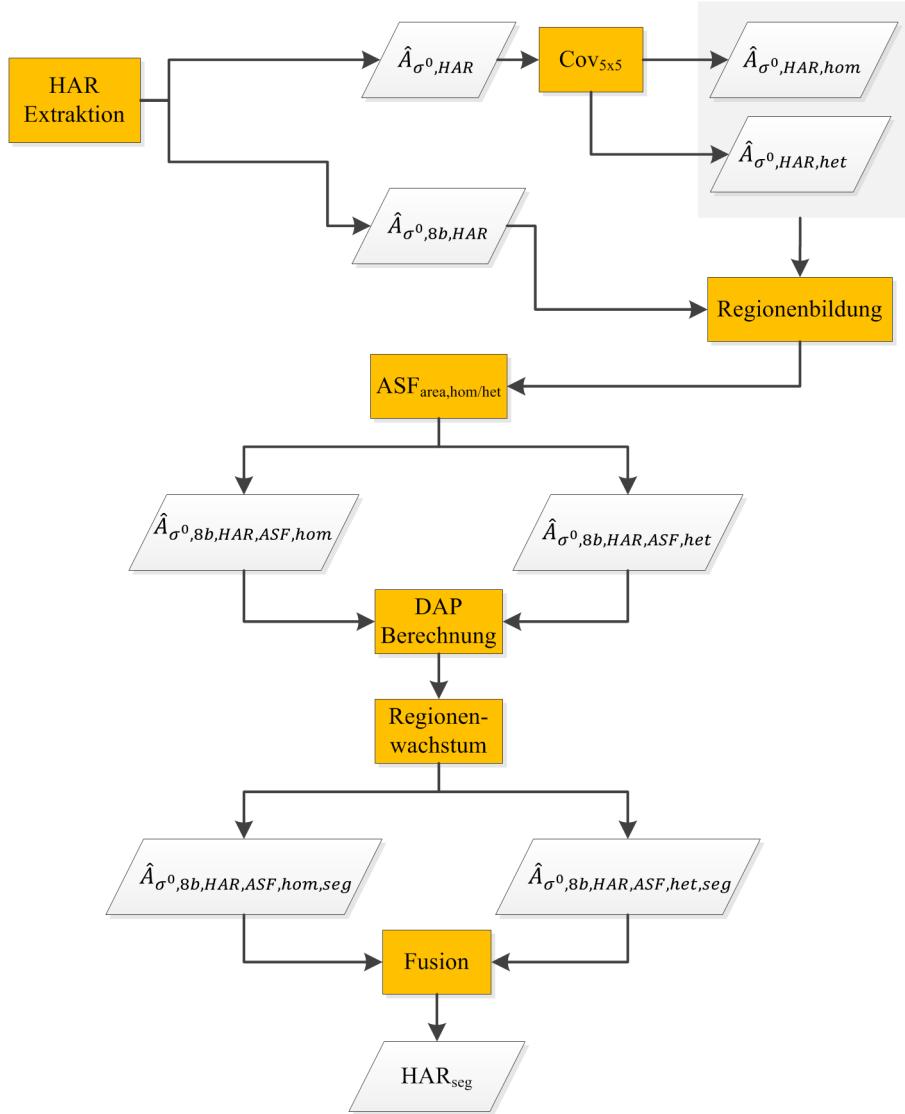


Abbildung 4.2.: Flussdiagramm zur Segmentierung von Hochaktivitätsregionen. Gelbe Rechtecke beinhalten Prozessierungsschritte, Rauten stellen Daten dar.

mit der Anzahl  $N$  an unabhängigen Bildern.

Für eine Zeitreihe bestehend aus 15 Bildern (Datensatz „Stuttgart Flughafen“) ergibt sich somit ein Schwellwert von  $Cov_{ideal, ML, N} = 0,26$ , der dem Cov-Wert für eine ideal homogene Bildregion entspricht. Die sich auf diese Weise ergebenden Bildregionen werden aus dem auf 256 Graustufen skalierten Bild  $\hat{A}_{\sigma^0, 8b, HAR}$  extrahiert und repräsentieren die Eingabebilder ( $\hat{A}_{\sigma^0, 8b, HAR, hom}$ ,  $\hat{A}_{\sigma^0, 8b, HAR, het}$ ) für die daran anschließende Filterung. Für diese Filterung wird eine jeweils geeignete ASF-Konfiguration für homogene und heterogene Bildinhalte mit den Wertesequenzen  $\chi_i^{area, hom} = [25, 50, 100, 200, 500, 1000]$  und  $\chi_i^{area, het} = [5, 10, 20, 40, 80]$  gewählt, wobei sich diese im Rahmen von eingangs vorgenommenen Testläufen als zweckmäßig und zielführend herausgestellt hatten. Die auf diese Weise entstehenden Bilder  $\hat{A}_{\sigma^0, 8b, HAR, ASF, hom}$  und  $\hat{A}_{\sigma^0, 8b, HAR, ASF, het}$  stellen die Basis für die pixelweise Berechnung der DAP dar.

Für die Berechnung der DAP werden die zwei SAR-spezifischen Attribute  $Cov$  und  $\sigma^0$  betrachtet. Als jeweils untere und obere Schranken der Wertesequenzen werden  $\chi_1^{Cov} = 0$  beziehungsweise  $\chi_s^{Cov} = 0,26$  und  $\chi_1^{\sigma^0} = -22$  beziehungsweise  $\chi_s^{\sigma^0} = 10$  angewendet (siehe auch Abschnitt 4.2.5), wobei die  $\sigma^0$ -Werte in Dezibel [dB] skaliert vorliegen. Die Wertebereiche werden in gleichen Abständen aufgeteilt. Letztlich ergeben sich zehndimensionale DAP-Signaturen für jedes Pixel der beiden Eingabebilder, die als Grundlage für die Beurteilung der Homogenität dienen.

Zwei benachbarte Pixel  $a$  und  $b$  sind homogen beziehungsweise zueinander ähnlich, wenn das arithmetische Mittel  $\widehat{d}_{L_2}$  ihrer DAP-Vektoren  $DAP_{Cov, a}$  und  $DAP_{Cov, b}$ , beziehungsweise  $DAP_{\sigma^0, a}$  und  $DAP_{\sigma^0, b}$  kleiner als ein Schwellwert  $\tau$  ist:

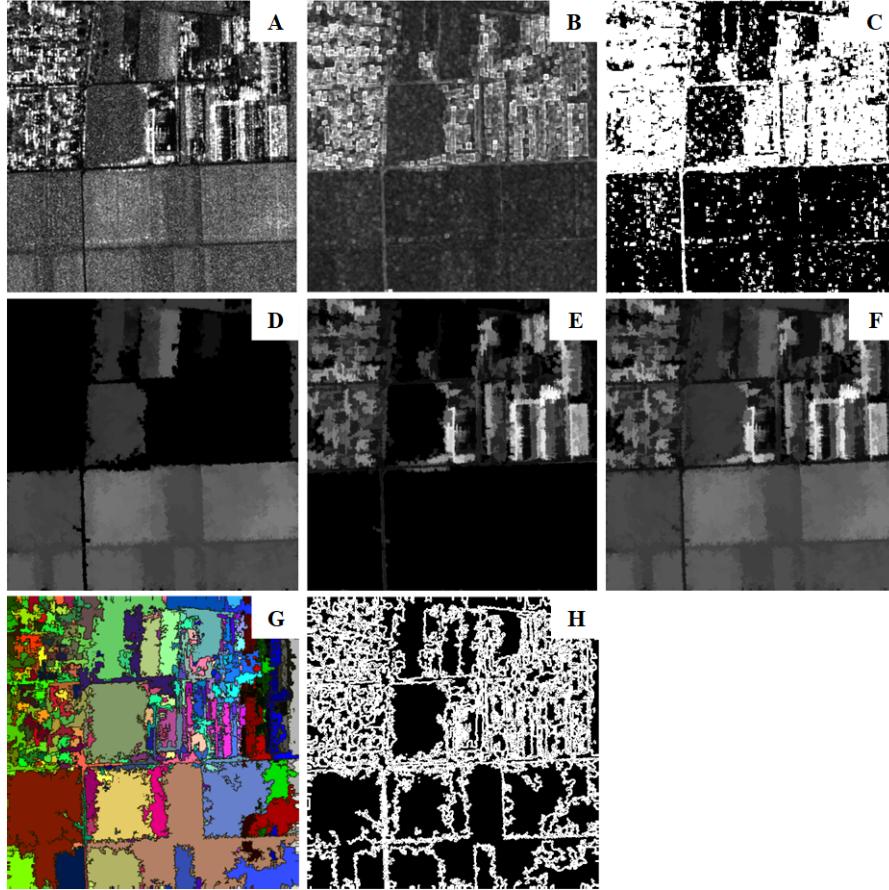


Abbildung 4.3.: Bildliche Darstellung des Ablaufs zur Segmentierung von Hochaktivitätsregionen. A: Auf 256 Grauwerte skaliertes, kalibriertes Amplitudenbild; B: Cov-Bild; C: Anwendung des Werts für ideal homogene Gebiete; D: ASF-gefilterte, homogene Bereiche; E: ASF-gefilterte, heterogene Bereiche; F: Fusionsbild; G: Farbkodiertes Segmentierungsresultat, H: Segmentgrenzen.

$$d_{L_2,Cov} = \left[ \sqrt{\left( \sum_{i=1}^n |DAP_{Cov,a,i} - DAP_{Cov,b,i}|^2 \right)} \right], \quad (4.4)$$

$$d_{L_2,\sigma^0} = \left[ \sqrt{\left( \sum_{i=1}^n |DAP_{\sigma^0,a,i} - DAP_{\sigma^0,b,i}|^2 \right)} \right], \quad (4.5)$$

$$\widehat{d_{L_2}} = \frac{d_{L_2,Cov} + d_{L_2,\sigma^0}}{2}, \quad (4.6)$$

mit dem Laufindex  $i$  und der Dimension  $n$  des DAP-Vektors. Der Schwellwert  $\tau$  wird eingangs anhand eines detektierten homogenen Bildbereichs auf unüberwachte Weise durch Beurteilung der dort existierenden (Euclidischen) DAP-Distanzen bestimmt.

Die Segmentierung erfolgt mittels Regionenwachstum und beginnt mit einem zufällig gewählten Bildelement. In der lokalen (8er-)Nachbarschaft dieses Pixels wird sukzessive hinsichtlich Homogenität geprüft und ähnliche Pixel werden so lange zu einem Segment zusammengefasst, bis der Schwellwert  $\tau$  überschritten wird. In diesem Fall wird ein neues Startpixel gewählt und die Segmentierung beginnt von Neuem. Ein Segmentierungsergebnis liegt vor, wenn alle Bildelemente einem Segment eindeutig zugewiesen sind. Die final segmentierte Variante des Eingabeausschnitts  $\widehat{A}_{\sigma^0,8b,HAR}$  ergibt sich aus der Fusion der beiden Segmentierungsresultate  $\widehat{A}_{\sigma^0,8b,HAR,ASF,hom,seg}$  und  $\widehat{A}_{\sigma^0,8b,HAR,ASF,het,seg}$  zu einem Gesamtbild  $HAR_{seg}$  (Abbildung 4.2).

Abbildung 4.3 enthält die Darstellung der maßgeblichen Zwischen- und Endresultate der vorgestellten Segmentierungsmethode, basierend auf einem Bildausschnitt, der sowohl homogene (rurale) als auch heterogene (urbane) Strukturen enthält.

Nr.	Kontextklasse („Stuttgart Flughafen“)	Nr.	OSM-Layer
1	Volumenstreuer (Wald etc.)	1	Eisenbahnen, Schienenwege
2	Urban	2	Landnutzung (Landwirtschaft etc.)
3	Rural (landwirtsch. genutzt)	3	Natürlich (Landschaftselemente, Vegetation)
4	Rural (sonstige)	4	Gebäude
5	Flughafenvorfeld (Infrastruktur)	5	Verkehrsnetz
6	Flughafen Gates		
7	Flughafenvorfeld (Park, Be- und Entladeplätze)		
8	Infrastruktur (Straßen, Wege, etc.)		
9	unklassifiziert		
Nr.	Kontextklasse („Greding“)		
1	Volumenstreuer (Wald etc.)		
2	Urban		
3	Rural (landwirtsch. genutzt)		
4	Rural (sonstige)		
5	Infrastruktur (Straßen, Wege, etc.)		
6	unklassifiziert		

Abbildung 4.4.: Kontextklassen (linke Seite) und OSM-Layer (rechte Seite). Links oben: Datensatz „Stuttgart Flughafen“, links unten: Datensatz „Greding“.

### Zuweisung der Kontextklasse:

Die Identifikation des zu einem Hochaktivitätsobjekt gehörigen Segments erfolgt durch Überlagerung des HAO mit dem Segmentierungsresultat. Da mehrere Segmente ein spezifisches HAO überlappen können, wird jenes Segment extrahiert, das den größten räumlichen Anteil am HAO besitzt. Für dieses zu einem HAO zugeordnete Segment werden die in Abschnitt 4.2.3 beschriebenen Formparameter berechnet und zur Analyse der abschließenden Klassenbeschreibung genutzt (siehe Abschnitt 6.2.6).

Als Grundlage für die Zuweisung einer Kontextklasse wird das jeweilige HAO selbst, beziehungsweise seine Nachbarschaft anhand von verfügbaren Referenzdaten beurteilt. Diese werden, soweit für die auszuwertende Szene erhältlich, durch OSM-Vektordaten dargestellt. Obwohl sie den Vorteil besitzen, frei, kostenlos und für jedermann zugänglich zu sein, spiegeln OSM-Daten mitunter das individuelle Engagement der sie erstellenden Person wider. Im Vergleich zu amtlichen Kartierungen, deren Durchführung im Regelfall auch vollständig erfolgt, entstehen OSM-Layer zumeist nicht in strukturiert organisierter Art und Weise. Amtliche Kartierungen, die auch als Grundlage für die OSM-Datenerstellung dienen können, besitzen allerdings den Nachteil der nicht immer gegebenen Aktualität.

Um diese Unsicherheit abzuschwächen, wird zur Unterstützung eine LULC-Kartierung verwendet, die das Resultat einer überwachten Klassifikation mittels CovAmCoh-Bildmaterial darstellt. Da sie nur in Regionen zum Einsatz kommt, in denen die Abdeckung durch OSM lückenhaft bis unzureichend ist, nimmt sie bei der Zuweisung der Kontextklasse lediglich eine ergänzende Rolle ein. Der Vorzug bei der Auswertung von CovAmCoh-Bildern (siehe auch Abschnitt 2.1) liegt in der Möglichkeit, verschiedene LULC-Klassen visuell unmittelbar anhand eines Regelwerks ([113] und [112]) zu identifizieren. Ein detailliertes Fachwissen von Nutzerseite ist nicht zwingend notwendig.

Die hier zum Einsatz kommenden Kontextklassen sind in Abbildung 4.4 inklusive der verfügbaren OSM-Layer aufgelistet. Im Vergleich zum Testdatensatz „Greding“ weist der primär verwendete Datensatz „Stuttgart Flughafen“ ergänzende, den Flughafenbereich charakterisierende Klassen auf. Im Anhang A befinden sich entsprechende Bildausschnitte, die die einzelnen Kontextklassen darstellen (Abbildung A.1). Die Unterscheidung der beiden Klassen mit den Nummern drei und vier (*Rural (landwirtsch. genutzt)* und *Rural (sonstige)*) erfolgt anhand einer Kohärenzanalyse entlang der Zeitreihe in diesen Gebieten. In [93] ist dargelegt, dass eine rural temporär instabile Kohärenz Hinweise auf landwirtschaftliche Nutzung liefert. Dieser Umstand wird im Zuge der LULC-Kartierung berücksichtigt.

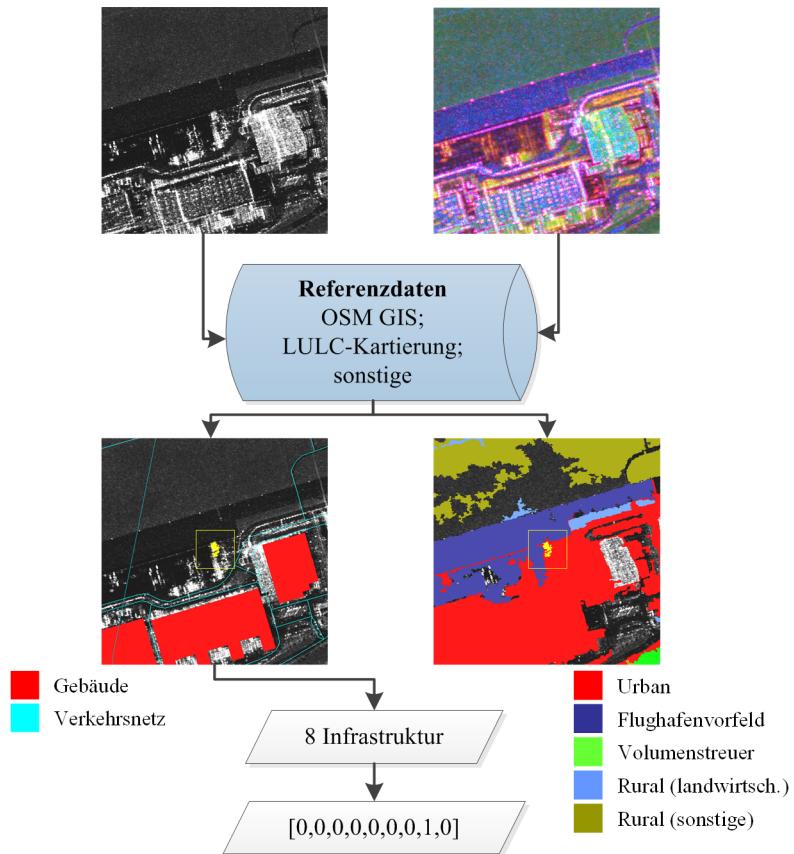


Abbildung 4.5.: Zuweisung der Kontextklasse *Infrastruktur*.

Der Ablauf zur Zuweisung eines HAO zu einer Kontextklasse ist in Abbildung 4.5 dargestellt und startet mit der Erstellung der jeweiligen Bildausschnitte aus dem mittleren kalibrierten und skalierten Amplitudenbild (siehe oben), sowie dem mittleren *CovAmCoh*-Bild der Zeitreihe (obere Reihe der Abbildung 4.5). Im nächsten Schritt wird mittels der zur Verfügung stehenden GIS-Layer geprüft, ob in der Nachbarschaft des HAO (gelbe Markierung) entsprechende Vektordaten vorhanden sind. Diese lokale Nachbarschaft wird iterativ bis zu einer Maximalfläche von  $50 \times 50$  Pixel ( $2500 m^2$ ) erweitert. Liegen in dieser erweiterten lokalen Nachbarschaft keine der in Abbildung 4.4 gelisteten GIS-Layer vor, wird die auf dem mittleren *CovAmCoh*-Bild der Zeitreihe basierende LULC-Kartierung herangezogen. Liefert auch diese Informationsebene keine extrahierbare Kontextklasse, wird das HAO der Klasse *unklassifiziert* zugeordnet. In dem hier dargestellten Beispiel wird das HAO der Kontextklasse *Infrastruktur* zugewiesen, da in unmittelbarer Nachbarschaft der OSM-Layer *Verkehrsnetz* vorliegt (Abbildung 4.5, cyan).

Dieser Zuweisungsprozess wird für jedes HAO durchgeführt, woraus für jedes  $HAO_i$  ein binärer Kontextklassenvektor  $v_{HAO_i, KK}$  resultiert, dessen neun („Stuttgart Flughafen“) Elemente die Werte Null und Eins annehmen können. Für den Gredinger Datensatz liegen sechs Elemente vor (siehe auch Abbildung 4.4).

#### Räumliche Ausdehnung und Begrenztheit:

Eine weitere genutzte Komponente zur Beurteilung des räumlichen Kontextes ist durch die Zugehörigkeit beziehungsweise Nichtzugehörigkeit eines HAO zu einer begrenzten oder ausgedehnten Nachbarschaft gegeben. Eine begrenzte Nachbarschaft liegt vor, wenn ein bestimmtes HAO in einer vorgegebenen Nachbarschaft (hier:  $25 \times 25$  Pixel) ohne weitere, entferntere Hochaktivitätsobjekte enthalten ist. Wird an dieser bestimmten, durch das HAO definierten Örtlichkeit die zeitliche Komponente berücksichtigt, so können die dort vorhandenen HAO zu einem Hochaktivitätsstapel kombiniert werden (siehe Abschnitt 3.2.3). Die einzelnen zu einem solchen Stapel gehörenden HAO sind somit ebenfalls räumlich begrenzt.

Anhand der Berücksichtigung der räumlich begrenzten beziehungsweise ausgedehnten Nachbarschaft der Änderungsobjekte wird versucht, zusätzliche Informationen abzuleiten, die zur Unterscheidung zum Beispiel eines Parkplatzes (Annahme: örtlich ausgedehnt) von einer Be- und Entladestelle (Annahme: örtlich begrenzt) beitragen. In Abbildung 4.6 ist ein Beispiel für ein räumlich begrenztes (obere Zeile), sowie ein räumlich ausgedehntes HAO (untere Zeile) dargestellt. Die in den Ausschnitten enthaltene cyan-farbene Umrandung entspricht der vordefinierten Nachbarschaft eines HAO.

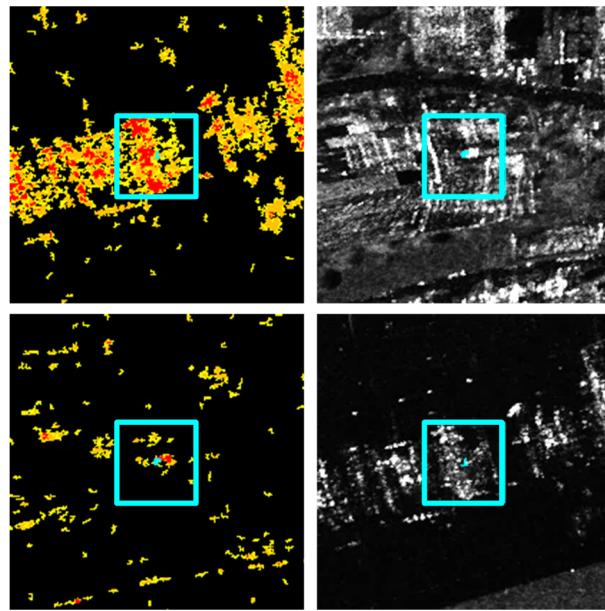


Abbildung 4.6.: Räumliche Ausdehnung und Begrenztheit. Obere Zeile: Örtlich ausgedehntes HAO (mittleres, cyan-farbenes Segment) in Aktivitätskarte (links) und Amplitude (rechts). Untere Zeile: Örtlich begrenztes HAO in Aktivitätskarte und Amplitude.

Der Wertebereich zur Feststellung der räumlichen Ausdehnung umfasst die beiden Werte Null und Eins, wobei eine Eins bedeutet, dass ein HAO zu einer ausgedehnten Nachbarschaft gehört. Eine Null steht entsprechend für die Zugehörigkeit zu einer räumlich begrenzten Nachbarschaft.

Das Kontextmerkmal in seinen verschiedenen Ausprägungen (Kontextklasse, räumliche Ausdehnung und Begrenztheit, Formparameter) kommt bei der Beschreibung der final resultierenden Ergebnisse zum Einsatz und dient zur Unterstützung des Nutzers. Da zur Kategorisierung und Klassifikation der HAO keinerlei Referenzdaten notwendig sind, sind diese Verarbeitungsschritte demzufolge auch unabhängig von der Bestimmung des Kontextmerkmals.

Neben dem oben erläuterten binär vorliegenden Kontextmerkmal kommen weitere Merkmale zum Einsatz, deren Wertebereiche kontinuierlich sind. Eines davon ist die Kohärenz, die als statistisches Maß die Güte der interferometrischen Phase eines Bildpaars misst.

#### 4.2.2. Kohärenz

Da im Umfang der hier bearbeiteten Aufgabenstellung Zeitreihen aus TSX SLC-Bildern verfügbar sind (siehe Abschnitte 6.1.1 beziehungsweise 6.1.2), die weiterhin den herkömmlichen Regelfall bei der Datenlieferung einnehmen (Abschnitt 2.1), wird neben der alleinigen Nutzung amplitudenbasierter Merkmale die Kohärenz als ein dazu komplementäres Merkmal betrachtet. Im weiteren Verlauf der Arbeit (Abschnitt 6.2.3) wird anhand der Testdaten der Einfluß der einzelnen Merkmale auf eine spätere Kategorisierung der HAO überprüft. Die Berechnung der Kohärenz setzt die Existenz eines interferometrischen SAR-Bildpaars voraus und damit auch die Existenz der zu beiden Aufnahmezeitpunkten beobachteten Phaseninformation (siehe Abschnitt 2.1). Mit Formel (2.16) erfolgt ferner die Berechnung eines Kohärenzbilds, das unter anderem eine Unterscheidung zeitlich stabiler und instabiler Bildstrukturen durch entsprechend codierte Grauwerte ermöglicht.

In Abbildung 4.7 ist exemplarisch ein Ausschnitt eines Bildpaars (zeitliche Basislinie: 11 Tage) der Testszen „Stuttgart Flughafen“ inklusive Kohärenzbild dargestellt. Es ist ersichtlich, dass urbane Strukturen (1) im Vergleich zu Vegetation oder ruralen Oberflächen höhere Kohärenzwerte durch ihre stabile Rückstreucharakteristik aufweisen. Für abgerntete Felder kann dieser Effekt ebenfalls beobachtet werden, da diese (rauen) Oberflächen vergleichbare Eigenschaften in Bezug auf die Rückstreuung des Radarsignals besitzen können (2). In einem aus den beiden SAR-Aufnahmen bestimmten CovAmCoh-Bild können kohärente und inkohärente Bereiche in einfacher Weise unterschieden werden. Jede Region mit blauer Färbung (Abbildung 4.7, D) liefert indirekt Hinweise auf zeitlich stabile Oberflächenstrukturen. In F ist das für das in C visualisierte Kohärenzbild resultierende Histogramm dargestellt, das den kontinuierlichen Wertebereich im Intervall [0; 1] aufzeigt.

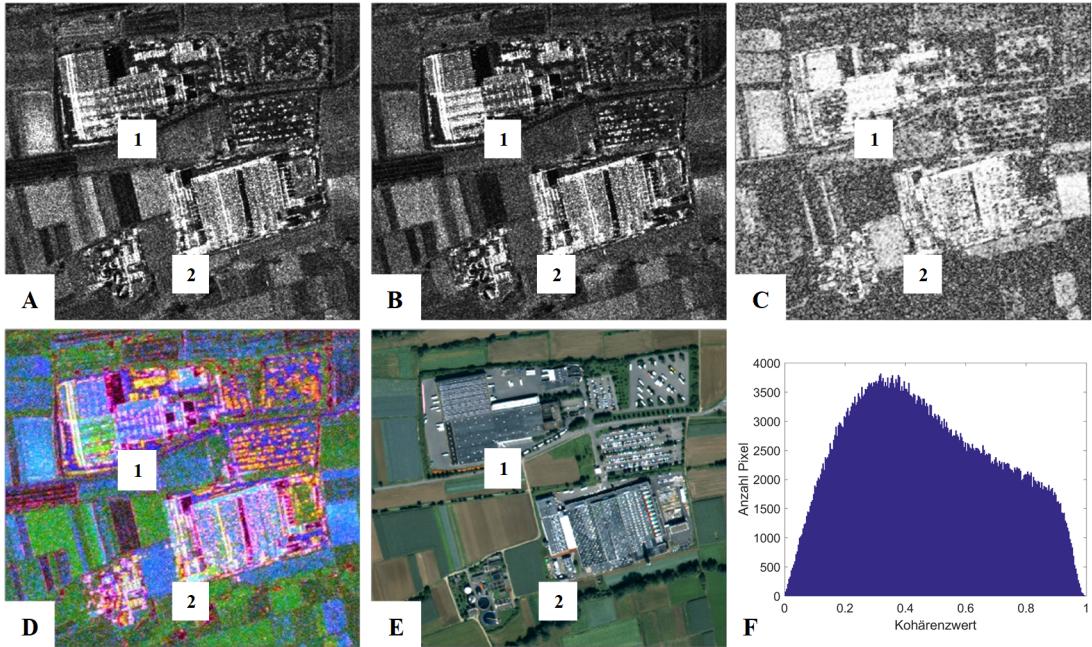


Abbildung 4.7.: Interferometrische Kohärenz. A und B: Amplitudenbildpaar, C: Kohärenzbild, D: CovAmCoh, E: WV-2-Ausschnitt, F: Histogramm von C, 1: Urbane Strukturen, 2: Hochkohärente Feldstruktur.

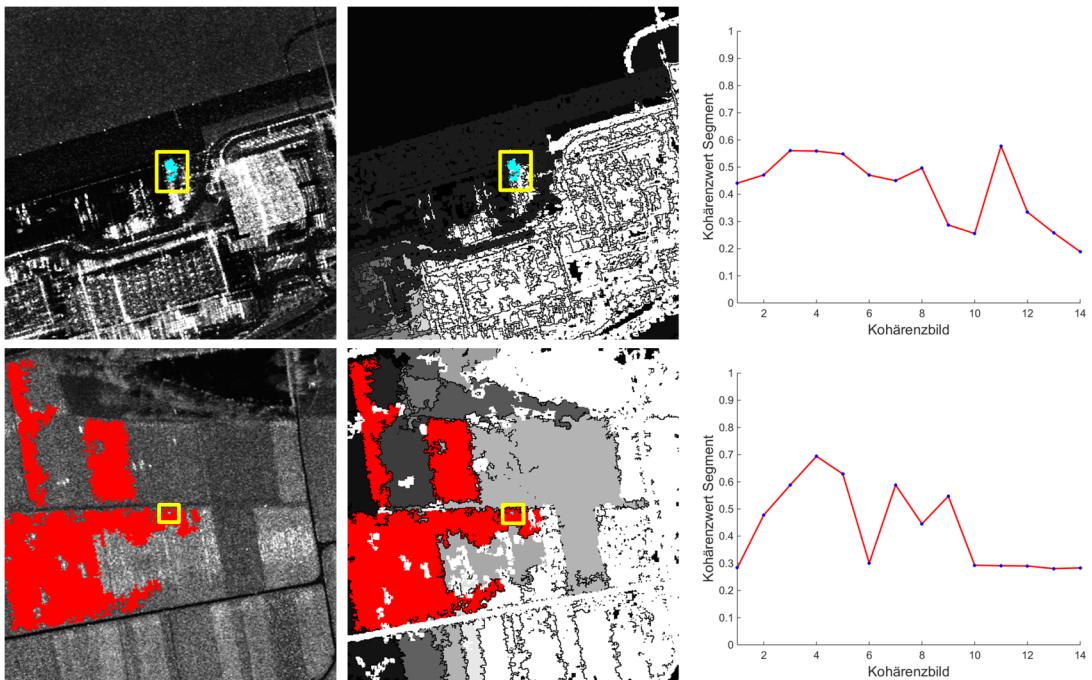


Abbildung 4.8.: Ableitung des Kohärenzmerkmals. Obere Zeile: Urbane Nachbarschaft, untere Zeile: Rurale Nachbarschaft. Linke Spalte: HAO (cyan eingefärbt und gelb umrandet) und umgebendes Segment (rot) in mittlerem Amplitudenbild, mittlere Spalte: HAO in skaliertem Segmentierungsresultat, rechte Spalte: Abgeleitete Kohärenzsingatur.

Unter die Kategorie zeitlich instabiler Strukturen fallen auch Bildbereiche, die aufgrund von durch den Menschen verursachten Veränderungen einen niedrigen Kohärenzwert aufweisen. Im Umkehrschluss bedeutet dies, dass Änderungsobjekte wie die in dieser Arbeit betrachteten HAO, beziehungsweise die von ihnen abgedeckten Bildbereiche zum Zeitpunkt ihres Auftretens oder Verschwindens als generell inkohärent betrachtet werden können. Daher sind die in dem durch ein HAO definierten Bereich berechneten Kohärenzwerte für eine Unterscheidung verschiedener Änderungskategorien nicht zielführend. Aus diesem Grund werden Kohärenzwerte basierend auf dem Segment, welches das jeweilige HAO umschließt, beziehungsweise flächenmäßig mit dem größten Anteil wiedergibt, verwendet. Als Bestimmungsgrundlage dient hierfür das Resultat aus der Segmentierung der lokalen Änderungsnachbarschaft (vergleiche auch Abschnitt 4.2.1).

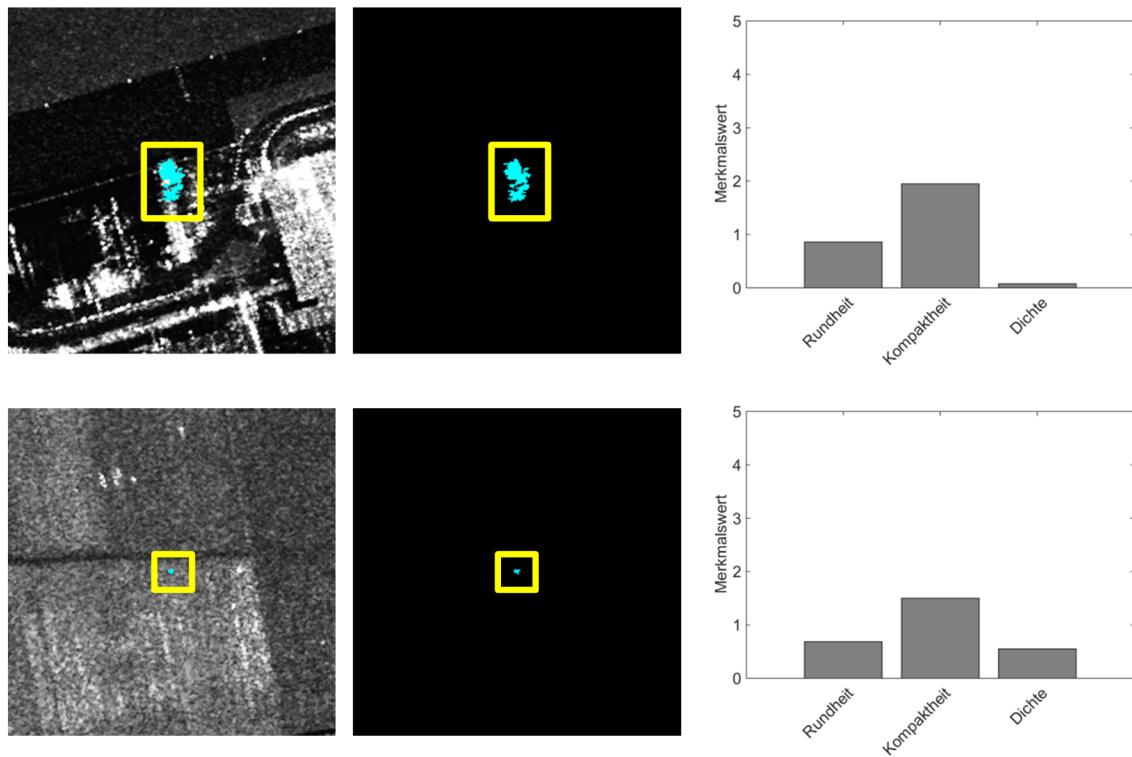


Abbildung 4.9.: Ableitung des Formmerkmals. Obere Zeile: HAO (cyan-farben markiert, gelbe Umrandung) in urbaner Nachbarschaft, untere Zeile: HAO (cyan-farben markiert, gelbe Umrandung) in ruraler Nachbarschaft. Linke Spalte: HAO in mittlerer Amplitude, mittlere Spalte: HAO als farbiger Vordergrund in Binärbild, rechte Spalte: Formmerkmale und Werte.

Die in diesem Bereich berechneten, mittleren Kohärenzwerte werden aus den *CovAmCoh*-Bildern der Zeitreihe extrahiert. Besteht eine Zeitreihe aus  $n$  SLC-Aufnahmen, resultieren folglich  $n - 1$  interferometrische, zeitlich aufeinander folgende Bildpaare. Das Kohärenzmerkmal setzt sich demzufolge aus einer auf ein HAO bezogenen Signatur  $v_{HAO_i, Koh}$  aus  $n - 1$  Werten zusammen, deren Elemente Werte im Intervall von  $[0; 1]$  annehmen. Die Signatur stellt somit den zeitlichen Verlauf der Kohärenz in dem jeweils an dem HAO beteiligten Segment dar. In Abbildung 4.8 sind hierzu zwei Beispiele dargestellt. Die obere Zeile enthält ein in einem urbanen Bereich detektiertes HAO, die untere Zeile enthält ein in einer ruralen Örtlichkeit vorliegendes HAO (jeweils cyan-farben markiert). In roter Farbe ist das jeweilig zugehörige, umgebende Segment visualisiert, welches im Beispiel der urbanen Nachbarschaft so fein beziehungsweise klein ist, dass es von dem dort existierenden HAO weitestgehend verdeckt wird. Dieser Effekt ist auf die unterschiedliche Segmentierung homogener und heterogener Bildbereiche zurückzuführen (Abschnitt 4.2.1), die tendenziell zur Detektion feinerer Bildobjekte in urbanen Gebieten führt. In der rechten Spalte der Abbildung sind die abgeleiteten Kohärenzsignaturen dargestellt, die aufgrund der unterschiedlichen Örtlichkeit beziehungsweise Segmentierung eine voneinander verschiedene Struktur aufweisen, welche zur Unterscheidung verschiedener HAO-Kategorien genutzt werden kann.

Neben dem sich auf die Phase des Radarsignals beziehenden Kohärenzmerkmal existieren weitere, komplementär einsetzbare Eigenschaften zur Charakterisierung der Hochaktivitätsobjekte. Eine Komponente davon sind die formbeschreibenden Merkmale.

#### 4.2.3. Form

In Abschnitt 2.2.4 wurde bereits der Mehrwert beschrieben, der durch die OBIA im Vergleich zu klassischen pixelbasierten Ansätzen entsteht. Weiterhin wurden vier formbeschreibende Merkmale vorgestellt (Formeln (2.47) bis (2.50)), deren Berechnungsvorschriften unmittelbar auf die verfügbaren Hochaktivitätsobjekte angewendet werden können.

Das Merkmal Segmentgröße ( $S_{area}$ ) wird im Zuge der morphologischen Analyse (Abschnitt 4.2.5) eingesetzt, weshalb an dieser Stelle der Verarbeitung darauf verzichtet wird.

Daraus folgt, dass je HAO ein Vektor  $v_{HAO_i, Form} \in [0; 1]^3$  berechnet wird. Bezuglich des Wertebereichs  $[0; 1]$  ist zu erwähnen, dass die bestimmten Werte nicht ursprünglich in diesem Intervall vorliegen. In Anbetracht

der späteren Anwendung eines *Clustering*-Verfahrens zur Kategorienbildung ist eine Skalierung auf ein einheitliches Wertebereich notwendig (siehe auch Abschnitt 6.2.3).

Abbildung 4.9 enthält exemplarisch die beiden im vorherigen Abschnitt gezeigten HAO und die extrahierten formbeschreibenden Merkmalswerte. Auffällig ist, dass sich die beiden HAO einzig im Merkmal Dichte ( $S_{dens}$ ) voneinander abgrenzen scheinen. Dies ist dadurch begründet, dass die Dichte im Vergleich zu den anderen beiden Merkmalen eine komplementäre Eigenschaft zur Formbeschreibung darstellt.

Rundheit und Kompaktheit bezeichnen Maße, die den Grad der Übereinstimmung mit vorgegebenen Formen wie Ellipse oder Rechteck widerspiegeln. Das Dichtemerkmalswert stellt keinen Übereinstimmungsgrad mit einer vorgegebenen Referenzfläche dar, sondern ist als ein abstraktes Maß anzusehen, das die Form einer dem jeweiligen Segment (hier: HAO) optimal angepassten Ellipse auswertet (Formeln (2.50) und (2.51)). Das hat zur Folge, dass HAO mit ähnlichem Kompaktheitsgrad voneinander unterschiedliche Dichtegrade aufweisen (Abbildung 4.9) und somit durch dieses Merkmal voneinander differenzierbar sind.

#### 4.2.4. Textur

Im Gegensatz zu den formbezogenen Merkmalen kann mit der Textur die lokale Umgebung eines HAO mit statistischen Mitteln ausgewertet werden. Dies erfolgt hier anhand der Grauwertmatrix (GLCM).

Zur Berechnung der GLCM-basierenden Haralick-Parameter (siehe auch Abschnitt 2.2.3) ist neben bereits erwähnten Parametern wie Pixelgröße und Orientierung ein weiterer Aspekt zu berücksichtigen. Da die Eingabebilder oftmals über Grauwerte verfügen, die sich über sehr große Wertebereiche  $w$  erstrecken (exemplarisch: TSX beziehungsweise TDX SAR-Amplitude:  $w_A = [0; 2^{16} - 1]$ ), wird aus Gründen der Berechnungsdauer und zur Rauschverminderung [198] eine Quantisierung dieser Bereiche auf eine geringere Anzahl an *Bins* durchgeführt. Da die Skalierung mittels der Tangens-Hyperbolus-Funktion (Formel (2.14)) eine wirkungsvolle und verlustfreie Methode zur Quantisierung von SAR-Amplituden- oder Intensitätsbildern darstellt, wird sie an dieser Stelle zur Reduzierung des Grauwertebereichs auf  $2^8$  *Bins* eingesetzt. Als Grundlage für die Skalierung dienen hier die radiometrisch  $\sigma^0$ -kalibrierten Amplitudensbilder der Zeitreihe  $I_{norm,tanh,t_i}$  (Notation in Anlehnung an Abschnitt 2.1).

Die Bestimmung der in Abschnitt 2.2.3 beschriebenen Parameter erfolgt auf Basis der zuvor detektierten HAO, wobei stets jenes Bild der Zeitreihe betrachtet wird, in der das HAO enthalten ist. Auf diese Weise wird sichergestellt, dass die abgeleiteten Texturwerte direkten Bezug zu den später zu kategorisierenden Hochaktivitätsobjekten besitzen. Die Detektion der passenden Bildkomponenten der Zeitreihe erfolgt durch Betrachtung der Rückstreuintensitäten in dem durch das jeweilige HAO definierten Bildbereich. Wurde beispielsweise ein HAO als abrupte Änderung zwischen den Bildern  $I_{norm,tanh,t_1}$  und  $I_{norm,tanh,t_2}$  erkannt, so wird geprüft, ob die mittlere Rückstreuintensität in  $t_1$  größer ist als in  $t_2$  oder umgekehrt. Ist beispielsweise dieser Wert in  $t_1$  größer als in  $t_2$ , so ist  $I_{norm,tanh,t_1}$  das passende Eingabebild für die Berechnung der Texturparameter.

In Abbildung 4.10 ist hierzu ein Beispiel anhand zweier unterschiedlicher HAO dargestellt. Der gelb umrandete Bereich symbolisiert den Ausschnitt, der für die Berechnung der GLCM verwendet wird. In beiden Fällen (HAO 1 und HAO 2) ist das erste Bild des Paares das für die Ableitung der Texturwerte verwendete Eingabebild. Mit Blick auf die in diesem Beispiel ermittelten Texturwerte kann festgestellt werden, dass sich diese mehr oder weniger stark voneinander unterscheiden, was für eine Einteilung der HAO in unterschiedliche Kategorien genutzt werden kann. Die letzliche Eignung der Texturparameter im Zusammenhang mit der Kategorisierung wird in Abschnitt 6.2.3 anhand des vorliegenden Testdatensatzes „Stuttgart Flughafen“ mittels Untersuchung der aus der PCA abgeleiteten *Loadings* bewertet.

Abschließend kann festgehalten werden, dass je HAO ein Vektor  $v_{HAO_i,Text}$  der Dimension 5 (Kontrast, Heterogenität, Energie, Korrelation und Entropie) berechnet wird. Da die einzelnen Werte nicht in einem einheitlichen Bereich sowohl untereinander als auch im Vergleich zu den weiteren, zum Einsatz kommenden kontinuierlichen Merkmalen liegen, wird eine Skalierung auf das Intervall  $[0; 1]$  vorgenommen (siehe Abschnitt 6.2.3).

Eine solche Skalierung ist für die Gruppe der morphologischen Merkmale nicht notwendig, da diese bereits bei der Berechnung einheitlich normiert werden. Der nachfolgende Abschnitt enthält die dazu entsprechenden Ausführungen.

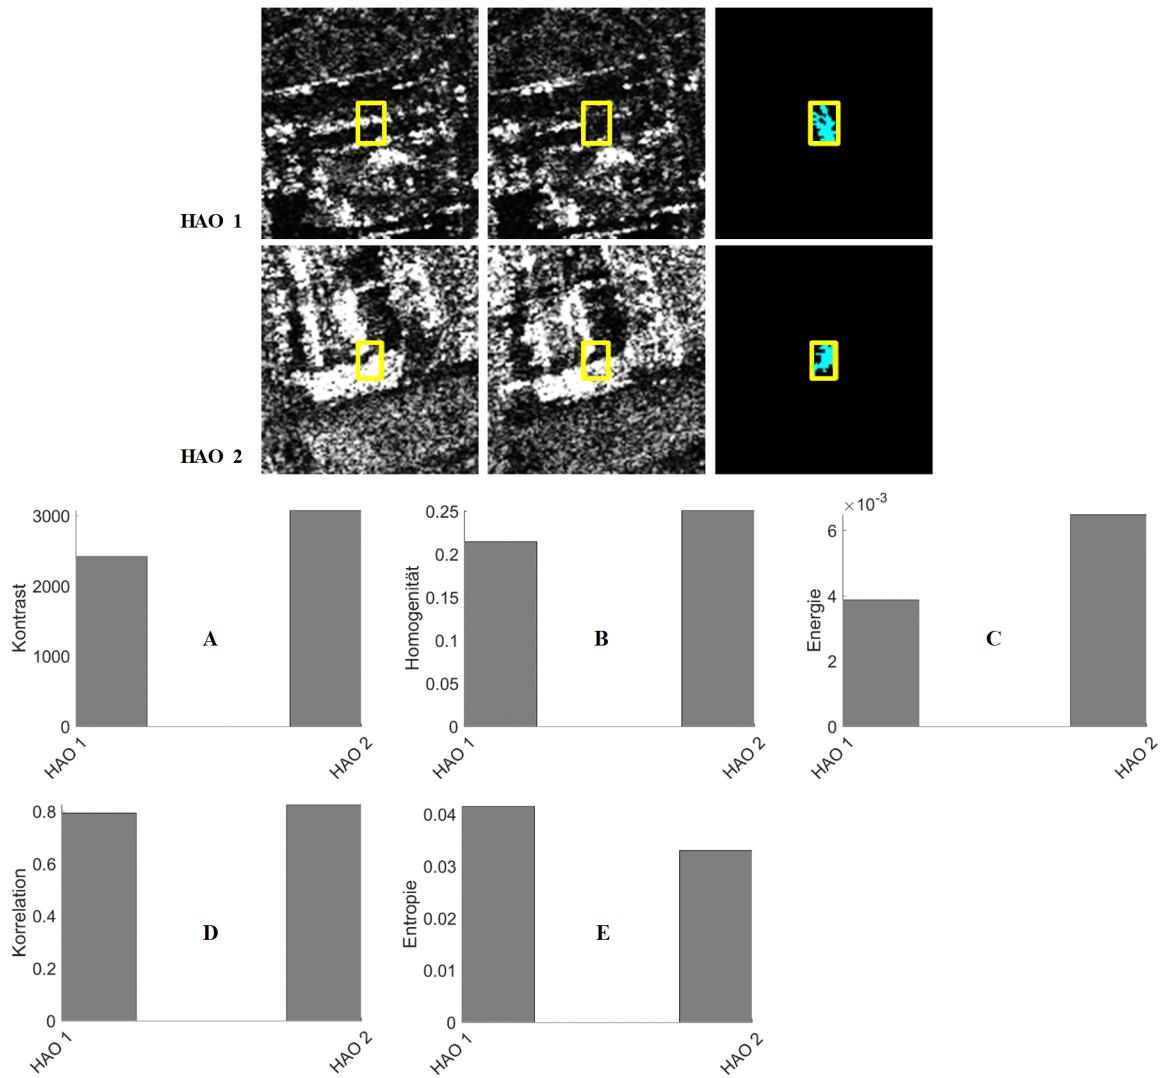


Abbildung 4.10.: Ableitung der Texturmerkmale. Oben, von links nach rechts: HAO-Bereich (gelbe Umrandung) in  $t_1$ , HAO-Bereich (gelbe Umrandung) in  $t_2$ , cyan-farbene HAO. Der durch die gelbe Umrandung gekennzeichnete Bereich stellt den für die GLCM-Berechnung genutzten Ausschnitt dar. Unten, von A bis E: Für beide HAO berechnete Merkmale Kontrast, Homogenität, Energie, Korrelation und Entropie.

#### 4.2.5. Morphologie

Das Konzept der differentiellen Attributprofile (DAP) (siehe auch Abschnitt 2.2.1) wird genutzt, um für jedes detektierte HAO eine charakteristische morphologische Signatur abzuleiten. In [199] konnte bereits gezeigt werden, dass diese Signaturen zur Differenzierung unterschiedlicher Änderungstypen verwendet werden können. Die Berechnung der Attributprofile besitzt gegenüber der klassischen morphologischen Bildverarbeitung den Vorteil, dass der Informationsgehalt des Eingabebilds in flexibler Weise vollständig ausgewertet werden kann (Abschnitt 2.2.1). Dieser Umstand ist dadurch begründet, dass sehr viele unterschiedliche und komplementäre Attribute (radiometrische, statistische, formbeschreibende) zum Einsatz kommen können. Die Verarbeitung erfolgt basierend auf den im Bild enthaltenen zusammenhängenden Komponenten (CC), die in Anbetracht des genutzten Attributs und der Wertesequenz entweder erhalten bleiben oder gelöscht werden. Für jedes einzelne Pixel kann schließlich eine DAP-Signatur ermittelt werden, die Aufschluss darüber gibt, ob dieses Pixel Teil einer erhaltenen oder gelöschten Bildstruktur ist beziehungsweise war (siehe auch Abschnitt 2.2.1). Mit Bezug zur objektorientierten Analyse der HAO bedeutet dies, dass die zu einem HAO gehörenden Pixel sowie deren DAP-Signaturen für ein spezifisches Attribut extrahiert werden. Eine das HAO beschreibende Signatur resultiert schließlich durch Mittelung der zuvor auf das Intervall  $[0; 1]$  normierten Werte der das Änderungsobjekt definierenden HAP.

Nachfolgend werden die eingesetzten Attribute erläutert und anhand eines Bildbeispiels die DAP-Signaturen zweier verschiedener HAO dargestellt.

Das wohl am leichtesten zugängliche Attribut ist das der Fläche beziehungsweise Größe einer CC. Es dient in dieser Arbeit zur Veranschaulichung bei der Herleitung des DAP-Konzepts in Abschnitt 2.2.1, weshalb auf eine erneute Beschreibung an dieser Stelle verzichtet wird. Die verwendete Wertesequenz  $\chi_i^{area}$  setzt sich aus fünf Komponenten zusammen, die entsprechend der im Zuge der abrupten Änderungsdetektion getroffenen Einstellungen hinsichtlich der Zielobjektgröße (siehe Abschnitt 3.1) gewählt sind. Das Intervall aus minimaler (acht Pixel) und maximaler HAO-Größe (400 Pixel) wird in fünf Werte mit jeweils gleich großem Abstand in vier Subintervalle eingeteilt, woraus sich die Sequenz zu  $\chi_i^{area} = [8; 106; 204; 302; 400]$  ergibt. Der letztlich in die spätere Kategorisierung eingehende DAP-Vektor ist daher zehndimensional.

Unter Verwendung des Attributs *diag* wird die Länge der Diagonale des Rechtecks *BB* beurteilt, das die jeweilige CC minimal approximiert. Auf diese Weise können HAO voneinander abgegrenzt werden, die zwar eine ähnliche Fläche aber eine unterschiedlich ausgedehnte Form (linienförmig oder eher quadratisch) aufweisen. Analog zum Flächenattribut wird eine Wertesequenz  $\chi_i^{diag}$  erstellt, die sich aus fünf Werten zusammensetzt. Diese Werte sind im Einzelnen  $\chi_i^{diag} = [5; 28; 75; 52; 5; 76; 25; 100]$ , die wie folgt ermittelt wurden.

Die maximale HAO-Fläche von 400 Pixel (siehe oben) kann anhand eines umgebenden Vierecks in verschiedener Weise dargestellt werden. Liegt eine quadratische Form mit einer Kantenlänge von 20 Pixel vor, so ergibt sich für die Diagonale eine Länge von ungefähr 28 Pixel. Wird die Form dieses Vierecks ausgedehnt, vergrößert sich die Länge der Diagonalen. Wird beispielsweise ein sehr ausgedehntes Viereck mit Kantenlängen von 133 und 3 Pixeln angenommen, so resultiert eine Diagonale mit Länge 133 (Pixel). Da dieser Extremfall eher theoretischer Natur ist, wird als maximale Diagonalenlänge ein Wert von 100 Pixel eingestellt. Auf der anderen Seite, die die minimal vorliegende HAO-Größe kennzeichnet (acht Pixel, siehe oben), kann eine Diagonalenlänge von circa fünf Bildelementen angenommen werden. Aus einer Aufspaltung dieses Intervalls zu gleichen Anteilen bei fünf Attributwerten folgt letztlich die oben erwähnte Wertesequenz  $\chi_i^{diag}$ .

Das dritte, hier genutzte Attribut zur Ableitung von DAP-Signaturen zur Charakterisierung von HAO ist das *Hu*-Moment erster Ordnung (siehe auch [187]), das im Folgenden als *moi* bezeichnet wird. Näherungsweise kann es als Massenträgheitsmoment beschrieben werden, das die Ausdehnung einer CC relativ zu ihrem Massenschwerpunkt kennzeichnet [116] und somit im Vergleich zu den beiden zuvor beschriebenen Attributen ein komplementäres Maß darstellt.

In seiner klassischen mechanischen Definition bezeichnet das Massenträgheitsmoment den Widerstand eines starren Körpers gegenüber einer Änderung seiner Rotationsbewegung um eine feste Achse und ist somit direkt abhängig von der Form des Körpers sowie der Massenverteilung beziehungsweise der Massendichte in Bezug auf diese Drehachse [200]. Wird dieses Konzept auf die Bildverarbeitung übertragen, kann der Bildschwerpunkt als Ursprung für die Rotationsachse und die Helligkeiten beziehungsweise Grauwertintensitäten der einzelnen Bildelemente als physikalische Dichte aufgefasst werden.

Das erste *Hu*-Moment ist wie folgt definiert [201]:

$$moi = n_{20} + n_{02}, \quad (4.7)$$

mit den skalierungsvarianten Momenten

$$ansn_{ij} = \frac{m_{ij}}{m_{00}^{\left(1+\frac{i+j}{2}\right)}}, \quad (4.8)$$

und den zentralen Momenten

$$m_{ij} = \sum_{x=1}^P \sum_{y=1}^P (x - \bar{x})^i (y - \bar{y})^j I(x, y), \quad (4.9)$$

wobei  $x$  und  $y$  die Bildkoordinaten des vorliegenden HAO,  $\bar{x}$  beziehungsweise  $\bar{y}$  die Schwerpunktskoordinaten des HAO und  $P$  die Anzahl der zu einem HAO gehörenden Pixel sind.  $I(x, y)$  bezeichnet den an Stelle  $(x, y)$  des Eingabebilds vorliegenden Grauwert.

Untersuchungen anhand obiger Formeln zeigten, dass ausgedehnte beziehungsweise langgestreckte Regionen (zum Beispiel linienförmig) ein größeres Massenträgheitsmoment als kompaktere Strukturen (zum Beispiel quadratisch oder kreisförmig) aufweisen. Neben der Form der Bildregion ist die dort vorhandene Grauwertstruktur ausschlaggebend auf das *Hu*-Moment erster Ordnung. Liegen beispielsweise konstant helle Grauwerte vor, so ergibt sich ein vergleichsweise großer Wert in Relation zu einem Gebiet ohne dominant helle

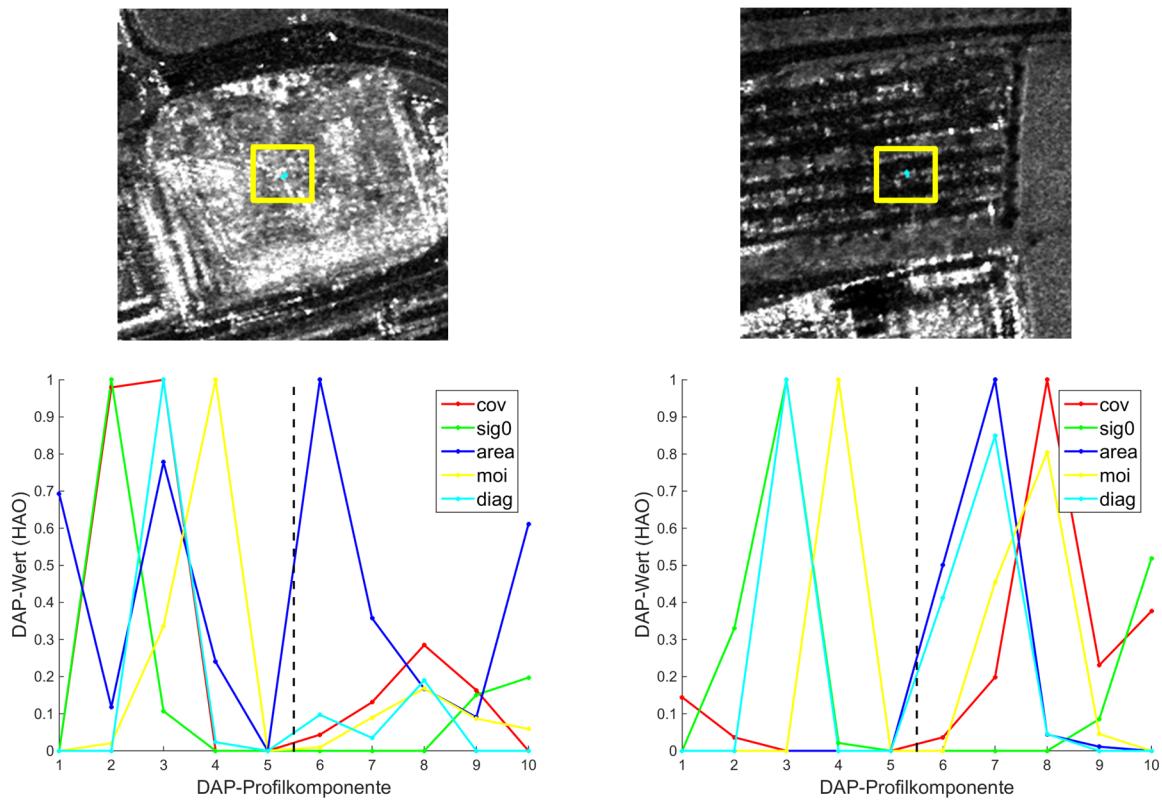


Abbildung 4.11.: DAP-Signaturen zweier HAO (cyan-farben, gelbe Umrandung) in unterschiedlicher Örtlichkeit. Linke Spalte: PKW-Parkplatz; rechte Spalte: Baustelle. Eine DAP-Profilkomponente bezeichnet ein Bild in einem DAP-Stapel. Die gestrichelte schwarze Linie kennzeichnet den Ursprung des Profils.

Grauwertverteilung. Daraus folgt, dass anhand des *moi*-Attributs eine zu den bisherig beschriebenen Methoden ergänzende Möglichkeit zur Ableitung HAO-bezogener Merkmale vorliegt.

In Bezug auf den Wertebereich ist zu erwähnen, dass ein theoretisches, allgemein gültiges Intervall nicht vorhanden ist, das für die Festlegung der Minimal- und Maximalwerte einer Wertesequenz  $\chi_i^{moi}$  genutzt werden könnte. Aus den obigen Erläuterungen hinsichtlich der betrachteten HAO-Größe kann dennoch abgeleitet werden, dass ein rechteckiges HAO mit den Kantenlängen zehn und 40 Pixel einen *moi*-Wert von rund 378 aufweist (bei konstant heller Region mit  $I(x, y) = 255, \forall x, y \in I$ ). Nähert sich diese Region stärker einer linienförmigen Struktur an, so wird der *moi*-Wert rasch größer (exemplarisch:  $moi \approx 700$ , Kantenlängen: acht und 50 Pixel). Die hier verwendete Wertesequenz ist entsprechend gewählt und deckt folgenden Bereich ab:  $\chi_i^{moi} = [0; 200; 400; 600; 800]$ .

Die letzten hier genutzten Attribute sind SAR-spezifische Merkmale, die jeweils auf Basis des radiometrisch normierten Amplitudenbildes (genau: Intensitätsbild durch  $\sigma^0$ -Kalibrierung, siehe Abschnitt 2.1) berechnet werden.

Das erste Attribut *sig0* kennzeichnet die in einer HAO-Region gemessene mittlere Rückstreuintensität, wobei die verbreitet genutzte Darstellung in [dB] verwendet wird. In Anbetracht der zu wählenden Spannweite der Wertesequenz wird in Anlehnung an [102] als Maximalwert +10 [dB] gewählt. Als Minimalwert kann der vom jeweiligen Sensorsystem abhängige Wert genutzt werden, der das Hintergrundrauschen des Systems kennzeichnet und somit die (nicht vorhandene) Rückstreustärke in Bereichen vollkommener Spiegelung beziehungsweise Abschattung wiedergibt (Abschnitt 2.1). Im Zuge von Rückstreuanalysen für Asphaltoberflächen wurde für mittlere Einfallswinkel ein normalisierter Rückstreuwert von -22 [dB] erhoben, der sich für gegenwärtige X- und C-Band Satellitensysteme in der Größenordnung des NESZ befindet [113]. Durch Aufteilung des durch diese beiden Werte darstellbaren Intervalls mittels fünf Werten mit gleich großen Abständen untereinander folgt die Sequenz zu  $\chi_i^{sig0} = [-22; -14, -6; 2, 10]$ .

Das zweite SAR-spezifische Attribut *cov* stellt ein statistisches Maß dar, das zur Unterscheidung homogener und heterogener Bildbereiche dient (siehe Abschnitt 4.2.1). Im Hinblick auf die Ableitung eines passenden Wertebereichs kann auf [113] verwiesen werden, wo simulationsgestützt geeignete Schwellwerte für eine Skalierung der CovAmCoh-Bildlayer vorgeschlagen werden. Der dort ermittelte Wertebereich wird als Grundlage für das hier angewandte Intervall genutzt, wobei aus Gründen der Robustheit Minimal- und Maximalwert jeweils leicht verkleinert, beziehungsweise vergrößert eingehen. Es resultiert die Sequenz

$$\chi_i^{cov} = [0; 0, 5; 1; 1, 5; 2].$$

Zusammenfassend ergibt sich das Morphologiemarkmal aus fünf zehndimensionalen Vektoren ( $v_{HAO_i,area}$ ,  $v_{HAO_i,diag}$ ,  $v_{HAO_i,moi}$ ,  $v_{HAO_i,sig_0}$  und  $v_{HAO_i,cov}$ ). Da die darin enthaltenen Werte bereits zur Berechnungszeit linear auf den Wertebereich [0; 1] normiert werden, ist eine nachträgliche Skalierung nicht notwendig.

Zum Abschluss dieses Abschnitts sind in Abbildung 4.11 die DAP-Signaturen zweier HAO gegenübergestellt, die sich an unterschiedlichen Örtlichkeiten befinden (PKW-Parkplatz und Baustelle). Es ist ersichtlich, dass sich unter Berücksichtigung aller hier genutzten Attribute die Signaturen beider HAO stark voneinander unterscheiden, was als vorteilhaft für eine kategorisierende Einteilung der Änderungsobjekte erachtet werden kann.

## Kapitel 5.

### Kategorisierung und Klassifikation

In diesem Kapitel werden die anfangs formulierten Überlegungen aus Abschnitt 1 zur Entwicklung einer Vorgehensweise aufgegriffen, die ohne Gebrauch von Referenz- oder Trainingsdatensätzen eine Kategorisierung und Klassifikation der detektierten Änderungsobjekte ermöglicht. Diese nachfolgend beschriebene Vorgehensweise nimmt eine gegensätzliche Stellung zu verbreiteten Methoden zur LULC-Klassifikation ein. Weiterhin besitzt sie durch ihren hohen Automatisierungsgrad und die begrenzte Anzahl an Eingabedaten einen für die Praxis hochrelevanten Nutzen.

Der Anwender benötigt keine detaillierte Fachkenntnis über die zugrunde liegenden Daten und die abgebildete Szenerie, da dieses Wissen in iterativer Weise durch das hier vorgestellte Verfahren vermittelt wird. Der Algorithmus benötigt dafür ausschließlich einen initialen Zustand, der den Ausgangs- beziehungsweise Startpunkt für die Ableitung eines Klassenkatalogs darstellt, der bestmöglich zu den (kategorisierten) Daten passt. Ein Überblick über das entwickelte Konzept ist inklusive einer schrittweisen Erläuterung des Ablaufplans in Abschnitt 5.1 enthalten. Die beiden zentralen Aspekte sind hierbei die Kategorisierung der HAO und die Optimierung eines vorab selektierten Klassenkatalogs in Bezug zum *Clustering*-Resultat. Die Klassenzuweisung der HAO erfolgt anhand des optimierten Katalogs.

Für die Kategorisierung der HAO kommt eine unüberwachte Konfiguration des *k-means*-Verfahrens zum Einsatz. Dieses wird in Abschnitt 5.2.1 thematisiert.

Das restliche Kapitel enthält den Ablauf zur Klassifikation der HAO, der von der Eingabe eines manuell gewählten Klassenkatalogs bis zur Ausgabe eines optimierten Katalogs sowie von klassenbezogenen Beschreibungen reicht, die dem Anwender zusätzliche Informationen zur Wissensbildung beziehungsweise Ergebnisinterpretation zur Verfügung stellen.

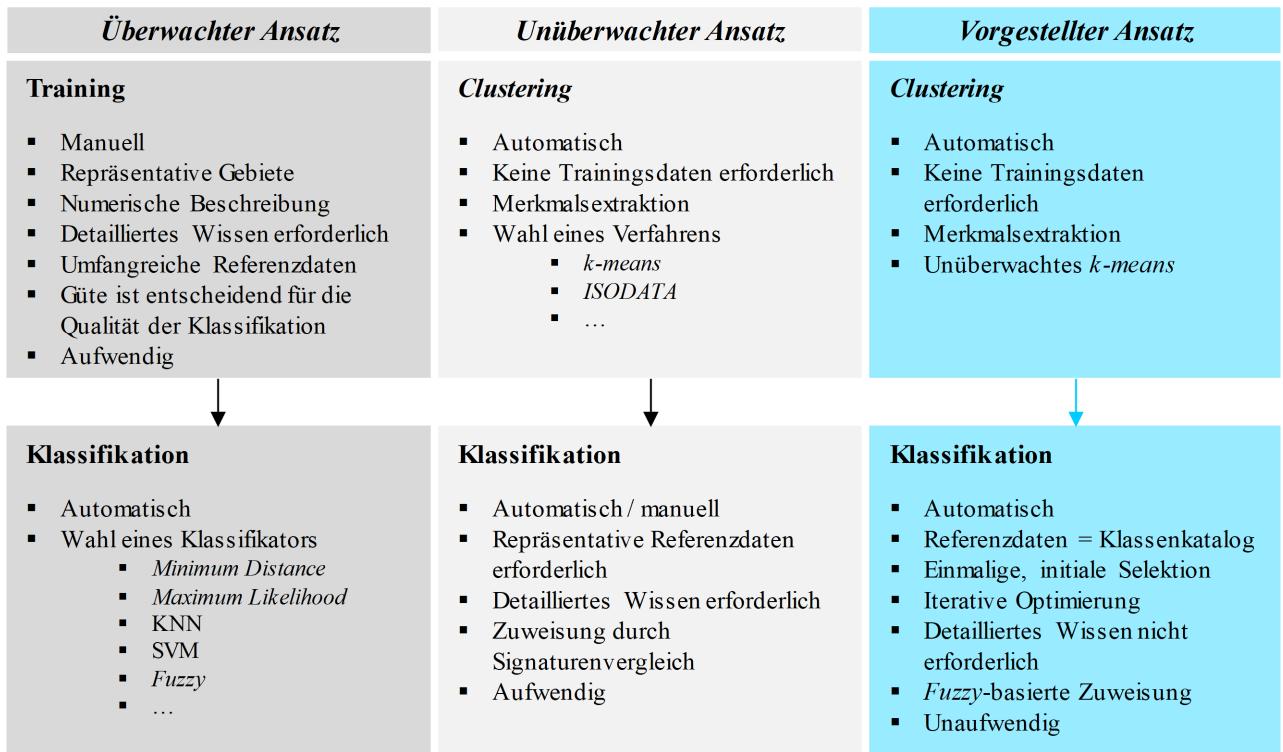


Abbildung 5.1.: Einordnung des Konzepts in den Themenbereich der LULC-Klassifikation.

## 5.1. Konzept

In Anlehnung an die in Kapitel 1 und in den Abschnitten 1.1 und 2.2.7 enthaltenen Erläuterungen wird zunächst mit Abbildung 5.1 eine Einordnung des in dieser Arbeit vorgestellten Verfahrens vorgenommen. Als literarische Bezugsquelle für die Ausführungen dient [3].

Aus allgemeiner Sicht können Ansätze zur LULC-Klassifikation in die beiden Sparten *überwacht* und *unüberwacht* eingeteilt werden.

Die überwachte Vorgehensweise (Abbildung 5.1, links) enthält die bereits bekannten Nachteile, die der vor der Klassifikation durchzuführende Trainingsschritt mit sich führt. In [3] wird dieser Verarbeitungsschritt als *Kunst und Wissenschaft* zugleich bezeichnet, da die Auswahl repräsentativer Trainingsgebiete anhand umfangreicher Referenzdaten sowohl Geschick als auch detailliertes Wissen von Seiten des Anwenders erfordert. Diese Selektion mit dem Ziel der Ableitung numerischer Beschreibungen geeigneter Attribute oder Merkmale zur Unterscheidung der Klassen kann zeitaufwendig und je nach vorliegender Referenzdatengrundlage unhandlich sein. Einen ungeübten Anwender ohne tiefergehende Kenntnis über die Methode, die auszuwertenden Klassen oder die zu analysierende Szenerie, kann dies vor bedeutende Schwierigkeiten stellen. Auf der anderen Seite erscheint diese Verfahrensweise im Hinblick auf möglichst schnell vorliegende Analyseergebnisse unpraktikabel, sowie für eine unmittelbare Adaption auf andere Szenen ungeeignet. Dieses Problem der Adaption wird im Bereich des maschinellen Lernens versucht, durch sogenannte *Transfer-Learning*-Methoden zu lösen. In [202] ist exemplarisch ein Ansatz gegeben, bei dem der Hauptaspekt in der Gewinnung von Kategoriemeerkmalen liegt, die für bereits prozessierte ähnliche Daten gemeinsam relevant sind. Mit einer so abgeleiteten geringeren Anzahl an Trainingsdaten werden nachfolgende Klassifikationen auf Basis ähnlicher Bilddaten performanter (Dauer und Genauigkeit) durchführbar.

Die unüberwachte Methode (Abbildung 5.1, Mitte) besitzt im Vergleich zur überwachten Herangehensweise den Vorteil, dass der Trainingsschritt nicht erforderlich ist, da auf Basis vorab extrahierter Merkmale mittels eines automatischen *Clustering*-Verfahrens eine kategorisierende Einteilung der Eingabedaten erfolgt. Ein weiterer Vorteil besteht darin, dass in den Daten enthaltene, aber für den Nutzer nicht direkt ersichtliche Information entdeckt wird, die zur Kategorienbildung verwendet werden kann [3]. Die Klassifikation erfolgt vergleichbar wie der zuvor beschriebene Trainingsschritt der überwachten Ansätze. Auch hier sind repräsentative Referenzdaten erforderlich, die entweder selbst erstellt werden müssen, oder im besten Fall bereits zum Beispiel in Form von Datenbankinformationen vorliegen. Die Klassenzuweisung selbst kann automatisch oder manuell erfolgen, was erneut fundiertes Fachwissen erforderlich macht. Somit kann resümiert werden, dass

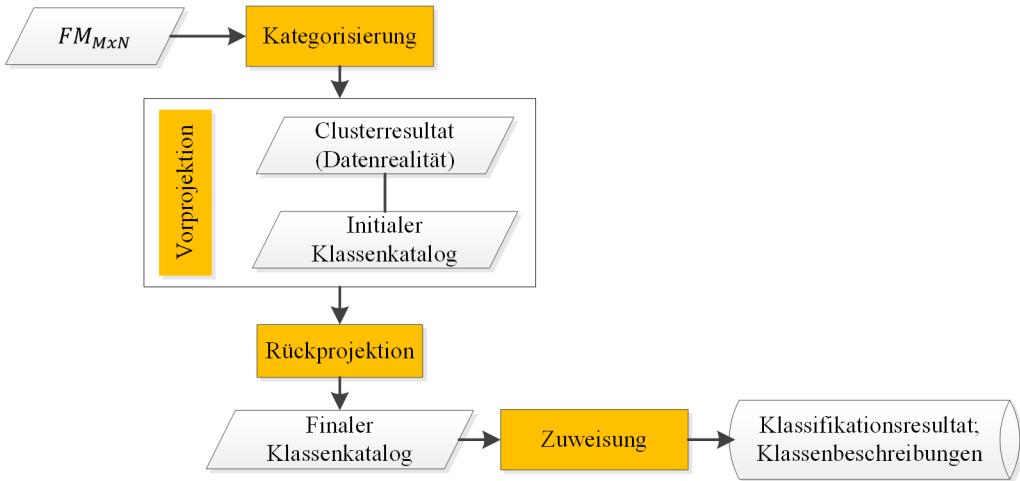


Abbildung 5.2.: Konzept zur Kategorisierung und Klassifikation.

auch die unüberwachten Ansätze eine mehr oder weniger starke Involvierung eines geübten Anwenders erfordern.

An den Nachteilen der beiden Ansätze setzt die vorgestellte Methode zur Klassifikation an (Abbildung 5.1, rechts). Sie ist als hybrides Verfahren aufzufassen, das im Anschluss an eine unüberwachte Kategorisierung der Daten und auf Grundlage eines manuell durch den Anwender selektierten Klassenkatalogs eine iterative Optimierungsprozedur enthält, an deren Ende eine Klassenbeschreibung steht, die zum tatsächlich enthaltenen Informationsgehalt der Eingabedaten stimmig ist. Da die Selektion des Klassenkatalogs einmalig initialisierend erfolgt, ist der Automatisierungsgrad hoch und die Nutzerinteraktionsrate gering. Detailliertes Wissen über die Methode oder die verfügbaren Daten ist von Nutzerseite nicht erforderlich, da dies im Prozessierungsverlauf durch das Verfahren vermittelt wird. Der Anwender lernt den Datensatz und eine sinnvolle Klassenbeschreibung kennen. Die bei überwachten Trainingsschritten bislang schwer zu treffende Entscheidung, welche Gebiete für welche Klasse möglichst repräsentative Vertreter darstellen, wird auf diese Weise hinfällig. Die Existenz umfangreicher Referenzdaten ist ebenfalls nicht notwendig, da diese durch den tatsächlich in den Eingabedaten vorliegenden Informationsgehalt gegeben ist. Zusammenfassend ergibt sich eine Methode, die eine sowohl nutzerfreundliche als auch praktikable und wirtschaftliche Alternative zu konventionellen Vorgehensweisen darstellt.

In Bezug auf die verwendeten Daten wurde bereits erwähnt, dass in dieser Arbeit die HAO die Grundlage für die Klassifikation bilden. Der klassische Begriff der LULC-Klassifikation verändert sich so zu einer Klassifikation der durch die Änderungssegmente definierten Bildbereiche (zum Beispiel Parkplätze, Baustellen, etc.). Eine Nutzung des Verfahrens für weitere pixelbasierte oder objektorientierte Klassifikationsaufgaben ist generell möglich. Hierzu müsste lediglich die Merkmalsextraktion als vorverarbeitender Schritt für das *Clustering* auf die anderen Prozessierungseinheiten angepasst werden.

In Abbildung 5.2 ist das Flussdiagramm des vorgestellten Ansatzes zur Analyse der HAO visualisiert. Als Eingabe für die Kategorisierung der Hochaktivitätsobjekte dient die aus der Merkmalsextraktion resultierende, reduzierte Matrix  $FM$  mit den Merkmalsvektoren für die  $M$  vorliegenden HAO. Die Anzahl der Spalten beziehungsweise die Länge der Merkmalsvektoren  $N$  bezeichnet die Anzahl der nach der Reduzierung verfügbaren Hauptkomponenten (siehe auch Abschnitt 6.2.3).

Das Clusterresultat wird im Rahmen der weiteren Analyse als feste Datenrealität betrachtet, die den tatsächlich in den Daten enthaltenen Informationsgehalt kennzeichnet. Diese Datenrealität dient als Vergleichs- und Optimierungsgrundlage für die Herleitung eines optimierten Klassenkatalogs, der nach iterativer Abarbeitung der *Rückprojektion* (RP) vorhanden ist. Die RP baut auf der *Vorprojektion* (VP) auf, die Erkenntnisse darüber liefert, welche Clusterzusammensetzung in einer manuell selektierten Klasse enthalten ist. Dies erfolgt anhand der in den Ortsraum (Bildraum) projizierten Datenrealität durch Detektion der klassenbezogenen Clusterinstanzen (kategorisierte HAO). Anschaulich können VP und RP als Projektionen interpretiert werden, die das Kategorisierungsergebnis mit dem Klassenkatalog in Verbindung setzen und umgekehrt. Im Vergleich zur RP erfolgt die VP nicht iterativ und dient zur einmaligen Vorabbeurteilung des durch den Anwender gewählten Klassenkatalogs. Den Kern der Rückprojektion bildet die Berechnung und Beurteilung bestimmter Kennzahlen, deren Optimierung gleichbedeutend mit der Verbesserung des initialen Klassenkatalogs ist. Eine detaillierte Beschreibung dieser beiden Prozessierungen sowie der weiteren Verarbeitungsschritte ist in den nachfolgenden Abschnitten zu finden.

Der final vorhandene, optimierte Klassenkatalog dient schließlich als Eingabe für die Zuweisung der HAO

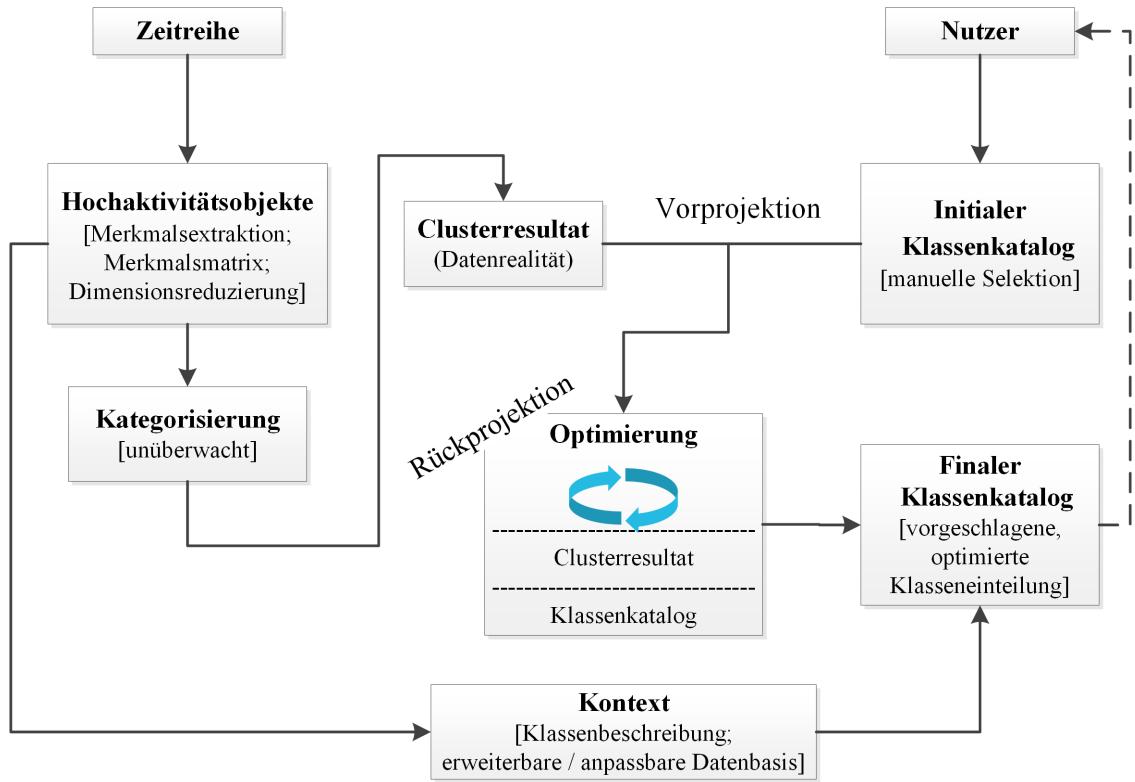


Abbildung 5.3.: Vereinfachtes Schema des vorgestellten Ansatzes.

zu den darin enthaltenen Klassen. Als Ergebnis wird dem Anwender das Klassifikationsresultat inklusive verschiedener, die Klassen beschreibender Informationen bereitgestellt.

