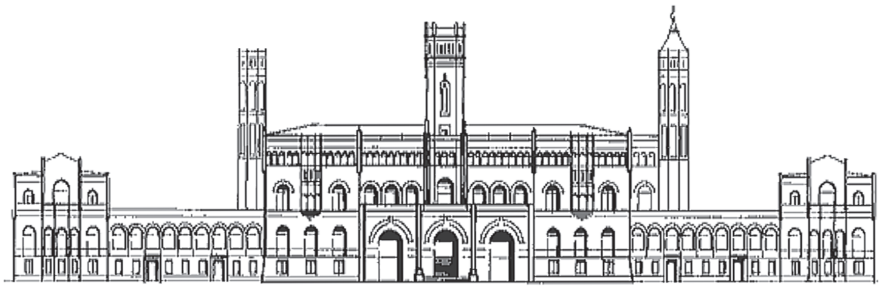

LEIBNIZ UNIVERSITÄT HANNOVER

INSTITUT FÜR
PHOTOGRAMMETRIE UND GEOINFORMATION

INSTITUT FÜR
INFORMATIONSVERARBEITUNG

Masterarbeit

Automatische Verifikation und Fortführung von ATKIS-Daten mit Hilfe von Radardaten

Shoaib Nezam

Betreuer:	Dipl.-Ing. Jan Dirk Wegner,
	Dipl.-Ing. Marcel Ziems,
	Dr.-Ing. Sönke Müller
Erstprüfer:	Prof. Dr.-Ing. Jörn Ostermann
Zweitprüfer:	Prof. Dr.-Ing. Uwe Sörgel

Aufgabenstellung

Das Amtliche Topographisch-Kartographische Informationssystem (ATKIS) ist eine umfangreiche Datenbasis, welche Vektordaten mit detaillierten Informationen über Objekte (z.B. Ackerflächen, Wald- und Siedlungsbereiche, Straßen) enthält. Damit bietet ATKIS die Basis für zahlreiche Entscheidungen mit Raumbezug für die Bereiche Wirtschaft und Verwaltung. Die Verifikation und Fortführung dieser Daten ist besonders aufwendig und macht automatisierte Ansätze notwendig. So wurden am TNT bereits Verfahren für einen automatischen Abgleich mit aktuellen Satellitenbildern entwickelt. Hierbei ist die automatische Interpretation der Bilddaten als zentrale Herausforderung anzusehen.
Seit einigen Jahren sind neben den herkömmlichen optischen Satelliten verstärkt alternative Sensorsysteme verfügbar. So erreicht die neueste Generation von Radar-Sensoren mit synthetischer Apertur (SAR), wie z.B. der deutsche Satellit TerraSAR-X, SAR-Bilder mit bisher ungekannter räumlicher Auflösung. Gegenüber optischen Sensoren haben SAR-Sensoren den großen Vorteil, dass sie Bilder unabhängig vom Tageslicht und von Wolkenbedeckung aufnehmen können. Außerdem werden aufgrund des speziellen SAR-Aufnahmeprinzips Objekteigenschaften sichtbar, die in optischen Daten nicht oder nur schwer erkannt werden können. Dies macht die Nutzung von SAR-Bildern für die Fortführung von ATKIS interessant.

Im Rahmen der Masterarbeit soll untersucht werden, welches Potential automatisierte Verfahren zur Verifikation und Fortführung der ATKIS Datenbasis mit TerraSAR-X Daten haben. Hierfür soll ein bereits bestehender Klassifikationsalgorithmus für die Nutzung von SAR-Bildern weiterentwickelt werden. Das zugrunde liegende „Markov Random Field“-Verfahren bezieht zur Pixelklassifikation lokale Nachbarschaften mit ein. Im Bereich der Computer Vision wurde dieses Verfahren bereits mit Erfolg auf SAR-Bildern angewendet. Allerdings gehen die bereits existierenden Ansätze bei der Wahl der Likelihood-Funktion zumeist von einer Normalverteilung bzw. einer Gleichverteilung der Grauwerte aus. Diese Annahme ist für die vorliegenden Daten jedoch nicht zutreffend. Dementsprechend soll im Rahmen dieser Arbeit der verwendete a priori-Term und die Likelihood-Funktion für die Anwendung auf SAR-Amplitudenbilder optimiert werden. Hierfür ist eine automatische Parametrisierung auf Basis der jeweils vorliegenden Daten erforderlich.
Auf Grundlage der Ergebnisse sollen differenzierte Aussagen zur Eignung von SAR-Bildern im Hinblick auf verschiedene ATKIS-Objekte getroffen werden. Als Entwicklungsplattform dient die Open Source Bibliothek „ORFEO Toolbox“ (OTB) in der Programmiersprache C++.

Eigenständigkeitserklärung

Shoaib Nezam
Trockener Kamp 5
31139 Hildesheim

Matrikelnummer: 2235750
Studienrichtung: Informatik

Ich erkläre hiermit, dass ich die vorliegende Arbeit selbständig angefertigt und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet habe.

Hannover, den 24. November 2009

Danksagung

An dieser Stelle möchte ich mich bei Jan Dirk Wenger, Marcel Ziems und Sönke Müller für die Betreuung und Unterstützung während der Masterarbeit bedanken. Alle standen mir bei Fragen jederzeit und hilfsbereit zur Verfügung.

Desweiteren danke ich Prof. Dr. Jean-Marie Nicolas und Celine Tison aus Frankreich, die mir trotz der Distanzschwierigkeiten sehr behilflich waren und sich für meine Fragen immer Zeit nahmen.

Ebenso bedanke ich mich bei meinen Freunden Ajmal und Christian, die mir bei sprachlicher Korrektur und technischen Herausforderungen halfen.

Zuletzt danke ich meiner Freundin Vujdan und meinen Eltern für deren Unterstützung in jeglicher Hinsicht während der Dauer der Masterarbeit und während meines Studiums.

Kurzfassung

Radarsensoren mit Synthetischer Apertur (SAR) besitzen gegenüber optischen Sensoren den Vorteil, dass sie von Wetterbedingungen und Tageszeiten weitgehend unabhängig sind.

In dieser Masterarbeit wird das Potential hochauflösender TerraSAR-X Bilder für eine Fortführung und Verifikation der Amtlichen Topographisches-Kartographisches Informationssystems (ATKIS) Datenbasis untersucht. Hierzu wird ein Klassifikationsverfahren, basierend auf dem Bayeschen Ansatz verwendet, wobei der a priori-Term mit einen Markoff-Zufallsfeld modelliert und die Likelihood-Funktion mittels Fisher-Verteilung abgeschätzt wird.

Mit der Fisher-Verteilung lassen sich Siedlungsbereiche, die durch ihre Heterogenität gekennzeichnet sind, sowie ländliche Regionen in SAR- Amplitudenbildern charakterisieren. Die Parametrisierung der Fisher-Verteilung erfolgt innerhalb einer überwachten Trainingsphase. Hierbei werden durch Lernstichproben die interessierenden Klassen mit Hilfe der „Second-Kind Statistics“ abgeschätzt.

Die Klassifikation wird auf zwei TerraSAR-X Bilder der Städte Fuhrberg (Deutschland) und Algier (Algerien) angewandt und die Güte der Klassifikationsergebnisse anhand eines manuell erstellten Referenzbildes bewertet.

Die Ergebnisse zeigen, dass sich insbesondere die Klasse Ackerland/Grünland für ATKIS eignet. Weiterhin sind die Klassen Straße/Landebahn und Siedlung/Industrie zufriedenstellend abgebildet und haben somit Potential für eine Fortführung von ATKIS. Die Klasse Wald hingegen ist mit unserem Ansatz nicht ausreichend geeignet.

Abstract

Radar sensors with Synthetic Aperture (SAR) provide significant advantages compared to optical sensors, since they are largely unaffected by weather conditions and time of day.

In this thesis, the potential of high-resolution TerraSAR-X images for updating and verification of the ATKIS database is examined. A classification method based on the Bayesian approach is designed, where we model the prior term with a Markov random field and the likelihood function using Fisher distributions.

Fisher distributions are well suited to model urban areas, which are characterized by their heterogeneity, as well as rural areas in SAR amplitude images. The parameterization of the Fisher distribution is conducted during a supervised training step. We estimated each class of interest with the help of the „Second-Kind Statistics“ by taking training areas.

The classification is applied to two TerraSAR-X images of the cities Fuhrberg (Germany) and Algier (Algeria). Classification quality is assessed based on manually generated ground truth.

The findings demonstrate that the class of cropland/grassland is ideally suited for ATKIS. Furthermore, the classes of road/runway and settlement/industry can be classified as satisfying. In addition, these classes are including some potential for updating ATKIS. Contrary, the class of forest is not appropriate with our approach.

Inhaltsverzeichnis

1. Einleitung **1**
1.1. Motivation . . . 1
1.2. Ziel der Arbeit . . . 2
1.3. Aufbau der Arbeit . . . 3

2. Grundlagen zur Radarfernerkundung **4**
2.1. Allgemeine Physikalische Grundlagen . . . 4
2.2. Grundprinzip und Auflösung abbildender Radarsysteme . . . 6
2.3. Charakteristika von SAR-Bildern . . . 10
2.3.1. Geometrische Eigenschaften . . . 10
2.3.2. Radiometrische Eigenschaften . . . 11
2.4. Der Speckle-Effekt . . . 15

3. Statistische Modellierung und Methodik zur Parameterabschätzung **18**
3.1. Statistische Begriffe . . . 19
3.2. Stand der Technik: Statistische Modellierung von SAR-Daten . . . 21
3.2.1. Standard Modell . . . 21
3.2.2. Empirisches Modell . . . 24
3.2.3. Produkt Modell . . . 26
3.3. Die Fisher-Verteilung . . . 27
3.4. Parameterabschätzung durch: „Second-Kind Statistics“ . . . 29
3.4.1. Die Mellin Transformation . . . 30
3.4.2. Wichtige Definitionen der Second-Kind Statistics . . . 31
3.4.3. Parameterabschätzung der Fisher-Verteilung . . . 32
3.5. Validierungen des Fisher-Modells . . . 34

4. Klassifikation mit Markoff-Zufallsfeldern **36**
4.1. Klassifikationsansätze in der Radarfernerkundung . . . 36
4.2. Mathematische Grundlagen und Begriffe . . . 41
4.2.1. Zufallsfelder . . . 41
4.2.2. Bayes-Theorem . . . 43
4.3. Markoff-Zufallsfelder und Gibbs-Verteilung . . . 43
4.4. Modellierung . . . 48
4.5. Optimierung . . . 50

5. Ergebnisse **53**
5.1. Datengrundlage . . . 53
5.2. Klassifikationsstrategie . . . 54
5.3. Klassifikationsergebnisse der TerraSAR-X Bilder von Fuhrberg . . . 56
5.3.1. Trainingsphase (Anlernen des Klassifikators) . . . 56

5.3.2. Ergebnis Region Fuhrberg 59
5.3.3. Ergebnis Region Fuhrberg mit Speckle-Filter 60
5.4. Klassifikationsergebnisse des TerraSAR-X Bildes von Algier 62
5.4.1. Trainingsphase (Anlernen des Klassifikators) 62
5.4.2. Ergebnis Region Algier 64
5.5. Bewertung der Ergebnisse im Hinblick auf die ATKIS Datenbasis 66

6. Zusammenfassung und Ausblick **67**
6.1. Zusammenfassung 67
6.2. Schlussfolgerung und Ausblick 68

Literaturverzeichnis **73**

Abbildungsverzeichnis **74**

Tabellenverzeichnis **77**

A. Anhang **78**
A.1. Tabellen und Diagramme aus der Trainingsphase 78
A.2. Klassifikationsergebnisse unter Verwendung des Gauss-Modells 81
A.2.1. Ergebnisse Furhberg 81
A.2.2. Ergebnisse Furhberg mit Speckle-Filter 82
A.2.3. Ergebnisse Algier 83

1. Einleitung

1.1. Motivation

Der rasante Fortschritt in der automatisierten Datenverarbeitung und der damit einhergehende Aufbau unterschiedlichster Informationssysteme haben zur Folge, dass eine rein graphische Darstellung der Erdoberfläche in analoger Form den Anforderungen privater und öffentlicher Nutzer nicht mehr genügt.

Mit dem Amtlichen Topographisch-Kartographischen Informationssystem (ATKIS) bieten die Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland Informationen über die Topographie der Erdoberfläche in digitaler datenverarbeitungsgerechter Form an. Diese stellen eine umfangreiche, bundesweit einheitliche Datenbasis dar, welche Vektordaten mit detaillierten Informationen über Objekte (wie z. B. Wald-, Acker-, oder Siedlungsflächen, Straßen, etc.) sowie ihre räumliche Lage und Form in einem Landeskoordinatensystem beinhaltet. Damit bietet ATKIS die Basis für zahlreiche Entscheidungen mit Raumbezug, u.a. für die Bereiche Wirtschaft, Verwaltung, Landesplanung, Verkehrsplanung, Geologie, Forstwirtschaft, etc.

Die Verifikation und Fortführung der ATKIS Datenbasis ist besonders aufwendig und macht automatisierte Ansätze notwendig. In der Bildanalyse befassen sich seit einigen Jahren zahlreiche Forschungsarbeiten mit voll automatischer Objektextraktion und wissensbasierter Bildinterpretation [1], [2], [3]. So wurden bereits am Institut für Theoretische Nachrichtentechnik und Informationsverarbeitung (TNT) sowie am Institut für Photogrammmetrie und Geoinformation (IPI) der Leibniz Universität Hannover Verfahren mit einem automatischen Abgleich mittels aktueller Satellitenbilder entwickelt [4]. Hierbei ist die automatische Interpretation der Bilddaten als zentrale Herausforderung anzusehen.

Zur Verifikation und Fortführung der ATKIS Datenbasis wurden bisher hauptsächlich optische Bilddaten verwendet, die im sichtbaren und im nahen Infrarotbereich des elektromagnetischen Spektrums Reflexionen der Erdoberfläche aufzeichnen.

Seit einigen Jahren kommen, neben herkömmlichen optischen Satelliten, zunehmend luftgestützte oder satellitengetragene Radarsysteme zum Einsatz. So erreichen Radarsensoren mit Synthetischer Apertur (SAR), wie der deutsche Satellit TerraSAR-X, Bilder mit einer Auflösung von bis zu einem halben Meter.