Zum Abschluss dieses Abschnitts findet sich mit Abbildung 5.3 ein generalisierter Überblick zu den zuvor beschriebenen Verarbeitungsschritten. Zu zentralen Aspekten (beispielsweise „Hochaktivitätsobjekte“ oder „Initialer Klassenkatalog“) sind charakterisierende Eigenschaften in eckigen Klammern hinzugefügt. So ist mit den HAO die Berechnung und Extraktion der Merkmale, die Erstellung der Merkmalsmatrix sowie die Reduzierung dieser Matrix auf Hauptkomponenten eng verknüpft. Das Kontextmerkmal, das nicht zur Kategorisierung der HAO genutzt wird, dafür aber als Grundlage für eine spätere Klassenbeschreibung dient, wird durch die flexibel verwendbare Datenbasis charakterisiert. Wie weiter oben bereits erwähnt, nehmen die VP und die RP zentrale Schritte in dem vorgestellten Konzept ein. Für die optimierende RP ist ferner die Projektion des geclusterten Merkmalsraums in ein zweidimensionales Raster für die Berechnung von Kennzahlen von Bedeutung (siehe auch Abschnitt 5.2.4). Nach der RP liegt dem Nutzer ein durch das Verfahren vorgeschlagener finaler Klassenkatalog vor, der als Grundlage einer möglichen Weiterverarbeitung unter Berücksichtigung der inzwischen gewonnenen Erkenntnisse zur Verfügung steht. Diese Option ist in Abbildung 5.3 mit gestricheltem Pfeil dargestellt.

## 5.2. Umsetzung

In diesem Abschnitt werden die grundlegenden Abläufe und Zusammenhänge vermittelt, die für das Verständnis der entwickelten Methode notwendig sind. Hierbei werden im Gegensatz zur konventionellen Vorgehensweise nicht die Bildelemente verwendet, aus denen sich die jeweilige Klasse zusammensetzt (zum Beispiel Pixel oder Segmente eines Feldes, einer Vegetationsform, etc.). Die Klassifikation erfolgt vielmehr indirekt anhand der in diesen Klassen befindlichen beziehungsweise detektierten Hochaktivitätsobjekte eines Zeitreihendatensatzes. Der Fokus liegt hier auf der Analyse kleinskaliger HAO, die beispielsweise durch hinzukommende oder verschwindende Fahrzeuge auf einem Parkplatz oder an einer Be- und Entladestelle in industriellem Bereich hervorgerufen werden.

Die Methode kann als hybride Verfahrensweise betrachtet werden, die unüberwachte (Kategorisierung, Abschnitt 5.2.1) mit überwachten Elementen kombiniert. Hierfür werden keine umfangreiche und repräsentative Trainings- und Referenzdaten benötigt, womit detailliertes Expertenwissen auf Nutzerseite nicht erforderlich ist. Die einzige Interaktion des Verfahrens mit dem Anwender erfolgt einmalig bei der Definition eines initialen Klassenkatalogs (Abschnitt 5.2.2).

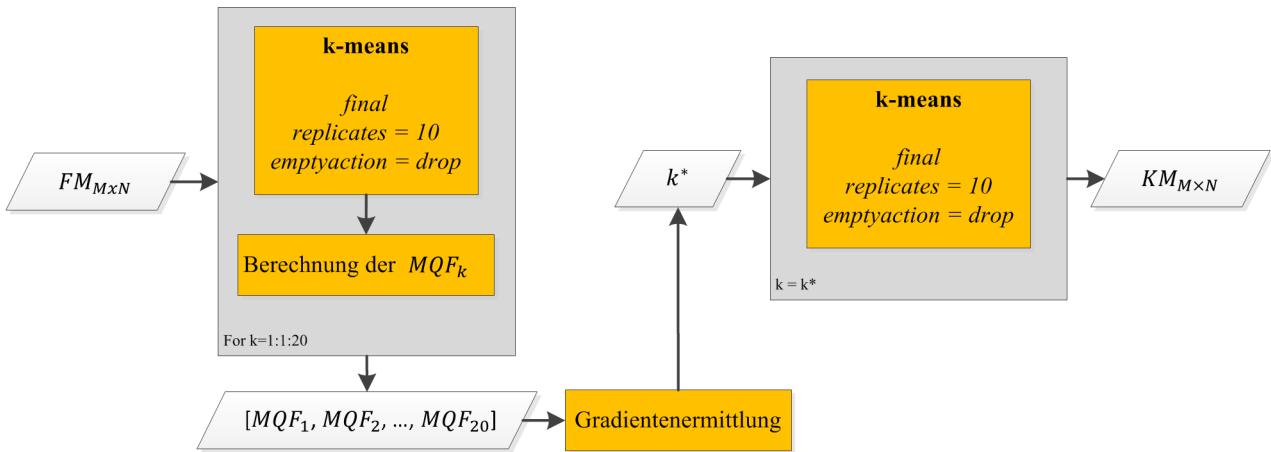


Abbildung 5.4.: Ablauf der Kategorisierung.

Als vorverarbeitender Schritt für die Rückprojektion erfolgt die Vorprojektion (Abschnitt 5.2.3), die letztlich zur Überprüfung dient, ob eine durch den Anwender selektierte Klasse in den kategorisierten Daten (HAO) enthalten ist, oder ob keine dominante Kategoriennausprägung vorliegt. Der initiale Klassenkatalog wird im weiteren Ablauf des Verfahrens iterativ anhand des tatsächlich in den Daten enthaltenen Informationsgehalts optimiert (RP, Abschnitt 5.2.4).

Die eigentliche Klassifikation der HAO wird auf Basis des final durch die Methode gefundenen Klassenkatalogs durchgeführt. Da es aufgrund von in der Realität existierenden Mischklassen sowie einer möglichen, ungenauen Selektion des initialen Katalogs zu Überlappungen der resultierenden Klassen kommen kann, wird als Zuweisungsmethode die *Fuzzy-Logik* eingesetzt (Abschnitt 5.2.5).

### 5.2.1. Kategorisierung

In Abschnitt 2.2.6 wurden die Grundlagen der Clusteranalyse beschrieben, sowie verbreitet genutzte Methoden (*k-means*, *Mean-Shift* und *ISODATA*) erläutert. Durch Gegenüberstellung der Vor- und Nachteile dieser Verfahren resultierte der *k-means*-Algorithmus als die hier am Besten geeignete Methode. Dies ist insbesondere dadurch begründet, dass der Parameter  $k$  (Anzahl der Cluster) anhand verschiedener Ansätze (zum Beispiel *Davis-Bouldin-Kriterium*, *Ellbogenmethode*, etc.) in unüberwachter Weise ermittelt werden kann und somit eine automatische Kategorisierung der Hochaktivitätsobjekte erlaubt. Abbildung 5.4 enthält den Kategorisierungsablauf. Als Eingabe dient, gemäß den in Abschnitt 2.2.5 enthaltenen Erläuterungen, die reduzierte Merkmalsmatrix  $FM_{M \times N}$ . Die Reduzierung wird in Abschnitt 6.2.3 anhand des tatsächlich vorliegenden Testdatensatzes beschrieben.

Zur Durchführung der Kategorisierung wird die in der *Statistics Toolbox* der Entwicklungsumgebung *Matlab* enthaltene *k-means*-Implementierung genutzt, wobei bis auf wenige Ausnahmen die ursprünglich eingestellte Parametrisierung beibehalten wird (Abbildung 5.4). Diese ursprünglichen Einstellungen umfassen beispielsweise die Verwendung der Euklidischen Distanz  $d_{L_2}$  (Formel (2.52)), die maximale Anzahl mit einhundert Durchläufen je Iterationsschritt, sowie die Anwendung des *kmeans++*-Algorithmus nach [203] zur initialen Wahl der jeweiligen Clusterzentren. Da hinsichtlich der Anzahl an unabhängigen Durchläufen in der ursprünglichen Konfiguration nur einmal prozessiert wird und damit die in Abschnitt 2.2.6 dargelegte Problematik der zufälligen Initialisierung bestehen würde, wird der Algorithmus zehnmal unabhängig angewendet (*replicates = 10*). Auf diese Weise wird je Durchlauf eine andere, zufällige Initialisierung der Clusterzentren vorgenommen, woraus jeweils verschiedene Kategorisierungslösungen resultieren. Als finales Ergebnis wird jene Lösung genommen, die über die kleinsten In-Cluster-Summen der Distanzen zwischen Instanzen und Clusterzentren verfügt. Sollten im Zuge der Prozessierung Kategorien gefunden werden, die im weiteren Verlauf keine Instanzen (hier: HAO) mehr besitzen, so werden diese zur Vermeidung von Kategorien, die nicht in den Daten enthalten sind, gelöscht (*emptyaction = drop*).

Für die unüberwachte Wahl eines geeigneten Werts für die Anzahl  $k$  der Cluster wird die *Ellbogenmethode* verwendet (Abschnitt 2.2.6 und [27]). In Konsequenz daraus wird das *Clustering* zur Ermittlung eines optimalen  $k^*$  für 20 verschiedene  $k_i$  durchgeführt ( $i = [1, 2, \dots, 20]$ ). Daraus ergibt sich für jedes  $k_i$  ein zehnmaliger Durchlauf des Algorithmus mit jeweils verschiedenen selektierten Startpunkten des  $k = 1$  beziehungsweise der  $k > 1$  Clusterzentren. Für jedes  $k_i$  resultiert ein Vektor aus zehn MQF-Werten (Formel (2.63)), woraus letztlich durch Mittelung ein repräsentativer Wert  $MQF_i$  gewählt wird (Abbildung 5.4). Die derart resultierenden 20 MQF-Werte werden gemäß den in Abschnitt 2.2.6 enthaltenen Erläuterungen visualisiert. Der sich aus der



Abbildung 5.5.: Selektion der Klasse *Sammelstelle*. Links: Hochaktivitätspixel (rot) in mittlerem Amplitudenbild mit farbig markiertem Klassenpolygon (grün). Mitte: Entsprechender Ausschnitt aus pangeschärftem WV-2-Bild. Rechts: Im Rahmen einer Ortsbegehung fotografierteter Hochaktivitätsbereich.

*Ellbogenmethode* ergebende, optimal für die Eingabedaten geeignete Wert  $k^*$  kennzeichnet die Eingabeanzahl an Clustern für die Berechnung des finalen Kategorisierungsergebnisses.

Die Ausgabe des *Clustering* ist die kategorisierte Version  $KM_{M \times N}$  der ursprünglich eingegebenen reduzierten Merkmalsmatrix  $FM_{M \times N}$ , die eine farbkodierte Darstellung der kategorisierten HAO im Ortsraum (Bild) ermöglicht. Das Kategorisierungsergebnis bildet weiterhin die Grundlage für die nachfolgenden Verarbeitungsschritte. Zunächst erfolgt in interaktiver Weise die Selektion eines initialen Klassenkatalogs durch den Nutzer.

### 5.2.2. Initialer Klassenkatalog

Aus den in Abschnitt 1 dargelegten Gründen wird auf eine Berücksichtigung von Referenzdaten im Zuge der Klassifikation der HAO verzichtet. Diese erfolgt iterativ durch Optimierung eines durch den Anwender erstellten Klassenkatalogs in Anlehnung an die tatsächlich in den Bilddaten enthaltene Information (Datenrealität, Abbildung 5.3). Dieser Katalog ist in Kombination mit der vorliegenden Datenrealität die Basis für die weiteren Verarbeitungsschritte.

Die Erstellung des Klassenkatalogs erfolgt interaktiv anhand der aus den Daten berechneten, gefilterten Aktivitätskarte, die die Hochaktivitätspixel als Überlagerung in der mittleren Zeitreihenamplitude enthält (siehe Abschnitte 3.2.1 und 3.2.2). Auf diese Weise wird von vornherein der Fokus auf die entsprechenden Zielgebiete beziehungsweise Zielklassen gelegt. Der Anwender übernimmt einzig die Aufgabe, die aus seiner Sicht beziehungsweise Erwartungshaltung gegenüber dem Datensatz enthaltenen Klassen im Ortsraum zu selektieren. Diese Selektion erfolgt durch freihändige Auswahl eines die jeweilige Klassenregion umrandenden Polygons. Die Abbildung 5.5 enthält die Darstellung der Definition der Klasse *Sammelstelle*, deren hohe Aktivität über die Zeit in diesem Beispiel durch Bewegung sowie An- und Abtransport von Metallcontainern begründet ist.

Befinden sich in einer gewählten Klassenregion keine HAO, so wird der Anwender mit Hinweis auf eine erneute, passendere Selektion in Anlehnung an die in rot dargestellten HAP (Abbildung 5.5, links) entsprechend informiert.

Ist die Selektion aller Klassen abgeschlossen, werden durch das Verfahren für jede Klasse beziehungsweise jede Hochaktivitätsregion die dazugehörigen Änderungsobjekte ermittelt. Dies erfolgt auf Basis der in der Region befindlichen Hochaktivitätspixel HAP gemäß der in Abschnitt 3.2.3 erläuterten, nicht redundanten Weise. Anhand der für jede verfügbare Klasse vorliegenden HAO werden für den nachfolgenden Schritt der Vorprojektion die Kategorienzugehörigkeiten betrachtet.

### 5.2.3. Vorprojektion

Die Vorprojektion (VP) ist die Abbildung des Kategorisierungsergebnisses in den durch die Bilddaten dargestellten Ortsraum. Sie dient einerseits zur Visualisierung und andererseits zur Identifikation möglicher, in den Klassen enthaltener dominanter Clusterausprägungen. Diese Information bildet gleichzeitig die Eingabe für die an die VP anschließende Rückprojektion (RP). Abbildung 5.6 enthält das Ablaufschema zur VP sowie ein Beispiel mit vier Kategorien.

Als Eingabedaten werden die Ergebnisse aus der Kategorisierung, die Matrix mit den HAO-bezogenen Clusterzuweisungen  $KM_{M \times N}$  sowie der zuvor durch den Nutzer definierte, aus  $KL$  Klassen bestehende Katalog betrachtet. Für jede Klasse  $kl_j$  dieses Katalogs werden die von ihr in der jeweiligen Örtlichkeit abgedeckten Änderungsobjekte detektiert und die entsprechenden Kategorienzugehörigkeiten extrahiert. Anhand dieser Information, die visuell dem Anwender als klassenbezogenes Clusterhistogramm (Abbildung 5.6, unten

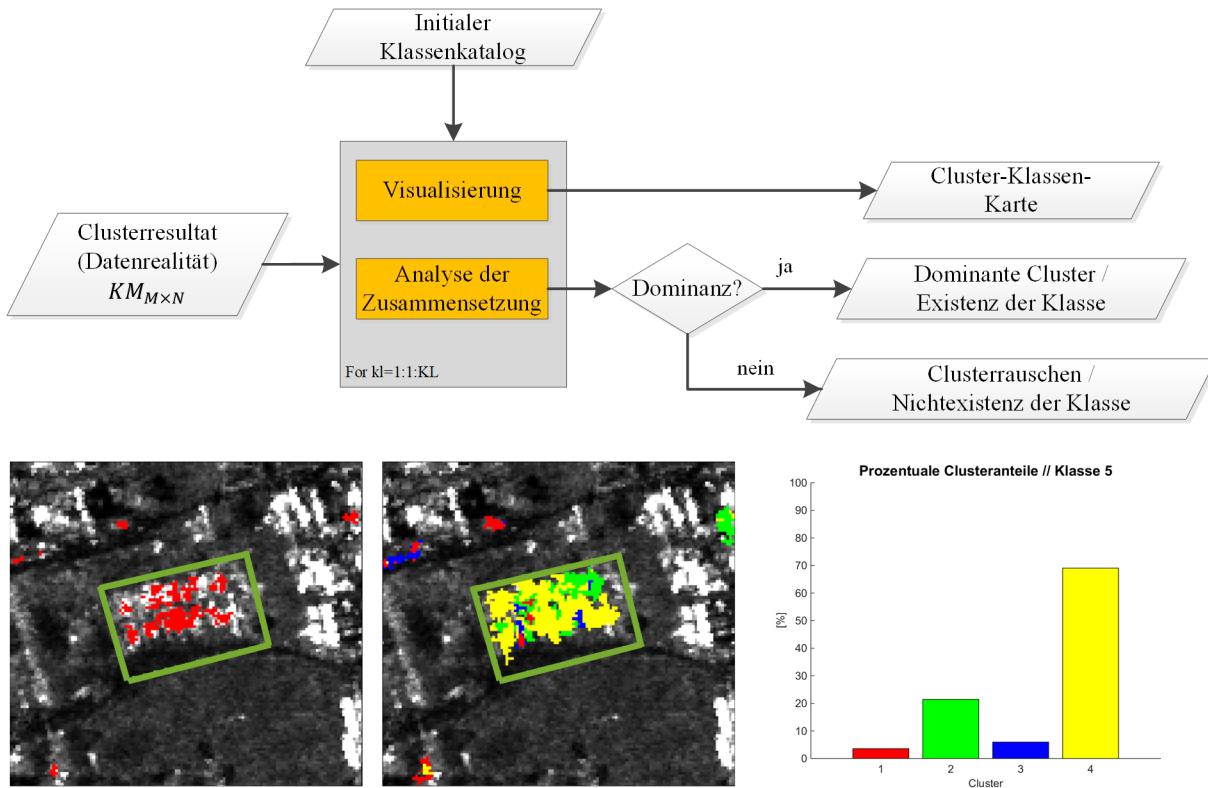


Abbildung 5.6.: Oben: Schematischer Ablauf der Vorprojektion; unten: Visualisiertes Beispiel mit Klassenregion (links), in den Ortsraum projiziertes Clusterresultat (Mitte) und Clusterhistogramm (rechts).

rechts) vermittelt wird, erfolgt die Beurteilung, ob die aktuelle Klasse eine dominante Clusterstruktur oder lediglich Clusterrauschen beinhaltet.

Zur Entscheidung, ob  $c_i$  Kategorien die jeweilige Klasse  $kl_j$  dominieren, wird ein Schwellwert  $CL_\tau$  verwendet, der die maximale Anzahl  $CL$  an dominanten Clustern je Klasse steuert. Im Rahmen der vorliegenden Arbeit wird  $CL_\tau = k^*/2$  gewählt (siehe Kapitel 6), wobei  $k^*$  die Anzahl der Cluster des jeweiligen Datensatzes ist (vergleiche auch Abschnitt 5.2.1). Im idealisierten Fall beinhaltet eine Klasse genau ein Cluster. Da dieser Idealfall in natürlichen Daten als rein theoretisch eingestuft werden kann, werden hier  $k^*/2$  Kategorien zugelassen.

Die eine Klasse dominierenden  $CL$  Kategorien grenzen sich hinsichtlich ihrer prozentualen Anteile an der in einer Klasse enthaltenen HAO ab. Zur Formulierung dieser Abgrenzung gelten folgende Regeln, wobei  $i, ii, j, jj \in \mathbb{N}$ :

- Genau ein dominantes Cluster  $c_i$  liegt in einer Klasse  $kl_j$  vor, wenn  $c_i$  mehr als doppelt so viele HAO dieser Klasse auf sich vereint als ein anderes Cluster  $c_{ii}$ , das die zweitmeisten HAO der Klasse besitzt. In diesem Fall ist  $CL = 1$ .
- Es liegen höchstens  $k^*/2$  dominante Cluster in Klasse  $kl_j$  vor, wenn ...
  - ... die prozentuale Summe der auf sie vereinten HAO größer ist, als die prozentuale Summe der zu den weiteren Clustern gehörenden HAO;
  - ... der Unterschied dieser beiden Summen größer als 20 Prozent ist.

Im Fall von b) ist  $1 < CL \leq (k^*/2)$ . Die Angabe der prozentualen Schwelle basiert auf empirischen Testläufen.

Das in Abbildung 5.6 visualisierte Beispiel der durch den Anwender gewählten Klasse *Sammelstelle* (siehe auch Abbildung 5.5) basiert auf einer aus vier Clustern (rot, grün, blau, gelb) bestehenden Kategorisierungslösung ( $k^* = 4$ ). Auf der rechten Seite der Abbildung ist das für diese Klassenregion abgeleitete Clusterhistogramm dargestellt. Die vierte Kategorie (gelb) ist mit einem Anteil von 69 Prozent (58 von insgesamt 84 HAO) die einzige dominante Kategorie. Die Kategorie mit der zweitgrößten Anzahl an in der Klasse enthaltenen HAO (18/58) nimmt die Nummer zwei (grün) mit 21 Prozent ein. Es folgen die weiteren Kategorien drei (sechs Prozent, 5/84) und eins (vier Prozent, 3/84).

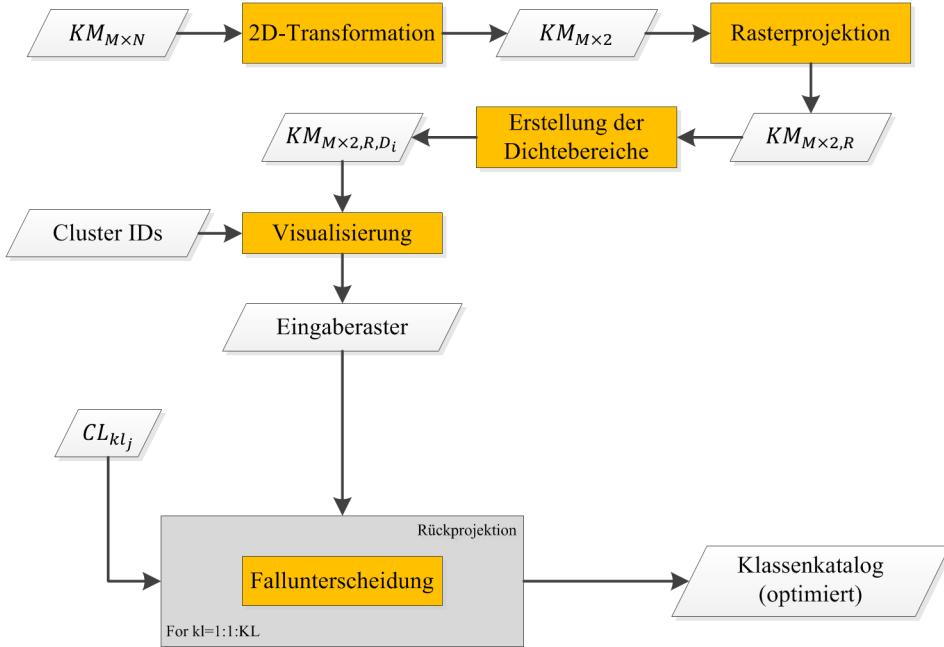


Abbildung 5.7.: Eingabe- und Ausgabedaten der Rückprojektion.

Der im Rahmen der VP berechnete Parameter  $CL$  erfüllt neben der Aussage, ob eine bestimmte Klasse durch maximal  $k^*/2$  Kategorien dargestellt wird oder nur Clusterrauschen beinhaltet, einen weiteren Zweck: Für die iterative Optimierung des Klassenkatalogs im Verlauf der Rückprojektion ist die Projektion der Klassen in den kategorisierten Merkmalsraum notwendig (siehe Abschnitt 5.2.4).

Wie anhand des oben beschriebenen Beispiele erkennbar ist, kann eine gewählte Klasse eine Mischung aus Anteilen verschiedener Cluster enthalten. Aus diesem Grund werden lediglich die dominierenden Kategorien und die dazugehörigen HAO als Grundlage für die Visualisierung der Klassen betrachtet. Ohne diese Form der Gewichtung würde eine bestimmte Klasse im Merkmalsraum alle beteiligten Kategorien zu nahezu gleichen Anteilen abdecken.

Liegt keine Dominanz bestimmter Kategorien mit maximaler Anzahl von  $CL \leq k^*/2$  vor, so dienen jene Kategorien (und die dazugehörigen HAO) als Gewichtungsgrundlage, die in Summe mindestens 75 Prozent der gesamten in der Klasse enthaltenen Änderungsobjekte auf sich vereinen. Es resultiert somit eine Klassendarstellung im Merkmalsraum, die mehr als  $k^*/2$  Cluster abdeckt und die tatsächliche, verrauschte Clusterstruktur der Klasse wiedergibt.

Der nachfolgende Abschnitt enthält die detaillierten Ausführungen hinsichtlich der Abläufe zur Rückprojektion.

#### 5.2.4. Rückprojektion

Die Ergebnisse aus der Vorprojektion, gegeben durch die Anzahl dominanter Kategorien  $CL$  je Klasse  $kl_j$ , sowie den Identifikationsnummern (IDs) der entsprechenden Cluster, stellen die eine Seite der für die Rückprojektion notwendigen Eingabedaten dar (Abbildung 5.7). Die andere Seite nimmt der kategorisierte Merkmalsraum  $KM_{M\times N}$  ein, der vor dem Hintergrund der späteren, zweidimensionalen Ableitung empirischer Kennzahlen zunächst in passender Weise vorverarbeitet werden muss (Abbildung 5.7, 2D-Transformation).

Der erste Schritt dieser Vorverarbeitung ist demzufolge die geeignete Transformation von  $KM_{M\times N}$  nach  $KM_{M\times 2}$ , wofür beispielsweise Methoden wie das Sammon-Mapping [204] in Frage kommen.

Die Kennzahlen (siehe weiter unten) dienen unter anderem zur Auswertung der durch die Cluster definierten räumlichen Zusammenhänge. Aus diesem Grund erfolgt eine Transformation der  $KM_{M\times 2}$  in ein Raster (Abbildung 5.7, Rasterprojektion), wobei eine Instanz des Merkmalsraums (kategorisiertes HAO) als ein Bildelement dargestellt wird ( $KM_{M\times 2,R}$ ). Die aus der Vorprojektion abgeleiteten Wertebereiche der jeweils dominanten Kategorien (Cluster IDs) und den dazugehörigen HAO werden durch ihre Schwellwertcharakteristik im zweidimensionalen Raster als Klassenboxen visualisiert (siehe Absatz „Dichtebereiche“).

Darüber hinaus wird eine Detektion der die jeweiligen Kategorien kennzeichnenden Bereiche des Merkmalsraums mittels dichtebasierter Regionenwachstum durchgeführt.

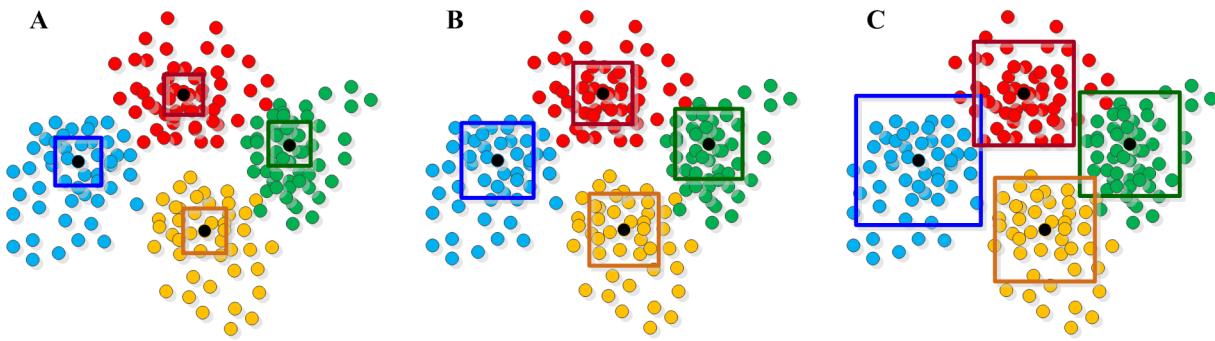
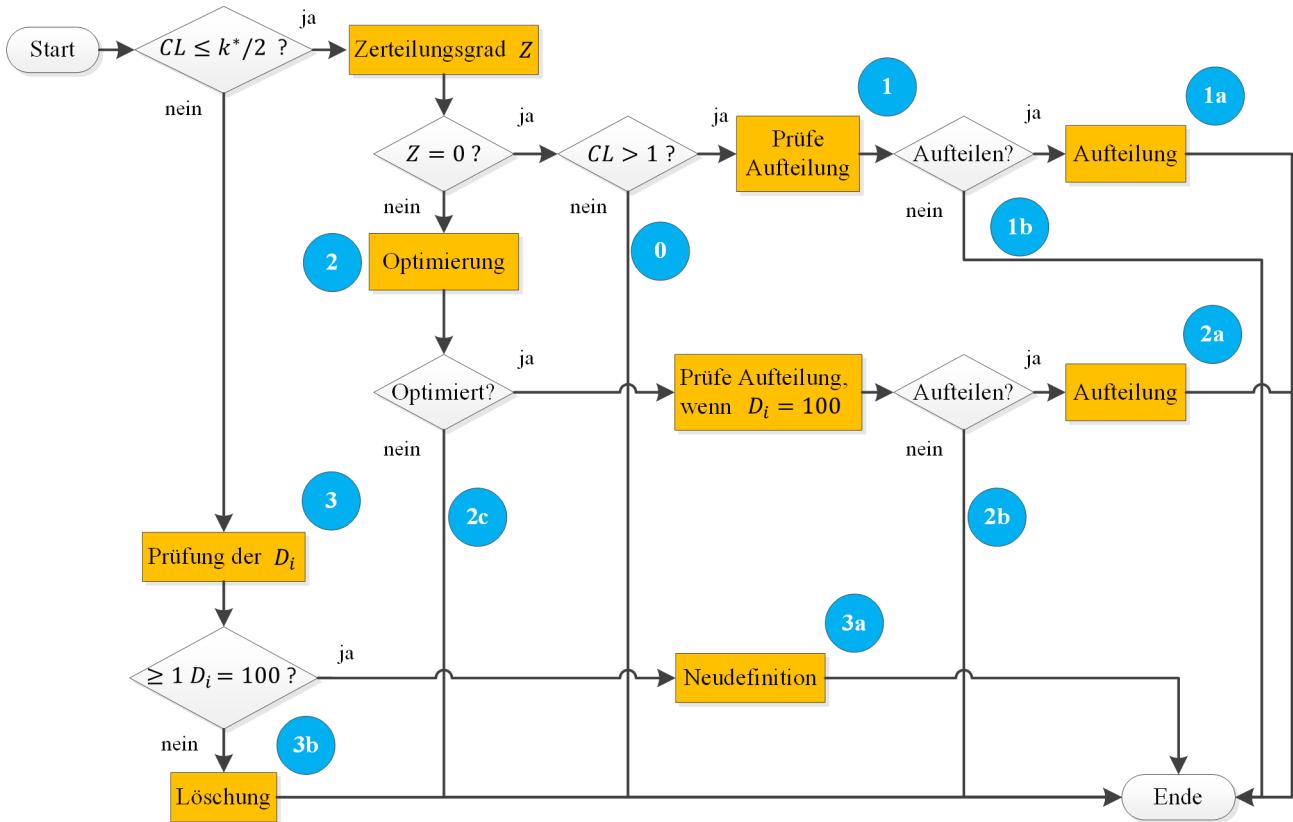


Abbildung 5.8.: Regionenwachstum zur Bestimmung der Dichtebereiche  $D_i$  der Cluster.



For  $k=1:1:KL$

Abbildung 5.9.: Abläufe bei der Fallunterscheidung zur Optimierung des Klassenkatalogs.

## Dichtebereiche

Die im reduzierten, zweidimensional transformierten Merkmalsraster visualisierten Klassen besitzen rechteckige Form, was durch die Ableitung minimaler und maximaler Werte der zu dominanten Cluster gehörenden HAO beziehungsweise deren Merkmalsausprägungen begründet ist. Im Zuge der optimierenden Rückprojektion wird der derart visualisierte initiale Klassenkatalog mit den kategorisierten Daten verglichen (Abbildung 5.7, Eingaberaster), sowie Kennzahlen bestimmt und ausgewertet. Zur Wahrung der geometrischen Homogenität zu den Klassenboxen und somit zur Erleichterung der Auswertung werden die Dichtebereiche ebenfalls in viereckiger Form erstellt.

Der zu einem Cluster gehörende Dichtebereich  $D_i$  wird im Umfang eines iterativen Regionenwachstums ermittelt, das an der Stelle des Clusterschwerpunkts  $C_i$  mit kleiner Quadratgröße beginnt. Das Wachstum ist abgeschlossen, wenn entweder 80 % der zu dem speziellen Cluster gehörenden HAO Teil des Dichtebereichs sind, oder wenn die enthaltene Anzahl an HAO anderer Cluster mehr als 25 % (Wert abgeleitet aus Testläufen) der Anzahl an eigenen HAO beträgt. Mit dieser Einschränkung wird eine zu starke Überlappung der einzelnen Dichtebereiche und somit eine nicht repräsentative Darstellung der Cluster verhindert. In Abbildung 5.8 ist schematisch der Ablauf zur Erstellung der Dichtebereiche  $D_i$  vom Ausgangszustand (A) bis zum Endresultat

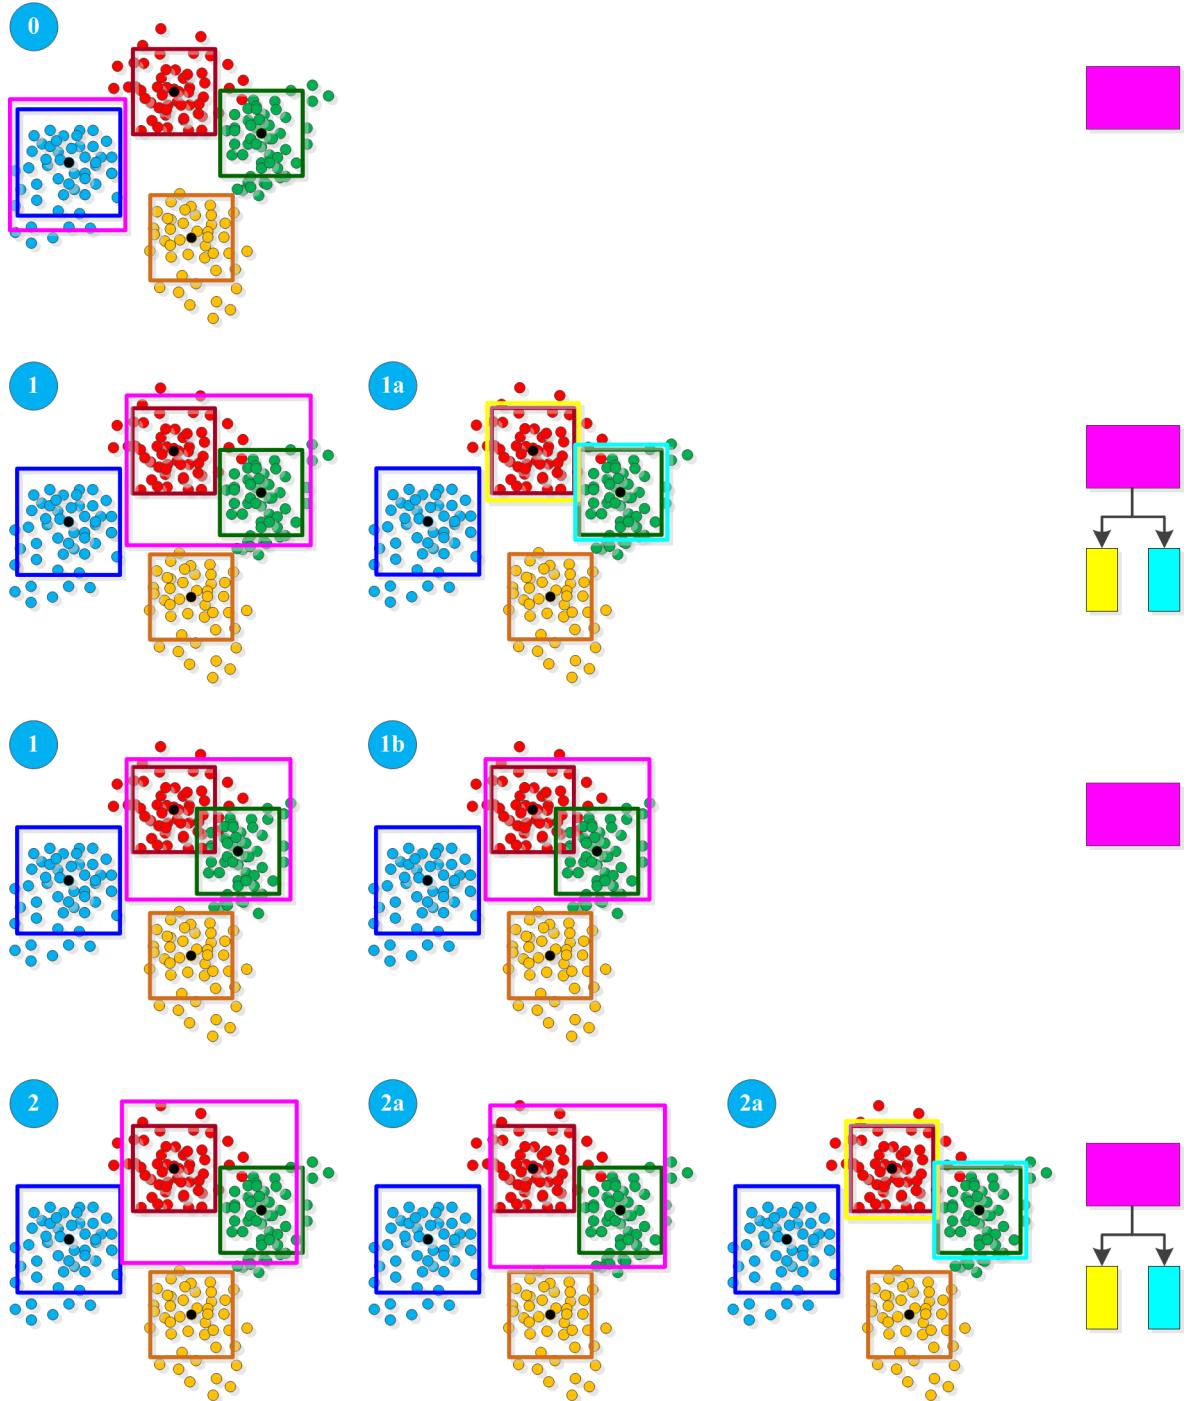


Abbildung 5.10.: Visualisierung der Komponenten der Fallunterscheidung, Fälle 0 bis 2a. Magenta-farbene Box: Initiale Beispielklasse.

(C) visualisiert. Die schwarz dargestellten Punkte sind die Schwerpunkte  $C_i$  der Kategorien.

### Fallunterscheidung

Den Kern der für jede initiale Klasse  $kl_j$  durchgeführten Rückprojektion nimmt der in Abbildung 5.7 als Fallunterscheidung bezeichnete Prozessierungsschritt ein. Als zentraler Eingabeparameter dient die Anzahl  $CL$  an dominanten Clustern, der darüber entscheidet, ob eine durch den Anwender selektierte Klasse durch den Algorithmus als *existent* oder *nicht existent* behandelt wird. Es werden vier Fälle unterschieden, wobei die Fälle 1, 2 und 3 jeweils noch eine Feinuntergliederung aufweisen (Abbildung 5.9).

Die beiden Kennzahlen  $CL$  (Anzahl dominanter Cluster je Klasse) und  $D$  (Dichtebereich eines Clusters) nehmen neben dem Parameter  $Z$  (Zerteilungsgrad) bedeutende Rollen bei der Rückprojektion ein. Der Zerteilungsgrad sagt aus, wie viele Cluster durch die jeweilige Klasse  $kl_j$  im 2D-Merkmalsraum zerteilt werden. Als Grundlage für die Bestimmung von  $Z$  dienen die Dichtebereiche  $D_i$ . Werden beispielsweise die

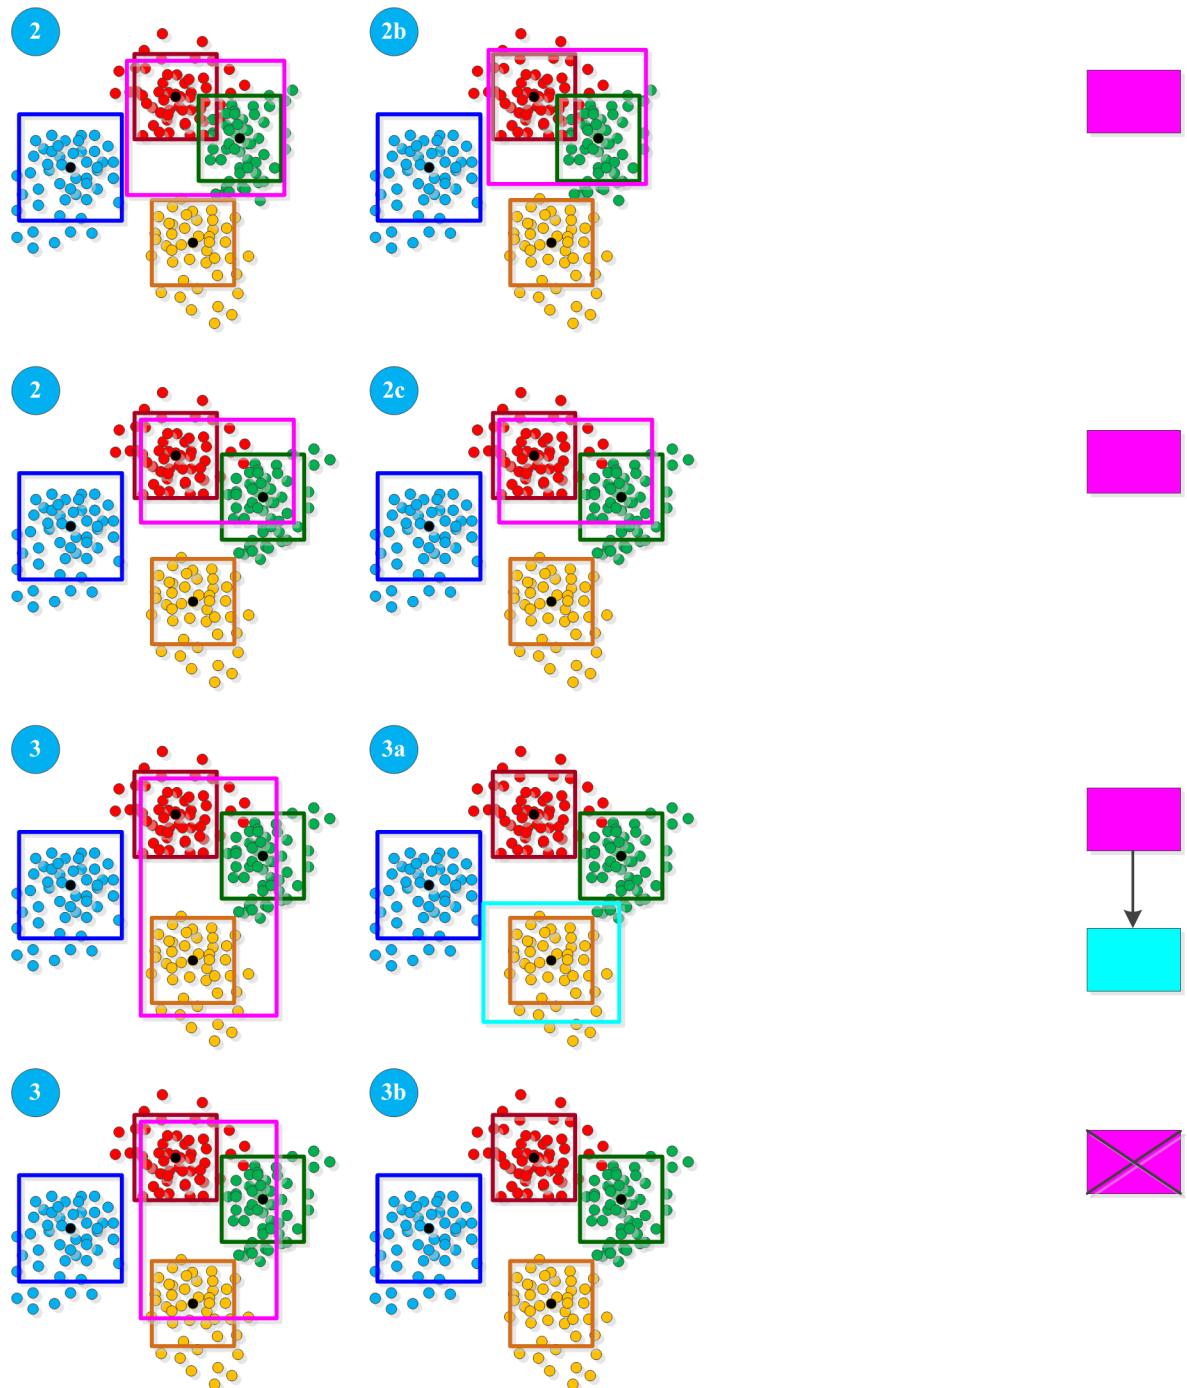


Abbildung 5.11.: Visualisierung der Komponenten der Fallunterscheidung, Fälle 2b bis 3b. Magenta-farbene Box: Initiale Beispielklasse.

Dichtebereiche zweier Cluster durch die Klasse nicht komplett abgedeckt, so resultiert ein Zerteilungsgrad von  $Z = 2$ . Im Optimalfall einer bestmöglich definierten Klasse ist  $Z = 0$ . Nachfolgend werden die einzelnen Komponenten der Fallunterscheidung erläutert. Eine visuelle Auflistung der einzelnen durch das Verfahren abgebildeten Fälle ist in den beiden Abbildungen 5.10 und 5.11 zu finden.

#### Fall 0 (Klasse existiert, $CL \leq k^*/2$ )

Dieser erste Fall verkörpert das zuvor beschriebene Szenario, wenn die Klasse  $kl_j$  bereits optimal definiert vorliegt und den Dichtebereich  $D$  genau eines Clusters vollständig abdeckt. Die Kennzahlen sind  $CL = 1$ ,  $D = 100$  und  $Z = 0$ , wobei der Wert für  $D$  in Prozent ausgedrückt wird. Eine Optimierung der Klasse  $kl_j$  ist in diesem Fall nicht notwendig.

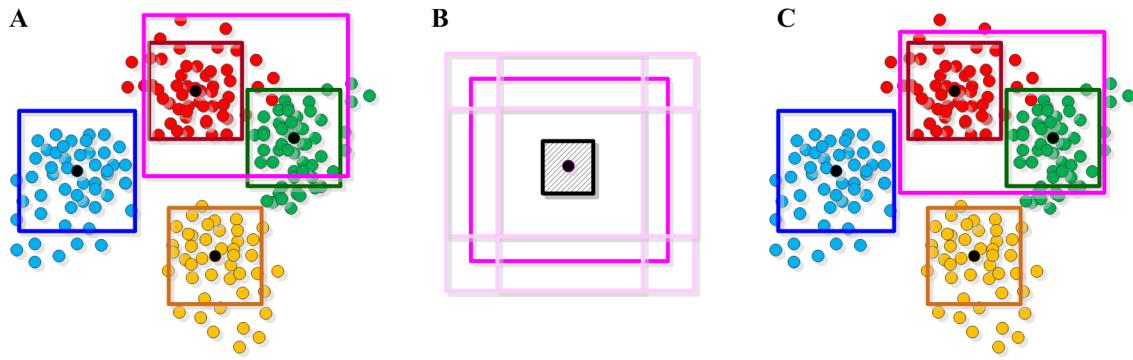


Abbildung 5.12.: Optimierende Verschiebung einer Klasse im Merkmalsraum. Magenta-farbene Box (A bis C): Beispielklasse; B: Suchbereich (schraffiert) um Klassenschwerpunkt (schwarzer Punkt) und Bereich der verschobenen Klassenboxen (schwach magenta-farben).

#### Fälle 1, 1a und 1b (Klasse existiert, $CL \leq k^*/2$ )

Eine optimal ausgewählte Klasse  $kl_j$ , die mehr als ein Cluster (vollständig) beinhaltet ( $D_i = 100, Z = 0$ ) wird im Rahmen einer Feinuntergliederung (Fälle 1a und 1b) hinsichtlich ihrer Eignung für eine Aufteilung in Unterklassen analysiert. Eine solche Aufteilung ist sinnvoll, wenn  $kl_j$  als eine eventuell zu grob selektierte *Elternklasse* identifiziert wird. Als anschauliches Beispiel kann ein Parkplatzbereich herangezogen werden, der exemplarisch zwei verschiedene aber dominante Kategorien (PKW und LKW) beinhaltet. Sind diese beiden Kategorien klar trennbar, können diese als eigenständige *Kindklassen* betrachtet werden. Auf diese Weise wird der Algorithmus dazu befähigt, für den Anwender verborgene aber in den Daten enthaltene Klassenstrukturen aufzufinden, was zur Wissensbildung über den jeweiligen Datensatz beiträgt. Die Entscheidung, ob die in einer Klasse befindlichen Kategorien voneinander abgrenzbar sind, erfolgt durch Analyse der Überlappungen der entsprechenden Dichtebereiche  $D_i$ .

Liegt eine Überlappung der beteiligten Kategorien von kleiner gleich 10 Prozent vor, wird eine Aufteilung der ursprünglichen Klasse vorgenommen (Fall 1a). Die Konstruktion der neu entstehenden Unterklassen erfolgt durch Regionenwachstum um die Schwerpunkte  $C_i$  der entsprechenden Cluster analog zu Abbildung 5.8. Das Regionenwachstum ist abgeschlossen, wenn der Zerteilungsgrad  $Z \neq 0$  ist. Als finales Resultat wird das diesem Status zuletzt vorangegangene Iterationsergebnis übernommen.

Überschreiden sich die an der Klasse beteiligten Cluster zu stark, wird keine Aufteilung vorgenommen (Fall 1b). Eine eindeutige Trennung der ursprünglich gewählten Klasse ist somit nicht möglich.

#### Fälle 2, 2a, 2b und 2c (Klasse existiert, $CL \leq k^*/2$ )

Ist eine Klasse  $kl_j$  zwar in den Daten vorhanden, aber nicht optimal durch den Anwender ausgewählt ( $Z \neq 0$ ), wird eine Optimierung durch das Verfahren geprüft. Diese Optimierung erfolgt durch Verschieben der die Klasse darstellenden Box im gerasterten 2D-Merkmalsraum innerhalb eines  $10 \times 10$  Pixel großen Fensters um den Klassenschwerpunkt  $S_{kl_j}$  (Abbildung 5.12).

Eine Vergrößerung oder Verkleinerung der Klasse findet bei der Verschiebung der Klasse nicht statt, die ursprünglich selektierte Klassengröße wird somit beibehalten. Es wird nur getestet, ob die vorgegebene Klasse im Merkmalsraum an leicht anderer Örtlichkeit eine bessere Konfiguration der Kennzahlen erreicht. Wird in dem lokalen Suchbereich um den Schwerpunkt der Klasse eine Örtlichkeit gefunden, die zu einer Verbesserung von  $CL$ , der  $D_i$ , oder von  $Z$  führt, so wird diese als neuer Schwerpunkt der Klasse  $kl_j$  übernommen. Falls nicht, wird die ursprüngliche Klassendefinition beibehalten (Fall 2c).

Resultiert aus der Verschiebung der Klasse im Merkmalsraum eine vollständige Abdeckung der beteiligten Kategorien ( $D_i = 100$ ) so wird analog zu Fall 1 geprüft, ob eine Aufteilung der initialen Klasse möglich ist (Fälle 2a und 2b).

In Abbildung 5.12 ist eine Klasse dargestellt (magenta-farbene Box), die im Merkmalsraum nicht optimal enthalten ist ( $Z \neq 0$ ). Der schraffierte Bereich in Schritt B kennzeichnet den Suchbereich um den Klassenschwerpunkt (schwarzer Punkt). Die in schwächerem Magenta dargestellten Boxen entsprechen den Abbildungen der Klasse, wenn der aktuelle Schwerpunkt mit den Eckpunkten des Suchbereichs zusammenfällt. In Schritt C ist das Resultat der optimierenden Klassenverschiebung gegeben ( $Z = 0$ ), das in diesem Fall auf eine mögliche Aufteilung in Unterklassen getestet werden würde.

#### Fälle 3, 3a und 3b (Klasse existiert nicht, $CL > k^*/2$ )

Gegenüber den bisher behandelten Fällen liegt hier eine vordefinierte Klasse  $kl_j$  zugrunde, die über keine dominant ausgeprägte Kategorienstruktur verfügt, da  $CL$  den vorgegebenen Schwellwert  $CL_\tau$  übersteigt.

Dieser Umstand kann resultieren, wenn  $kl_j$  durch den Anwender zu groß gewählt wird. Der Algorithmus prüft diese ungenaue Auswahl und ob mindestens eine Kategorie durch  $kl_j$  vollständig abgedeckt wird. Ist dies der Fall, wird dem Nutzer eine Neudefinition der Klasse vorgeschlagen (Fall 3a), die zum Verständnis der Szenerie und dem vorliegenden Informationsgehalt sowie zur Verbesserung des Klassenkatalogs beiträgt. Es wird dementsprechend eine möglicherweise bessere Formulierung der Klasse erzielt, falls die ursprünglich selektierte Klasse in der Datenrealität nicht vorgefunden wird. Die Neudefinition von  $kl_j$  erfolgt in analoger Form zum oben abgebildeten Regionenwachstum (Abbildung 5.8), ausgehend von den jeweiligen Clusterschwerpunkten  $C_i$ .

Deckt hingegen die Klasse im 2D-Merkmalsraum mehr als  $k^*/2$  Kategorien ab, ohne mindestens einen Dichtebereich davon vollständig zu enthalten, wird diese initiale Klasse gelöscht (Fall 3b).

Nach der Fallunterscheidung für jede der vordefinierten Klassen liegt eine neue Version des Katalogs in optimierter Form vor (Abbildung 5.7). Dieser verbesserte Klassenkatalog wird als Grundlage für die finale Klassifikation der HAO verwendet. Der nachfolgende Abschnitt enthält dazu entsprechende Ausführungen.

### 5.2.5. Optimierter Klassenkatalog und Zuweisung

Der optimierte Klassenkatalog wird in dem finalen Verarbeitungsschritt für die Zuweisung der Hochaktivitätsobjekte zu den am wahrscheinlichsten Klassen verwendet. Die Modellierung dieser Wahrscheinlichkeit, hier ausgedrückt in prozentualer Klassenzugehörigkeit nach dem Prinzip der Fuzzy-Logik (siehe Abschnitt 2.2.7), wird durch die mögliche Überlappung der Klassenregionen im 2D-Merkmalsraum notwendig.

Zunächst erscheinen sich überlappende und teilweise auch vollständig umgebende Klassen hinderlich, da ein Klassifikationsresultat generell so eindeutig und präzise wie möglich sein soll. Im Hinblick auf das Ziel der Wissensvermittlung an den Anwender durch das Verfahren stellen sich umgebende (beziehungsweise einschließende) oder überlappende Klassen wichtige Informationen zur Verfügung. Man stelle sich eine zunächst nicht in den Daten abbildbare, durch den Anwender selektierte Klasse vor, die im Zuge der fallunterscheidenden Rückprojektion neu definiert wird. Diese neue Klasse wird im Regelfall einen kleinen Bereich im 2D-Merkmalsraum abdecken, was durch das schwerpunktbasierter Regionenwachstum begründet ist. Im Umkehrschluss bedeutet dies, dass diese neue, kleine Klasse durchaus von einer anderen, größeren, aber in den Daten existenten Klasse vollständig umschlossen wird. Es liegt nun beim Anwender, in interaktiver Art und Weise zu überprüfen, ob diese neu definierte Klasse tatsächlich als Teilmenge einer umgebenden Klasse anzusehen ist. Diese Überprüfung kann anhand des Klassifikationsresultats erfolgen, das die HAO im Ortsraum mit ihrer Klassenzugehörigkeit visualisiert. Demzufolge wird durch das Verfahren nützliche Information hinsichtlich der tatsächlich durch die Daten abbildbaren Klassenstruktur bereitgestellt.

Aus der möglichen Überlappung der in der finalen Klassenbeschreibung enthaltenen Regionen folgt als Konsequenz, dass ein bestimmtes HAO in Abhängigkeit seiner Lage im Merkmalsraum zu verschiedenen Klassen mehr oder weniger wahrscheinlich gehört. Damit aus der Lage eines HAO im Merkmalsraum ein Zugehörigkeitsgrad zu einer bestimmten Klasse ermittelt werden kann, werden für die finalen Klassenregionen Fuzzy-Zugehörigkeitsbereiche festgelegt. Der Grundgedanke dahinter ist, dass im Lagezentrum einer Klasse die Wahrscheinlichkeit der Zugehörigkeit eines HAO zu dieser Klasse am höchsten ist und zu den Randregionen der Klassenbox abnimmt. Zur Modellierung dieser Annahme werden klassenboxbezogene normalverteilte Zugehörigkeitsfunktionen genutzt. Dies bedeutet, dass für beide Achsen einer Klassenbox (erste und zweite Hauptkomponente der reduzierten Merkmalsmatrix; Abschnitt 5.2.4) je eine Gauß-Funktion entsprechend der beiden Wertintervalle der Klassenregion im Merkmalsraum berechnet wird, wobei das Zentrum der Verteilung mit dem Schwerpunkt der Klasse übereinstimmt (Abbildung 5.13, links).

Der prozentuale Zugehörigkeitswertebereich  $v[\%] = [0; 100]$  wird, wie in Abbildung 5.13 visualisiert, in fünf Abschnitte eingeteilt, die sich anhand eingangs vorgenommener Testläufe als zweckmäßig ergeben haben: 0 - 10 (rot), 11 - 25 (gelb), 26 - 50 (cyan), 51 - 75 (grün) und 76 - 100 (weiß). Ob ein Änderungsobjekt zu einer spezifischen Klasse gehört, wird mit einem durch den Anwender vorgegebenen Schwellwert  $z$  entschieden, der mit der relativen Lage des HAO im den die Zugehörigkeitsbereiche enthaltenen Merkmalsraum verglichen wird. Wird beispielsweise  $z = 50$  vorgegeben, so ist ein spezifisches HAO Teil einer bestimmten Klasse, wenn das Änderungsobjekt mindestens im grünen Zugehörigkeitsbereich liegt.

Das Prinzip der Klassenzuweisung ist in Abbildung 5.13 auf der rechten Seite visualisiert, wobei zwei HAO (schwarz und magenta-farben) als Beispiel dienen sollen. Es sind drei Klassen A, B und C gegeben, die sich im 2D-Merkmalsraum überlappen. Der Kreis im Zentrum der jeweiligen Klasse kennzeichnet den Klassenschwerpunkt. Das schwarze HAO wird der Klasse A zugewiesen, da der zu dieser Klasse entsprechende Zugehörigkeitsbereich (gelb) eine höhere Wahrscheinlichkeit darstellt als der rote Bereich der Klasse B. Hierbei muss auch der eingestellte Wert  $z$  beachtet werden. Wäre in diesem Beispiel  $z = 50$ , würde das

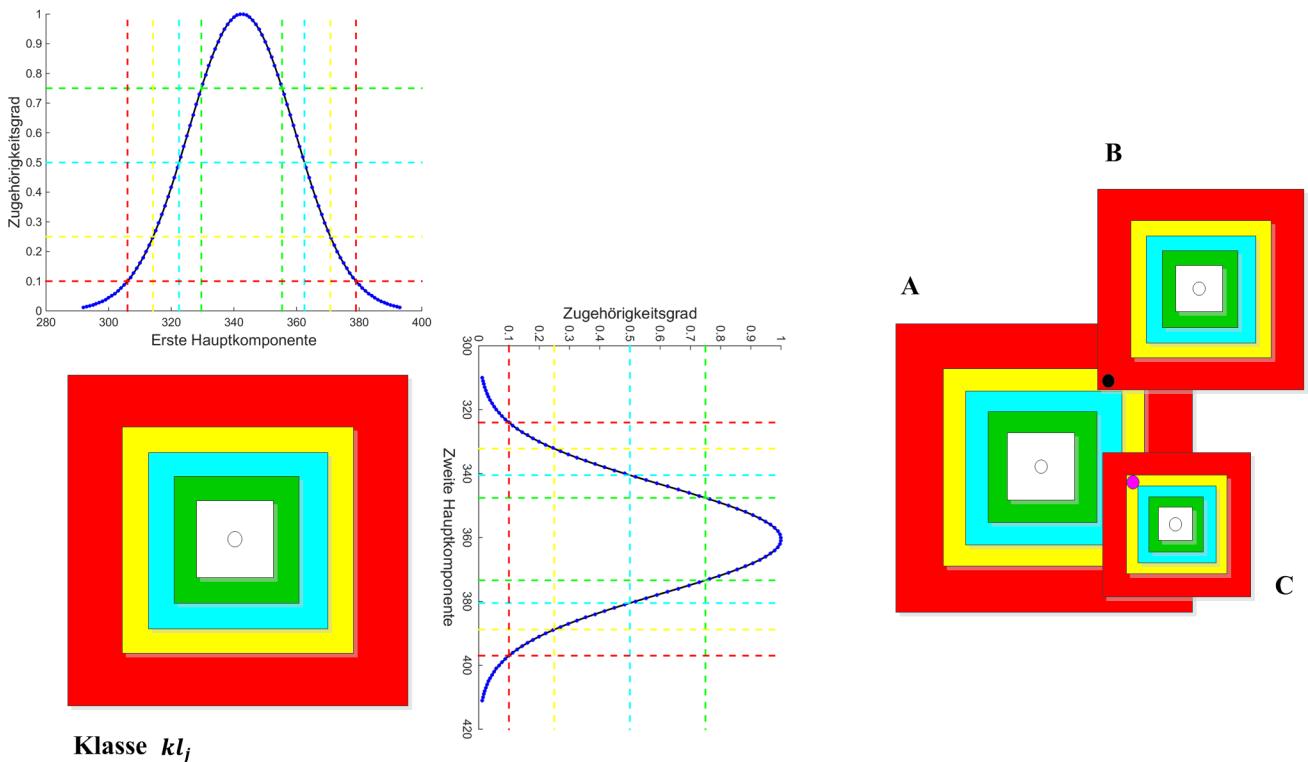


Abbildung 5.13.: Fuzzy-Zugehörigkeitsbereiche einer Klasse  $kl_j$  (links) und Klassenzuweisung mit den drei Beispielklassen A bis C (rechts).

schwarze HAO keiner der beiden Klassen A oder B zugewiesen werden. Liegt ein HAO wie das magenta-farbene im gleichen Zugehörigkeitsbereich zweier Klassen, so wird der Euklidische Abstand des HAO zu den beteiligten Klassenschwerpunkten analysiert. Erlaubt der Schwellwert  $z$  eine Zuweisung, bekommt die Klasse den Zuschlag, deren Schwerpunkt näher am HAO liegt. Im dargestellten Fall wird das HAO der Klasse C zugewiesen.

In Anbetracht des Schwellwerts kann somit analog zu den Ausführungen in Abschnitt 2.2.7 resümiert werden, dass die Anzahl klassifizierter HAO mit größer gewähltem  $z$  abnimmt. Tendenziell ergibt sich so ein präziseres, da aussagekräftigeres Klassifikationsergebnis. Unterschiedlich gewählte Werte für  $z$  sind Gegenstand der Untersuchungen in Abschnitt 6.3.7, wo die Auswirkung auf das Klassifikationsresultat basierend auf dem primär genutzten Datensatz „Stuttgart Flughafen“ diskutiert wird.

Das finale Klassifikationsresultat wird als Kartendarstellung bereitgestellt, wobei die einzelnen HAO entsprechend ihrer Klassenzugehörigkeit farbkodiert werden.

Nach der Durchführung der Klassenzuweisung folgt abschließend die Ausgabe von Informationen, die den final vorliegenden Klassenkatalog beschreiben und eine durch den Anwender vorzunehmende Interpretation erleichtern.

### 5.2.6. Klassenbeschreibung

Neben dem bildlich dargestellten Klassifikationsresultat werden für die final vorliegenden Klassen unterschiedliche, die Interpretation unterstützende Beschreibungen ermittelt. Die wohl anschaulichste Beschreibung wird durch die HAO-basierte Zuweisung der Kontextklasse bereitgestellt. Nachfolgend sind die einzelnen Ausgaben erläutert.

#### Kontextklasse

Der lokale Kontext bezeichnet in dieser Arbeit ein HAO-bezogenes Merkmal mit binärem Wertebereich. Das bedeutet, dass ein bestimmtes HAO Teil einer beispielsweise durch den Anwender vorgegebenen, oder durch bereits verfügbare LULC-Kartierungen definierten Kontextklasse sein kann (Wert Eins). Ist kein passender lokaler Kontext extrahierbar, so besitzt das HAO den Wert Null (unklassifiziert). Anhand der zu einer finalen Klasse gehörenden HAO wird die Ausprägung der verschiedenen Kontextklassen durch Visualisierung der

prozentualen Anteile erstellt. Diese Darstellung vermittelt somit einen Eindruck über die lokalen semantischen Begebenheiten einer Klasse. Auf diese Weise wird insbesondere die Interpretation neu definierter Klassen des Katalogs für den Nutzer erleichtert.

### **Räumliche Ausdehnung und Begrenztheit**

Bezug nehmend zu den Erläuterungen in Abschnitt 4.2.1 werden für jede der final vorliegenden Klassen des optimierten Katalogs die Statistiken zur räumlichen Ausdehnung und Begrenztheit ermittelt. Auf diese Weise soll geprüft werden, ob klassenbezogene Muster hinsichtlich dieser beiden Kenngrößen ableitbar sind.

### **Formparameter**

Die in Abschnitt 2.2.4 beschriebenen Formparameter, die im Zuge der Segmentierung der lokalen Änderungs-umgebung für jedes, ein HAO umgebendes Segment extrahiert werden (Abschnitt 4.2.1), dienen ebenfalls zur Klassenbeschreibung. Für jede der final vorliegenden Klassen wird dem Nutzer ein Histogramm zur Verfügung gestellt, in dem die Parameterwerte der in dieser Klasse befindlichen HAO aufgeführt sind. In den Abschnitten 6.2.6 und 6.2.7 wird darauf näher eingegangen.

### **Klassifikationsbasierte Informationen**

Ein Resultat der im vorangegangenen Abschnitt beschriebenen Klassenzuweisung basierend auf dem aus der Rückprojektion entstandenen Klassenkatalog ist die Darstellung der entsprechend ihrer Klassenzugehörigkeit eingefärbten HAO im Ortsraum.

Darüber hinaus kann der initial manuell selektierte Klassenkatalog mit dem final vorliegenden Katalog verglichen werden. Hierzu werden die zu einer ursprünglichen Klassenregion gehörenden HAO hinsichtlich ihrer durch das Verfahren ermittelten Klassenzugehörigkeit ausgewertet. Letzten Endes kann auf diese Weise überprüft werden, inwieweit der initiale Klassenkatalog mit dem optimierten Katalog übereinstimmt. Die Ergebnisse der Rückprojektion und der Klassenzuweisung werden somit neben der bildlichen Visualisierung in anderer, komplementärer Art dargestellt.

Als weitere klassifikationsbasierte Ausgabe werden statistische Informationen zum Klassifikationsergebnis bereitgestellt. Diese umfasst die Anzahl der insgesamt vorliegenden HAO, die Anzahl der den einzelnen Klassen zugewiesenen HAO, sowie die Anzahl jener HAO, die keiner Klasse zugewiesen worden sind. Eine zentrale Aussage ist mit dieser Auflistung extrahierbar. So kann die Anzahl unklassifizierter HAO auf einen zu stringent gewählten Schwellwert  $z$  zur Modellierung der Fuzzy-Klassenzugehörigkeit hinweisen. Diese Information liefert somit Erkenntnisse, die zu einem stärkeren Verständnis der Daten beitragen und gegebenenfalls eine Schwellwertanpassung erfordern.

Die in den Abschnitten 3.2.2 (Aktivitätscluster) und 3.2.3 (Hochaktivitätsstapel) beschriebenen Zusammenhänge werden in Abschnitt 6.3.4 detaillierter untersucht. Es wird insbesondere die Fragestellung diskutiert, ob mit dieser raumzeitlichen Analyse klassenspezifische Ausprägungen ableitbar sind.



# **Kapitel 6.**

## **Resultate und Bewertung**

Die vorangegangenen Kapitel 1 bis 5 vermittelten einen Überblick über die Motivation, die notwendigen theoretischen Grundlagen sowie die konzeptionellen Abläufe der verwendeten und entwickelten Verfahrensbestandteile. Diese Inhalte und Zusammenhänge werden nachstehend auf zwei voneinander unabhängige Testdatensätze („Stuttgart Flughafen“ und „Greding“) angewendet, wobei die Stuttgarter Szene primär genutzt wird. Der sekundäre Datensatz „Greding“ nimmt eine verifizierende Funktion ein.

Eine Beschreibung der beiden Szenen, sowie deren Vorverarbeitung für die vorgestellte Methode ist in Abschnitt 6.1 enthalten. Die Ergebnisse aus der Anwendung des Verfahrens zur Änderungsanalyse sind Bestandteil von Abschnitt 6.2. Die Untergliederung dieses Abschnitts erfolgt analog zur Abfolge der zuvor erläuterten Verarbeitungsschritte und beginnt mit der Identifikation der Hochaktivitätsobjekte.

Im letzten Abschnitt des Kapitels werden Parametervariationen sowie Untersuchungen im Zusammenhang der entwickelten Methoden thematisiert (exemplarisch: Verifikation der DAP-basierten Segmentierungsme thode). Zum Ende des Abschnitts 6.3 ist eine zusammenfassende Diskussion der gewonnenen Erkenntnisse zu finden.

Nr.	Datum (TT.MM.JJ)	Uhrzeit (UTC / MEZ)	Orbit	Polarisation	Einfallsinkel [°]	Pixelabstand Slant Range [m]	Pixelabstand Slant Azimuth [m]	Sensor	Intervall [Tage]
1	10.11.13	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	
2	04.01.14	17:00 / 18:00	ASC	HH	22,72	0,59	0,86	TSX	55
3	06.02.14	17:00 / 18:00	ASC	HH	22,72	0,59	0,86	TSX	33
4	28.02.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	22
5	11.03.14	17:00 / 18:00	ASC	HH	22,72	0,59	0,86	TSX	11
6	22.03.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	11
7	02.04.14	17:00 / 18:00	ASC	HH	22,71	0,59	0,86	TSX	11
8	13.04.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	11
9	05.05.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	22
10	16.05.14	17:00 / 18:00	ASC	HH	22,72	0,59	0,86	TSX	11
11	10.07.14	17:00 / 18:00	ASC	HH	22,72	0,59	0,86	TSX	55
12	23.08.14	17:00 / 18:00	ASC	HH	22,71	0,59	0,86	TSX	44
13	06.10.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	44
14	28.10.14	17:00 / 18:00	ASC	HH	22,73	0,59	0,86	TSX	22
15	08.11.14	17:00 / 18:00	ASC	HH	22,71	0,59	0,86	TSX	11

Tabelle 6.1.: Zeitreihe aus SLC-Daten (Datensatz „Stuttgart Flughafen“).

## 6.1. Daten und Vorverarbeitung

Als notwendige Eingabedaten für die hier vorgestellte Methode zur Änderungsanalyse (Änderungsdetektion, Kategorisierung und Klassifikation) sind ausschließlich Zeitreihen aus SAR SLC-Aufnahmen zu nennen. Die in Abschnitt 4.2.1 beschriebenen Referenzdaten zur Segmentierung der lokalen Änderungsumgebung dienen unter anderem zur Extraktion binärer Merkmale (Kontextklasse), die als Teil der Klassenbeschreibung keine maßgebliche Funktion in der datenverarbeitenden Prozesskette einnehmen. Darüber hinaus ist die Bestimmung der Kontextklasse so gestaltet, dass im Optimalfall keinerlei Interaktion mit dem Anwender erfolgen muss (siehe Abschnitt 4.2.1). Weitere, nachfolgend erwähnte Daten (exemplarisch: optische Satellitenbilder) werden zur Verifikation der Verarbeitungsweise und der ermittelten Resultate eingesetzt.

Die Stuttgarter Szenerie ist eine für die vorgestellte Methode zur Änderungsanalyse ideale Datengrundlage, da sie eine sehr heterogene LULC-Struktur beinhaltet. In Konsequenz bedeutet dies, dass verschiedene Änderungsbereiche und somit Änderungskategorien enthalten sein können, was für die Entwicklung, Anwendung und Verifikation der Methode vorteilhaft ist. In Abschnitt 6.1.1 ist eine Beschreibung der Stuttgarter Daten gegeben.

Als sekundäre, zur Verifikation eingesetzte Testszenen wird eine Zeitreihe aus SLC-Bildern berücksichtigt, die den Ort Greding zeigen. Gegenüber der primären Testszene enthält dieser Datensatz eine weitaus geringere Anzahl an Hochaktivitätsobjekten, was durch die vergleichsweise ländlichere Örtlichkeit begründet ist. Für die Beurteilung des Verfahrens ist dies nicht von Nachteil, da auf diese Weise seine Funktionalität auf Basis einer veränderten Datensituation geprüft werden kann.

Neben der Beschreibung der beiden Testszenen und der vorliegenden Referenzdaten werden notwendige Vorverarbeitungsschritte dargelegt.

### 6.1.1. Szene „Stuttgart Flughafen“

Der Datensatz „Stuttgart Flughafen“ besteht aus vier Komponenten: SAR, Optisch, GIS und Höhenmodell.

## SAR

Die Zeitreihe aus SLC-Bildern ist die Kernkomponente des Datensatzes, da sie die notwendige Eingabeinformation für das entwickelte Verfahren darstellt. Diese ist hier durch 15 zeitlich unregelmäßig aufeinander folgende TSX-Aufnahmen im Zeitraum von einem Jahr (11/2013 bis 11/2014) gegeben (Tabelle 6.1). In Abbildung 6.1, oben, ist das mittlere Amplitudenbild der Zeitreihe visualisiert.

Das für dieses Sensorsystem minimal mögliche Intervall zwischen zwei Aufnahmen derselben Szene zu identischen Aufnahmeparametern liegt bei 11 Tagen. Aufgrund verschiedener Gründe wie beispielsweise Wartungsarbeiten war die Einhaltung dieses Abstandes über die beobachtete Zeitspanne nicht immer möglich. Dieser Umstand kann als vorteilhaft betrachtet werden, da eine solche unregelmäßige Zeitreihe eher als realitätsnah anzusehen ist, als ein Bildstapel mit jeweils identischem Intervall zwischen den Aufnahmezeitpunkten. In Tabelle 6.1 sind weiterhin die Aufnahmeparameter gelistet, wobei „ASC“ für aufsteigende Orbitrichtung, „UTC“ für die koordinierte Weltzeit (*Universal Time Coordinated*) und „MEZ“ für die mitteleuropäische Zeit steht. In der Spalte „Einfallswinkel“ sind die jeweiligen lokalen Beleuchtungswinkel  $\theta$  mit Bezug zur abgebildeten Szenenmitte enthalten. Es ist ersichtlich, dass die Aufnahmekonfiguration über die Zeitreihe hinweg nahezu identisch war. Alle Bilder wurden im HS300-Modus (siehe [107]) unter Nutzung des hochpräzisen *Science-Orbits* (Abschnitt 3.1) aufgezeichnet. Dieser Umstand ermöglicht die pixelgenaue Registrierung der Zeitreihenbilder mittels Orthorektifizierung.

Das geographische Zentrum der Szene befindet sich bei  $48,68^\circ$  (Breite) und  $9,216^\circ$  (Länge) (Bezugsellipsoid: WGS84) und beinhaltet sehr unterschiedliche LULC-Arten. Der suburbane Bereich des Flughafens (Abbildung 6.1, 1), der flächenmäßig ( $4000 \times 1600$  Pixel) ungefähr ein Zehntel der abgebildeten Szene ( $10200 \times 6000$  Pixel, Schrägsichtgeometrie) einnimmt, befindet sich in der Szenenmitte. Die Szenenausdehnung reicht im Nordwesten von einem kleinen Ausschnitt der Ortschaft Leinfelden-Echterdingen (Abbildung 6.1, 2) bis im Südosten zu einer vollständigen Abdeckung des Orts Neuhausen auf den Fildern (Abbildung 6.1, 3). Der westliche Rand der Szene ist durch Waldgebiete (Abbildung 6.1, 4), der östliche Rand durch rurale und urbane Strukturen (Abbildung 6.1, 5, 3) gekennzeichnet. Im Norden der Szenerie befindet sich ein Teil von Plieningen (Abbildung 6.1, 12), im Süden ist ein Ausschnitt der Ortschaft Bonlanden (Abbildung 6.1, 13) abgebildet. Als zentrale Verkehrswände in West-Ost (Ost-West) und Nord-Süd (Süd-Nord) Richtung sind die Autobahn A8 und die Bundesstraße B27 zu nennen, die im Zusammenhang mit der Detektion bewegter Zielobjekten in [205] analysiert wurden.

Zusammenfassend ist zu erwähnen, dass sich die Szene aus urbanen, suburbanen, industriellen (Abbildung 6.1, 6, 9) und ruralen Bereichen sowie Waldgebieten und Infrastruktur zusammensetzt. Insbesondere der große Anteil an industriellen Gebieten ist im Hinblick auf die Detektion kleinräumiger Änderungen essentiell, da diese exemplarisch sehr viele Parkplätze beinhalten. Aus der großen Variation an LULC-Typen folgt potentiell eine große Anzahl verschiedener Änderungskategorien. Für die vorliegende Aufgabenstellung ist dies vorteilhaft, da so die Funktionalität des Verfahrens und seine Potentiale und Schwächen erprobt werden können. Beispielsweise kann bei der Erstellung des initialen Klassenkatalogs sowohl eine geringe, als auch große Anzahl an verschiedenen Klassen vorgegeben werden.

## Vorverarbeitung

Neben der alleinigen Amplitudeninformation werden weitere Eingabedaten zur Ableitung von Merkmalen genutzt (Kapitel 4), die aus dem vorliegenden SLC-Stapel extrahierbar sind. Hierbei handelt es sich einerseits um die radiometrisch kalibrierten  $\sigma^0$ -Intensitätsbilder und andererseits um die gemäß Formel (2.16) aus der komplexwertigen Bildinformation berechneten Kohärenzbilder als Bestandteil der (hier: 14) CovAm-Coh-Bilder, die bei der Ermittlung der HAO-bezogenen Kontextklasse als Alternative zu den GIS-Daten Verwendung finden (Abschnitt 4.2.1). Zur Feinregistrierung als Voraussetzung für die Berechnung der Kohärenzbilder wurde die Software ENVI von Exelis Visual Information Solutions mit der SARscape-Funktionalität verwendet.

Der zentrale Vorverarbeitungsschritt ist die Projektion auf ein quadratisches Raster (Pixelgröße  $1 \times 1$  Meter) mit einheitlichem Bezugssystem (hier: UTM Koordinatensystem, WGS84 Ellipsoid) (vergleiche auch Abschnitt 3.1). Diese Projektion aller Komponentenbilder der Zeitreihe auf die einheitliche UTM-Kartendarstellung erfolgt mittels eines, die komplette Szenerie abdeckenden Höhenmodells (siehe unten). Als Software für die Orthorektifizierung wird ERDAS IMAGINE (Version 2014) von Hexagon Geospatial mit der OrthoRadar-Funktionalität der Radar Toolbox verwendet. Als Resampling-Methode wird Nearest Neighbor gewählt. Die orthorektifizierten Bilder haben jeweils eine Größe von  $12910 \times 7509$  Pixel (Pixelgröße  $1 \times 1$  m), wobei durch die Kartenprojektion neben der eigentlichen Bildinformation auch sogenannte Hintergrundpixel enthalten sind (siehe Abbildung 6.1), die auf die nachfolgende Prozessierung (automatische Schwellwertberechnung zur Änderungsdetektion) keinen Einfluss nehmen (Abschnitt 3.1).

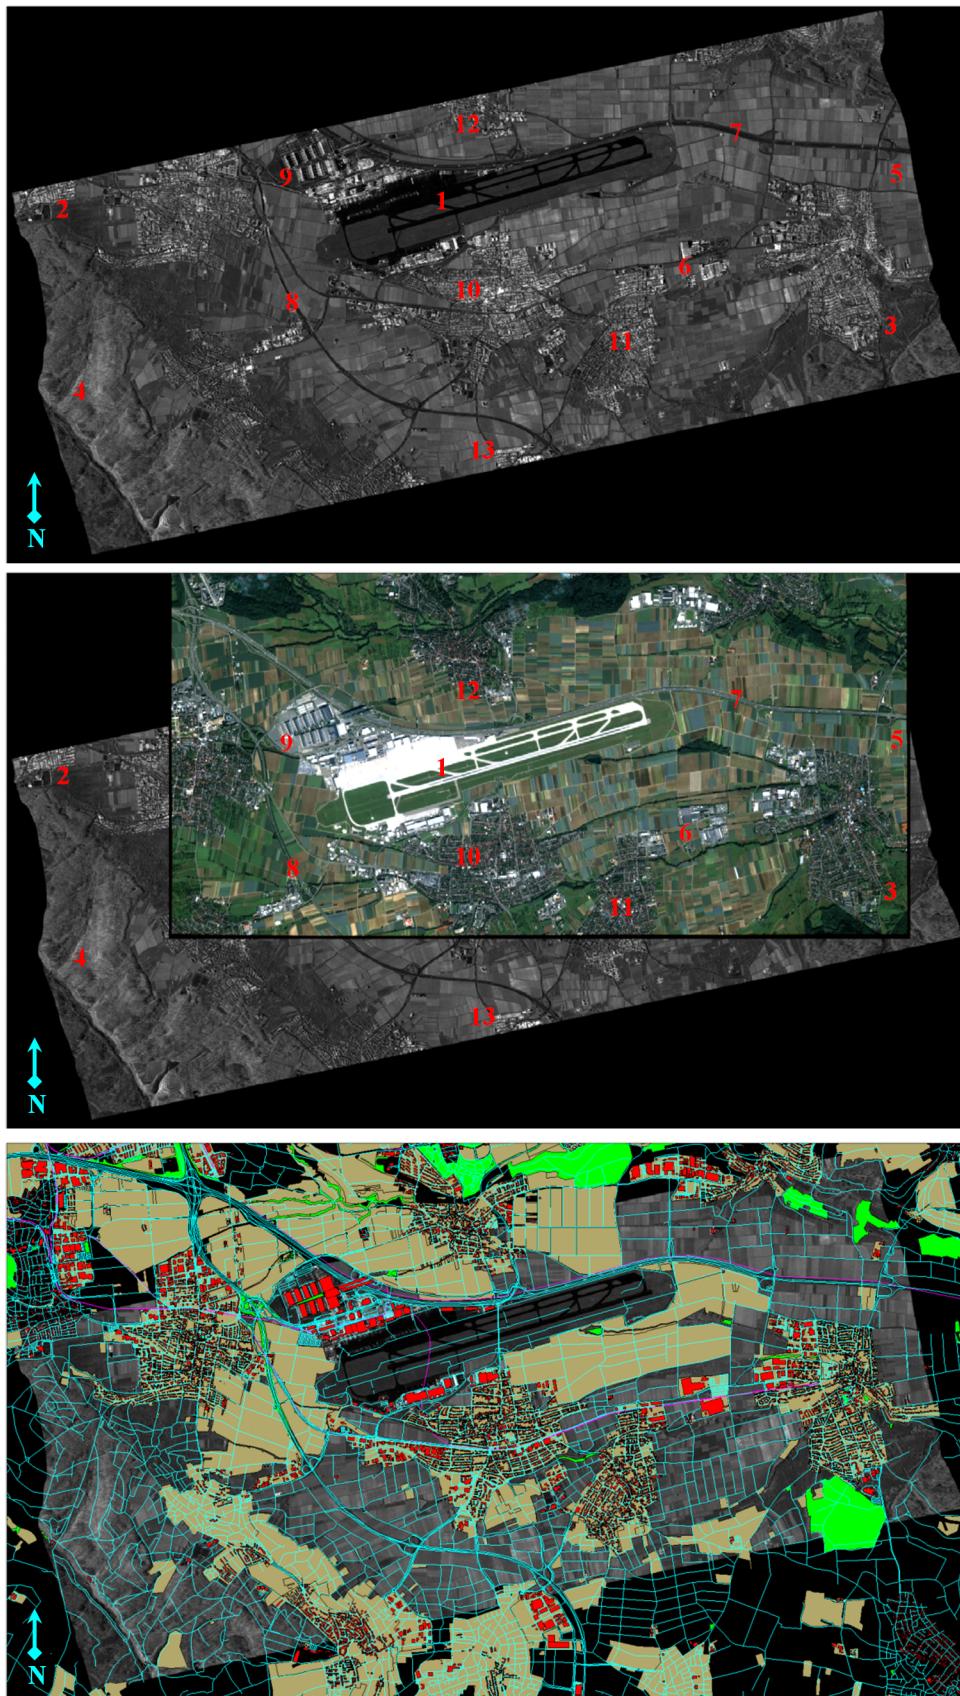


Abbildung 6.1.: Datensatz „Stuttgart Flughafen“, oben: Mittleres Amplitudenbild der Zeitreihe, Mitte: Mittleres Amplitudenbild der Zeitreihe mit überlagertem WV-2-Bild, unten: Mittleres Amplitudenbild der Zeitreihe mit überlagerten OSM-Layern. 1: Flughafen, 2: Leinfelden-Echterdingen, 3: Neuhausen auf den Fildern, 4: Wald, 5: Rural, 6: Industriebereich, 7: Autobahn A8, 8: Bundesstraße B27, 9: Messe Stuttgart, 10: Filderstadt, 11: Sielmingen, 12: Plieningen, 13: Bonlanden.

## **Optisch**

Die verfügbaren optischen Bilddaten setzen sich aus Satellitendaten, fotografischen Aufnahmen ausgesuchter Örtlichkeiten der Szene und aus Screenshots von Webcam-Aufnahmen verschiedener Bereiche des Flughafen-gebiets zusammen.

### **WorldView-2**

In Abbildung 6.1, Mitte, ist die WV-2-Szene dem mittleren Amplitudenbild der Zeitreihe überlagert dargestellt. Die Aufnahme stammt vom 24.08.2011 (Uhrzeit: 10:59 UTC) und kann somit nicht in direkter Weise mit der Szene verglichen werden, die erst zwei Jahre später von TSX aufgezeichnet wurde. Das WV-2-Bild kommt dementsprechend nur zur Verifikation unklarer LULC-Arten zum Einsatz und soll insbesondere den in der SAR-Bildauswertung ungeübten Anwender bei der Selektion des initialen Klassenkatalogs unterstützen. Der WV-2-Datensatz umfasst ein panchromatisches Bild hoher räumlicher Auflösung (0,46 m, Nadir) und ein multispektrales Bild (acht Kanäle) niederer Auflösung (1,84 m, Nadir) [5].

### **Fotomaterial**

Zur Verifikation einiger ausgewählter Hochaktivitätsgebiete wurden im Rahmen von Ortsbegehungen zu zwei Zeitpunkten Fotos aufgenommen. Es konnten zehn Bereiche betrachtet werden, die verschiedene Aktivitätsgebiete (PKW- und LKW-Parkplätze, Sammelstellen, Be- und Entladestellen, Baustellen) beinhalten. Im Anhang A befinden sich Abbildungen zu diesen Bereichen (Abbildungen A.2 und A.3).

### **Webcam**

Zeitgleich zu den jeweiligen SAR-Aufnahmen (Tabelle 6.1) wurden im Internet frei verfügbare Webcam-Bilder einiger Abschnitte des Flughafenvorfelds via Bildschirmaufnahme (*Screenshot*) extrahiert. Da auf diese Weise der direkte Bezug zu detektierten Änderungen hergestellt werden kann, können diese Aufnahme zur Beurteilung der Detektionsgüte verwendet (siehe auch Abschnitt 6.3.1) werden.

### **Vorverarbeitung**

Zur Verbesserung des visuellen Informationsgehalts wird die räumliche Auflösung des WV-2-Datensatzes bei gleichzeitiger Berücksichtigung der spektralen Information pangeschärft (*Pansharpening*). Für diese Verarbeitung stehen beispielsweise in *ERDAS IMAGINE* (Version 2014) verschiedene Methoden in der Funktionalität *Pan Sharpen* zur Verfügung, von denen aufgrund seiner einfachen Bedienbarkeit sowie schnellen Verarbeitung die Option *HCS Resolution Merge* genutzt wird. Das Ergebnisbild wird schließlich noch zur Wahrung der Einheitlichkeit zum SAR-Datensatz von seiner ursprünglichen geographischen Koordinatenreferenz in das UTM-System überführt. Als *Resampling*-Methode wird auch hier *Nearest Neighbor* eingesetzt.

Das im Rahmen der Ortsbegehungen aufgenommene Fotomaterial sowie die Webcam-Aufnahmen müssen nicht in spezieller Art vorverarbeitet werden. Im Fall der Webcam-Bilder wurde eine Vorauswahl durchgeführt, um für die Evaluierung des Verfahrens geeignete Bilder verwenden zu können (siehe auch Abschnitt 6.3.1).

## **GIS**

In den Abschnitten 1.1 und 4.2.1 wurde bereits der Mehrwert dargestellt, der durch die frei nutzbaren OSM-Vektorlayer entsteht. In der vorliegenden Arbeit dient diese Referenzinformation zur unüberwachten Ableitung der zu einem spezifischen Hochaktivitätsobjekt gehörenden Kontextklasse. Das Wissen um die Kontextklasse dient dazu, den Anwender bei der Interpretation der Analyseresultate zusätzlich zu unterstützen. In Abbildung 6.1, unten, sind die hier genutzten Vektorlayer dem mittleren Amplitudenbild überlagert dargestellt.

### **Vorverarbeitung**

Da die OSM-Daten Vektorlayer sind, ist eine kombinierte bildverarbeitende Analyse mit den weiteren, als Raster vorliegenden Daten nicht unmittelbar möglich. Zunächst muss eine Konvertierung der Vektordaten ins Rasterformat erfolgen, was hier mit der Software *ERDAS IMAGINE* (Version 2014) durchgeführt wird. Nach dieser Umwandlung werden die einzelnen Layer in die Bildgröße der SAR-Bilddaten überführt, sowie in das UTM-Koordinatensystem transformiert.

### **Höhenmodell**

Das Höhenmodell dient zur Orthorektifizierung und der letztlichen Überführung der SAR-Zeitreihendaten in ein Raster mit einheitlicher Projektion. Im vorliegenden Fall ist ein DTED (*Digital Terrain Elevation Data*) Modell Level 2 verfügbar, das über eine ungefähre räumliche Auflösung von einer Bogensekunde verfügt (Pixelgröße circa 30 m). Da die Topographie der Szene, insbesondere der Szenenmitte, keine abrupt auf-

Nr.	Datum (TT.MM.JJ)	Uhrzeit (UTC / MEZ)	Orbit	Polarisation	Einfallsinkel [°]	Pixelabstand Slant Range [m]	Pixelabstand Slant Azimuth [m]	Sensor	Intervall [Tage]
1	08.08.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,86	TSX	
2	19.08.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,87	TSX	11
3	30.08.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,87	TSX	11
4	10.09.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,88	TSX	11
5	21.09.08	17:08 / 18:08	ASC	HH	48,49	0,59	0,87	TSX	11
6	02.10.08	17:08 / 18:08	ASC	HH	48,49	0,59	0,87	TSX	11
7	13.10.08	17:08 / 18:00	ASC	HH	48,50	0,59	0,87	TSX	11
8	24.10.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,87	TSX	11
9	04.11.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,88	TSX	11
10	15.11.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,87	TSX	11
11	26.11.08	17:08 / 18:08	ASC	HH	48,50	0,59	0,87	TSX	11
12	07.12.08	17:08 / 18:08	ASC	HH	48,49	0,59	0,87	TSX	11

Tabelle 6.2.: Zeitreihe aus SLC-Daten (Datensatz „Greding“).

oder absteigenden Bergverläufe aufweist, ist diese Höhenauflösung geeignet. In Anhang A, Abbildung A.4, unten, ist das Höhenmodell visualisiert. Anhand der dortigen Grauwerte ist ein Höhenverlauf von circa 101 m (hellgrau) bis ungefähr 40 m (schwarz) über dem Meeresspiegel kodiert dargestellt. Eine Vorverarbeitung des Höhenmodells ist nicht notwendig.

Neben diesem primär in dieser Arbeit genutzten Datensatz wird eine weitere Szene zur Verifikation des Verfahrens betrachtet. Diese wird im nachfolgenden Abschnitt beschrieben.

### 6.1.2. Szene „Greding“

Der Datensatz „Greding“ besteht aus vier Komponenten: SAR, Optisch, LULC-Karte und Höhenmodell.

#### SAR

Der SLC-Bildstapel besteht aus 12 Aufnahmen, die aufeinander folgend im regelmäßigen Abstand von 11 Tagen entlang eines Intervalls von circa vier Monaten aufgenommen wurden (Tabelle 6.2). Das mittlere Amplitudenbild der Zeitreihe ist in Abbildung 6.2, links oben, dargestellt. Es ist ersichtlich, dass die Aufnahmegeometrie hinsichtlich des lokalen Beleuchtungswinkels im Vergleich zur Stuttgarter Szenerie unterschiedlich ist. Die hier beschriebene Szene wurde mit knapp doppelt so großem  $\theta$  aufgezeichnet, woraus folgt, dass insbesondere an erhabenen Strukturen wie zum Beispiel Häusern mehr beziehungsweise auch großflächigere Radarschattenbereiche resultieren. Im Umkehrschluss bedeutet dies, dass in eng bebautem Gebiet möglicherweise kleinräumige Änderungen durch das Radarsignal nicht erfasst und daher auch nicht abgebildet werden.

Die Gredinger Szene besteht im Gegensatz zu „Stuttgart Flughafen“ größtenteils aus ruralen Bereichen (Abbildung 6.2, 2), die sich mit Waldgebieten abwechseln (Abbildung 6.2, 5). Im Szenenzentrum befindet sich der Ortskern von Greding (Abbildung 6.2, 4), an dem an westlicher Seite die Autobahn A9 vorbeiführt (Abbildung 6.2, 1). In Autobahnnähe befinden sich suburbane Strukturen mit industriellen Bereichen (Abbildung 6.2, 3).

Die Tatsache, dass die Gredinger Szenerie im Kontrast zum Stuttgarter Datensatz durch ihre ländlichere Struktur eine geringere Anzahl an Hochaktivitätsgebieten enthält, kann neben dem unterschiedlichen Beleuchtungswinkel als vorteilhaft im Hinblick auf die hier vorgestellte Methode erachtet werden. Auf diese Weise kann erprobt werden, ob das Verfahren in Bezug auf diese Differenzen robuste und aussagekräftige Ergebnisse produziert.

Die Vorprozessierung der SAR-Zeitreihe „Greding“ erfolgt analog zu den entsprechenden Abläufen zur

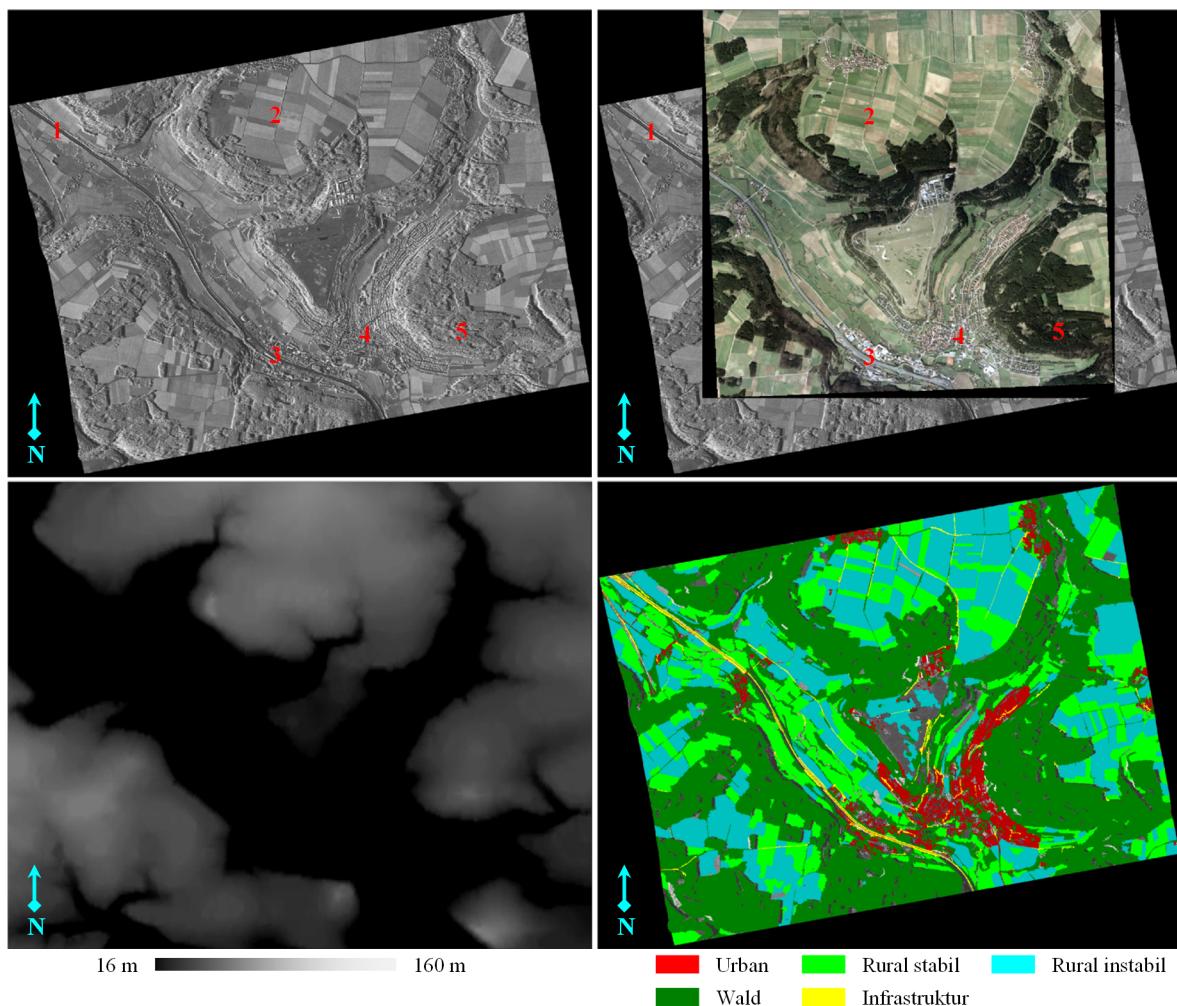


Abbildung 6.2.: Datensatz „Greding“, oben links: Mittleres Amplitudenbild der Zeitreihe, oben rechts: Mittleres Amplitudenbild der Zeitreihe mit überlagertem RMK-Mosaik, unten links: DTED Level 2 Höhenmodell, unten rechts: LULC-Karte aus Klassifikation. 1: Autobahn A9, 2: Rurale Bereiche, 3: Suburbane Strukturen mit Industriegebieten, 4: Ortskern, 5: Waldgebiet.

Vorverarbeitung des Datensatzes „Stuttgart Flughafen“.

### **Optisch**

Als optische Datenreferenz zur visuellen Überprüfung und Interpretation der detektierten Hochaktivitätsbereiche liegen vier Reihenmesskamera (RMK)-Luftbildaufnahmen vor. In Abbildung 6.2, oben rechts, befindet sich die SAR-Szene überlappende Bereich dieses Luftbildmosaiks. Die RMK-Bilddaten stammen ursprünglich vom Bayerischen Landesvermessungsamt und wurden am 07.04.2002 aufgezeichnet. Die räumliche Zeilen- und Spaltenauflösung (Pixelgröße) der digitalisierten Luftbilder beträgt 0,4 Meter. Im Hinblick auf die Interpretation der SAR-basierten Resultate ist zu beachten, dass - wie auch bei der Stuttgarter Szene - ein relativ großer zeitlicher Abstand zwischen dem SAR-Zeitreihenstapel und der optischen Referenz vorhanden ist.

Eine Vorverarbeitung der RMK-Bilder ist nicht notwendig.

### **Thematische Informationsebene**

Im Gegensatz zu der Stuttgarter Szene wurde auf die Berücksichtigung eines OSM-Datensatzes aus den in Abschnitt 4.2.1 geschilderten Gründen verzichtet. Mit diesem Verzicht wird der in der Praxis mögliche Fall der Nichtexistenz von GIS-Datenbeständen simuliert. Anstelle von OSM-Layern wird eine LULC-Karte genutzt (Abbildung 6.2, unten rechts), die ursprünglich im Rahmen einer objektorientierten Klassifikation mit der Software *eCognition Developer* erstellt worden ist. Fünf Klassen sind in dieser Karte enthalten, die dem in Abbildung A.1 (Anhang) dargestellten Schema ähnlich sind. Die Klasse *Rural instabil* ist mit dort enthaltenen Klasse *Rural (landwirtschaftlich genutzt)* gleichzusetzen. *Rural stabil* entspricht der Klasse *Rural*

Datensatz	Anzahl PC-3-Pixel (HAP)	Anzahl AC	Anzahl HAO
„Stuttgart Flughafen“	63.396	7.056	34.363
„Greding“	3.666	875	1.852

Tabelle 6.3.: Resultate der Präkategorisierung.

(sonstige). Eine spezielle Vorverarbeitung der LULC-Karte ist nicht notwendig.

### **Höhenmodell**

Wie für den Stuttgarter Datensatz liegt auch für die Gredinger Szenerie ein komplett abdeckendes DTED Level 2 Höhenmodell vor (Abbildung 6.2, unten links), das für die Orthorektifizierung des SAR-Zeitreihenstapels verwendet wird. Der in Abbildung 6.2 dargestellte Ausschnitt aus dem Höhenmodell enthält eine in Grauwerten kodierte Höhenvariation von circa 160 m (hellgrau) bis etwa 16 m (schwarz) über dem Meeresspiegel. Eine Vorverarbeitung des Höhenmodells ist nicht notwendig.

## **6.2. Änderungsanalyse**

In diesem Abschnitt wird die praktische Anwendung der erläuterten Verfahrensweise zur Änderungsanalyse auf die beiden Testdatensätze „Stuttgart Flughafen“ und „Greding“ beschrieben, wobei die Reihenfolge der in Kapitel 5 enthaltenen Prozessierungsabfolge entspricht.

Zunächst werden im Rahmen der Präkategorisierung die Hochaktivitätspixel (HAP) identifiziert und entsprechend ihrer Zeitreihensignatur in Aktivitätscluster (AC) eingeordnet (Abschnitt 6.2.1).

Auf Grundlage der HAP wird im nächsten Schritt die pixelbasierte Ebene verlassen und die Hochaktivitätsobjekte (HAO) in nicht redundanter Weise extrahiert (Abschnitt 6.2.2).

Für jedes der so detektierten HAO wird die Extraktion der in Kapitel 4 beschriebenen Merkmale durchgeführt und diese in geeigneter Weise auf ein einheitliches Wertebereichskontinuum skaliert. Darüber hinaus erfolgt aufgrund der Größe der Merkmalsmatrix eine Reduzierung auf maßgebliche Hauptkomponenten (Abschnitt 6.2.3).

Mittels der reduzierten Merkmalsmatrix erfolgt eine unüberwachte Kategorisierung der HAO bezüglich ihrer merkmalsorientierten Ähnlichkeiten (Abschnitt 6.2.4).

Durch manuelle Selektion wird ein initialer Klassenkatalog ausgewählt, der die Eingabe für die iterative Optimierung in Relation zum geclusterten Merkmalsraum darstellt (Abschnitt 6.2.5).

Der letzte Prozessierungsschritt beinhaltet die *fuzzy*-basierte Klassifikation der HAO anhand eines Zugehörigkeitswerts (ebenfalls Abschnitt 6.2.5).

Schließlich werden dem Anwender ergebnisbeschreibende Ausgabeinformationen für eine Interpretation der Resultate zur Verfügung gestellt (Abschnitt 6.2.6).

Eine diskutierende Bewertung der Resultate erfolgt in Abschnitt 6.2.7.

### **6.2.1. Präkategorisierung und Aktivitätscluster**

Analog zu der in Abschnitt 3.2.2 dargelegten Vorgehensweise werden basierend auf der (gefilterten) Aktivitätskarte die Hochaktivitätspixel (HAP) detektiert und entsprechend ihrer zeitlichen Signatur in Kategorien (Aktivitätscluster AC) eingeteilt. Später wird geprüft, ob anhand dieser zeitlichen Dimension Muster hinsichtlich Klassenzugehörigkeiten abgeleitet werden können (Abschnitt 6.3.4).

Abbildung 6.3 enthält einen Ausschnitt aus der gefilterten Aktivitätskarte mit den in diesem Gebiet enthaltenen HAP sowie die farbliche Visualisierung der AC (D), wobei jede dort dargestellte Farbe ein bestimmtes Aktivitätscluster bezeichnet.

In Anbetracht der Gesamtszene ergeben sich für den Stuttgarter beziehungsweise für den Gredinger Datensatz die in Tabelle 6.3 zusammengefassten Präkategorisierungsresultate. Die in Abschnitt 6.1.2 beschriebenen Annahmen hinsichtlich der für die Gredinger Szene erwartete weitaus geringere Anzahl an Änderungsobjekten werden durch die für diesen Datensatz abgeleitete Anzahl an HAP bestätigt (Tabelle 6.3).

### **6.2.2. Hochfrequente Änderungsobjekte**

Wie in Abschnitt 3.2.3 beschrieben, muss zur Redundanzvermeidung die Identifikation der Hochaktivitätsobjekte (HAO) anhand der sie definierenden HAP in eindeutiger Weise erfolgen. Würde dieser Schritt nicht

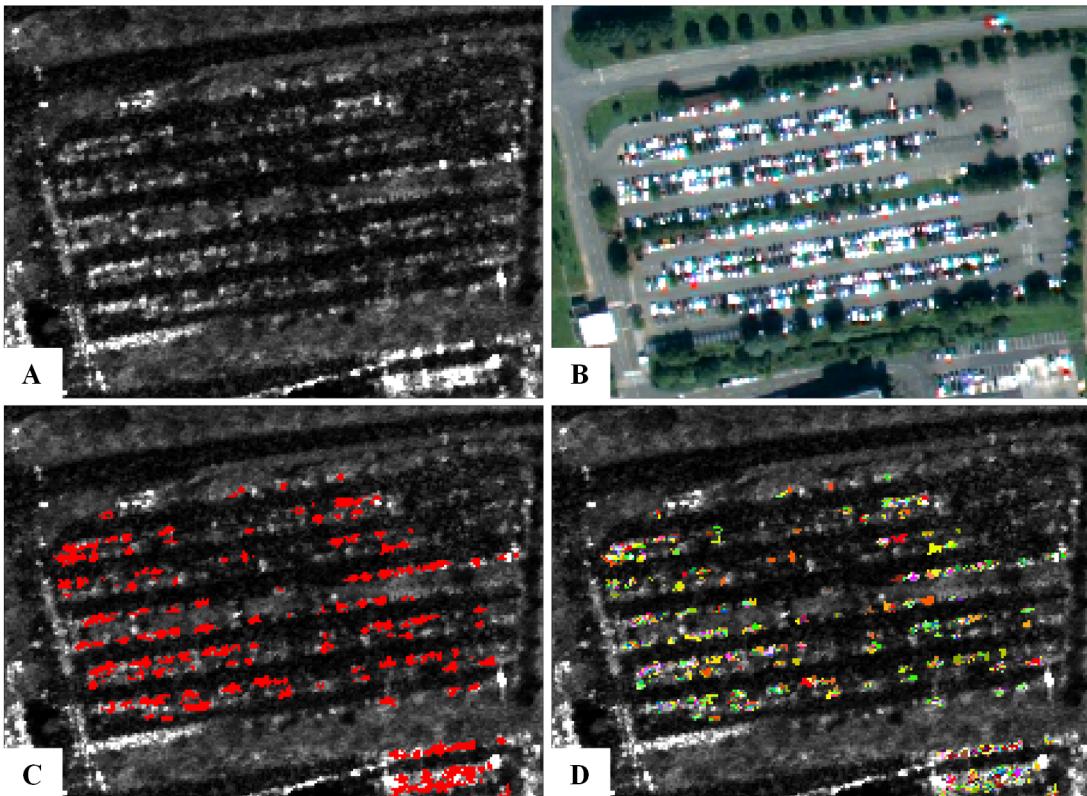


Abbildung 6.3.: Hochaktivitätsbereich PKW-Parkplatz (Datensatz „Stuttgart Flughafen“). A: Mittleres Amplitudenbild der Zeitreihe, B: Pangeschärftes WV-2-Bild, C: Gefilterte Aktivitätskarte mit HAO (rot), D: Präkategorisierte HAO.

durchgeführt werden, lägen einzelne HAO mehrfach vor, woraus ein unverhältnismäßig starker Anstieg der Berechnungskosten entstehen würde.

Nach seiner Identifikation wird für nachfolgende, interne Zugriffszwecke jedes HAO in eine Liste eingetragen, in der weitere eindeutig kennzeichnende Attribute enthalten sind (Abschnitt 3.2.3). Tabelle 6.3 enthält die für die beiden Datensätze extrahierten HAO-Anzahlen. Ein Beispiel für die Liste ist anhand der Stuttgarter Szene in Tabelle A.1 visualisiert. Die drei ersten Spalten beinhalten darin die fortlaufende Nummer des HAO, die Nummer der das Änderungsobjekt enthaltenden Änderungskarte, sowie die Nummer des dort vermerkten Labels. Die Spalten vier und fünf enthalten die Bildkoordinaten seines Schwerpunkts  $S_{HAO}$  und die letzten beiden Spalten geben Auskunft über seine räumliche Ausdehnung.

### 6.2.3. Merkmalsextraktion, Skalierung und Reduzierung

Die im letzten Abschnitt gelisteten HAO dienen als Grundlage für die Extraktion der in Kapitel 4 beschriebenen Merkmale, wovon die diskreten binären Merkmale eine Sonderrolle einnehmen und nicht für die Kategorisierung genutzt werden. Im Einzelnen aufgezählt ergeben sich je  $HAO_i$  die Merkmale zu:

- ( $v_{HAO_i,Koh}$  (Kohärenz, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 14 / 1 \times 11$ )
- ( $v_{HAO_i,Form}$  (Form, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 3$ )
- ( $v_{HAO_i,Text}$  (Textur, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 5$ )
- ( $v_{HAO_i,area}$  (DAP Fläche, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 10$ )
- ( $v_{HAO_i,diag}$  (DAP Diagonale, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 10$ )
- ( $v_{HAO_i,moi}$  (DAP Massenträgheitsmoment, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 10$ )
- ( $v_{HAO_i,sig0}$  (DAP Sigma Nought, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 10$ )
- ( $v_{HAO_i,cov}$  (DAP Variationskoeffizient, Dimension („Stuttgart Flughafen“ / „Greding“):  $1 \times 10$ )

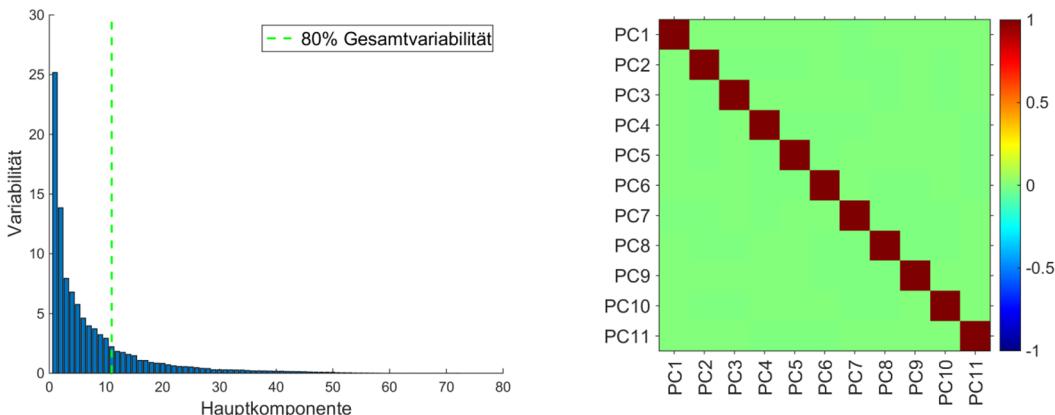


Abbildung 6.4.: Links: Aus der PCA resultierendes Eigenspektrum für die vorliegende Merkmalsmatrix. Rechts: Korrelationsmatrix der aus der PCA resultierenden 11 Hauptkomponenten (beides für den Datensatz „Stuttgart Flughafen“).

Als Konsequenz aus diesen 72 berechneten Merkmalswerten je Hochaktivitätsobjekt folgt mit den in Tabelle 6.3 gelisteten HAO-Anzahlen eine Merkmalsmatrix der Dimension  $34.363 \times 72$  für den Stuttgarter Datensatz und eine  $1.852 \times 72$  große Matrix für die Szene „Greding“. In Kapitel 4 wurde bereits beschrieben, dass für eine kategorisierende Weiterverarbeitung eine Skalierung der Merkmalswerte auf einen einheitlichen Wertebereich durchzuführen ist. Würde eine solche Skalierung nicht erfolgen, wäre eine uneinheitliche Gewichtung der Merkmale im Rahmen des Reduzierungs- und damit auch im *Clustering*-Prozess die Folge, was zu einer Verfälschung der Resultate führen würde. Als einheitlicher, für alle Merkmale geltender Wertebereich wird  $[0; 1]$  gewählt, da beispielsweise die Kohärenz und die morphologischen Merkmale bereits in diesem Intervall vorliegen. Die weiteren Merkmale werden anhand ihres jeweiligen Maximalwerts linear auf den Bereich  $[0; 1]$  abgebildet. Einen Ausnahmefall nimmt das Texturmerkmal der Korrelation ein, das zunächst linear in den positiven Wertebereich verschoben und anschließend skaliert wird.

Die im Anhang befindlichen Abbildungen A.5 und A.6 vermitteln eine Übersicht über die Histogramme der einzelnen Merkmale vor und nach der Skalierung, wobei die Häufigkeiten der Merkmalswerte über alle HAO dargestellt sind. Im Fall des Morphologiemerkals und der entsprechenden DAP-Signaturen wird aus Gründen der Übersichtlichkeit eine Visualisierung analog zu Abschnitt 4.2.5 gewählt und lediglich die Signatur der ersten 100 von insgesamt 34.363 HAO dargestellt (Abbildung A.7).

Wie anhand der Abbildungen A.5 und A.6 abgeleitet werden kann, ist nach Skalierung der Merkmale kein Verlust an Information im Vergleich zum unskalierten Zustand ersichtlich.

Im Hinblick auf die große Anzahl an zugrunde liegenden HAO sowie verwendeten Merkmalen wird mittels PCA (Abschnitt 2.2.5) eine Dimensionsreduzierung der Merkmalsmatrix durchgeführt. Darüber hinaus erfolgt eine PCA-basierte Bewertung der Merkmale zur Identifikation der an den Hauptkomponenten maßgeblich beteiligten Eingangsmerkmalen. Diese Bewertung wird anhand der *Loadings* durchgeführt. Auf diese Weise können vor dem Hintergrund der Bildung unterschiedlicher Änderungskategorien geeignete von weniger geeigneten Merkmalen unterschieden werden.

Wie in Abschnitt 2.2.5 bereits erwähnt, wird zur Identifikation der letztlich verwendeten Hauptkomponentanzahl der prozentuale Anteil der Eigenvektoren an der Gesamtvariabilität analysiert. Als Schwellwert wird hierfür 80 % betrachtet. In Abbildung 6.4, links, ist das für den Stuttgarter Datensatz resultierende Eigenspektrum visualisiert, das die prozentualen Anteile der einzelnen Komponenten an der Gesamtvariabilität enthält. Die gestrichelte, vertikal verlaufende grüne Linie kennzeichnet den kumulativen Schwellwert von 80 %, der hier durch die ersten 11 Komponenten überschritten wird. Weiterhin ist ersichtlich, dass der Hauptanteil der in den Daten enthaltenen Information bereits durch die ersten beiden Komponenten ausgedrückt wird (*circa* 40 % der Gesamtvarianz) und die weiteren verbleibenden neun PC als Rauschanteil interpretiert werden können. Dieser Umstand manifestiert sich auch in den zweidimensionalen Streudiagrammen über alle PC im nachfolgenden Abschnitt der Kategorisierung (siehe Abschnitt 6.2.4, Abbildung 6.8).

Abbildung 6.4, rechts, zeigt beispielhaft für den Stuttgarter Datensatz die linearen Korrelationskoeffizienten nach Pearson [206] für den reduzierten Merkmalsraum. Es ist offensichtlich, dass die einzelnen Hauptkomponenten statistisch unabhängige Merkmale darstellen und somit eine gute Grundlage für die Beschreibung der Hochaktivitätsobjekte hinsichtlich einer Kategorisierung bilden.

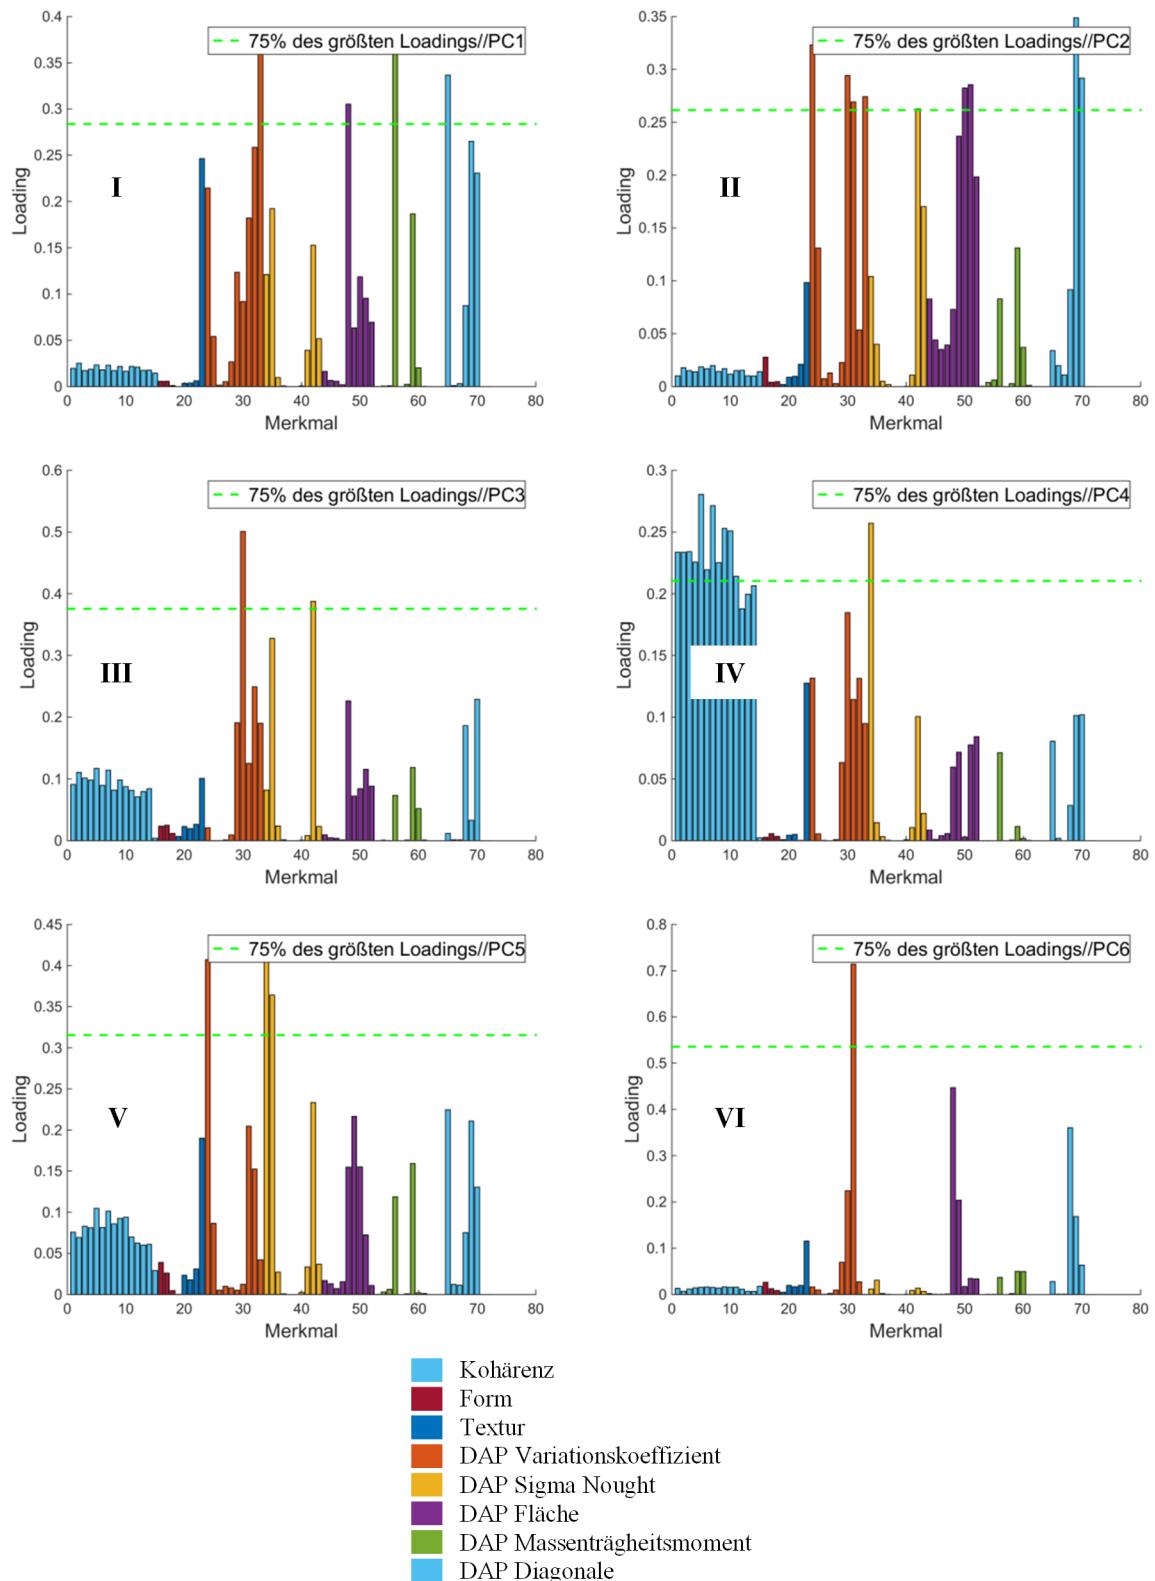


Abbildung 6.5.: Teil 1 der *Loadings* der Eingangsmerkmale an den resultierenden Hauptkomponenten (I bis VI) (Datensatz „Stuttgart Flughafen“).

Die Frage nach geeigneten Merkmalen für eine Kategorisierung der HAO kann, wie oben beschrieben, über die Auswertung der *Loadings* erfolgen. Jede resultierende PC kann als Linearkombination der ursprünglichen Eingangsmerkmale dargestellt werden. In dieser Linearkombination stehen die *Loadings* für die Koeffizienten

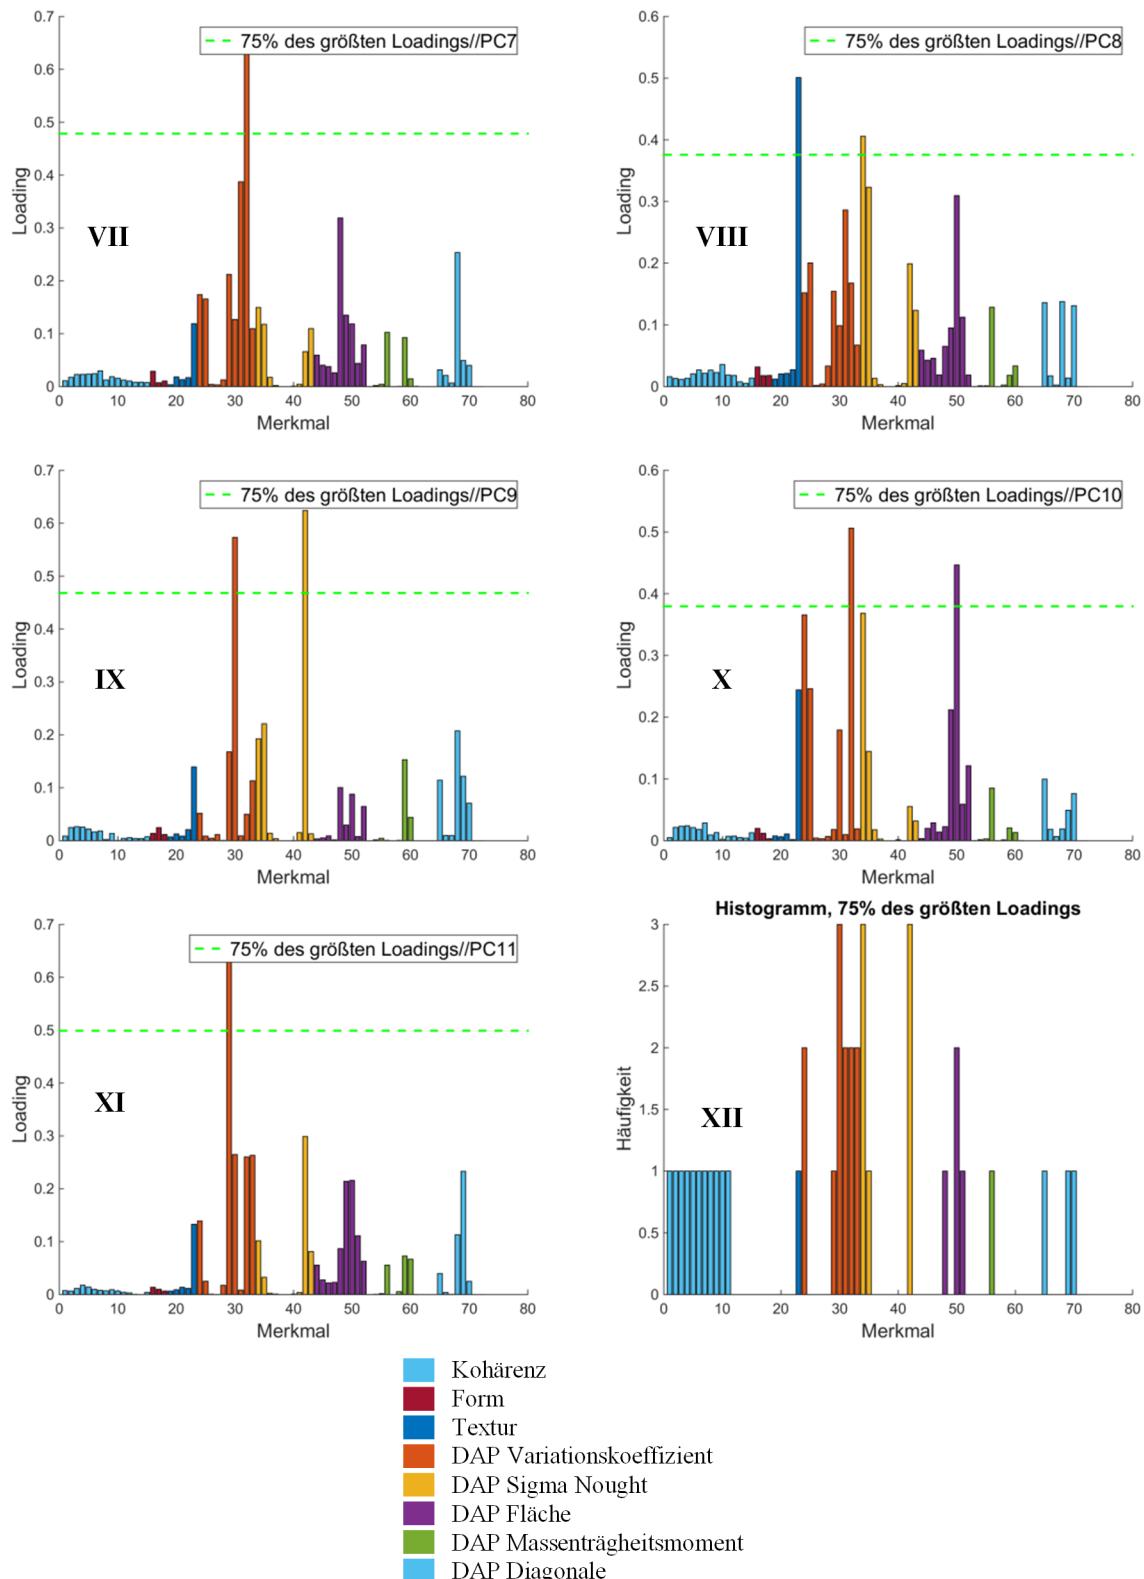


Abbildung 6.6.: Teil 2 der Loadings der Eingangsmerkmale an den resultierenden Hauptkomponenten (VII bis XI), sowie Histogramm der über alle PC am maßgeblichsten beteiligten Eingangsmerkmale (XII) (Datensatz „Stuttgart Flughafen“).

der Eingangsmerkmale. In den Abbildungen 6.5 und 6.6 sind die Koeffizienten entsprechend ihrer Verbindung zu den Eingangsmerkmalen farbkodiert für alle Hauptkomponenten enthalten. Zur Kennzeichnung der für eine bestimmte Komponente maßgeblichen Eingangsmerkmale wird als Schwelle der 75 %-Anteil am jeweils höchsten Koeffizientenwert betrachtet (grün gestrichelte, horizontal verlaufende Linie).

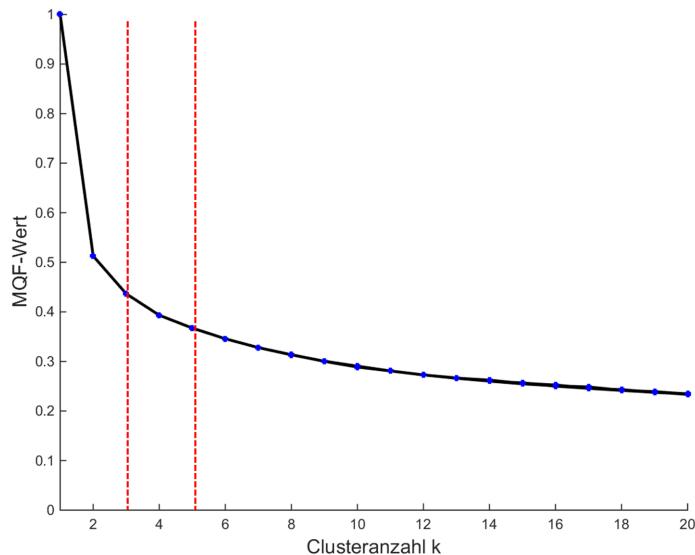


Abbildung 6.7.: Visualisierte Indexwerte aus der *Ellbogenmethode* (Datensatz „Stuttgart Flughafen“). Die vertikal verlaufenden, rot gestrichelten Linien kennzeichnen die optimale Clusteranzahl durch Analyse der Kurvengradienten.

Es zeigt sich, dass über alle PC hinweg die größten Anteile in den morphologischen Merkmalsgruppen zu finden sind, woraus sich diese als für die PC bedeutende Eingangsmerkmale ableiten lassen. Speziell aus diesen Merkmalsgruppen lassen sich die SAR-spezifischen  $v_{HAO_i,cov}$ - und  $v_{HAO_i,sig_0}$ -Gruppen (siehe Abbildung 6.6, XII) herausgreifen. Daraus folgt, dass die hier genutzten HAO durch diese beiden Merkmalsgruppen in maßgeblicher Art und Weise beschrieben werden können. Als Ergebnis aus der PCA beziehungsweise PCT und somit als Eingabe für die Kategorisierung der Szene „Stuttgart Flughafen“ liegt eine Merkmalsmatrix der Dimension  $34.363 \times 11$  vor.

In Anbetracht des geringen Einflusses des Kohärenzmerkmals kann weiterhin geschlossen werden, dass die alleinige Nutzung von Amplitudenbilddaten für die hier vorgestellte Verfahrensweise zielführend ist.

Im Anhang A befinden sich die visualisierten Ergebnisse für den Gredinger Datensatz. Analog zu der Stuttgarter Szene resultieren auch hier 11 Hauptkomponenten (Abbildung A.8), deren Loadings ebenfalls auf die Differentiellen Attributprofile als maßgebliche Eingangsmerkmale schließen lassen (Abbildungen A.11 und A.12). Zur Kategorisierung der mit „Greding“ detektierten Hochaktivitätsobjekte liegt final eine  $1.852 \times 11$  große Merkmalsmatrix vor.

#### 6.2.4. Kategorisierung

Die die Hochaktivitätsobjekte beschreibende, skalierte und reduzierte Merkmalsmatrix bildet die Basis für die Kategorisierung. In Abschnitt 2.2.6 wurde hierfür bereits das  $k$ -means-Verfahren als die für den vorliegenden Fall geeignete Methode identifiziert. Es wurde weiterhin gezeigt, dass verschiedene Methoden zur unüberwachten Extraktion einer optimal zum jeweiligen Datensatz passenden Anzahl an Clustern (Kategorien) existieren, wovon sich der Caliński-Harabasz-Index  $CH_k$ , das Davis-Bouldin-Kriterium  $DB_k$  und die *Ellbogenmethode* als grundsätzlich tauglich herausgestellt haben. Aufgrund der Resultate aus der Gegenüberstellung dieser Ansätze wurde die *Ellbogenmethode* als sinnvollste Verfahrensweise abgeleitet (Abschnitt 2.2.6).

Zur Ermittlung des geeigneten  $k$ -Werts werden 20 verschiedene  $k_i = [1, 2, \dots, 20]$  betrachtet und die mittleren quadratischen Fehler  $MQF_k$  berechnet, sowie normiert. In Abbildung 6.7 sind die für die Stuttgarter Szene extrahierten  $MQF_k$  visualisiert. Setzt man voraus, dass das passende  $k$  an jener Stelle vorhanden ist, wo mit ansteigender Clusteranzahl keine weitere signifikante Änderung des Kurvengradienten erfolgt, so resultiert in diesem Fall  $k = 4$ . Dieses  $k$  wird zur Ermittlung des optimalen *Clustering*-Resultats durch zehnmaliges unabängiges Durchlaufen des Algorithmus verwendet.

Die Resultate des *Clustering*-Verfahrens sind in Abbildung 6.8, unten, anhand der zweidimensionalen Streudiagramme zusammengefasst. Es ist direkt ersichtlich, dass nur die ersten beiden Hauptkomponenten für eine sinnvolle Trennung der vier Kategorien genutzt werden können, wohingegen alle weiteren PC lediglich Rauschen beinhalten. Dieses Rauschen manifestiert sich dort durch eine starke Durchmischung der abgebildeten

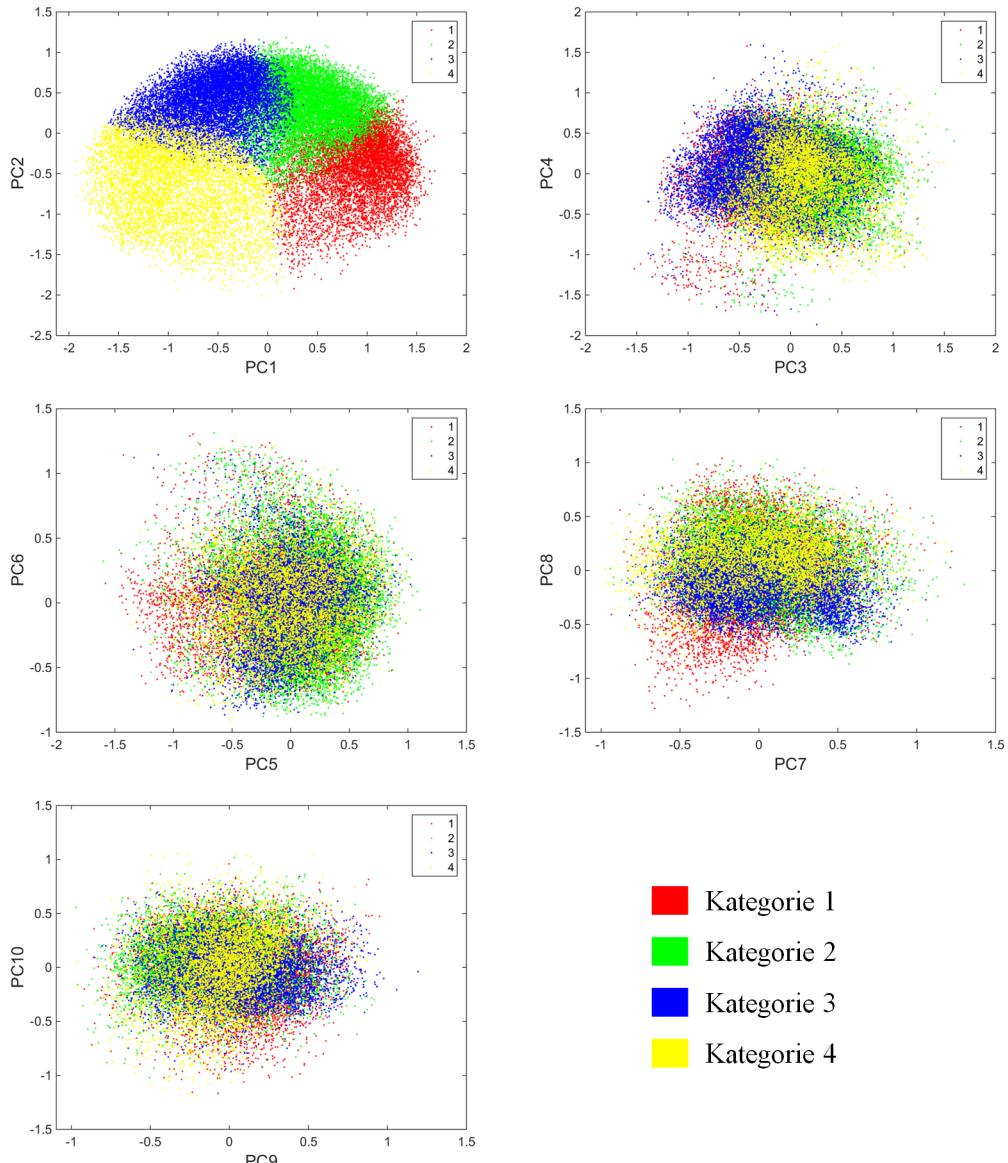


Abbildung 6.8.: Darstellung des Kategorisierungsresultats anhand zweidimensionaler Streudiagramme über alle Hauptkomponenten für die Szene „Stuttgart Flughafen“. Jeder farbkodierte Punkt im Merkmalsraum kennzeichnet ein HAO. Das Diagramm zwischen PC11 und PC12 existiert nicht aufgrund der 11 vorliegenden Hauptkomponenten.

vier Kategorien. Für die weitere Verarbeitung im Hinblick auf die Optimierung eines durch den Anwender vorgegebenen Klassenkatalogs ist diese Erkenntnis von zentraler Bedeutung, da sie die Durchführung eines speziellen Verfahrens zur Transformation in eine zweidimensionale Datenbeschreibung (zum Beispiel *Sammon-Mapping*, Abschnitt 5.2.4) nicht notwendig macht. Hierzu können ohne bedeutenden Informationsverlust die ersten beiden PC genommen werden, was eine unmittelbare und schnelle Prozessierung ermöglicht.

Im Hinblick auf den Gredinger Datensatz wurde anhand der *Ellbogenmethode*  $k = 5$  ermittelt (Abbildung A.9). In Abbildung A.13 sind die Ergebnisse aus der Kategorisierung in den entsprechenden zweidimensionalen Streudiagrammen dargestellt. Analog zum Stuttgarter Datensatz zeigt sich auch hier die bestmögliche Kategorientrennung für die hier vorliegenden 1.852 HAO in den ersten beiden Hauptkomponenten.

### 6.2.5. Klassenkatalog, Optimierung und Klassifikation

Die durch den Anwender durchzuführende Definition eines Katalogs zur Klassifikation der Hochaktivitätsobjekte erfolgt für den Stuttgarter Datensatz mehrheitlich auf Grundlage der im Rahmen von Ortsbegehungen eruierten Hochaktivitätsbereiche (Abbildungen A.2 bis A.3). Grundsätzlich ist es möglich, diese Erstellung eines Katalogs anhand einer optischen Referenzdatenbasis (beispielsweise Luft- oder Satellitenbilder aus Google

ID Klasse	Name	Farbe
1	PKW-Parkplatz	Blau
2	LKW-Parkplatz	Orange
3	Baustelle	Gelb
4	Be- / Entladestelle	Violett
5	Sammelstelle	Grün
6	Flughafen Gate	Hellblau

Tabelle 6.4.: Initialer Klassenkatalog (Datensatz „Stuttgart Flughafen“).

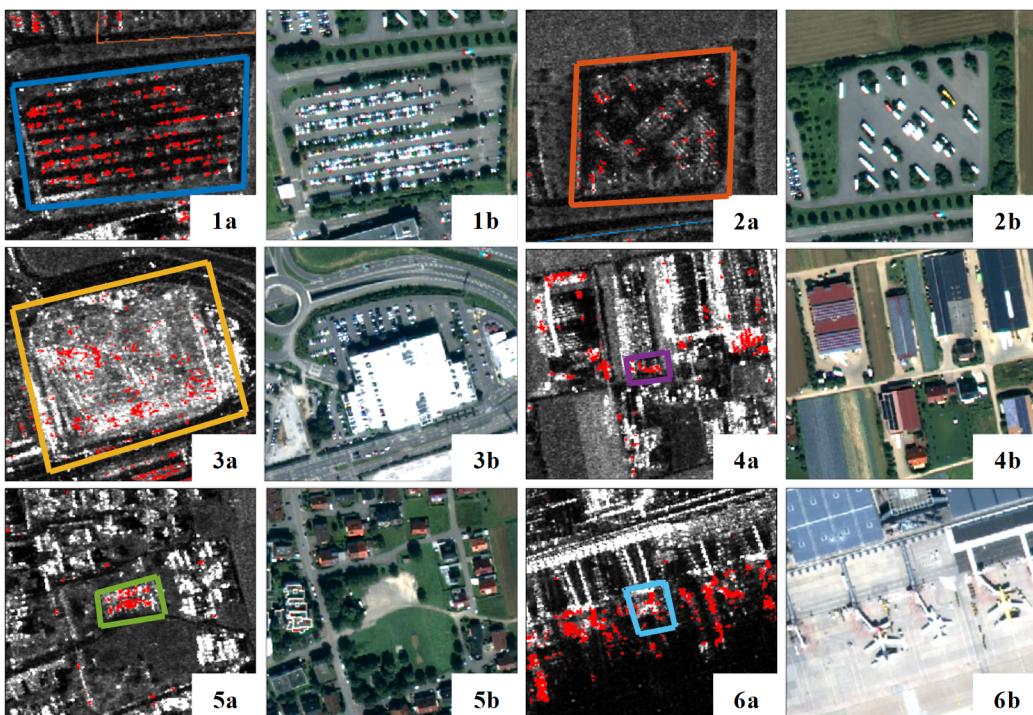


Abbildung 6.9.: Initiale Klassen Datensatz „Stuttgart Flughafen“. (a): Selektierter Klassenbereich in Örtlichkeit (hier: mittleres Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln; (b): Entsprechender Bereich im pangeschräften WV-2-Bild. 1: PKW-Parkplatz; 2: LKW-Parkplatz; 3: Baustelle; 4: Be- / Entladestelle; 5: Sammelstelle; 6: Flughafen Gate.

Earth) und ohne spezielle Szenenkenntnis durchzuführen. Diese Vorgehensweise wurde für die Szene „Greding“ erprobt.

### Initialer Klassenkatalog

In Tabelle 6.4 ist der initiale, aus sechs Klassen bestehende Katalog („Stuttgart Flughafen“) gelistet. Die Ausführung für den Gredinger Datensatz ist identisch zu dem in Tabelle 6.4 gezeigten Katalog, mit Ausnahme der Klasse *Flughafen Gate*, die in Greding nicht existent ist. Der initiale Klassenkatalog zur Gredinger Szene ist im Anhang A in Tabelle A.2 visualisiert. Die Abbildungen 6.9 und A.14 enthalten jeweils die Darstellungen der einzelnen Klassen im Ortsraum, wobei die Hochaktivitätspixel HAP dem mittleren Amplitudenbild der Zeitreihe überlagert sind.

Klasse 1 (*PKW-Parkplatz*) beinhaltet einen Firmenparkplatz für Mitarbeiter (Abbildung A.3), auf dem unterschiedlich große PKW in verschiedener Anordnung über die Zeitreihe abgestellt wurden. Die HAP in diesem Parkplatzgebiet kennzeichnen demnach einzelne Parkplätze, die entlang des beobachteten Zeitintervalls durch Fahrzeuge abwechselnd besetzt und unbesetzt gewesen sind.

Vergleichbares gilt für die zweite Klasse *LKW-Parkplatz* mit dem Unterschied, dass die HAP keine durch PKW verursachte Veränderungen aufweisen, sondern durch das Abstellen sowie Entfernen von Lastkraftwagen hervorgerufen worden sind.

Als Repräsentant für die dritte Klasse *Baustelle* wird ein Bereich vorgegeben, in dem von November 2013 bis November 2014 ein Parkhausgebäude durch einen Bürogebäudekomplex ersetzt wurde<sup>1</sup>. Die in diesem Bereich detektierten HAP stehen somit für Änderungen, die sowohl durch Baumaterial als auch durch Baumaschinen oder -geräte erzeugt wurden. Daher sollten die Hochaktivitätsstapel (Abschnitt 3.2.3) eine größere Variation an Merkmalswerten besitzen als beispielsweise die zur vierten Klasse *Be- / Entladestelle* gehörenden Stapel. Diese Annahme wird detaillierter in Abschnitt 6.3.4 diskutiert. Unter einer *Be- / Entladestelle* wird in dieser Arbeit ein lokal begrenzter Bereich verstanden, in dem beispielsweise in industriellem Landnutzungsgebiet Waren oder auch landwirtschaftliche Erzeugnisse be- und entladen werden. Als Beispiel wird die Be- und Entladerampe für LKW in einem landwirtschaftlichen Betrieb (Abbildung A.2) ausgewählt.

Als fünfte Klasse wurde im urbanen Bereich des Ortes Sielmingen ein Hochaktivitätsgebiet identifiziert, das sich in der Örtlichkeit als *Sammel- beziehungsweise Deponierstelle* für Grün- und sonstige Abfälle herausstellte (Abbildung A.3).

*Flughafen Gate* bildet die sechste Klasse, die ein typisches Hochaktivitätsgebiet im Flughafenabschnitt darstellt. Sie kennzeichnet den Bereich, den ein Flugzeug in Parkposition direkt am Gate zur Aufnahme beziehungsweise Abgabe von Passagieren sowie Gepäck einnimmt. Dementsprechend beinhalten die dort extrahierte HAP sowohl Flugzeugstrukturen als auch Eigenschaften einer *Be- / Entladestelle*.

### **Vorprojektion**

Gemäß der in Kapitel 5 geschilderten Prozessierungsabfolge wird zunächst anhand der Vorprojektion überprüft, welche der initial selektierten Klassen tatsächlich in den kategorisierten Daten enthalten sind und welche nicht. Die Ableitung dieser Entscheidung erfolgt mittels Berechnung der klassenbezogenen Clusterhistogramme (Abschnitt 5.2.3) zur Identifikation dominanter Kategorien. Abbildung 6.10 enthält die für die sechs Klassen ermittelten Clusterhistogramme sowie als Tabelle visualisiert die dazu gehörigen empirischen Werte. Es zeigt sich, dass im Hinblick auf das in Abschnitt 5.2.3 aufgestellte Kriterium  $CL_{\tau} = k^*/2$  zur Ermittlung dominanter Cluster die Klassen 2 (*LKW-Parkplatz*), 4 (*Be- / Entladestelle*) und 6 (*Flughafen Gate*) keine ausgeprägte Dominanz bestimmter Cluster aufweisen. Im Gegensatz dazu werden die Klassen 1 (*PKW-Parkplatz*), 3 (*Baustelle*) und 5 (*Sammelstelle*) durch jeweils maximal  $k^*/2$  dominiert, wobei  $k^*$  die Anzahl der Cluster des Datensatzes ist.

Es lässt sich daraus ableiten, dass das Hauptaugenmerk bei der Optimierung des initialen Klassenkatalogs insbesondere auf den Klassen mit Clusterrauschen liegt. Die im nachfolgenden Schritt der Rückprojektion durchzuführenden Prozessierungen werden klären, ob diese Klassen gänzlich aus dem Katalog entfernt werden müssen, oder ob eine durch das Verfahren vorgeschlagene Neudeinition sinnvoll ist. Darüber hinaus gilt es zu prüfen, ob eine Optimierung der initialen Klassendefinition generell möglich ist. Bei den Resultaten der VP für die Szene „Greding“ zeigt sich, dass alle vorab ausgewählten Klassen mit Ausnahme von Klasse 3 (*Baustelle*) das Dominanzkriterium erfüllen und dementsprechend in den Daten auffindbar sind (Abbildung A.15). Das im Vergleich zum Stuttgarter Datensatz hier zusätzlich identifizierte Cluster 5 nimmt bei allen selektierten Klassen eine untergeordnete Rolle ein. In Abschnitt 6.2.7 wird dieser Umstand detaillierter diskutiert.

### **Rückprojektion**

Die im Rahmen der RP zu bestimmenden Kennzahlen erfordern eine Überführung des kategorisierten Datensatzes in eine zweidimensionale Rasterdarstellung (Abschnitt 5.2.4). Diese Transformation ist wie oben erwähnt in einfacher und direkter Weise anhand der ersten beiden Hauptkomponenten der reduzierten Merkmalsmatrix beider Datensätze möglich. Abbildung 6.11 enthält das in ein Rasterbild konvertierte Kategorisierungsresultat sowie die initial gewählten Klassen, die die Resultate der VP in anschaulicher Weise wiedergeben. Das Pendant für den Gredinger Datensatz ist in Abbildung A.16 enthalten. Mit der Zielsetzung eines optimal zur vorhandenen Datengrundlage stimmigen Klassenkatalogs werden nun der Reihe nach alle Klassen einzeln überprüft. Nachfolgend wird diese Abfolge detailliert für den Stuttgarter Datensatz beschrieben. Bei allen weiteren Durchläufen, die im Rahmen der Variation einzelner Parameter durchgeführt werden (Abschnitt 6.3), wie auch für die Gredinger Szene wird auf einen solchen Detailgrad verzichtet. Die Visualisierungen der Ergebnisse für diesen zweiten Datensatz befinden sich in Anhang A (Tabelle A.3 und Abbildung A.16). Die Diskussion der Ergebnisse erfolgt in Abschnitt 6.2.7.

---

<sup>1</sup><http://www.flughafen-stuttgart.de/business-to-business/immobilien/stuttgart-airport-city/neues-buerogebaeude-skyloop>, zuletzt besucht (TT.MM.JJJJ): 09.01.2018

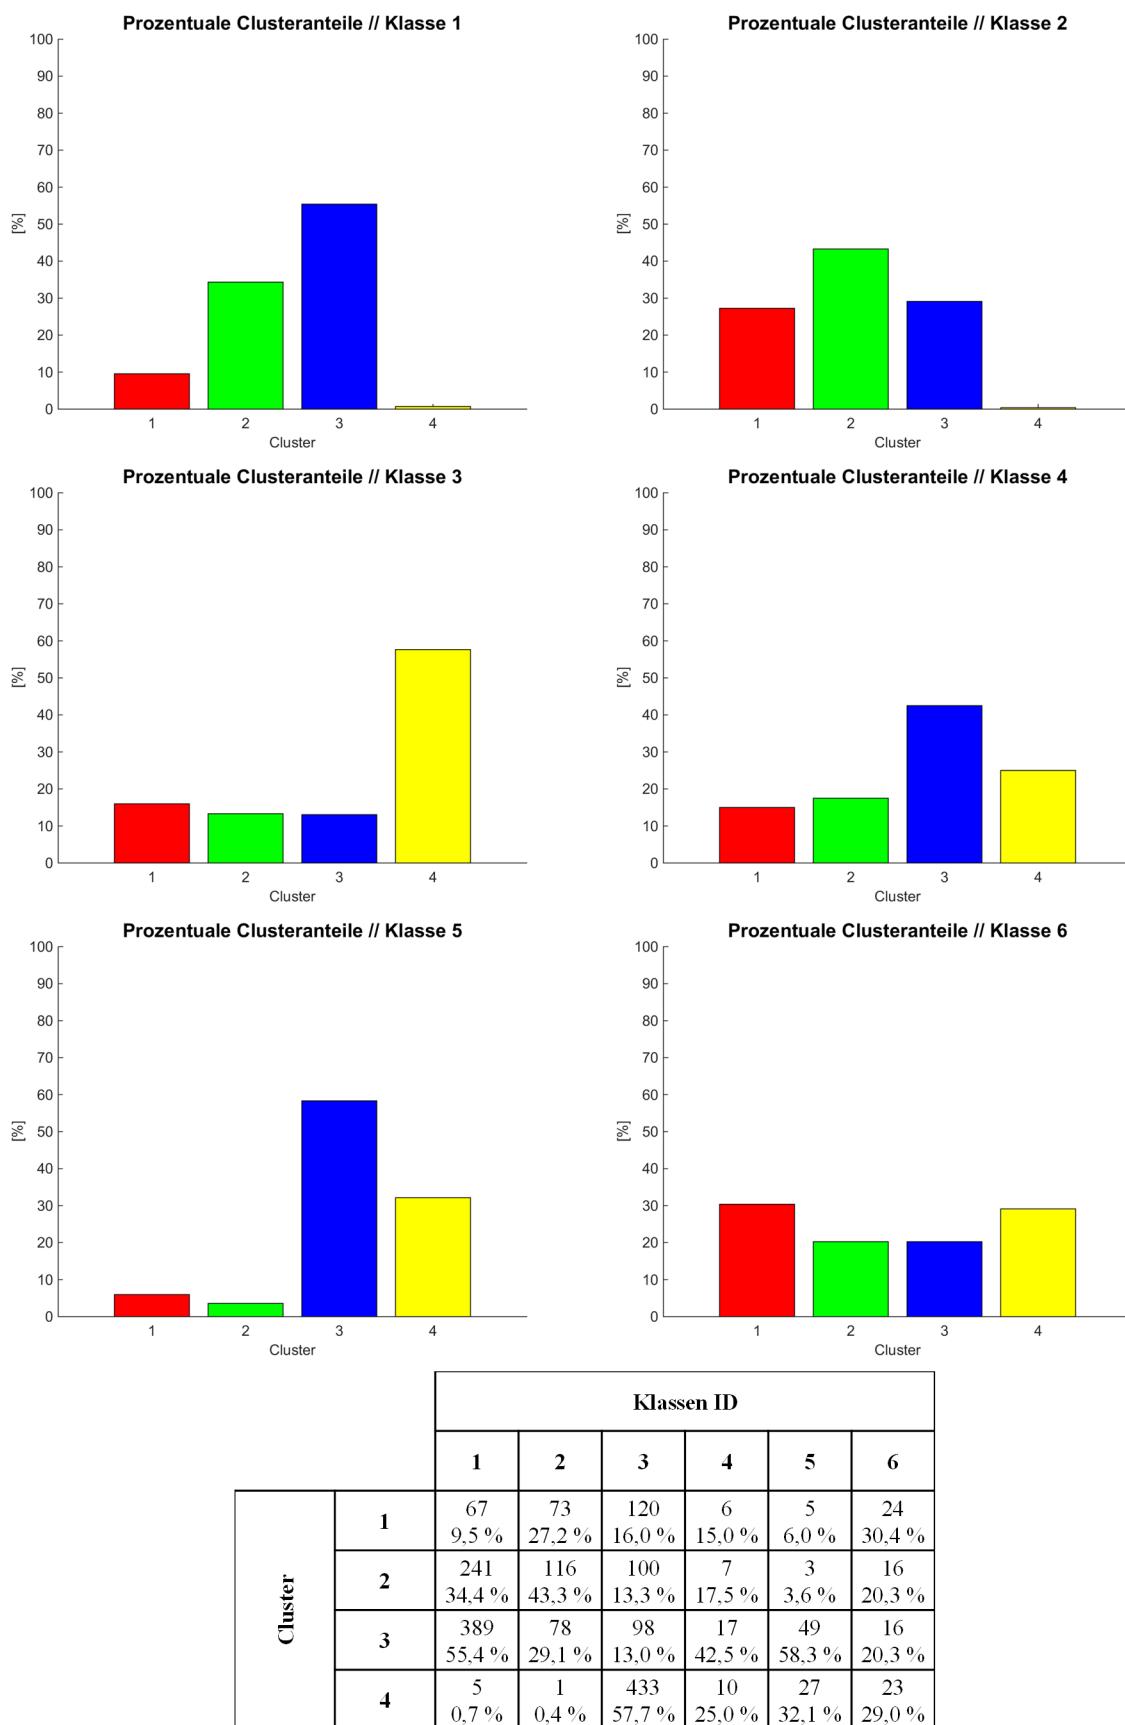


Abbildung 6.10.: Ergebnisse der Vorprojektion (Datensatz „Stuttgart Flughafen“). Die unten dargestellte Tabelle enthält die empirischen Werte (Anzahl der in der Klasse enthaltenen HAO und prozentualer Clusterzugehörigkeitsanteil) zu den oben visualisierten Clusterhistogrammen. Klasse 1: PKW-Parkplatz; Klasse 2: LKW-Parkplatz; Klasse 3: Baustelle; Klasse 4: Be-/Entladestelle; Klasse 5: Sammelstelle; Klasse 6: Flughafen Gate.