Radar ist ein aktives Verfahren, das selbst ausgesendete und an der Erdoberfläche reflektierte Mikrowellenstrahlung aufzeichnet. Aus diesem Verfahren ergibt sich eine Reihe von Vorteilen gegenüber optischen Sensoren. Die wesentlichen Vorteile von Radar liegen in der Unabhängigkeit der Aufnahme von der Tageszeit und wegen der hohen Durchlässigkeit der Atmosphäre für Mikrowellenstrahlung, in der weitgehenden Unabhängigkeit von Wit-

Abb. 1.1.: optisches Satellitenbild von IKONOS (links) und Radarbild vom TerraSAR-X (rechts). Während optische Bilder die chemischen Eigenschaften der Erdoberfläche abbilden, sind in Radarbildern die physikalischen Eigenschaften erfasst.

terungsverhältnissen (z. B. Wolkenbedeckung). Außerdem werden aufgrund des speziellen SAR-Aufnahmeprinzips Objekteigenschaften sichtbar, die in optischen Daten nur schwer erkannt werden können (siehe Abb. 1.1).

Das immer größer werdende Auflösungsvermögen der SAR-Sensoren erlaubt zunehmend auch die Erkennung von Straßen und Gebäuden. Dies macht die Nutzung von SAR-Bildern für die Fortführung von ATKIS interessant.

1.2. Ziel der Arbeit

SAR stellt ein mächtiges Werkzeug zur Erdbeobachtung dar. Die Klassifikation der Amplitudenbilder der SAR-Daten ist allerdings aufgrund des „Speckle-Effekt“ (siehe Abschnitt 2.4), welches einem starken multiplikativen Rauschen entspricht, besonders problematisch (siehe Abb. 1.1). Dies macht die Nutzung typischer Klassifikationsansätze in der Bildanalyse nur beschränkt möglich.

In dieser Arbeit wird ein für optische Satellitenbilddaten bestehendes Verfahren zur Klassifikation von SAR-Bilddaten angepasst und erweitert. Die zugrunde liegenden Markoff-Zufallsfelder beziehen zur Pixelklassifikation lokale Nachbarschaften mit ein. Allerdings geht der bereits existierende Ansatz bei der Wahl der Likelihood-Funktion von einer Gauss-Verteilung aus. Diese Vorgehensweise ist nicht optimal, da die Bedingung der Gauss-Verteilung bei den verwendeten Merkmalen nur näherungsweise erfüllt ist.

Der Schwerpunkt dieser Arbeit liegt daher in der Untersuchung optimaler SAR-Statistik sowie der Modellierung des Markoff-Zufallsfeldes angepasst auf SAR-Amplitudenbilder. Durch eine eingehende Analyse der erzielten Klassifikationsergebnisse soll das Potential von hoch auflösenden Bilddaten des Radarsensors TerraSAR-X für die Verifikation und Fortführung von ATKIS Datenbasis im Hinblick auf verschiedene ATKIS Objektklassen untersucht werden.

1.3. Aufbau der Arbeit

Die vorliegenden Masterarbeit beschäftigt sich in Kapitel 2 zunächst mit den Grundlagen der Radarfernerkundung. Der Schwerpunkt liegt dabei auf den typischen Eigenschaften und Merkmalen von SAR-Bilddaten.

Kapitel 3 geht vertiefend auf die statistische Modellierung von SAR-Bildern ein und stellt verschiedene Ansätze aus der Literatur vor. Es werden Stärken und Schwächen dieser Ansätze diskutiert und daraus Schlussfolgerungen für die Arbeit abgeleitet. Hierbei werden die Fisher-Verteilung und ihre Parametrisierung durch die „Second-Kind Statistics“ in den Vordergrund gestellt.

Kapitel 4 hat seinen Schwerpunkt in der Klassifikation mit Markoff-Zufallsfeldern gesetzt. Es wird zunächst ein Überblick über die Klassifikationsmöglichkeiten von SAR-Bildern gegeben. Der Hauptteil des Kapitels beschäftigt sich mit der Anpassung und Modellierung des Markoff-Zufallfeldes für SAR-Bilder.

Kapitel 5 stellt schließlich die Klassifikationsstrategie sowie die Ergebnisse anhand zweier hochauflösender SAR-Bilder der TerraSAR-X Satelliten vor. Die Klassifikationsergebnisse werden mit einem manuell erstellten Referenzbild mit einem Operator automatsich verglichen um daraus Rückschlüsse auf die Möglichkeit zur Fortführung und Verifikation von AKTIS zu ziehen.

Eine Zusammenfassung der Arbeit sowie Ansatzpunkte für zukünftige Verbesserungen der Klassifikation von SAR-Bildern gibt Kapitel 6.

2. Grundlagen zur Radarfernerkundung

In diesem Kapitel werden die Grundlagen von Radar behandelt. Radar ist ein Akronym für Radio Detection and Ranging und wurde ursprünglich entwickelt, um mit Radiowellen Objekte aufzuspüren (Englisch: Detection) und deren Abstand (Englisch: Range) bzw. Position zu bestimmen.

Durch die Nutzung verschiedener Bereiche des elektromagnetischen Spektrums unterscheiden sich Radarbilder von optischen Bildern. Diese unterschiede werden detailliert in Abschnitt 2.1 beschrieben. In Abschnitt 2.2 wird auf das Grundprinzip Abbildender Radarsysteme eingegangen. Aufgrund der Art der Abbildung sowie der Verwendung eines kohärenten Sende/Empfangssystem ergeben sich besondere Charakteristika (Abschnitt 2.3) von Radarbildern. Ein typischer Effekt eines kohärenten Abbildungssystems ist die starke Körnigkeit (Speckle) von flächigen Zielen in den Aufnahmen, worauf in Abschnitt 2.4 eingegangen wird.

2.1. Allgemeine Physikalische Grundlagen

In der Fernerkundung dient elektromagnetische Strahlung als Informationsträger zwischen dem zu untersuchenden Objekt und dem Fernerkundungssensor. Die vom Objekt reflektierte oder emittierte Strahlung wird detektiert und lässt Aussagen über dessen Eigenschaften zu. Daraus lassen sich mittels spezieller Auswerteverfahren wiederum abstrakte Informationen wie z.B. Landoberflächenkategorien (Siedlung, Wald, Wasser, ...) ableiten.

Die Eigenschaften spezifischer Wellenlängen können anhand des elektromagnetischen Spektrums analysiert werden. Dementsprechend lassen sich Rückschlüsse auf die Wirkung der Strahlung treffen. In der Abb. 2.1 werden verschiedene Spektralbereiche, ihre Bezeichnung, ihre Transmissivität durch die Atmosphäre und die wichtigsten Aufnahmeverfahren dargestellt. Zur Kennzeichnung und Trennung der Spektralbereiche werden die Wellenlänge λ und die Frequenz f verwendet. Für diese Masterarbeit sind die von IKONOS (orange) bzw. von TerraSAR-X verwendeten Spektralbereiche (gelbe) von Bedeutung.

Natürliche Quellen elektromagnetischer Strahlung sind die Sonne und die Erde, die aufgrund ihrer Temperatur ein kontinuierliches Spektrum aussenden. Hierbei ist die Strahlungsenergie der Sonne bedeutend höher als die der Erde. Sie hat ihr Strahlungsmaximum bei ca. 480 *nm* im Bereich des sichtbaren Lichtes. Das Maximum der Erdstrahlung liegt bei ca. 10 μm im thermalen Infrarot.

In der Fernerkundung unterscheidet man zwischen passiven und aktiven System. Während passive Systeme die natürliche elektromagnetische Strahlung detektieren erzeugen aktive Systeme künstlich die elektromagnetische Strahlung selbst.

In dieser Arbeit werden Daten des Radarsystems TerraSAR-X verwendet. Radar ist ein aktives Fernerkundungsverfahren und nutzt den Spektralbereich der Mikrowellen. Daraus ergeben sich gegenüber dem Gebiet der optischen Fernerkundung, die hauptsächlich im Bereich des Sichtbaren Lichtes und nahen Infrarots aufzeichnet, prinzipielle Vorteile.

Die Aufnahme der Daten im Bereich der Mikrowellen ist weitgehend unabhängig vom Tageslicht und Witterungsverhältnissen. Daher können die Daten, die Verfügbarkeit entsprechender Sensoren vorausgesetzt, in stetiger zeitlicher Auflösung erfasst werden. Ein weiterer Vorteil des aktiven Aufnahmeverfahrens liegt in dem expliziten Wissen über die Eigenschaften der Polarisation, Wellenlänge, Phase und der gesendeten Leistung. Durch die Auswertung des am Sensor detektierten, rückgestreuten Anteils kann die Interaktion mit der Erdoberfläche sehr genau beschrieben bzw. physikalisch modelliert und Informationen über ihre Eigenschaften abgeleitet werden. Hierbei werden grundsätzlich andere Informationen über Geländeobjekte als optische Fernerkundungssysteme (siehe Abschnitt 2.3) geliefert.

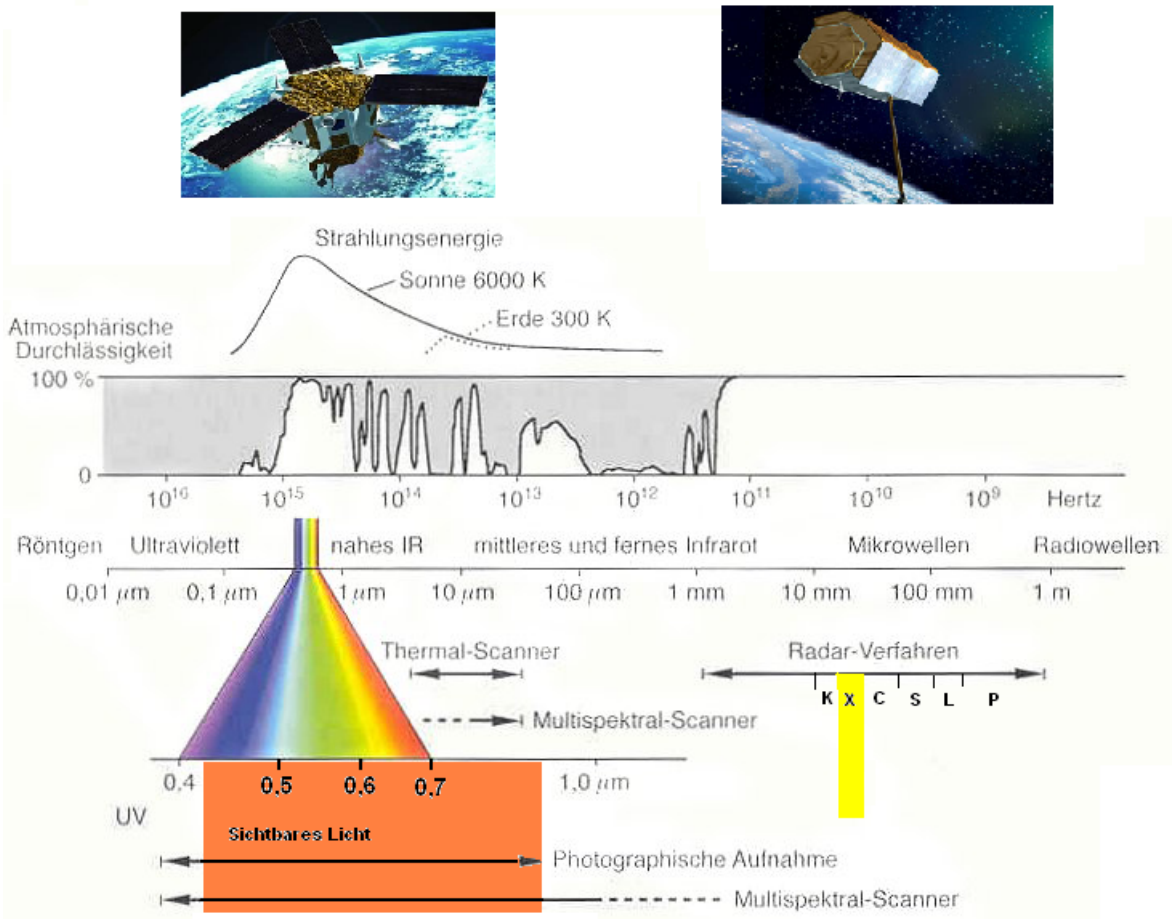

Abb. 2.1.: Das Elektromagnetische Spektrum. Markiert sind Frequenzband der IKONOS-Kanäle (orange) und des von TerraSAR-X genutzten X-Bandes (nach [5]).

2.2. Grundprinzip und Auflösung abbildender Radarsysteme

Ein besonderes Merkmal abbildender Radarsysteme ist die Aufnahmegeometrie. Der Sensor sendet über die Radarantenne extrem kurze, kohärente Mikrowellensignale senkrecht zu Flugrichtung schräg auf die Erdoberfläche (siehe Abb. 2.2). Diese Systeme werden als Seitensichtradar (SLAR: Side Looking Apertur Radar) bezeichnet. Die Seitensicht ist eine notwendige Voraussetzung, da für die räumliche Trennung der Signale die Laufzeit essentiell ist. Benachbarte Bodenpunkte in der Nähe des Nadirs können nicht aufgelöst werden, weil sie fast die gleiche Laufzeit haben.