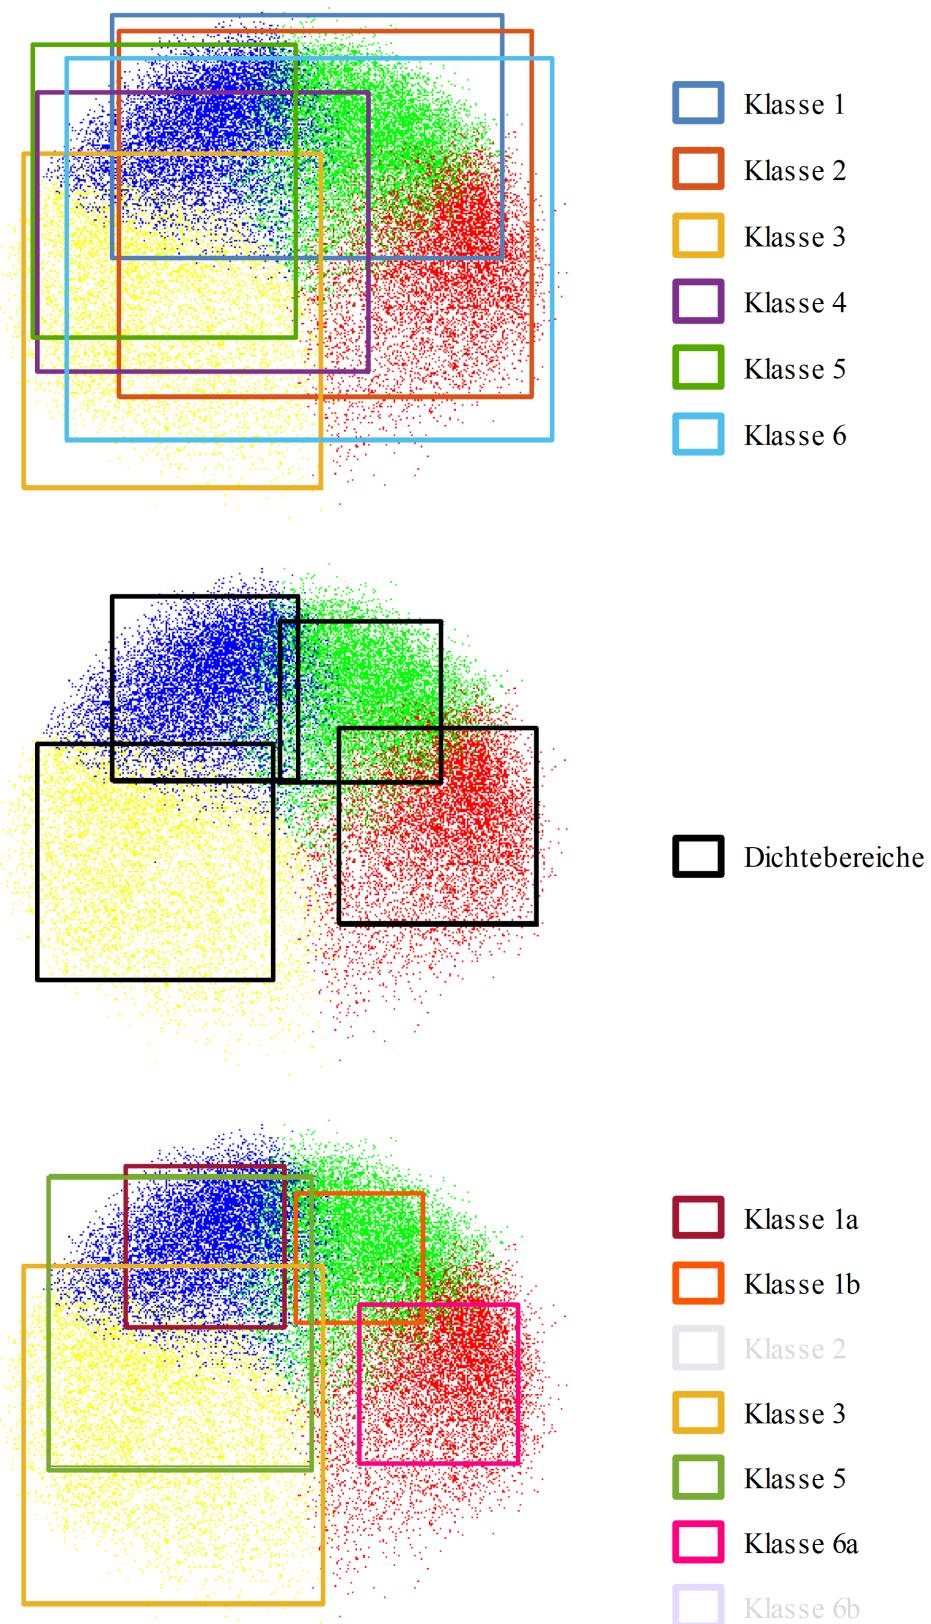


Abbildung 6.11.: Oben: Zweidimensionales Raster mit Kategorisierungsresultat und initialen Klassenregionen; Mitte: Zweidimensionales Raster mit Kategorisierungsresultat und Dichtebereichen; unten: Zweidimensionales Raster mit Kategorisierungsresultat und finalen Klassenregionen (Datensatz „Stuttgart Flughafen“). Aus Redundanzgründen ist von den drei identischen Klassenregionen 1b, 2 und 6b (siehe auch Abbildung 6.12) lediglich die Klasse 1b dargestellt.

	Initiale Kennzahlen Optimierte Kennzahlen				
	CL	D [%]	Z	Fall	
Initiale Klasse	1	2	[36,2; 100,0; 100,0; 20,7] [unverändert]	0	1a
	2	3	[96,8; 100,0; 96,6; 0,0] [unverändert]	2	3a
	3	1	[0,0; 12,2; 40,2; 100,0] [unverändert]	0	0
	4	3	[0,0; 46,1; 72,6; 77,3] [unverändert]	3	3b
	5	2	[0,0; 10,9; 96,6; 63,8] [0,0; 20,8; 100,0; 70,5]	2	2b
	6	3	[100,0; 100,0; 0,0; 87,9] [unverändert]	1	3a

Tabelle 6.5.: Optimierungsverlauf des initialen Klassenkatalogs (Datensatz „Stuttgart Flughafen“). CL: Anzahl dominanter Cluster; D[%]: Prozentualer Anteil am Dichtebereich eines Clusters; Z: Zerteilungsgrad.

Der Optimierungsverlauf jeder einzelnen vorgegebenen Klasse ist in den Tabellen 6.5 beziehungsweise A.3 zusammengefasst, wobei sich auf die in Abschnitt 5.2.4 erläuterten Fallunterscheidungen bezogen wird.

#### Initiale Klasse 1 (PKW-Parkplatz)

Die erste Klasse des Katalogs für die Stuttgarter Szene deckt die beiden Kategorien 2 und 4 vollständig ab ( $D_2 = 100$  und  $D_3 = 100$ ), woraus  $CL = 2$  und  $Z = 0$  folgt (Abbildung 6.11 und Tabelle 6.5). Die beiden vollständig abgedeckten Dichtebereiche werden weiterhin in Bezug auf den Grad ihrer gegenseitigen Überlappung und einer möglichen Unterscheidbarkeit überprüft (siehe Abschnitt 5.2.4). Im Fall der Klasse 1 (PKW-Parkplatz) liegt eine solche Unterscheidbarkeit vor, weshalb die ursprüngliche Klassendefinition in zwei neue Unterklassen (1a und 1b) aufgeteilt wird (Abbildung 6.12). Anhand dieser automatisch erfolgten Aufteilung kann abgeleitet werden, dass die vorab durch den Anwender durchgeführte Klassendefinition zu grob erfolgt ist und sich die initiale Klasse in der Datenrealität durch zwei unterscheidbare Klassen ausdrücken lässt. Demnach entspricht die Klasse 1 dem in Abbildung 5.9 dargestellten Fall 1a.

#### Initiale Klasse 2 (LKW-Parkplatz)

Für Klasse 2 (LKW-Parkplatz) wird festgestellt, dass ihre initiale Definition in den Daten nicht existent ist, da sie im Merkmalsraum mehr als  $CL_\tau = k^*/2$  verschiedene Kategorien abdeckt. Weiterhin ist  $Z = 2$ , was darauf schließen lässt, dass zwei der drei beteiligten Cluster durch die Klasse zerteilt werden. Da aber der Dichtebereich einer dieser Kategorien durch die Klasse vollständig abgedeckt wird, kann eine Neudefinition der Klasse erfolgen. Eine derartige Neudefinition ist generell als ein Vorschlag des Verfahrens zu betrachten, das zur Wissens- und Erkenntnisbildung auf Seiten des Anwenders genutzt werden kann. Mögliche Änderungen in der Klassensemantik sind durch den Anwender zu prüfen und eine neue, eventuell geeignetere Klassenbeschreibung abzuleiten. Die in diesem Fall erzeugte finale (neue) Klasse 2 ergibt sich als deckungsgleiche Klasse zur zuvor eingeführten Unterkategorie 1b. Aus Redundanzgründen wird deshalb bei der Visualisierung der finalen Klassen nur die Klasse 1b dargestellt (Abbildung 6.11, unten). Analoges gilt für die unten erwähnte Subklasse 6b.

#### Initiale Klasse 3 (Baustelle)

Der oben beschriebene, an den Flughafenbereich angrenzende Baustellenabschnitt deckt im Merkmalsraum nur das vierte Cluster vollständig ab ( $D_4 = 100$ ). Es wird keine Kategorie zerteilt, woraus resultiert, dass diese Klasse tatsächlich in den Daten existiert. Weder eine Optimierung noch eine Aufteilung ist notwendig beziehungsweise möglich, so dass für Klasse 3 der Fall 0 beobachtet werden kann.

#### Initiale Klasse 4 (Be- / Entladestelle)

Gegenteiliges gilt für die vierte Klasse des Katalogs, die aufgrund ihrer Eingangskennzahlen folgern lässt, dass eine automatische Neudefinition dieser offensichtlich nicht in der kategorisierten Datenrealität enthaltenen Klasse sinnvoll ist (Fall 3b). Hier wird die Lösung dieser Klasse vorgenommen, was ebenfalls zum Prozess

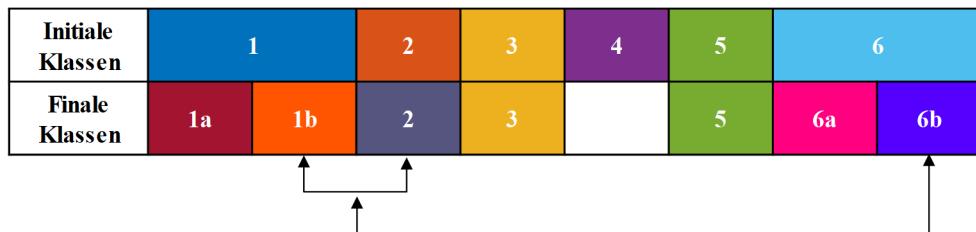


Abbildung 6.12.: Visualisierter Optimierungsverlauf mit den jeweilig vorgegebenen, beziehungsweise resultierenden Farbkodierungen der Klassen (Datensatz „Stuttgart Flughafen“).

der Wissensbildung beiträgt. Als Konsequenz folgt, dass diese Klasse für künftige Katalogsdefinitionen eher ungeeignet ist.

#### **Initiale Klasse 5 (Sammelstelle)**

Die Klasse Sammelstelle setzt sich aus zwei dominierenden Kategorien (3 und 4, Tabelle 6.5) zusammen ( $CL = 2$ ), die beide nicht vollständig durch die Klasse abgedeckt werden ( $Z = 2$ ). Der hier vorliegende Fall 2b führt zur Prüfung einer optimierten Formulierung durch Variation der Klasse in einem lokalen Bereich um den Klassenschwerpunkt (Abschnitt 5.2.4). Nach Anwendung dieser Vorgehensweise liegt in diesem Fall eine optimierte Version der Klasse 5 vor, da eine der beiden genannten Kategorien vollständig abgedeckt wird und der Zerteilungsgrad  $Z$  um Eins reduziert ist.

#### **Initiale Klasse 6 (Flughafen Gate)**

Als Einzige der selektierten Klassen beinhaltet die Klasse *Flughafen Gate* einen nicht im Rahmen von Ortsbegehungen erfassten Hochaktivitätsbereich. Die manuelle Selektion erfolgte deshalb anhand der optisch vorliegenden Referenzdaten. Anhand des vorgestellten Verfahrens wird geprüft, ob diese Klassenauswahl in Anbetracht der zugrunde liegenden Daten stimmig erfolgt ist. Als Resultat dieser Überprüfung ergeben sich die Kennzahlen  $CL = 3$  und  $Z = 1$ , was einerseits zwar die Nichtexistenz dieser Klasse bedeutet - andererseits aber eine Neudefinition ermöglicht (zwei der drei dominanten Kategorien werden vollständig abgedeckt). Aus der initial gewählten Klasse entstehen somit zwei neue, alternativ durch die Methode vorgeschlagene Klassen 6a und 6b, wovon letztere deckungsgleich mit den Klassen 1b beziehungsweise 2 ist (Abbildung 6.12).

#### **Klassifikation**

Die Klassifikation der HAO (Abschnitt 5.2.5) erfolgt an dieser Stelle beispielhaft anhand der Fuzzy-Zugehörigkeitsschwelle  $z = 50$ . In Abschnitt 6.3.7 werden verschiedene Schwellwerte für die Klassenzugehörigkeit getestet und die Ergebnisse gegenübergestellt.

Die Wahl von  $z = 50$  führt im vorliegenden Beispiel der 34.363 HAO („Stuttgart Flughafen“) zu 14.204 klassifizierten Hochaktivitätsobjekten, was einem prozentualen Anteil von circa 41 % entspricht (20.159 beziehungsweise 59 % unklassifizierte HAO). Für die Gredinger Szene resultieren bei gleich gewählter Zugehörigkeitsschwelle vergleichbare Werte: 772 (circa 42 %) klassifizierte und 1.080 (circa 58 %) unklassifizierte HAO bei einer Gesamtanzahl von 1.852 Hochaktivitätsobjekten.

Eine visuelle Zusammenstellung der Klassifikationsergebnisse für den Stuttgarter Datensatz ist in den Abbildungen 6.13 und 6.14 und für die Szene „Greding“ in der Abbildung A.17 enthalten. Dazu ergänzend sind je Klassenregion des initialen Katalogs die prozentualen Anteile der den finalen Klassen zugewiesenen HAO aufgeführt. Neben der relativ hohen Rate an unklassifizierten HAO zeigt sich, dass insbesondere die unpräzise gewählten Klassenregionen 1, 2, 4 und 6 sogenannte Mischklassenregionen sind, die sich in der Datenrealität aus Subklassen zusammensetzen, oder nicht existieren. Im Hinblick auf die durch das Verfahren optimierte Version der initialen Klasse 2 zeigt sich, dass sich diese in den selektierten Klassenregionen nicht abbildet. Dieser auf den ersten Blick eigenartig erscheinende Umstand ist der Tatsache geschuldet, dass deckungsgleich definierte Klassen durch den Algorithmus nicht redundant verarbeitet werden. In diesem speziellen Fall liegt eine Redundanz der finalen Klassen 1b, 2 und 6b vor, weshalb einzige Klasse 1b zur Klassifikation genutzt wird.

Um zu überprüfen, ob die Klassifikationsresultate zur tatsächlichen in den Bilddaten enthaltenen Ortssemantik stimmig sind, wurde ein Szenenausschnitt analysiert, der unterschiedliche Hochaktivitätsgebiete beinhaltet (Anhang A, Abbildung A.18). Unter Berücksichtigung dreier Beispielbereiche (1: lokaler Containerbereich mit einer Be- und Entladestelle für LKWs; 2 und 3: Be- und Entladestellen sowie industrieller Sammelstellen) fällt vor allem auf, dass sich die Klasse 3 (*Baustelle*, Abbildung A.18, E) semantisch klar von den anderen Klassen unterscheidet. Weiterhin ist auffällig, dass HAO der Örtlichkeiten 2 und 3 ebenfalls zur Klasse 3 *Baustelle* zugewiesen wurden (Abbildung A.18, E und F), was nicht als Falschklassifikation

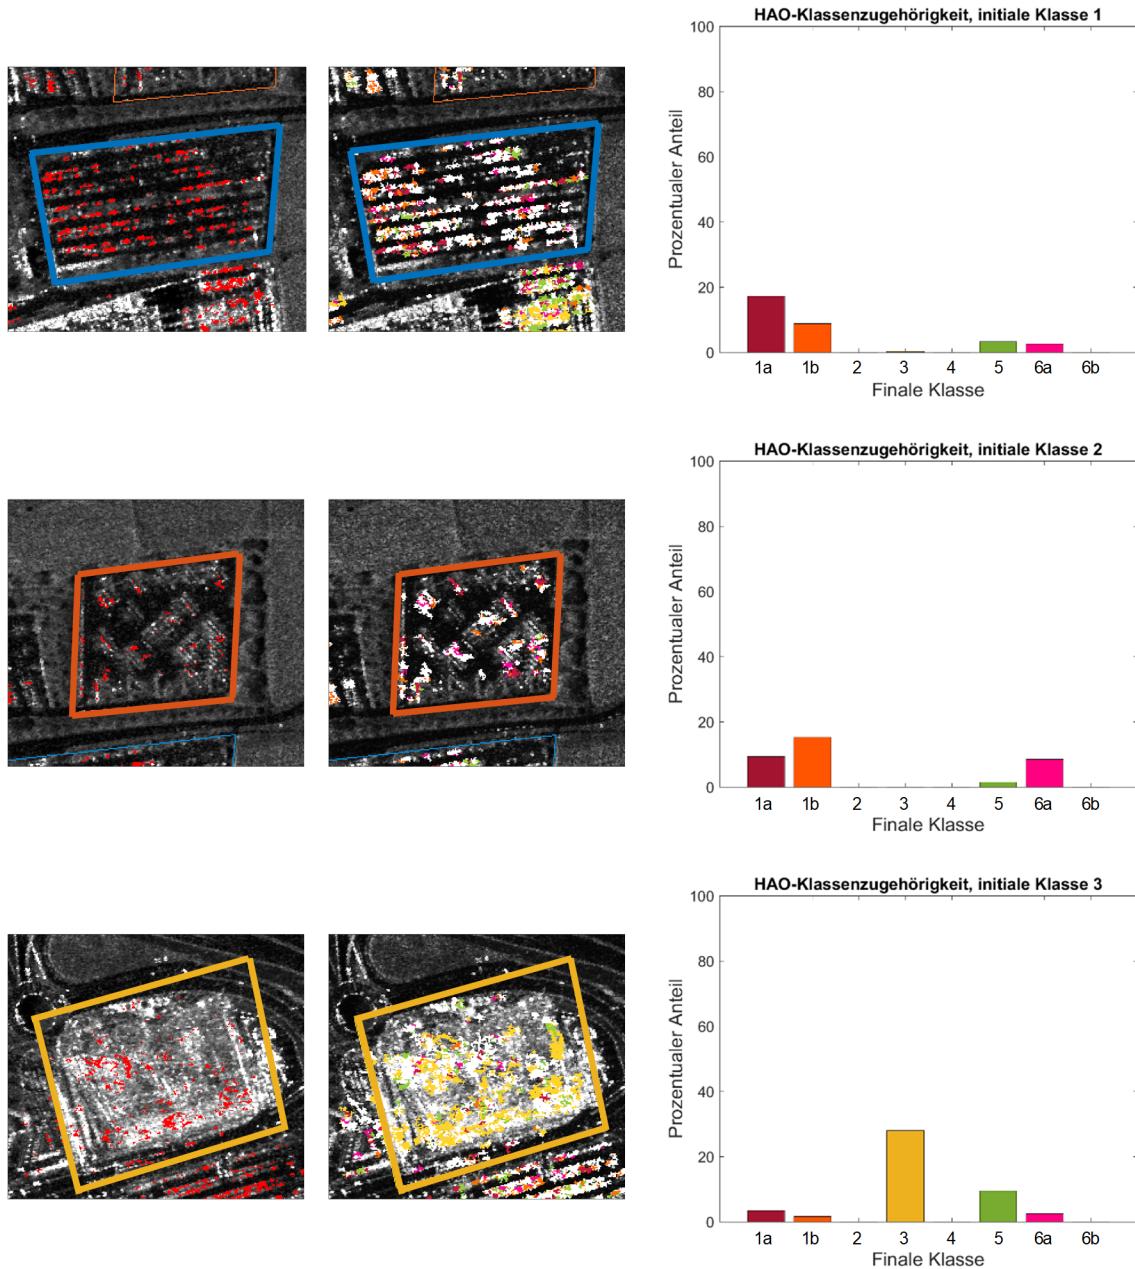


Abbildung 6.13.: Visualisierte Resultate der Klassifikation in den initial selektierten Hochaktivitätsgebieten mit der Fuzzy-Zugehörigkeitsschwelle  $z = 50$  (Datensatz „Stuttgart Flughafen“), Teil 1. Die Farbgebung der Klassifikation orientiert sich an der in Abbildung 6.12 dargestellten finalen Version des Katalogs. Weiß: Unklassifizierte HAO.

zu interpretieren ist. Sowohl Sammel- als auch Be- und Entladestellen weisen in ihrer Zusammensetzung durchaus baustellenähnliche Strukturen auf (Baumaterialien, Maschinen und Gerätschaften sowie Schutt). Mit Fokus auf den ersten Beispielbereich ist ersichtlich, dass die finale Klasse 5 *Sammelstelle* diese Örtlichkeit dominiert (Abbildung A.18, F).

Zusammenfassend kann gefolgert werden, dass die Klassifikationsergebnisse in Anbetracht der Ortssemantik sinnvoll sind. „Sinnvoll“ bedeutet hier, dass die Resultate in Bezug auf die real existierenden und offensichtlich ableitbaren LULC-Klassen der abgebildeten Örtlichkeit stimmig sind. Auf eine empirische Quantifizierung der Klassifikationsergebnisse mittels Kenngrößen (beispielsweise anhand einer Konfusionsmatrix) wird verzichtet. Eine solche Auswertung würde eine umfangreiche Referenzdatenbasis (zum Beispiel LULC-Karte) erfordern, die im Idealfall sowohl präzise als auch zeitlich aktuelle Informationen bereitstellen muss. Dieser Umstand steht somit im Gegensatz zu den in dieser Arbeit formulierten Anforderungen an ein möglichst einfaches und übertragbares Verfahren zur Änderungsanalyse (vergleiche auch Kapitel 1).

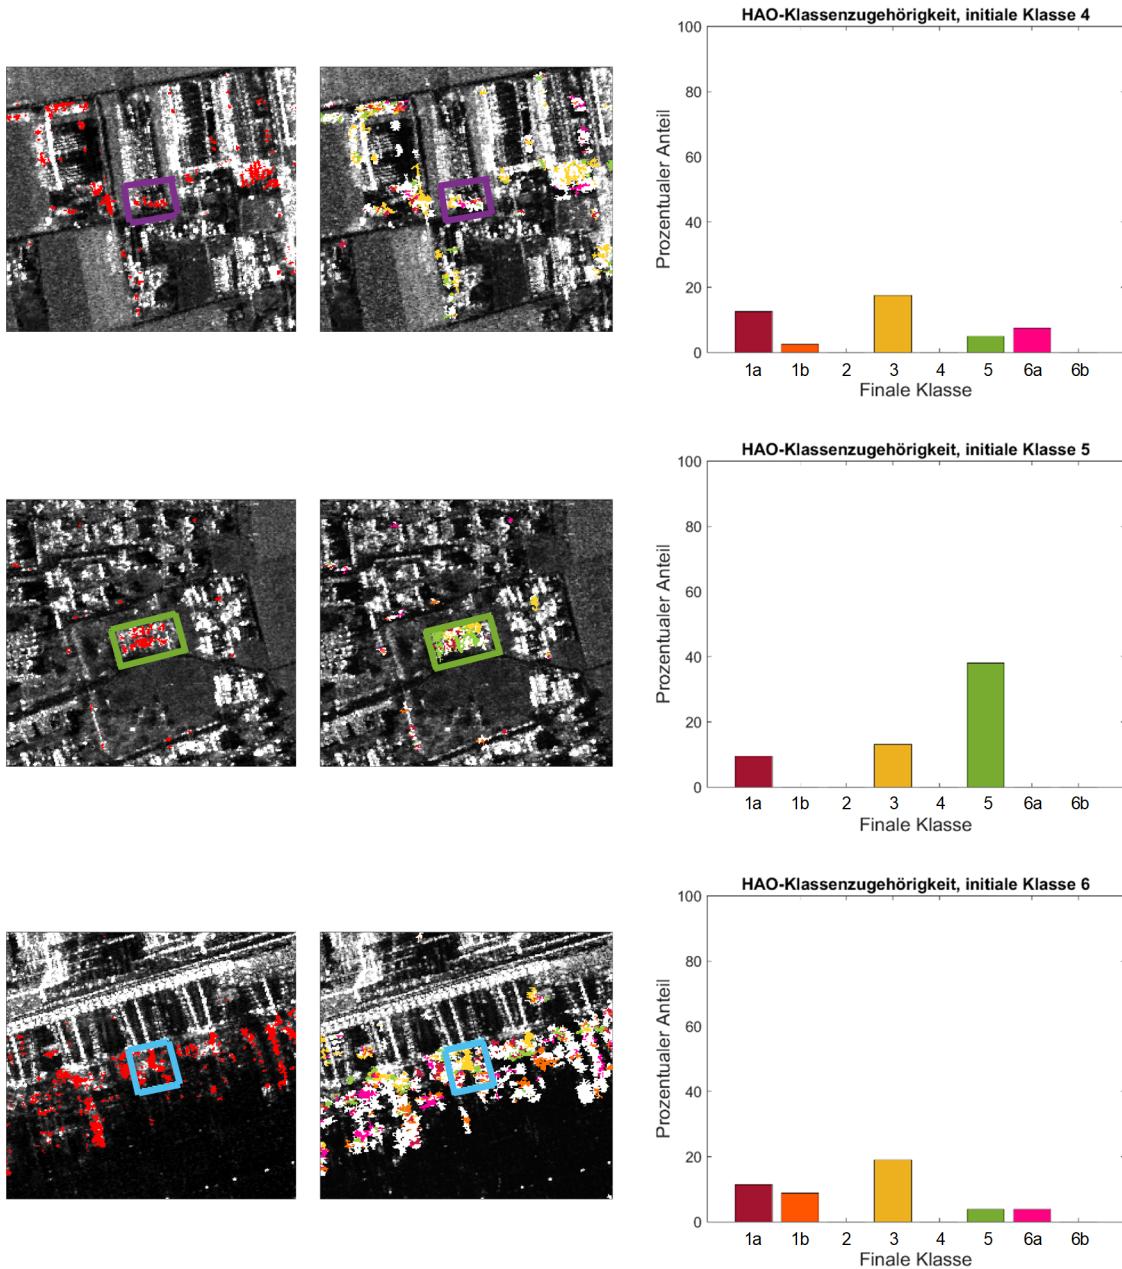


Abbildung 6.14.: Visualisierte Resultate der Klassifikation in den initial selektierten Hochaktivitätsgebieten mit der Fuzzy-Zugehörigkeitsschwelle  $z = 50$  (Datensatz „Stuttgart Flughafen“), Teil 2. Die Farbgebung der Klassifikation orientiert sich an der in Abbildung 6.12 dargestellten finalen Version des Katalogs. Weiß: Unklassifizierte HAO.

Neben der Ausgabe der visualisierten Ergebnisse inklusive der finalen Klassifikation der ursprünglich selektierten Hochaktivitätsregionen werden weitere Informationen bereitgestellt, die die Interpretation des optimierten Klassenkatalogs erleichtern. Diese für die beiden Testdatensätze berechneten Parameter sind Gegenstand des nachfolgenden Abschnitts.

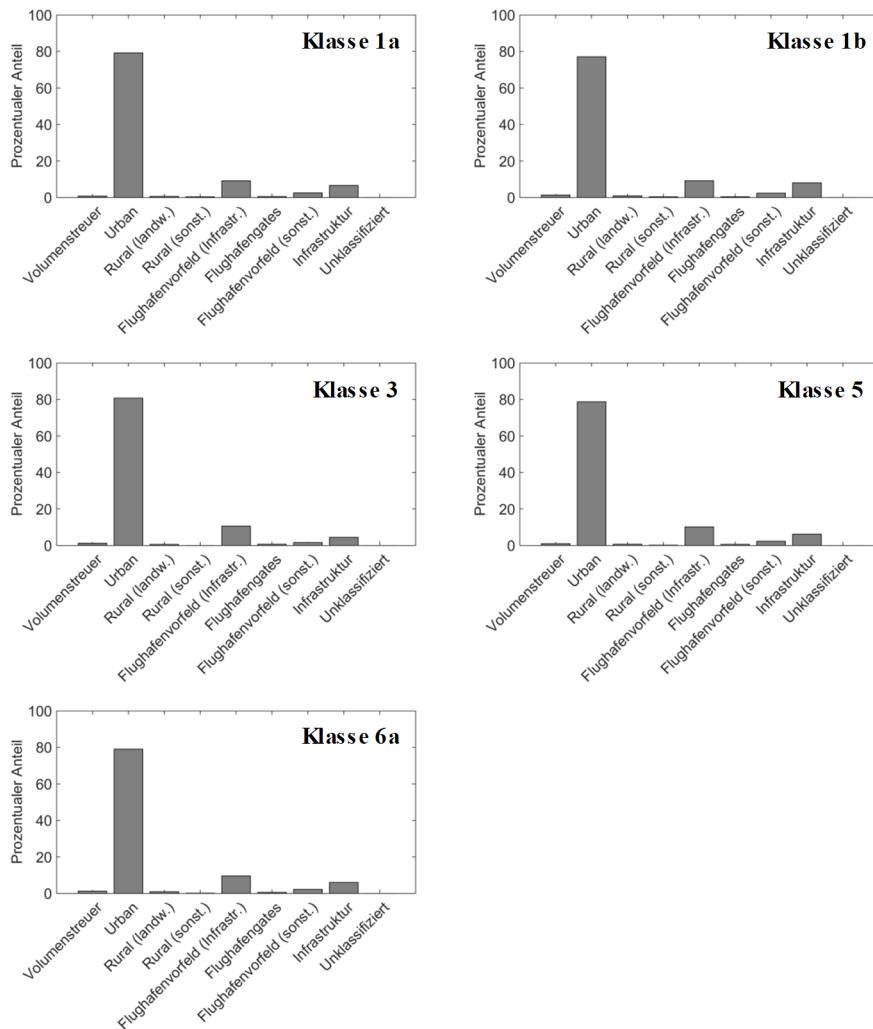


Abbildung 6.15.: Zu finalen Klassen gehörende HAO und deren prozentuale Zugehörigkeiten zu Kontextklassen (Datensatz „Stuttgart Flughafen“).

### 6.2.6. Klassenbeschreibung

Die in Abschnitt 4.2.1 erläuterte Analyse der lokal segmentierten Nachbarschaft eines Hochaktivitätsobjekts ermöglicht die ergänzende Beurteilung der final vorliegenden optimierten Klassen. Insbesondere bei Klassen, die durch das Verfahren neu eingeführt werden, stellt diese zusätzliche Information ein Hilfsmittel dar, das zur Wissensbildung über den Datensatz beiträgt. Hierfür sind drei Parameter beziehungsweise Merkmale verfügbar, die zur Interpretation der Semantik der Hochaktivitätsregionen (HAR) bereitgestellt werden: Kontextklasse, räumliche Ausdehnung beziehungsweise Begrenztheit und Form des die HAO umgebenden Segments (Abschnitt 4.2.1). Die Diskussion der aufgeführten Ergebnisse ist im nachfolgenden Abschnitt 6.2.7 enthalten.

#### Kontextklasse

Da die Zuweisung der Kontextklasse für jedes einzelne HAO erfolgt, wird eine histogrammbasierte Beurteilung der final vorliegenden Klassen durchgeführt. Sämtliche zu einer Klasse gehörenden HAO und deren lokalen Kontextinformationen werden entsprechend ihrer Auftrittshäufigkeit gelistet und visuell dargestellt (Abbildung 6.15). Für den Stuttgarter Datensatz bedeutet dies ein Kontextklassenhistogramm je Klasse mit einer Abszissendimension von neun (Abbildung 4.4). Im Fall des Datensatzes „Greding“ resultieren Histogramme mit sechs Abszisseneinträgen (Abbildungen 4.4 und A.10). Die Histogramme für die finalen Klassen 2 und 6b zeigen aus genannten Redundanzgründen keine Aussagen.

#### Räumliche Ausdehnung und Begrenztheit

Analog zum Kontextmerkmal werden auch die Informationen über die räumliche Beschaffenheit einer Änderung für jedes HAO einzeln abgeleitet. Wie in Abschnitt 4.2.1 dargelegt, können mit dieser Art der

Finale Klasse	Anzahl HAO	Räumlich ausgedehnt	Räumlich begrenzt
1a	3.064	2.551 (83,3%)	513 (16,7%)
1b	2.669	2.116 (79,3%)	553 (20,7%)
2	-	-	-
3	2.853	2.538 (89,0%)	315 (11,0%)
5	3.240	2.723 (84,0%)	517 (16,0%)
6a	2.378	1.850 (77,8%)	528 (22,2%)
6b	-	-	-

Tabelle 6.6.: Resultate der Analyse zur räumlichen Ausdehnung beziehungsweise Begrenztheit von Hochaktivitätsobjekten (Datensatz „Stuttgart Flughafen“).

Auswertung Rückschlüsse auf die vorliegende Klasse des finalen Katalogs entnommen werden. Besteht diese Klasse beispielsweise größtenteils aus räumlich begrenzten HAO, so wird angenommen, dass diese Klasse eine lokal begrenzte LULC-Art darstellt (exemplarisch: einzelne Be- und Entladestelle).

Tabelle 6.6 enthält die Ergebnisse für den Stuttgarter Datensatz. Die Resultate für die Szene „Greding“ sind im Anhang zu finden (Tabelle A.4).

### Formparameter

Aus der Segmentierung der lokalen Änderungsumgebung können Formparameter berechnet werden (Abschnitte 4.2.1 und 4.2.3), die weiterführende Informationen über die optimierten Klassen zur Verfügung stellen. Gegenstand der in dieser Arbeit enthaltenen Ausführungen ist die Überprüfung, ob eine Unterscheidung der finalen Klassen anhand von Formparametern überhaupt möglich ist und ob klassenspezifische Ausprägungen beobachtbar sind.

Diese Überprüfung erfolgt ausschließlich mittels visueller Beurteilung grafisch aufbereiteter Resultate (Datensatz „Stuttgart Flughafen“: Abbildungen A.19 und A.20; Datensatz „Greding“: Abbildungen A.21 und A.22).

### 6.2.7. Diskussion

In diesem Abschnitt werden die zuvor gelisteten Resultate der Änderungsanalyse für beide Datensätze gegenübergestellt, sowie einzeln beurteilt. Als Grundlage hierfür dienen die vorgegebenen beziehungsweise angenommenen Voreinstellungen hinsichtlich des initialen Klassenkatalogs und der Verwendung des Fuzzy-Zugehörigkeitswerts von  $z = 50$ .

### Präkategorisierung und Aktivitätscluster

Die Anzahl der im Zusammenhang mit der Präkategorisierung identifizierten Hochaktivitätsobjekte spiegelt die Unterschiede der beiden Testszenen wieder. „Stuttgart Flughafen“ setzt sich aus einer Vielzahl urbaner und suburbaner Strukturen inklusive des Flughafengebiets zusammen, das aufgrund seiner Nutzungsart ständige Veränderungen beinhaltet. Im Vergleich dazu besitzt „Greding“ ländlichen Charakter, da hier eine Kleinstadt von ruralen Bereichen umrandet vorliegt, die allein durch die Autobahn A9 und damit verbundene Rast- und Parkplätzen einige zentrale Hochaktivitätsregionen aufweist. Als Konsequenz resultieren stark unterschiedliche HAO-Anzahlen („Stuttgart Flughafen“: 34.363; „Greding“: 1.852).

Im Hinblick auf die Anzahl der Aktivitätscluster, die HAO mit identischer zeitlicher Signatur zusammenfassen, können ebenfalls stark unterschiedliche Anzahlen festgestellt werden („Stuttgart Flughafen“: 7.056; „Greding“: 875).

### Merkalsextraktion, Skalierung und Reduzierung

Im Zuge der Reduzierung der extrahierten Merkmalsmatrix auf ein unkorreliertes System aus wenigen Hauptkomponenten (Abschnitt 6.2.3) konnten die morphologischen differentiellen Attributprofile als dominante Merkmale identifiziert werden. Daraus folgt für weiterführende Arbeiten, dass sich einerseits eine Beschränkung auf diese Merkmalsgruppe anbietet und andererseits, dass weitere Attribute zur Erstellung der

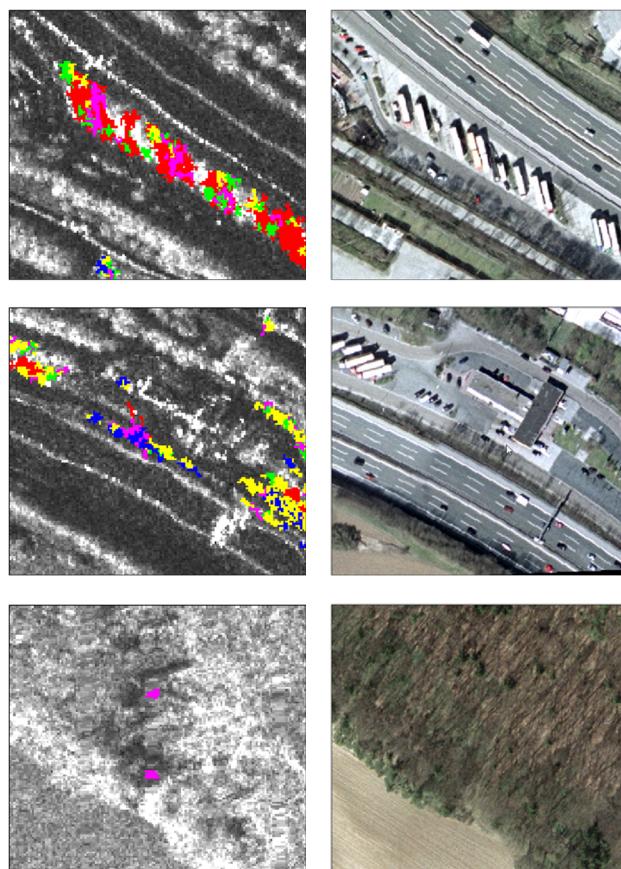


Abbildung 6.16.: Fünfte Kategorie des Datensatzes „Greding“ (magenta-farbene HAO). Obere und mittlere Zeile zeigen Beteiligung an Hochaktivitätsregionen wie Parkplätzen. Untere Zeile: HAO als Teil bewegter Objekte. Linke Spalte: Kategorisierte HAO überlagert in mittlerer Amplitude der Zeitreihe. Rechte Spalte: Entsprechender Ausschnitt aus dem RMK-Luftbildmosaik.

DAP getestet werden sollten (formbeschreibende Parameter etc.).

Der lokale Kontext ist ein Merkmal, das aufgrund seiner binären Ausprägung für den hier beschriebenen Kategorisierungsprozess nicht genutzt wurde, aber dennoch und grundsätzlich viel Potenzial zur Unterscheidung verschiedenartiger Änderungen beinhaltet. Dieses Potenzial wird in der vorliegenden Arbeit zur Unterstützung des Anwenders bei der Interpretation und Analyse des finalen Klassenkatalogs verwendet. Auf diese Weise wird bewusst der Gedanke verfolgt, die verfügbare Datengrundlage und den damit verbundenen Informationsgehalt mit Hilfe des Verfahrens zu erlernen. Um den Kontext auch für die Kategorisierung berücksichtigen zu können, muss eine alternative Bestimmung beziehungsweise Extraktion erfolgen, die keinen diskreten Wertebereich hervorruft. Ein Konzept zur alternativen, *fuzzy*-basierten Berechnung soll im Folgenden erläutert werden.

Es sei ein beliebiges HAO gegeben, das im segmentierten Bildraum von drei Segmenten umgeben ist (Abbildung A.23, II), die zu jeweils unterschiedlichen Kontextklassen gehören (Urban, Infrastruktur, Rural). Weiterhin seien die Schwerpunkte des HAO sowie der drei Segmente bekannt. Wird um die Schwerpunkte der drei Nachbarssegmente analog zu den in Abschnitt 5.2.5 getroffenen Überlegungen jeweils in vier Richtungen eine normalverteilte Zugehörigkeitsfunktion (Abbildung A.23, I) gelegt, so verfügt jedes dieser drei Segmente über eine mit kontinuierlichen Werten modellierbare Zugehörigkeitsregion. Danach können, ausgehend vom Schwerpunkt des HAO, in beispielsweise acht unterschiedlichen Orientierungen (Abbildung A.23, III) in einer vorgegebenen Nachbarschaft (Distanz in Pixel, zum Beispiel 50) die Zugehörigkeitswerte extrahiert werden und in einer tabellarischen Darstellung zusammengefasst werden (Tabelle A.5). Auf diese Weise ergibt sich für jedes HAO eine kontextklassenbezogene Zugehörigkeitsmatrix, die eine Berücksichtigung des lokalen Kontextes für einen statistischen *Clustering*-Prozess ermöglichen würde.

### Kategorisierung

Die Ergebnisse der Vorprojektion geben Aufschluss darüber, ob eine durch den Anwender selektierte Klassenregion in der Datenrealität abgebildet wird. Eine visuelle Beurteilung dieser Datenrealität wird in diesem Absatz anhand der Kategorisierungsresultate für die beiden Testdatensätze vorgenommen. Insbesondere

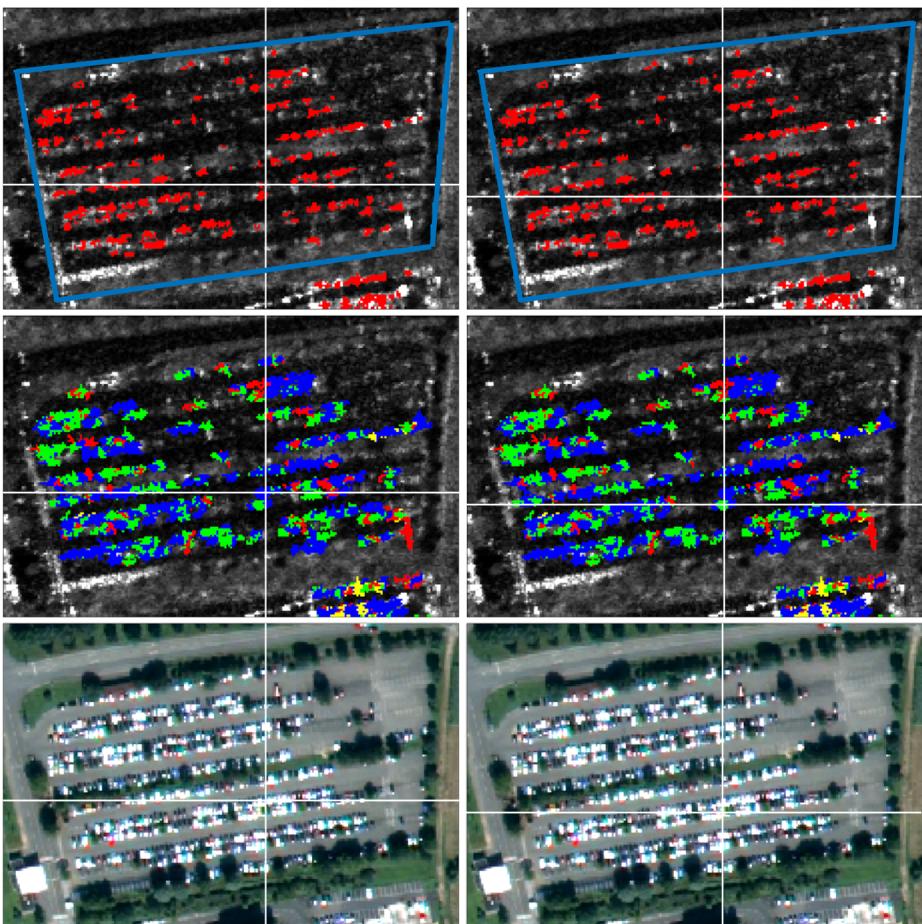


Abbildung 6.17.: Detaillierte visuelle Analyse der durch das Verfahren gefundenen Subklassen 1a und 1b, die auf den beiden dominanten Kategorien 2 (grün) und 3 (blau) aufbauen (Datensatz „Stuttgart Flughafen“, ursprüngliche Klasse PKW-Parkplatz). Obere Reihe: Initial selektierte Klassenregion in gefilterter Aktivitätskarte; mittlere Reihe: Kategorisierungsresultat; untere Reihe: Pangeschärftes WV-2-Bild. Linke Spalte: Örtliche Selektion der Kategorie 2; rechte Spalte: Örtliche Selektion der Kategorie 3.

wird die fünfte Kategorie des Gredinger Datensatzes betrachtet, da diese sich in keiner Klasse des Katalogs als prägend herausstellte (Abbildung A.15). Dies ist erkennbar an den Clusterhistogrammen der initialen Klassen, bei denen die fünfte Kategorie durchweg über geringe prozentuale Anteile verfügt.

Anhand von Abbildung 6.16 ist ersichtlich, dass die fünfte für die Gredinger Szene detektierte HAO-Kategorie offenbar eine Art Mischkategorie darstellt, die jene Änderungsobjekte enthält, die nicht eindeutig zu den ersten vier Kategorien zugeordnet werden konnten. Neben einigen auf Parkplatzbereichen auftretenden kleineren Änderungsstrukturen fällt eine weitere Änderungsform auf, die auf den ersten Blick keinen Zusammenhang zu bisher bekannten Hochaktivitätsregionen aufweist (Abbildung 6.16, unten, Waldbereich). Bei diesen HAO ist auffällig, dass sie jeweils in derselben Vertikalebene, sowie vor einem verschwommenen beziehungsweise verwaschenen Hintergrund im SAR-Bild angeordnet sind. Diese auf den ersten Blick etwas eigenartige Bildsignatur wird durch Objekte auf der Erdoberfläche verursacht, die sich zum Zeitpunkt der Aufnahme in Azimutrichtung relativ zum Sensor in Bewegung befinden. Da sich im Regelfall eine Bewegung eines Objekts am Boden aus Azimut- und Entfernungsrichtungskomponenten zusammensetzt, werden solche Objekte im SAR-Bild versetzt zur eigentlichen Position dargestellt ([207] und [208]).

Eine Begründung des Umstandes, dass diese Änderungskategorie im Gredinger Datensatz enthalten ist und in der Stuttgarter Szenerie nicht, besteht aus verschiedenen Teilaспектen. Einer davon kann in der stark dezimierten Anzahl sogenannter Bewegtobjekte im Vergleich zu den anderen Hochaktivitätsobjekten (Datensatz „Stuttgart Flughafen“) liegen, weshalb diese Kategorie aus statistischer Sicht im Zuge des *Clustering* unbeachtet bleibt. Weiterhin ist es denkbar, dass die große Anzahl an urbanen und industriellen Bereichen inklusive Parkplätzen in der Stuttgarter Szene dazu führt, dass sehr viele Bewegtobjekte räumlich versetzt in diesen Gebieten abgebildet werden. Daraus folgt, dass sich diese bewegten Ziele nicht kategorisch von anderen Objekten trennen lassen.

Bei Betrachtung der Resultate der Vorprojektion für die Szene „Stuttgart Flughafen“ fällt auf, dass je vordefinierter Klasse verschiedene Kategorien dominieren (Abbildung 6.10). Relativ eindeutig kann abgeleitet

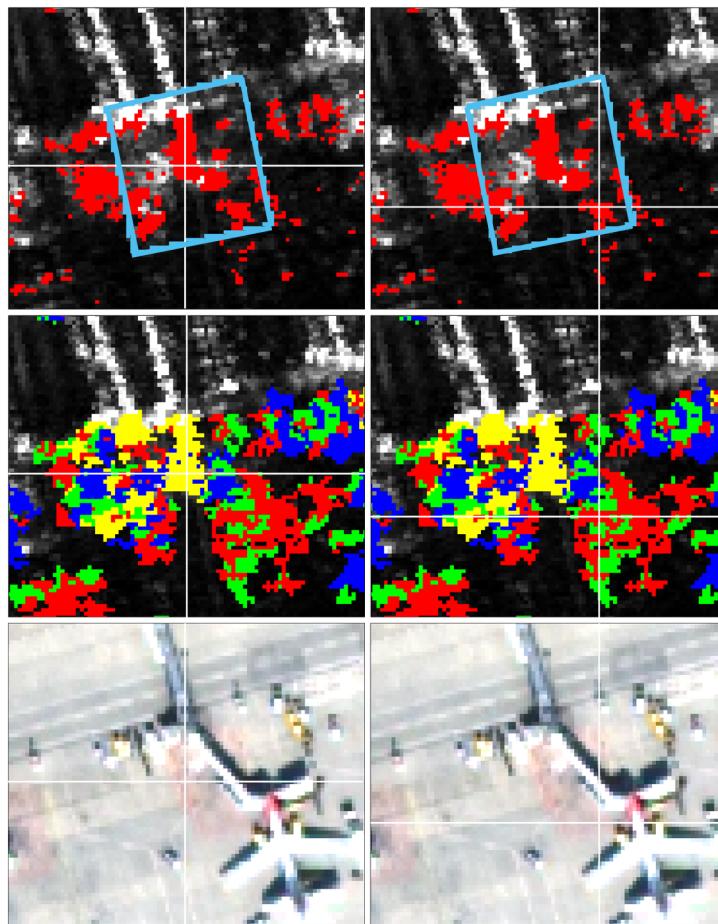


Abbildung 6.18.: Detaillierte visuelle Analyse der durch das Verfahren gefundenen Subklassen 6a und 6b, die auf den beiden dominanten Kategorien 1 (rot) und 4 (gelb) aufbauen (Datensatz „Stuttgart Flughafen“, ursprüngliche Klasse *Flughafen Gate*). Obere Reihe: Initial selektierte Klassenregion in gefilterter Aktivitätskarte; mittlere Reihe: Kategorisierungsresultat; untere Reihe: Pangeschärftes WV-2-Bild. Linke Spalte: Örtliche Selektion der Kategorie 4; rechte Spalte: Örtliche Selektion der Kategorie 1.

werden, dass die vierte Kategorie für die Klasse *Baustelle* steht. Diese Kategorie zeigt sich ebenfalls prägend bei der Klasse *Sammelstelle*, was unter Berücksichtigung des Fotomaterials aus den Ortsbegehungen (Abbildung A.3) durchaus sinnvoll erscheint, da auch hier baustellenähnliche Strukturen enthalten sind (Kipplaster und Container). Eine weitere interessante Beobachtung kann anhand der ersten beiden Klassen *PKW-* und *LKW-Parkplatz* gemacht werden. Beide Klassen beinhalten zwei wesentliche Kategorien (2 und 3), wobei sich diese jeweils in ihrer Dominanz abwechseln (*PKW-Parkplatz*: Kategorie 3; *LKW-Parkplatz*: Kategorie 2) und dementsprechend grundsätzlich voneinander abgrenzbar sind. Ein vergleichbares Verhalten zeigt sich bei der Gredinger Testszene zwischen den Kategorien 3 und 4.

### **Klassenkatalog, Optimierung und Klassifikation**

Die Verarbeitungsschritte der VP, RP und der Klassifikation werden nachfolgend diskutiert. Zunächst wird geprüft, ob die durch die Vorprojektion identifizierten „Problemklassen“ optimiert oder gar neu formuliert wurden. Weiterhin wird die Robustheit des Verfahrens untersucht. So wird beispielsweise getestet, ob für andere Eingabedatensätze mit unterschiedlichem Szeneninhalt oder unter Berücksichtigung anderer Parametereinstellungen sinnvolle Resultate erzeugt werden. Letzteres wird in Abschnitt 6.3 behandelt. An dieser Stelle werden die mit den zuvor beschriebenen Einstellungen produzierten Ergebnisse sowie daraus abgeleitete generelle Stärken und Schwächen der Verfahrensweise diskutiert.

Im Stuttgarter Datensatz wurden im Rahmen der Vorprojektion die initialen Klassen 2, 4 und 6 als problematisch selektiert, da sie nicht unmittelbar als in den Daten abgebildete Klassen erkannt wurden. In Anbetracht der Ergebnisse aus der Rückprojektion kann resumiert werden, dass diese Klassen in robuster Art und Weise neu definiert (Klassen 2 und 6), oder sogar gelöscht wurden (Klasse 4). Darüber hinaus wurden zwei Klassen (Klasse 1 und die neudefinierte Klasse 6) durch den Algorithmus in jeweils zwei Subklassen aufgeteilt, da diese Aufteilung als eine stimmigere Formulierung erachtet wurde. Dieser Klassensplit ist als Stärke des Verfahrens zu nennen, da auf diese Weise kleinere, aber bedeutende Klassenstrukturen identifiziert

werden, die für den menschlichen Nutzer möglicherweise unerkannt geblieben wären. Dieser kann die derart gewonnenen Erkenntnisse nutzen, um den vorliegenden Datensatz und die darin enthaltene Information zu erlernen. In den Abbildungen 6.17 und 6.18 sind die beiden ursprünglichen Klassen 1 und 6 jeweils detaillierter im Ortsraum (Bild) dargestellt. In Bezug zur ursprünglichen Klasse *PKW-Parkplatz* kann durch manuelle Inspektion (weiße Fadenkreuze) festgestellt werden, dass keine klare Unterscheidung der Ortssemantik möglich ist, wobei generell zu beachten ist, dass die hier verwendete optische Datengrundlage nicht die gleiche zeitliche Epoche wie die SAR-Zeitreihe wiederspiegelt. Darüber hinaus ist zu erwähnen, dass die räumlich äußerst beengte Anordnung der Stellplätze auf diesem Parkplatz grundsätzlich zu unerwünschten Zusammenlegungseffekten von Änderungssegmenten führen kann. Da die in dieser Arbeit verwendete Methode zur Änderungsdetektion auf der Analyse von zusammenhängenden Komponenten aufbaut, ist die Tendenz vorhanden, räumlich nah beieinander angeordnete aber semantisch verschiedene Objekte der realen Welt zu einem Änderungssegment zusammenzufassen. Dies kann zur Folge haben, dass eine Verfälschung in der Kategorisierung und damit auch in der Klassifikation auftritt. Der Anwender muss diese Problematik stets bei der Selektion seiner initialen Klassenregion in Betracht ziehen und gegenebenfalls eine alternative Auswahl vornehmen.

Bei der sechsten initialen Klasse (*Flughafen Gate*) ist die detaillierte Betrachtung mithilfe der optischen Datenreferenz zielführender (Abbildung 6.18). Es kann abgeleitet werden, dass die gelbe Kategorie in einem Ortsbereich dominiert, in dem sich die schwenkbare Brücke befindet, die zum Betreten und Verlassen eines Flugzeugs genutzt wird (Abbildung 6.18, untere Reihe). Im Gegensatz dazu dominiert die rote Kategorie einen Bereich, der als Parkplatz für be- und entladbare Flugzeuge verwendet wird. Zusammenfassend kann somit festgehalten werden, dass in dieser lokalen Ortsregion tatsächlich zwei voneinander verschiedene Hochaktivitätsbereiche identifizierbar sind.

Für die Gredinger Szenerie lieferte die Vorprojektion einen Hinweis darauf, dass die vorab gewählte Klasse 3 über keine dominant ausgeprägte Kategorienstruktur verfügt (Abbildung A.15). Da diese Klasse dennoch die Dichtebereiche zweier Kategorien vollständig abdeckte, wurde durch das Verfahren eine Neudeinition in die beiden Klassen 3a und 3b durchgeführt (ähnlich zu den Klassen 6 beziehungsweise 6a und 6b des Stuttgarter Datensatzes). Eine zur Stuttgarter Szenerie ähnliche, detaillierte Beurteilung dieser Klassenregion ist hier nicht möglich, da es sich hierbei um eine Baustelle handelt, die zum Zeitpunkt der RMK-Bildaufnahme noch nicht vorhanden war. Zu den beiden Subklassen 3a und 3b können deshalb nur Mutmaßungen angestellt werden. Eine mögliche Erklärung könnte sein, dass im Zuge des dortigen Bauvorhabens kategorisch unterschiedliche Gerätschaften oder Baumaterial positioniert waren. Da die neu erstellten Klassen 3a und 3b mit der ursprünglich definierten Klassenregion keine Gemeinsamkeiten mehr aufweisen, können in Abbildung A.17 keine sinnvollen Zusammenhänge mehr hergestellt werden. Tritt dieser Fall ein, so muss der Anwender selbst die neu erstellten Klassen interpretieren und beispielsweise mittels optischer Datenreferenz die jeweilige Semantik erlernen. Dieser Umstand ist als Schwäche der Methode zu verstehen, da diese Vorgehensweise wiederum ein gewisses Maß an Geschick im Umgang mit fernerkundlichem Bildmaterial voraussetzt. Eine Unterstützung erhält der Anwender dennoch durch die im Rahmen der Klassenbeschreibung zur Verfügung gestellten Zusatzinformationen hinsichtlich des lokalen Kontextes.

In Anbetracht der Ergebnisse aus der Rückprojektion fällt auf, dass zwar zu grob selektierte Klassen in mögliche Unterklassen aufgeteilt werden, aber eine zu feine beziehungsweise detaillierte Klassendefinition nicht zu einem Zusammenschluss (*Merging*) mit umgebenden größeren Klassenregionen führt. Dieses Verhalten der Methode ist an dieser Stelle ausdrücklich so gewollt, da tendenziell ein möglichst detaillierter Klassenkatalog erstellt werden soll, um dem Anwender eine genaue Klassenunterscheidung zur Wissensbildung zu ermöglichen. Durch manuelle Analyse des zweidimensionalen Merkmalsraums mit final vorliegendem Klassenkatalog (Abbildung 6.11) können mögliche Überlagerungen und räumliche Zusammenhänge in einfacher Weise und unmittelbar abgeleitet werden.

Hinsichtlich der Klassifikation der HAO ist festzuhalten, dass eine pauschal für alle Eingabedaten und Anwendungszwecke gültige Einstellung des Schwellwerts  $z$  nicht existiert. Eine Variation dieses Parameters wird in Abschnitt 6.3.7 erläutert. Die Klassifikationsresultate sind in Anlehnung an die initial gewählten Klassenregionen in der Örtlichkeit dargestellt (Abbildungen 6.13, 6.14, beziehungsweise A.17). Neben der relativ hohen Rate an unklassifizierten HAO (weiß markiert) zeigt sich, dass die beiden ersten ursprünglichen Klassen für die Stuttgarter Szene im finalen Status durch die beiden Unterklassen 1a und 1b (jeweils wechselnd) dominiert werden. Daraus folgt, dass die in der Klassenregion *PKW-Parkplatz* enthaltene finale Klasse 1a im Vergleich zur Region *LKW-Parkplatz* charakterisierend ist und eine Struktur kennzeichnet, die auf dem *PKW-Parkplatz* stärker vertreten ist. Die initialen Klassenregionen 6 (Datensatz „Stuttgart Flughafen“) und 3 (Datensatz „Greding“) spiegeln die weiter oben beschriebene Schwäche des Verfahrens bei neu definierten Klassen wieder. Beide ursprünglichen Klassenregionen umfassen ein mehr oder weniger stark ausgeprägtes Rauschen an unterschiedlichen Kategorien, was dazu führt, dass sich die entsprechenden Klassenboxen im Merkmalsraum über mehrere verschiedene Cluster erstrecken. Bei einer Neudeinition dieser Klassen durch

den Algorithmus wird zwar diese grobe Abdeckung im zweidimensionalen Merkmalsraum aufgelöst, doch kann damit auch eine Abkehrung von der ursprünglichen Ortssemantik erfolgen. Dies ist darin begründet, dass sich zwar die Klassenboxen im Merkmalsraum an eine andere Stelle verschieben, die kategorisierten HAO jedoch an ihrer ursprünglichen Örtlichkeit verbleiben. Wie weiter oben beschrieben müssen somit neu entstandene Klassen mit den initialen Selektionen nichts mehr gemeinsam haben, wie anhand der beiden Klassen 6 (final: 6a und 6b, „Stuttgart Flughafen“) und 3 (final: 3a und 3b, „Greding“) ersichtlich ist. Abschließend wurden für eine ortssemantische Analyse die Klassifikationsresultate (Datensatz: „Stuttgart Flughafen“, sechs initiale Klassen, Fuzzy-Zugehörigkeitsschwelle  $z = 50$ ) in einem Bildausschnitt, der mehrere Hochaktivitätsbereiche beinhaltet, analysiert (Abbildung A.18). Es zeigte sich, dass durchweg sinnvolle Ergebnisse erstellt wurden, die zur jeweiligen Örtlichkeit stimmig sind.

### Klassenbeschreibung

Wie zuvor erwähnt, ist die Beschreibung der Kontextklasse eine wichtige, insbesondere zur Interpretation neu eingeführter Klassen verwendbare Informationsebene. Anhand der in den Abbildungen 6.15 und A.10 zusammengefassten Ergebnisse unter Berücksichtigung des hier eingestellten Zugehörigkeitswerts  $z = 50$  kann ein unterschiedliches Verhalten beobachtet werden.

Für die Stuttgarter Szenerie lässt sich eindeutig die Kontextklasse *Urban* als dominant über alle finalen Klassen festhalten. Im Fall der Gredinger Szenerie ist dies tendenziell die Kontextklasse *Infrastruktur*, wobei hier auch andere Kontextklassen bedeutenden Einfluß aufweisen. Eine Erklärung hierfür ist in der jeweils genutzten Datengrundlage zu finden (Datensatz „Stuttgart Flughafen“: OSM und *CovAmCoh* als Unterstützung; Datensatz „Greding“: LULC-Kartierung), die zu Testzwecken unterschiedlich gewählt wurde. Als Erkenntnis aus diesem Test kann abgeleitet werden, dass eine LULC-Karte eine detailliertere und somit auch vollständigere Modellierung der örtlichen Begebenheiten darstellt, die zu einer aussagekräftigeren Beurteilung des lokalen Kontextes verwendet werden kann. Zwar ist die durch OSM und *CovAmCoh* gestützte Verarbeitung zuweilen die am einfachsten zugängliche Methode, besitzt allerdings den Nachteil, dass die aus OSM extrahierten Vektorlayer nicht für jede Szenerie im gleichen Detailgrad verfügbar sind.

Bei der Analyse der räumlichen Ausdehnung und Begrenztheit der HAO innerhalb ihrer lokalen Umgebung können für beide Testdatensätze vergleichbare Trends festgestellt werden (Tabellen 6.6 und A.4). Einerseits ist dies nicht verwunderlich, da für beide Szenen vergleichbare Klassenkataloge voreingestellt wurden, die gleichfalls Klassenregionen beinhalten, deren beteiligte HAO im Regelfall keine lokale Begrenztheit aufweisen sollten (Parkplätze oder Sammelstellen). Dennoch ist ein Effekt im Zusammenhang mit der Klasse *Be-/Entladestelle* zu beobachten, deren Klärung im Rahmen weitergehender Arbeiten eingehender untersucht werden sollte.

Da diese Klasse für den Stuttgarter Datensatz als nicht existent bewertet und demzufolge gelöscht wurde, soll hierfür die Gredinger Szene als Anschauungsbeispiel dienen. Die initiale Klasse 4, die auch im optimierten Klassenkatalog vorhanden ist, kennzeichnet gemäß Vorauswahl einen räumlich gering ausgedehnten lokalen Bereich eines industriellen Geländes (Abbildung A.14). Entgegen der Erwartung, bei dieser Klasse einen hohen prozentualen Anteil an räumlich begrenzten HAO zu beobachten, stehen die in Tabelle A.4 enthaltenen Werte. Eine mögliche Erklärung für diese Gegensätzlichkeit kann mit Tabelle A.3 gegeben werden, die besagt, dass diese Klasse im Rahmen der Rückprojektion optimiert wurde und dementsprechend nicht exakt mit ihrer initialen Version übereinstimmt. Da sich die in den zuvor genannten Tabellen enthaltenen Werte auf die dem finalen Klassenkatalog zugewiesenen HAO beziehen, kann dies widersprüchliche Rückschlüsse erzeugen. Im Grunde ist dieses Verhalten analog zu der oben erläuterten Problematik neu definierter Klassen zu bewerten. Abhilfe könnte hier die Analyse jener HAO schaffen, die sich beispielsweise in einem durch den Anwender manuell gewählten Bildbereich befinden, der allein die neu erstellte Klasse beinhaltet.

Als letztes unterstützendes Merkmal zur Beschreibung des finalen Klassenkatalogs wurden Formparameter für die HAO-umgebenden Segmente berechnet (Abbildungen A.19, A.20, beziehungsweise A.21, A.22).

Für den Stuttgarter Datensatz kann festgehalten werden, dass bei den Merkmalen Rundheit und Fläche keine klassenspezifischen Verläufe beobachtbar sind. Ansatzweise können derartige Trends bei den Merkmalen Dichte und Kompaktheit festgestellt werden (Dichte: Finale Klassen 1b und 3; Kompaktheit: Finale Klassen 3 und 5 ähnlich, Unterschiede zu finalen Klassen 1a, 1b und 6a). Ähnliche Erkenntnisse liefert der Gredinger Datensatz, bei dem auch die Merkmale Dichte und Kompaktheit tendenziell das meiste Potenzial zu einer Klassenunterscheidung besitzen. Grundsätzlich kann aber festgehalten werden, dass diese Form der Klassenbeschreibung eher wenig brauchbar erscheint, da für beide Szenen ähnliche Klassenregionen betrachtet wurden, die durch ähnlich strukturierte Bildregionen gekennzeichnet sind und zu ähnlich beschaffenen Segmenten führen. Für andere Szenen, in denen Hochaktivitätsregionen semantisch verschiedene Örtlichkeiten bezeichnen (zum Beispiel urbane und rurale Bereiche), könnte mittels dieser Vorgehensweise ein Mehrwert an verwendbarer Information extrahierbar sein.

### 6.3. Quantitative Evaluierungen und Vergleiche verschiedener Verfahren

Im vorherigen Abschnitt 6.2 wurde bereits angesprochen, dass einige Parametereinstellungen zur Erstellung der dort präsentierten Resultate vorgenommen worden sind (zum Beispiel Anzahl und Beschaffenheit der Klassen im intialen Katalog sowie Fuzzy-Zugehörigkeitswert (Abschnitt 6.2.5)). Darüber hinaus wurde der Schwellwert  $CL_\tau = k^*/2$  zur Beurteilung verwendet, ob eingeführte Klassen überhaupt in den kategorisierten Daten enthalten sind (Abschnitt 5.2.3). Zu diesen Parametrisierungen sind nachfolgend weiterführende Untersuchungen und Erklärungen gegeben.

Des Weiteren wird das vorgestellte Verfahren zur Änderungsdetektion mit der für SAR verbreiteten KLD-Methode (siehe Abschnitt 1.1) verglichen (Abschnitt 6.3.1) und anhand von Referenzdatenmaterial evaluiert. Für diesen Evaluierungsschritt werden die in Abschnitt 6.1.1 beschriebenen Webcam-Aufnahmen genutzt. Als Datengrundlage dient somit exemplarisch die Stuttgarter Testszene.

Die in dieser Arbeit automatisch vorgenommene Detektion von Änderungen anhand der Methode nach Renyi (siehe Abschnitt 2.2.2) wird in Abschnitt 6.3.2 den anderen entropiebasierten Schwellwertverfahren nach Kapur und Yen bewertend gegenübergestellt.

Eine Evaluierung der in Abschnitt 4.2.1 erläuterten Segmentierungsmethode wird in Abschnitt 6.3.3 vorgenommen. Als Vergleichsmethode wird das MrSeg-Verfahren der kommerziellen Software eCognition Developer betrachtet.

Sowohl für die Gegenüberstellung der Schwellwertverfahren als auch für die Evaluierung der entwickelten Segmentierungsmethode werden Konfusionsmatrizen und daraus ableitbare Kenngrößen (zum Beispiel *True Positives* etc.) eingesetzt. Eine vergleichbare Evaluierung der Kategorisierungs- und Klassifikationsergebnisse findet, wie bereits in Abschnitt 6.2.5 erläutert, nicht statt. Hier wird die Tatsache als ausreichend erachtet, dass sich einerseits die ermittelten Kategorien beziehungsweise Cluster klar voneinander im Merkmalsraum abgrenzen und sich andererseits semantisch stimmige Klassifikationsresultate ergeben, die je nach Wahl der Fuzzy-Zugehörigkeitsschwelle variieren.

In Abschnitt 6.3.4 erfolgen Ausführungen zur raumzeitlichen Analyse, die die in den Abschnitten 3.2.2 und 3.2.3 eingeführten Aktivitätscluster und Hochaktivitätsstapel umfasst. Insbesondere soll geklärt werden, ob diese Informationsebene für eine detailliertere Änderungsanalyse genutzt werden kann.

#### 6.3.1. Änderungsdetektion

Im Vergleich zu der in dieser Arbeit verwendeten Methode zur Detektion von Änderungen in SAR-Bildpaaren (siehe Abschnitt 3.1) stellt die *Kullback-Leibler-Divergenz* (KLD) ein statistisch motiviertes Verfahren dar. Dieses Prinzip basiert auf dem Vergleich zweier voneinander temporär unabhängiger SAR-Bilder durch Gegenüberstellung der anhand der enthaltenen Grauwerte schätzbarer Wahrscheinlichkeitsdichtefunktionen (PDF) ([32] und [52]). Zur Schätzung dieser PDF und zur Berechnung der KLD existieren verschiedene Ansätze. Einer davon ist die Verwendung eines bewegten Fensters, in dem für beide Bilder in identischen Bereichen die Histogramme der dort befindlichen Grauwerte bestimmt werden, wobei hierfür eine fest vorgegebene Anzahl an *Bins* vorgegeben wird [33].

Ein alternativer Ansatz [52] basiert auf der Nutzung der sogenannten *Edgeworth-Reihenentwicklung*, sowie auf der Annahme, dass normalverteilte Bilddaten in die Berechnung eingehen. Als Berechnungsformel für die KLD ergibt sich dann für zwei logarithmierte SAR-Amplitudenbilder  $A_1$  und  $A_2$ :

$$KLD(A_1, A_2) = \frac{\sigma_1^4 + \sigma_2^4 + (\mu_1 - \mu_2)^2 (\sigma_1^2 + \sigma_2^2)^2}{2\sigma_1^2\sigma_2^2} - 1, \quad (6.1)$$

wobei  $\mu_i$  die Mittelwerte und  $\sigma_i$  die Standardabweichungen sind, die in den bewegten Fenstern der Bilder  $i$  berechnet werden.

Die Schätzung des KLD-Werts in einem bewegten Fenster beinhaltet sowohl Vor- als auch Nachteile. Der Vorteil liegt sicherlich darin, dass die Wahl der Fenstergröße ähnlich zu der hier verwendeten LR-Methode basierend auf einem modifizierten ASF-Filterungsansatz, eine indirekte Steuerung der resultierenden Änderungsgröße erlaubt. In Kontrast zu dem gewählten LR-Ansatz besitzt die hier beschriebene KLD-Methode aber einen bedeutenden Nachteil. Dieser ergibt sich aus der Berechnung anhand eines bewegten Fensters, das je Größe zu einem mehr oder weniger stark „verwaschenen“ Ergebnisbild führt. Dieser der Anwendung eines Glättungsfilters ähnelnde Effekt tritt bei der Detektion mit der vorgeschlagenen ASF-Filterungstechnik nicht auf, da dabei die zusammenhängenden Komponenten und keine umgebenden Strukturen betrachtet werden (siehe auch Abbildung 6.19, III bis IX). Ein weiterer Nachteil der KLD-Methode besteht darin, dass die Wahl einer geeigneten Dimensionierung des bewegten Fensters wiederum einen *Trial-and-Error*-Prozess darstellt. Da aus genannten Gründen die präsentierte LR-Methode in Verbindung mit der ASF-Filterung gewichtige

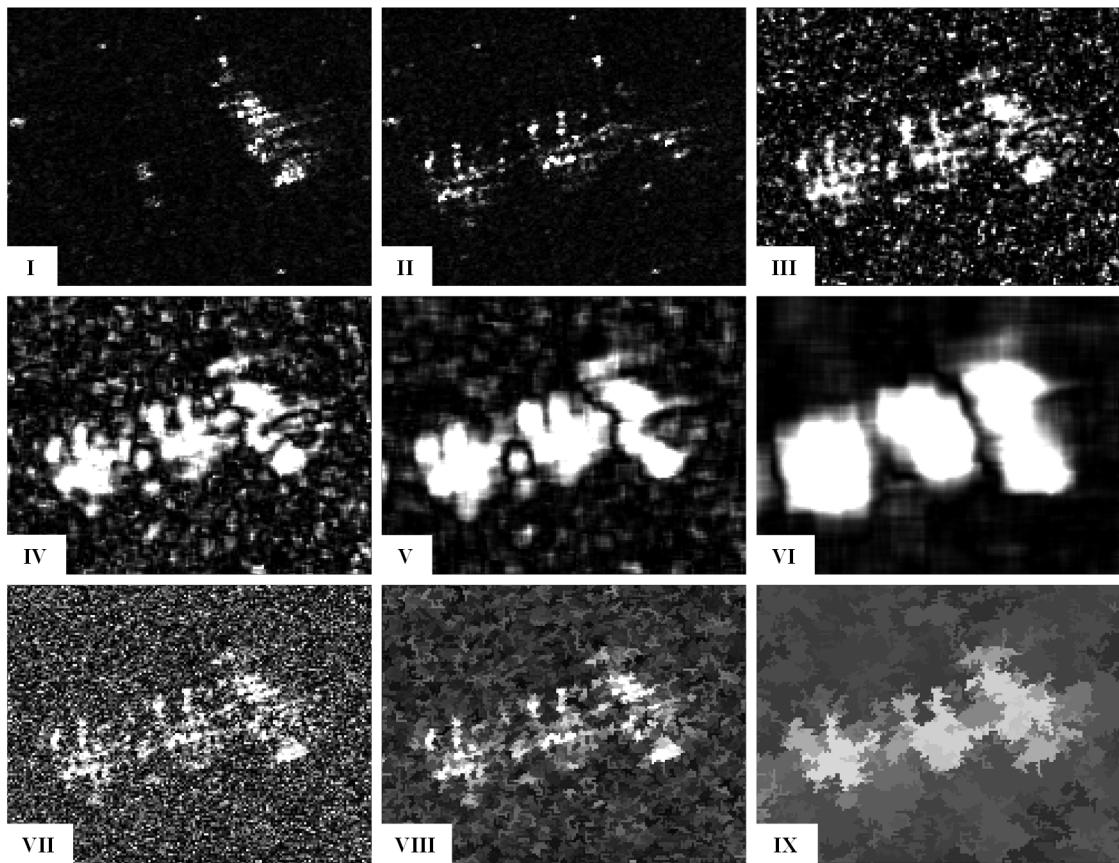


Abbildung 6.19.: Gegenüberstellung der KLD-Methode mit dem vorgestellten LR-Ansatz (Teil 1). I: Amplitude zum Zeitpunkt  $t_1$ ; II: Amplitude zum Zeitpunkt  $t_2$ ; III: KLD-Ergebnis für Fenstergröße  $3 \times 3$ ; IV: KLD-Ergebnis für Fenstergröße  $5 \times 5$ ; V: KLD-Ergebnis für Fenstergröße  $9 \times 9$ ; VI: KLD-Ergebnis für Fenstergröße  $25 \times 25$ ; VII: LR-Quotientenbild vor ASF-Filterung; VIII: ASF-gefiltertes Quotientenbild mit Fokus auf kleinräumige Änderungen; IX: ASF-gefiltertes Quotientenbild mit Fokus auf mittleräumige Änderungen.

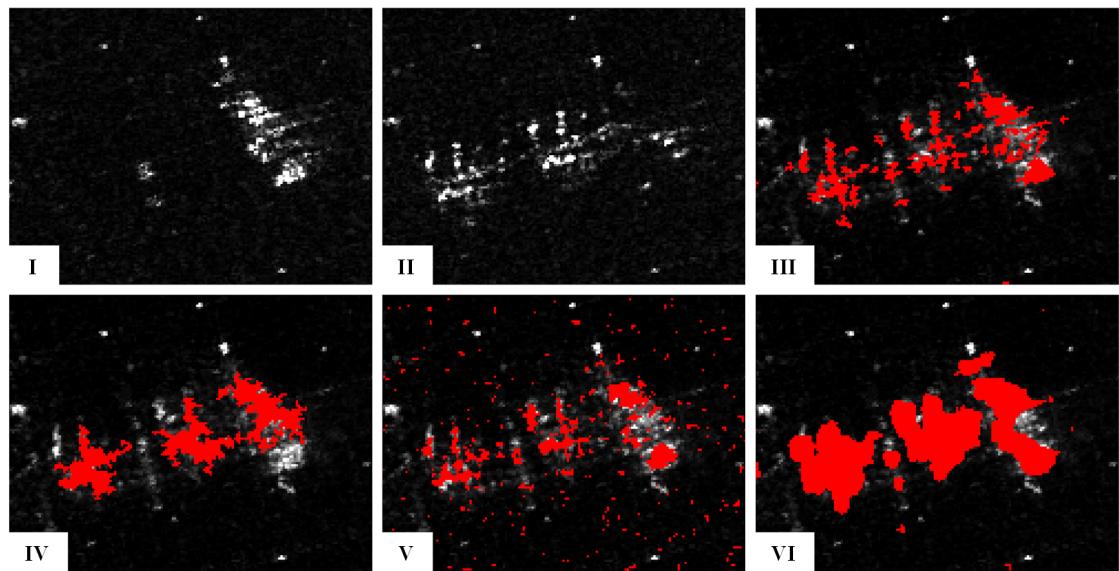


Abbildung 6.20.: Gegenüberstellung der KLD-Methode mit dem vorgestellten LR-Ansatz (Teil 2). I: Amplitude zum Zeitpunkt  $t_1$ ; II: Amplitude zum Zeitpunkt  $t_2$ ; III: Farbkodiertes Detektionsresultat (rot: Änderungen) auf Grundlage des Bildes in Abbildung 6.19, VIII; IV: Farbkodiertes Detektionsresultat (rot: Änderungen) auf Grundlage des Bildes in Abbildung 6.19, III; V: Farbkodiertes Detektionsresultat (rot: Änderungen) auf Grundlage des Bildes in Abbildung 6.19, V; VI: Farbkodiertes Detektionsresultat (rot: Änderungen) auf Grundlage des Bildes in Abbildung 6.19, V.

Vorteile besitzt, die für die Bearbeitung der vorliegenden Aufgabenstellung besser geeignet ist als die KLD-Methode, wird auf eine detaillierte, empirische Gegenüberstellung der Detektionsresultate verzichtet.

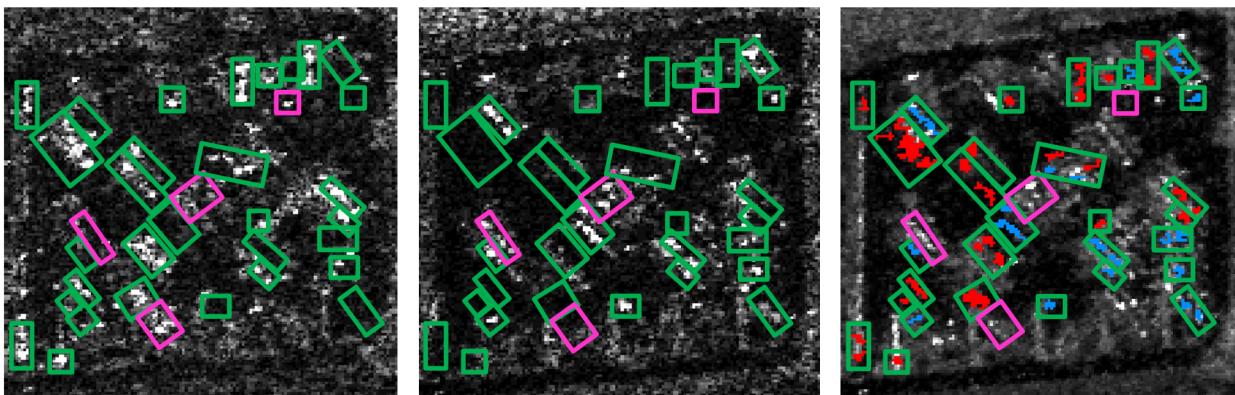


Abbildung 6.21.: Empirische Beurteilung der Detektionsgüte in einer Hochaktivitätsregion (Datensatz „Stuttgart Flughafen“). Links: Amplitude zum Zeitpunkt  $t_{13}$ ; Mitte: Amplitude zum Zeitpunkt  $t_{14}$ ; rechts: Analyseresultat. Grüne Boxen kennzeichnen korrekt erkannte Änderungen, magenta-farbene Boxen symbolisieren nicht detektierte Änderungen.

Der Vergleich wird visuell durchgeführt.

Als Beispielbildpaar dienen Ausschnitte der ersten beiden zeitlich aufeinander folgenden Aufnahmen der Stuttgarter Zeitreihe. Es wird die durch die in Abschnitt 3.1 beschriebene Verfahrensweise erstellte farbkodierte binäre Änderungskarte mit der durch die oben dargelegte KLD-Methode ermittelten Änderungsinformation verglichen. Der Schwellwert zur Identifikation von Änderungen auf Grundlage des KLD-Resultats wird analog zu der in dieser Arbeit verwendeten LR-Methode durch Anwendung des Verfahrens nach Renyi ermittelt. Hierfür erfolgt als Vorverarbeitung eine lineare Skalierung des aus dem KLD-Verfahren resultierenden Grauwertbereichs von [0; 1] nach 8 Bit beziehungsweise [0; 255]. In Abbildung 6.20 sind die farbkodierten Ergebnisbilder der beiden Detektionsverfahren enthalten. Der durch Abbildung 6.19 gestützte Eindruck der Generalisierung mit zunehmender Fenstergröße bei Anwendung des KLD-Verfahrens zeigt sich auch hier. Diese Tendenz zur glättenden Eliminierung ursprünglicher Bildstrukturen erweist sich insbesondere für eine formbasierte Analyse der Änderungen als nachteilig. Außerdem ist ersichtlich, dass eine feinskalig gewählte Fensterung (Abbildung 6.19, III) zu einem relativ verrauschten Detektionsergebnis im Vergleich zur ASF-basierten LR-Methode führt (Abbildung 6.20, III und V). Um die starke Generalisierung mit ansteigender Fenstergröße bei der KLD-Methode zu vermeiden, könnte eine alternative Vorgehensweise verfolgt werden. Diese beinhaltet die Verwendung der KLD-Resultate nicht direkt als Eingabebilder für die Änderungsdetektion, sondern lediglich als Indikationsgrundlage. Auf diese Weise würden zunächst mittels KLD-Resultat Hinweise auf Änderungsregionen extrahiert und diese im ursprünglichen, maximalen Quotientenbild (Abbildung 6.19, VII) markiert werden. In diesem Bild würde im Anschluß eine Suche nach hellen Bildelementen erfolgen, was aber wieder der Anwendung eines Schwellwerts bedarf. Auch bei dieser Vorgehensweise würde ein ähnliches Ergebnis produziert werden, wie es in Abbildung 6.20, V, bereits gegeben ist. Auch anhand dieser Überlegungen erweist sich die in dieser Arbeit vorgestellte LR-Methode als vorteilhaft, da die Filterung mit den ASF zu einer zielführenderen und praktikableren Lösung führt.

Zusammenfassend kann festgehalten werden, dass die in dieser Arbeit vorgestellte LR-Methode unter Berücksichtigung eines modifizierten ASF-Ansatzes für die vorliegende Aufgabenstellung signifikante Vorteile besitzt. Das KLD-Verfahren detektiert zwar die gleichen Änderungsbereiche, doch führt die Anwendung des bewegten Fensters zu einer unerwünschten Eliminierung von informationstragenden Bildstrukturen.

### Evaluierung der Detektionsgüte des vorgestellten Verfahrens

Zur Beurteilung der Güte des in dieser Arbeit erläuterten Verfahrens zur Änderungsdetektion werden einerseits eine Webcam-Aufnahme eines Vorfeldabschnitts des Flughafens Stuttgart und andererseits eine weitere Hochaktivitätsregion (LKW-Parkplatz) manuell ausgewertet. Für den Stuttgarter Flughafen existieren verschiedene Webcams, die quasi in Echtzeit mit einem zeitlichen Abstand von wenigen Sekunden optische Bilddaten unterschiedlicher Bereiche (Gates, Vorfeld, etc.) zur Verfügung stellen<sup>2</sup>. Zum Aufnahmezeitpunkt der SAR-Bilder konnte dementsprechend für diese Bereiche GT-Bildmaterial erhoben werden. In Abbildung A.24 ist exemplarisch der Standpunkt 1 und das Sichtfeld dieser Webcam dargestellt.

Die in der farbkodierten Änderungskarte visualisierten Bereiche (Abbildung A.24, unten) wurden durch manuelle visuelle Interpretation identifiziert. Jeder der drei Bereiche beinhaltet entweder hinzukommende oder verschwindende Änderungen (hier: Flugzeuge), die komplett und korrekt durch das Verfahren detektiert wurden.

Eine empirische Auswertung der Detektionsgüte erfolgt in dem bereits bekannten Hochaktivitätsgebiet des

<sup>2</sup><http://www.flughafen-stuttgart.de/erlebnis-flughafen/webcams-am-flughafen>, zuletzt besucht (TT.MM.JJJJ): 15.01.2018

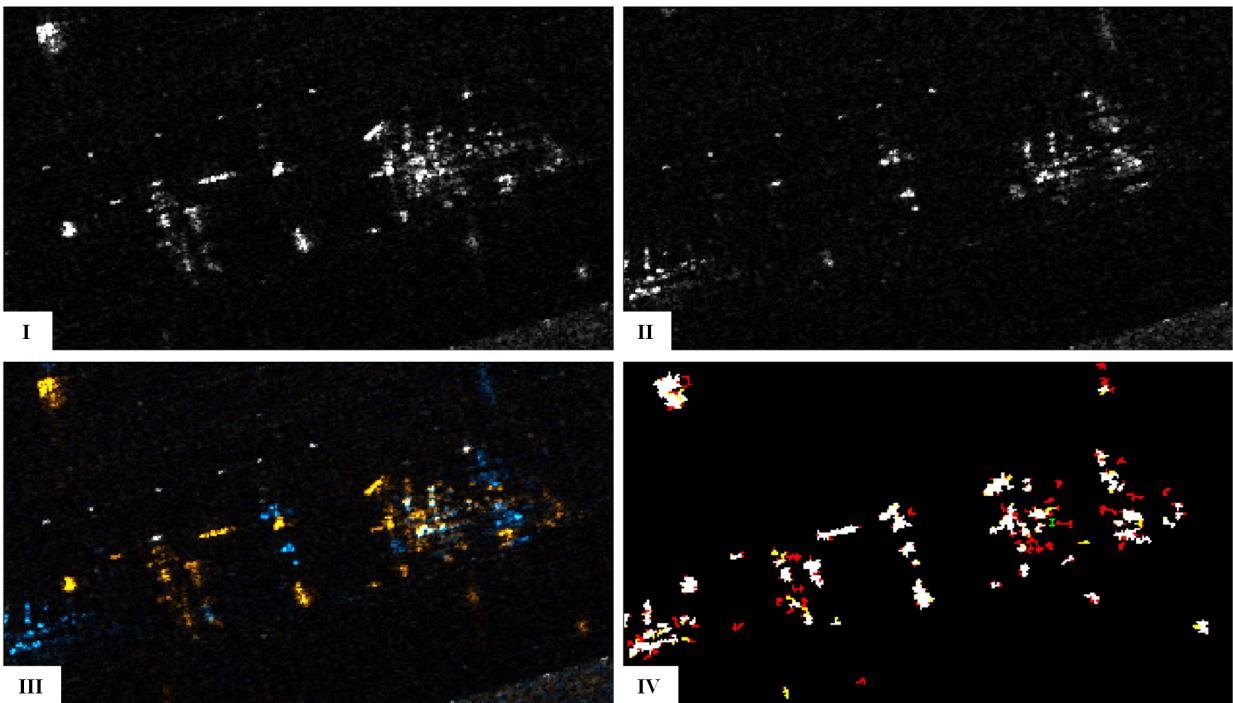


Abbildung 6.22.: Gegenüberstellung entropiebasierter Schwellwertmethoden (Datensatz „Stuttgart Flughafen“), erstes Testgebiet. I: Amplitude  $t_1$ ; II: Amplitude  $t_2$ ; III: Farbige Darstellung der Änderungen („blue is new, gold is old“); IV: RGB-Visualisierung der drei resultierenden binären Änderungskarten ( $R = CM_{Renyi}$ ,  $G = CM_{Kapur}$  und  $B = CM_{Yen}$ ). Die Darstellung zeigt einen Ausschnitt aus dem in diesem Abschnitt genutzten,  $525 \times 894$  Pixel großen Testgebiet.

LKW-Parkplatzes (siehe auch Abschnitt 3.1). In diesem Bildbereich wurden in überwachter Weise alle zeitlich aufeinander folgenden Bildpaare der Zeitreihe betrachtet und Änderungen manuell markiert. Diese Markierungen wurden danach mit den passenden Änderungskarten abgeglichen, wobei vier Fälle beurteilt wurden: „Korrekt detektiert“; „nicht detektiert“; „teilweise korrekt detektiert“; „falsch detektiert“. Der dritte Fall der teilweisen korrekten Detektion tritt auf, wenn eine manuell selektierte Änderung nicht vollständig durch ein automatisch ermitteltes Änderungssegment abgedeckt wird. Eine falsche Detektion kennzeichnet einen durch das Verfahren erstellten Falschalarm. Als Beispiel dient das sich aus den Amplituden zu den Zeitpunkten  $t_{13}$  und  $t_{14}$  zusammensetzende Bildpaar (Abbildung 6.21, links und Mitte). Auf der rechten Seite ist das Analyseresultat dargestellt, wobei eine grüne Box eine korrekte Detektion und eine magenta-farbene Box eine nicht detektierte Änderung markiert. Die Farbkodierung der Änderungskarte (rechts) entspricht den in Abschnitt 3.1 beschriebenen Vorgaben. So symbolisieren rot markierte Bereiche verschwindende Änderungen und blau markierte Bereiche hinzukommende Änderungen.

In dem hier visualisierten Fall resultierten folgende Werte: Korrekte Detektionen (88,6 %), nicht detektierte Änderungen (11,4 %), teilweise korrekt detektiert (2,9 %) und falsch detektiert (0,0 %). Über die gesamte Zeitreihe hinweg, bestehend aus 14 zeitlich aufeinander folgenden Änderungskarten, ergaben sich für diesen Bildbereich die Werte: Korrekte Detektionen (67,8 %), nicht detektiert (17,6 %), teilweise korrekt detektiert (8,5 %) und falsch detektiert (6,1 %). Als äußerst positiv für das Verfahren ist die sehr geringe Falschalarmrate zu nennen. Weiterhin resultiert eine hohe Rate an korrekt detektierten Änderungen - auch unter Berücksichtigung des Werts für teilweise korrekt detektierte Änderungen.

Hinsichtlich der Genauigkeit des Verfahrens in Bezug auf die Detektionsgüte kann somit festgehalten werden, dass durchweg verlässliche und robuste Ergebnisse erreicht werden.

### 6.3.2. Unüberwachte Schwellwertverfahren

Im Abschnitt 2.2.2 wurden bereits die Formalismen dreier entropiebasierter Methoden (*Renyi*, *Kapur* und *Yen*) zur unüberwachten Ermittlung eines Schwellwerts erläutert. Nachfolgend werden diese Verfahren empirisch anhand zweier Bildbeispiele (Ausschnitte aus der Szene „Stuttgart Flughafen“) gegenübergestellt.

Die Testgebiete (Dimensionen:  $525 \times 894$  Pixel und  $315 \times 367$  Pixel) wurden aus dem ersten zeitlich aufeinander folgenden Bildpaar der Stuttgarter Zeitreihe extrahiert. Das erste Testgebiet umfasst einen Bereich des Stuttgarter Flughafens, bestehend aus Gates und Vorfeld (ein Ausschnitt ist in Abbildung 6.22 enthalten). Das

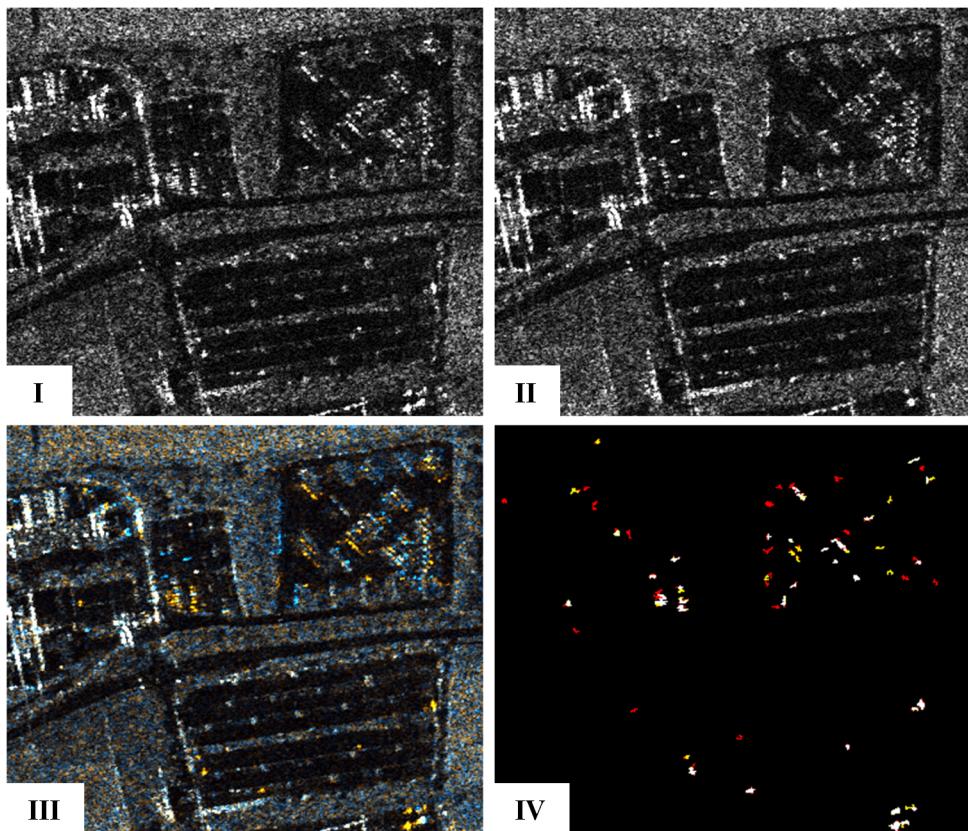


Abbildung 6.23.: Gegenüberstellung entropiebasierter Schwellwertmethoden (Datensatz „Stuttgart Flughafen“), zweites Testgebiet. I: Amplitude  $t_1$ ; II: Amplitude  $t_2$ ; III: Farbige Darstellung der Änderungen („blue is new, gold is old“); IV: RGB-Visualisierung der drei resultierenden binären Änderungskarten ( $R = CM_{Renyi}$ ,  $G = CM_{Kapur}$  und  $B = CM_{Yen}$ ).

zweite Testgebiet beinhaltet einen industriellen Bereich, der sich aus LKW- und PKW-Parkplätzen zusammensetzt (Abbildung 6.23).

Als Detektionsergebnis für die Methode nach *Renyi* wurde die im Zuge der abrupten Änderungsdetektion (Abschnitt 3.1) berechnete binäre Änderungskarte verwendet. Die beiden weiteren Verfahren nach *Kapur* und *Yen* wurden auf der gleichen Prozessierungsgrundlage (ASF-gefiltertes Quotientenbild) angewendet. Hierfür wurde die bereits existierende und frei verfügbare Funktionalität *Auto Threshold* der Software *ImageJ* genutzt<sup>3</sup>.

Die Strategie zum Vergleich der drei Schwellwertverfahren umfasst drei zentrale Schritte, die für die zwei Testgebiete analog abgearbeitet werden: Berechnung der jeweiligen binären Änderungskarten inklusive eines unabhängigen Referenzbildes; einheitliche Filterung der in diesen Karten enthaltenen Änderungssegmente; Erstellung der Konfusionsmatrix und Bewertung.

Für den ersten Schritt wird für alle drei Verfahren das gleiche ASF-gefilterte, maximale Quotientenbild als Eingabebild genutzt (siehe Abschnitt 3.1). Die binären Ergebnisbilder werden für einen verbesserten visuellen Eindruck in einem RGB-Bild mit folgender Anordnung dargestellt:  $R = CM_{Renyi}$ ,  $G = CM_{Kapur}$  und  $B = CM_{Yen}$  (Abbildungen 6.22 und 6.23, jeweils IV). Aus dieser Darstellung kann abgeleitet werden, dass die Methode nach *Renyi* im Vergleich zu den anderen beiden Ansätzen in den Testgebieten mehr Änderungen erkannt hat (rote Segmente). Weiße Segmente sind Änderungsbereiche, die von allen drei Verfahren detektiert wurden. Als Evaluierungsgrundlage wird anhand wissensbasierter manueller Analyse ein für jedes Testgebiet repräsentatives Referenzbild durch Anwendung eines Schwellwerts erstellt.

Um einen empirischen Vergleich der drei Methoden vornehmen zu können, erfolgt eine flächenbezogene Filterung der Ergebnisbilder inklusive des Referenzbildes, so dass jeweils Änderungssegmente mit einer Größe  $S_{area}$  von  $8 \leq S_{area} \leq 400$  berücksichtigt werden. Die Gegenüberstellung der Resultate erfolgt schließlich durch Betrachtung der Elemente einer Konfusionsmatrix, die im Umfeld des maschinellen Lernens eine weit verbreitete Methode zur Evaluierung darstellt [209]. Eine solche Matrix setzt sich aus den vier Elementen *True Positives* (TP), *False Positives* (FP), *True Negatives* (TN) sowie *False Negatives* (FN) zusammen. In Bezug zur vorliegenden Analyse spiegelt die TP-Rate korrekt detektierte Änderungen und die FP-Rate Falschdetektionen

<sup>3</sup>[http://imagej.net/Auto\\_Threshold](http://imagej.net/Auto_Threshold), zuletzt besucht (TT.MM.JJJJ): 15.01.2018

	Kapur		Yen		Renyi	
Testgebiet 1	74,2% [TP]	25,8% [FN]	62,1% [TP]	37,9% [FN]	93,2% [TP]	6,8% [FN]
	0,0% [FP]	100,0% [TN]	0,0% [FP]	100,0% [TN]	0,1% [FP]	99,9% [TN]
Testgebiet 2	66,7% [TP]	35,3% [FN]	47,1% [TP]	52,9% [FN]	93,3% [TP]	6,7% [FN]
	0,0% [FP]	100,0% [TN]	0,0% [FP]	100,0% [TN]	0,1% [FP]	99,9% [TN]

Tabelle 6.7.: Konfusionsmatrizen der beiden Testgebiete.

wieder. Die TN-Rate erfasst Bildbereiche, die sich nicht verändert haben und die FN-Rate steht für Änderungen, die durch das Verfahren nicht detektiert wurden.

Für das erste Testgebiet und den entsprechend vorliegenden Bildausschnitt ( $525 \times 894$  Pixel) liegen nach Filtrierung insgesamt 456 Referenzsegmente mit einer durchschnittlichen Größe von 25 Pixel vor. Die Methode nach *Kapur* detektierte 359 Änderungssegmente mit einer Durchschnittsfläche von 23,5 Pixel, das Verfahren nach *Yen* detektierte 317 Änderungssegmente (Durchschnittsfläche: 22,3 Pixel) und der Algorithmus nach *Renyi* erkannte 462 Änderungssegmente (Durchschnittsfläche: 25,9 Pixel). Im zweiten Testgebiet ergeben sich die Zahlenwerte (Anzahl Segmente; Durchschnittsfläche) zu: Referenzbild (64; 16,7), *Kapur* (40; 17,3), *Yen* (31; 16,2) und *Renyi* (68; 16,8).

In Tabelle 6.7 sind die Konfusionsmatrizen gelistet. Anhand der Werte kann abgeleitet werden, dass die Methode nach *Renyi* deutlich bessere Ergebnisse liefert (TP-Rate). Alle drei Verfahren verfügen über praktisch keine Falschdetektionen (FP-Rate), was generell die Aussage zulässt, dass alle Methoden für sich stehend verlässliche und robuste Ergebnisse hervorbringen. Die FN-Rate ist bei den Verfahren nach *Kapur* und *Yen* relativ zum Algorithmus nach *Renyi* hoch, was darauf schließen lässt, dass letztere Methode die jeweiligen Referenzsegmente besser beschreibt. Dies zeigt sich ebenso in den TP-Raten. Unveränderte Bildbereiche, die in der TN-Rate wiedergegeben werden, konnten durch alle drei Verarbeitungsweisen robust als solche erkannt werden.

Als Resümee kann somit festgehalten werden, dass das unüberwachte entropiebasierte Schwellwertverfahren nach *Renyi* den beiden vergleichbaren Methoden nach *Kapur* und *Yen* in Anbetracht der Detektionsgenauigkeit überlegen ist. Im Abgleich mit den unabhängig erstellten Referenzbildern für zwei verschiedene Testgebiete wurden vergleichbare Ergebnisse beobachtet, wobei das Verfahren nach *Renyi* jeweils eine Änderungskarte zur Folge hatte, die sowohl in Anzahl als auch Durchschnittsfläche der Änderungssegmente mit der Referenz am Besten übereinstimmt.

### 6.3.3. Segmentierung

In Abschnitt 4.2.1 wurde ein Verfahren zur Segmentierung von SAR-Amplitudenbilddaten präsentiert, das in unüberwachter Weise die morphologische Ähnlichkeit als Homogenitätskriterium verwendet. Diese Ähnlichkeit basiert auf der Betrachtung der mittleren Euklidischen Distanz zwischen den DAP-Signaturen zweier Pixel. Nachfolgend werden die Ergebnisse dieser Methode dem in der Software *eCognition Developer* implementierten MrSeg-Algorithmus (Abschnitt 2.2.4) gegenübergestellt (siehe auch [210]).

Abbildung 6.24 zeigt die für zwei Testgebiete, deren Größe mit den in Abschnitt 4.2.1 beschriebenen HAR identisch ist, resultierenden Segmentierungsergebnisse der beiden Ansätze. Für die Segmentierung anhand des MrSeg-Algorithmus wurden nach verschiedenen Testläufen folgende Einstellungen verwendet, da diese nach visueller Prüfung eine für die hier beschriebene Auswertung optimale Lösung produzierten: Gleichmäßige Gewichtung der spektralen und räumlichen Heterogenität zu jeweils 0,5; sowie der *Scale Parameter* zu 100.

Der erste Schritt zur Gegenüberstellung der beiden Segmentierungsmethoden ist durch die wissensbasierte Markierung von Referenzsegmenten gegeben. Diese Selektion erfolgt anhand der CovAmCoh-Darstellung der jeweiligen Testgebiete (Abbildung 6.25). Für beide Testgebiete, die sowohl rurale als auch urbane Elemente mit Infrastruktur enthalten, werden jeweils drei Referenzsegmente ausgewählt. Die empirische Analyse erfolgt anhand der im vorherigen Abschnitt bereits zur Bewertung der Schwellwertverfahren genutzten Elemente der

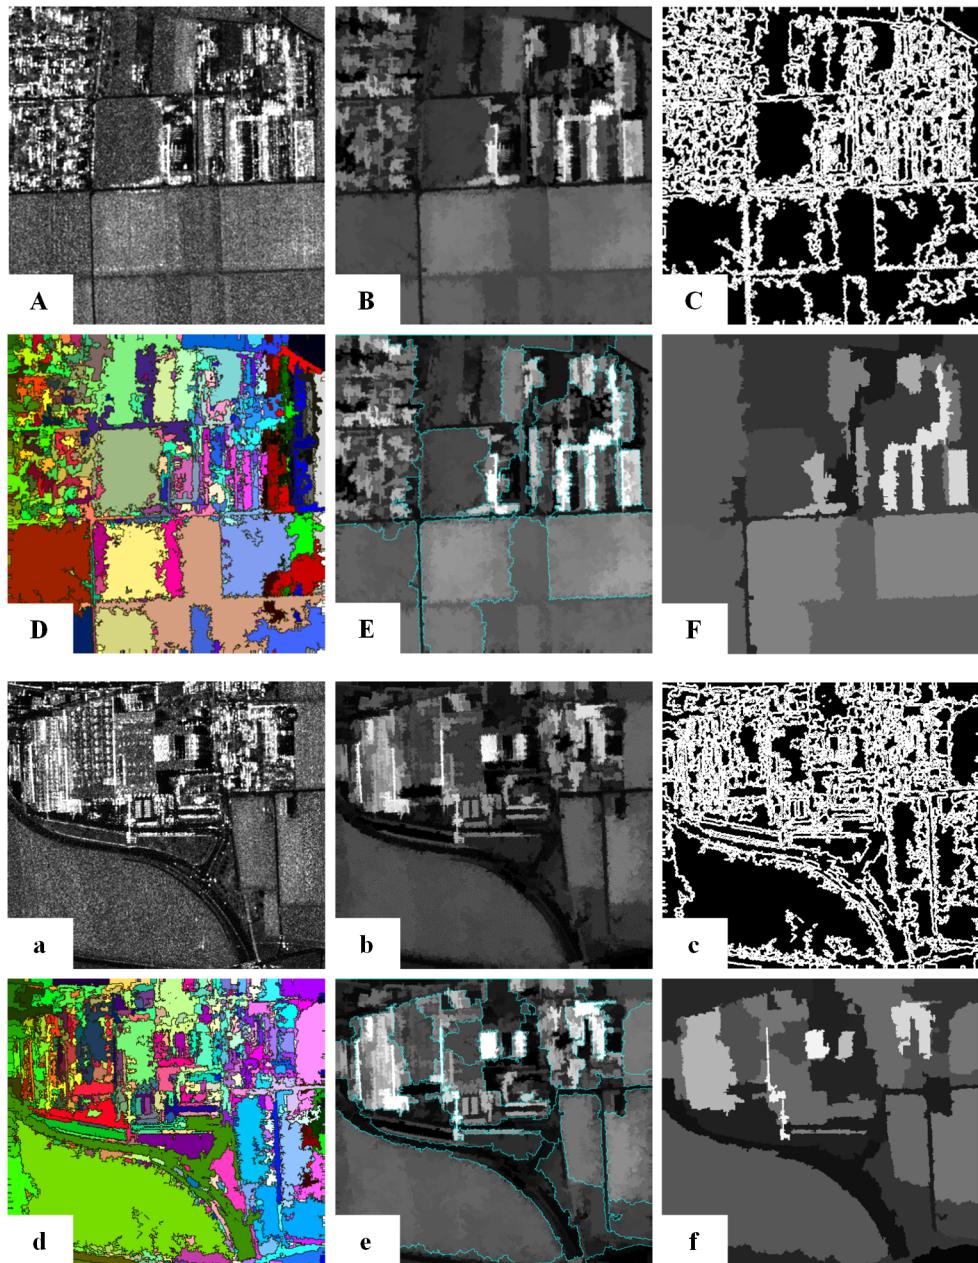


Abbildung 6.24.: Gegenüberstellung der Segmentierungsresultate zweier Testgebiete (Datensatz „Stuttgart Flughafen“). A, a: Mittlere Amplitude der Zeitreihe; B, b: Resultat der ASF-Filterung; C, c: Segmentgrenzen aus der DAP-basierten Segmentierung; D, d: Farbkodiertes Resultat der DAP-basierten Segmentierung; E, e: Segmentgrenzen aus der MrSeg-Methode; F, f: Visualisierung der Segmentmittelwerte aus der MrSeg-Methode.

Konfusionsmatrix (Tabelle 6.8).

Im Hinblick auf die TP-Rate, die den Anteil an Referenzpixeln beinhaltet, der korrekt durch das Verfahren segmentiert wurde, erzeugt die DAP-basierte Segmentierung durchweg stabile Ergebnisse mit  $\geq 82\%$ . Die Falschalarmrate FP bewegt sich für beide Testgebiete und darin enthaltener Referenzsegmente unterhalb von 2 %, woraus eine gute Robustheit des Verfahrens ableitbar ist. Im Vergleich dazu produziert die MrSeg-Methode zwar vereinzelt bessere TP-Werte, doch variieren insgesamt die Werte stärker als bei der DAP-Methode. Tendenziell ruft das MrSeg-Verfahren eine größere FP-Rate hervor als der DAP-basierte Ansatz, weshalb zusammenfassend gesagt werden kann dass Letzterer verlässlichere, da robustere Ergebnisse erzielt.

In der hier beschriebenen vergleichenden Auswertung beider Segmentierungsansätze zeigte sich anhand zweier Testgebiete und insgesamt sechs manuell selektierter Referenzbereiche, dass der neue DAP-basierte Ansatz stabilere und robustere Ergebnisse erzielt. Natürlich muss hierbei erwähnt werden, dass die Anzahl an Referenz- und Testgebieten gering ausgelegt ist. Der beobachtete Trend könnte somit in künftigen Arbeiten anhand eines umfangreicheren Referenzdatensatzes verifiziert werden.

Schlussendlich kann dennoch die in Abschnitt 4.2.1 präsentierte Verfahrensweise als äußerst vielversprechend

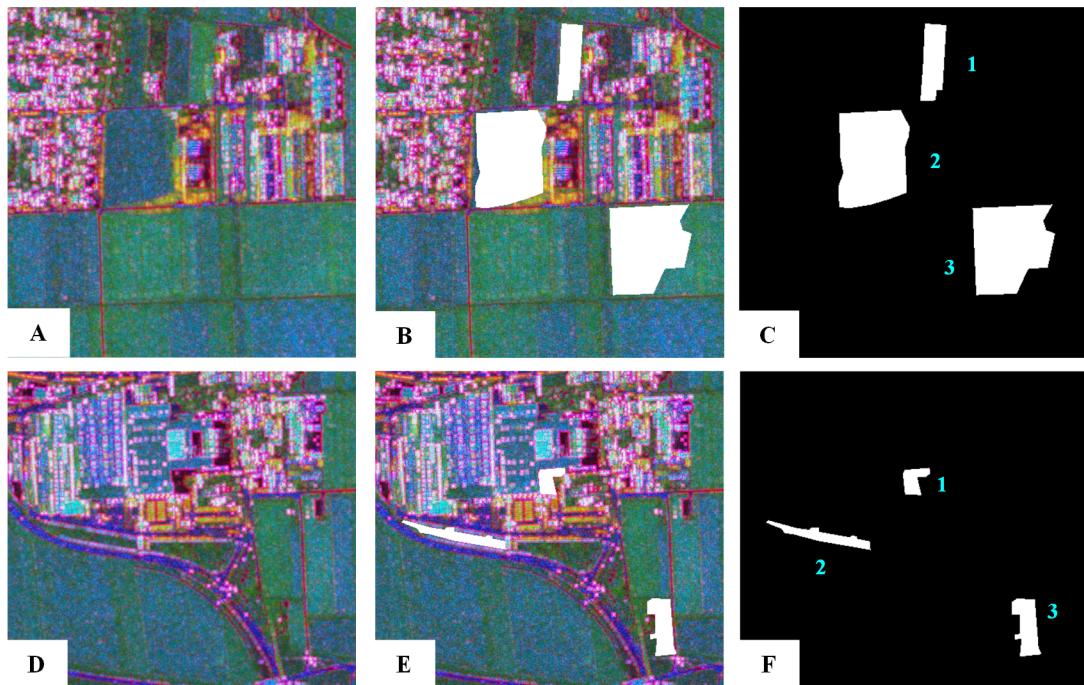


Abbildung 6.25.: Manuell anhand der CovAmCoh-Bilder beider Testgebiete selektierte Referenzsegmente (1, 2, 3) (Datensatz „Stuttgart Flughafen“). A, D: CovAmCoh-Bild Testgebiet 1, 2; B, E: Farbig markierte Referenzsegmente in CovAmCoh-Bild des Testgebiets 1, 2; C, F: Binärbild mit Referenzsegmenten im Vordergrund (weiß) für Testgebiet 1, 2.

	Segment 1		Segment 2		Segment 3	
Testgebiet 1 (DAP)	82,3% [TP]	17,7% [FN]	89,0% [TP]	11,0% [FN]	85,7% [TP]	14,3% [FN]
	0,0% [FP]	100,0% [TN]	0,2% [FP]	99,8% [TN]	0,1% [FP]	99,9% [TN]
Testgebiet 2 (DAP)	85,5% [TP]	14,5% [FN]	87,3% [TP]	12,7% [FN]	87,9% [TP]	12,2% [FN]
	0,0% [FP]	100,0% [TN]	0,0% [FP]	100,0% [TN]	1,7% [FP]	98,3% [TN]
Testgebiet 1 (MrSeg)	94,9% [TP]	5,1% [FN]	54,5% [TP]	45,5% [FN]	99,9% [TP]	0,1% [FN]
	0,5% [FP]	99,5% [TN]	0,1% [FP]	99,9% [TN]	4,0% [FP]	96,0% [TN]
Testgebiet 2 (MrSeg)	98,2% [TP]	1,8% [FN]	83,6% [TP]	16,4% [FN]	95,2% [TP]	4,8% [FN]
	0,9% [FP]	99,1% [TN]	0,0% [FP]	100,0% [TN]	3,3% [FP]	96,7% [TN]

Tabelle 6.8.: Konfusionsmatrizen der manuell anhand der CovAmCoh-Bilder beider Testgebiete selektierten Referenzsegmente (1, 2, 3) (Datensatz „Stuttgart Flughafen“).

erachtet werden. Insbesondere bei Anwendungsfällen, bei denen weder detailliertes Fachwissen von Anwendungsseite noch die notwendige Zeit zum Testen einer optimalen Parameterkonstellation der MrSeg-Methode vorhanden ist, stellt sich die Nutzung der DAP als vorteilhaft heraus.

	Klasse 1a		Klasse 1b		Klasse 3		Klasse 5		Klasse 6a	
Mittlerer Überlappungsgrad [%] (PC1   PC2)	30,5	31,8	27,6	27,1	29,7	30,6	28,8	30,3	25,4	24,9
Varianz der Überlappungsgrade (PC1   PC2)	590	629	624	621	548	559	571	604	682	654

Tabelle 6.9.: Mittlere Überlappungsgrade und deren klasseninternen Variationen.

### 6.3.4. Raumzeitliche Analyse

Die raumzeitliche Analyse untergliedert sich in zwei Teilaufgaben. So wird zunächst geprüft, ob die in Abschnitt 3.2.2 beschriebenen Aktivitätscluster (AC) zur Ableitung spezifischer Muster für verschiedene LULC-Klassen anhand der darin enthaltenen Hochaktivitätsobjekte geeignet sind. Weiterhin wird getestet, ob die sich räumlich zu Hochaktivitätsstapeln (Abschnitt 3.2.3) kombinierbaren HAO für eine bestimmte Klasse auch bestimmte Merkmalssignaturen aufweisen. Als Berechnungsgrundlage für beide Untersuchungen dienen die durch das Verfahren ermittelten finalen Klassen des optimierten Katalogs (Abschnitt 6.2.5) für den Datensatz „Stuttgart Flughafen“. Hierbei werden jene HAO betrachtet, die nach Klassifikation zu einer bestimmten Klasse zugehörig sind. Das heisst, dass für jede finale Klasse ein HAO-basiertes Histogramm extrahiert werden kann, mit dem die Häufigkeit eines spezifischen AC (Abschnitt 3.2.2) dargestellt wird.

#### Aktivitätscluster

Jeder der in dieser Arbeit betrachteten Hochaktivitätsbereiche verfügt über eine spezifische zeitliche Abfolge aus den beiden möglichen Konstellationen *besetzt* (durch Objekt) und *unbesetzt*. In der Aktivitätskarte enthaltene Hochaktivitätspixel HAP besitzen somit jedes für sich eine spezifische zeitliche Abfolge beziehungsweise Zeitreihensignatur, die dafür genutzt wird, HAP mit identischen Signaturen in sogenannte Aktivitätscluster zusammenzufassen (Abschnitt 3.2.3). Übertragen auf die objektorientierte Verarbeitungsebene bedeutet dies, dass sich ein Hochaktivitätsobjekt HAO aus mehreren HAP zusammensetzt, woraus folgt, dass ein bestimmtes HAO zu verschiedenen AC gehören kann.

Stellt man sich nun eine bestimmte Hochaktivitätsregion HAR (zum Beispiel PKW-Parkplatz) vor, so kann leicht gefolgert werden, dass für die auf dem gesamten Parkplatzbereich verfügbaren Parkbuchten grundsätzlich auch unterschiedliche zeitliche Abfolgen von *besetzt* und *unbesetzt* denkbar sind. Dies bedeutet, dass die Extraktion klassenspezifischer AC-Charakteristiken nicht eindeutig möglich ist.

Die in Abbildung 6.26 dargestellten Histogramme der zu den final gefundenen Klassen des in Abschnitt 6.2.5 betrachteten Katalogs zugehörigen HAO stützt diese Überlegung, da keine charakterisierende Signatur beobachtet wird. Eine Unterscheidung der Klassen anhand der darin enthaltenen AC ist somit nicht möglich.

#### Hochaktivitätsstapel

Analog der Vorgehensweise zur Analyse der AC werden die Hochaktivitätsstapel basierend auf den einer finalen Klasse zugewiesenen HAO beurteilt. Es wird geprüft, ob anhand von Kennzahlen, extrahiert für diese Stapel, Rückschlüsse auf klassenspezifische Systematiken ableitbar sind. In Abbildung 6.27, oben, ist das hierfür erstellte Ablaufschema visualisiert. Für jede Klasse  $kl$  werden die entsprechenden HAO identifiziert und die dazugehörigen Gruppen aus Hochaktivitätsstapel bestimmt. In diesem Beispiel liegen für das  $HAO_1 \in S$  Stapel vor, was daraus begründet ist, dass ein spezifisches HAO Teil verschiedener Stapel sein kann (siehe auch Abschnitt 3.2.3).

Für jeden dieser  $S$  Stapel werden basierend auf dem aus den beiden ersten Hauptkomponenten definierten zweidimensionalen Merkmalsraum Intervalle aus Minimal- und Maximalwerten extrahiert (Abbildung 6.27, oben rechts). Die erste abgeleitete Kennzahl gibt Auskunft über die Überlappung dieser  $S$  Intervalle. Hierfür wird zunächst paarweise der Grad der Überlappung berechnet (siehe Abbildung 6.27, unten) und abschließend aus diesen  $S - 1$  Werten für jedes  $HAO_i$  einer Klasse der mittlere Überlappungsgrad bestimmt. Für jedes in einer Klasse vorhandene HAO ergibt sich dementsprechend ein Überlappungsgrad der an ihm beteiligten Stapelintervalle. Durch Ableitung eines Repräsentanten (Mittelwert) aus diesen Überlappungswerten resultiert jeweils ein Wert je Klasse  $kl$ . Darüber hinaus wird mit einer weiteren Kennzahl geprüft, wie stark die HAO-bezogenen mittleren Überlappungswerte je Klasse variieren. Letztlich soll auf diese Weise analysiert werden, ob die Intervalle der in einer Klasse vorliegenden Hochaktivitätsstapel homogen verteilt sind. Dies wäre der Fall, wenn sehr hohe Überlappungswerte beobachtet werden würden, die untereinander wenig variieren.

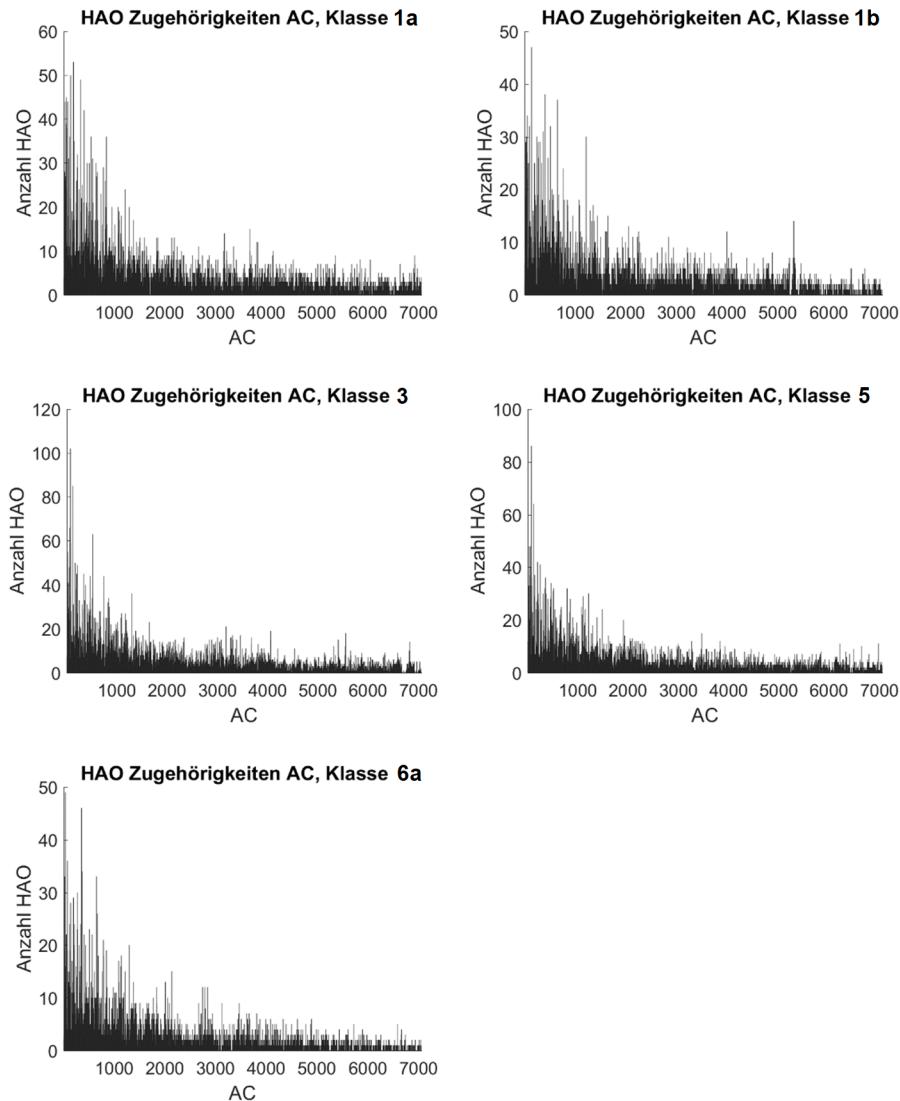


Abbildung 6.26.: Histogramme über die AC-Zugehörigkeiten der zu den finalen Klassen zugewiesenen HAO (Datensatz „Stuttgart Flughafen“).

In Tabelle 6.9 sind die für die final existierenden Klassen abgeleiteten Werte gelistet. Es zeigt sich, dass anhand der erläuterten Vorgehensweise keine signifikante Unterscheidung der finalen Klassen möglich ist. Allenfalls lässt sich ein Trend beobachten, der relativ hohe Homogenität in den Klassen 1a, 3 und 5 erahnen lässt, die einer gewissen Heterogenität in Klasse 6a gegenüber stehen. Mit den Erläuterungen in Abschnitt 6.2.7 kann ferner gefolgert werden, dass die neue Klasse 6a durch den dominanten Cluster 1 (rot) beschrieben wird, der im Ortsbereich der initialen Klasse den Abschnitt mit dem Flugzeugparkplatz einnimmt. In diesem Bereich liegen sehr heterogene Objektstrukturen (Flugzeug, Gepäckwagen, Gateways, etc.) vor, die unterschiedliche Änderungskategorien und damit auch unterschiedlich strukturierte HAO hervorrufen können. In Kontrast zu dieser Folgerung stehen die Werte der Klasse 3 (*Baustelle*) (Tabelle 6.9), für die pauschal ebenfalls eine heterogene Struktur innerhalb von Hochaktivitätsstapeln angenommen wurde. Ebenso kann die von der theoretischen Überlegung herrührende Annahme, dass die Klasse 4 *Be- / Entladestelle* über eine homogeneren Stapelstruktur verfügt als beispielsweise die Klasse 3 *Baustelle* (Abschnitt 6.2.5) hier nicht bestätigt werden, da die erste der beiden Klassen durch das Verfahren im Zuge der Optimierung ersatzlos gelöscht wurde. Es kann somit festgehalten werden, dass mit dieser Verfahrensweise zur Analyse der Hochaktivitätsstapel keine wirkliche Tendenz zur Unterscheidung der final resultierenden Klassen zu beobachten ist. Die Ausnahme nimmt Klasse 6a ein, wofür in Anbetracht der in Abschnitt 6.2.7 dargelegten Folgerungen eine schlüssige Begründung abgeleitet werden konnte. Die Werte für die weiteren finalen Klassen unterscheiden sich nicht signifikant, weshalb die hier beschriebene Strategie nicht weiter verfolgt wird. Eine mögliche Erklärung für die Ähnlichkeit der Überlappungsgrade ist die Mittelung der HAO-bezogenen Werte. Eine direkte Alternative wäre die Benennung eines die Klasse repräsentierenden HAO und der alleinigen Auswertung der daran

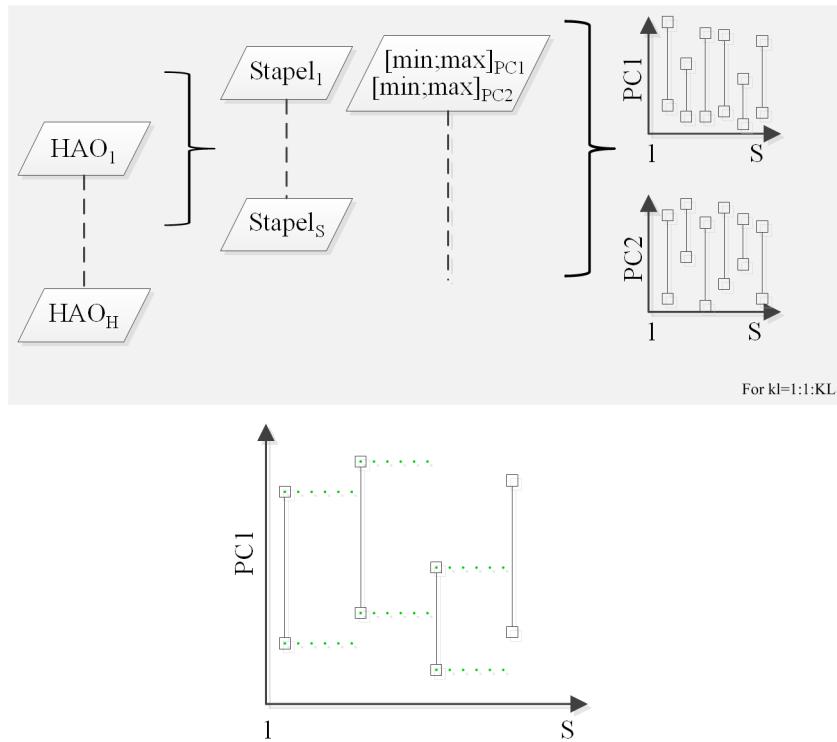


Abbildung 6.27.: Ablaufschema zur klassenbezogenen Analyse von Hochaktivitätsstapeln (oben); paarweise Extraktion der Intervallüberlappungen (unten).

geknüpften Hochaktivitätsstapel. Problematisch erscheint hierbei die Wahl eines geeigneten HAO. Im Zuge weiterführender Untersuchungen sollten alternative Verfahrensweisen getestet werden. Eine davon könnte die Varianzanalyse der die jeweiligen Intervalle beschreibenden Minimal- und Maximalwerte darstellen. Darüber hinaus sollte der durch die beiden ersten Hauptkomponenten beschriebene Merkmalsraum für die Analyse der Hochaktivitätsstapel verlassen werden. Insbesondere Formmerkmale (siehe Abschnitt 2.2.4) scheinen aus pauschaler Sicht vielversprechend zu sein, wenn von homogenen HAO-Formen beispielsweise auf einem Abschnitt eines Parkplatzes ausgegangen wird.

Abschließend ist anzumerken, dass eine zielführende Nutzung der Hochaktivitätsstapel und der AC zur Ableitung klassenspezifischer, raumzeitlicher Muster durch die hier genutzten Daten erschwert wird. Die hier betrachteten Klassen stellen in sich selbst raumzeitlich heterogene LULC-Strukturen dar. Als interessant könnte sich deshalb die Untersuchung raumzeitlich homogener Klassenregionen erweisen. So könnten PKW-Parkplätze, die sich an den selben Tagen füllen und wieder leeren über ein spezifisches Muster verfügen. Als Beispiele für solche Regionen können die Parkplätze an Kreuzfahrtkais („Park and Cruise“), Sportstadien und Wochenmärkten dienen.

### 6.3.5. Anzahl dominanter Cluster

In dieser Arbeit nimmt der Parameter  $CL$  eine grundlegende Bedeutung für die in den Abschnitten 5.2.3 und 5.2.4 dargelegten Abläufe zur Optimierung eines initialen Klassenkatalogs ein. Da der Wert für  $CL$  darüber entscheidet, welche Klassen des Katalogs tatsächlich in der kategorisierten Datenrealität existieren und welche nicht, wird nachfolgend die Wahl des Schwellwerts  $CL_\tau$  zu  $CL_\tau = k^*/2$  eingehender diskutiert. Hierzu wird der in den obigen Ausführungen verwendete Standardfall mit vier Kategorien ( $k = 4$ ) und sechs initialen Klassen als Referenz genutzt. Dieser wird mit zwei weiteren Fällen ( $k = 8$  und  $k = 12$ ) verglichen, wobei für diesen Vergleich jeweils die Anzahl an dominanten Clustern maßgeblich ist. Auf diese Weise wird geprüft, ob der Schwellwert  $CL_\tau$  für diese drei Clusteranzahlen geeignet gewählt ist, beziehungsweise ob initiale Klassen, die gemäß Standardkonfiguration in den Daten vorliegen, auch für die beiden anderen Kategorisierungsresultate durch Berücksichtigung des Schwellwerts existent sind. Somit können für einzelne Klassen Trends in Anbetracht eines geeigneten Schwellwerts  $CL_\tau$  abgeleitet werden.

Hierfür wird die Vorprojektion für die drei verschiedenen  $k = 4, 8, 12$  durchgeführt. Abbildung A.25 enthält

ID Klasse	Name	CL (k = 4)	CL (k = 8)	CL (k = 12)
1	PKW-Parkplatz	2	3	4
2	LKW-Parkplatz	3	4	5
3	Baustelle	1	3	1
4	Be- / Entladestelle	3	4	6
5	Sammelstelle	2	3	1
6	Flughafen Gate	3	4	6

Tabelle 6.10.: Anzahl dominanter Clusterstrukturen je Klasse für unterschiedliche Kategorisierungsresultate ( $k = 4, 8, 12$ ). Grün: Klasse existiert, da  $CL_\tau < k^*/2$ ; orange: Klasse unsicher existent, da  $CL_\tau = k^*/2$ ; rot: Klasse existiert nicht, da  $CL_\tau > k^*/2$ .

die entsprechenden Ergebnisse in Form von Clusterhistogrammen (vergleiche auch Abschnitt 6.2.5). Die daraus abgeleiteten Erkenntnisse hinsichtlich der Anzahl der dominanten Clusterstrukturen sind in Tabelle 6.10 zusammengefasst. Die dort vorliegende Farbkodierung (grün, orange, rot) orientiert sich an dem zugrunde gelegten Schwellwert  $CL_\tau = k^*/2$ , wobei grün bedeutet, dass die Klasse in einem Kategorisierungsergebnis existiert und rot für eine Nicht-Existenz steht. Eine orange-farbene Zelle bedeutet ein unsicheres Ergebnis, das im Zuge der Rückprojektion detaillierter geprüft werden sollte. Dies ist für  $k = 4$  beispielsweise bei der Klasse 1 (PKW-Parkplatz) der Fall (siehe Abschnitt 6.2.5), die im weiteren Ablauf in zwei Subklassen aufgeteilt wird. Ein solches unsicheres Ergebnis resultiert, wenn die Anzahl der dominanten Cluster gleich dem Schwellwert  $CL_\tau = k^*/2$  ist.

Mit Hilfe der in der Tabelle gelisteten Resultate kann festgestellt werden, dass für alle Klassen über alle drei Kategorisierungsergebnisse vergleichbare Trends vorliegen. Die Klasse 6 (Flughafen Gate) erweist sich für alle Kategorisierungen als problematisch und ist durchweg mindestens als unsichere Klasse zu beurteilen. Analoges gilt für Klasse 4 (Be- / Entladestelle), die im Ergebnis für  $k = 4$  als eher nicht existent eingestuft wird und für die beiden weiteren Clustering-Resultate zumindest für weitere Untersuchungen herangezogen werden sollte. Die Klassen 1, 3 und 5 sind für alle drei kategorisierenden Datenrealitäten verfügbar. Eine Sonderstellung bei der Ableitung dieser Trends nimmt die zweite Klasse (LKW-Parkplatz) ein, die mit ansteigender Anzahl an Kategorien als tendenziell existent eingestuft wird. Dies kann zum Beispiel darin begründet sein, dass sich diese Klasse aus vielen eigenständigen Änderungskategorien zusammensetzt, aus denen sich bei einem ansteigendem Wert für  $k$  von einem ursprünglichen Clusterrauschen ( $k = 4$ ) dominante Strukturen herausbilden ( $k = 8$  und  $k = 12$ ). Dennoch ist auch hier ein Trend zu einem ansteigenden CL-Wert zu beobachten. Zur Vervollständigung der hier visualisierten Ergebnisse ist in Anhang A eine weitere Abbildung gegeben, in der die initialen Klassen in den verschiedenen 2D-Merkmalsräumen dargestellt sind (Abbildung A.26).

Als Schlussfolgerung kann dementsprechend abgeleitet werden, dass für die in der vorliegenden Arbeit genutzte niedrige Anzahl an Kategorien der Schwellwert  $CL_\tau$  zur Charakterisierung existenter Klassen mit  $CL_\tau = k^*/2$  in geeigneter Form gewählt ist. Natürlich kann anhand der hier vorgenommenen Untersuchung, die sich rein zweckmäßig an dieser geringen Kategorienanzahl orientiert, keine allgemeingültige Auskunft für weitaus größere Werte für  $k$  vorgenommen werden. Es kann gefolgert werden, dass für ähnliche Anwendungen wie der hier geschilderten Vorgehensweise, eine stark ansteigende Kategorienanzahl nicht erwartet wird. Der hier genutzte äußerst heterogene Datensatz, sowohl in Anbetracht verschiedener Änderungskategorien als auch LULC-Klassen, ist als repräsentative Grundlage anzusehen. Eine Ausnahme hierbei nehmen maritime Szenen mit Hafengebieten ein, die möglicherweise andere Änderungskategorien beinhalten. Eine Steigerung der Kategorienanzahl in Bereiche jenseits von  $k = 12$  wird in diesem Fall nicht erwartet.

### 6.3.6. Klassenkatalog

In diesem Abschnitt wird überprüft, ob das vorgestellte Verfahren zur Änderungsanalyse sinnvolle und verlässliche Ergebnisse produziert, wenn der initial vorgegebene Klassenkatalog (siehe Abschnitt 6.2.5) variiert wird. Es wird getestet, ob die Methode eine geringere Anzahl an grob gewählten Klassen beziehungsweise eine größere Anzahl an fein definierten Klassen robust verarbeiten kann. Als Testdatensatz dient hierfür die Szene „Stuttgart Flughafen“. Die Anwendung des Klassifikationsschritts ist hier nicht notwendig, da

ID Klasse	Name		Farbe			
1	Urban		Blau			
2	Industriell		Orange			
3	Flughafen Vorfeld		Gelb			
Initiale Kennzahlen Optimierte Kennzahlen						
Initiale Klasse	CL	D [%]	Z	Fall		
1	2	[0,0; 100,0; 0,0; 100,0] [unverändert]	3	3a		
2	3	[96,0; 0,0; 100,0; 100,0] [unverändert]	3	3a		
3	2	[100,0; 100,0; 20,5; 5,4] [unverändert]	0	1a		
Initiale Klassen	1	2	3			
Finale Klassen	1	2	3	4	3a	3b

The diagram illustrates the classification process. At the top is a table of the initial class catalog with three entries: 'Urban' (ID 1, blue), 'Industriell' (ID 2, orange), and 'Flughafen Vorfeld' (ID 3, yellow). Below it is a table showing the optimization process. The first row shows 'Initiale Kennzahlen' (Initial Characteristics) and 'Optimierte Kennzahlen' (Optimized Characteristics). The second row defines columns: 'CL' (Number of dominant clusters), 'D [%]' (Percentage share of cluster density), 'Z' (Division degree), and 'Fall' (Case). The third row contains data for three initial classes: Class 1 (CL=2, D=[0,0; 100,0; 0,0; 100,0] unaltered), Class 2 (CL=3, D=[96,0; 0,0; 100,0; 100,0] unaltered), and Class 3 (CL=2, D=[100,0; 100,0; 20,5; 5,4] unaltered). The fourth row shows the resulting final classes: Class 1 (purple), Class 2 (green), Class 3 (cyan), Class 4 (dark red), Class 3a (blue), and Class 3b (dark olive green). Arrows point from the initial classes (1, 2, 3) to their corresponding final classes (1, 2, 3, 4, 3a, 3b).

Abbildung 6.28.: Ergebnisse der Rückprojektion für drei grob gewählte Klassen (Abbildung A.27). Oben: Initialer Klassenkatalog; Mitte: Optimierungsverlauf; unten: Visualisierter Optimierungsverlauf mit den vorgegebenen beziehungsweise resultierenden Farbkodierungen der Klassen. CL: Anzahl dominanter Cluster; D [%]: Prozentualer Anteil am Dichtebereich eines Clusters; Z: Zerteilungsgrad.

nur beurteilt werden soll, ob die durch die Rückprojektion durchgeführte Optimierung der Klassenkataloge jeweils begründbare Resultate erzeugt.

#### Klassenkatalog bestehend aus drei Klassen

Eine Darstellung der selektierten Klassen in der Örtlichkeit ist in Abbildung A.27 enthalten. Es ist ersichtlich, dass alle drei Klassen großräumige Flächen einnehmen, die jeweils auch große Bereiche im zweidimensionalen kategorisierten Merkmalsraum abdecken. Aus einer großflächigen Selektion im Ortsraum (Bild) folgt somit eine Beteiligung vieler unterschiedlicher Kategorien, was tendenziell in Anbetracht des Schwellwerts  $CL_{\tau} = k^*/2$  dazu führt, dass eine solche Klasse in den vorhandenen Daten nicht existiert. Diese Annahme wird durch die hier ermittelten Ergebnisse aus der Rückprojektion gestützt (Abbildung 6.28). Für die ersten beiden Klassen *Urban* und *Industriell* wurde jeweils eine Neudeinition vorgenommen (Fall 3a, siehe Abschnitt 5.2.4). Einzig die dritte Klasse *Flughafen Vorfeld*, die sich hier aus einem Hochaktivitätsbereich bestehend aus vorhandenen und nicht vorhandenen Flugzeugen inklusive Be- und Entladestellen zusammensetzt, konnte als existent identifiziert werden. Da sich diese Klassenregion ferner durch zwei Cluster definiert, die voneinander klar trennbar sind, wird eine Aufteilung in die beiden Subklassen 3a und 3b vorgenommen.

Eine zweidimensionale Darstellung des initialen und optimierten finalen Klassenkatalogs ist in Abbildung A.28 gegeben. Es zeigt sich weiterhin, dass die neu entstandene Klasse 1 mit der Subklasse 3b identisch ist. Gleicher gilt für die neu erstellten Klassen 2 und 4. Letzterer Umstand ist dadurch begründbar, dass sich im gewählten urbanen Gebiet Strukturen befinden, die ebenfalls im selektierten Industriebereich vorhanden sind. Ähnliches kann für die beiden Klassen 1 und 3b festgehalten werden, da sowohl im urbanen Raum als auch im Abschnitt des Flughafenvorfelds parkplatzähnliche Strukturen vorliegen.

#### Klassenkatalog bestehend aus zehn Klassen

Den gegensätzlichen Fall zu den oben beschriebenen, grob definierten Klassen nimmt die hier erläuterte Verarbeitung eines aus vielen und teilweise kleinfächigen Klassen bestehenden Katalogs ein (Abbildung 6.29, oben). Der Katalog setzt sich zusammen aus bereits bekannten Klassen wie *PKW-* oder *LKW-Parkplatz* (siehe Abschnitt 6.2.5), sowie den hier neu betrachteten Klassen *PKW-* und *LKW-Parkplatz* (ID 1), *Baustelle urban* (ID

ID Klasse	Name		Farbe
1	PKW- und LKW-Parkplatz		Blau
2	PKW-Parkplatz		Orange
3	LKW-Parkplatz		Gelb
4	Baustelle urban		Violett
5	Baustelle suburban		Grün
6	Be- / Entladestelle		Blau
7	Sammelstelle urban		Rot
8	Sammelstelle industriell		Blau
9	Flughafen Gate		Olivengrün
10	Flughafen Vorfeld		Grün

	Initiale Kennzahlen				Fall
	CL	D [%]		Z	
Initiale Klasse	1	1	[24,5; 100,0; 18,8; 1,6] [unverändert]	0	0
	2	2	[36,3; 100,0; 100,0; 20,7] [unverändert]	0	1a
	3	3	[96,8; 100,0; 96,6; 0,0] [unverändert]	3	3a
	4	2	[29,1; 100,0; 70,9; 14,8]	1	2b
		2	[31,8; 100,0; 79,5; 20,5]	1	
	5	1	[0,0; 12,2; 40,2; 100,0] [unverändert]	0	0
	6	3	[0,0; 46,1; 72,6; 77,3] [unverändert]	3	3b
	7	2	[0,0; 10,9; 96,6; 63,8]	2	2b
		2	[0,0; 20,8; 100,0; 70,5]	1	
	8	1	[0,0; 10,0; 63,2; 12,5]	1	2b
		1	[0,0; 19,5; 71,8; 19,0]	1	
Initiale Klassen	9	3	[81,6; 0,0; 84,6; 0,0] [unverändert]	3	3b
	10	2	[67,2; 93,1; 4,3; 0,0] [79,2; 100,0; 12,8; 0,0]	2	2b

Initiale Klassen	1	2	3	4	5	6	7	8	9	10
Finale Klassen	1	2a	2b	3	4	5		7	8	10



Abbildung 6.29.: Ergebnisse der Rückprojektion für zehn fein gewählte Klassen (Abbildungen A.29 bis A.30). Oben: Initialer Klassenkatalog; Mitte: Optimierungsverlauf; Unten: Visualisierter Optimierungsverlauf mit den vorgegebenen beziehungsweise resultierenden Farbkodierungen der Klassen. CL: Anzahl dominanter Cluster; D [%]: Prozentualer Anteil am Dichtebereich eines Clusters; Z: Zerteilungsgrad.

4), *Sammelstelle industriell* (ID 8), sowie einem kleinflächigen Ausschnitt des Flughafenvorfelds (ID 10) (vergleiche hierzu auch die Abbildungen A.29 bis A.30). Diese neu definierten Klassen wurden mit Ausnahme der Klasse 10 als solche im Rahmen beider Ortsbegehung identifiziert.

Anhand von Abbildung 6.29 (Mitte und unten) kann abgeleitet werden, dass die Auswahl tendenziell eher kleinräumiger Klassen für die vorliegende Datenrealität geeigneter ist, da derartige Selektionen weniger von Neudeinitionen durch den Algorithmus betroffen sind. Nur für die beiden Klassen 6 (*Be- / Entladestelle*) und 9 (*Flughafen Gate*) wurde der Fall 3b ermittelt, der zur ersatzlosen Löschung aus dem Katalog führt. Für die Klasse 6 ist dies nicht überraschend, da diese ebenfalls in Abschnitt 6.2.5 durch das Verfahren gestrichen wurde. Für die Klasse 9 röhrt dies daher, dass die Selektion der Klassenregion lediglich mittels SAR-Bildgrundlage durchgeführt wurde. Somit resultierte eine leicht abweichende initiale Klassenregion, die zu einem unterschiedlichen Prozessierungsverhalten führte. In Konsequenz bedeutet dies, dass für ein möglichst exaktes Ergebnis auch die Auswahl der jeweiligen Klassenregion im Ortsgebiet präzise erfolgen muss. Da die in Abschnitt 6.2.5 betrachteten Regionen sowohl anhand des SAR- als auch des optischen Referenzbilds ausgewählt wurden, kann eine derartige Vorgehensweise an dieser Stelle empfohlen werden. Insbesondere in Bildbereichen, in denen das SAR-Bild eine genaue Gebietsauswahl erschwert, sollte eine unterstützende Nutzung optischer Bilddaten erfolgen.

In dem hier analysierten Beispiel des aus zehn Klassen bestehenden Katalogs wurde viermal der Fall 2b durch das Verfahren angewendet (Klassen 4, 7, 8 und 10), was eine Beibehaltung aber lokale Optimierung der Klasse im Merkmalsraum bedeutet. Die zugehörigen Hochaktivitätsregionen existieren somit zwar aus semantischer Sicht in den Daten, beschreiben allerdings leicht von der ursprünglichen Auswahl abweichende Klassen. Die Ableitung der womöglich veränderten Bedeutung im Ortsraum muss letztlich durch den Anwender anhand des final vorliegenden Klassifikationsresultats vorgenommen werden, woraus die tatsächliche Datengrundlage erlernt wird. Eine visuelle Darstellung der ursprünglichen und der finalen Klassenboxen im zweidimensionalen Merkmalsraum ist in Abbildung A.31 gegeben.

### 6.3.7. Klassenzugehörigkeit

Die in Abschnitt 6.2.5 erläuterten Ergebnisse zur Klassenzuweisung basieren auf dem dort vermittelnd gewählten Fuzzy-Schwellwert  $z = 50$ . Nachfolgend werden zwei davon abweichende Fälle mit  $z = 10$  und  $z = 85$  betrachtet, wobei als initial eingestellter Klassenkatalog der in Abschnitt 6.2.5 verwendete Katalog genutzt wird. Dementsprechend erfolgt die Klassifikation der Hochaktivitätsobjekte anhand des dort vorliegenden, optimierten Katalogs. Für die Gegenüberstellung der Klassifikationsergebnisse werden die initial gewählten Klassenregionen analysiert (siehe auch Abbildung 6.13 und Abbildung 6.14).

In den Abbildungen 6.30 und A.32 sind die Resultate dargestellt, die sich durch Variation der Zugehörigkeitsschwelle ergeben. Die beiden Werte  $z = 10$  und  $z = 85$  wurden so gewählt, um in Relation zu dem in Abschnitt 6.2.5 verwendeten Wert kontrastreiche Resultate bezüglich der gesetzten Zugehörigkeitsbereiche (Abbildung 5.13) zu produzieren.

Zunächst ist es direkt ersichtlich, dass mit zunehmendem Wert für  $z$  die Wahrscheinlichkeit steigt, dass das jeweilig klassifizierte HAO auch tatsächlich zu der entsprechenden Klasse gehört (Abbildung 5.13). Im Umkehrschluss bedeutet dies die Zunahme der Rate an unklassifizierten HAO (Abbildung 6.30, oben). Wird hingegen ein in Relation dazu sehr niedriger Wert für  $z$  gewählt, so werden zwar nahezu alle HAO einer Klasse zugewiesen, doch nimmt damit auch die Zuverlässigkeit dieser Zuweisung ab. Insbesondere bei in räumlicher Nachbarschaft im Merkmalsraum angeordneten Klassen nimmt die Eindeutigkeit der Klassenzuweisung für ein niedriges  $z$  ab. So kann es sein, dass in einer bestimmten Region (exemplarisch: Klassenregion *Baustelle*, Abbildung A.32, c) einige HAO Klassen zugeordnet werden, die für ein hohes  $z$  noch unklassifiziert gewesen sind. Für  $z = 85$  existieren für dieses Beispiel in erwähnenswertem Maß allein die Klassen 3 und 6a (Abbildung A.32, c.4), wohingegen für  $z = 10$  neben der dominanten Klasse 3 noch weitere andere Klassen vertreten sind (Abbildung A.32, c.2).

Es ist somit festzuhalten, dass für Klassifikation von Hochaktivitätsobjekten kein allgemeingültiger Zugehörigkeitsschwelle  $z$  existiert. Dieser muss vielmehr in überwachter Art und Weise erprobt werden. Eine automatische Generierung dieses Werts mittels Verfahren zur *Defuzzifikation*, die die Akkumulation oder Inferenz der einzelnen Zugehörigkeitsfunktionen analysiert [175] wird hier nicht betrachtet, da die zuvor erwähnte Erprobung eines geeigneten Werts für  $z$  dazu führt, dass der Anwender die Klassifikation an den vorhandenen Daten selbst erlernt und auf diese Weise ein Gefühl dafür entwickelt, welcher Zugehörigkeitsschwelle zum jeweilig vorliegenden Anwendungsfall am Besten passt. Gegenüber bisherigen konventionellen Ansätzen, für die Trainingsdaten mehr oder weniger umfangreich selektiert werden oder bereits vorliegen müssen, stellt die vorgestellte Methode durch die alleinige Wahl der Zugehörigkeitsschwelle eine effiziente Alternative dar. Für das hier behandelte Beispiel mit den sechs initial selektierten Klassen im Datensatz „Stuttgart Flughafen“ wird

	<b><i>z</i></b>	<b>HAO Gesamtanzahl</b>	<b>HAO klassifiziert</b>	<b>HAO unklassifiziert</b>
	<b>10</b>	34.363 (100%)	29.525 (86%)	4.838 (14%)
	<b>50</b>	34.363 (100%)	14.204 (41%)	20.159 (59%)
	<b>85</b>	34.363 (100%)	3.603 (10%)	30.760 (90%)

<b><i>z</i></b>	<b>HAO- Zugehörigkeit (init. Klasse 1) [%]</b>	<b>HAO- Zugehörigkeit (init. Klasse 2) [%]</b>	<b>HAO- Zugehörigkeit (init. Klasse 3) [%]</b>	<b>HAO- Zugehörigkeit (init. Klasse 4) [%]</b>	<b>HAO- Zugehörigkeit (init. Klasse 5) [%]</b>	<b>HAO- Zugehörigkeit (init. Klasse 6) [%]</b>	<b>Finale Klasse</b>
<b>10</b>	39,2	20,5	6,9	25,0	14,3	16,5	1a
	24,5	35,5	5,2	10,0	2,4	16,5	1b
	0,0	0,0	0,0	0,0	0,0	0,0	2
	1,4	0,7	56,0	30,0	29,8	29,1	3
	0,0	0,0	0,0	0,0	0,0	0,0	4
	10,5	5,6	12,8	10,0	47,6	5,1	5
	5,3	20,9	8,9	17,5	3,6	17,7	6a
	0,0	0,0	0,0	0,0	0,0	0,0	6b
<b>50</b>	17,2	9,3	3,5	12,5	9,5	11,4	1a
	8,8	15,3	1,6	2,5	0,0	8,9	1b
	0,0	0,0	0,0	0,0	0,0	0,0	2
	0,3	0,0	28,0	17,5	13,1	19,0	3
	0,0	0,0	0,0	0,0	0,0	0,0	4
	3,3	1,5	9,5	5,0	38,1	3,8	5
	2,6	8,6	2,5	7,5	0,0	3,8	6a
	0,0	0,0	0,0	0,0	0,0	0,0	6b
<b>85</b>	3,4	1,5	0,8	2,5	4,8	3,8	1a
	2,3	4,1	0,1	0,0	0,0	2,5	1b
	0,0	0,0	0,0	0,0	0,0	0,0	2
	0,0	0,0	7,1	0,0	3,6	1,3	3
	0,0	0,0	0,0	0,0	0,0	0,0	4
	0,9	0,4	3,6	0,0	13,1	1,3	5
	0,4	3,0	0,5	5,0	0,0	0,0	6a
	0,0	0,0	0,0	0,0	0,0	0,0	6b

Abbildung 6.30.: Ergebnisse der Variation von  $z$ . Obige Tabelle: Anzahl und prozentuale Rate klassifizierter und unklassifizierter Hochaktivitätsobjekte bei variierendem  $z$ . Untere Tabelle: Auflistung der prozentualen (finalen) Klassenzugehörigkeiten der sich in einer initial gewählten Klassenregion befindlichen HAO. Die finalen Klassen entsprechen den in Abschnitt 6.2.5 enthaltenen Ausführungen.

ein Wert von mindestens  $z = 50$  und maximal  $z = 85$  empfohlen, da so die Aussagekraft und Zuverlässigkeit des Klassifikationsergebnisses sichergestellt wird.

### 6.3.8. Zusammenfassung

Im Folgenden werden die in den vorherigen Abschnitten behandelten Parametervariationen sowie andere Untersuchungen resümierend diskutiert.

#### Änderungsdetektion

Die eingesetzte Methode zur Detektion abruperter Änderungen in SAR-Amplitudensbildpaaren wurde der *Kullback-Leibler-Divergenz* (KLD) gegenübergestellt. Die beschriebene Berechnung der KLD basierend auf einer fensterorientierten Verarbeitung wurde als nachteilig gegenüber der verwendeten Verfahrensweise mittels morphologischem alternierenden Filter beurteilt. Mit zunehmender Fenstergröße werden zwar tendenziell auch größere Änderungsbereiche detektiert, doch wird deren ursprüngliche Form und Struktur verfälscht. Dieser Umstand erscheint vor allem im Hinblick auf eine merkmalsbasierte Auswertung der Änderungsobjekte, wie in dieser Arbeit erläutert, äußerst limitierend.

Es konnte festgehalten werden, dass die ASF-basierte LR-Methode nach Abschnitt 3.1 für die in dieser

Arbeit behandelte Aufgabenstellung die geeignetere Alternative darstellt. Durch Nutzung des ASF werden ursprüngliche in den Bilddaten enthaltene Objektstrukturen erhalten und nicht verfälscht. Darüber hinaus handelt es sich um eine leicht umsetzbare Methode zur anwendungsorientierten Detektion von Interessenobjekten spezifischer räumlicher Ausdehnung (exemplarisch: Fahrzeuge mit einer bestimmten Mindest- und Maximalgröße).

Neben diesen signifikanten Vorteilen des entwickelten Verfahrens gegenüber der KLD-Methode konnte weiterhin seine Detektionsgüte und Robustheit nachgewiesen werden. Für einen Hochaktivitätsbereich ergaben sich über den gesamten Zeitreihendatensatz hinweg betrachtet durchweg positive Ergebnisse. So lag beispielsweise die Falschalarmrate lediglich bei 6,1 % und die Rate an korrekten Detektionen bei knapp 70 %.

### **Unüberwachte Schwellwertverfahren**

Das zur unüberwachten Bestimmung eines Schwellwerts eingesetzte Verfahren nach *Renyi* wurde zwei weiteren entropiebasierten Methoden (*Kapur* und *Yen*) gegenübergestellt. Um eine von den drei Methoden unabhängige Referenz zu erstellen, wurde durch überwachte Inspektion zweier Testgebiete des Datensatzes „Stuttgart Flughafen“ ein Schwellwert extrahiert, der die Erstellung einer repräsentativen Änderungskarte ermöglichte. Beide Testgebiete beinhalten Hochaktivitätsbereiche, jeweils mit unterschiedlicher räumlicher Ausdehnung und Anzahl an Hochaktivitätsobjekten. Durch Verschneiden der drei Ergebniskarten mit der Referenz wurde eine empirische Bewertung mittels Konfusionsmatrizen durchgeführt. Es konnte beobachtet werden, dass für beide Testgebiete das Resultat aus der Methode nach *Renyi* in Relation zu den anderen beiden Änderungskarten besser mit der Referenz übereinstimmt und somit als genauestes dieser drei Entropieverfahren betrachtet werden kann.

Obwohl die Ergebnisse eine eindeutige Aussage zur Detektionsgenauigkeit erlauben, muss vor Augen geführt werden, dass nur zwei Testgebiete eines Datensatzes untersucht wurden. In weiterführenden Analysen sollten deshalb die in dieser Arbeit vorgestellten Ergebnisse anhand weiterer Testbereiche evaluiert werden. Insbesondere die Nutzung mindestens einer ergänzenden Szenerie, im Optimalfall aufgenommen von einem anderen, aber zu TSX beziehungsweise TDX vergleichbaren Sensorsystem (zum Beispiel CSK), sollte angestrebt werden.

### **Segmentierung**

Eine qualitative Bewertung der Resultate mittels der Elemente der Konfusionsmatrix wurde ebenfalls für die Beurteilung des in Abschnitt 4.2.1 eingeführten und im Rahmen dieser Arbeit genutzten Verfahrens zur Segmentierung der lokalen Änderungsnachbarschaft eingesetzt. Als alternative Methode wurde der in der Software *eCognition Developer* verfügbare MrSeg-Algorithmus hinzugezogen. Es wurden zwei voneinander unabhängige Bildausschnitte des Stuttgarter Datensatzes untersucht, wobei jeweils drei unterschiedliche Segmente durch manuelle Selektion als Referenz eingeführt wurden. Die Vorgehensweise zur Bestimmung der Elemente der Konfusionsmatrix wurde analog zur Analyse der Schwellwertverfahren gewählt.

Letztlich konnte festgestellt werden, dass die auf den Differentiellen Attributprofilen (DAP) basierende Methode zwar leicht unpräzisere Ergebnisse als MrSeg produziert, diese aber für sämtliche Testsegmente stabil und vergleichbar sind. Im Gegensatz dazu resultierten aus dem MrSeg-Verfahren nahezu optimale Übereinstimmungen mit der Referenz, aber auch teilweise große Unterschiede für die einzelnen betrachteten Segmente. Unter Berücksichtigung der Tatsache, dass die DAP-orientierte Verfahrensweise vollständig unüberwacht abläuft und mit geringem Zeitaufwand durchweg gute Ergebnisse (minimale Rate an TP-Pixel hier: 82,3 %) zur Verfügung stellt, kann diese im Vergleich zu MrSeg für die vorliegende Arbeit als überlegen eingestuft werden. Der MrSeg-Algorithmus verläuft halbautomatisch und setzt eine manuell gewählte Parametrisierung voraus, die zunächst im Rahmen von *Trial-and-Error*-Iterationen (mit vergleichbar hohem zeitlichen Aufwand) optimiert werden muss. Darüber hinaus ist eine solche für einen bestimmten Datensatz gefundene optimale Parametrisierung nicht uneingeschränkt ohne Anpassungen auf andere Szenen übertragbar. Eine solche Übertragbarkeit ist durch die DAP-basierte Methode grundsätzlich gegeben, als alleinige Anpassung muss einzig der Cov-Wert für einen ideal homogenen Bildbereich eventuell angepasst werden.

Im Hinblick auf die hier durchgeführte Bewertung der beiden Segmentierungsansätze kann analog zu der Schwellwertmethode festgehalten werden, dass eine Evaluierung der ermittelten Resultate anhand fortrender, umfangreicher Referenzdaten verfolgt werden sollte.

### **Raumzeitliche Analyse**

Unter der raumzeitlichen Analyse wird in dieser Arbeit die Untersuchung verstanden, ob durch kombinierte Verwendung räumlich abgeleiteter Merkmale mit zeitlichen Aspekten aus dem vorliegenden Bildstapel klassenspezifische Systematiken beobachtbar sind. Somit soll geprüft werden, ob beispielsweise die final existierenden Klassen des optimierten Katalogs anhand spezifischer Ausprägungen der Aktivitätscluster AC voneinander abgrenzbar sind. Die AC beinhalten jeweils Hochaktivitätspixel HAP, die über eine identische Signatur (vorhanden / nicht vorhanden) entlang der Zeitreihe verfügen. Es zeigte sich, dass die AC keine

Rückschlüsse auf eine eindeutige Unterscheidbarkeit der finalen Klassen zulassen (Abbildung 6.26). Dieser Umstand erscheint nicht besonders verwunderlich im Anbetracht der Tatsache, dass für eine wie in Abschnitt 6.2.5 definierten Klasse (zum Beispiel *Parkplatz*) mehrere unterschiedliche AC existieren können (besetzte / unbesetzte Parkbuchten). In Konsequenz folgt daraus, dass eine zielführende Nutzung der AC für eine Differenzierung der Klassen mittels der betrachteten Datengrundlage nicht möglich ist. Dennoch sollte im Rahmen weiterer Untersuchungen getestet werden, ob dieses Verhalten ebenfalls für sehr kleinräumig beziehungsweise fein selektierte Klassen existiert, oder ob auf diese Weise eine raumzeitliche Unterscheidung durch Verwendung der AC ermöglicht wird. Würde beispielsweise anstelle eines gesamten Parkplatzbereichs eine einzelne Parkbucht als Klasse definiert werden, sollten sich die dort extrahierten AC von denen eines einzelnen Parkplatzes einer Be- / Entladestelle unterscheiden.

Der zweite Aspekt der raumzeitlichen Analyse ist gegeben durch die Analyse der Hochaktivitätstapel (Abschnitt 3.2.3). Dieser Analyse liegt die Überlegung zugrunde, dass sich an identischem Ort aber zeitlich versetzt auftretende Hochaktivitätsobjekte hinsichtlich ihrer merkmalsbasierten Ausprägung und in Anbetracht ihrer ortsbezogenen Semantik wenig beziehungsweise stark voneinander unterscheiden sollten. Anhand dieser Überlegung sollte getestet werden, ob anhand dieser Stapel Rückschlüsse abgeleitet werden können, die für eine Unterscheidung der verschiedenen Klassen genutzt werden kann. Die dazu vorgestellte Strategie basiert letztlich auf der Berechnung der Überlappungsgrade der zu einer bestimmten Klasse zugeordneten Stapel und deren Wertintervalle im zweidimensionalen Merkmalsraum. Es wurde festgestellt, dass kein signifikanter Trend ableitbar ist, der eine semantische Abgrenzung der Klassen anhand der darin befindlichen Hochaktivitätstapel erlaubt. Die Verarbeitungsweise wurde als nicht zielführend deklariert und weitere detailliertere Prüfungen im Rahmen künftiger Arbeiten empfohlen. Eine mögliche alternative Herangehensweise wurde mit der Analyse der Varianzen der die Wertintervalle definierenden Minimal- und Maximalwerte genannt. Darüber hinaus wäre es interessant, den reduzierten zweidimensionalen Merkmalsraum zu verlassen und insbesondere die HAO-bezogenen Formmerkmale erneut und gesondert zu betrachten. Aus allgemeiner Sicht sind die für die raumzeitliche Analyse verwendeten Eingabedaten als in sich heterogene Klassenregionen anzusehen, die eine Ableitung typischer Muster erschweren. Aus diesem Grund scheint die Nutzung raumzeitlich homogener Klassenregionen (Parkplätze an Kreuzfahrtkais etc.) eine vielversprechende Möglichkeit darzustellen.