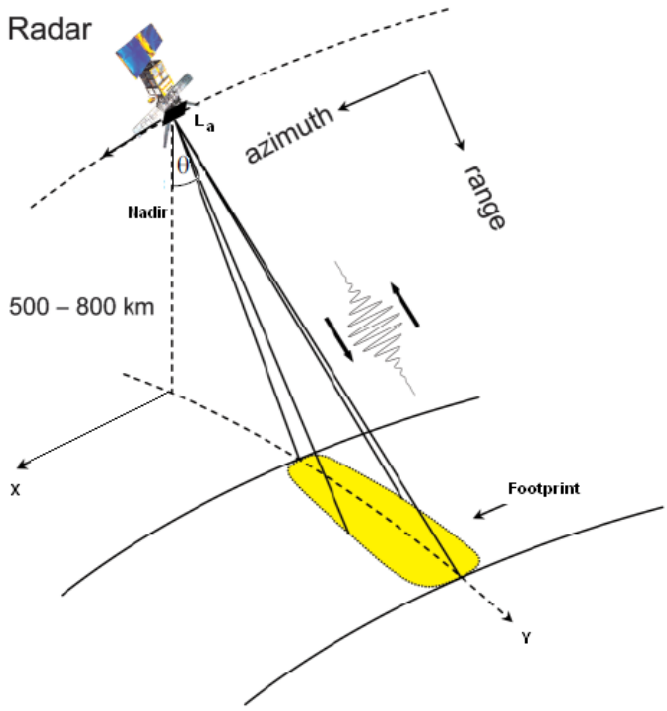

Abb. 2.2.: SAR-Aufnahmegeometrie (nach [6])

Durch eine spezielle Abstrahlcharakteristik wird die Energie auf einem bestimmten Bereich gebündelt. Der bestrahlte Bereich am Boden wird als Footprint bezeichnet. Aufgrund der Bündelung wird die Energie verstärkt, die als Antennengewinn bezeichnet wird. Das Signal wird am Boden reflektiert und ein Teil der Strahlung wird von der Antenne wieder empfangen.

Bei abbildenden Radarsystemen sind Sende- und Empfangseinheit oft identisch (monostatische Systeme), wobei die Antenne zwischen Sende- und Empfangsmodus umschaltet. Die vom Gelände zurückgestreuten Echos (Amplitude und Phase der gestreuten Wellen) werden in einem $I - Wert$ (In-Phase Component) und einem $Q - Wert$ (Quadrature Component) zerlegt und entsprechend der Position und Laufzeit in der zugehörigen Zeile und Spalte der Rohdatenmatrix als komplexe Zahl $I + jQ$ gespeichert. Die zweidimensionale Abbildung der Oberfläche wird aus den aufgenommenen komplexen Signalen generiert. Die orthogonalen Bildkoordinatenachsen sind die in Flugrichtung verlaufende Azimut-Achse und die senkrecht

zur Flugrichtung in Blickrichtung verlaufende Entfernungsachse.

Für abbildendende Radarsysteme gibt es im Wesentlichen zwei unterschiedliche Sensortypen:

- Systeme mit Realer Aperture (RAR: Real Aperture Radar)
- Systeme mit Synthetic Aperture (SAR: Synthetic Aperture Radar)

Beim System mit RAR wird jeder Bodenpunkt nur einmal beleuchtet. Die ausgesendeten Impulse sind so geschaltet, dass durch die Flugbewegung jeder Impuls eine neue Geländezeile quer zur Flugrichtung aufnimmt. Im Wesentlichen entsteht das Bild der Szene durch eine Aneinanderreihung der aufgenommenen Bildzeilen. Hingegen werden beim SAR die Radarsignale mit einer wesentlichen höheren Impulswiederholungsrate (PRF: Pulse Repetition Frequency) ausgestrahlt als beim RAR, was zu eine Steigerung der Auflösung in Flugrichtung führt.

Das grundlegende Konzept und die räumliche Auflösung von RAR und SAR werden im Folgenden beschrieben.

Auflösung in Entfernung

Bei den bildgebenden Radarsystemen können zwei Objektpunkte in der Entfernungsrichtung aufgelöst werden, wenn ihre beiden Signale u_1 und u_2 räumlich voneinander trennbar sind. Hierzu müssen sich ihre Laufzeiten (t_1 und t_2) voneinander um mindestens die Länge der Impulsdauer τ von einander unterscheiden: $|t_2 - t_1| \geq \tau$. Damit ergibt sich für die Auflösung (siehe Abb. 2.3) in Schrägentfernung (Slante Range) für RAR und SAR mit c für die Lichtgeschwindigkeit und Impulsdauer τ:

$$\delta_{sr} = \frac{c \cdot \tau}{2} \tag{2.1}$$

Da das Signal Hin-und Rückweg zurücklegen muss, folgt der Faktor zwei.
Projiziert man die Entfernungslösung mit dem Einfallswinkel θ auf den Boden (Ground Range) erhält man die Auflösung in Bodengeometrie:

$$\delta_{gr} = \frac{c \cdot \tau}{2sin\theta} = \frac{c}{2Bsin\theta} \tag{2.2}$$

Die Länge der Impulsdauer τ bzw. die Bandbreite $B = \frac{1}{\tau}$ sind also für die Auflösung in Entfernung entscheidend und nicht die Höhe des Sensors über den Grund. Die Pulsdauer τ fällt mit steigender Bandbreite.

Eine Verkürzung der Impulsdauer erhöht demnach die Auflösung in Entfernungsrichtung. Die Impulsdauer τ kann in der Praxis nicht beliebig verkleinert werden, da bei einer Verkürzung der Impulsdauer die zu sendende Energie steigt. Die Höhe der Energie ist wiederum Hardware beschränkt. Daher wird sich mit einem Trick beholfen: Hierbei wird anstelle eines kurzen Impulses ein zeitlich sehr viel ausgedehnteres, linearen frequenzmoduliertes Signal gesendet. Diese wird als Chirp bezeichnet. Nach dem Empfang des frequenzmodulierten Signals wird

es mit einem komplex konjugierten Chirp gefaltet (Matched-Filter-Ansatz). Durch diesen wird das erwünschte kurze Signal gesendet.

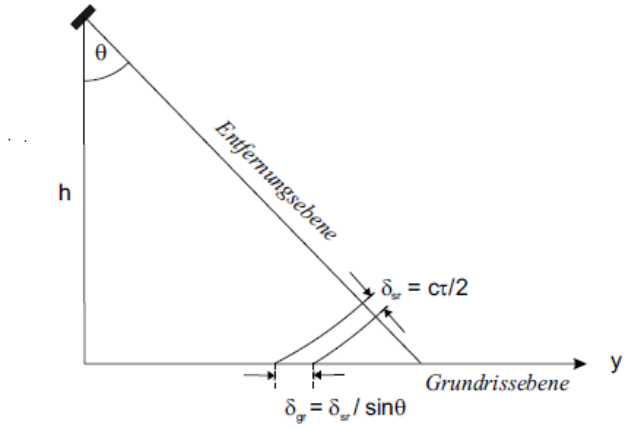

Abb. 2.3.: Auflösung in Entfernung und Grundrissebene (nach [7])

Auflösung in Azimut

Die geometrische Auflösung in Flugrichtung entspricht bei herkömmlichem RAR etwa der Breite des Footprints in Flugrichtung. Da im Prinzip ein Bodenpunkt nur einmal aufgenommen wird, können zwei Objekte nur unterschieden werden wenn sie nicht im gleichen Footprint liegen. Beim RAR hat eine Antenne der Länge L_a näherungsweise eine Öffnungswinkel von

$$\theta_a = \frac{\lambda}{L_a} \tag{2.3}$$

mit λ der Wellenlänge der emittierten Strahlung. Mit diesem Öffnungswinkel ergibt sich die geometrische Auflösung von RAR für eine bestimmte Entfernung R am Boden zu

$$\delta_{az}^{RAR} = R \cdot \theta_a \approx \frac{R \cdot \lambda}{L_a} \tag{2.4}$$

Zwei Objektpunkte müssen mindestens um die Breite des Footprints δ_{az}^{RAR} auseinander liegen, um aufgelöst werden zu können.

Die Auflösung in Azimut kann somit nur durch eine kürzere Wellenlänge, eine geringere Entfernung oder durch eine längere Antenne verbessert werden. Die Wellenlänge kann aber nicht beliebig verkleinert werden, weil mit zunehmender Frequenz die Atmosphären Dämpfung steigt (Siehe Abb. 2.1). Die Ausdehnung der Antenne ist durch den Träger begrenzt.

Durch das SAR-Prinzip wird die Azimutauflösung durch eine künstliche Verlängerung der Antenne erheblich verbessert. Dabei wird die PRF so erhöht, dass die Objektpunkte nahezu

kontinuierlich beleuchtet werden. Die Abbildung eines Objektes wird dann im Gegensatz zu RAR nicht nur durch eine Aufnahme sondern durch alle Aufnahmen erzeugt, in denen es enthalten ist. So ergibt sich die Länge der synthetischen Antenne L_{sa} aus der Länge der Flugstrecke des Sensors, innerhalb der sich ein Objektpunkt in der Antennenkeule befindet (vgl. Abb.2.4). L_{sa} entspricht also der RAR-Azimutauflösung:

$$L_{sa} = \delta_{az}^{RAR} \approx \frac{R \cdot \lambda}{L_a} \tag{2.5}$$

Die Winkelauflösung in Azimut θ_{sa} ist beim SAR doppelt so hoch wie beim Radar mit realer Apertur:

$$\theta_{sa} = \frac{\lambda}{2 \cdot L_{sa}} \tag{2.6}$$

Der Faktor 2 ist durch das nicht gleichzeitige Abstrahlen der einzelnen Antennenelemente beim SAR begründet, da es sowohl beim Hinweg als auch beim Rückweg zum Phasenunterschied kommt. Als maximale Auflösung in Azimut ergibt sich durch das einsetzen der $Gl.2.6$ in $Gl.2.4$:

$$\delta_{az}^{SAR} = R \cdot \theta_{sa} \approx \frac{R \cdot \lambda}{2L_{sa}} \approx \frac{L_a}{2} \tag{2.7}$$

Da die Azimutauflösung von SAR von der durch den Größenordnung der halben Antenne bestimmt wird, ist sie unabhängig von der Entfernung und Wellenlänge.

Für die Bildung der Synthetischen Apertur und das Zusammenfügen der einzelnen Aufnahmen gibt es mehrere Ansätze (vgl. [8]). Ein Ansatz basiert auf dem Doppler-Effekt. Hierbei macht man sich den Umstand zunutze, dass bei einer breiten Strahlenkeule jedes Objekt der Erdoberfläche bei einem Überflug mehrfach erfasst wird. Die kohärente Eigenschaft der Signale sowie der bekannte zeitliche Verlauf der Pulssende- und Empfangssequenzen erlauben später eine phasenkorrigierte Verarbeitung, da die verschiedenen Einzelechos eines Bodenpunktes mit Hilfe der Dopplerfrequenzen der zurückgestreuten Wellen zu trennen sind.

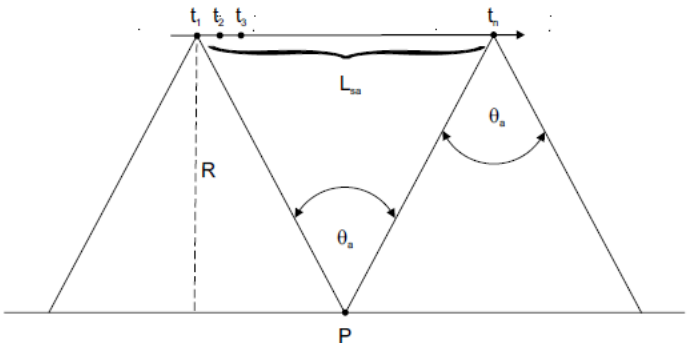

Abb. 2.4.: Geometrische Auflösung in Azimut: Länge des synthetischen Apertur L_{sa} (nach [7])

2.3. Charakteristika von SAR-Bildern

Aufgrund der Nutzung verschiedener Bereiche des elektromagnetischen Spektrums, der Art der Abbildung und der Verwendung eines kohärenten Sende/Empfangsystems unterscheiden sich Radarbilder in vielerlei Hinsicht von optischen Bildern. Für die Interpretation des Inhaltes von SAR-Bildern ist daher das Verständnis der Charakteristika von Radarbildern von grundlegender Bedeutung. Im Folgenden werden die wesentlichen geometrischen- und radiometrischen Eigenschaften von Radaraufnahmen beschrieben.

2.3.1. Geometrische Eigenschaften

Bei Radarbildern ergeben sich aufgrund der schrägen Sicht bei der Aufnahme einige besondere geometrische Effekte, die durch das Aufnahmeverfahren und die Geländeform verursacht werden. Diese Effekte haben auch eine radiometrische Auswirkung auf das Bild. Darüber hinaus kommt es wegen der Schrägsicht zu Effekten wie Foreshorting, Layover und Schatten, die durch unebenes Gelände verursacht werden. Die Schrägsicht führt grundsätzlich zu geometrischen Verzerrungen gegenüber der Bodengeometrie. Die geometrischen- und radiometrischen Verzerrungen können durch eine Umrechnung in die Bodenebene oder durch Georeferenzierung nicht völlig behoben werden. Im Folgenden werden die geometrisch bedingten Abbildungseffekte Foreshortening, Layover und Radarschatten erläutert.

Foreshorting

Dem Radarsensor zugeneigte Geländeformen werden im Schrägsichtbild verkürzt dargestellt. Ihre Oberfläche wird von der Wellenfront der Radarimpulse nahezu gleichzeitig erreicht und verschiedene Reflexionssignale fallen zeitlich zusammen (siehe Abb. 2.5 Bereich [1-2]). Berghänge werden z.B. in Richtung des Radars verkürzt erscheinen. Da die Rückstreuung größerer Flächen in Entfernungsrichtung zusammengestaucht wird, folgt für die Radiometrie eine Aufhellung des betroffenen Gebiets.

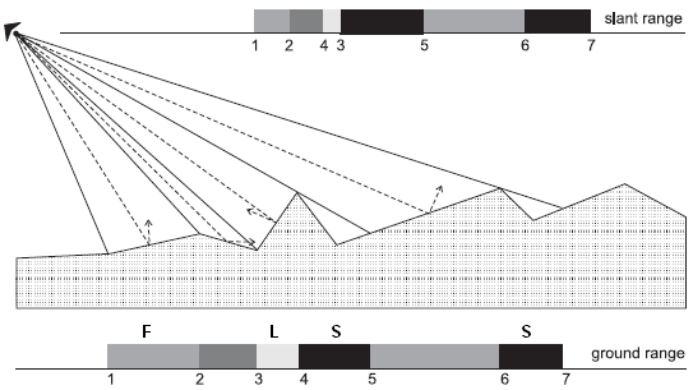

Abb. 2.5.: Geometrische und radiometrische Effekte im SAR-Bild (nach[9])

Layover

Bei noch steileren Einfallswinkeln, wie z.B. im Bereich von Hausfronten oder Waldrändern kommt es zu einem Umklappeffekt (Layover). Erreicht die Wellenfront den oberen Teil einer

Geländeform zu einem früheren Zeitpunkt als die untere so tritt Layover auf (siehe Abb. 2.5 Bereich [3-4]). Dabei findet eine Überlagerung der Signale statt, wodurch radiometrisch betrachtet, Layoverbereiche sehr hell im Bild erscheinen. Dieser Effekt ist für Siedlungsbereiche charakteristisch.

Radarschatten

Vom Sensor weg geneigte Flächen werden vom Radar nicht mehr beleuchtet (siehe Abb. 2.5 Bereich [4-5] und [6-7]), wenn ihre Neigung größer als der Depressionswinkel ($\beta = 90 - \Theta_a$) ist. Von diesen im Radarschatten liegenden Bereichen gibt es keine Rückstreuung. Im Bild erscheinen sie radiometrisch gesehen dunkel. Bei bewegten oder bebauten Gebieten können Abweichungen der Intensitäten zustande kommen, wenn eine Überlagerung der Schattenbereiche mit Layover stattfindet.

An den Intensitätswerten von Slant- und Ground Range-Darstellung sind qualitativ die radiometrischen Effekte des Reliefs erkennbar. Dem Sensor geneigte Fläche streuen einen höheren Anteil zurück als vom Sensor abgeneigte und erzeugen somit höhere Grauwerte. Bei der quantitativen Beurteilung der Intensitätseffekte ist neben variierenden lokalen Einfallswinkeln auch ein Zusammenhang mit dem in Abschnitt 2.3.2 beschriebenen Rauhigkeitseinfluß zu beachten.

2.3.2. Radiometrische Eigenschaften

Die Stärke des Rückstreusignals eines Radarsystems (Amplitude oder Intensität) ist eine Funktion der Sensor- und der Streueigenschaften des beleuchteten Objektes. Beide Einflussfaktoren auf das Rückstreuergebnis lassen sich mathematisch durch die Radargleichung beschreiben (vgl. [8]).

Die Radargleichung beschreibt die von der Antenne empfangene Leistung P_r pro Impuls in Abhängigkeit von der ausgesendeten Leistung P_t , des Antennengewinns G, der Wellenlänge λ, des Abstands zum Ziel R und den Streueigenschaften σ für die Polarisation σ_{jj}:

$$P_r = P_t \frac{G^2 \lambda^2}{(4\pi)^2 R^4} \sigma_{jj} \tag{2.8}$$

Die Distanz R zwischen Antenne und Auflösungszelle geht mit der vierten Potenz ein. Die zur Antenne rückgestreute Leistung P_r wird als Rückstreuung bezeichnet. Als Radarrückstreuquerschnitt σ (Radar Cross Sektion, im $[m^2]$) wird die Rückstreuung eines Punktzieles bezeichnet. Diese ist eine Funktion der Streueigenschaften bzw. des Reflexionsverhaltens des Zielobjektes auf der Erdoberfläche.

Zur Charakterisierung von Flächenzielen wird der Radarrückstreukoeffizient σ_0 definiert und der Radarrückstreuquerschnitt pro Einheitsfläche F eingeführt. Allgemein gilt:

$$\sigma_0 = \frac{\sigma_{jj}}{dF} \left[\frac{m^2}{m^2} \right] \tag{2.9}$$

Hierbei ist dF das beobachtete Flächenelement am Erdboden.

Für abbildende Radarsysteme ist σ_0 die eigentliche Messgröße, weil neben einzelnen künstlichen Objekten (z.B. Masten), vor allem flächenhafte Objekte (z.B. Wiese, Acker, Wald) die Szenen prägen. In der Literatur [10] werden Rückstreusignale vom Flächen- und Volumenzielen auch als Clutter bezeichnet. Die exakte Berechnung von σ_0 gegenüber σ ist sehr viel schwieriger, weil die Beschreibung der Fläche komplizierter als von einzelnen künstlichen Objekten ist, die man zumindest in der Geometrie näher modellieren kann. Allgemein ist σ_0 immer eine statistische Größe, deren Verteilungsfunktion für unterschiedliche Flächen jeweils verschieden und zum Teil auch charakteristisch ist. Dieser Zusammenhang wird in Kapitel 3 näher erläutert.

In der Praxis ist es erlaubt, an der Stelle des Differentialquotienten in Gl.2.9 den Radarrückstreuquerschnitt auf die von Radarsystemen vorgegebene Auflösungszelle zu beziehen, in dem man voraussetzt, dass sich der Radarrückstreuquerschnitt innerhalb der Fläche nicht gravierend ändert (vgl. [8]). Eine Auflösungszelle nennt man Pixel. Mit d_x und d_y bezeichnet man die Pixelabmessungen, dann resultiert mit $dF = d_x \cdot d_y$ für den Radarrückstreukoeffizienten σ_0:

$$\sigma_0 = \frac{\sigma_{jj}}{d_x \cdot d_y} \tag{2.10}$$

bzw.

$$\sigma_0 = \frac{\sigma_{jj}}{\delta_{gr} \cdot \delta_{az}} \tag{2.11}$$

Wird die Gl. 2.11 nach σ_{jj} aufgelöst und in Gl. 2.8 eingesetzt, dann ergibt sich für Flächenziele die Radargleichung:

$$P_r = P_t \frac{G^2 \lambda^2}{(4\pi)^2 R^4} \cdot (\sigma_0 \delta_{gr} \delta_{az}) \tag{2.12}$$

Aus der Radargleichung geht hervor, dass die Radarrückstreuung abhängig von systembedingten Einflüssen und objektspezifischen Eigenschaften ist. Die systembedingten Einflüsse auf die rückgestreute Leistung sind (z.B. Polarisation, Frequenz und Einfallswinkel) bekannt und können bei der Prozessierung und Kalibrierung mitberücksichtigt werden. Der Einfluss objektspezifischer Eigenschaften wird durch den Radarrückstreukoeffizienten ausgedrückt. Im Folgenden werden beide Faktoren beschrieben.

Systemspezifische Einflussfaktoren

Wellenlänge: Bestimmt den Anteil der Streuung an Objektoberflächen, die Eindringtiefe und die Signaldämpfung der Wellen in der Vegetation oder dem Boden und hat Einfluss auf den Anteil der Volumenstreuung an der Gesamtrückstreuung von der Erdoberfläche. Beispielsweise können langwellige Radarstrahlung (L-Band) in bestimmte Medien eindringen und somit andere Informationen über das Gelände liefern als es die oberflächlich reflektierte kurzwellige Radarstrahlung (z.B. X-Band) vermag. Durch die Wellenlänge wird die Rückstreuung auf

zwei Arten beeinflusst: Zum einem wird die effektive Rauigkeit durch die Relation zwischen Wellenlänge und Oberflächenrauigkeit bestimmt. Zum anderen bestimmt die Wellenlänge die Eindringtiefe der elektromagnetischen Wellen.

Polarisation: Polarimetrische Radarsysteme besitzen die Möglichkeit elektromagnetische Wellen in verschiedenen Polarisationsebenen zu senden bzw. zu empfangen. Oftmals beschränken sich die Systeme auf die linearen Polarisationsebenen der Gleichpolarisation (HH, VV) und Kreupolarisation (HV, VH). Hierbei steht „H“ für horizontal und „V“ für vertikal polarisiert. Für die Reihenfolge des Empfangspols und Sendepols gibt es keine einheitliche Definition. Meist bezeichnet der erste Buchstabe die Polarisationsebene der emittierten- und der zweite die der empfangenen Welle. Bei polarisierten Systemen ist die Orientierung der Objekte, die zu unterschiedlichen Rückstreuwerten führt, von Bedeutung. Durch die Polarimetrie werden in der Regel bessere Klassifikationsergebnisse geschafft.

Objektspezifische Einflussfaktoren

Der Radarrückstreukoeffizient ist im Wesentlichen durch objektspezifische Eigenschaften bestimmt. Für bestimmte Wellenlängen ist diese von den elektrischen Eigenschaften und der Art der Streumechanismen der Oberfläche abhängig. Je nach Beschaffenheit des Materials, Oberflächenrauhigkeit, Struktur und Verteilung von Inhomogenitäten unter der Geländeoberfläche, kommt es zu unterschiedlichen Rückstreumechanismen. Die Eindringtiefe wird hauptsächlich durch dielektrische Eigenschaften des Materials bestimmt.

Grundsätzlich können zwei Arten von Streumechanismen unterschieden werden:

- **Oberflächenstreuung**
- **Volumenstreuung**

Oberflächenstreuung tritt in der obersten Grenzschicht zwischen zwei homogenen Medien auf und hängt stark von der Oberflächenrauhigkeit ab (vgl. [8]). Eine Oberfläche wird allgemein als rau definiert, wenn die Höhenvariation größer oder gleich der Größenordnung der Wellenlänge ist ($\sigma_h \geq \lambda$). Volumenstreuung tritt auf, wenn die Welle weiter in den Boden eindringt oder diese teilweise von Vegetation reflektiert wird.

Im Folgenden werden die am häufigsten vorkommenden Rückstreumechanismen erläutert, die in der Abb. 2.6 dargestellt sind.

Spiegelnde Reflexion: Glatte Oberflächen $\sigma_h << \lambda$ haben einen hohen Reflexionsgrad (Abb. 2.6 (a)) entsprechend des Reflexionsgesetzes $(Einfallswinkel = Ausfallswinkel)$.
Der reflektierte Puls bleibt hierbei vollständig kohärent. Weil der einfallende Puls aber vom Sensor weg reflektiert wird, führt dies meistens nicht zu einer hohen Rückstreuung zum Radar. Dementsprechend wird die Rückstreuung zum Radar verschwindend klein und verursacht auf den Radarbild sehr dunkle bis schwarze Pixel.

Diffuse Reflexion: Die Reflexion des Radarpulses wird mit zunehmender Rauigkeit (Abb. 2.6(a)-(c)) mehr und mehr diffus. Bei leicht rauen Oberflächen $\sigma_h < \lambda$ wird ein geringer Teil diffus zurückgestreut und ein hoher kohärenter Teil bleibt bestehen (b). Bei sehr rauen

Oberflächen wird $\sigma_h >> \lambda$ (Rayleigh Kriterium) die Welle komplett diffus zurückgestreut(c). In diesem Fall enthält das Radarbild sehr helle Pixel.

Rückstrahl-Effekte: Sind zwei oder mehrere glatte Flächen so angeordnet, dass mehrere spiegelnde Reflexionen hintereinander stattfinden und das Reflexionssignal wieder in Richtung Sensor zurückgeworfen wird, dann tritt ein Rückstrahl-Effekt auf. Ein Beispiel hierfür sind Zweifachreflexion an Hauswänden (d). Objekte mit dieser Eigenschaft werden auch als Corner-Reflektoren bezeichnet und verursachen eine hohe Rückstreuung im Radarbild. Zu Mehrfachreflexionen in Sensorrichtung kommt es auch bei metallischen Objekten. Bei schrägem Einfall an länglich ausgerichteten metallischen Objekten entsteht eine Dipolreflexion (e). Metallische Strukturen, wie z.B. Autos, verursachen starke Rückstreuung (vgl. [8])

Volumenstreuung: Bei einer Volumenstreuung dringen die Radarwellen in die Oberflächenschicht ein. sodass es zu einer diffuser Streuung des Signals kommt (f). Die Streuung findet dann in einem Materialvolumen statt, wie beispielsweise in der Vegetationsdecke an Blättern, Zweigen und Baumstämmen. Volumenstreuung tritt insbesondere bei Waldflächen auf, da Radarwellen in die inhomogene Volumenstruktur der Baumkronen eindringen.

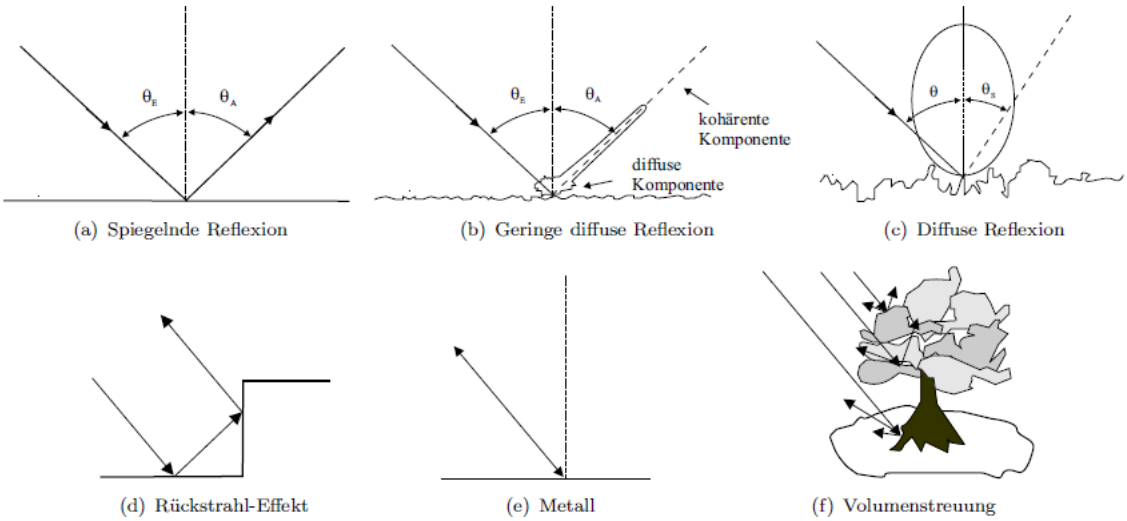

Abb. 2.6.: Rückstreumechanismen: Oberflächen- und Volumenstreuung (nach [7])

2.4. Der Speckle-Effekt

Eine typische Eigenschaft von SAR-Bildern ist ihre körnige Erscheinung. Diese Charakteristika von SAR-Bildern werden als Speckle [11] bezeichnet. In diesem Abschnitt werden der Speckle-Effekt und seine Auswirkung auf Flächen- und Punktziele erläutert.

Auswirkung des Speckle-Effektes auf homogene Flächen

Der SAR-Sensor sendet kohärente elektromagnetische Strahlung, die durch Amplitude und Phase ϕ beschrieben werden kann. Die vom Sensor ausgesendeten Wellen interagieren an der Oberfläche mit diskreten Streuelementen (z.B. auf einer Wiese mit Grashalmen).