### Anzahl dominanter Cluster

Der Parameter  $CL$ , der die Anzahl dominanter, verschiedener Kategorien einer Klasse beschreibt, nimmt eine zentrale Rolle ein. Es wurde getestet, ob der genutzte Schwellwert  $CL_\tau = k^*/2$  für eine vergleichsweise geringe Anzahl an unterschiedlichen Clustern  $k^* \leq 12$  in passender Weise vorliegt. Hierfür wurden drei Szenarien miteinander verglichen, um eine begründbare Aussage zum Schwellwert  $CL_\tau$  ableiten zu können. Es wurde getestet, ob Klassen, die für  $k^* = 4$  mit  $CL_\tau = k^*/2$  existierten beziehungsweise nicht existierten, auch für  $k^* = 8$  und  $k^* = 12$  in den Daten vorhanden beziehungsweise nicht vorhanden sind. Anhand dieser Vorgehensweise konnte mittels der sechs initial gewählten Klassen festgehalten werden, dass die Wahl des Schwellwerts zu  $k^*/2$  für die bearbeitete Aufgabenstellung als geeignet einzustufen ist.

Dennoch bleibt festzuhalten, dass die Testläufe auf drei unterschiedlichen, relativ geringen Clusteranzahlen erfolgten. Eine generelle Übertragbarkeit des genutzten Parameters  $CL$  mit der Konstellation  $CL_\tau = k^*/2$  erscheint aus diesem Grund zumindest unklar. So ist es durchaus denkbar, dass bei sehr vielen unterschiedlichen Kategorien der Wert  $CL_\tau$  entsprechend ansteigt und jenseits der  $k^*/2$  zu einem stimmigeren Ergebnis führt. Es muss ergänzend erwähnt werden, dass die Bewertung auf einem bestimmten Klassenkatalog erfolgte. Hier sollten in fortführender Weise noch andere Klassenkataloge in verschiedener Konstellation (wenige beziehungsweise viele Klassen) berücksichtigt werden.

### Klassenkatalog

In Abschnitt 6.3.6 wurden Prozessierungen des vorgestellten Verfahrens für zwei Klassenkataloge beschrieben, die von der in Abschnitt 6.2.5 behandelten Konstellation abweichen. Hierfür kamen ein nur aus drei, räumlich großflächig gewählten Klassen bestehender Katalog, sowie im Gegensatz dazu ein Katalog mit zehn teilweise äußerst fein selektierten Klassenbereichen zum Einsatz. Da nur getestet werden sollte, ob die Methode solch variierende Kataloge in robuster Weise verarbeitet, wurde das Hauptaugenmerk auf den Schritt der Rückprojektion und die damit verbundene Optimierung des vorab eingestellten Katalogs gelegt. Eine im Anschluss daran mögliche Klassifikation der HAO wurde aufgrund der fehlenden Notwendigkeit nicht durchgeführt.

Sowohl für den kleinen als auch den großen Klassenkatalog konnten anhand der Stuttgarter Szene sinnvolle und begründbare Ergebnisse im Zuge der Rückprojektion beobachtet werden. Die Robustheit des Algorithmus in Anbetracht sich verändernder, durch den Nutzer voreingestellter Datengrundlagen konnte somit

nachgewiesen werden.

### **Klassenzugehörigkeit**

Die Klassifikation der Hochaktivitätsobjekte erfolgt mittels *Fuzzy-Zugehörigkeitsregionen*, die dazu genutzt werden, je HAO für jede finale Klasse einen prozentualen Zugehörigkeitsgrad zu ermitteln (siehe auch Abschnitt 5.2.5). Die Zuweisung zu einer bestimmten Klasse erfolgt basierend auf der Lage des jeweiligen HAO im Merkmalsraum relativ zu dieser Klasse unter Berücksichtigung eines durch den Anwender einstellbaren Zugehörigkeitswerts  $z$ . Aus dieser Verfahrensweise folgt, dass insbesondere bei räumlich eng beieinander befindlichen Kategorien im Merkmalsraum und somit tendenziell auch bei mehr oder weniger stark überlappenden Klassen die Repräsentativität des Klassifikationsergebnisses mit geringerem Wert für  $z$  abnimmt, da so eine eindeutige Klassenzugehörigkeit für ein spezifisches HAO erschwert wird. Grundsätzlich hängt somit die Wahl eines geeigneten Werts für  $z$  von der verfügbaren Datenlage oder dem jeweilig geforderten Ergebnis ab. Eine automatische Bestimmung von  $z$ , beispielsweise durch Verfahren der *Defuzzifikation*, wird in Anbe tracht der Forderungen und Beiträge aus Kapitel 1 nicht verfolgt. Mit der hier umgesetzten Methode wird dementsprechend bewusst die Möglichkeit gegeben, den Datensatz und die darin enthaltene Klasseninforma tion zu erlernen.

# Kapitel 7.

## Zusammenfassung und Ausblick

In diesem abschließenden Kapitel wird das erläuterte Verfahren zur Änderungsanalyse den in Kapitel 1 formulierten Anforderungen und Thesen gegenübergestellt. Neben der Diskussion, ob diese durch die Methode hinreichend erfüllt sind, werden Stärken und Schwächen der Verarbeitungskette aufgezeigt. Darüber hinaus werden Anknüpfungspunkte für weitere Untersuchungen erläutert.

### Anforderungen und Thesen

Mit dem in Abschnitt 1.1 dargelegten Überblick zum Stand der Technik hinsichtlich Verfahren zur Detektion und weiterführenden Analyse (Kategorisierung, Klassifikation, Typisierung) von Änderungen in SAR-Bilddaten konnte abgeleitet werden, dass ein möglichst praktikables Verfahren bisher nicht existierte. Unter dieser Praktikabilität wird hier der Zusammenschluss der Faktoren Übertragbarkeit, Anwendungsorientierung und Nutzerfreundlichkeit verstanden (Abschnitt 1.2). Im Hinblick auf die Kategorisierung und die Klassifikation der Änderungen und damit auch in Bezug auf die indirekte Klassifikation der umgebenden LULC-Klasse konnte darüber hinaus in anschaulicher Weise mit Abschnitt 5.1 der Bedarf nach einer Methode ermittelt werden, die weder auf spezielles Expertenwissen noch auf umfangreiche Referenzdaten zurückgreift.

### Übertragbarkeit und Anwendbarkeit

Generell benötigt die beschriebene Prozesskette nur eine Zeitreihe bestehend aus SAR-Amplitudenbildern. Auf Trainings- oder Referenzdaten wird bewusst verzichtet, um die Methode so generalisiert wie möglich zu gestalten. Jene Stellen, an denen diese Referenzdaten zum Einsatz kommen (exemplarisch: Bestimmung der Kontextklasse (Abschnitt 4.2.1)), dienen allein zur Bestimmung ergänzender Informationen zur Interpretation der final resultierenden Klassen. Die Tatsache, dass eine LULC-Klassifikation anhand von Änderungsobjekten erfolgt, lässt die grundlegende Verarbeitungsweise für sämtliche vergleichbare Klassifikationsaufgaben nutzbar werden, bei denen eine entsprechende Datenbasis nur in eingeschränktem Umfang verfügbar ist.

Die Detektion der Änderungen (hier: Hochaktivitätsobjekte HAO) selbst erfolgt anhand des für SAR-Bilder verbreitet genutzten LR-Operators in Verbindung mit einer morphologischen Filterung (ASF), die einerseits das Rauschen im Quotientenbild und damit eine mögliche Falschdetektionsrate vermindert und andererseits die Steuerung der gewünschten, beziehungsweise geforderten Größe der Änderungsobjekte (beispielsweise kleinräumige Änderungen) erlaubt. Grundsätzlich ist diese Methode auf SAR-Amplitudenbilder anderer Sensoren übertragbar, bei der Parametrisierung des ASF müssen gegebenenfalls die unterschiedlichen geometrischen Auflösungen berücksichtigt werden.

Das *Clustering* der HAO wird anhand deren merkmalsorientierten Ausprägungen durchgeführt. Als Merkmale kommen gängige und verbreitete Eigenschaften wie Textur- oder Formparameter zum Einsatz. Für die vorliegenden Testdatensätze konnte das vergleichsweise junge Konzept der differentiellen morphologischen Attributprofile (DAP) als Merkmal identifiziert werden, das maßgeblich zur Unterscheidung der Änderungskategorien beiträgt. Die erläuterten DAP sind ebenfalls auf Szenen anderer Sensorplattformen nach etwaiger Anpassung ihrer Parametrisierungen (Wertesequenzen der Attribute) übertragbar. Der Vorteil der DAP liegt in ihrer Flexibilität. So sind sehr viele verschiedene Attribute denkbar, die zur komplementären Modellierung des jeweiligen Bildinhalts Anwendung finden können. Die hier genutzten Attribute sind als eine Teilmenge davon zu betrachten.

Das *Clustering*-Resultat dient als Datenrealität, auf deren Grundlage ein durch den Anwender eingeführter Klassenkatalog optimiert wird. Da auf diese Weise ein Klassenkatalog durch das Verfahren vorgeschlagen wird, der bestmöglich zu dem tatsächlich existierenden Informationsgehalt passt, wird zur Katalogerstellung kein spezifisches Wissen über die jeweilige Szene vorausgesetzt. Die Selektion des initialen Klassenkatalogs erfolgt flexibel für die jeweils vorliegende Szene in Abhängigkeit vom Bildinhalt und von der Aufgabenstellung. In Abschnitt 6.3.6 wurde gezeigt, dass der Algorithmus für unterschiedliche Klassenkataloge sinnvolle und begründbare Ergebnisse erzeugt und somit uneingeschränkt auf andere Szeneninhalte adaptierbar ist.

Für die Klassifikation der kategorisierten HAO kommen Fuzzy-Zugehörigkeitsregionen zum Einsatz, die sich an der Größe und Form der Klassenbox im Merkmalsraum orientieren (Abschnitt 5.2.5) und somit von der Beschaffenheit der final vorliegenden Klasse abhängig sind. Die durch den Anwender frei wählbare Zugehörigkeitsschwelle erhöht die Flexibilität des Verfahrens und trägt zur Wissensbildung auf Anwenderseite bei. Eine pauschale und für alle Datensätze allgemeingültige Empfehlung eines universellen Schwellwerts

existiert nicht, da dieser Wert in erster Linie von der relativen Anordnung der Kategorien im Merkmalsraum abhängt. Bei sich sehr stark überlappenden Klassenregionen erweist sich eine hoch gewählte Schwelle als sinnvoll, da so das Klassifikationsergebnis als präzise und repräsentativ betrachtet werden kann. Daraus folgt, dass die durch den Anwender vorzunehmende Wahl des Schwellwerts die Anwendbarkeit des Verfahrens steigert.

### Nutzerfreundlichkeit

Als zentrale Eigenschaft zur Charakterisierung der nutzerfreundlichen Bedienbarkeit ist hier der Umstand zu nennen, dass die beschriebene Methode kein Expertenwissen über die Szenerie oder die Verarbeitung erfordert. Weiterhin ist die Selektion von Trainingsgebieten, die Erfahrung im Umgang mit Fernerkundungsdaten voraussetzt und äußerst zeitaufwendig ist (siehe Abschnitt 5.1), für die vorgestellte Prozesskette unerheblich. Neben dem Verzicht auf Trainingsdaten, deren Auswahl auch indirekt die Güte des Klassifikationsresultats beeinflusst, spielt der Automatisierungsgrad bei der dargestellten Verfahrensweise eine bedeutende Rolle, um deren Bedienbarkeit zu vereinfachen. Die Detektion der HAO wird durch Nutzung des unüberwachten Schwellwerverfahrens nach *Renyi* vollautomatisch durchgeführt. Die in Kapitel 4 erläuterte Merkmalsextraktion erfolgt ebenfalls ohne Einwirkung des Anwenders, der sich allerdings in Vorarbeit einmalig auf eine sinnvolle Parametrisierung beziehungsweise Berechnungsweise der einzelnen Merkmale festlegen muss. Im Anschluss daran wird die Merkmalsmatrix auf eine gewisse Anzahl nicht redundanter, maßgeblicher Merkmale in unüberwachter Weise mittels PCA und PCT reduziert. Das *Clustering* der HAO basierend auf der reduzierten Merkmalsmatrix erfordert keine Interaktion mit dem Nutzer, da eine automatisierte Version des *k-means*-Algorithmus verwendet wird. Den hauptsächlichen Anteil von Anwenderseite erfährt die Methode durch die Definition eines initialen Klassenkatalogs, für die der Anwender beispielsweise unterstützend optische Bilddaten heranziehen kann. Die weitere Prozessierung mittels Vor- und Rückprojektionen wird durch den Algorithmus selbstständig durchgeführt. Zum Abschluss der Verfahrenskette wird die Zuweisung der HAO zu den final ermittelten Klassen durchgeführt, bei der der Anwender durch Vorgabe der *Fuzzy-Zugehörigkeitsschwelle* mit dem Verfahren interagiert. Beide Strategien (Wahl des Klassenkatalogs und des Zugehörigkeitsschwells) sind ausdrücklich so erwünscht, da diese zur Wissensbildung über den jeweiligen Datensatz beitragen. Dieses Wissen kann zur Erkenntnisbildung genutzt werden, welche Klassen tatsächlich für die vorliegende Datengrundlage zielführend sind, beziehungsweise welche Klassen unterschieden werden können.

Ein weiterer zentraler Aspekt zur Charakterisierung der Nutzerfreundlichkeit des hier vorgestellten Verfahrens ist die geringe Anzahl an einzustellenden Parametern. Der Anwender kann demnach unmittelbar, wenn die gewünschte Zielgröße der gesuchten Änderungen eingestellt wurde, mit der Prozessierung beginnen. Die Verarbeitung wird durch den Algorithmus übernommen, der Anwender bekommt das notwendige Wissen über den verfügbaren Datensatz bereitgestellt.

### Robustheit

Unter Robustheit wird an dieser Stelle die Eigenschaft des Algorithmus verstanden, verlässliche und präzise Ergebnisse, auch unabhängig von der jeweiligen Datengrundlage, zu produzieren.

In Abschnitt 6.3.1 wurde aufgezeigt, dass die hier genutzte Methode zur Änderungsdetektion gegenüber einem weiteren, in der SAR-Bildauswertung verbreiteten Verfahren (KLD) in Bezug zur vorliegenden Aufgabenstellung entscheidende Vorteile besitzt. Darüber hinaus wurde die Detektionsgüte durch Analyse eines Testgebiets nachgewiesen. Insbesondere mit der sehr niedrigen Rate an Falschdetektionen kann die Robustheit der Änderungsdetektion nachgewiesen werden.

Mit den in Abschnitt 6.3.2 beschriebenen Untersuchungen wurde das verwendete unüberwachte Schwellwertverfahren nach *Renyi* als geeigneter Vertreter aus insgesamt drei entropiebasierten Ansätzen identifiziert. Darüber hinaus konnte bereits in Abschnitt 3.1 beobachtet werden, dass die Methode nach *Renyi* unabhängig von der Anzahl an Hintergrundpixeln in den betrachteten Eingangsbildern robuste Ergebnisse bereitstellt.

Im Hinblick auf die Evaluierung der eingeführten Verfahrensweise zur automatischen, DAP-basierten Segmentierung von SAR-Amplitudenbildern (Abschnitt 4.2.1) wurde eine kommerziell erhältliche Methode (MrSeg) vergleichend gegenübergestellt (Abschnitt 6.3.3). Dabei zeigte sich, dass die morphologisch orientierte Methode zwar geringfügig ungenauere Segmentierungsergebnisse erstellt, diese dennoch in Relation zu den Resultaten aus MrSeg stabiler ausfallen. Weiterhin wurde gezeigt, dass der Verarbeitungsaufwand für die halbautomatische MrSeg vergleichsweise hoch einzuordnen ist und eine Übertragbarkeit einer gewählten Parametrisierung nicht uneingeschränkt gegeben ist. Die DAP-basierte Segmentierung hingegen ist grundsätzlich für andere Datensätze (Szenen, Sensoren) verwendbar.

Der Schwellwert  $CL_\tau$  zur Unterscheidung von vorhandenen und nicht vorhandenen Klassen anhand der Anzahl dominanter Clusterstrukturen wurde in Abschnitt 6.3.5 eingehender untersucht. Durch Verwendung

---

dreier verschiedener Kategorisierungsresultate konnte nachgewiesen werden, dass für die betrachtete Datengrundlage die Wertewahl zu  $CL_\tau = k^*/2$  sinnvoll getroffen wurde. Da als maximale Anzahl verschiedener Kategorien  $k^* = 12$  genutzt wurde, konnte nicht abschließend eine generelle Eignung des Schwellwerts für beliebige  $k^*$  abgeleitet werden. Da festgehalten werden kann, dass unter Berücksichtigung der hier zur Verfügung stehenden Datengrundlage ein größeres  $k^*$  als äußerst unwahrscheinlich einzuschätzen ist, wird  $CL_\tau = k^*/2$  als robuster Wert eingeordnet. Mit den im Abschnitt 6.3.6 enthaltenen Ausführungen kann rückgeschlossen werden, dass das präsentierte Verfahren zur Änderungsanalyse in robuster Art und Weise unterschiedliche initial selektierte Klassenkataloge verarbeitet und jeweils begründbare Resultate produziert, die zur Wissensbildung auf Anwenderseite genutzt werden können. Unpassend gewählte Klassenbereiche werden durch den Algorithmus ersatzlos gelöscht, oder falls möglich, zum Vorschlag von Neudefinitionen eingesetzt. Ein Übertrag des Verfahrens zur Optimierung des Klassenkatalogs ist uneingeschränkt auf andere Datensätze möglich. Einzig muss auf eine Anpassung des Katalogs an die örtlichen Begebenheiten geachtet werden. So müssten beispielsweise für urbane und maritime Szenen voneinander unterschiedliche Kataloge betrachtet werden.

### **Stärken und Schwächen**

Nach Diskussion der aus dem einführenden Kapitel abgeleiteten Anforderungen werden nachfolgend die Vor- und Nachteile des vorgestellten Verfahrens beurteilt.

Mit den Nachteilen beginnend, kann eingangs festgehalten werden, dass die vorgestellte Methode zur Änderungsanalyse keine völlig automatisierte Verarbeitungsweise zulässt. Obwohl Wert auf eine möglichst unüberwachte Prozessierungskette gelegt wurde, muss zumindest eine geringe Anzahl an Parametern durch den Anwender voreingestellt werden. Diese umfassen beispielsweise die Konfiguration des alternierenden sequentiellen Filters zur anwendungsorientierten Detektion von Änderungsobjekten bestimmter Größe. Je nach vorliegender Datenbasis müssen gegebenenfalls Anpassungen hinsichtlich der für die Änderungsobjekte extrahierten Merkmale erfolgen, wobei insbesondere die Einstellungen für die DAP-Berechnung anhand der SAR-spezifischen Attribute  $\sigma^0$  und  $Cov$  den Begebenheiten entsprechend angepasst werden müssen. Die Ableitung des Kontextklassenmerkmals erfolgt ebenso halbautomatisch, da die jeweilige Datengrundlage (Vektordaten,  $CovAmCoh$  oder LULC-Kartierung) zunächst beschafft werden muss.

Eine weitere Einschränkung betrifft ebenfalls das Kontextmerkmal, das im Rahmen dieser Arbeit binär vorliegt und demnach für die Kategorisierung selbst nicht genutzt werden kann. Da der lokale Kontext grundsätzlich als äußerst vielversprechend zur Unterscheidung verschiedener Änderungsobjekte einzustufen ist, sollte an dieser Stelle eine alternative Verarbeitungsweise geprüft werden. Ein entsprechendes Konzept ist in Abschnitt 6.2.7 enthalten.

In Bezug auf die in Abschnitt 6.3 enthaltenen Evaluierungen des Segmentierungs- und des Schwellwertverfahrens wurde eine relativ geringe Anzahl an Testsegmenten und -gebieten untersucht. Die dort dargelegten empirischen Aussagen sollten demzufolge ergänzend anhand weiterer Datensätze geprüft werden. Vergleichbares gilt für die Beurteilung des Parameters  $CL$  sowie für die Wahl des Klassenkatalogs. Hierfür könnte sicherlich eine Szene mit abweichend strukturiertem Inhalt eine gewinnbringende Rolle spielen.

Das durch die beiden Verarbeitungsschritte Vor- und Rückprojektion gekennzeichnete Verfahren zur Optimierung eines Klassenkatalogs berücksichtigt in der hier beschriebenen Vorgehensweise keine automatisierte semantische Analyse sich überlappender oder neu definierter Klassen. In beiden Fällen obliegt es dem Anwender, entsprechende Erkenntnisse über die final vorliegenden Klassen abzuleiten. Da für diesen Schritt jedoch mindestens ein gewisses Maß an Interpretationsfähigkeit von beispielsweise optischen Referenzdaten vorhanden sein muss, wäre eine unterstützende automatische Prozessierung wünschenswert, die etwa auf den Resultaten aus der Zuweisung der Kontextklasse aufbaut.

Diesen Nachteilen stehen bedeutende Vorteile und Stärken des Verfahrens gegenüber. Durch die eingeschränkte Datengrundlage und den bewussten Verzicht auf umfangreiche Referenz- oder Trainingsdatensätze werden optimale Übertragbarkeit und Nutzerfreundlichkeit sichergestellt, die dazu führen, dass die Methode über eine große Relevanz für praktische Anwendungsfälle in der Klassifikation von Fernerkundungsbildern verfügt. Darüber hinaus müssen dem Anwender keine detaillierten Informationen über das Interessengebiet vorliegen, da dieser bei der Wissensbildung durch den Algorithmus unterstützt wird. Die Entwicklung erfolgte zum Zweck der Klassifikation von in Zeitreihen detektierten Hochaktivitätsobjekten und ist nicht auf diesen speziellen Anwendungsfall beschränkt. Durch die Gestaltung einer möglichst unüberwacht ablaufenden Prozesskette bei gleichzeitiger Berücksichtigung einer minimal notwendigen Anzahl an manuell einzustellenden Parametern wird eine gute Generalisierbarkeit erreicht. Grundsätzlich ist eine Verwendung für sämtliche Klassifikationsaufgaben basierend auf SAR-Amplitudenbildern denkbar, unabhängig von der Wahl des Sensors, der Aufnahmeparameter sowie auch der Szene selbst. Durch eine Umgestaltung der SAR-spezifischen Merkmale und Parameter wäre ebenso die Anwendung auf optische Bildprodukte möglich.

Für diesen Schritt müssten insbesondere die Konfigurationen der DAP, sowohl für die Segmentierung als auch für die Merkmalsextraktion angepasst werden, was mit relativ geringem Aufwand verbunden wäre. Eine hohe Flexibilität hinsichtlich sich ändernder Anforderungen mit Bezug auf die gewünschte Änderungsgröße wird durch die Nutzung des variabel einstellbaren ASF erreicht. In dieser Arbeit wurde der Fokus auf die Identifikation kleinräumiger Änderungen gesetzt, die sich in einer Größenordnung von mindestens einem mittelgroßen PKW bis hin zu einem durchschnittlichen Einfamilienhausgrundstück bewegen. Anhand von Testläufen konnte beobachtet werden, dass eine vollständige Änderungsdetektion aller Größen (klein-, mittel- und großflächig) durch einfache Kombination der jeweiligen Ergebnisse möglich ist. Im Vergleich zur KLD nach Abschnitt 6.3.1 werden die Änderungen unabhängig von ihrer räumlichen Ausdehnung in ihrer ursprünglichen Struktur ohne Verfälschung belassen, was eine formbasierte Analyse ermöglicht.

Aus den bisher diskutierten Eigenschaften ergeben sich einige Anknüpfungspunkte für fortführende Arbeiten, die nachfolgend eingehender geschildert werden.

### Anknüpfungspunkte

In der gegenwärtigen Version der eingeführten Methode zur Änderungsanalyse kommen verschiedene Merkmale zur Kategorisierung der Hochaktivitätsobjekte zum Einsatz, von denen sich die differentiellen Attributprofile (DAP) als äußerst vielversprechend für eine Trennung unterschiedlicher Änderungskategorien herausgestellt haben.

Ein weiteres vielversprechendes Merkmal ist die Umschreibung des lokalen semantischen Kontextes, der im Zuge einer Klassifikation für jedes HAO als binärer Vektor abgeleitet wird. Da alle weiteren betrachteten Merkmale kontinuierlich verteilt vorliegen, würde das binäre Kontextmerkmal unverhältnismäßig Einfluss auf die Kategorisierung besitzen, weshalb dies allein zur Unterstützung des Nutzers bei der Interpretation der final existierenden Klassen verwendet wird. Eine Berücksichtigung des Kontextmerkmals im Rahmen der Kategorisierung erfordert demnach eine alternative Berechnungsweise, die das Merkmal kontinuierlich verteilt extrahiert. Hierfür wurde in Abschnitt 6.2.7 eine Möglichkeit vorgeschlagen, die im Rahmen weiterführender Arbeiten untersucht werden sollte.

Ein weiterer Punkt für mögliche Optimierungen und fortführende Arbeiten ist durch die Berücksichtigung umfangreicherer Referenzdaten zur Evaluierung der in Abschnitt 6.3 getroffenen Aussagen gegeben. Eine Art GT-Datensatz mit Informationen über die in der Szene vorhandenen LULC-Klassen könnte zielführend zur Ableitung eines geeigneten *Fuzzy*-Zugehörigkeitsschwellwerts genutzt werden. Auf diese Weise könnte getestet werden, für welchen Wert  $z$  die tatsächliche Klassenreferenz bestmöglich approximiert wird. Da aber der Zugehörigkeitswert indirekt von dem Kategorisierungsergebnis und der relativen Lage der Klassen im Merkmalsraum abhängt, würde eine solche Herangehensweise keine generelle und für alle Datensätze gültige Aussage erlauben. Diese Vorgehensweise müsste somit für verschiedene Szenen verfolgt werden, um einen robusten Wert für  $z$  abschätzen zu können.

Die Anwendung des Verfahrens auf andere Szenen mit abweichendem Inhalt (zum Beispiel maritim und/oder aussereuropäisch) ist ein Aspekt, der für künftige Arbeiten sicherlich berücksichtigt werden sollte. Im vorliegenden Fall wurden zwei Testszenen genutzt, die mit demselben Sensorsystem aufgezeichnet wurden und über vergleichsweise ähnliche LULC-Strukturen verfügen. Neben der Analyse einer anderen Szenerie sollte ebenfalls ein anderes Sensorsystem zum Einsatz kommen (zum Beispiel CSK, RADARSAT, SENTINEL), um die Robustheit der Methode gegenüber solchen Variationen überprüfen zu können. Eine empirische Evaluierung der Klassifikationsresultate könnte ebenfalls durch fortführende Arbeiten untersucht werden. Hierfür wäre allerdings eine umfassende, präzise und in Bezug auf die Eingangsbilder aktuelle Referenzdatenbasis notwendig.

Darüber hinaus kann grundsätzlich getestet werden, ob beispielsweise andere zeitreihenorientierte Änderungstypen (niedrig- und mittelfrequente Änderungen) zur Identifikation andersartiger LULC-Klassen führen. Unabhängig vom Themenfeld der Änderungsdetektion sollte untersucht werden, ob und inwiefern das vorgeschlagene Verfahren zur Klassifikation ohne jegliche Trainingsdatenbasis für andere Eingabedaten wie beispielsweise optische Luft- und Satellitenbilder Anwendung findet. In diesem Zusammenhang wäre es sinnvoll, eine automatisierte Erstellung der zu einem Datensatz passenden Parametrisierung der DAP anzustreben.

Im Hinblick auf eine Steigerung der ohnehin schon guten Bedienbarkeit und Nutzerfreundlichkeit kann beispielsweise die automatische Selektion abgebildeter Regionen, die zu den final vorgeschlagenen Klassen ähnlich sind, durch den Algorithmus erfolgen. Auf diese Weise würde der Anwender bei der bisherigen manuellen semantischen Interpretation des optimal zu den Daten passenden Klassenkatalogs weiterführend unterstützt werden. Die Methode würde so in unüberwachter Weise sämtliche Bildregionen selektieren, die eine gewisse Ähnlichkeit zu einer bestimmten Klassenregion (zum Beispiel PKW-Parkplatz) aufweisen.

---

An möglichen Anknüpfungspunkten für weitergehende Untersuchungen mangelt es nicht. Dennoch ist mit der in der vorliegenden Arbeit präsentierten Verfahrensweise eine veritable Alternative zu bisher existierenden Methoden zur Klassifikation oder Typisierung von Änderungen anhand fernerkundlicher SAR-Bilddaten vorgeschlagen worden.

Generell ist es auch mit dieser Arbeit wie mit allen anderen (wissenschaftlichen) Abhandlungen...

*So eine Arbeit wird eigentlich nie fertig.*

*Man muß sie für fertig erklären, wenn man nach Zeit und Umständen das Möglichste getan hat.*

Johann Wolfgang von Goethe



## Anhang A.

### Ergänzende Abbildungen

Nr.	Kontextklasse
1	Volumenstreuer (Wald etc.)
2	Urban
3	Rural (landwirtschaftlich genutzt)
4	Rural (sonstige)
5	Flughafenvorfeld (Infrastruktur)
6	Flughafen Gates
7	Flughafenvorfeld (Park, Be- und Entladeplätze)
8	Infrastruktur (Straßen, Wege, etc.)
9	unklassifiziert

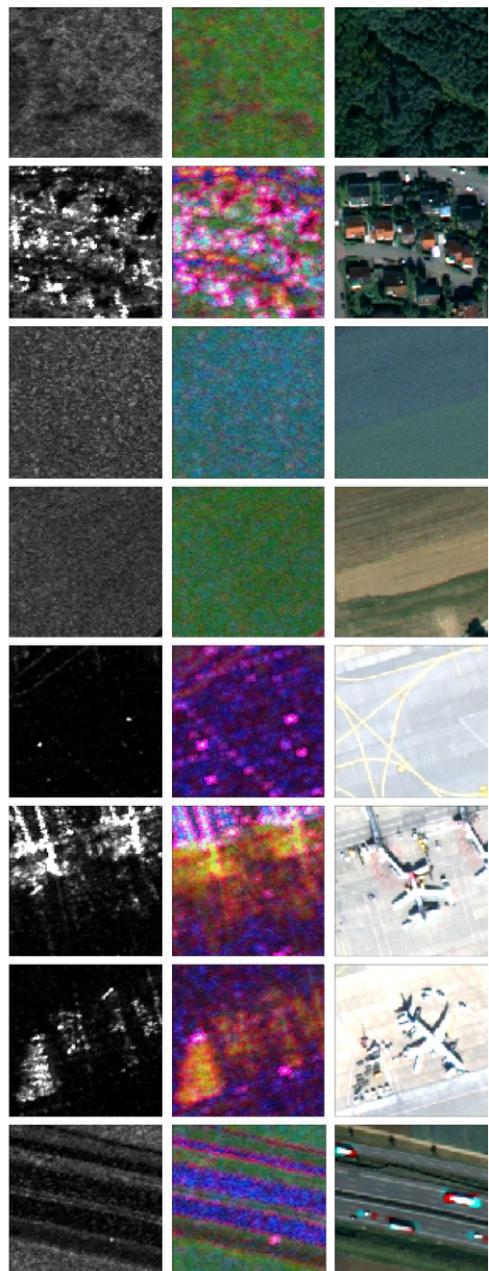


Abbildung A.1.: Beispielhafte Bildausschnitte für die einzelnen Kontextklassen (Datensatz „Stuttgart Flughafen“). Die Zeilenreihenfolge der Ausschnitte von oben nach unten entspricht der Listung in der Tabelle. Linke Spalte: Mittlere Amplitude der Zeitreihe, mittlere Spalte: Mittleres CovAmCoh-Bild der Zeitreihe, rechte Spalte: pangeschärftes WV-2-Bild.

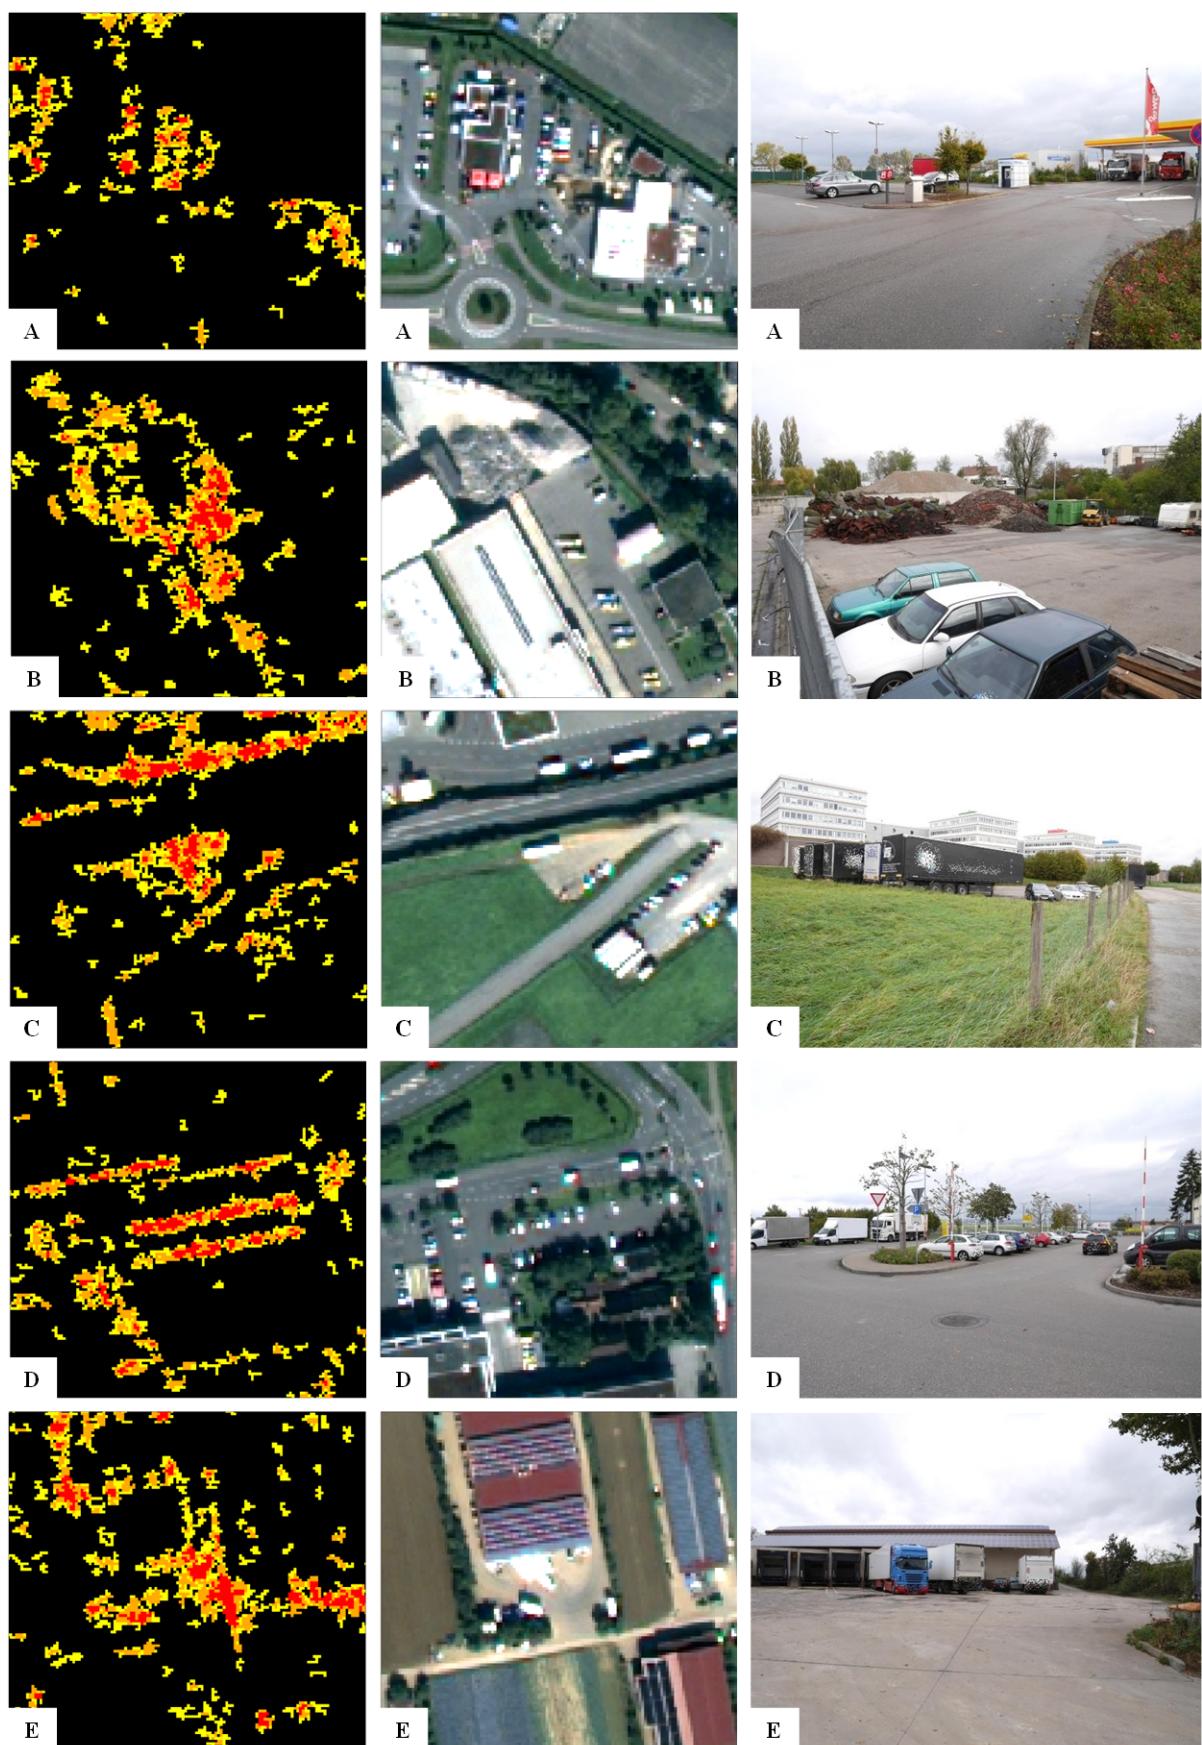


Abbildung A.2.: Hochaktivitätsgebiete. Spalten von links nach rechts: Ausschnitt aus Aktivitätskarte; Ausschnitt aus pangeschärftem WV-2-Bild; Foto aus Ortsbegehung am 22.10.2014. A: PKW- und LKW-Parkplatz; B: Baustelle; C: LKW-Parkplatz; D: PKW-Parkplatz; E: Be- und Entladestelle.

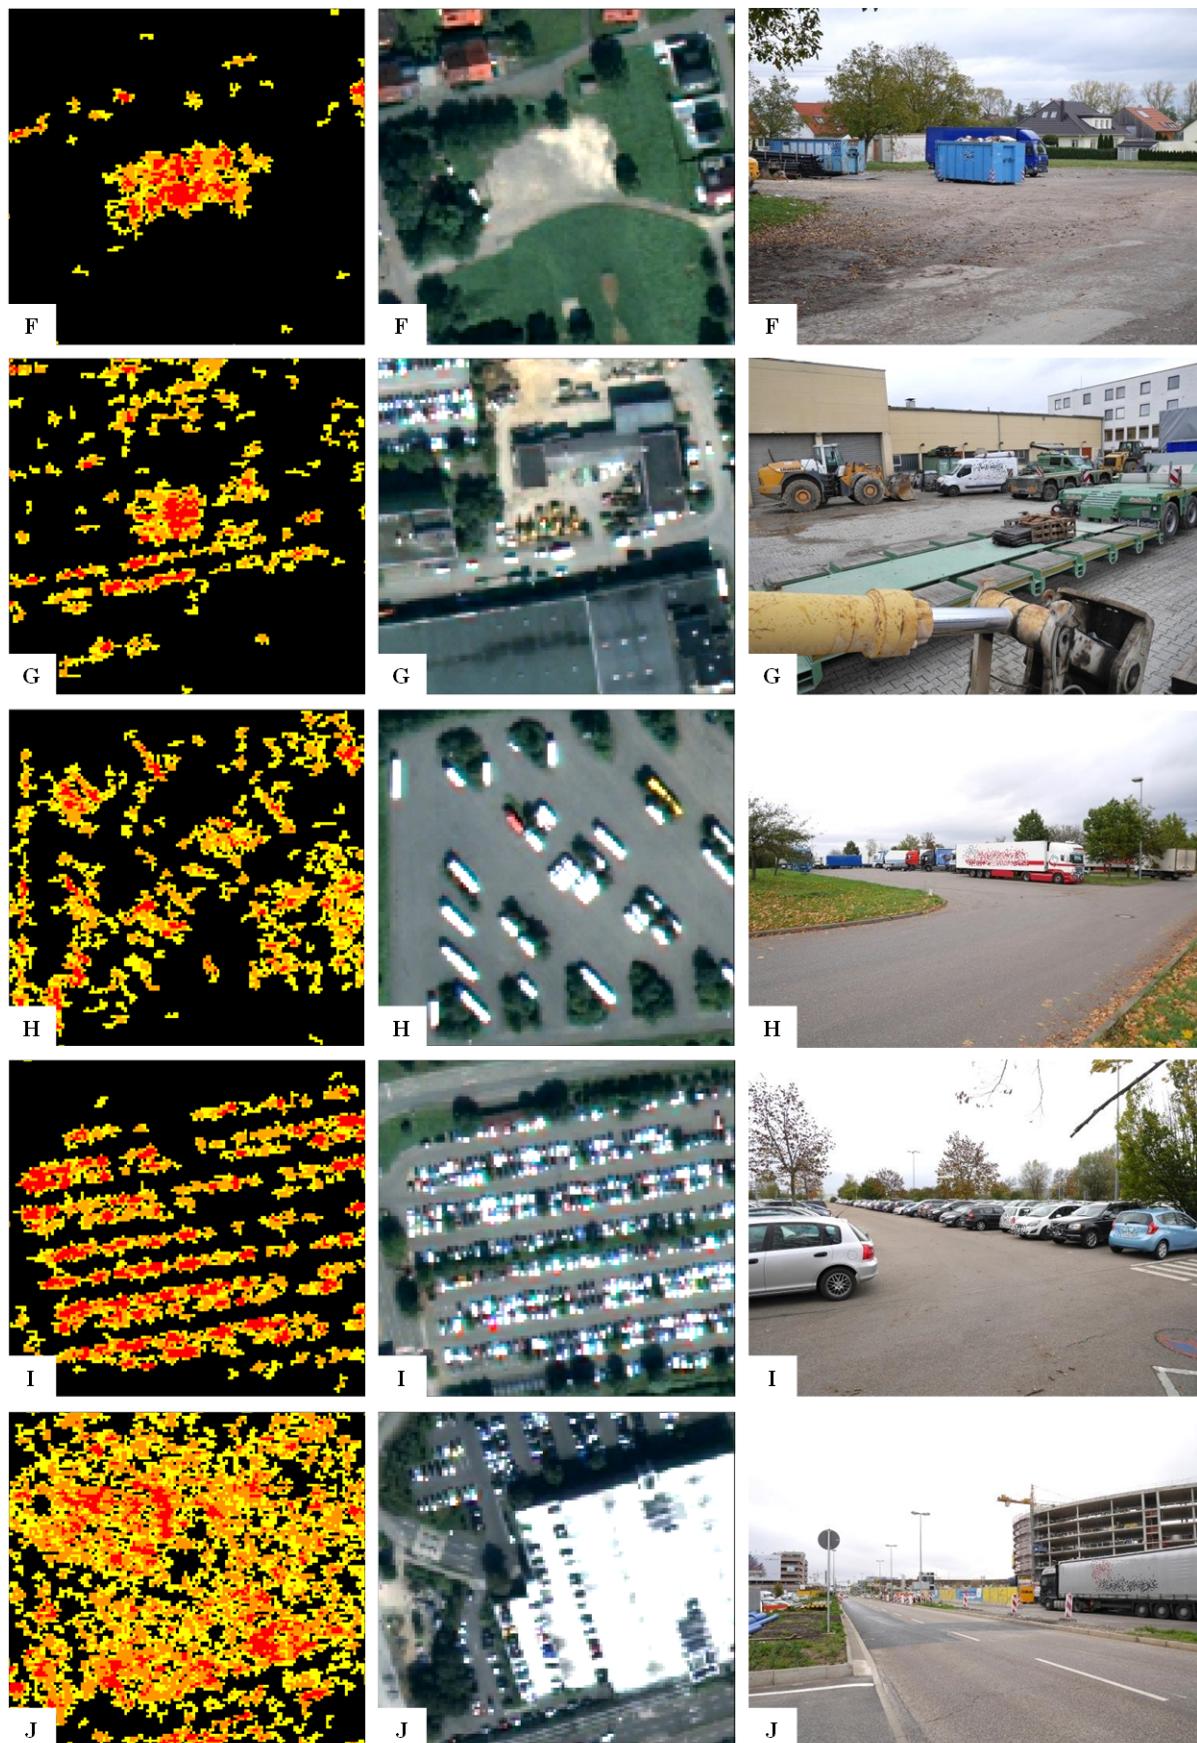


Abbildung A.3.: Hochaktivitätsgebiete. Spalten von links nach rechts: Ausschnitt aus Aktivitätskarte; Ausschnitt aus pangeschärftem WV-2-Bild; Foto aus Ortsbegehung am 22.10.2014. F: Sammelstelle; G: Parkplatz und Sammelstelle; H: LKW-Parkplatz; I: PKW-Parkplatz; J: Baustelle.

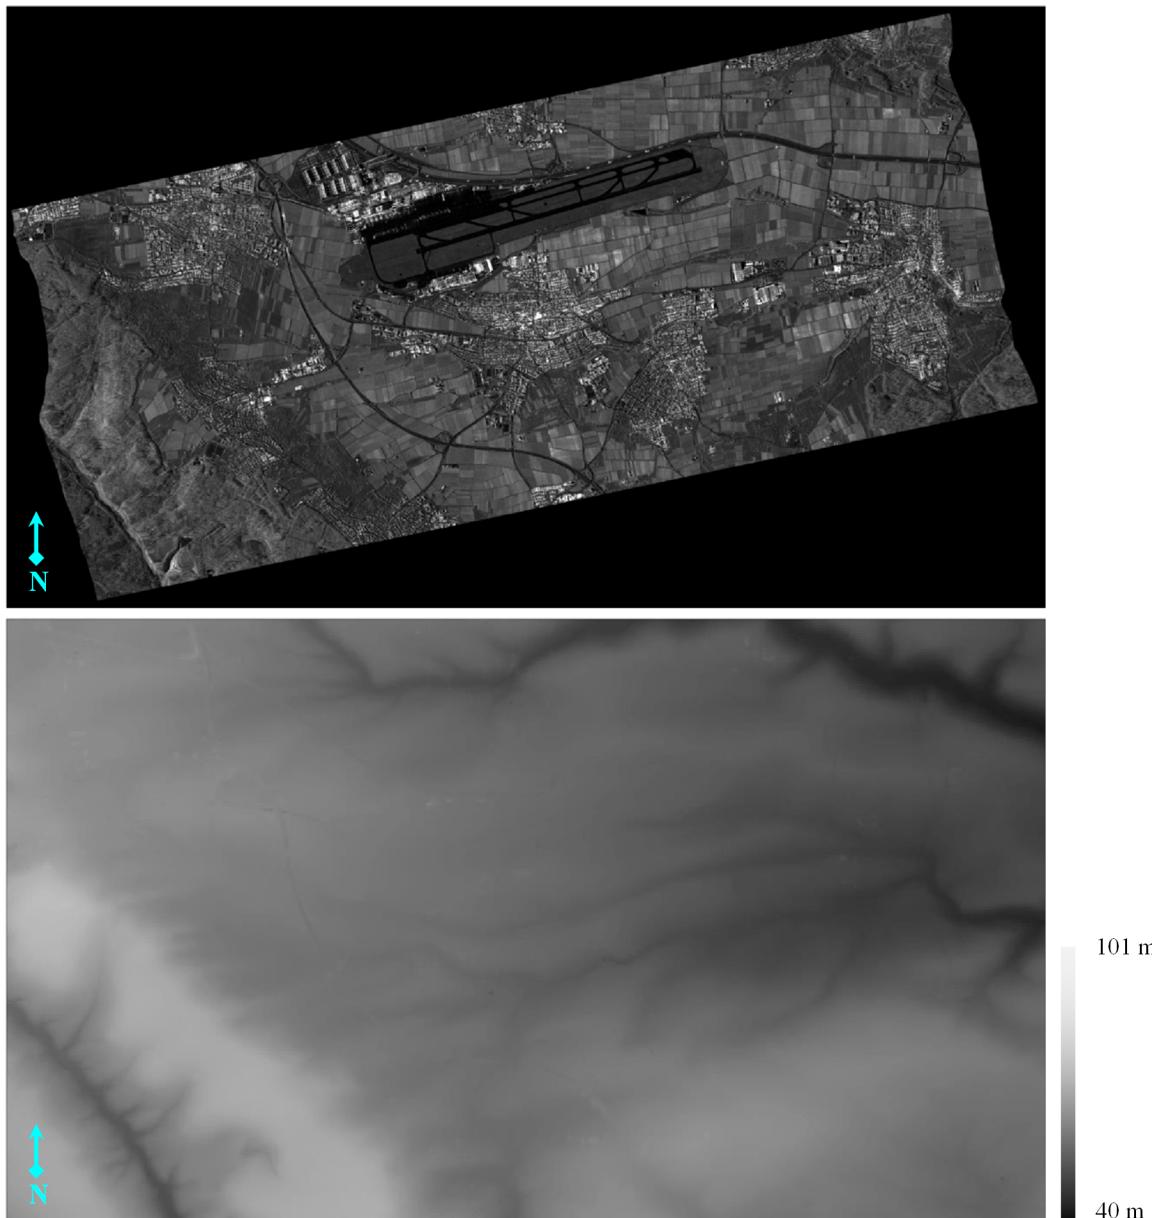


Abbildung A.4.: Oben: Mittleres Amplitudenbild der Zeitreihe, unten: DTED Level 2 Höhenmodell. Je heller der Grauwert, desto größer der Höhenwert.

Nr. HAO	Nr. CM	HAO Label	Nr. HAR	$S_{HAO,x}$	$S_{HAO,y}$	HAO Dimension X	HAO Dimension Y
1	2	9	1	687	2.626	6	3
2	5	5	1	688	2.627	8	3
3	7	8	1	686	2.627	6	3
4	13	10	1	688	2.626	7	3
5	2	4.309	2	4.041	4.351	7	4
6	5	2.597	3	4.038	4.351	3	4
7	7	2.525	3	4.039	4.350	11	6
8	13	3.302	2	4.039	4.352	4	4
9	2	4.562	4	4.177	2.448	11	30
10	5	2.764	4	4.178	2.460	6	5

Tabelle A.1.: Auszug aus der HAO-Liste mit zusätzlichen Attributen (Datensatz „Stuttgart Flughafen“).

ID Klasse	Name	Farbe
1	PKW-Parkplatz	Blue
2	LKW-Parkplatz	Orange
3	Baustelle	Yellow
4	Be- / Entladestelle	Purple
5	Sammelstelle	Green

Tabelle A.2.: Initialer Klassenkatalog (Datensatz „Greding“).

Initiale Klasse	Initiale Kennzahlen Optimierte Kennzahlen				Fall
	CL	D [%]	Z	Fall	
Initiale Klasse	1	1	[0,5; 4,2; 100,0; 70,7; 0,0] [unverändert]	0	0
	2	1	[21,7; 36,8; 100,0; 90,3; 15,4] [33,5; 46,0; 100,0; 99,1; 23,3]	1	2b
	3	3	[95,5; 100,0; 0,0; 100,0; 0,0] [unverändert]	3	3a
	4	2	[57,3; 32,6; 0,0; 30,1; 0,0] [68,5; 43,5; 0,0; 40,6; 1,7]	2	2b
	5	2	[46,1; 34,8; 0,0; 20,1; 0,0] [62,6; 46,2; 0,0; 28,9; 0,0]	2	2b

Tabelle A.3.: Optimierungsverlauf des initialen Klassenkatalogs (Datensatz „Greding“). CL: Anzahl dominanter Cluster; D [%]: Prozentualer Anteil am Dichtebereich eines Clusters; Z: Zerteilungsgrad.

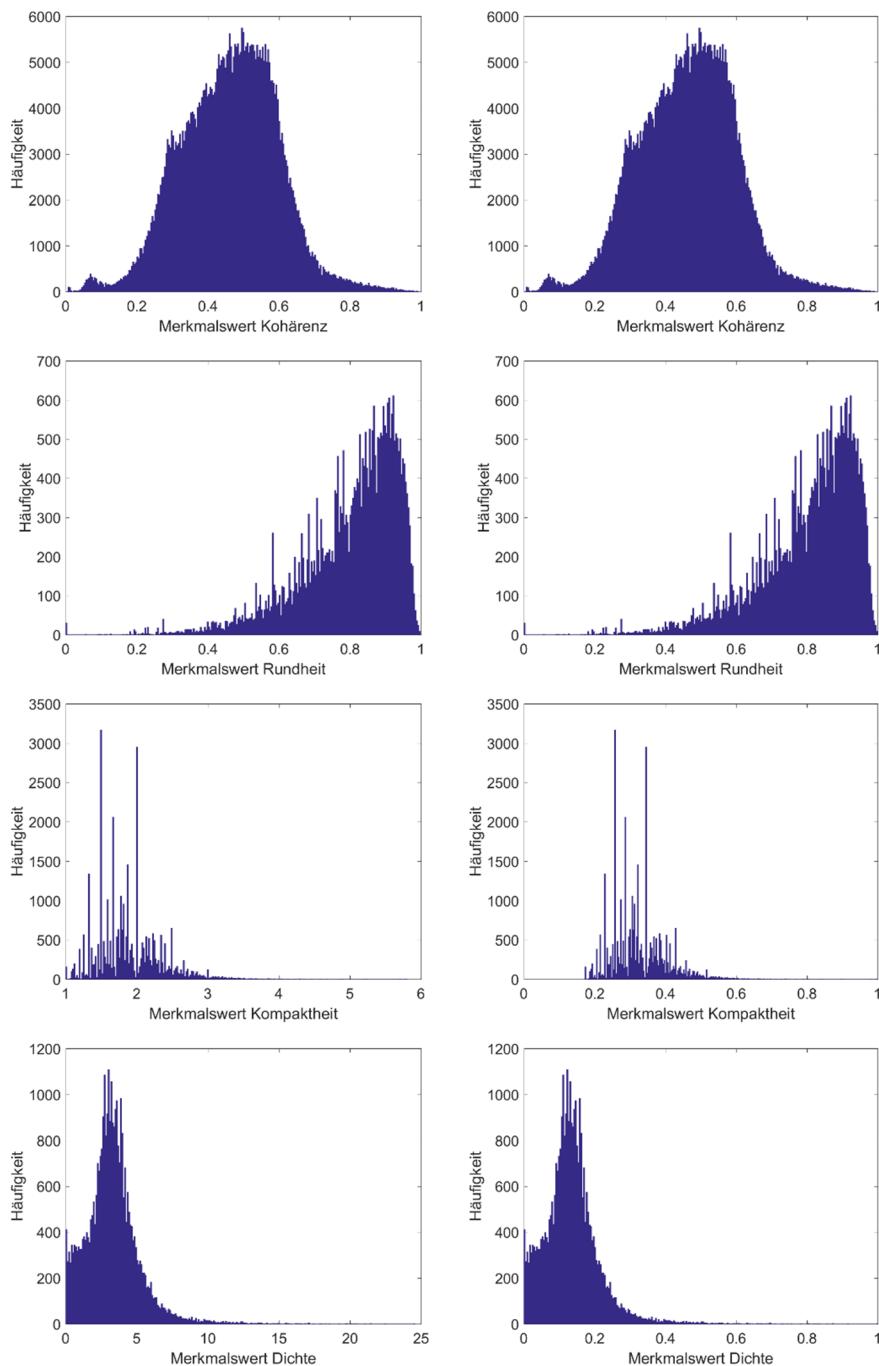


Abbildung A.5.: Histogrammdarstellungen der genutzten Merkmale (Teil 1). Abszisse: Merkmalswerte, Ordinate: Wertehäufigkeit über alle HAO. Linke Spalte: Unskalierter Wertebereich, rechte Spalte: Skalierter Wertebereich.

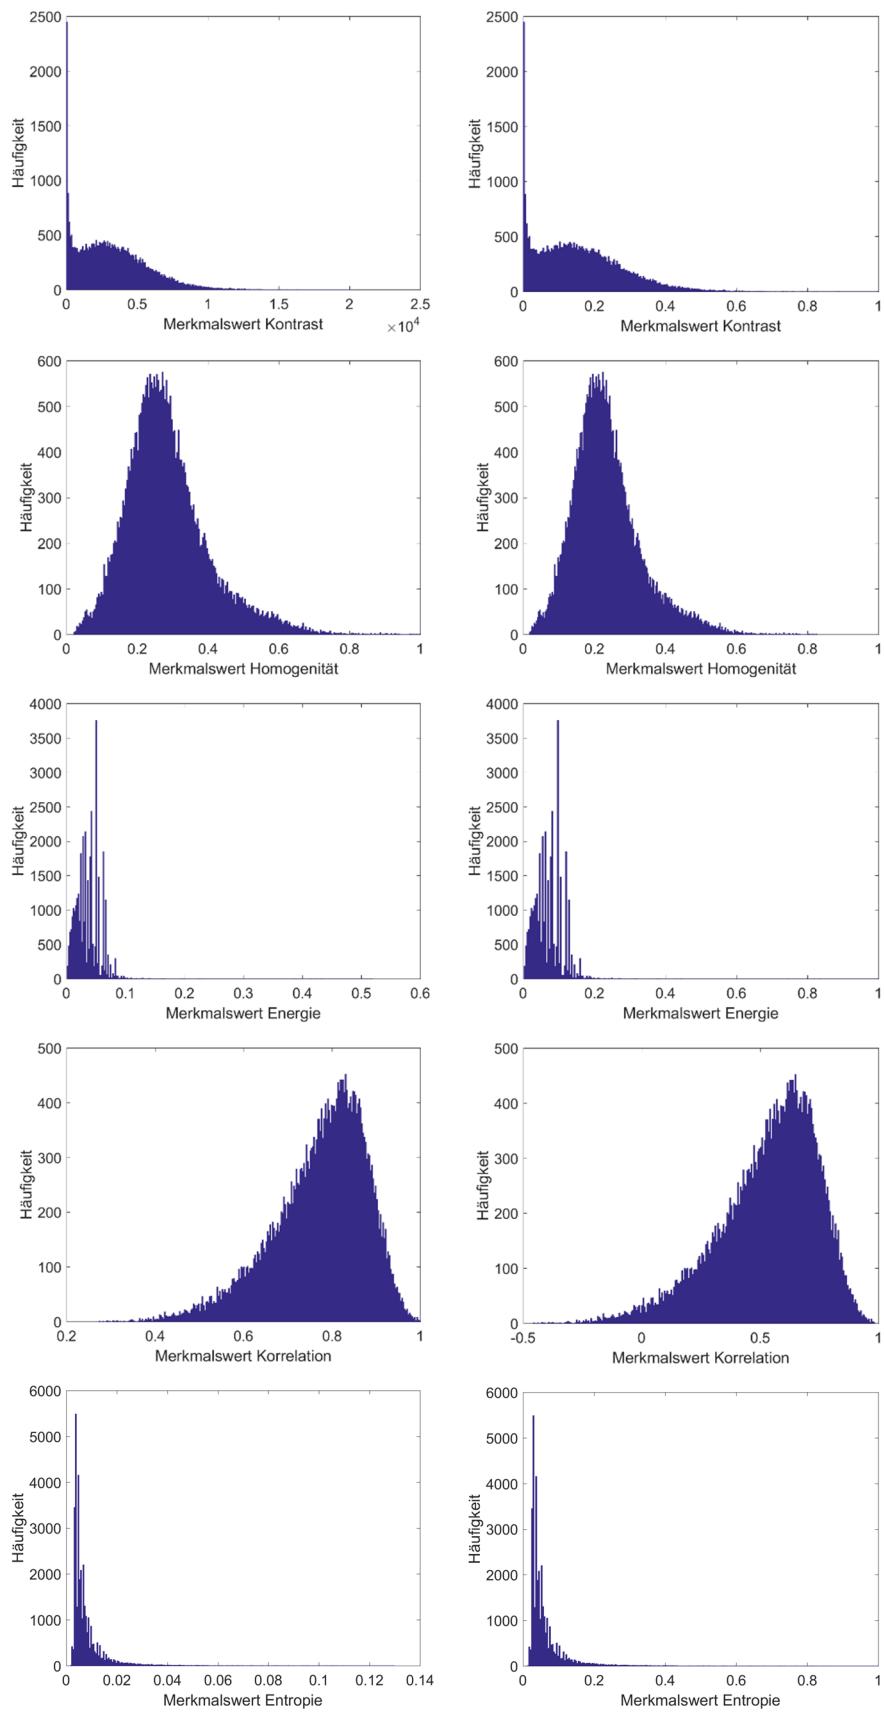


Abbildung A.6.: Histogrammdarstellungen der genutzten Merkmale (Teil 2). Abszisse: Merkmalswerte, Ordinate: Wertehäufigkeit über alle HAO. Linke Spalte: Unskalierter Wertebereich, rechte Spalte: Skalierter Wertebereich.

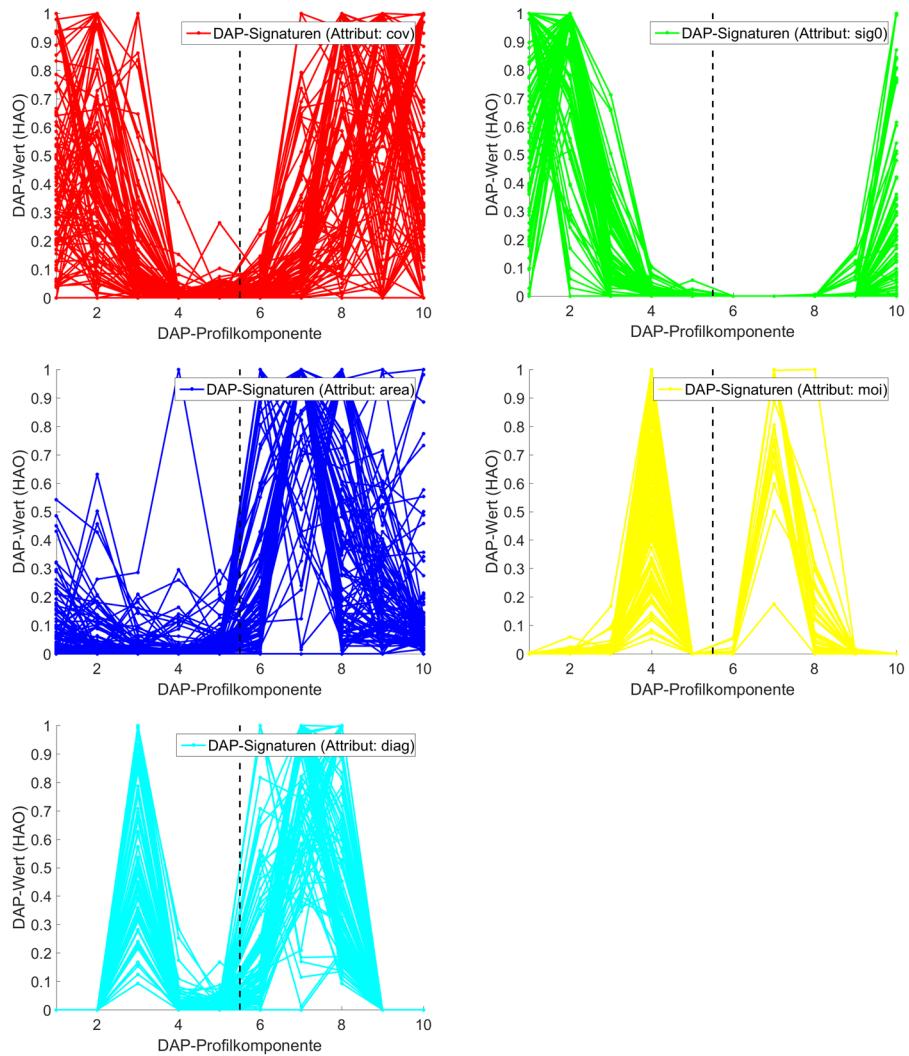


Abbildung A.7.: Darstellung der DAP-Signaturen der ersten 100 HAO mit den verschiedenen Attributen. Abszisse: DAP-Profilkomponente, Ordinate: DAP-Wert (HAO).

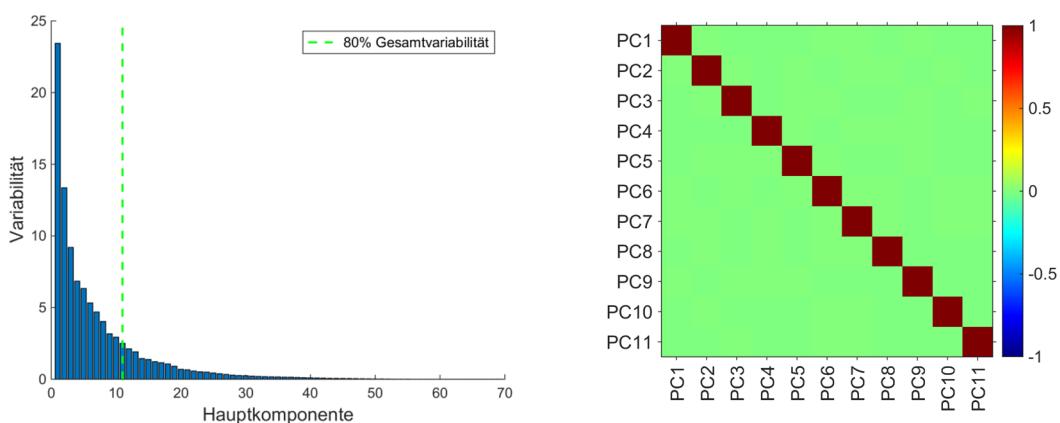


Abbildung A.8.: Links: Aus der PCA resultierendes Eigenspektrum für die vorliegende Merkmalsmatrix. Rechts: Korrelationsmatrix der aus der PCA resultierenden 11 Hauptkomponenten (beides auf Basis des Datensatzes „Greding“).

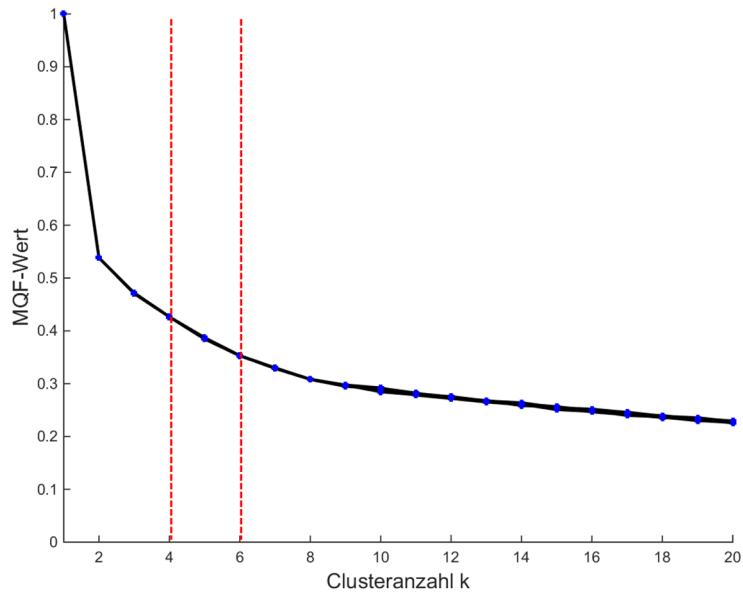


Abbildung A.9.: Visualisierte Indexwerte aus der *Ellbogenmethode* (Datensatz „Greding“). Die vertikal verlaufenden, rot gestrichelten Linien kennzeichnen die Position der optimalen Clusteranzahl.

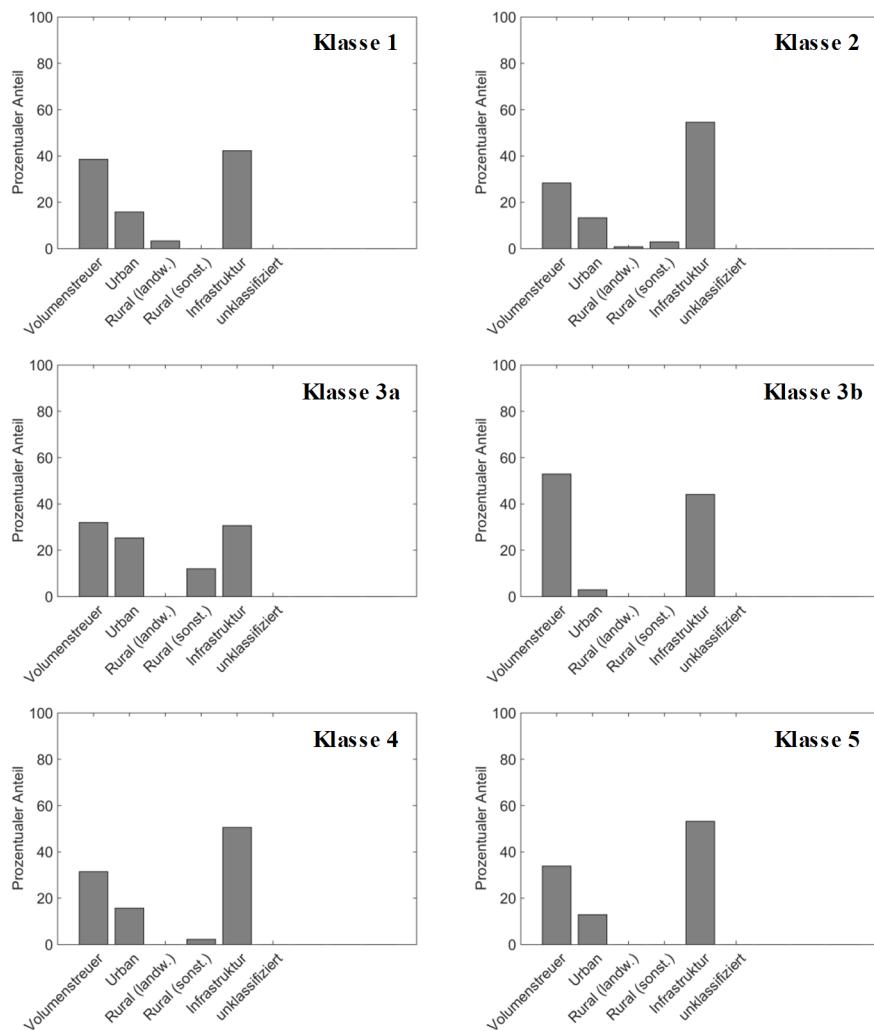


Abbildung A.10.: Zu finalen Klassen gehörende HAO und deren prozentuale Zugehörigkeiten zu Kontextklassen (Datensatz „Greding“).

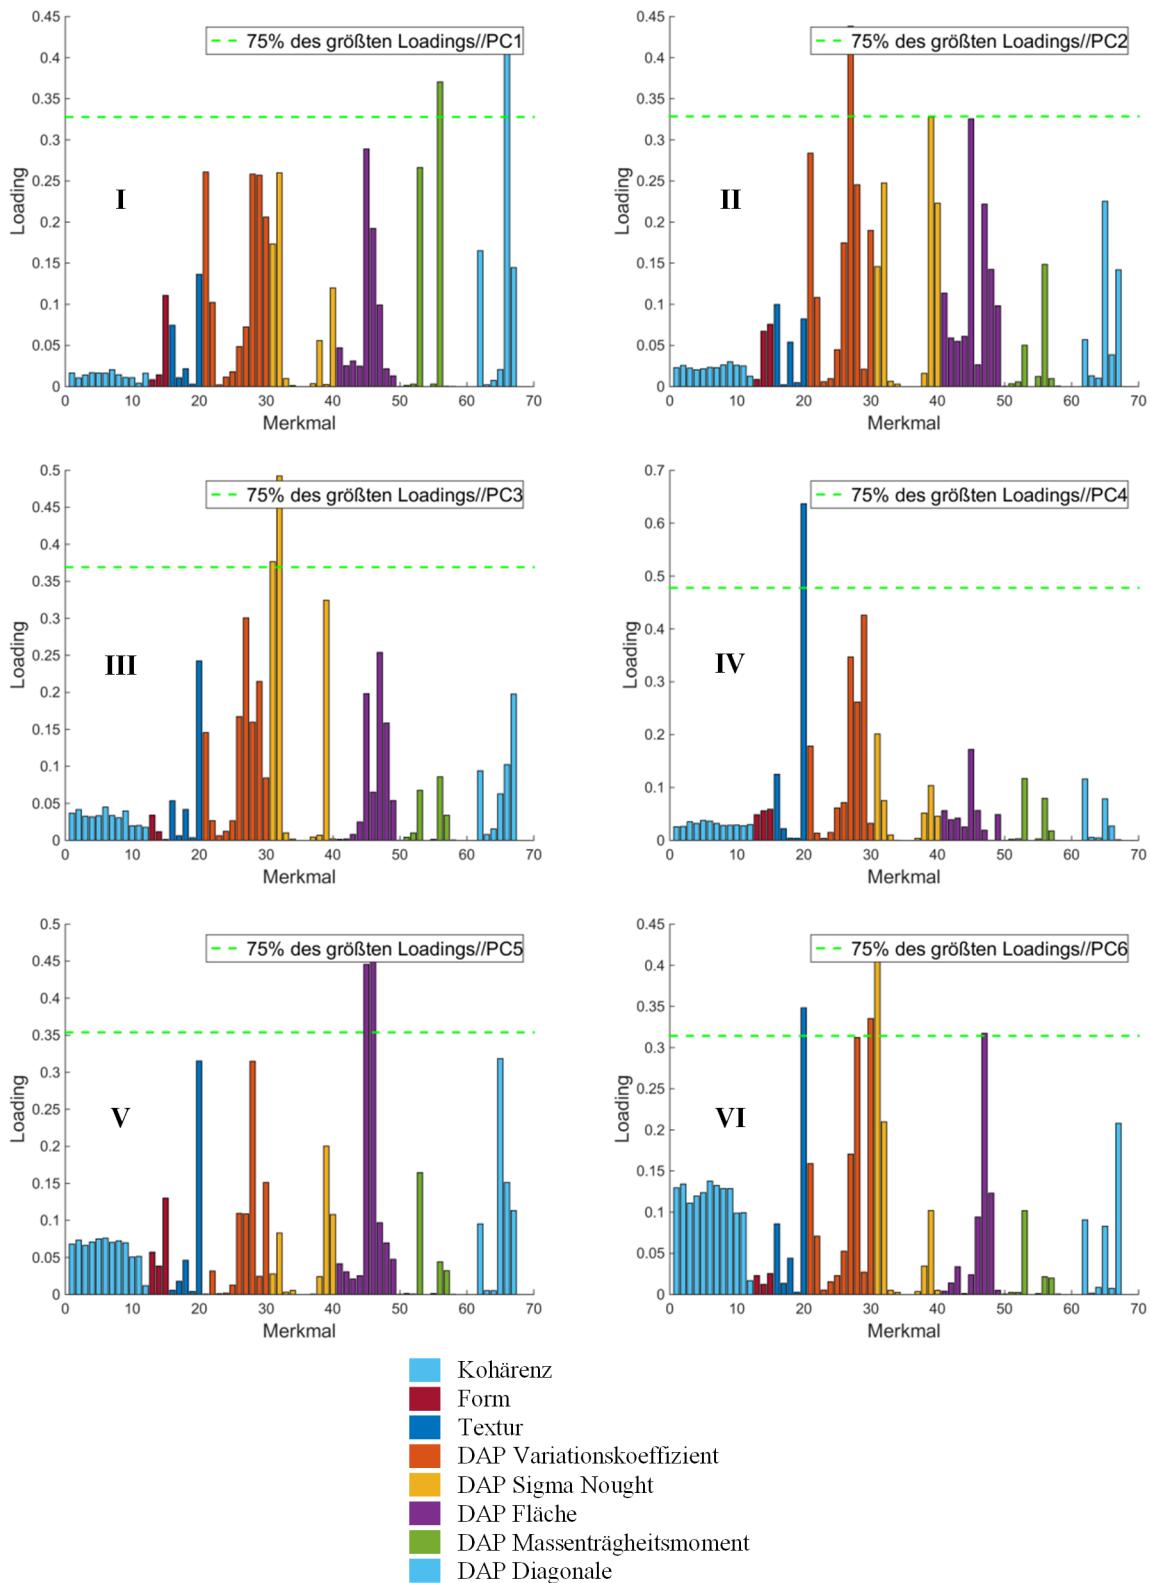


Abbildung A.11.: Teil 1 der Loadings der Eingangsmerkmale an den resultierenden Hauptkomponenten (I bis VI) (Datensatz „Greding“).

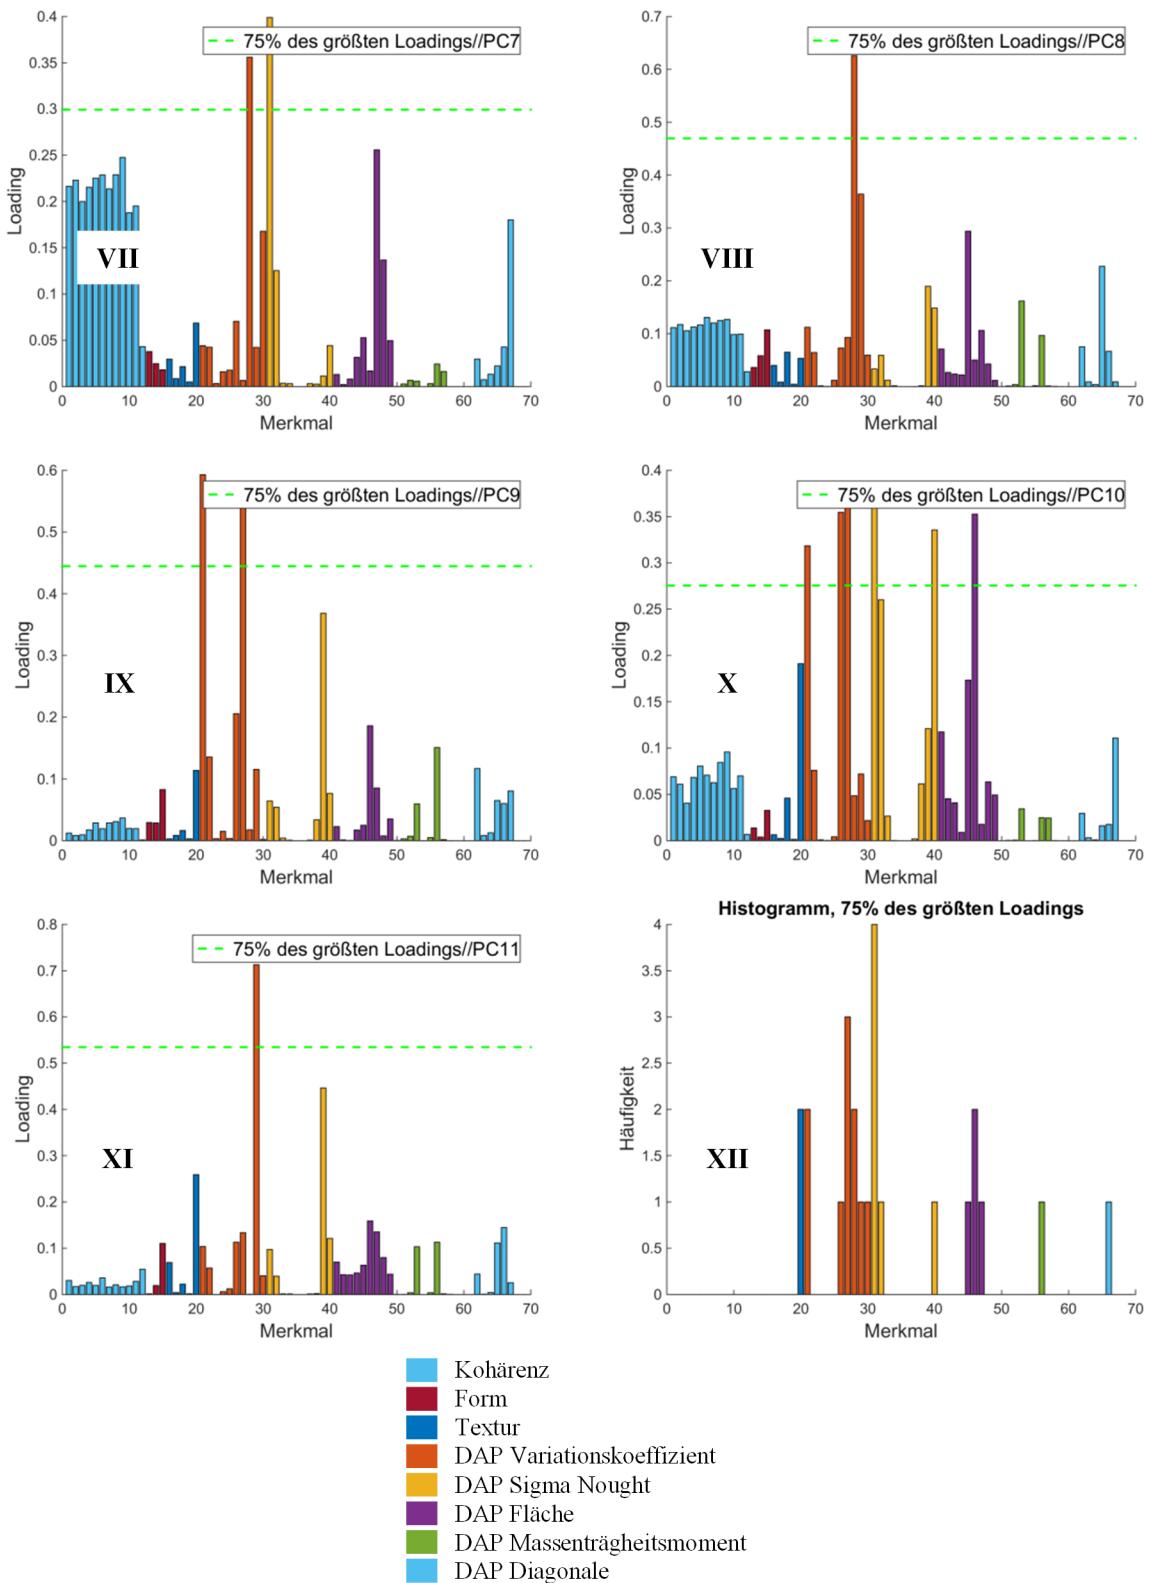


Abbildung A.12.: Teil 2 der *Loadings* der Eingangsmerkmale an den resultierenden Hauptkomponenten (VII bis XI), sowie Histogramm der über alle PC am maßgeblichsten beteiligten Eingangsmerkmale (XII) (Datensatz „Greding“).