Das Gesamtsignal einer Auflösungszelle setzt sich aus den rückgestreuten Wellen jedes einzelnen Streuelementes zusammen. Das vom Sensor empfangene Signal u lässt sich als Summer der rückgestreuten Wellen aller Streuelemente einer Auflösungszelle beschreiben als:

$$u = Ae^{i\phi} = \sum_{k=1}^{n} A_k e^{i\phi_k} \tag{2.13}$$

Hierbei hängt die Amplitude A von der Stärke des Rückstrahlsignals der Streuelemente und von Streumechanismen innerhalb der Auflösungszelle ab. Die Phase ϕ hängt von der Entfernung zwischen Sensor und Streuelementen ab.

Da die Wellenlänge ein Vielfaches kleiner ist als die Auflösungszelle, tragen n einzelne Streuelemente zum rückgestreuten Signal bei. In Abb. 2.7 wird dieser Zusammenhang veranschaulicht.

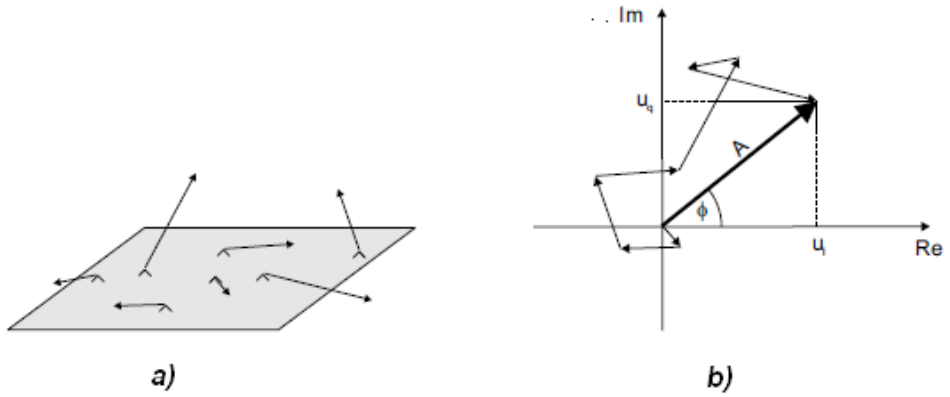

Abb. 2.7.: (a) Einzelne Streuelemente in einer Auflösungszelle und ihre rückgestreuten Wellen als Vektoren (Länge: Signalstärke, Richtung: Phase); (b) Signal als Summe der rückgestreuten Wellen einzelner Streuelemente (nach [7]).

Jedes einzelnes Streuelement erzeugt eine Amplitude die durch die Länge der Vektoren dargestellt ist. Die Richtung der Vektoren ist durch die Phase bestimmt (Abb. 2.7 a)). Das

rückgestreute Gesamtsignal ergibt sich dann aus einer phaseninkohärenten, zufälligen Überlagerung der reflektierten Wellen (Abb. 2.7 b)).

Da die räumlich zufällig verteilten Rückstreuer jeweils unterschiedliche Entfernungen vom Sensor haben, variieren somit die Phasen. Bei Zusammenfassung der empfangenen Signalanteile treten konstruktiver- oder destruktiver Interferenzerscheinungen auf. Es kommt daher zu einer Überlagerung oder Auslöschung der Signalanteile (siehe Abb. 2.8).

Die Interferenzerscheinungen haben zur Folge, dass von verschiedenen Stellen einer homogenen Objektoberfläche reflektierte und am Sensor empfangene Signal eine große oder kleine Amplitude in Abhängigkeit von der zufälligen Anordnung der Rückstreuer in der Auflösungszelle haben können. Dadurch erhalten homogene Objektoberflächen wie beispielsweise Acker oder Wiese eine granulare Erscheinung, welche als „Speckle“ bezeichnet wird. Allgemein wächst der Speckle-Effekt mit der Intensität des Signals.

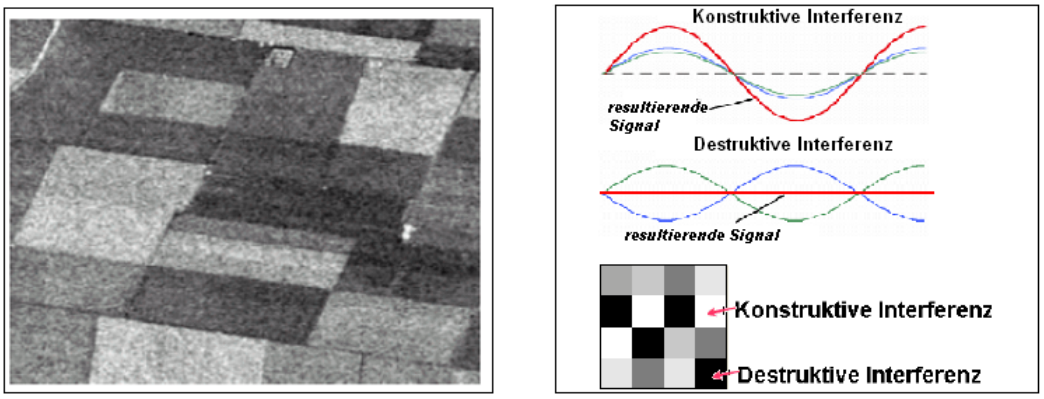

a) b)

Abb. 2.8.: a) körnige Erscheinung von homogenen Flächen (Ackerflächen) auf einem Radarbild, b) konstruktive- destruktive Interferenz und resultierende Helligkeitswerte

Theoretisch gesehen ist der Speckle-Effekt kein zufälliger Effekt sondern das Ergebnis eines deterministischen, elektromagnetischen Prozesses, der aufgrund der Aufsummierung kohärenter Signale zustande kommt. Es würden sich daher unter gleichen Gegebenheiten die gleichen Interferenzen ergeben. In der Praxis aber würde aufgrund des Einflusses der n Streuelemente eine erneute Messung selten zum gleichen Ergebnis führen, da sich die Sensorposition nicht exakt wiederholt und sich ebenso die Anordnung der Elemente ändert.

Weil die Anordnung der Rückstreuer in der Auflösungszelle nicht bestimmbar ist, kann das Empfangssignal lediglich mit Mitteln der Statistik beschrieben werden. Hierbei muss jeder einzelne Messwert als Zufallsgröße betrachtet werden. Eine Zufallsgröße ist definiert als Messwert, der bei verschiedenen, unter gleichen Bedingungen ausgeführten Messungen verschiedene, zufällige Werte annehmen kann.

Als Schwerpunkt dieser Arbeit wird die statistische Modellierung von Speckle und SAR-Objekten vertieft Kapitel 3 beschrieben.

Punktziele in SAR-Aufnahmen

Wird das Radarsignal innerhalb eines Pixels von einem dominanten Streuer reflektiert, so spricht man von Punktzielen. Der Wert des Flächenelements wird dann von Amplitude und Phase des rückgestreuten Signals des dominanten Objekts bestimmt. Da der Wert eines Pixels sich aus einem Reflexionssignal ergibt, tritt keine Interferenz auf, weil das Signal des dominanten Streuers verhältnismäßig sehr groß gegenüber allen anderen Reflexionen ist. Punktziele sind daher nicht vom Speckle-Effekt betroffen. Im Amplitudenbild ist das Punktziel ein lokales Maximum.

Speckle-Reduktion

Allgemein ist der Speckle-Effekt ein unerwünschtes Störsignal bei SAR-Aufnahmen. Es wird daher oft versucht die Varianz des Speckle in Bezug auf den Mittelwert der Rückstreuung soweit wie möglich zu reduzieren. Die Reduzierung des Speckle-Effekts geht jedoch immer zu Lasten der räumlichen Auflösung des Radarbildes, sodass für die Klassifikation ein individueller Kompromiss zwischen notwendiger Auflösung und bestmöglicher Speckle-Filterung gefunden werden muss. In dieser Arbeit wird versucht für die Klassifikation, die gesamte in der SAR-Szene vorhandene Information zu nutzen. Daher wird in den meisten Untersuchungen explizit auf eine Speckle-Filterung verzichtet.

3. Statistische Modellierung und Methodik zur Parameterabschätzung

Ein wichtiger Bestandteil des Klassifikationsansatzes in dieser Arbeit ist die korrekte statistische Modellierung des SAR-Sensors.

Das innerhalb einer Auflösungszelle (Pixel) bestimmte Radarsignal setzt sich in der Regel aus der Summe vieler Einzelsignale mit unterschiedlicher Amplitude und Phase zusammen. Für Amplitude und Phase kann eine statistische Verteilung angenommen werden. Dementsprechend unterliegt das empfangene Radarsignal statistischen Schwankungen (siehe Abschnitt 2.4) und kann somit als statistische Zufallsgröße betrachtet werden. Zufallsgrößen werden in der Statistik durch Verteilungsfunktionen (siehe Abschnitt 3.1) beschrieben.

Aus methodischer Sicht unterscheidet man in der Statistik zur Beschreibung einer Zufallsgröße zwischen parametrischen und nichtparametrischen Strategien. Für die erstere Strategie wird ein mathematisches Modell benötigt womit jede Klasse in Form einer Wahrscheinlichkeitsdichtefunktion (Englisch: probabillity density function, pdf) charakterisiert wird. Bei Auswahl einer geeigneten pdf wechselt man zum Problem der Parameterabschätzung. In der Literatur werden verschiedene klassische Ansätze, wie z.B die Maximum-Likelihood-Methode (MLE) und die Momentmethode (MOM) vorgeschlagen (vgl.[12]). Nicht-parametrische Strategien [13] werden im Rahmen dieser Arbeit nicht behandelt.

In diesem Kapitel werden zwei Themen behandelt:

1. Auswahl eines geeigneten statistischen Modells zur Charakterisierung von SAR-Daten in Form einer Wahrscheinlichkeitsdichtefunktion

2. Parameterabschätzung auf Basis der „Second-Kind Statistics “.

In Abschnitt 3.1 werden zunächst grundlegende statistische Begriffe und Methoden erläutert, welche in allen wissenschaftlichen Gebieten angewendet werden. In Abschnitt 3.2 wird ein Überblick über die gängigen statistischen Modelle und ihre Anwendbarkeit in der Praxis gegeben.

In dieser Arbeit wurde als statistisches Modell zur Charakterisierung von SAR-Objekten (z.B. Acker, Siedlung, Wald,. . .) die Fisher-Verteilung verwendet, welches in Abschnitt 3.3 erläutert wird.

Eine Besonderheit der Fisher-Verteilung ist, dass ihre Parameter nicht durch klassische Verfahren, wie z.B. MLE oder MOM, abgeschätzt werden können. Eine neue Methodik basiert auf der „Second-Kind Statistics“, welche in Abschnitt 3.4 beschrieben wird. In Abschnitt 3.5 werden die abgeschätzten Fisher-Verteilungen beurteilt.

3.1. Statistische Begriffe

In diesem Abschnitt wird anhand eines Beispiels aus der Bildverarbeitung (vgl. [14]) die wichtigsten Begriffe und Methoden der Statistik erläutert. Hierbei wird die statistische Eigenschaft des gemessenen Grauwerts an einem einzelnen Pixel betrachtet. Dann können statistische Methoden angewendet werden um die Messung einer einzelnen Größe zu bestimmen. Wird die Statistik an einem einzelnen Messpunkt betrachtet, dann wird diese Art der Statistik als Statistik erster Ordnung bezeichnet.

Wahrscheinlichkeitsdichte und Histogramm

Nehmen wir einen experimentellen Aufbau an, mit dem wir ein Objekt auf der Erdoberfläche (z.B. mit einem optischen Fernerkundungssensor) aufnehmen. Die an einem bestimmten Punkt (Pixel) gemessene Größe in der Bildebene ist die Bestrahlungsstärke (reflektierte oder absorbierte elektromagnetische Strahlung). Wegen der statistischen Natur des beobachteten Prozesses ergibt jede Messung einen anderen Wert. Die beobachtete Strahlung kann dann nicht nur durch einen einzigen Wert sondern durch eine Wahrscheinlichkeitsdichtefunktion $pdf(g)$ charakterisiert werden. Mit dieser Funktion wird ausgedrückt mit welcher Wahrscheinlichkeit ein bestimmter Wert g beobachtet wird. Eine durch Zufallsprozesse bestimmte Messgröße wie die Strahlung g wird als Zufallsvariable bzw. Zufallsgröße bezeichnet.

Es wird zwischen diskreten und kontinuierlichen Zufallsvariablen unterscheiden, die im Folgenden parallel behandelt werden. Erstere wird benötigt, da die beobachteten Daten nur diskrete Werte annehmen können und man so numerisch sehr einfach vorgehen kann. In letzterem Fall wird ein bestimmter Grauwert im Intervall $g+dg$ mit der Wahrscheinlichkeit $pdf(g)dg$ gemessen. Dagegen können wir im diskreten Fall nur eine endliche Zahl Q von Grauwerten g_q $(q = 1,2,...,Q)$ mit der Wahrscheinlichkeit f_q messen. Wird der Grauwert eines Pixels in einem Byte gespeichert, dann lassen sich für $Q = 256$ unterschiedliche Grauwerte messen. Die Gesamtwahrscheinlichkeit, einen beliebigen Wert zu beobachten, ist per Definition eins. Damit ergeben sich für die Wahrscheinlichkeitsdichtefunktionen folgende Bedingungen:

$$\int_{-\infty}^{\infty} pdf(g)dg = 1, \quad \sum_{q=1}^{Q} f_q = 1 \tag{3.1}$$

Die Stammfunktion der pdf wird Verteilungsfunktion genannt.

Die Wahrscheinlichkeitsverteilung ist im Allgemeinen nicht vorab bekannt, sondern sie wird mit Messungen abgeschätzt. Eine einfache Abschätzung der Wahrscheinlichkeitsdichtefunktion kann durch das Histogramm erfolgen. Ein Histogramm $H(g)$ ist eine Funktion der Grauwerte g, die für jeden Grauwert angibt, wie häufig er in einen Bild vorkommt. Werden die Werte von H mit der Anzahl der Pixel normiert so erhält man ein normiertes Histogramm $H_p(g)$, das für jeden Grauwert die Wahrscheinlichkeit seines Vorkommens im Bild angibt. Zur Formulierung der Definition kann man von der diskreten Delta-Funktion Gebrauch machen:

$$\delta(g) = \begin{cases} 1, & g = 0 \\ 0, & g \neq 0 \end{cases} \tag{3.2}$$

Das Histogramm ist in dieser Schreibweise gegeben durch:

$$h(g) = \sum_{i=1}^{N} \delta(f_i(x) - g) \tag{3.3}$$

Für jedes i prüft die δ-Funktion, ob der Grauwert $f_i(x)$ gleich g ist oder nicht. Ist das der Fall, dann wird der Zähler $h(g)$ um 1 erhöht, sonst bleibt er unverändert. Für das normierte Histogramm ergibt sich dann $\frac{1}{N}h(g) = h_p(g)$.

Die Abschätzung der Wahrscheinlichkeitsdichte ist auch für 16 Bit Bilder oder Fließkommabilder möglich. Hierzu teilt man den Bereich der möglichen Werte in Q gleich breite Intervalle auf. Jeder Wert wird dann dem entsprechenden Intervall zugeordnet.

Im Folgenden werden die in der Praxis gängig benutzten statistischen Merkmale einer Zufallsgröße erläutert. Hierbei gelten die Gleichungen auf der linken Seite für kontunuierliche und auf der rechte Seite für den disketen Fall.

Mittelwert, Varianz und Momente

Im Allgemeinen kann eine Zufallsgröße g durch zwei grundlegende Parameter, Mittewert μ (auchErwartungswert $E(g)$) und Varianz, charakterisiert werden. Der Mittelwert ist definiert als:

$$\mu = \int_{-\infty}^{\infty} g \cdot pdf(g) d_g, \quad \mu = \sum_{q=1}^{Q} g_q \cdot f_q \tag{3.4}$$

Die Varianz $\sigma^2 = E((g-\mu)^2)$ ist ein Maß dafür inwieweit ein gemessener Wert vom Mittelwert abweicht:

$$\sigma^2 = \int_{-\infty}^{\infty} (g-\mu)^2 \cdot pdf(g) d_g, \quad \sigma^2 = \sum_{q=1}^{Q} (g_q - \mu)^2 \cdot f_q \tag{3.5}$$

Die Wahrscheinlichkeitsdichtefunktion wird mit Hilfe ihrer Momente charakterisiert. Es gilt für das Moment n-ter Ordnung $\mu_n = E((g_q - \mu)^2)$:

$$\mu_n = \int_{-\infty}^{\infty} (g-\mu)^n \cdot pdf(g) d_g, \quad \mu_n = \sum_{q=1}^{Q} (g_q - \mu)^n \cdot f_q \tag{3.6}$$

Per Definition ist der erste zentrale Moment Null und das zweite entspricht der Varianz.

3.2. Stand der Technik: Statistische Modellierung von SAR-Daten

In diesem Abschnitt werden unterschiedliche Ansätze für die Modellierung der SAR-Daten in Form einer pdf vorgestellt. Hierzu gibt es theoretische Ansätze [10], [15] und heuristische Ansätze [16],[12].

Im theoretischen Ansatz geht man von einer großen Anzahl von Streuelementen innerhalb einer Auflösungszelle aus. Für die gemeinsame Wahrscheinlichkeitsdichte von Real- und Imaginärteil des Empfangssignals ergibt sich dann eine Gauss-Verteilung. Für die Amplitude des Empfangssignals erhält man eine Rayleigh-Verteilung. Bei Multilook Daten wird die Amplitude durch eine Nakagami-Gamma-Verteilung charakterisiert. Wenn das empfangene Signal durch eine oder wenige starke Streuelemente dominiert wird, dann kann der Prozess durch eine Rice-Verteilung modelliert werden.

Ein weiterer theoretischer Ansatz ist die Annahme, dass das empfangene Signal eines Pixels als zusammengesetzte Größe aufgefasst wird. Hierbei wird das empfangene Signal durch das Produkt aus einer deterministischen Signalkomponente und einer exponentialverteilten, zufälligen Störkomponente modelliert. Werden Signal- und Störkomponente durch eine Gamma-Verteilung moduliert, so erhält man für die Intensität des empfangenen Signals eine K-Verteilung.

Als Heuristisches Modell gelten die Log-Normalverteilung und die Weibul-Verteilung für Intensitäts- und Amplitudenbild. Im Folgenden werden die genannten Modelle genauer beschrieben und ihre Anwendbarkeit auf SAR Daten erläutert.

3.2.1. Standard Modell

In Abschnitt 2.4 wurde bereits erwähnt, dass das empfangene SAR-Signal als Zufallsgröße statistischen Schwankungen unterliegt, weil jedes Streuelement innerhalb eines Pixels zufällige Amplitude und Phase besitzt. Eine Zufallsgröße lässt sich in der Statistik durch eine Verteilungsfunktion und ihre Momente (auch Parameter) beschreiben. Die statistische Schwankungen des Empfangssignals haben zur Folge, dass eine abgebildete Fläche nicht entsprechend ihrem mittleren Reflexionsfaktor in einem einheitlichen Grauwert (Amplitude oder Intensität des Empfangsignals) dargestellt werden kann, sondern das die Grauwerte eine flimmernde Struktur aufweisen (siehe Abbildung 3.1 a)).

Die Abbildung 3.1 ist ein Beispiel für eine X-Band Radaraufnahme einer Landschaft (a) mit dem dazugehörigen Histogramm der Grauwerte (b), in diesem Fall die Amplitude, und die abgeschätzte Wahrscheinlichkeitsdichtefunktion der Rayleigh-Verteilung (c) dargestellt.

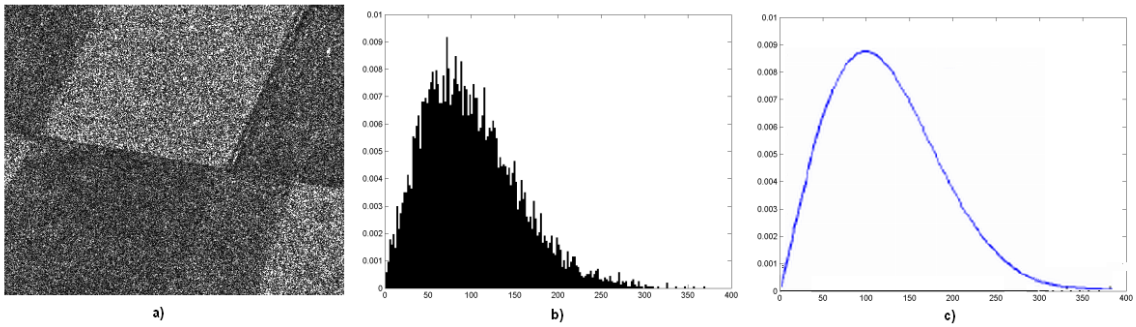

Abb. 3.1.: Beispiel für Speckle: (a) X-Band Radaraufnahme einer Landschaft,(b) Hilstogramm (Amplitude) und (c) Rayleigh-Verteilung

Im Folgenden wird die Verteilung für das gängige Rayleigh-Echo-Modell für das Amplitudenbild nach [7] hergeleitet.
Durch die Annahmen des Rayleigh-Echo-Modell, dass von einer großen Anzahl von zufällig verteilten Streuelementen innerhalb eines Pixel ausgeht, kann für alle voneinander unabhängigen Teilsignale der zentrale Grenzwertsatz angenommen werden. Der zentrale Grenzwertsatz besagt, dass die Wahrscheinlichkeitsdichtefunktionen voneinander unabhängigen Teilsignale normalverteilt sind, wenn jedes Teilsignal als Summe einer großen Anzahl voneinander unabhängiger Summanden aufgefasst werden kann, von denen jeder zu Summe nur ein unbedeutenden Beitrag liefert. Dementsprechend folgt für den Imaginär- und Realteil des Empfangssignals $u = u_i + ju_q$,

$$\Re\{u\} = u_i = Acos\theta \tag{3.7}$$

und

$$\Im\{u\} = u_q = Asin\theta \tag{3.8}$$

der Normalverteilung. Für sie ergeben sich die Wahrscheinlichkeitsdichtefunktionen mit Mittelwert gleich Null und der bestimmenden Parameter σ_u^2:

$$pdf_{u_i}(u) = pdf_{u_q}(u) = \frac{1}{\sigma_u\sqrt{2\pi}} e^{\left(-\frac{u^2}{\sigma_u^2}\right)} \tag{3.9}$$

Die gemeinsame Wahrscheinlichkeitsdichtfunktion von Real- und Imaginärteil ist durch eine zirkuläre Gauss-Verteilung gegeben:

$$pdf_{u_i}(u_i) \cdot pdf_{u_q}(u_q) = \frac{1}{\sigma_u^2 2\pi} e^{\left(-\frac{u_i^2+u_q^2}{\sigma_u^2}\right)} \tag{3.10}$$

Als eine Näherung für die Amplitude mit $A = |u|$ erhält man die Dichtefunktion der **Rayleigh-Verteilung**:

$$pdf(A) = \frac{A}{\sigma_u^2} e^{\left(-\frac{A^2}{2\sigma_u^2}\right)} \quad \text{für } A > 0 \tag{3.11}$$

Für das Intensitätsbild mit $I = |u|^2$ ergibt sich eine negativ exponentialverteilte Wahrscheinlichkeitsdichtefunktion beschrieben mit $\sigma_I = \mu_I = 2\sigma_u^2$ durch:

$$pdf(I) = \frac{I}{2\sigma_u^2} e^{\left(-\frac{I}{2\sigma_u^2}\right)} \quad \text{für } I > 0 \tag{3.12}$$

Der zu bestimmende Parameter σ_I entspricht dem Erwartungswert der Intensität. Standardabweichung und Erwartungswert sind also identisch.

Die Wahrscheinlichkeitsdichtefunktionen aus Gl. 3.11 und 3.12 beschreiben die Fluktuation der Pixelwerte, welche auch als Speckle-Effekt (siehe Abschnitt 2.4) bezeichnet wird. Der Speckle-Effekt wird oft auch als multiplikatives Rauschen modelliert, da die Variation der Intensität mit dem Mittelwert steigt.

Alternativ können Amplitude und Intensität auch durch Rayleigh-Nakagami- bzw. durch die Gammaverteilung [17] modelliert werden. Für die Gammaverteilung ergibt sich dann die Dichtefunktion:

$$pdf(I) = \frac{1}{\Gamma(L)} \frac{L}{\mu} \left(\frac{L \cdot I}{\mu}\right)^{L-1} e^{-\left(\frac{L \cdot I}{\mu}\right)} \tag{3.13}$$

Mit L Anzahl der Looks, $\mu = 2\sigma_u^2$ und $\Gamma(.)$ die Gammafunktion nach [18].
Für die Dichte der Raylaigh-Nakagammi-Verteilung ergibt sich mit $\mu = \sqrt{2\sigma_u^2}$

$$pdf(A) = \frac{\sqrt{L}}{\Gamma(L)} \frac{2}{\mu} \left(\frac{\sqrt{L} \cdot A}{\mu}\right)^{2 \cdot L-1} e^{-\left(\frac{L \cdot A^2}{\mu^2}\right)} \tag{3.14}$$

Interpretation der Verteilungen

Betrachtet man die Messung der Amplitude bzw. Intensität eines Pixels, so entspricht sie eine Stichprobe aus den obigen Verteilungen. Sie enthalten also Objektinformationen, die entsprechend der jeweiligen Verteilung durch multiplikative Störung („Speckle-Efffekt“) charakterisiert sind. Der Messwert für die Intensität ist stärker vom Speckle-Effekt als der Messwert der Amplitude in homogenen Bereichen, was auch durch den Variationskoeffizienten (Englisch: Coefficient of Variation)

$$C_v = \frac{\sigma_I}{\mu_I} \tag{3.15}$$

von konstant 1.0 bei Intensitätsbilder ausgedrückt werden kann . Dagegen sind erhalten Amplitudenbilder ein Wert von 0.52. Diese Aussage gilt nur für ländliche und Radarsensoren mit einer Auflösung von $30m$ und schlechter. Es soll vielmehr verdeutlicht werden, dass Intensitätsbilder mehr vom Speckle-Effekt betroffen sind als Amplitudenbilder. Daher wird bei der Klassifikation von SAR-Daten in der Praxis das Amplitudenbild oft bevorzugt.

Anwendbarkeit

Zur Bestimmung des empfangenen Signals mittels der in diesem Abschnitt vorgestellten Wahrscheinlichkeitsdichtefunktion müssen für n Rückstreuelemente innerhalb einer Auflösungszelle die folgenden Bedingungen erfüllt sein:

- Die Amplituden und Phasen von n Rückstreuern sind statistisch unabhängig voneinander.
- Jeder Signalanteil der Streuelemente ist eine Zufallsgröße derselben Wahrscheinlichkeitsverteilung. Es treten daher keine dominierenden Rückstreuer auf.
- Die Phasen sind im Vollkreis (Intervall $0-2\cdot\pi$) gleichverteilt. Dies ist der Fall wenn die Objektfläche relativ zur Wellenlänge des Signals rau ist, sodass benachbarte Rückstreuer große Phasendifferenzen gegenüber glatten Oberflächen aufweisen (siehe Abschnitt 2.3.2).
- Die Anzahl n der Rückstreuer muss sehr groß sein, sodass die realen und imaginären Anteile der komplexen Einzelsignale unabhängig voneinander und normal verteilt sind.

Oberflächen, die diese Voraussetzung erfüllen sind unbestelltes Ackerland, landwirtschaftlich genutzte Flächen, dichte Waldkronen und schneebedeckte Gebiete (vgl. [8]). Nicht geeignet sind urbane Gebiete und Radarsysteme mit sehr hochauflösenden Sensoren. Bei ersterem ist die Oberfläche von dominierenden Streuelementen geprägt wie z.B. Masten, Corner-Reflektoren, Autos. Weiterhin sind in urbanen Gebieten die Streuelemente nicht zufällig angeordnet. Bei hochauflösenden Sensoren wird die Zahl der Rückstreuelemente in der Auflösungszelle zudem noch viel kleiner, weil die Pixelfläche kleiner wird. Die Wahrscheinlichkeit dass sich innerhalb einer Auflösungszelle dominante Streuer befinden steigt.