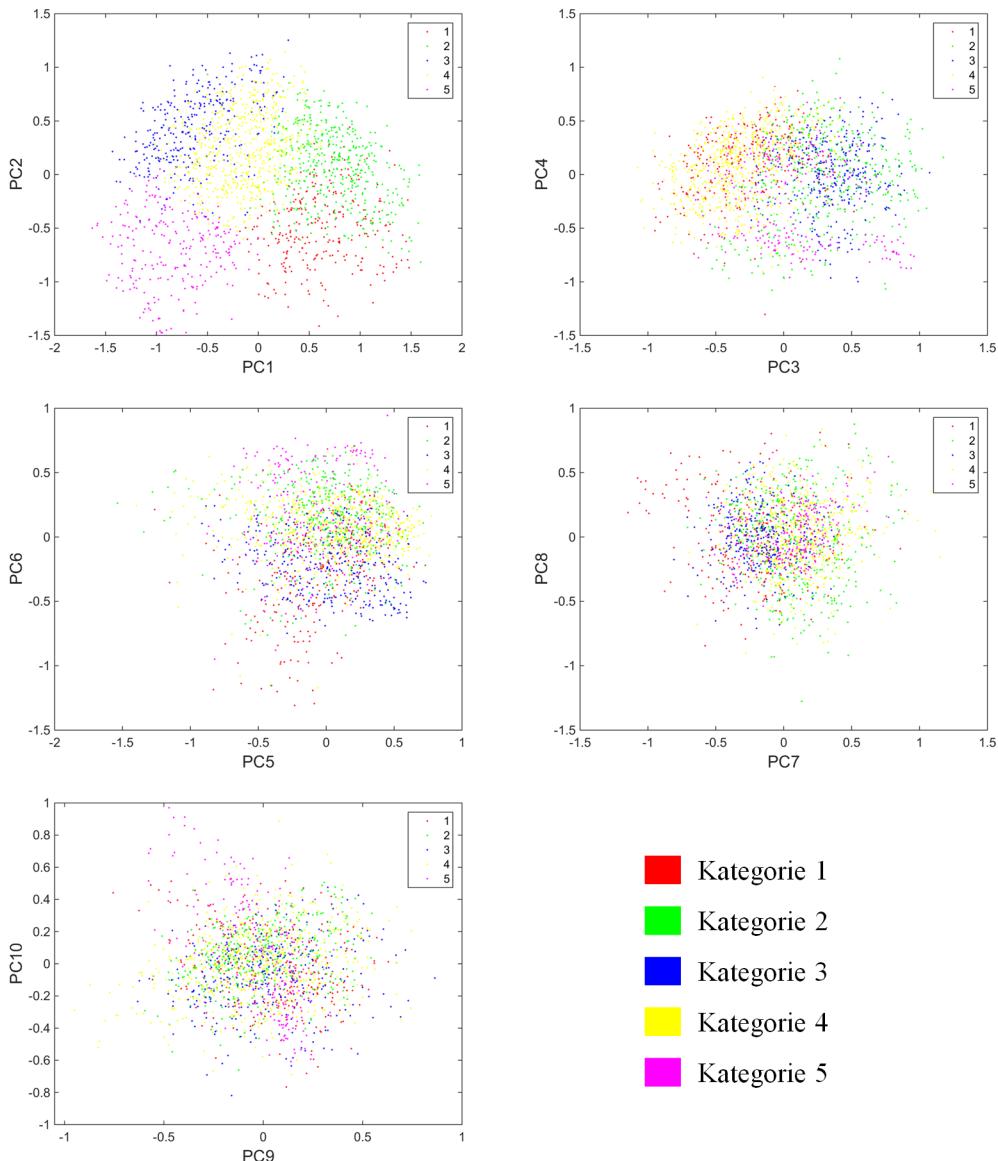


Abbildung A.13.: Darstellung des Kategorisierungsresultats anhand zweidimensionaler Streudiagramme über alle Hauptkomponenten (Datensatz „Greding“). Jeder farbkodierte Punkt im Merkmalsraum kennzeichnet ein HAO.

Finale Klasse	Anzahl HAO	Räumlich ausgedehnt	Räumlich begrenzt
1	272	187 (68,8%)	85 (31,3%)
2	240	187 (77,9%)	53 (22,1%)
3a	75	56 (74,7%)	19 (25,3%)
3b	34	26 (76,5%)	8 (23,5%)
4	89	82 (92,1%)	7 (7,9%)
5	62	51 (82,3%)	11 (17,7%)

Tabelle A.4.: Resultate der Analyse zur räumlichen Ausdehnung beziehungsweise Begrenztheit von Hochaktivitätsobjekten (Datensatz „Greding“). Die Nummerierung der finalen Klasse folgt der Darstellung in Abbildung A.16.

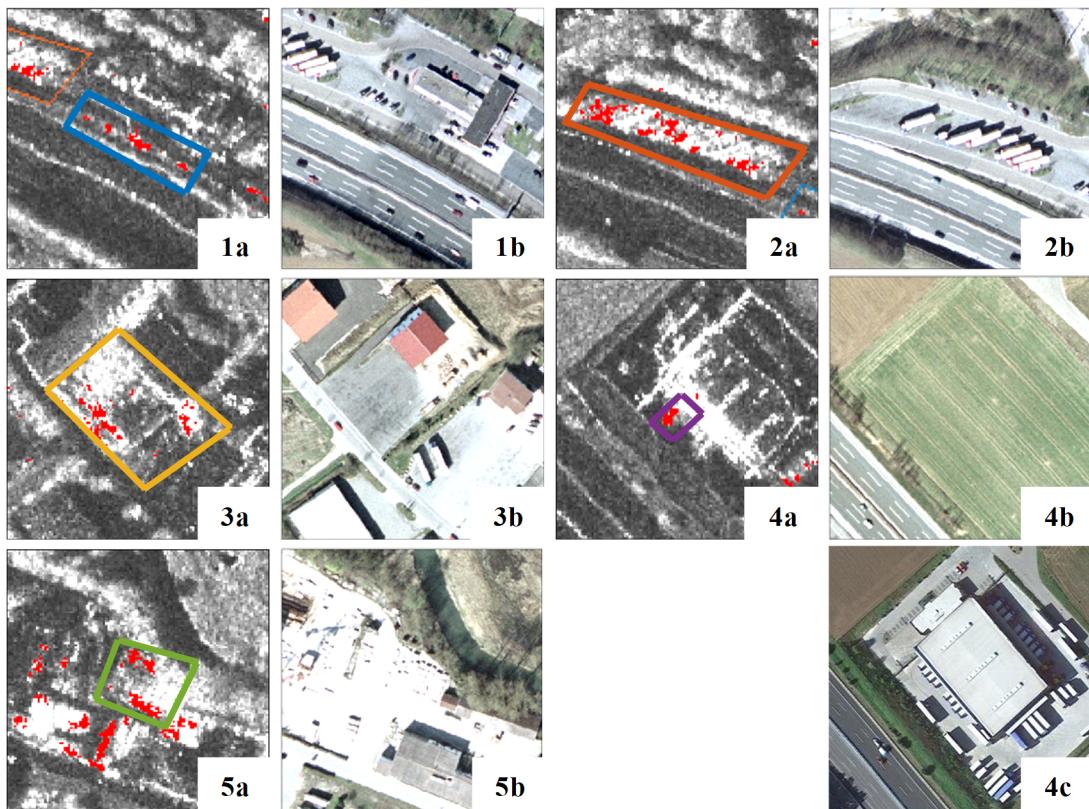


Abbildung A.14.: Initiale Klassen Datensatz „Greding“. Linke Spalte: Selektierter Klassenbereich in Örtlichkeit (mittleres Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln (a) und entsprechender Bereich im RMK-Luftbildmosaik (b)). 1a, 1b: PKW-Parkplatz; 2a, 2b: LKW-Parkplatz; 3a, 3b: Baustelle; 4a, 4b: Be- / Entladestelle; 5a, 5b: Sammelstelle. An der Klasse Be- / Entladestelle zeigt sich die nicht aktuelle, optische Referenzdatengrundlage. Das inzwischen dort vorhandene Industriegebiet ist im Luftbildmosaik aus dem Jahr 2002 noch nicht enthalten. Die Informationen über dieses Gebiet wurden deshalb aus *Google Earth* abgeleitet (4c).

Orientierung	Zugehörigkeitsgrad			
	Wert Pixel 1	Wert Pixel 2	Wert Pixel 3	...
1	Wert Pixel 1	Wert Pixel 2	Wert Pixel 3	...
2	Wert Pixel 1	Wert Pixel 2	Wert Pixel 3	...
3	Wert Pixel 1	Wert Pixel 2	Wert Pixel 3	...
4	...	...	...	...
5	...	...	...	...
6	...	...	...	...
7	...	...	...	...
8	...	...	...	...

Distanz in Pixel →

Tabelle A.5.: Vorschlag zur Berechnung eines kontinuierlichen Kontextmerkmals (Abspeicherung der Werte für jede ein HAO umgebende Kontextklasse). Die Distanz vom HAO-Schwerpunkt aus in Richtung der acht Orientierungen ist frei wählbar.

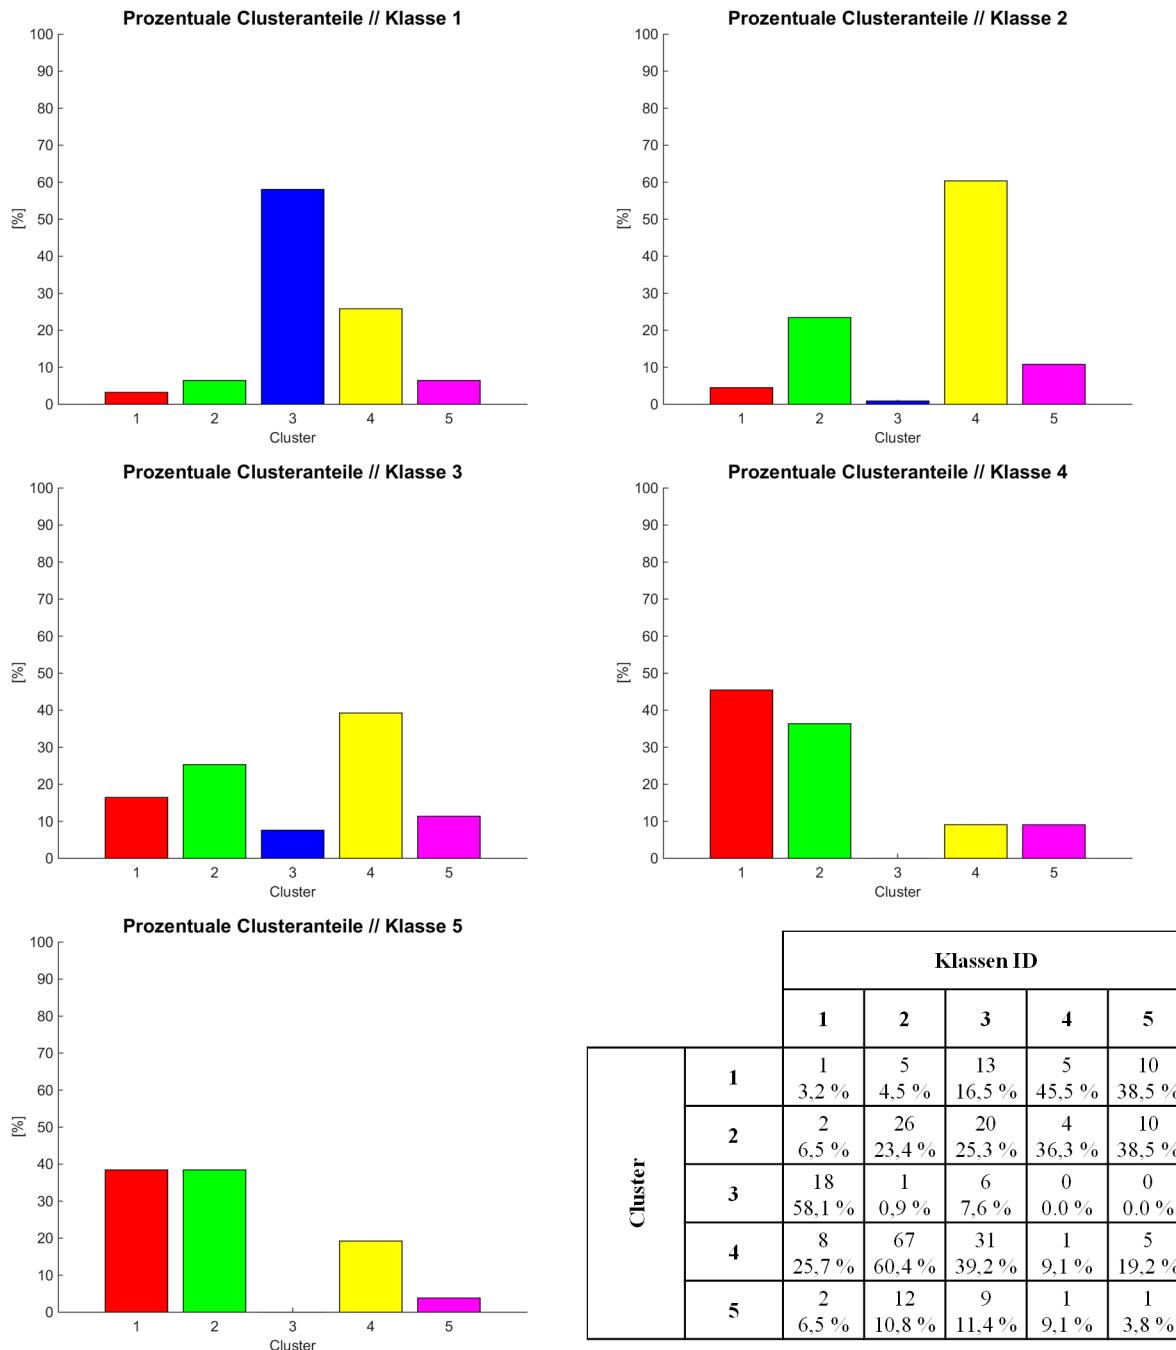


Abbildung A.15.: Ergebnisse der Vorprojektion (Datensatz „Greding“). Die Tabelle enthält die empirischen Werte (Anzahl der in der Klasse enthaltenen HAO und prozentualer Clusterzugehörigkeitsanteil) zu den visualisierten Clusterhistogrammen. Klasse 1: PKW-Parkplatz; Klasse 2: LKW-Parkplatz; Klasse 3: Baustelle; Klasse 4: Be- / Entladestelle; Klasse 5: Sammelstelle

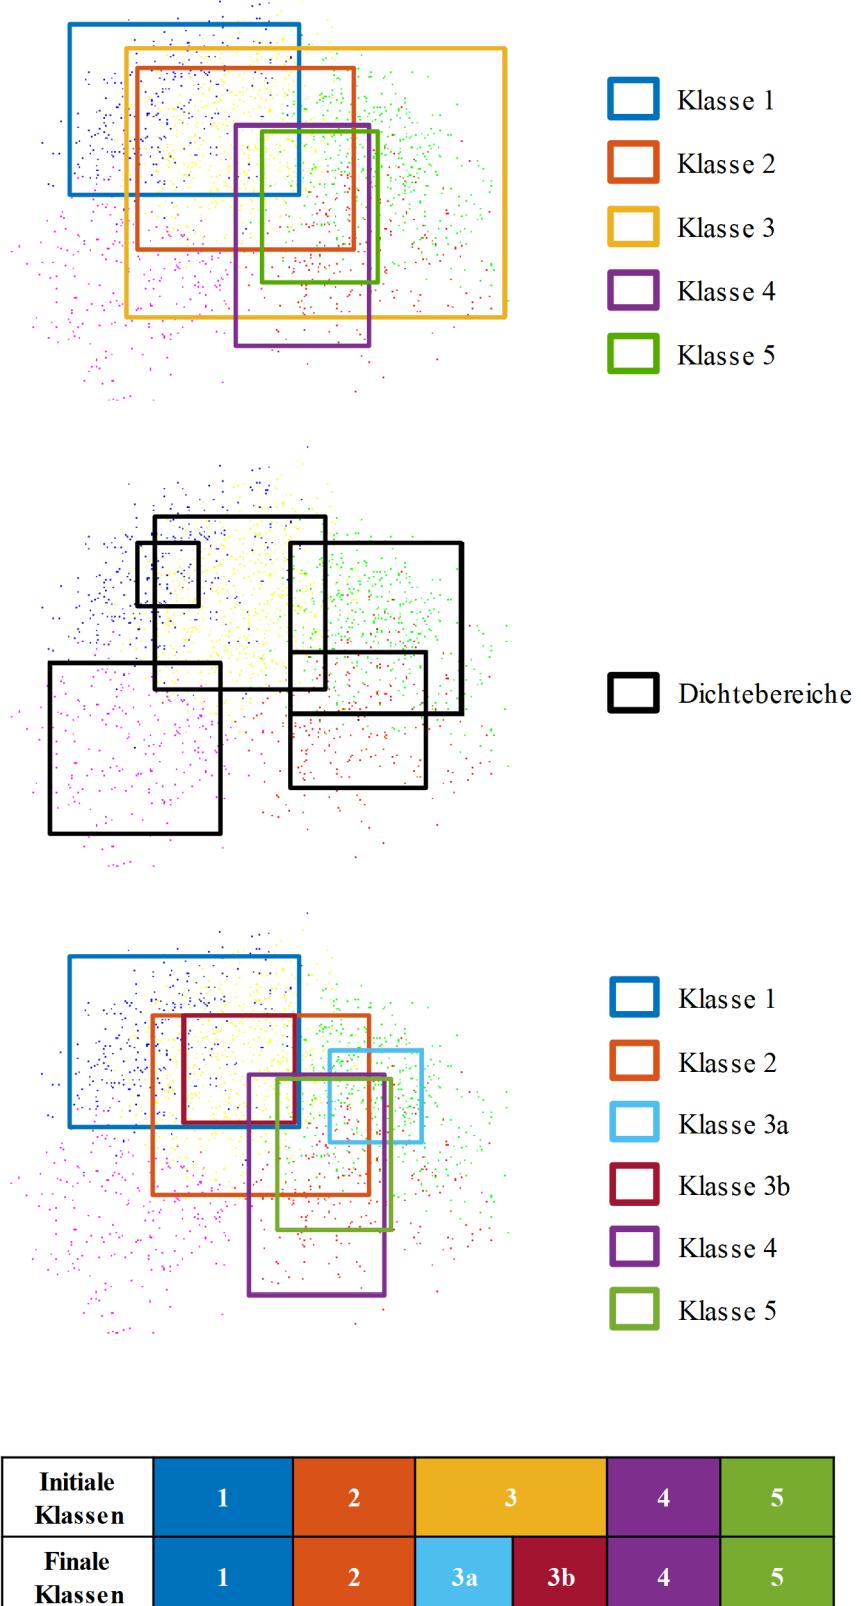


Abbildung A.16.: Oben: Zweidimensionales Raster mit Kategorisierungsresultat und initialen Klassenregionen; Mitte: Zweidimensionales Raster mit Kategorisierungsresultat und Dichtebereichen; unten: Zweidimensionales Raster mit Kategorisierungsresultat und finalen Klassenregionen (Datensatz „Greding“). Darunter: Tabelle mit visualisiertem Optimierungsverlauf und den jeweilig vorgegebenen, beziehungsweise resultierenden Farbkodierungen der Klassen.

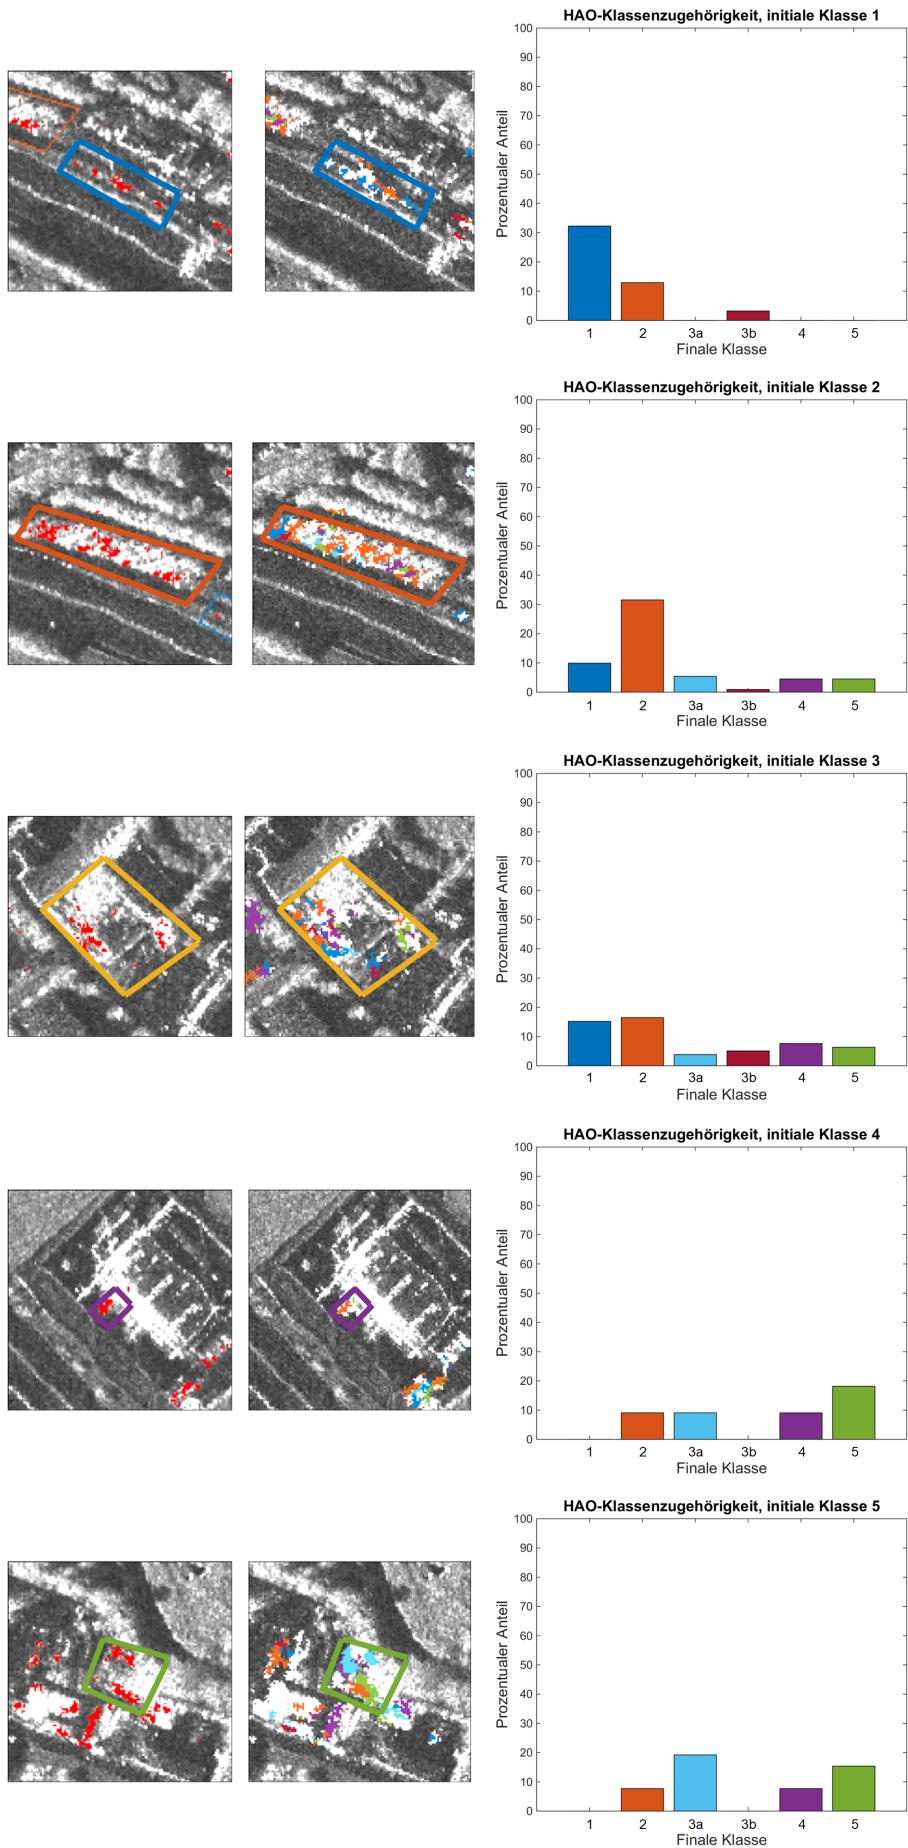


Abbildung A.17.: Visualisierte Resultate der Klassifikation in den initial selektierten Hochaktivitätsgebieten mit der Fuzzy-Zugehörigkeitsschwelle  $z = 50$  (Datensatz „Greding“). Die Farbgebung der Klassifikation orientiert sich an der in Abbildung A.16 dargestellten finalen Version des Katalogs. Weiß: Unklassifizierte HAO.

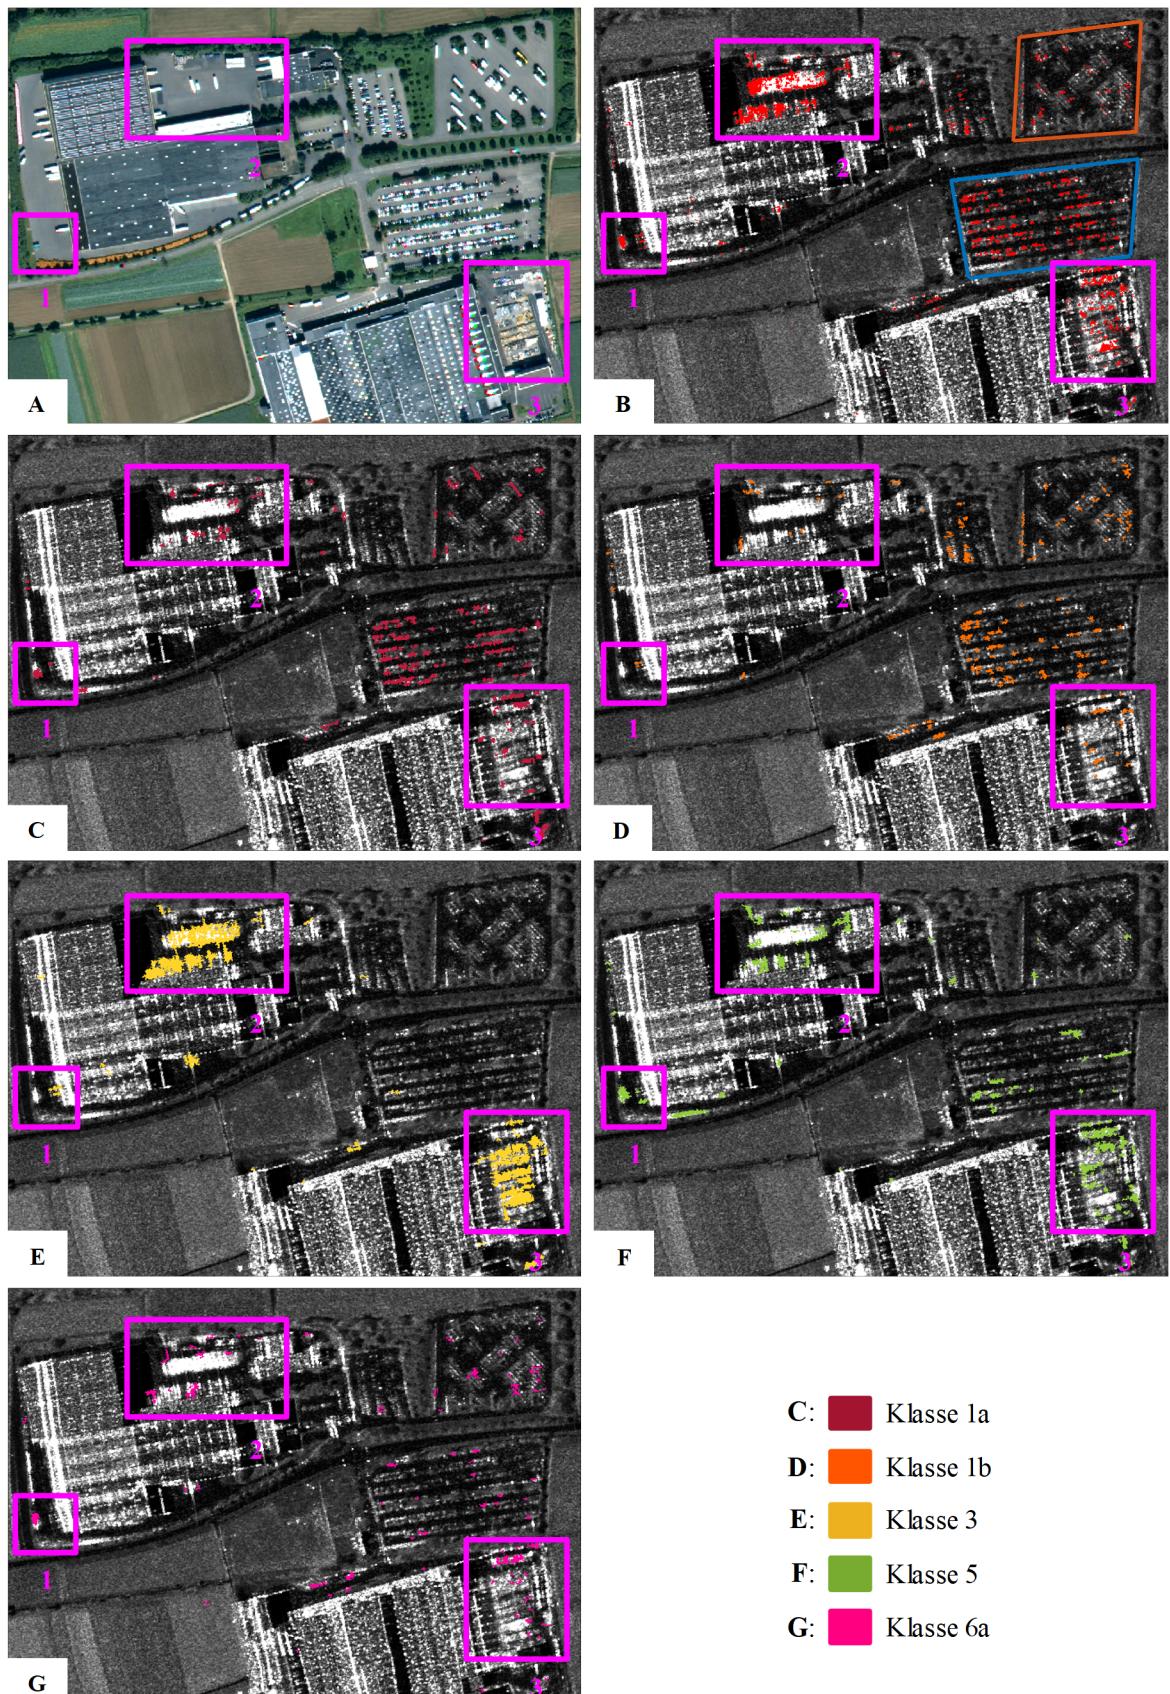


Abbildung A.18.: Ortssemantische Analyse der Klassifikationsresultate (*Fuzzy-Zugehörigkeitsschwelle  $z = 50$* , Datensatz „Stuttgart Flughafen“). A: WV-2-Bild; B: Gefilterte Aktivitätskarte mit initialen Klassenregionen 1 und 2 (orange-farbenes und blaues Polygon) als Überlagerung auf dem mittleren Amplitudenbild der Zeitreihe; C bis G: Klassifikationsresultate unter Nutzung der finalen Klassen 1a, 1b, 3, 5 und 6a. Magenta-farbene markierte Interessenregionen: Containerbereich (1), Be-/Entladestelle und Sammelstelle (2, 3).

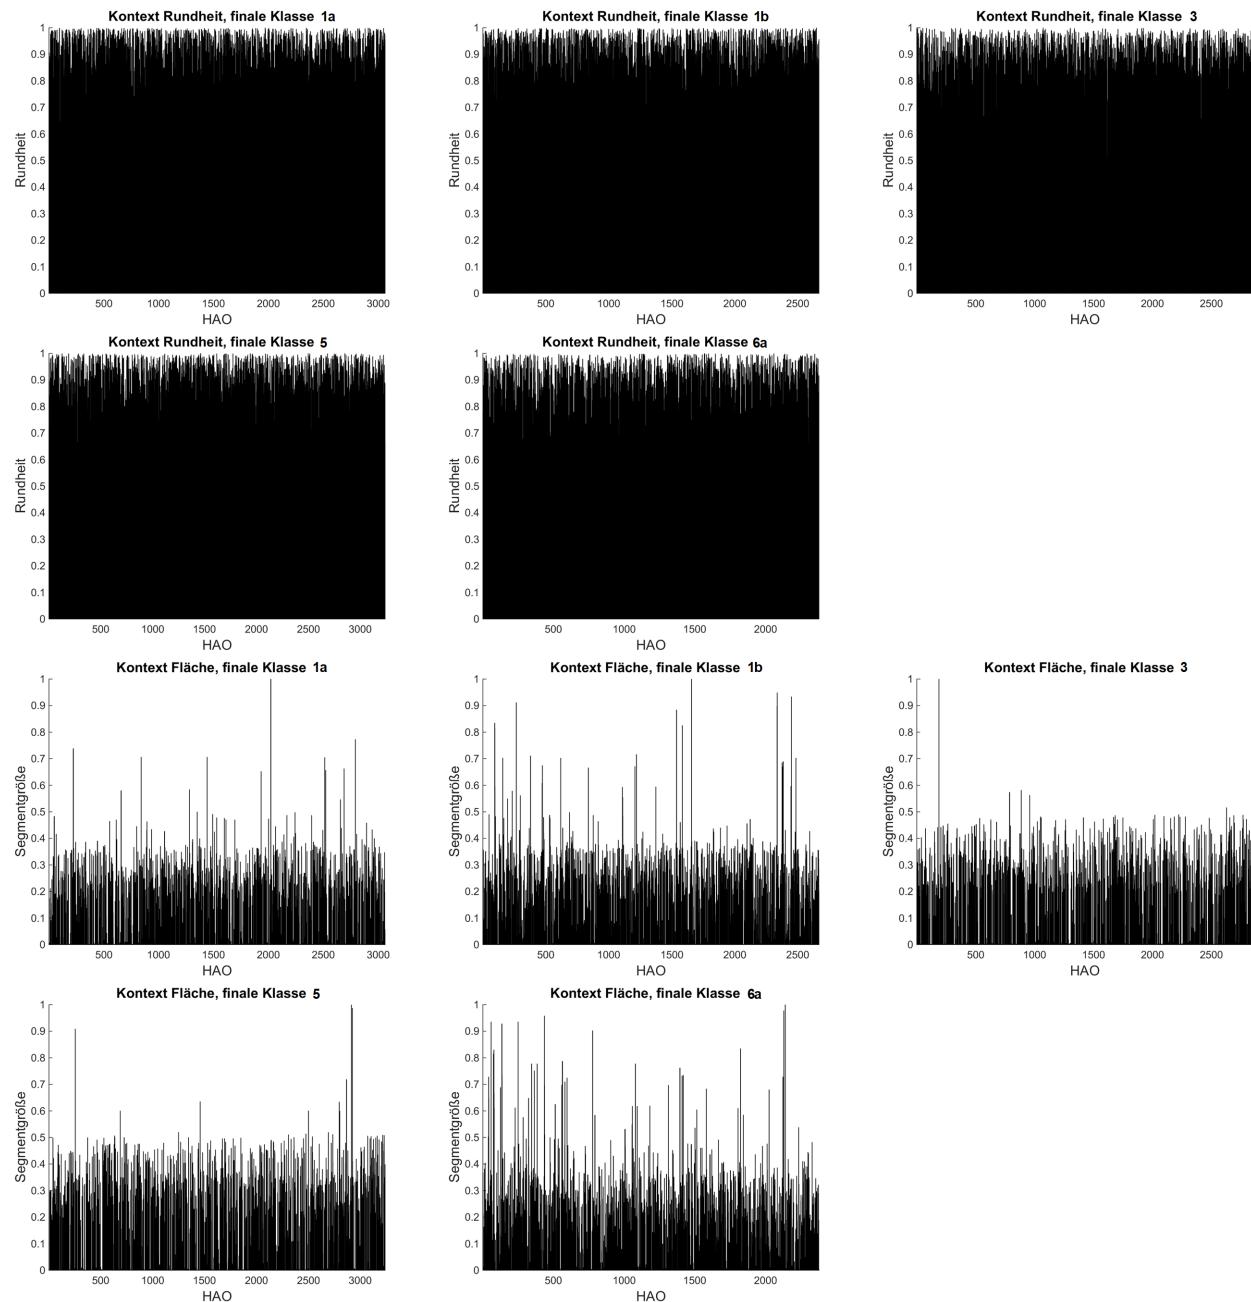


Abbildung A.19.: Übersicht über die Formparameter, extrahiert für jedes ein HAO umgebendes Segment (Datensatz „Stuttgart Flughafen“), Teil 1.

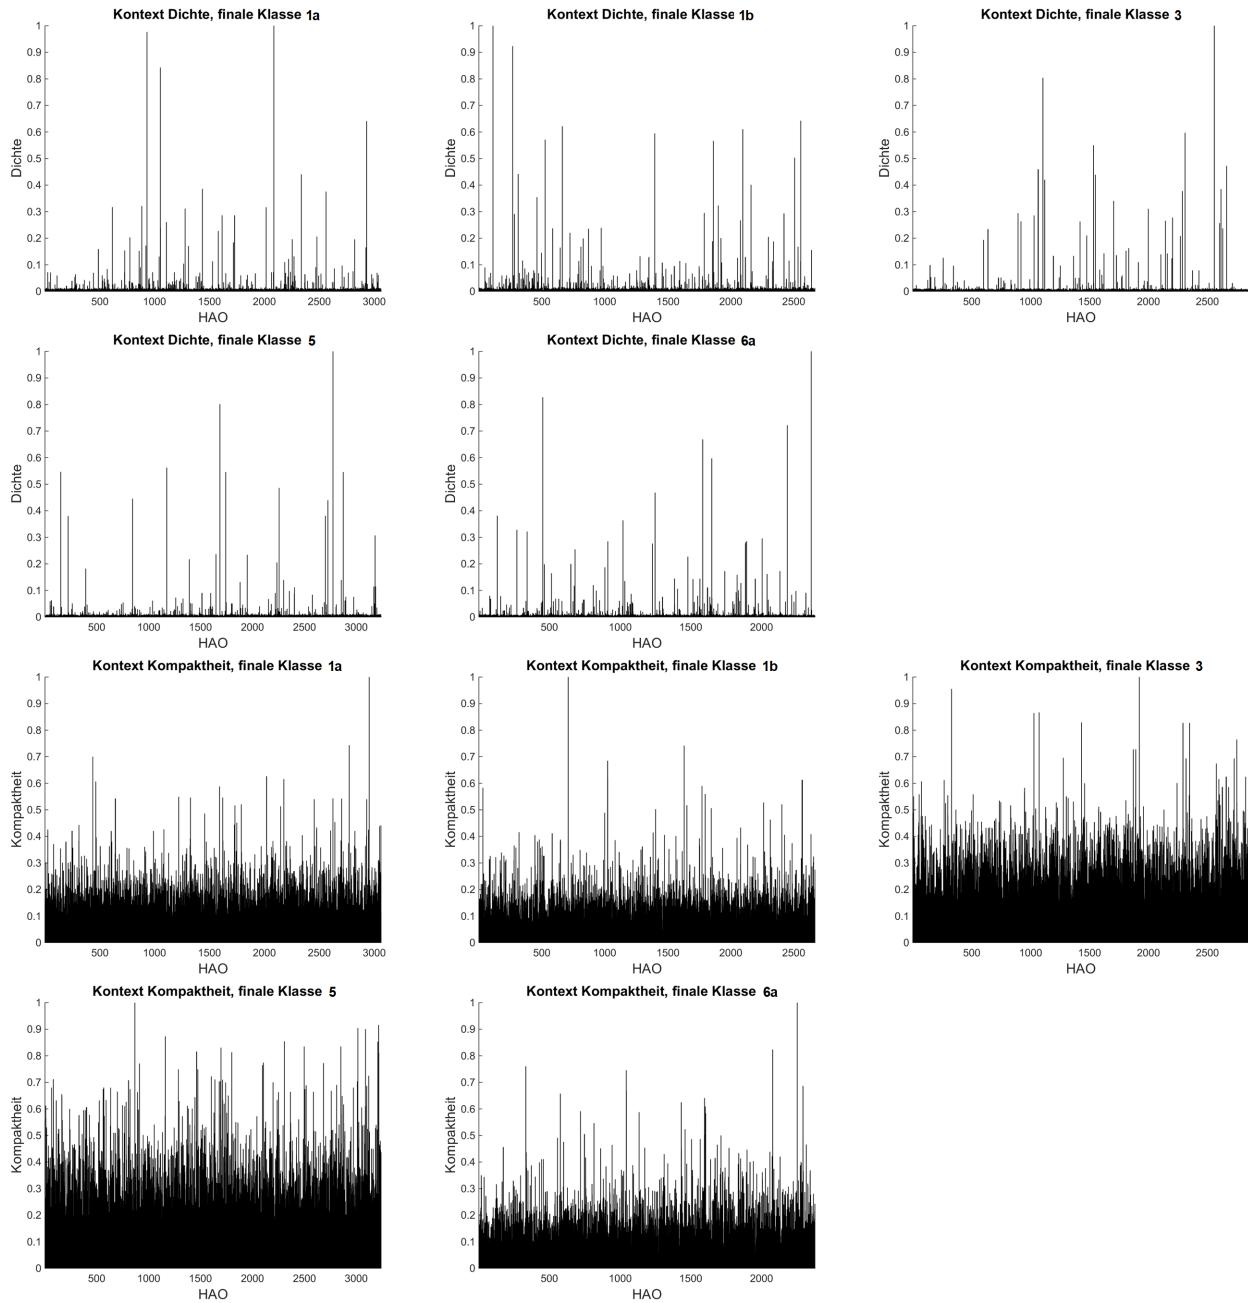


Abbildung A.20.: Übersicht über die Formparameter, extrahiert für jedes ein HAO umgebendes Segment (Datensatz „Stuttgart Flughafen“), Teil 2.

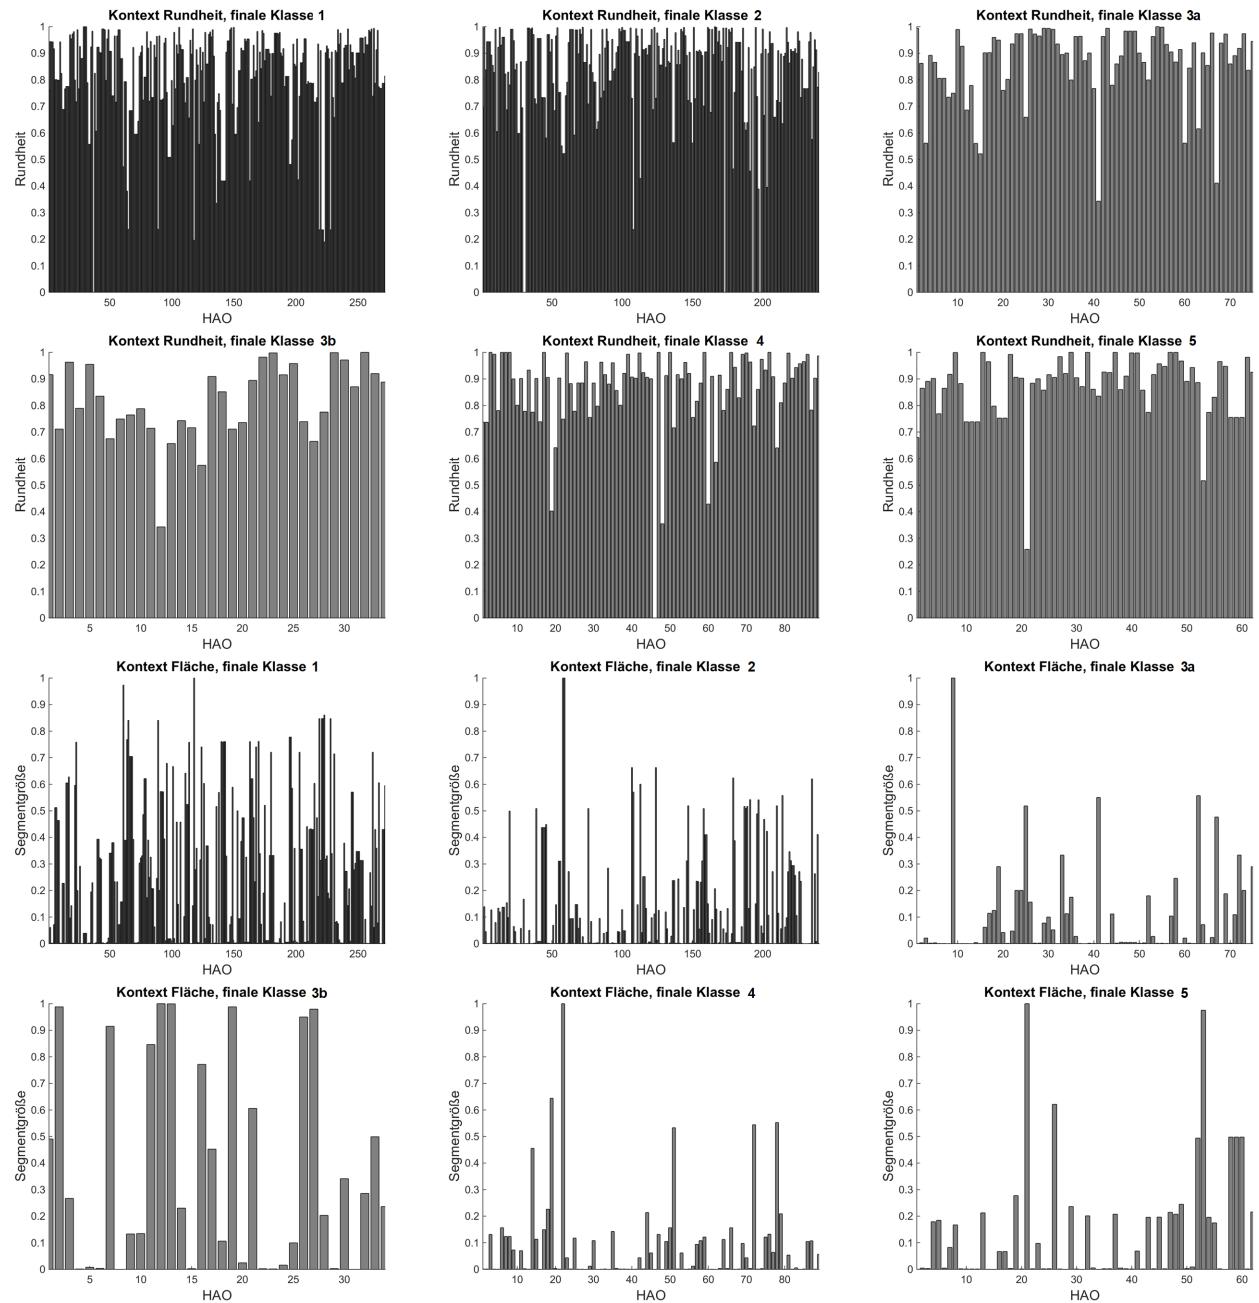


Abbildung A.21.: Übersicht über die Formparameter, extrahiert für jedes ein HAO umgebendes Segment (Datensatz „Greding“, Teil 1).

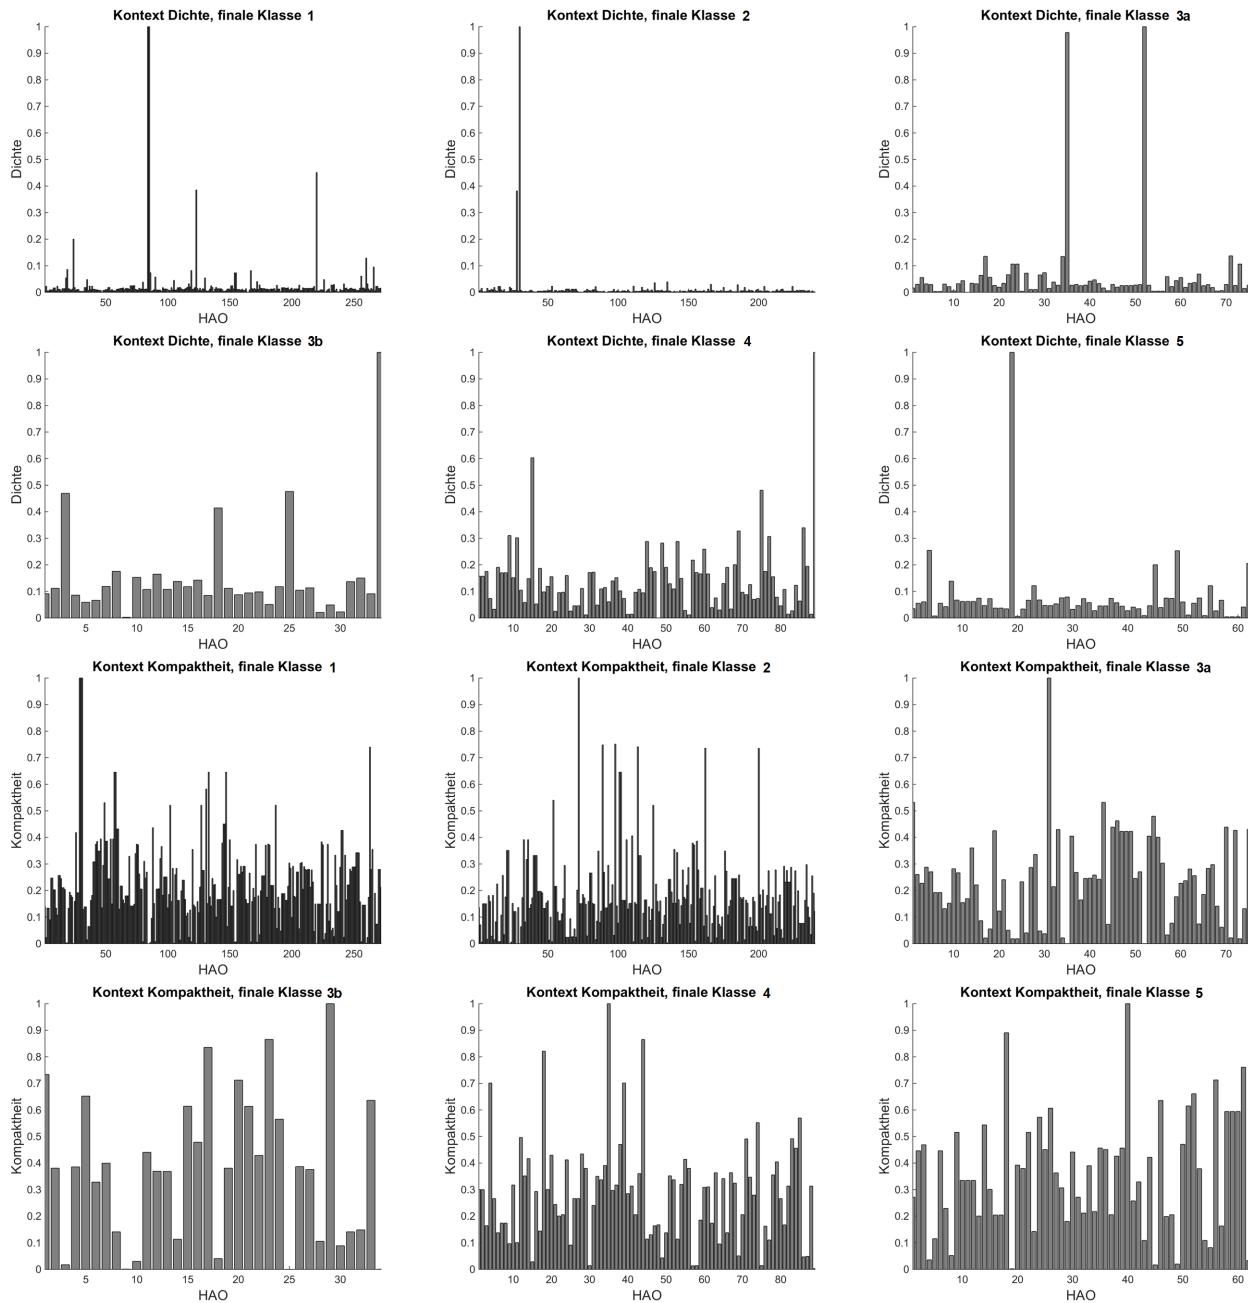


Abbildung A.22.: Übersicht über die Formparameter, extrahiert für jedes ein HAO umgebendes Segment (Datensatz „Greding“), Teil 2.

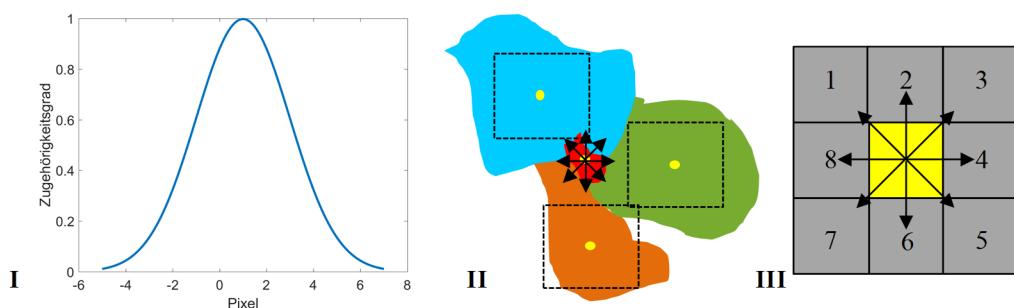


Abbildung A.23.: Konzept zur Berechnung eines kontinuierlichen Kontextmerkmals. I: Fuzzy-Zugehörigkeitsfunktion; II: Drei Segmente (blau, grün, orange) mit jeweils unterschiedlicher Kontextklasse in Nachbarschaft zu HAO (rot). Gelb: Schwerpunkte. Schwarz gestrichelt: Fuzzy-Zugehörigkeitsbereiche; III: 8er-Nachbarschaft eines HAO-Schwerpunkts.

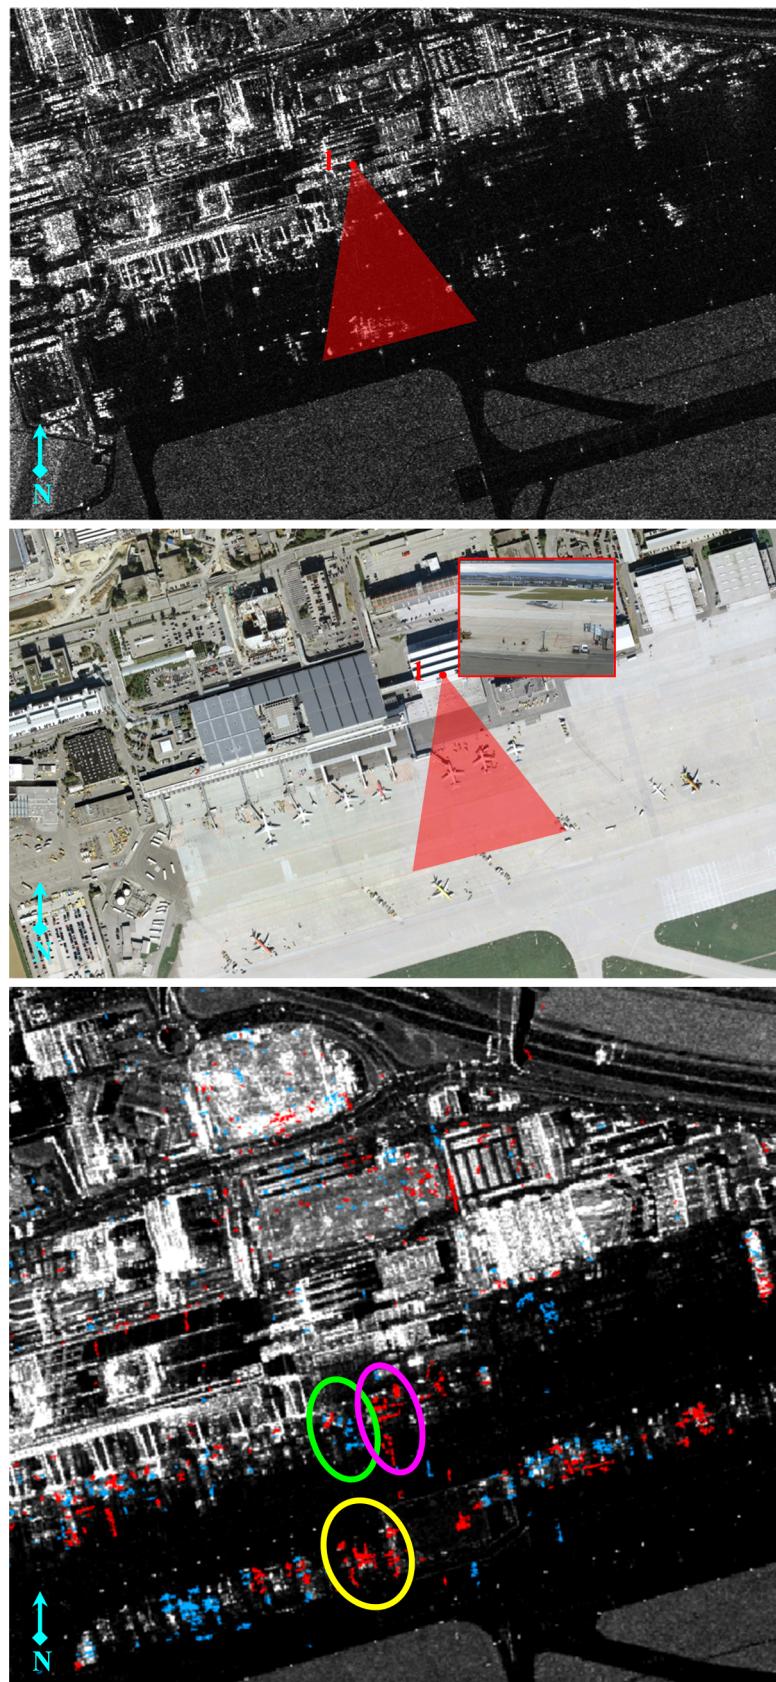


Abbildung A.24.: Standpunkt (roter Punkt) und ungefähres Sichtfeld (rotes Dreieck) einer Webcam (Datensatz „Stuttgart Flughafen“). Ausschnitte aus der mittleren Amplitude der Zeitreihe (oben), aus dem pangeschräferten WV-2-Datensatz (Mitte) und aus einer farbkodierten Änderungskarte (unten). Mitte: Das kleine, rot umrandete Bild zeigt ein Beispielbild der Webcam. Unten: Der grün umrandete Bereich bezeichnet eine hinzukommende Änderung, der magenta-farbene Bereich eine verschwindende Änderung und der gelbe Bereich eine weitere verschwindende Änderung.

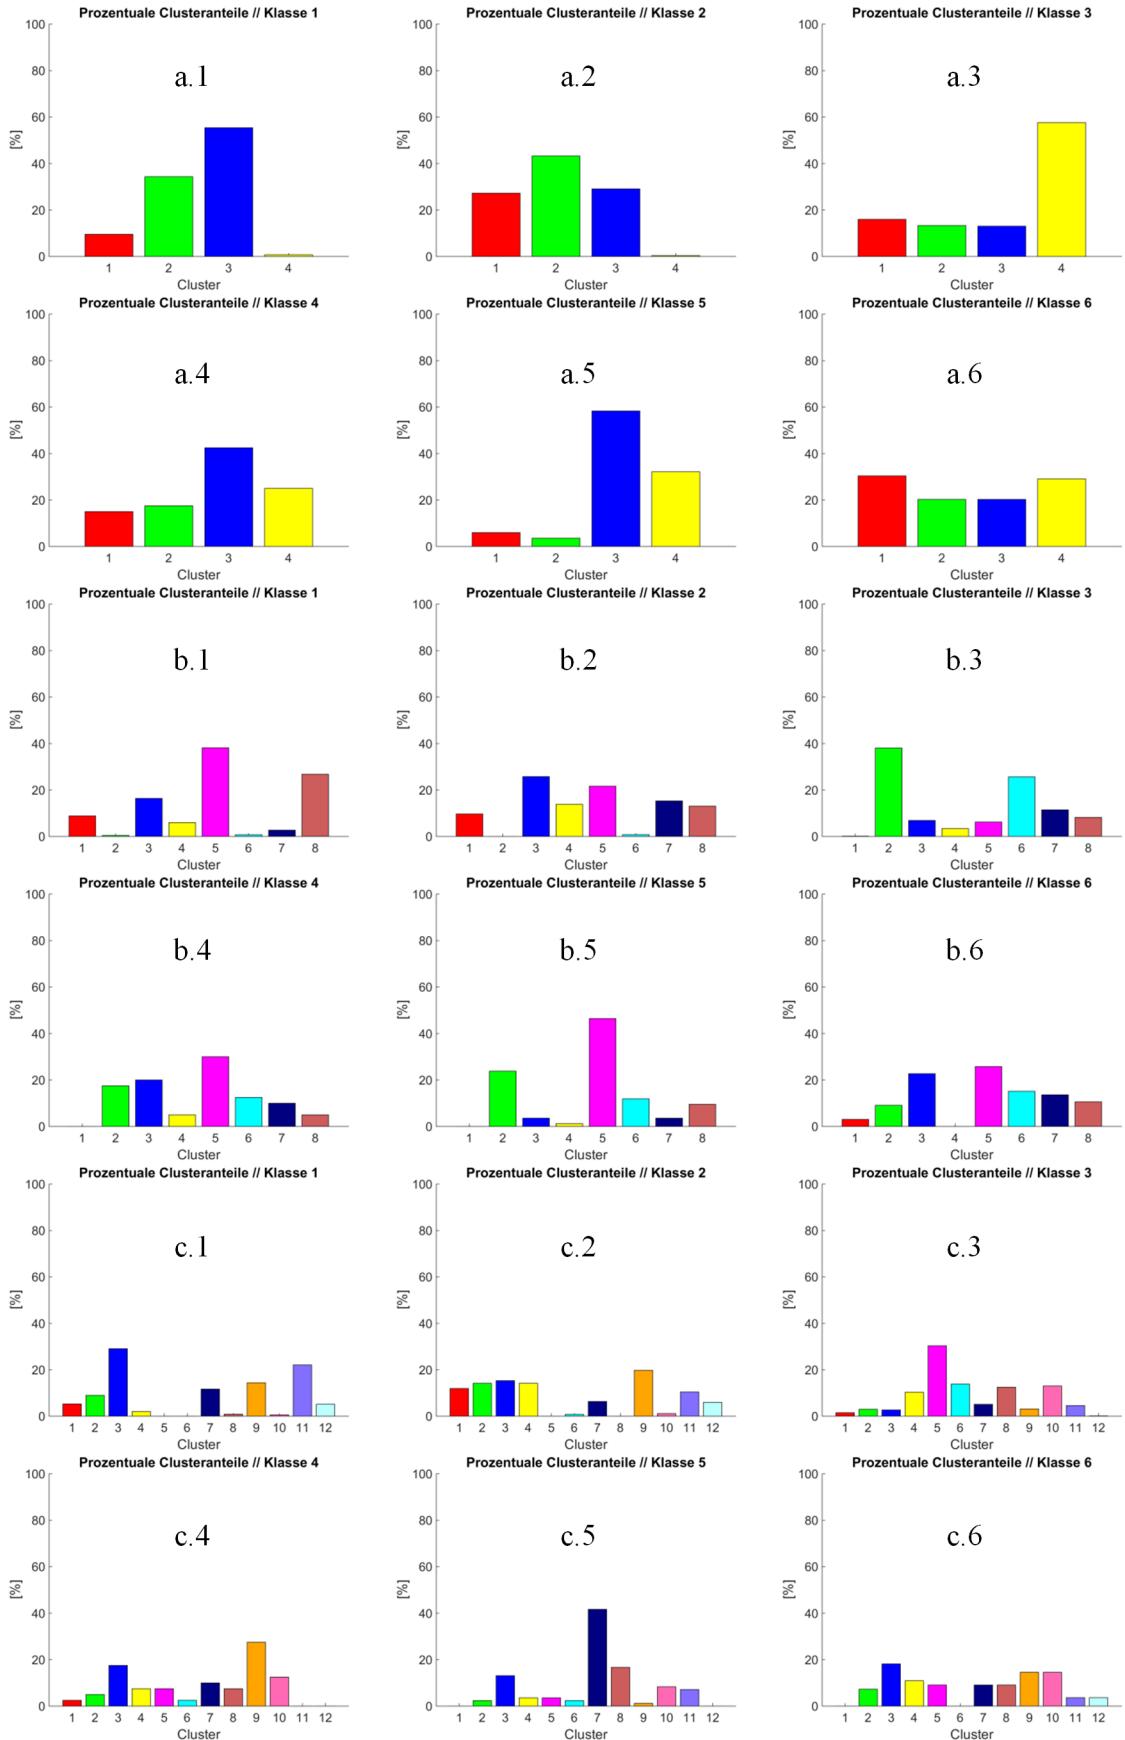


Abbildung A.25.: Clusterhistogramme aus der Vorprojektion für drei verschiedene Kategorisierungsresultate (Datensatz „Stuttgart Flughafen“). a: Clusterhistogramme der initialen Klassen 1 bis 6 für  $k = 4$  (siehe auch Abbildung 6.10); b: Clusterhistogramme der initialen Klassen 1 bis 6 für  $k = 8$ ; c: Clusterhistogramme der initialen Klassen 1 bis 6 für  $k = 12$ .

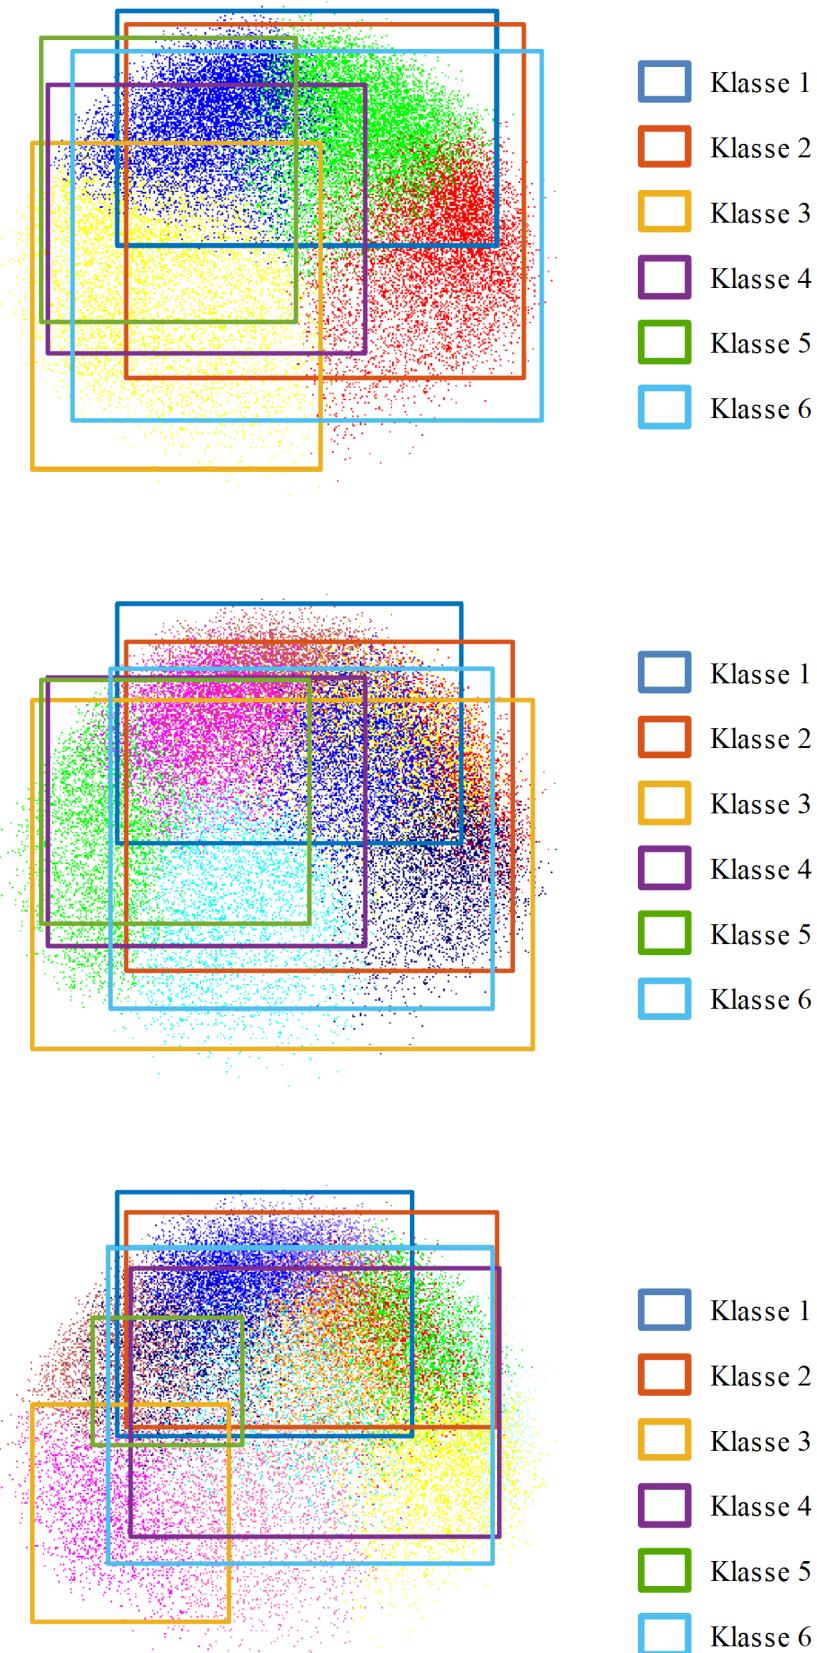


Abbildung A.26.: Visualisierung des initialen Klassenkatalogs in zweidimensionalem Merkmalsraum mit  $k = 4$  (oben),  $k = 8$  (Mitte) und  $k = 12$  (unten). Die Farbgebung der einzelnen Cluster orientiert sich an Abbildung A.25.



Abbildung A.27.: Initiale, grob gewählte drei Klassen (Datensatz „Stuttgart Flughafen“). Obere Zeile: Selektierter Klassenbereich in Örtlichkeit (hier: mittleres Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln); untere Zeile: Entsprechender Bereich im pangeschärftem WV-2-Bild. Spalten von links nach rechts: Klassen 1 (*Urban*), 2 (*Industriell*) und 3 (*Flughafen Vorfeld*).

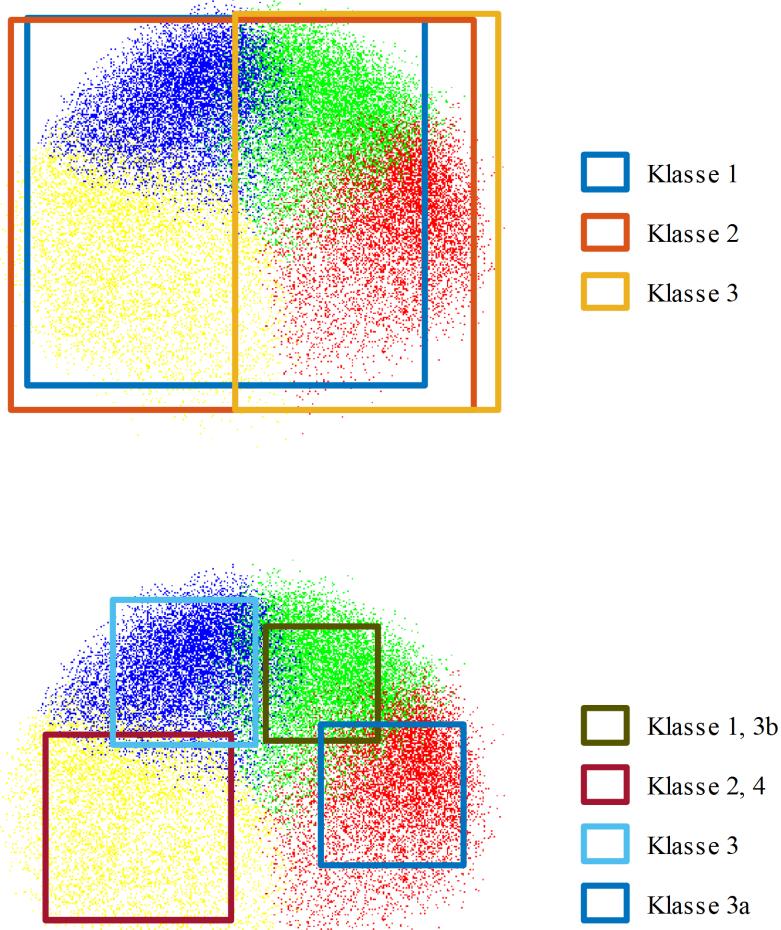


Abbildung A.28.: Oben: Zweidimensionales Raster mit Kategorisierungsresultat und initialen, grob gewählten drei Klassenregionen; unten: Zweidimensionales Raster mit Kategorisierungsresultat und finalen Klassenregionen (Datensatz „Stuttgart Flughafen“).

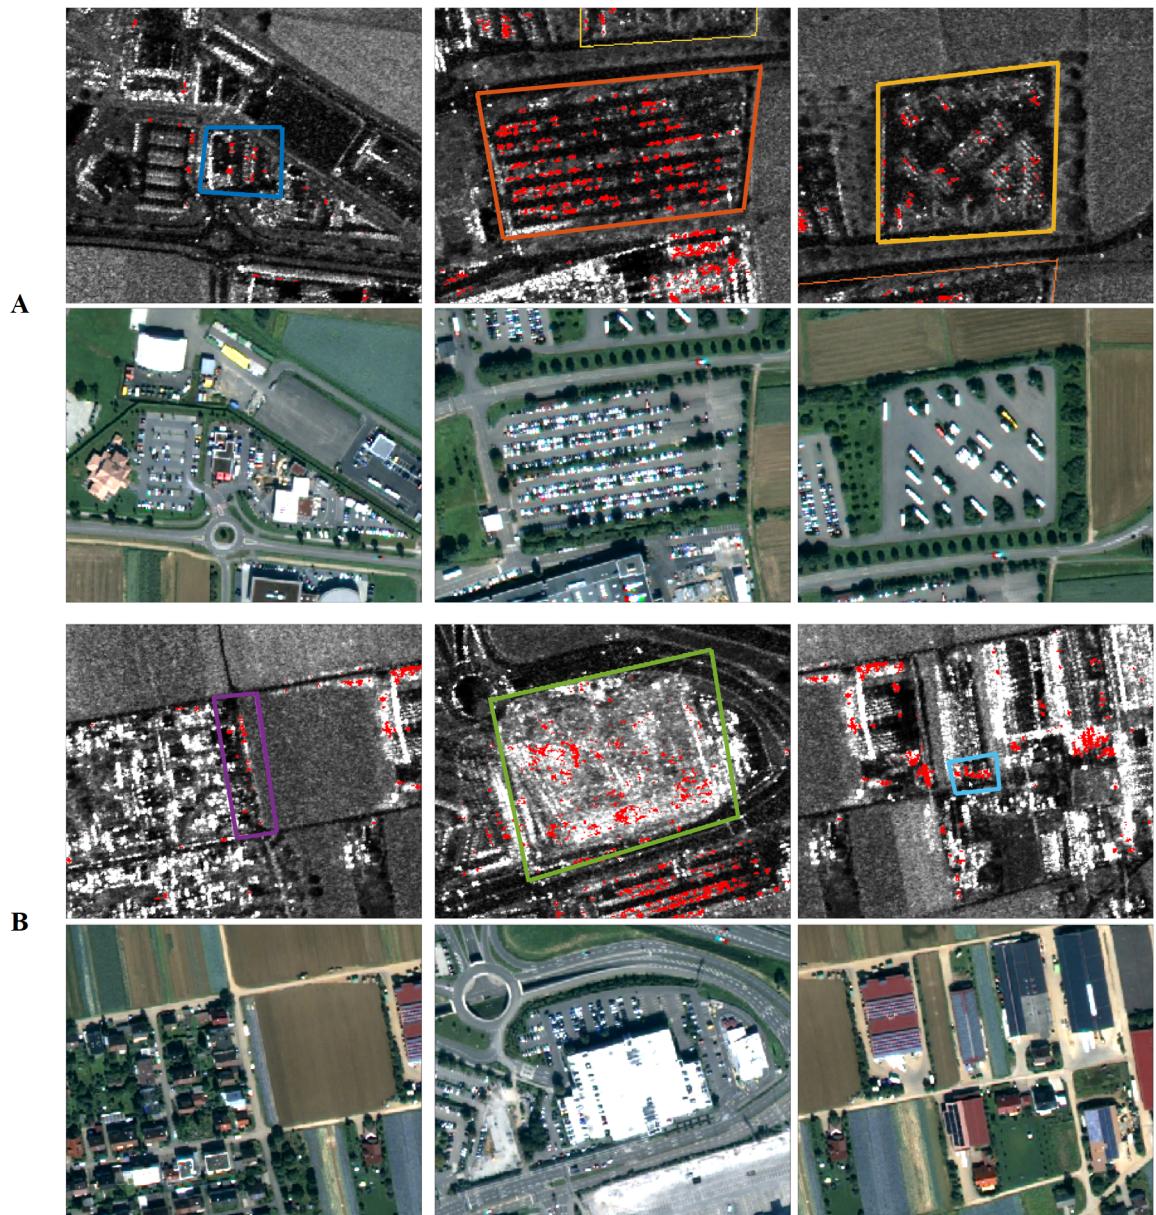


Abbildung A.29.: Initiale, fein gewählte zehn Klassen (Datensatz „Stuttgart Flughafen“), Teil 1. A bis B, jeweils obere Zeile: Selektierter Klassenbereich in Örtlichkeit (hier: mittleres Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln); A bis B, jeweils untere Zeile: Entsprechender Bereich im pangeschärftem WV-2-Bild. A: Spalten von links nach rechts: Klassen 1 (PKW- und LKW-Parkplatz), 2 (PKW-Parkplatz) und 3 (LKW-Parkplatz); B: Spalten von links nach rechts: Klassen 4 (Baustelle urban), 5 (Baustelle suburban) und 6 (Be- / Entladestelle).