3.2.2. Empirisches Modell

Die in Abschnitt 3.2.1 beschriebenen Modelle sind für SAR-Daten geringerer Auflösung geeignet, wenn Objekte wie z.B. Bäume viel kleiner als die Auflösungszelle sind. Das empfangene Signal innerhalb einer Auflösungzelle wird dann gemittelt, sodass keine räumlichen Unterschiede und Korrelationen mehr sichtbar sind. Das resultierende komplexe Signal erhält als pdf eine Gaussverteilung für Real- und Imaginärteil, eine Rayleigh-Verteilung für die Amplitude und negative Exponential-Verteilung für die Intensität, wie bereits im obigen Abschnitt erläutert.

Je höher die Auflösung der Daten werden umso mehr sind räumliche Unterschiede und Korrelationen im Radarbild sichtbar. Daher wird die statistische Beschreibung hochauflösender Aufnahmen in [12] zwei parametrische Verteilungen für notwendig gehalten, um den Bildkontrast besser charakterisieren zu können. In der Praxis werden hier verschiedene

empirische Verteilungen angewendet wie z.B Nakagami-Rice, Weibul-Verteilung und Log-Normal-Verteilung.

Die Log-Normal Verteilung wird für heterogene- und besonders urbane Bereiche angewendet, die durch ein starkes Empfangssignal gekennzeichnet ist. In der Verteilung ist dies durch ein Maximum charakterisiert. Die Weibul-Verteilung wird oft für ländliche Regionen angewendet. Die Rice-Verteilung wird verwendet, wenn das Empfangssignal von einem oder wenigen starken Streuelementen dominiert wird (z.B. Corner-Reflektor an Hauswänden in städtische Gebiete). Eine Erweiterung der Rice -Verteilung ist die Nakagami-Rice-Verteilung. Anwendung findet diese Verteilung, wenn sich innerhalb einer homogenen Fläche ein starker Reflektor befindet.

Im Folgenden werden die allgemeinen Eigenschaften der oben genannten Verteilungen erläutert. Diese können für das Amplitudenbild und das Intensitätsbild angepasst werden. Auf die mathematische Herleitung wird in diesem Zusammenhang verzichtet. An dieser Stelle soll vielmehr ein Überblick SAR typischer Daten Modelle gegeben werden, die in Form von pdf angepasst werden können.

Die **Log-Normal-Verteilung** (Abbildung 3.2 a)) ist gegeben durch

$$pdf(x) = \frac{1}{V\sqrt{2\pi V}} e^{-\left(\frac{(ln(x)-\beta)^2}{2V}\right)} \tag{3.16}$$

wobei β und V Mittelwert und Varianz von $ln(x)$ ist. Der Wert von x kann entweder durch die Intensität I oder Amplitude A ersetzt werden. Die Log-Normalverteilung sagt für Intensitäten- bzw. Amplituden die den Wert Null haben keine Wahrscheinlichkeit voraus. Daher ist die Modellierung für Intensitätsbilder mit Speckle weniger geeignet. Dagegen wurde mit Amplitudenbildern für Regionen mit starker räumlicher Unterschiede wie z.B. bei Urbanen Räume gute Ergebnisse erzielt (vgl. [12]).

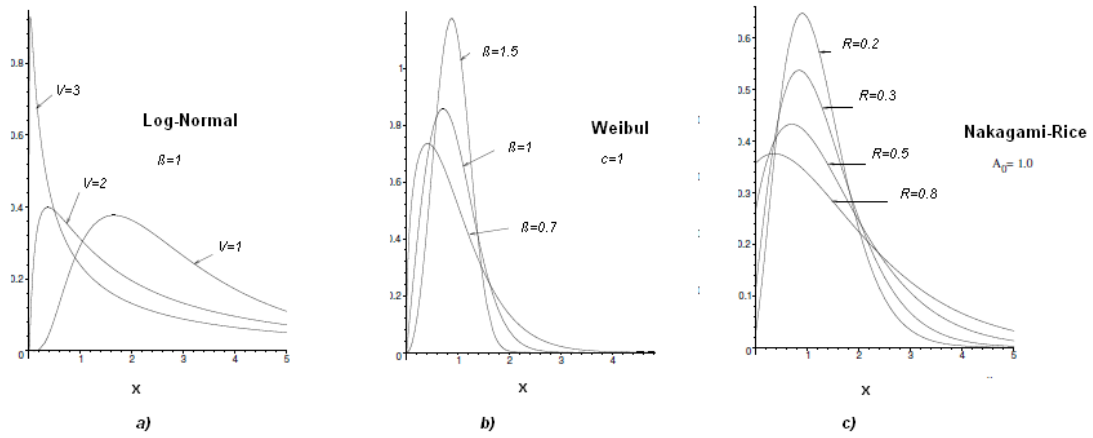

Abb. 3.2.: Verteilungen des empirischen Modells: a) Log-Normal-, b) Weibul- und c) Nakagami-Rice-Verteilung

Die **Weibul-Verteilung** (Abbildung 3.2 b)) ist gegeben durch:

$$pdf(x) = \frac{cx^{c-1}}{b^c} e^{(-\left(\frac{x}{b}\right)^c)} \tag{3.17}$$

Wobei b ein Skallierungsparameter und c ein shape Parameter zu Steuerung der Form der Verteilung sind. Beispielsweise entspricht sie der Weibul-Verteilung mit $c = 2$ der Rayleigh-Verteilung und mit $c = 1$ der negativen Exponential-Verteilung. Daher kann damit Speckle sowohl in Intensitäts- als auch in Amplitudenbildern modelliert werden.

Die **Nakagami-Rice-Verteilung** (Abbildung 3.2 c)) ist gegeben, wenn ein starker Reflektor (mit Rückstreuquerschnitt A_0) in homogenen Clutter (mit durchschnittlicher Reflektivität R) vorhanden ist. Die Verteilung ist definiert durch:

$$pdf(x) = \frac{1}{R} e^{(-\frac{u+A_0^2}{R})} I_0(2\frac{\sqrt{uA_0^2}}{R}) \tag{3.18}$$

I_0 ist hierbei die modifizierte Bessel Funktion 1.Art (vgl. [19]). Nach [16] ist diese Verteilung für Ziele in homogene Flächen mit Gausschem Charakter geeignet.

Wohlbekannte geometrische Strukturen (wie z.B. Masten, Autos, Häuser, ...) haben ein deterministisches Rückstreuverhalten, wenn das Signal von einer oder einigen wenigen starken Streuelementen dominiert wird. Beispiele dafür sind Corner-Reflektoren an Hauswände. In diesem Fall kann der Prozess durch die **Rice-Verteilung** beschrieben werden (vgl. [10]).

3.2.3. Produkt Modell

In Erweiterung zu den in Abschnitten 3.2.1 und 3.2.2 genannten Annahmen kann die beobachtete Intensität x des empfangenen Signals eines Pixels auch als zusammengesetzte Größe aufgefasst werden. Die Idee hinter diesem Modell liegt darin, dass das empfangene Signal eines Auflösungselements aus zwei Prozessen besteht. Während der Speckle-Effekt aufgrund der zufälligen Verteilungen der Streuelemente verursacht wird, ist der Radarrückstreuquerschnitt von physikalischen Eigenschaften (siehe Abschnitt 2.3.2) der Streuelemente abhängig. Die Intensität eines Pixels wird dann als Produkt einer deterministischen Signalkomponente σ (Radarrückstreuquerschnitt) und einer exponentialverteilten, zufälligen Störkomponente S_z modelliert mit:

$$x = \sigma \cdot S_z \tag{3.19}$$

Durch die Störkomponente wird der Einfluss des multiplikativen Speckle-Effekts repräsentiert der die Verteilung bestimmt. Additive Störungen werden hingegen nicht beachtet, weil sie im Gegensatz zu multiplikativen Störungen nur bei kleinen Signalintensitäten relevant sind.

Werden der Radarrückstreuquerschnitt σ und die Störkomponente S_z mit einer Gammaverteilung modelliert, dann erhält man eine K-Verteilung für die Intensität des Pixels. Die durch die zwei Parameter beschriebene Gammaverteilung hat den Vorteil, dass mit ihr Verteilungen zwischen Gauß'schen und der Exponentialverteilung relativ gut beschrieben werden können.

Die **K-Verteilung** (Abbildung 3.3) ist definiert für $M > 0$ und $L > 0$ durch:

$$pdf(x) = \frac{1}{\Gamma(L)\Gamma(M)} \frac{2LM}{\mu} \left(\frac{LM}{\mu}\right)^{\frac{M+L}{2}-1} \cdot K_{M-L}\left[2(\frac{LM}{\mu}x)^{\frac{1}{2}}\right] \tag{3.20}$$

mit M als Formparameter. K_{M-L} entspricht der Bessel Funktion 2. Art und Γ der Gammafunktion.

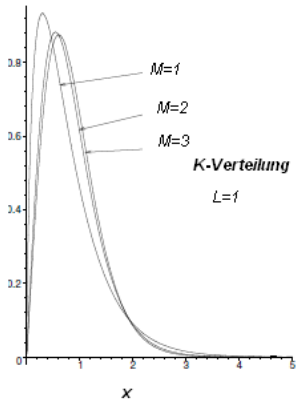

Abb. 3.3.: K-Verteilung mit $\mu = 0$

Das Modell wird in der Praxis oft für heterogene Gebiete angewendet. Nach [16] tendiert dieses Modell dazu, hohen Intensitätswerten große Wahrscheinlichkeiten zu zuordnen. Dadurch kommt es im Vergleich von abgeschätzten Daten und des Histogramms zu Unstimmigkeiten. Sprich die abgeschätzten K-Verteilung stimmen nicht mit der relativen Häufigkeit ab.

3.3. Die Fisher-Verteilung

Die Statistik von SAR-Bildern hoher Auflösung von urbanen Gebieten zeigen, dass die Wahrscheinlichkeit des Auftretens hoher Helligkeitswerte relativ groß ist. Dies begründet sich durch die Präsenz starker Reflektoren wie etwa Autos, Kanten von Mauern, Balkonen, etc. Das führt zu einem Histogramm mit „heavy tail“ (Deutsch: langschwänzig) mit geringem „Schrumpfraten“. „Heavy tail“ einer Verteilung bedeutet, dass die Verteilung nach einem Potenzgesetz zerfällt.

In der Statistik spricht man von einer Heavy-Tailed-Verteilung eine Wahrscheinlichkeitsverteilung mit einer unendlichen Varianz. Anschaulich besagt der Begriff, dass eine Verteilung einen langen „Schwanz“ besitzt auf dem noch viel Masse bzw. Gewicht liegt. Dies wiederum hat zur Folge, dass die Wahrscheinlichkeit sehr große Werte zu beobachten nicht vernachlässigbar ist. Im Gegensatz dazu besitzen die "klassischen"Verteilung, wie z.B. die Rayleigh- oder Expoentialverteilung, einen „light tail“. Ein gutes statistisches Modell sollte also diese Besonderheit der „heavy-tail“ wiedergeben können.

Viele der bisherigen Modelle aus Absschnitt 3.2 verhalten sich nicht auf dieser Weise und können die Heterogenität und Diversität von urbanem Gebiete nicht zufriedenstellend modellieren. Es können nicht alle Oberflächenarten, künstliche wie natürliche, modelliert werden. Zwar hat die Log-Normalverteilung eine Art „heavy-tail“, kann aber nach [16] und [20], nur in beschränkten und genau spezifizierten Regionen eingesetzt werden.

Ein ideales Modell sollte also alle bisherigen beschriebenen Modelle und Annahmen enthalten. Aus dieser Festlegung wird eine Verteilung bzw. eine Familie von Verteilungen benötigt, mit der man alle Oberflächenarten im urbanen Bereich beschreiben (z.B. Wiese, Dächer, etc.) und ländliche Regionen (z.B. Acker, Wald, etc.) kann.

Andererseits aber ist die Rückstrahlung elektromagnetischer Wellen im urbanen Bereich so komplex, dass es schwierig ist ein einheitliches statistisches Modell zu finden, dass die physikalischen Eigenschaften berücksichtigt.

Die wichtigste Eigenschaft, die man hierbei beachten muss, ist das Auftreten von sehr hellen starken, nicht vernachlässigbaren Werten („heavy tail“). Diese sehr hellen Werte treten aufgrund einiger starker Reflektoren auf, die über die ganze Szene verteilt sind. Aufgrund aller zuvor genannten Bedingungen wird in [16] die Fisher-Verteilung als eine ideale Verteilung empfohlen.

Die Fisher-Verteilung wird durch drei Größen parametrisiert. Als Wahrscheinlichkeitsdichtefunktion ergeben sich für die Intensität des empfangenen Signals mit $L > 0$ und $M > 0$:

$$pdf(I) = \frac{\Gamma(L+M)}{\Gamma(L)\cdot\Gamma(M)} \frac{L}{M\mu} \frac{\left(\frac{LI}{M\mu}\right)^{L-1}}{\left(1+\frac{LI}{M\mu}\right)^{L+M}} \tag{3.21}$$

Und für Amplitude ergibt sich:

$$pdf(A) = \frac{\Gamma(L+M)}{\Gamma(L)\cdot\Gamma(M)} \sqrt{\frac{L}{M}} \frac{2}{\mu} \frac{\left(\sqrt{\frac{L}{M}}\frac{A}{\mu}\right)^{2L-1}}{\left(1+\left(\sqrt{\frac{L}{M}}\frac{A}{\mu}\right)^{2}\right)^{L+M}} \tag{3.22}$$

Hierbei sind L und M Formparameter der Verteilung und μ ein Gewichtungsfaktor.

Die Fisher-Verteilung ist besonders durch ihre Flexibilität gekennzeichnet. Insbesondere kann der Schwanz der Verteilung mehr oder weniger gewichtet werden, was es erlaubt eine Menge an unterschiedlichen Oberflächen zu charakterisieren. Die Gewichtung des Schwanzes ist über den Parameter M justierbar (siehe Abbildung 3.4).

Haupt-Vorteil dieser Verteilung im Vergleich zu bisherigen Modellen ist, dass für M gegen unendlich, die Fisher-Verteilung gegen die Gamma-Verteilung strebt. Außerdem ist das Gesetz von Fisher implizit bereits in anderen Modellen beschrieben [27]. Für ($L < M$) entspricht die Fisher-Verteilung den klassischen Verteilungen (Abs 3.1) und für ($L > M$) entspricht sie

„heavy-tailed“ Verteilungen.