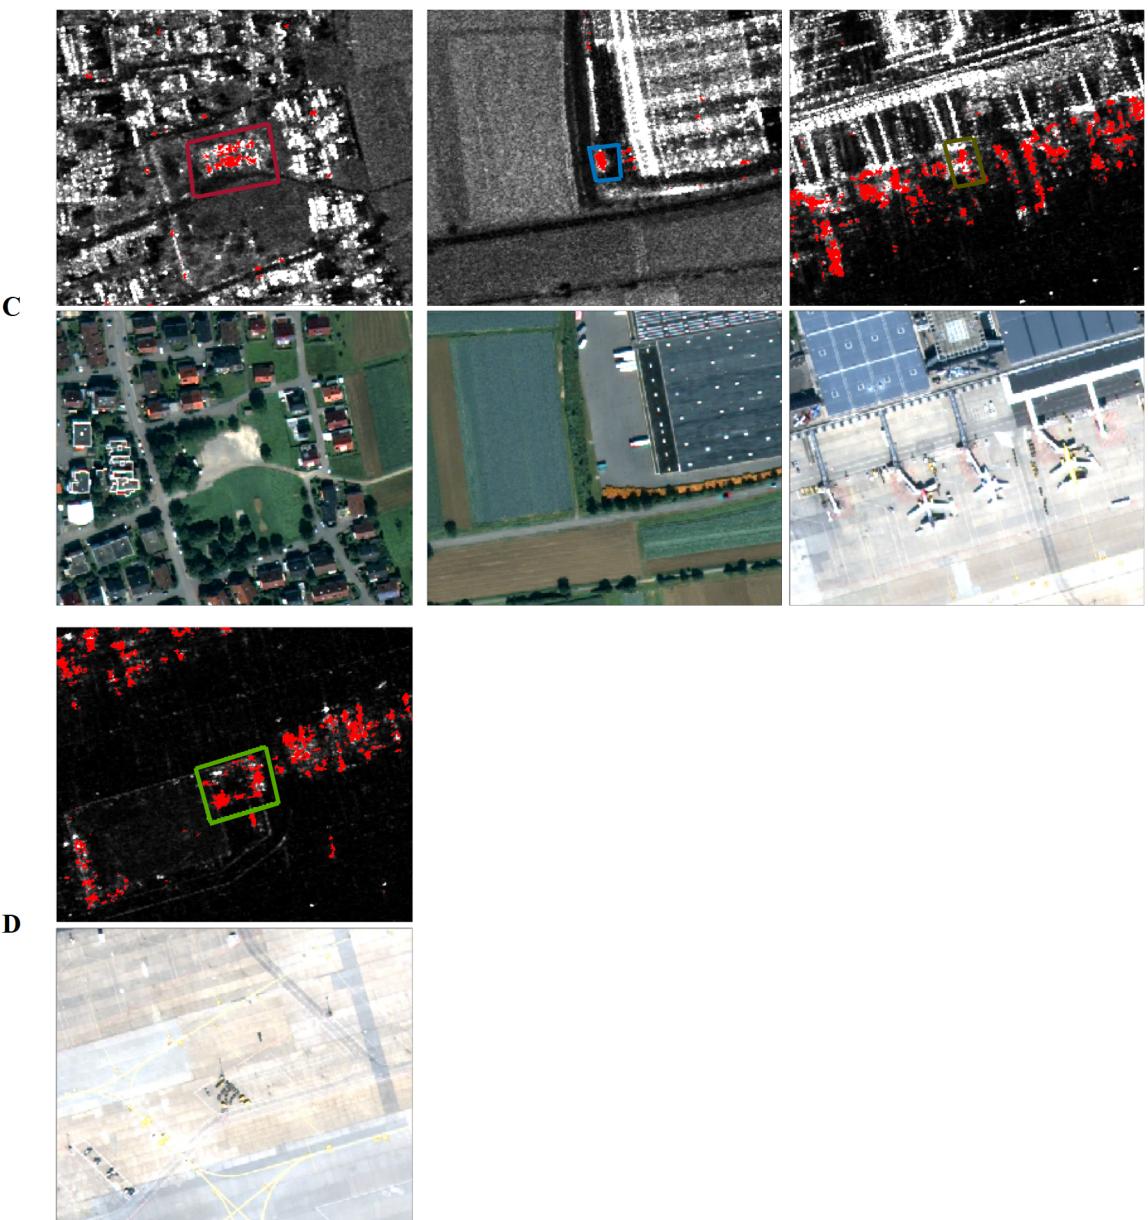
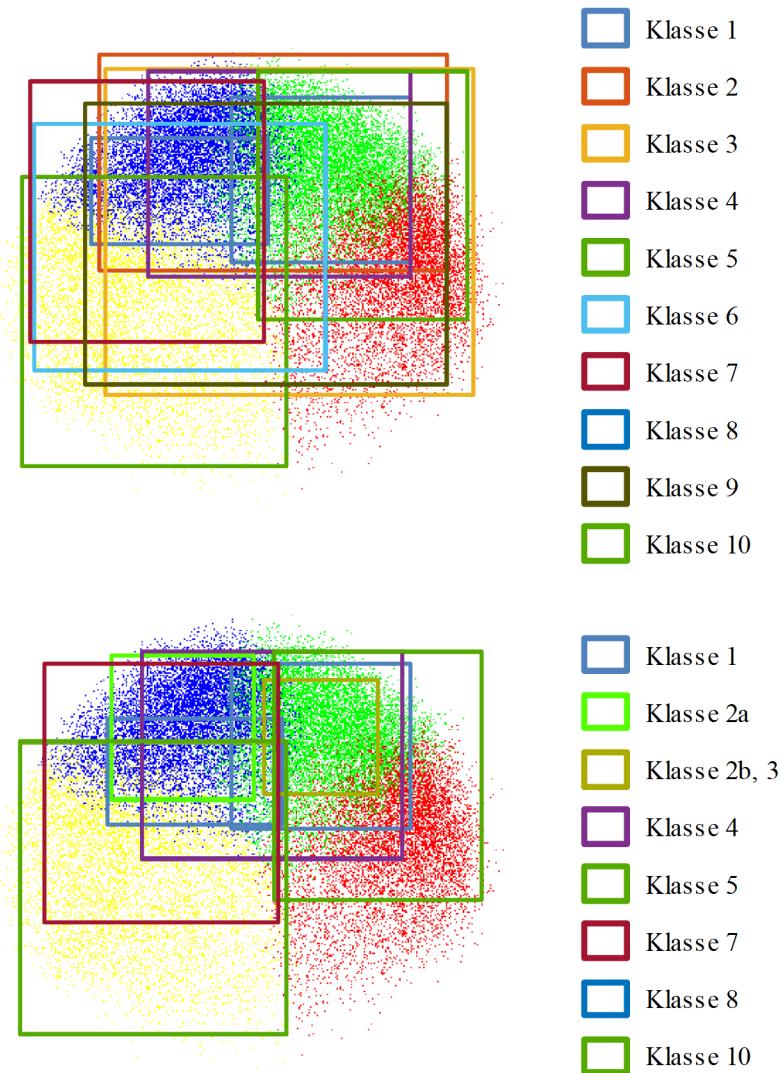


Abbildung A.30.: Initiale, fein gewählte zehn Klassen (Datensatz „Stuttgart Flughafen“), Teil 2. C bis D, jeweils obere Zeile: Selektierter Klassenbereich in Örtlichkeit (hier: mittleres Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln); C bis D, jeweils untere Zeile: Entsprechender Bereich im pangeschärftem WV-2-Bild. C: Spalten von links nach rechts: Klassen 7 (*Sammelstelle urban*), 8 (*Sammelstelle industriell*) und 9 (*Flughafen Gate*); D: Klasse 10 (*Flughafen Vorfeld*).



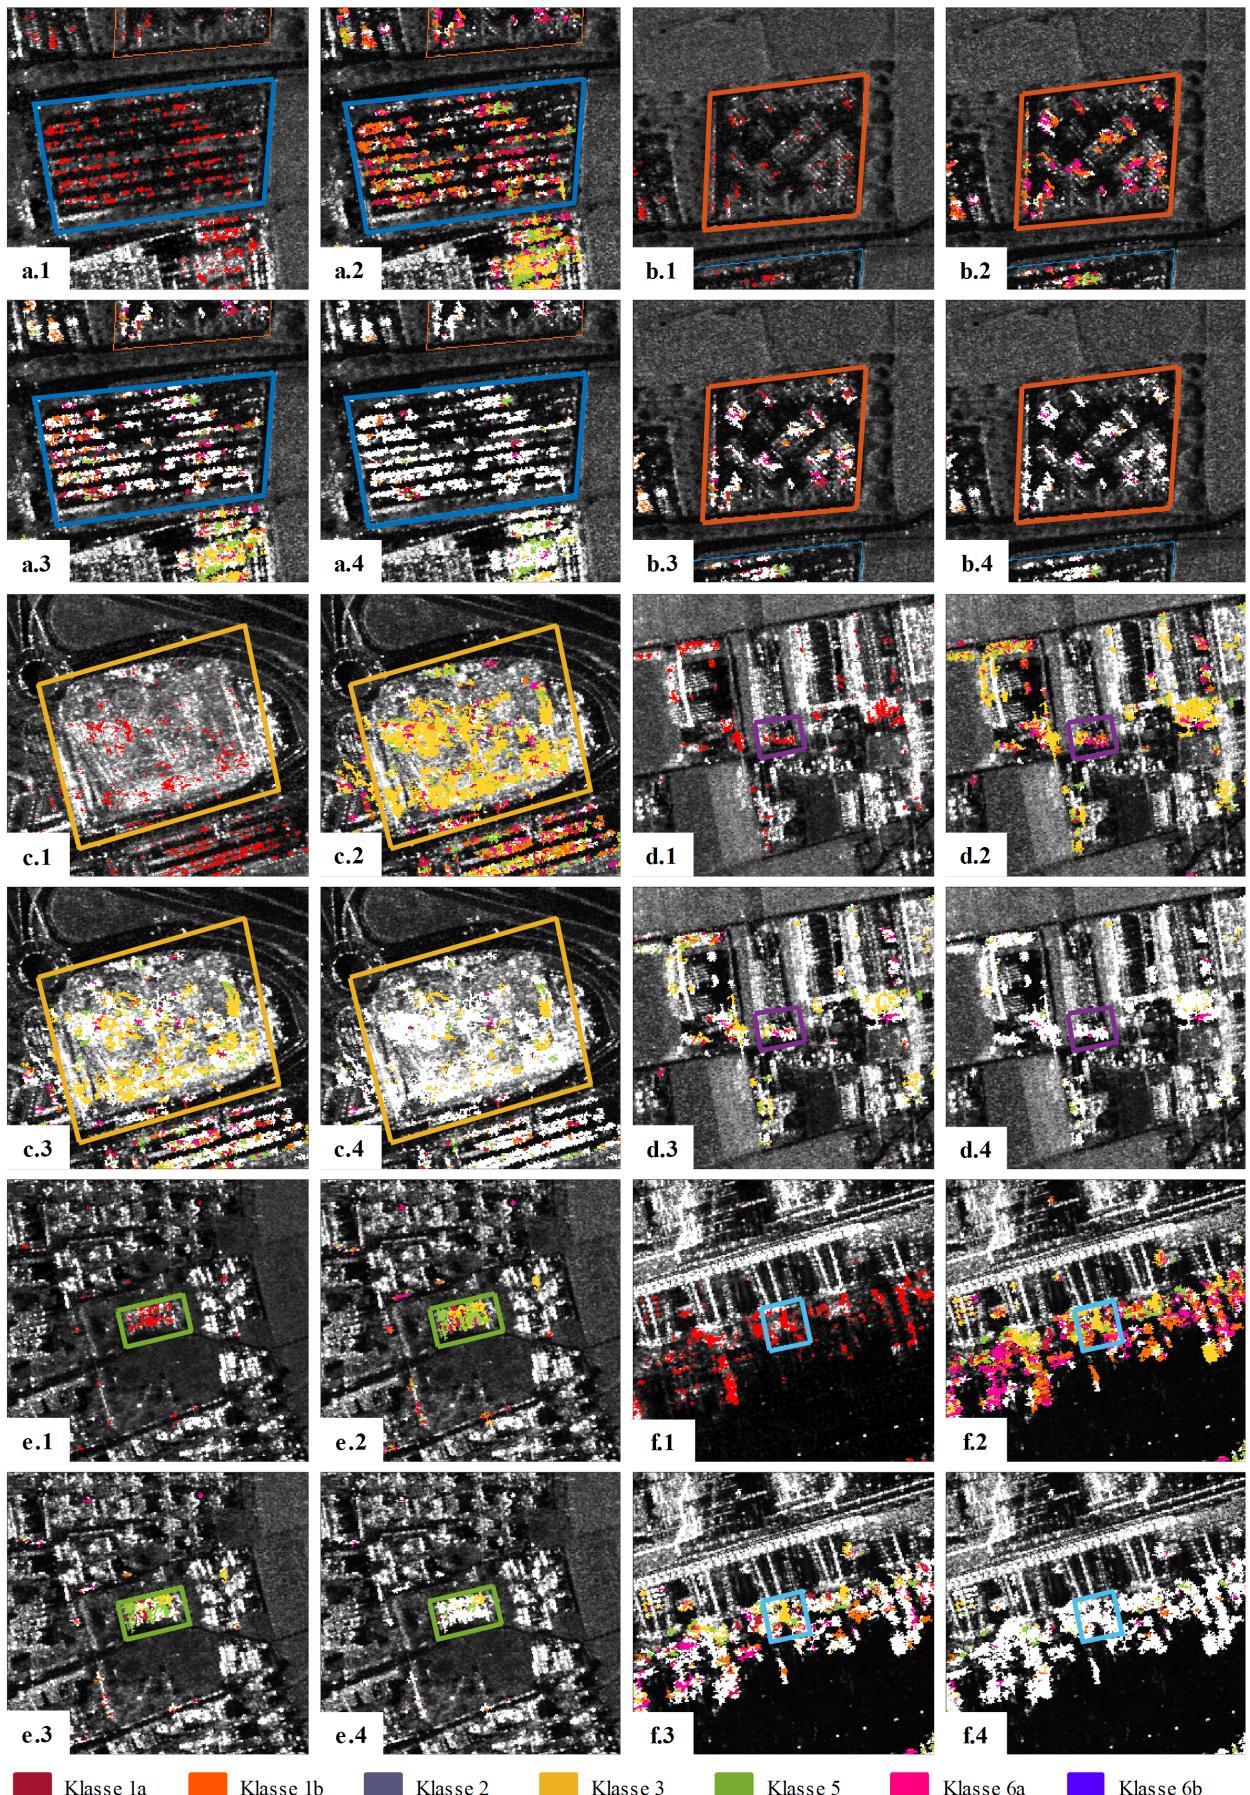


Abbildung A.32.: Variation der Fuzzy-Zugehörigkeitsschwelle  $z$ . 1: Selektierte Klassenregion in Örtlichkeit markiert auf mittlerem Amplitudenbild der Zeitreihe mit Hochaktivitätspixeln; 2: Klassifikationsresultat für  $z = 10$ ; 3: Klassifikationsresultat für  $z = 50$ ; 4: Klassifikationsresultat für  $z = 85$ . a: Initiale Klasse 1 (PKW-Parkplatz), b: Initiale Klasse 2 (LKW-Parkplatz), c: Initiale Klasse 3 (Baustelle), d: Initiale Klasse 4 (Be-/Entladestelle), e: Initiale Klasse 5 (Sammelstelle), f: Initiale Klasse 6 (Flughafen Gate).



## Abkürzungs- und Symbolverzeichnis

$\alpha_E$	Lokaler Einfallswinkel der Radarstrahlung
$\beta^0$	Rückstreuoeffizient <i>Beta Nought</i>
$\beta_a$	Angulare Radarkeulenbreite
$\chi_i^{attr}$	(Morphologische) Attributwertesequenz
$\delta_{az,RAR}$	Breite des Radarkeulen- <i>Footprints</i> (Auflösung eines RAR in Azimut-Richtung)
$\delta_{az,SAR}$	Auflösung eines SAR in Azimut-Richtung
$\epsilon_i$	zu klassifizierende Bildeinheit (Pixel oder Segment)
$\epsilon_{i,mw}$	Merkmalswert einer bestimmten Bildeinheit $\epsilon_i$
$\eta$	(Morphologische) Dilatation
$\Gamma_{Cl,CC}$	(Morphologische) triviale Schließung
$\Gamma_{Cl,CC}^A$	(Morphologische) Attributschließung
$\Gamma_{Op,CC}^A$	(Morphologische) Attributöffnung
$\lambda$	Wellenlänge
$(t^*(\alpha), s^*(\alpha))$	Optimales Schwellwertpaar (Methode nach <i>Renyi</i> )
$\mathbb{N}$	Menge der natürlichen Zahlen
$\mathbb{R}$	Menge der reellen Zahlen
$\Omega$	(Morphologische) Öffnung
$\Omega_{CC}$	(Morphologische) zusammenhängende Öffnung
$\Omega_{Op,CC}$	(Morphologische) triviale Öffnung
$\Psi$	(Morphologische) Schließung
$\Psi_{CC}$	(Morphologische) zusammenhängende Schließung
$\sigma^0$	Rückstreuoeffizient <i>Sigma Nought</i>
$\theta$	Lokaler Beleuchtungs- beziehungsweise Blickwinkel des Sensors
$v$	Fuzzy-Zugehörigkeitswertebereich
$\varepsilon$	(Morphologische) Erosion
$A_{MR}^*$	Maximales Quotientenbild
$AC^3$	Aktivitätscluster der Hochaktivitätspixel HAP
$ASF_{CC}$	(Morphologische(r)) zusammenhängende(r) Alternierende(r) Sequentielle(r) Filte(r)
$C_i$	Clusterzentren, Clusterschwerpunkte ( <i>k-means</i> -Algorithmus)
$CH_k$	<i>Caliński-Harabasz-Index</i>
$CL$	Anzahl dominanter Cluster in einer selektierten Klasse
$CL_\tau$	Maximal zulässige dominante Cluster je Klasse
$cs$	in der CM enthaltenes Änderungssegment
$D_i$	Dichtebereich einer Klasse $i$
$d_{L_2}$	Euklidische Distanz ( $L_2$ -Norm)
$DB_k$	<i>Davis-Bouldin-Kriterium</i>
$e$	Scale Parameter (MrSeg-Algorithmus)
$f$	Fusion Factor (MrSeg-Algorithmus)
$FM_{M \times N}$	Reduzierte Merkmalsmatrix (M: Anzahl der Datenpunkte (HAO); N: Anzahl der Merkmale)
$GAP_k$	<i>GAP-Index</i>
$H_b^\alpha(t, s)$	Entropie des Bildvordergrunds (Methode nach <i>Renyi</i> )
$H_w^\alpha(t, s)$	Entropie des Bildhintergrunds (Methode nach <i>Renyi</i> )
$i^2$	Imaginäre Einheit
$k$	Clusteranzahl ( <i>k-means</i> -Algorithmus)
$k^*$	(Optimal ermittelte) Clusteranzahl ( <i>k-means</i> -Algorithmus)
$KL$	Klassenanzahl des initial selektierten Klassenkatalogs
$kl_j$	Klasse $j$ eines Klassensystems oder Klassenkatalogs
$KM_{M \times 2, R}$	Kategorisierte, auf ein 2D-Raster transformierte reduzierte Merkmalsmatrix (M: Anzahl der Datenpunkte (HAO))
$KM_{M \times 2}$	Kategorisierte, auf 2D reduzierte Merkmalsmatrix (M: Anzahl der Datenpunkte (HAO))
$KM_{M \times N}$	Kategorisierte, reduzierte Merkmalsmatrix (M: Anzahl der Datenpunkte (HAO); N: Anzahl der Merkmale)
$l_{ant}$	(reale) Antennenlänge

$MQF_k$	Mittlerer quadratischer Fehler für Clusteranzahl $k$
$R_0$	Entfernung zwischen Sensor und Zielobjekt an der Erdoberfläche
$r_{BW}$	Bandbreitenparameter, Radius ( <i>Mean-Shift</i> Algorithmus)
$S_{area}$	Fläche eines Bildsegments oder -objekts
$S_{compact}$	Kompaktheit eines Bildsegments oder -objekts
$S_{dens}$	Dichte eines Bildsegments oder -objekts
$S_{HAO}$	Schwerpunkt eines Hochaktivitätsobjekts
$S_{round}$	Rundheit eines Bildsegments oder -objekts
$SH_k$	<i>Silhouettenindex</i>
$T_{Entr}$	Entropie (Textur, Basis: Grauwertmatrix)
$T_{En}$	Energie (Textur, Basis: Grauwertmatrix)
$T_{Hom}$	Homogenität (Textur, Basis: Grauwertmatrix)
$T_{Kontr}$	Kontrast (Textur, Basis: Grauwertmatrix)
$T_{Korr}$	Korrelation (Textur, Basis: Grauwertmatrix)
$v_{HAO_i,Koh}$	DAP-Merkmalsvektor (Diagonale) des HAO $i$
$v_{HAO_i,Koh}$	DAP-Merkmalsvektor (Fläche) des HAO $i$
$v_{HAO_i,Koh}$	DAP-Merkmalsvektor (Massenträgheitsmoment) des HAO $i$
$v_{HAO_i,Koh}$	DAP-Merkmalsvektor (Sigma Nought) des HAO $i$
$v_{HAO_i,Koh}$	DAP-Merkmalsvektor (Variationskoeffizient) des HAO $i$
$v_{HAO_i,Koh}$	Form-Merkmalsvektor des HAO $i$
$v_{HAO_i,Koh}$	Kohärenz-Merkmalsvektor des HAO $i$
$v_{HAO_i,Koh}$	Textur-Merkmalsvektor des HAO $i$
$Z$	Zerteilungsgrad
$z$	Fuzzy-Zugehörigkeitswert, -schwelle
$z_k$	Komplexe Zahl
AC	Aktivitätscluster
AF	<i>Adaptive Filtering</i>
ALS	<i>Airborne Laser Scanning</i>
AM	<i>ActivityMap</i>
AP	(morphologische(s)) <b>AttributProfil(e)</b>
ASF	Alternierende(r) <b>Sequentielle(r) Filter</b>
CC	<i>Connected Component(s)</i> , zusammenhängende Komponente(n)
CFAR	<i>Constant False Alarm Rate</i>
CM	<i>ChangeMap</i> , binäre Änderungskarte
Cov	<i>Coefficient of variation</i>
CSK	<b>COSMO-SkyMed</b>
CVA	<i>Change Vector Analysis</i>
DAP	(morphologische(s)) <b>Differentielle(s) Attributprofil(e)</b>
dB	<b>Dezibel</b>
DTED	<i>Digital Terrain Elevation Data</i>
FN	<b>False Negatives</b>
FP	<b>False Positives</b>
GIS	<b>Geoinformationssystem</b>
GLCM	<i>Gray-Level Co-Occurrence Matrix</i>
GT	<b>Ground Truth</b>
HAO	<b>High Activity Object</b> , <b>Hochaktivitätsobjekt</b>
HAP	<b>Hochaktivitätspixel</b>
HAR	<b>Hochaktivitätsregion</b>
HS	<i>High Resolution SpotLight Modus</i> (TerraSAR-X, TanDEM-X)
ICA	<i>Independent Component Analysis</i>
IFA	<i>Independent Factor Analysis</i>
IM	<i>IndexMap</i>
KLD	<i>Kullback-Leibler-Divergenz</i>
KNN	Künstliche Neuronale Netze
LiDAR	<i>Light Detection and Ranging</i>
LKW	<b>Lastkraftwagen</b>
LR	<i>LogRatio</i>
LULC	<i>Land Use / Land Cover</i>
MaLi	<i>Maximum Likelihood</i>

MCS .....	<b>M</b> ulti <b>C</b> hannel <b>S</b> egmentation
MDA .....	<b>M</b> ultiple <b>D</b> iscriminant <b>A</b> nalysis
ML .....	<b>M</b> ulti- <b>L</b> ook
MM .....	<b>M</b> athematische <b>M</b> orphologie
MNF .....	<b>M</b> aximum <b>N</b> oise <b>F</b> raction <b>T</b> ransformation
moi .....	<b>m</b> oment <b>o</b> f <b>i</b> ncertia (Massenträgheitsmoment)
MP .....	<b>M</b> orphologische(s) <b>P</b> rofil(e)
MRD .....	<b>M</b> ean <b>R</b> atio <b>D</b> etector
MrSeg .....	<b>M</b> ultiresolution <b>S</b> egmentation
NDVI .....	<b>N</b> ormalized <b>D</b> ifference <b>V</b> egetation <b>I</b> ndex
NEBN .....	<b>N</b> oise <b>E</b> quivalent <b>B</b> eta <b>N</b> ought
NESZ .....	<b>N</b> oise <b>E</b> quivalent <b>S</b> igma <b>Z</b> ero
OBIA .....	<b>O</b> bject <b>B</b> ased <b>I</b> mage <b>A</b> nalysis
OSM .....	<b>O</b> pen <b>S</b> treet <b>M</b> ap
PC .....	<b>P</b> rinciple <b>C</b> omponent(s) (Hauptkomponente(n))
PCA .....	<b>P</b> rincipal <b>C</b> omponent <b>A</b> nalysis (Hauptkomponentenanalyse)
PCT .....	<b>P</b> rincipal <b>C</b> omponent <b>T</b> ransformation (Hauptkomponententransformation)
PDF .....	<b>P</b> robability <b>D</b> ensity <b>F</b> unction
PKW .....	<b>P</b> ersonenkraftwagen
PSI .....	<b>P</b> ersistent <b>S</b> catterer <b>I</b> nterferometry
RAR .....	<b>R</b> eal <b>A</b> perture <b>R</b> adar
RMK .....	<b>R</b> eihen <b>m</b> esskamera
RP .....	<b>R</b> ück <b>p</b> rojektion
SAR .....	<b>S</b> ynthetic <b>A</b> perture <b>R</b> adar
SE .....	<b>S</b> trukturierendes <b>E</b> lement
SL .....	<b>S</b> pot <b>L</b> ight-Modus (TerraSAR-X, TanDEM-X)
SNR .....	<b>S</b> ignal <b>t</b> o <b>N</b> oise <b>R</b> atio
SSC .....	<b>S</b> ingle <b>L</b> ook <b>S</b> lant <b>R</b> ange <b>C</b> omplex
SSE .....	<b>S</b> um <b>of <b>S</b>quared <b>E</b>rrors</b>
SVM .....	<b>S</b> upport <b>V</b> ector <b>M</b> achine(s)
TDX .....	<b>T</b> an <b>D</b> EM- <b>X</b>
TN .....	<b>T</b> rue <b>N</b> egatives
TP .....	<b>T</b> rue <b>P</b> ositives
TSX .....	<b>T</b> erra <b>S</b> AR- <b>X</b>
UTC .....	<b>U</b> niversal <b>T</b> ime <b>C</b> oordinated
UTM .....	<b>U</b> niversal <b>T</b> ransverse <b>M</b> ercator
VP .....	<b>V</b> or <b>p</b> rojektion
WGS84 .....	<b>W</b> orld <b>G</b> eodetic <b>S</b> ystem 1984
WV-2 .....	<b>W</b> orld <b>V</b> iew-2



## Literaturverzeichnis

- [1] Kapitel Change Detection (chapter 7), book part B. In: THÉAU, J.: *Springer Handbook of Geographic Information*. Springer-Verlag Berlin Heidelberg, 2012. – ISBN 9783540726807, S. 75 – 94
- [2] ALBERTZ, J.: *Einführung in die Fernerkundung - Grundlagen der Interpretation von Luft- und Satellitenbildern*. Wissenschaftliche Buchgesellschaft Darmstadt, 2001. – 249 S. – ISBN 3534146247
- [3] LILLESAND, T. ; KIEFER, R. W. ; CHIPMAN, J.: *Remote Sensing and Image Interpretation*. 6. John Wiley & Sons, Inc., 2008. – 756 S. – ISBN 9780470052457
- [4] HEGAZY, I. R. ; KALOOP, M. R.: Monitoring urban growth and land use change detection with GIS and remote sensing techniques in Daqahlia governorate Egypt. In: *International Journal of Sustainable Built Environment* 4 (2015), S. 117 – 124
- [5] DIGITALGLOBE: *WorldView-2 Datasheet*. [http://satimagingcorp.s3.amazonaws.com/site/pdf/WorldView-2\\_datasheet.pdf](http://satimagingcorp.s3.amazonaws.com/site/pdf/WorldView-2_datasheet.pdf). Version: 2009. – Zuletzt besucht (TT.MM.JJJJ): 09.01.2018
- [6] BOUARABA, A. ; YOUNSI, A. ; BELHADJ-AISSA, A. ; ACHEROY, M. ; MILISAVLJEVIC, N. ; CLOSSON, D.: Robust Techniques for Coherent Change Detection using COSMO-SkyMed SAR Images. In: *Progress in Electromagnetics Research M* 22 (2012), S. 219 – 232
- [7] MILISAVLJEVIC, N. ; CLOSSON, D. ; BLOCH, I.: Detecting Human-Induced Scene Changes using Coherent Change Detection in SAR Images. In: *Proceedings of the ISPRS TC VII Symposium - 100 years ISPRS* Bd. XXXVIII, Part 7B, 2010, S. 389 – 394
- [8] USTALLI, N. ; PASTINA, D. ; PIERALICE, F. ; LOMBARDO, P. ; CIARAMAGLIA, F. ; GRAZIANO, A.: Comparing Non-coherent and Coherent techniques for the Detection of Scene changes from multi-temporal SAR imagery. In: *Proceedings of the 11<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2016, S. 1220 – 1223
- [9] WEHR, A. ; LOHR, U.: Airborne laser scanning - an introduction and overview. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 54 (1999), S. 68 – 82
- [10] LU, D. ; MAUSEL, P. ; BRONDIZIO, E. ; MORAN, E.: Change detection techniques. In: *International Journal of Remote Sensing* 25 (2003), Nr. 12, S. 2365 – 2407
- [11] BRUZZONE, L. ; BOVOLO, F.: A Novel Framework for the Design of Change-Detection Systems for Very-High Resolution Remote Sensing Images. In: *Proceedings of the IEEE* Bd. 101, 2013, S. 609 – 630
- [12] SINGH, A.: Review Article Digital change detection techniques using remotely-sensed data. In: *International Journal of Remote Sensing* 10:6 (1989), S. 989–1003
- [13] HUSSAIN, M. ; CHEN, D. ; CHENG, A. ; WEI, H. ; STANLEY, D.: Change detection from remotely sensed images: From pixel-based to object-based approaches. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 80 (2013), S. 91 – 106
- [14] Duden - Das Fremdwörterbuch. 9., aktualisierte Auflage. Dudenverlag Mannheim Leipzig Wien Zürich, 2010. – 1104 S.
- [15] COPPIN, P. ; JONCKHEERE, I. ; NACKAERTS, K. ; MUYS, B. ; LAMBDIN, E.: Digital change detection methods in ecosystem monitoring: a review. In: *International Journal of Remote Sensing* 25 (2004), Nr. 9, S. 1565 – 1596
- [16] MAS, J.-F.: Monitoring land-cover changes: a comparison of change detection techniques. In: *International Journal of Remote Sensing* 20 (1999), Nr. 1, S. 139 – 152
- [17] İLSEVER, M. ; ÜNSALAN, C.: *Two-Dimensional Change Detection Methods: Remote Sensing Applications*. Springer London Heidelberg New York Dordrecht, 2012 (SpringerBriefs in Computer Science). – 72 S. – ISBN 9781447142546

- [18] JIANYA, G. ; HAIGANG, S. ; GUORUI, M. ; QIMMING, Z.: A Review of Multi-Temporal Remote Sensing Data Change Detection Algorithms. In: *Proceedings of the ISPRS Congress Beijing 2008* Bd. 27, 2008, S. 757–762
- [19] Ross, S. ; BHADAURIA, H. S.: A Review of Change Detection Techniques of LandCover Using Remote Sensing Data. In: *IOSR Journal of Computer Engineering (IOSR-JCE)* 17 (2015), Nr. 3, S. 17 – 21
- [20] FISHER, P.: The pixel: a snare and a delusion. In: *International Journal of Remote Sensing* 18 (1997), Nr. 3, S. 679 – 685
- [21] LISTNER, C. ; NIEMEYER, I.: Object-based Change Detection. In: *PFG Photogrammetrie, Fernerkundung, Geoinformation* (2011), Nr. 4, S. 233 – 245
- [22] SOFINA, N. ; EHLERS, M.: Object-Based Change Detection Using High-Resolution Remotely Sensed Data and GIS. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXIX-B7, 2012, S. 345 – 349
- [23] VARSHNEY, S. S. ; RAJPAL, N. ; PURWAR, R.: Comparative Study of Image Segmentation Techniques and Object Matching using Segmentation. In: *Proceedings of International Conference on Methods and Models in Computer Science (ICM2CS)*, 2009, S. 1 – 6
- [24] NARKHEDE, H. P.: Review of Image Segmentation Techniques. In: *International Journal of Science and Modern Engineering (IJISME)* 1 (2013), Nr. 8, S. 54 – 61
- [25] HAPP, P. N. ; FERREIRA, R. S. ; BENTES, C. ; COSTA, G. A. O. P. ; FEITOSA, R. Q.: Multiresolution Segmentation: A Parallel Approach for High Resolution Image Segmentation in Multicore Architectures. In: *Proceedings of the ISPRS International Conference on Geographic Object-Based Image Analysis* Bd. XXXVIII-4/C7, 2010, S. 6
- [26] MANSOURPOUR, M. ; RAJABI, M. A. ; BLAIS, J. A. R.: Effects and Performance of Speckle Noise Reduction Filters on Active Radar and SAR Images. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXVI-1/W41, 2006, S. 6
- [27] BOLDT, M. ; THIELE, A. ; SCHULZ, K. ; HINZ, S.: Unsupervised Segmentation of HR SAR Time Series Amplitude Imagery Aiming on Context Based Change Categorization. In: *Proceedings of the 10<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2014, S. 616 – 619
- [28] LEE, J.-S. ; JURKEVICH, L. ; DEWAELE, P. ; WAMBACQ, P. ; OOSTERLINCK, A.: Speckle Filtering of Synthetic Aperture Radar Images: A Review. In: *Remote Sensing Reviews* 8 (1994), S. 313 – 340
- [29] SOILLE, P.: *Morphologische Bildverarbeitung: Grundlagen, Methoden, Anwendungen*. Springer Verlag Berlin Heidelberg, 1998. – 316 S. – ISBN 3540643230
- [30] ASHOK, H. G. ; PATIL, D. R.: Survey on Change Detection in SAR Images. In: *IJCA Proceedings on National Conference on Emerging Trends in Computer Technology NCETCT* (2014), Nr. 2, S. 4 – 7
- [31] WEYDAHL, D. J.: Change Detection in SAR Images. In: *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1991, S. 1421 – 1424
- [32] Kapitel Change detection in remote sensing observations. In: MERCIER, G. ; DERRODE, S. ; TROUVÉ, E. ; BOMBRUN, L.: *Multivariate Image Processing: Methods and Applications*. ISTE Ltd and Jon Wiley & Sons Inc., 2010 (Digital Signal and Image Processing Series). – ISBN 9781848211391, S. 95 – 142
- [33] HAMMER, H. ; DUBOIS, C. ; BOLDT, M. ; KUNY, S. ; CADARIO, E. ; THIELE, A.: Comparison of Multiple Methods for Detecting Changes in Urban Areas in TerraSAR-X Data. In: *Proceedings of SPIE, Earth Resources and Environmental Remote Sensing/GIS Applications* Bd. 10005, 2016, S. 100050Y-1 – 100050Y-16
- [34] XU, L. ; ZHANG, S. ; HE, Z. ; GUO, Y.: The Comparative Study of Three Methods of Remote Sensing Image Change Detection. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Services* Bd. 37, 2008, S. 1595 – 1598
- [35] DEKKER, R. J.: SAR change detection techniques and applications. In: *Proceedings of the 25<sup>th</sup> EARSeL Symposium; Global Developments in Environmental Earth Observation from Space*, 2005, S. 63 – 69

- [36] RIGNOT, E. J. M. ; ZYL, J. J.: Change Detection Techniques for ERS-1 SAR Data. In: *IEEE Transactions on Geoscience and Remote Sensing* 31 (1993), Nr. 4, S. 896 – 906
- [37] WEYDAHL, D. J.: Temporal Change Detection in ERS-1 SAR Images. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 1992, S. 1346 – 1348
- [38] WU, F. ; WANG, C. ; ZHANG, H. ; ZHANG, B.: Change Detection and Analysis with Radarsat-1 SAR Image. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2007, S. 2601 – 2604
- [39] GARZELLI, A. ; ZOPPETTI, C.: Detail-Preserving Change Detection from Amplitude SAR Images. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2013, S. 3002 – 3005
- [40] PAUL, L. ; RAMAMOORTHY, P.: Synthetic Aperture Radar Image Change Detection Using Fuzzy C-Means Clustering Algorithm. In: *International Journal of Advanced Research in Computer and Communication Engineering* 2 (2013), Nr. 3, S. 1374 – 1379
- [41] SU, J. ; WANG, R. ; DU, K.: A Change Detection Method for Man-made Objects in SAR Images Based on Curvelet and Level Set. In: *Proceedings of the 6<sup>th</sup> International Conference on Image and Graphics*, 2011, S. 543 – 547
- [42] DUDA, R. O. ; HART, P. E. ; STORK, D. G.: *Pattern Classification*. 2. John Wiley & Sons, Inc., 2000. – 680 S.
- [43] GULATI, V. ; PAL, P. A.: Survey on Various Change Detection Techniques for Hyper Spectral Images. In: *International Journal of Advanced Research in Computer Science and Software Engineering* 4 (2014), Nr. 8, S. 852 – 855
- [44] HYVÄRINEN, A. ; OJA, E.: Independent Component Analysis: Algorithms and Applications. In: *Neural Networks* 13 (2000), Nr. 4, S. 411 – 430
- [45] WU, C. ; ZHANG, L. ; DU, B.: Hyperspectral anomaly change detection with slow feature analysis. In: *Neurocomputing* 151 (2015), S. 175 – 187
- [46] BASENER, W. F. ; MESSINGER, D. W.: Enhanced Detection and Visualization of Anomalies in Spectral Imagery. In: *Proceedings of SPIE Vol. 7334, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV*, 2009, S. 73341Q-1 – 73341Q-10
- [47] HYTLA, P. C. ; HARDIE, R. C. ; EISMANN, M. T. ; MEOLA, J.: Anomaly detection in hyperspectral imagery: comparison of methods using diurnal and seasonal data. In: *Journal of Applied Remote Sensing* 3 (2009), Nr. 1, S. 033546-1 – 033546-30
- [48] MOLERO, J. M. ; GARZÓN, E. M. ; GARCIA, I. ; PLAZA, A.: Analysis and Optimizations of Global and Local Versions of the RX Algorithm for Anomaly Detection in Hyperspectral Data. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 6 (2013), Nr. 2, S. 801 – 814
- [49] SOOFBAF, S. R. ; VALADANZOEJ, M. J. ; FAHIMNEJAD, H. ; ASHOORI, H.: Efficient Detection of Anomalies in Hyperspectral Images. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science* Bd. XXXVII, Part B7, 2008, S. 303 – 308
- [50] CAVES, R. G. ; McCONNELL, I. ; COOK, R. ; QUEGAN, S.: Multi-channel SAR segmentation: Algorithms and applications. In: *IEE Colloquium on Image Processing for Remote Sensing*, 1996, S. 2/1 – 2/6
- [51] RICHARDS, J. A.: *Remote Sensing with Imaging Radar*. Springer Berlin Heidelberg, 2009 (Signals and Communication Technology). – 361 S. – ISBN 9783642020193
- [52] INGLADA, J. ; MERCIER, G.: A New Statistical Similarity Measure for Change Detection in Multitemporal SAR Images and Its Extension to Multiscale Change Analysis. In: *IEEE Transactions on Geoscience and Remote Sensing* 45 (2007), Nr. 5, S. 1432 – 1455
- [53] MOHAMED, N. ; MOBARAK, B.: Change Detection Techniques using Optical Remote Sensing: A Survey. In: *American Scientific Research Journal for Engineering, Technology, and Science (ASRJETS)* 17 (2016), Nr. 1, S. 42 – 51
- [54] SHEN, G. ; GUO, H. ; LIAO, J.: Change vector analysis method for inundation change detection using multi-temporal multi-polarized SAR images. In: *Proceedings of SPIE, Remote Sensing and GIS Data Processing and Applications; and Innovative Multispectral Technology and Applications* Bd. 6790, 2007, S. 679007-1 – 679007-8

- [55] YE, X. ; ZHANG, H. ; WANG, C. ; ZHANG, B. ; WU, F. ; TANG, Y.: SAR Image Change Detection based on Object-Based Method. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2013, S. 2083 – 2086
- [56] YOUSIF, O. ; BAN, Y.: Object-Based Urban Change Detection Using High Resolution SAR Images. In: *Proceedings of the Joint Urban Remote Sensing Event (JURSE)*, 2015, S. 4
- [57] KUROSU, T. ; FUJITA, M. ; CHIBA, K.: Monitoring of Rice Crop Growth From Space Using the ERS-1 C-band SAR. In: *IEEE Transactions on Geoscience and Remote Sensing* 33 (1995), Nr. 4, S. 1092 – 1096
- [58] BRUZZONE, L. ; MARCONCINI, M. ; WEGMÜLLER, U. ; WIESMANN, A.: An Advanced System for the Automatic Classification of Multitemporal SAR Images. In: *IEEE Transactions on Geoscience and Remote Sensing* 42 (2004), Nr. 6, S. 1321 – 1334
- [59] HE, M. ; HE, X. F.: Urban change detection using Coherence and Intensity Characteristics of Multitemporal SAR Imagery. In: *Proceedings of the 2<sup>nd</sup> Asian-Pacific Conference on Synthetic Aperture Radar (APSAR)*, 2009, S. 840 – 843
- [60] JIANG, L. ; LIAO, M. ; LIN, H. ; ZHAO, A.: Urban change detection using multitemporal ERS-1/2 InSAR data. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2005, S. 4002 – 4005
- [61] LI, Q. ; PERISSIN, D. ; LUO, Q. ; LIN, H. ; PANG, M.: High Resolution SAR Change Detection in Hong Kong. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2011, S. 1630 – 1633
- [62] LÈ, T. T. ; ATTO, A. M. ; TROUVÉ, E.: Change Analysis using Multitemporal Sentinel-1 SAR Images. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015, S. 4145 – 4148
- [63] SU, X. ; DELEDALLE, C.-A. ; TUPIN, F. ; SUN, H.: Change Detection and Classification of Multi-Temporal SAR Series based on Generalized Likelihood Ratio Comparing-and-Recognizing. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2014, S. 1433 – 1436
- [64] HACHICHA, S. ; DELEDALLE, C.-A. ; CHaabane, F. ; TUPIN, F.: Multi-temporal SAR classification according to change detection operators. In: *Proceedings of the 6<sup>th</sup> International Workshop on the Analysis of Multi-temporal Remote Sensing Images (Multi-Temp)*, 2011, S. 133 – 136
- [65] CROSETTO, M. ; MONSERRAT, O. ; JUNGNER, A. ; CRIPPA, B.: Persistent Scatterer Interferometry: Potential and Limits. In: *Proceedings of the ISPRS Workshop on High-Resolution Earth Imaging for Geospatial Information*, 2009, S. 6
- [66] CROSETTO, M. ; MONSERRAT, O. ; CUEVAS-GONZÁLEZ, M. ; DEVANTHÉRY, N. ; CRIPPA, B.: Persistent Scatterer Interferometry: A review. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 115 (2016), S. 78 – 89
- [67] YANG, C. H. ; SOERGEL, U.: Change Detection based on Persistent Scatterer Interferometry - Case Study of Monitoring an Urban Area. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XL-3/W3, 2015, S. 123 – 130
- [68] BOLDT, M. ; THIELE, A. ; SCHULZ, K. ; HINZ, S.: Structural Analysis of Forest Areas in High-Resolution SAR Images. In: *Proceedings of SPIE, Earth Resources and Environmental Remote Sensing/GIS Applications II* Bd. 8181, 2011, S. 81810S-1 – 81810S-15
- [69] ZORAN, M.: Urban land cover changes assessment by satellite remote sensing imagery. In: *Proceedings of SPIE, Remote Sensing for Agriculture, Ecosystems, and Hydrology XI* Bd. 7472, 2009, S. 74721I-1 – 74721I-9
- [70] GHOFRANI, Z. ; MOKHTARZADE, M. ; SAHEBI, M. R. ; BEYKIKHOSH, A.: Evaluating coverage changes in national parks using a hybrid change detection algorithm and remote sensing. In: *Journal of Applied Remote Sensing* 8 (2014), S. 083646-1 – 083646-16
- [71] RAJESWARI, A. V. ; SARITHA, S. ; KUMAR, G. S.: Classification based Land Use/Land Cover Change Detection through Landsat images. In: *Proceedings of the International Conference on Data Science and Engineering (ICDSE)*, 2014, S. 232 – 237

- [72] BOLDT, M. ; THIELE, A. ; SCHULZ, K.: Object-based Urban Change Detection Analyzing High Resolution Optical Satellite Images. In: *Proceedings of SPIE, Earth Resources and Environmental Remote Sensing/GIS Applications III* Bd. 8538, 2012, S. 85380E-1 – 85380E-9
- [73] NIEMEYER, I. ; BACHMANN, F. ; JOHN, A. ; LISTNER, C. ; MARPU, P. R.: Object-based change detection and classification. In: *Proceedings of SPIE, Image and Signal Processing for Remote Sensing XV* Bd. 7477, 2009, S. 74770S-1 – 74770S-11
- [74] WEIHING, D. ; PONCET, F. von ; SCHLUND, M. ; LANG, O.: Change Analysis with TerraSAR-X Data. In: *Proceedings of the ISPRS TC VII Symposium IAPRS* Bd. XXXVIII, Part 7B, 2010, S. 644 – 647
- [75] BARRETO, T. L. M. ; SOSA, R. A. S. ; WIMMER, C. ; MOREIRA, J. R. ; BINS, L. S. ; CAPPABIANCO, F. A. M. ; ALMEIDA, J.: Classification of Detected Changes From Multitemporal High-Res Xband SAR Images: Intensity and Texture Descriptors From SuperPixels. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (2016), Nr. 12, S. 5436 – 5448
- [76] ACHANTA, R. ; SHAJI, A. ; SMITH, K. ; LUCCI, A. ; FUJII, P. ; SÜSSSTRUNK, S.: SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 34 (2012), Nr. 11, S. 2274 – 2281
- [77] LOPEZ, C. V. ; ANGLBERGER, H. ; STILLA, U.: Fusion of very high resolution SAR and optical images for the monitoring of urban areas. In: *Proceedings of the Joint Urban Remote Sensing Event (JURSE)*, 2017, S. 4
- [78] YOUSIF, O. ; BAN, Y.: Fusion of SAR and Optical Data for Unsupervised Change Detection: A Case Study in Beijing. In: *Proceedings of the Joint Urban Remote Sensing Event (JURSE)*, 2017, S. 4
- [79] HU, H. ; BAN, Y.: Urban Land Cover Mapping and Change Detection with RADARSAT SAR Data using Neural Network and Rule-Based Classifiers. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXVII Part B7, 2008, S. 1549 – 1554
- [80] MISHRA, B. ; SUSAKI, J.: SAR and Optical Data Fusion for Land Use and Land Cover Change Detection. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2014, S. 4691 – 4694
- [81] ZENG, Y. ; ZHANG, J. ; GENDEREN, J. L.: Change Detection Approach to SAR and Optical Image Integration. In: *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXVII, Part B7, 2008, S. 1077 – 1084
- [82] THIELE, A. ; BOLDT, M. ; HINZ, S.: Automated Detection of Storm Damage in Forest Areas by Analyzing TerraSAR-X Data. In: *Proceedings of the IEEE Geoscience and Remote Sensing Symposium (IGARSS)*, 2012, S. 1672 – 1675
- [83] DEILAMI, B. R. ; AHMAD, B. ; SAFFAR, M. R. A. ; UMAR, H. Z.: Review of Change Detection Techniques from Remotely Sensed Images. In: *Research Journal of Applied Sciences, Engineering and Technology* 10 (2015), Nr. 2, S. 221 – 229
- [84] SEZGIN, M. ; SANKUR, B.: Survey over image thresholding techniques and quantitative performance evaluation. In: *Journal of Electronic Imaging* 13 (2004), Nr. 1, S. 146 – 165
- [85] REN, W. ; SONG, J. ; TIAN, S. ; WU, W.: Survey on Unsupervised Change Detection Techniques in SAR Images. In: *Proceedings of IEEE China Summit & International Conference on Signal and Information Processing (ChinaSIP)*, 2014, S. 143 – 147
- [86] KIANA, E. ; HOMAYOUNI, S. ; SHARIFI, M. A. ; FARID-ROHANI, M.: Unsupervised Change Detection in SAR images using Gaussian Mixture Models. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XL-1/W5, 2015, S. 407 – 410
- [87] BRUZZONE, L. ; PRIETO, D. F.: Automatic Analysis of the Difference Image for Unsupervised Change Detection. In: *IEEE Transactions on Geoscience and Remote Sensing* 38 (2000), Nr. 3, S. 1171 – 1182
- [88] XIAO, W. ; XU, S. ; ELBERINK, S. O. ; VOSSELMAN, G.: Individual Tree Crown Modeling and Change Detection From Airborne Lidar Data. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (2016), Nr. 8, S. 3467 – 3477

- [89] MARINELLI, D. ; PARIS, C. ; BRUZZONE, L.: Fusion of High and Very High Density LiDAR Data for 3D Forest Change Detection. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, S. 3595 – 3598
- [90] PENG, D. ; ZHANG, Y.: Building Change Detection by Combining LiDAR Data and Ortho Image. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XLI-B3, 2016, S. 669 – 676
- [91] WALTER, V.: Object-based classification of remote sensing data for change detection. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 58 (2004), S. 225 – 238
- [92] LI, D.: Remotely sensed images and GIS data fusion for automatic change detection. In: *International Journal of Image and Data Fusion* 1 (2010), Nr. 1, S. 99 – 108
- [93] SCHULZ, K. ; BOLDT, M.: Analysis of Seasonal Changes in High Resolution Repeat Pass SAR Image Pairs by the CoVAmCoh Method. In: *Proceedings of 9<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2012, S. 563 – 566
- [94] SOFIANE, H. ; FERDAOUS, C.: Comparison of Change Detection Indicators in SAR Images. In: *Proceedings of the 8<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2010, S. 109 – 112
- [95] SAHOO, P. K. ; ARORA, G.: A thresholding method based on two-dimensional Renyi's entropy. In: *Pattern Recognition* 37 (2004), Nr. 6, S. 1149 – 1161
- [96] LEEUW, J. de ; VRIELING, A. ; SHEE, A. ; ATZBERGER, C. ; HADGU, K. M. ; BIRADAR, C. M. ; KEAH, H. ; TURVEY, C.: The Potential and Uptake of Remote Sensing in Insurance: A Review. In: *MDPI Journal of Remote Sensing* 6 (2014), S. 10888 – 10912
- [97] ROTH, A. ; EINEDER, M. ; SCHÄTTLER, B.: TerraSAR-X: A New Perspective for Applications Requiring High Resolution Spaceborne SAR Data. In: *Proceedings of the Joint ISPRS 6th EarSel Workshop on High Resolution Mapping from Space*, 2003, S. 4
- [98] WERNINGHAUS, R. ; BUCKREUSS, S.: The TerraSAR-X Mission and System Design. In: *IEEE Transactions on Geoscience and Remote Sensing* 48 (2010), Nr. 2, S. 606 – 614
- [99] BUCKREUSS, S. ; WERNINGHAUS, R. ; PITZ, W.: The German Satellite Mission TerraSAR-X. In: *Proceedings of the IEEE RadarCon*, 2008, S. 1 – 5
- [100] MITTERMAYER, J. ; WOLLSTADT, S. ; PRATS, P. ; SCHEIBER, R. ; KOPPE, W.: Staring Spotlight Imaging with TerraSAR-X. In: *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2012, S. 1606 – 1609
- [101] HENDERSON, F. M. ; LEWIS, A. J.: *Principles & Applications of Imaging Radar, Manual of Remote Sensing*. Bd. 2. 3. John Wiley & Sons, Inc., 1998. – 896 S.
- [102] KLAUSING, H. ; HOLPP, W.: *Radar mit realer und synthetischer Apertur, Konzeption und Realisierung*. Oldenbourg Verlag München Wien, 2000. – 399 S. – ISBN 3486234757
- [103] Kapitel High Resolution Radar Imaging of Urban Areas. In: STILLA, U.: *Photogrammetric Week '07*. Wichmann Verlag, Heidelberg, 2007, S. 149 – 158
- [104] SOERGEL, U. ; CADARIO, E. ; THIELE, A. ; THOENNESSEN, U.: Feature Extraction and Visualization of Bridges Over Water From High-Resolution InSAR Data and One Orthophoto. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 1 (2008), Nr. 2, S. 147 – 153
- [105] THIELE, A.: *3D Building Reconstruction From High Resolution Multi-Aspect Interferometric Synthetic Aperture RADAR Data*, Leibniz Universität Hannover, Fachrichtung Geodäsie und Geoinformatik, Dissertation, 2013. – 163 S.
- [106] BAGHDADI, N. ; HAJJ, M. E. ; FERNANDEZ, D. D. ; ZRIBI, M. ; BELAUD, G. ; CHEVIRON, B.: Signal level comparison between TerraSAR-X and COSMO-SkyMed SAR Sensors. In: *IEEE Geoscience and Remote Sensing Letters* 12 (2014), Nr. 3, S. 448 – 452

- [107] AIRBUS DEFENCE AND SPACE GEO-INTELLIGENCE PROGRAM LINE (Hrsg.): *TerraSAR-X Image Product Guide, Basic and Enhanced Radar Satellite Imagery*. Airbus Defence and Space GmbH, Claude-Dornier-Straße, 88090 Immenstaad, Deutschland: Airbus Defence and Space Geo-Intelligence Program Line, 2014. – 24 S. [https://mdacorporation.com/docs/default-source/product-spec-sheets/geospatial-services/image\\_product\\_guide.pdf?sfvrsn=4](https://mdacorporation.com/docs/default-source/product-spec-sheets/geospatial-services/image_product_guide.pdf?sfvrsn=4). – Zuletzt besucht (TT.MM.JJJJ): 09.01.2018
- [108] SCHMITT, A.: *Änderungserkennung in multitemporalen und multipolarisierten Radaraufnahmen*, Universität Fridericiana zu Karlsruhe (TH), Fakultät für Bauingenieur-, Geo- und Umweltwissenschaften, Dissertation, 2012. – 302 S.
- [109] DASARI, K. ; ANJANEYULU, L. ; JAYASRI, P. V. ; PRASAD, A. V. V.: Importance of Speckle Filtering in Image Classification of SAR Data. In: *Proceedings of the IEEE International Conference on Microwave, Optical and Communication Engineering (ICMOCE)*, 2015, S. 349 – 352
- [110] AIRBUS DEFENCE AND SPACE GEO-INTELLIGENCE (Hrsg.): *Radiometric Calibration of TerraSAR-X Data: Beta Naught and Sigma Naught Coefficient Calculation*. Infoterra GmbH, 88039 Friedrichshafen, Deutschland: Airbus Defence and Space Geo-Intelligence, 2008. – 15 S.
- [111] SCHULZ, K. ; CADARIO, E. ; BOLDT, M. ; THIELE, A.: Improving High-Resolution Repeat Pass SAR Image Interpretation by the CoVAmCoh Method. In: *Proceedings of the 8<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2010, S. 36 – 39
- [112] SCHULZ, K. ; BOLDT, M. ; THIELE, A.: CovAmCoh-Analysis: A method to improve the interpretation of high resolution repeat pass SAR images of urban areas. In: *Proceedings of SPIE, Remote Sensing for Environmental Monitoring, GIS Applications, and Geology IX* Bd. 7478, 2009, S. 747805-1 – 747805-9
- [113] SCHULZ, K. ; BOLDT, M. ; EVEN, M.: Generalization of the CoVAmCoh Analysis for the Interpretation of Arbitrary InSAR Images. In: *Proceedings of the IEEE Geoscience and Remote Sensing Symposium (IGARSS)*, 2012, S. 7444 – 7447
- [114] SERRA, J. ; VINCENT, L.: An Overview of Morphological Filtering. In: *Circuits, Systems and Signal Processing* 11 (1992), Nr. 1, S. 47 – 108
- [115] BREEN, E. J. ; JONES, R.: Attribute Openings, Thinnings, and Granulometries. In: *Computer Vision and Image Understanding* 64 (1996), S. 377 – 389
- [116] DALLA MURA, M. ; BENEDIKTSSON, J. A. ; WASKE, B. ; BRUZZONE, L.: Morphological Attribute Profiles for the Analysis of Very High Resolution Images. In: *IEEE Transactions on Geoscience and Remote Sensing* 48 (2010), S. 3747 – 3762
- [117] DALLA MURA, M.: *Advanced Techniques Based on Mathematical Morphology for the Analysis of Remote Sensing Images*, University of Trento, University of Iceland, Dissertation, 2011. – 185 S. – Verfügbar unter (z.B.): <http://eprints-phd.biblio.unitn.it/592/>
- [118] BENEDIKTSSON, J. A. ; ARNASON, K. ; PESARESI, M.: The Use of Morphological Profiles in Classification of Data from Urban Areas. In: *Proceedings of Remote Sensing and Data Fusion over Urban Areas, IEEE/ISPRS Joint Workshop*, 2001, S. 30 – 34
- [119] SAHOO, P. ; WILKINS, C. ; YEAGER, J.: Threshold Selection Using Renyi's Entropy. In: *Pattern Recognition* 30 (1997), Nr. 1, S. 71 – 84
- [120] ALBUQUERQUE, M. P. ; ESQUEF, I. A. ; MELLO, A. R. G.: Image thresholding using Tsallis entropy. In: *Pattern Recognition Letters* 25 (2004), S. 1059 – 1065
- [121] PAL, N. R. ; PAL, S. K.: Entropy: A New Definition and its Applications. In: *IEEE Transactions on Systems, Man, and Cybernetics* 21 (1991), Nr. 5, S. 1260 – 1270
- [122] RENYI, A.: On measures of entropy and information. In: *Proceedings of the Fourth Berkeley Symposium on Math. Statist. Prob.* Bd. 1, 1960, S. 547 – 561
- [123] KAPUR, J. N. ; SAHOO, P. K. ; WONG, A. K. C.: A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram. In: *Computer Vision, Graphics and Image Processing* 29 (1985), S. 273 – 285
- [124] YEN, J.-C. ; CHANG, F.-J. ; CHANG, S.: A New Criterion for Automatic Multilevel Thresholding. In: *IEEE Transactions on Image Processing* 4 (1995), Nr. 3, S. 370 – 378

- [125] SRINIVASAN, G. N. ; SHOBHA, G.: Statistical Texture Analysis. In: *World Academy of Science, Engineering and Technology* 36 (2008), S. 1264 – 1269
- [126] Kapitel Texture Analysis. In: TUCERYAN, M. ; JAIN, A. K.: *The Handbook of Pattern Recognition and Computer Vision*. 2. World Scientific Publishing Co., 1998, S. 207 – 248
- [127] HARALICK, R. M. ; SHANMUGAM, K. ; DINSTEIN, I.: Textural Features for Image Classification. In: *IEEE Transactions on Systems, Man and Cybernetics SMC-3* (1973), Nr. 6, S. 610 – 621
- [128] KUNY, S. ; SCHULZ, K. ; HAMMER, H.: Simulation based texture analysis of heaps of debris for damage assessment in high resolution SAR data. In: *Proceedings of the 6th International Conference on Recent Advances in Space Technologies (RAST)* Bd. 2, 2013, S. 1169 – 1172
- [129] PATHAK, B. ; BAROOAH, D.: Texture Analysis based on the Gray-Level Co-Occurrence Matrix Considering Possible Orientations. In: *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering* 2 (2013), Nr. 9, S. 4206 – 4212
- [130] BOLDT, M. ; THIELE, A. ; SCHULZ, K. ; HINZ, S.: Feature Extraction for Change Analysis in SAR Time Series. In: *Proceedings of SPIE, Earth Resources and Environmental Remote Sensing/GIS Applications VI* Bd. 9644, 2015, S. 964410-1 – 964410-10
- [131] BLASCHKE, T.: Object based image analysis for remote sensing. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 65 (2010), S. 2 – 16
- [132] HAY, G. J. ; CASTILLA, G.: Object-Based Image Analysis: Strengths, Weaknesses, Opportunities and Threats (SWOT). In: *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXVI, part 6, 2006, S. 3
- [133] R. C. WEIH, Jr. ; N. D. RIGGAN, Jr.: Object-Based Classification vs. Pixel-Based Classification: Comparative Importance of Multi-Resolution Imagery. In: *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, GEOBIA 2010: Geographic Object-Based Image Analysis* Bd. XXXVIII-4/C7, 2010, S. 6
- [134] ZERROUKI, N. ; BOUCHAFFRA, D.: Pixel-Based or Object-Based: Which Approach is More Appropriate for Remote Sensing Image Classification? In: *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*, 2014, S. 864 – 869
- [135] TRIMBLE GERMANY GMBH (Hrsg.): *Trimble Documentation eCognition Developer 9.1 Reference Book*. Document Version 9.1.2. Arnulfstrasse 126, D-80636 Munich, Germany: Trimble Germany GmbH, September 2015. – 532 S.
- [136] BAATZ, M. ; SCHÄPE, A.: Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT-Symposium Salzburg 2000* (2000), S. 12–23
- [137] DABIRI, Z. ; HÖLBLING, D. ; LANG, S. ; BARTSCH, A.: Applicability of Multi-Seasonal X-Band SAR Imagery for Multiresolution Segmentation: A Case Study in a Riparian Mixed Forest. In: *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, International Conference on Sensors & Models in Remote Sensing & Photogrammetry* Bd. XL-1/W5, 2015, S. 123 – 128
- [138] LEE, J.-S. ; JURKEVICH, I.: Segmentation of SAR Images. In: *IEEE Transactions on Geoscience and Remote Sensing* 27 (1989), Nr. 6, S. 674 – 680
- [139] LANKOANDE, O. ; HAYAT, M. M. ; SANTHANAM, B.: Segmentation of SAR Images Based on Markov Random Field Model. In: *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 2005, S. 6
- [140] CARVALHO, E. A. ; USHIZIMA, D. M. ; MEDEIROS, F. N. S. ; MARTINS, C. I. O. ; MARQUES, R. C. P. ; OLIVEIRA, I. N. S.: SAR imagery segmentation by statistical region growing and hierarchical merging. In: *Digital Signal Processing* 20 (2010), S. 1365 – 1378
- [141] LI, Z. ; YANG, Z. ; XIONG, H.: Homogeneous Region Segmentation for SAR Images Based on Two Steps Segmentation Algorithm. In: *Proceedings of the International Conference on Computers, Communications, and Systems*, 2015, S. 196 – 200

- [142] DUTTA, A. ; SARMA, K. K.: SAR Image Segmentation using Wavelets and Gaussian Mixture Model. In: *Proceedings of the International Conference on Signal Processing and Integrated Networks (SPIN)*, 2014, S. 766 – 770
- [143] OGOR, B. ; HAESE-COAT, V. ; RONSIN, J.: SAR image segmentation by mathematical morphology and texture analysis. In: *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1996, S. 717 – 719
- [144] POODANCHI, M. ; AKBARIZADEH, G. ; SOBHNIFAR, E. ; ANSARI-ASL, K.: SAR Image Segmentation Using Morphological Thresholding. In: *Proceedings of the 6<sup>th</sup> Conference on Information and Knowledge Technology (IKT)*, 2014, S. 33 – 36
- [145] NOBRE, R. H. ; RODRIGUES, F. A. A. ; MARQUES, R. C. P. ; NOBRE, J. S. ; NETO, J. F. S. R. ; MEDEIROS, F. N. S.: SAR Image Segmentation With Rényi's Entropy. In: *IEEE Signal Processing Letters* 23 (2016), Nr. 11, S. 1551 – 1555
- [146] HUGHES, G.: On the Mean Accuracy of Statistical Pattern Recognizers. In: *IEEE Transactions on Information Theory* 14 (1968), Nr. 1, S. 55 – 63
- [147] HSU, P.-H.: Feature Extraction of hyperspectral images using wavelet and matching pursuit. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 62 (2007), S. 78 – 92
- [148] FALGE, R.: *Kategorisierung von Änderungen in Zeitreihen hochauflöster SAR-Satellitenbilder*, Institut für Photogrammetrie und Fernerkundung (IPF), Karlsruher Institut für Technologie (KIT); Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung (IOSB), Abteilung Szenenanalyse (SZA), Masterarbeit, 2015. – 77 S. – Archiviert in der Institutsbibliothek des Geodätischen Instituts (GIK) am Karlsruher Institut für Technologie (KIT)
- [149] RERIS, R. ; BROOKS, J. P.: Principal Component Analysis and Optimization: A Tutorial. In: *Proceedings of the 14<sup>th</sup> INFORMS Computing Society Conference (ICS)*, 2015, S. 212 – 225
- [150] Kapitel The Basics of Linear Principal Components Analysis. In: KEHO, Y.: *Computer and Information Science, Numerical Analysis and Scientific Computing, Principal Component Analysis*. InTech, 2012. – ISBN 9789535101956, 181 - 206
- [151] WOLD, S. ; ESBENSEN, K. ; GELADI, P.: Principal Component Analysis. In: *Chemometrics and Intelligent Laboratory Systems* 2 (1987), S. 37 – 52
- [152] ABDI, H. ; WILLIAMS, L. J.: Principal component analysis. In: *Wiley Interdisciplinary Reviews: Computational Statistics* 2 (2010), Nr. 4, S. 433 – 459
- [153] OWEN, J.-A.: Principal Component Analysis: Data Reduction and Simplification. In: *McNair Scholars Research Journal* 1, Article 2 (2014), S. 1 – 23
- [154] DOUGHERTY, G.: *Pattern Recognition and Classification - An Introduction*. Springer Verlag New York Heidelberg Dordrecht London, Springer Science+Business Media New York, 2013. – 196 S.
- [155] GREEN, A. A. ; BERMAN, M. ; SWITZER, P. ; CRAIG, M. D.: A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal. In: *IEEE Transactions on Geoscience and Remote Sensing* 26 (1988), Nr. 1, S. 65 – 74
- [156] COMON, P.: Independent component analysis, a new concept? In: *Signal Processing* 36 (1994), Nr. 3, S. 287 – 314
- [157] ATTIAS, H.: Independent Factor Analysis. In: *Neural Computation* 11 (1999), Nr. 4, S. 803 – 851
- [158] JAIN, A. K. ; MURTY, M. N. ; FLYNN, P. J.: Data Clustering: A Review. In: *ACM Computing Surveys (CSUR)* 32 (1999), Nr. 3, S. 264 – 323
- [159] MACQUEEN, J.: Some Methods for Classification and Analysis of Multivariate Observations. In: *Proceedings of the 5<sup>th</sup> Berkeley Symposium on Mathematical Statistics and Probability* Bd. 1, 1967, S. 281 – 297
- [160] FUKUNAGA, K. ; HOSTETLER, L.: The Estimation of the Gradient of a Density Function, with Applications in Pattern Recognition. In: *IEEE Transactions on Information Theory* 21 (1975), Nr. 1, S. 32 – 40

- [161] BALL, G. H. ; HALL, D. J.: ISODATA, a novel method of data analysis and pattern classification / Stanford Research Institute, Menlo Park, California. 1965. – Technical Report. – 72 S.
- [162] AGGARWAL, C. C. (Hrsg.) ; REDDY, C. K. (Hrsg.): *Data Clustering Algorithms and Applications*. CRC Press, Taylor & Francis Group, 2014. – 622 S. – ISBN 9781466558212
- [163] YAN, M.: *Methods of Determining the Number of Clusters in a Data Set and a New Clustering Criterion*, Virginia Polytechnic Institute and State University, Diss., 2005. – 120 S.
- [164] ARBELAITZ, O. ; GURRUTXAGA, I. ; MUGUERZA, J. M. ; PÉREZ, J. M. ; PERONA, I.: An extensive comparative study of cluster validity indices. In: *Pattern Recognition* 46 (2013), Nr. 1, S. 243 – 256
- [165] CALIŃSKI, T. ; HARABASZ, J.: A dendrite method for cluster analysis. In: *Communications in Statistics-theory and Methods* 3 (1974), Nr. 1, S. 1 – 27
- [166] DAVIES, D. L. ; BOULDIN, D.: A Cluster Separation Measure. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* PAMI-1 (1979), Nr. 2, S. 224 – 227
- [167] ROUSSEEUW, P. J.: Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. In: *Journal of Computational and Applied Mathematics* 20 (1987), S. 53 – 65
- [168] TIBSHIRANI, R. ; WALTHER, G. ; HASTIE, T.: Estimating the number of clusters in a data set via the gap statistic. In: *Journal of the Royal Statistics Society Series B (Statistical Methodology)* 63 (2001), Nr. 2, S. 411 – 423
- [169] BHOLOWALIA, P. ; KUMAR, A.: EBK-Means: A Clustering Technique based on Elbow Method and K-Means in WSN. In: *International Journal of Computer Applications (0975 - 8887)* 105 (2014), Nr. 9, S. 17 – 24
- [170] KODINARIYA, T. M. ; MAKWANA, P. R.: Review on determining number of Cluster in K-Means Clustering. In: *International Journal of Advance Research in Computer Science and Management Studies* 1 (2013), Nr. 6, S. 90 – 95
- [171] COMANICIU, D. ; MEER, P.: Mean Shift: A Robust Approach Toward Feature Space Analysis. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24 (2002), Nr. 5, S. 603 – 619
- [172] LU, D. ; WENG, Q.: A survey of image classification methods and techniques for improving classification performance. In: *International Journal of Remote Sensing* 28 (2007), Nr. 5, S. 823 – 870
- [173] LI, M. ; ZANG, S. ; ZHANG, B. ; LI, S. ; WU, C.: A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. In: *European Journal of Remote Sensing* 47 (2014), S. 389 – 411
- [174] BENZ, U. C. ; HOFMANN, P. ; WILLHAUCK, G. ; LINGENFELDER, I. ; HEYNEN, M.: Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58 (2004), S. 239 – 258
- [175] TIZHOOSH, H. R.: *Fuzzy-Bildverarbeitung: Einführung in Theorie und Praxis*. Springer-Verlag Berlin Heidelberg New York, 1998. – 242 S. – ISBN 3540631372
- [176] NEDELJKOVIC, I.: Image Classification based on Fuzzy Logic. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Commission VI* Bd. 34, Part XXX, 2006, S. 1 – 6
- [177] BOLDT, M. ; SCHULZ, K.: Change Detection in Time Series of High Resolution SAR Satellite Images. In: *Proceedings of SPIE, Earth Resources and Environmental Remote Sensing/GIS Applications III* Bd. 8538, 2012, S. 853806–1 – 853806–9
- [178] EINEDER, M. ; FRITZ, T. ; MITTERMAYER, J. ; ROTH, A. ; BOERNER, E. ; BREIT, H.: TerraSAR-X Ground Segment, Basic Product Specification Document / Deutsches Zentrum für Luft- und Raumfahrt DLR. 2008. – Forschungsbericht. – 103 S.
- [179] WEYDAHL, D. J. ; ELDHUSSET, K.: Geolocation accuracy of TSX spotlight image data. In: *Proceedings of the 8<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2010, S. 544 – 547
- [180] WANG, J. ; BALZ, T. ; LIAO, M.: Absolute geolocation accuracy of high-resolution spotlight TerraSAR-X imagery - validation in Wuhan. In: *Geo-Spatial Information Science* 19 (2016), Nr. 4, S. 267 – 272

- [181] LI, Z. ; BETHEL, J.: Image Coregistration in SAR Interferometry. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XXXVII, Part B1, 2008, S. 433 – 438
- [182] DANUDIRDJO, D. ; HIROSE, A.: Local Subpixel Coregistration of Interferometric Synthetic Aperture Radar Images Based on Fractal Models. In: *IEEE Transactions on Geoscience and Remote Sensing* 51 (2013), Nr. 7, S. 4292 – 4301
- [183] DEKRA REAL ESTATE EXPERTISE GMBH: DEKRA-Bericht Auswertung Immobilienwirtschaftlicher Daten zu Einfamilienhäusern. Untertürkheimer Straße 25, 66117 Saarbrücken, 2008. – Forschungsbericht. – 41 S.
- [184] WEINMANN, M.: *Reconstruction and Analysis of 3D Scenes: From Irregularly Distributed 3D Points to Object Classes*. Springer International Publishing Switzerland, 2016. – 233 S. – ISBN 9783319292441
- [185] GILANI, S. O. ; JAMIL, M. ; FAZAL, Z. ; NAVID, M. S. ; SAKINA, R.: Automated Scene Analysis by Image Feature Extraction. In: *Proceedings of the IEEE 14<sup>th</sup> International Conference on Dependable, Autonomic and Secure Computing, 14<sup>th</sup> International Conference on Pervasive Intelligence and Computing, 2<sup>nd</sup> International Conference on Big Data Intelligence and Computing and Cyber Science and Technology Congress*, 2016, S. 530 – 536
- [186] BURGER, W. ; BURGE, M. J.: *Digitale Bildverarbeitung Eine Einführung mit Java und ImageJ*. 2. Springer Verlag Berlin Heidelberg, 2005, 2006. – 514 S. – ISBN 3540309403
- [187] HU, M.-K.: Visual Pattern Recognition by Moment Invariants. In: *IRE Transactions on Information Theory* 8 (1962), S. 179 – 187
- [188] DALLA MURA, M. ; BENEDIKTSSON, J. A. ; BRUZZONE, L.: Modeling Structural Information for Building Extraction with Morphological Attribute Filters. In: *Proceedings of SPIE, Image and Signal Processing for Remote Sensing XV* Bd. 7477, 2009, S. 747703–1 – 747703–9
- [189] PEDERGNANA, M. ; MARPU, P. R. ; DALLA MURA, M. ; BENEDIKTSSON, J. A. ; BRUZZONE, L.: Classification of Remote Sensing Optical and LiDAR Data Using Extended Attribute Profiles. In: *IEEE Journal of Selected Topics in Signal Processing* 6 (2012), S. 856–865
- [190] FALCO, N. ; DALLA MURA, M. ; BOVOLO, F. ; BENEDIKTSSON, J. A. ; BRUZZONE, L.: Change Detection in VHR Images Based on Morphological Attribute Profiles. In: *IEEE Geoscience and Remote Sensing Letters* 10 (2013), S. 636 – 640
- [191] CHINI, M. ; PACIFICI, F. ; EMERY, W. J.: Morphological Operators Applied to X-Band SAR for Urban Land Use Classification. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2009, S. 506 – 509
- [192] MAKSYMIUK, O. ; BRENNER, A. ; STILLA, U.: Detection of stationary vehicles in airborne decimeter resolution SAR intensity images using morphological attribute filters. In: SEYFERT (Hrsg.): *33. Wissenschaftlich-Technische Jahrestagung der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation e.V. (DGPF), Dreiländertagung DGPF, OVG, SGPF* Bd. 22, 2013, S. 391 – 400
- [193] DUMITRU, C. O. ; SINGH, J. ; DATCU, M.: Selection of relevant features and TerraSAR-X products for classification of high resolution SAR images. In: *Proceedings of the 9<sup>th</sup> European Conference on Synthetic Aperture Radar (EUSAR)*, 2012, S. 243 – 246
- [194] ZHAO, J. ; GUO, W. ; CUI, S. ; ZHANG, Z. ; YU, W.: Convolutional Neural Network for SAR Image Classification at Patch Level. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, S. 945 – 948
- [195] GUPTA, S. ; KUMAR, S. ; GARG, A. ; SINGH, D. ; RAJPUR, N. S.: Class Wise Optimal Feature Selection for Land Cover Classification Using SAR Data. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, S. 68 – 71
- [196] MA, Y. ; ZENG, K. ; ZHAO, C. ; DING, X. ; HE, M.: Feature Selection and Classification of Oil Spills in SAR Image Based on Statistics and Artificial Neural Networks. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2014, S. 569 – 571

- [197] ULABY, F. T. ; MOORE, R. K. ; FUNG, A. K.: *Microwave Remote Sensing: Active and Passive. Volume II: Radar Remote Sensing and Surface Scattering and Emission Theory*. Addison-Wesley Publishing Company, Advanced Book Program / World Science Division, Reading, Massachusetts, 1982. – 1064 S. – ISBN 0201107600
- [198] GÓMEZ, W. ; PEREIRA, W. C. A. ; INFANTOSI, A. F. C.: Analysis of Co-Occurrence Texture Statistics as a Function of Gray-Level Quantization for Classifying Breast Ultrasound. In: *IEEE Transactions on Medical Imaging* 31 (2012), Nr. 10, S. 1889 – 1899
- [199] BOLDT, M. ; SCHULZ, K. ; THIELE, A. ; HINZ, S.: Using Morphological Differential Attribute Profiles for Change Categorization in High Resolution SAR Images. In: *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences; ISPRS Hannover Workshop Bd. XL-1/W1*, 2013, S. 29 – 34
- [200] HERING, E. ; MARTIN, R. ; STOHRER, M.: *Physik für Ingenieure*. 8. Auflage. Springer-Verlag Berlin Heidelberg, 2002. – 744 S. – ISBN 3540429646
- [201] HUANG, Z. ; LENG, J.: Analysis of Hu's Moment Invariants on Image Scaling and Rotation. In: *Proceedings of the 2<sup>nd</sup> International Conference on Computer Engineering and Technology (ICCET)*, 2010, S. 476 – 480
- [202] QUATTONI, A. ; COLLINS, M. ; DARRELL, T.: Transfer Learning for Image Classification with Sparse Prototype Representations. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2008, S. 8
- [203] ARTHUR, D. ; VASSILVITSKII, S.: K-means++: The Advantages of Careful Seeding. In: *Proceedings of the 18<sup>th</sup> Annual ACM-SIAM Symposium on Discrete Algorithms (SODA)*, 2007, S. 1027 – 1035
- [204] SAMMON, J. W.: A Nonlinear Mapping for Data Structure Analysis. In: *IEEE Transactions on Computers* C-18 (1969), Nr. 5, S. 401 – 409
- [205] BOLDT, M. ; THIELE, A. ; SCHULZ, K. ; HINZ, S.: GIS Based Ground Moving Target Indication in Time Series of SAR Amplitude Images. In: *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015, S. 4133 – 4136
- [206] NETO, A. M. ; VICTORINO, A. C. ; FANTONI, I. ; ZAMPIERI, D. E. ; FERREIRA, J. V. ; LIMA, D. A.: Image Processing Using Pearson's Correlation Coefficient: Applications on Autonomous Robotics. In: *Proceedings of the 13<sup>th</sup> International Conference on Mobile Robots and Competitions (Robotica 2013)*, 2013, S. 14 – 19
- [207] HINZ, S. ; KURZ, F. ; WEIHING, D. ; SUCHANDT, S.: Spatio-Temporal Matching of Moving Objects in Optical and SAR Data. In: *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences (PIA 2007)* Bd. 36-3/W49A, 2007, S. 155 – 160
- [208] HINZ, S. ; MEYER, F. ; LAIKA, A. ; BAMLER, R.: Spaceborne Traffic Monitoring with Dual Channel Synthetic Aperture Radar - Theory and Experiments. In: *Proceedings of Computer Vision and Pattern Recognition (CVPR 2005)*, 2005, S. 57 – 65
- [209] FAWCETT, T.: An introduction to ROC analysis. In: *Pattern Recognition Letters* 27 (2006), S. 861 – 874
- [210] BOLDT, M. ; THIELE, A. ; SCHULZ, K. ; HINZ, S.: SAR Image Segmentation Using Morphological Attribute Profiles. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. XL-2, 2014, S. 39 – 44