Weitere Eigenschaften

Die Fisher-Verteilung ist durch die Mellin-Transformation (vgl. [21]) einer Gamma-Verteilung mit einer inversen Gamma-Verteilung mit $pdf(I) = InverseGamma(1,M) \hat{\star} Gamma(\mu,L)$ konstruiert. Für das Amplitudenbild ist die Fisher-Verteilung durch die Mellin-Transformation der Rayleigh-Nakagami Verteilung mit der inversen Rayleigh-Nakagami Verteilung mit $pdf(A) = InverseNakagammi \hat{\star} Nakagammi(\mu,L)$konstruiert.

Allgemeine Probleme in der Heavy-tailed-Verteilung liegen darin, dass ihre Parameter nicht durch klassische Verfahren bestimmt werden können, weil nicht alle Momente existieren (dies gilt ausnahmsweise nicht für die Log-Normal-Verteilung). Beispielsweise existieren bei der Fisher-Verteilung alle Momente $M < 3$ nicht.

Eine Möglichkeit ergibt sich nach [22] in die „Second-Kind Statistics“ mit Hilfe der Mellin-Transform und der Bestimmung der log-Momente zu wechseln. Diese Methodik wird im nächsten Abschnitt beschrieben.

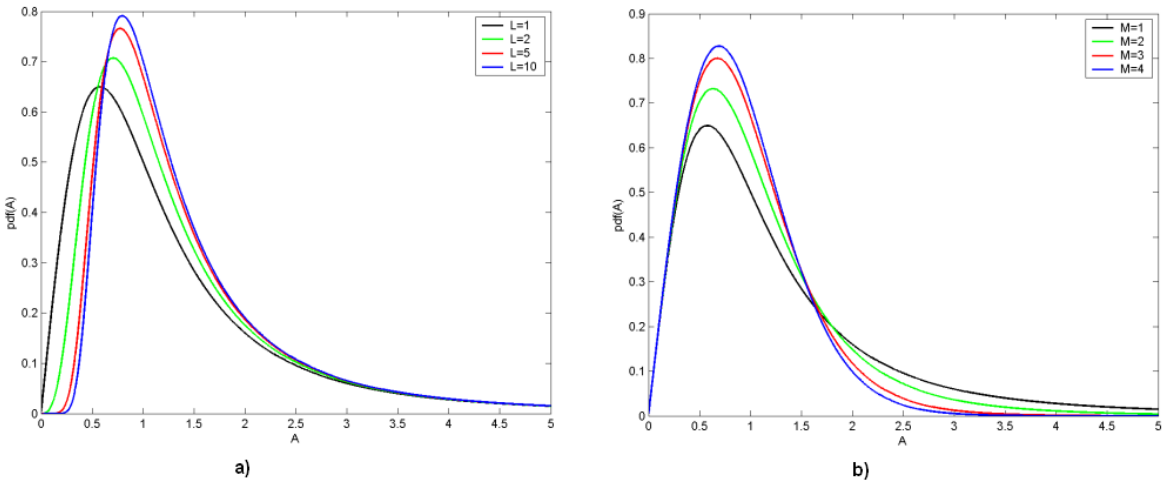

Abb. 3.4.: Fisher-Verteilung für das Amplitudenbild mit unterschiedlichen Parametereinstellungen a) $\mu = 1$, $M = 1$ und $L = 1,2,5,10$, b) $\mu = 1$, $L = 1$, $M = 1,2,5,10$ (Beschriftung der Abbildung Größer)

3.4. Parameterabschätzung durch: „Second-Kind Statistics“

Die Parameterabschätzung auf Basis der „Second-Kind Statistics“ ist eine spezielle Technik für die Abschätzung von Parametern der Wahrscheinlichkeitsdichtefunktionen deren Verteilungen über die positive Achse (Rechtsachse: $[0,+\infty]$) definiert sind. Diese Eigenschaft ist u.a. bei den statistischen Modellen von SAR Amplituden- und Intensitätsdaten gegeben. In diesem Abschnitt werden grundlegende Ideen der „Second-Kind Statistics“ beschrieben. Der

Schwerpunkt liegt hierbei in der Abschätzung der Parameter der Fisher-Verteilung.

3.4.1. Die Mellin Transformation

In der klassischen Statistik wird die Wahrscheinlichkeitsdichtefunktion mit Hilfe der Fouriertransformation analysiert. Mithilfe der Fouriertransformation kann die charakteristische Funktionen einer pdf bestimmt werden. Die charakteristischen Funktionen sind ein wichtiges analytisches Hilfsmittel in der Statistik. Mit ihnen können die Momente stetiger sowie der diskreten Zufallsvariable berechnet werden. Bezüglich des Wertebereiches der Zufallsvariable muss keine Einschränkung gemacht werden. Während die Momenterzeugende Funktion[1] reellwertige ist, handelt sich bei der charakteristischen Funktionen um eine komplexwertige Funktion.

Die charakteristische Funktion einer Wahrscheinlichkeitsdichtefunktion ist durch ihre Fouriertransformation definiert:

$$\Phi_x(\nu) = \int_{-\infty}^{+\infty} e^{i\nu u} pdf_x(u) d_u \tag{3.23}$$

Mit $pdf_x(u)$ als Wahrscheinlichkeitsdichtefunktion einer Zufallsvariablen X und u aus $\mathbb{R}$ (reelle Zahlen). Wobei die imaginäre Einheit j definiert ist mit $j^2 = -1$. Soweit die Momente einer Zufallsvariablen existieren, kann man sie mittels der charakteristischen Funktion dieser Zufallsvariable bestimmen.

Im Allgemeinen gelten folgende Eigenschaften bzgl. der charakteristischen Funktion:

- die n-te Moment der Wahrscheinlichkeitsdichtefunktion lässt sich durch die n-te Ableitung der charakteristischen Funktion bestimmen.
- die n-te Kumulante lässt sich durch die n-te Ableitung der logarithmischen charakteristischen Funktion bestimmen.
- erste und zweite Ordnung der Kummulante entsprechen Mittelwert und Varianz der Verteilung.

Es ist wichtig an dieser Stelle zu betonen, dass die Momente und Kumulanten einer pdf stark von den Parameter abhängen, die die Verteilung bestimmen. Alle statistichen Momente eines pdf können mit Hilfe der Fouriertransformtion hergeleitet werden.

In der „Second-Kind Statistics“ werden alle Funktionen über $\mathbb{R}_+$ (positive Reelle Zahlen) mit Hilfe der Mellin-Transformation analysiert. Also für alle Zufallsvariablen X die Werte u aus $\mathbb{R}_+$ annehmen.

[1] Mit der Momenterzeugenden Funktion kann das k-te Moment der Wahrscheinlichkeitsverteilung einer Zufallsvariablen ermittelt werden

Für eine Funktion f definiert über R_+ ist das Integral $MT[f]$

$$MT[f](s) = \int_0^{+\infty} u^{s-1} f(u) du \tag{3.24}$$

die Mellin-Transformation von f und s eine komplexe Zahl dessen Norm gleich eins ist. Die Mellin-Transformation von einer Funktion existiert nur, wenn sie über R_+ definiert ist. Die Wahrscheinlichkeitsdichtefunktionen von SAR Intensitäts- und Amplitudenbildern sind exakt über derselben Intervall mit $\int_0^{+\infty} pdf_x(u)du = 1$ definiert. Daher existieren deren Mellin-Transfomation für alle Werte der komplexen Zahl s.

3.4.2. Wichtige Definitionen der Second-Kind Statistics

Die „Second-Kind Statistics“ ist eng mit der Analyse der pdf basierend auf der Fouriertransformation verwandt. Es ergeben sich folgende Funktionen nach [17]:

- Erste charakteristische Funktion der „Second-Kind Statistics“ für die Zufallsvariable X ist durch die Mellin-Transformation gegeben:

$$\phi_s(s) = MT[pdf_x] = \int_0^{+\infty} u^{s-1} pdf_x(u) du \tag{3.25}$$

- Die zweite charakteristische Funktion der „Second-Kind Statistics“ wird definiert durch den natürlichen Logarithmus der ersten charakteristischen Funktion:

$$\Psi_x(s) = log(\phi_x(s)) \tag{3.26}$$

- Der r-te Moment (Log-Momente) der „Second-Kind Statistics“ ist über die r-te Ableitung der ersten charakteristischen Funktion wie folgt definiert:

$$\tilde{m}_r = \frac{d^r \phi_x(s)}{ds^r}|_{s=1} = \int_0^{+\infty} (logu)^r pdf_x(u) du \tag{3.27}$$

- r-te Kumulante („log- Kumulante“) der „Second-Kind Statistics“ ist über die r-te Ableitung der charakteristischen Funktion wie folgt definiert:

$$\tilde{k}_r = \frac{d^r \Psi_x(s)}{ds^r}|_{s=1} \tag{3.28}$$

Ebenso wie bei der Fouriertransformation hängen auch die Log-Momente und die Log-Kumulanten einer pdf über R_+ von dem beschriebenen Parameter ab.

Zwischen Gl. 3.27 und 3.28 gibt es eine Beziehung nach [23], die wie folgt ausgedrückt ist:

$$\tilde{k}_1 = \tilde{m}_1 \tag{3.29}$$
$$\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1 \tag{3.30}$$
$$\tilde{k}_3 = \tilde{m}_3 - \tilde{m}_1\tilde{m}_2 + 2\tilde{m}_1^3 \tag{3.31}$$

Die ersten drei log-Kumulanten können mit Hilfe eines empirischen Ausdrucks mit N Stichproben y_i wie folgt abgeschätzt werden:

$$\tilde{k}_1 = \frac{1}{N}\sum_{i=1}^{N}[log(y_i)] \tag{3.32}$$
$$\tilde{k}_2 = \frac{1}{N}\sum_{i=1}^{N}[(log(y_i) - \tilde{k}_1)^2] \tag{3.33}$$
$$\tilde{k}_3 = \frac{1}{N}\sum_{i=1}^{N}[(log(y_i) - \tilde{k}_1)^2]. \tag{3.34}$$

Die empirischen Ausdrücke werden üblicher Weise als „log-Momente“ bezeichnet.

3.4.3. Parameterabschätzung der Fisher-Verteilung

In diesem Abschnitt wird die Idee zur Abschätzung der Parameter der Fisher-Verteilung für das Intensitätsbild nach [21] vorgestellt. Die Abschätzung für das Amplitudenbild erfolgt durch eine kleine Modifizierung des im Folgenden beschriebenen Verfahrens.

Die Fisher-Verteilung ist durch die Parameter L, M und μ beschrieben. Eine analytische Beziehung zwischen den Parametern und der log-Kumulante ist durch die Digamma Funktion Ψ und die Polygamma Funktion $\Psi(n,L)$ (vgl. [18]) gegeben. Für das Intensitätsbild ergibt sich die folgende Beziehung zwischen den log-Kumulanten und den Parametern mit $L,M > 0$:

$$\tilde{k}_1 = log(\mu) + (\Psi(L) - log(L)) - (\Psi(M) - log(M)) \tag{3.35}$$
$$\tilde{k}_2 = \Psi(1,L) + \Psi(1,M) \tag{3.36}$$
$$\tilde{k}_3 = \Psi(2,M) - \Psi(2,L) \tag{3.37}$$

Für das Amplitudenbild ist eine Beziehung zwischen den log-Kumulanten und Parametern durch folgendes Gleichungssystem mit $L,M > 0$ gegeben:

$$\tilde{k}_1 = log(\mu) + \frac{1}{2}(\Psi(L) - log(L)) - \frac{1}{2}(\Psi(M) - log(M)) \tag{3.38}$$
$$\tilde{k}_2 = \frac{1}{4}(\Psi(1,L) + \Psi(1,M)) \tag{3.39}$$
$$\tilde{k}_3 = \frac{1}{8}(\Psi(2,M) - \Psi(2,L)) \tag{3.40}$$

Die Schätzung der Parameter der Fisher-Verteilung erfolgt durch Lösen des Gleichungssystems (Gleichungen 3.35 - 3.37) für das Intensitätsbild bzw. für das Amplitudenbild (Gleichungen 3.38 - 3.40). Die ersten drei Kumulanten können nach Abschnitt 3.4.2 mit Hilfe von Stichproben abgeschätzt werden. Eine analytische Lösung der Gleichungssysteme ist aufgrund der Digamma- und Polygamma Funktionen nicht möglich. Sie kann aber aufgrund der Monotonie der Polygamma Funktion numerisch gelöst werden.

In dieser Arbeit wird eine numerische Methode nach [24] angewendet um das obige Gleichungssystem zu lösen. Die wesentlichen Schritte zur Bestimmung der Parameter der Fisher-Verteilung für das Intensitätsbild sind:

1. Auswahl einer Region (Acker, Siedlung, ...) im SAR-Bild
2. Bestimmung der abgeschätzten log-Kumulanten $\tilde{k}_1 - \tilde{k}_3$ nach Abschnitt 3.4.2. Die Stichprobe entspricht hierbei den Pixelwerten der ausgewählten Region.
3. Bestimmung der Parameter L umd M mit Hilfe der der Gleichung 3.36 und 3.37 wie folgt:
   - Schritt 1:
     Lösung des Gleichungssystems mit Hilfe theoretischer Tabellen grob annähern. Theoretische Tabellen mit $\tilde{k}_2$ und $\tilde{k}_3$ als Funktionen von L und M erlauben eine grobe Lösung des Gleichungssystems.
   - Schritt 2:
     Mit der groben Schätzung kann der Algorithmus initialisiert werden, um präzisiere Lösungen zu finden
   - Alternativ:
     i) Initialisiere $M_0 = L_0$, es gilt dann:

     $$\Psi(1, M_0) = \Psi(1, L_0) = \frac{\tilde{k}_2}{2} \quad und$$

     $$\Psi(2, L_0) - \Psi(2, M_0) = 0$$

     ii) Überprüfe ob $\tilde{k}_3 \leq 0$, dann gilt $L < M$

     a) Erhöhe M um einem Schritt δM mit $M_1 = M_0 + \delta M$ und finde $L_1 \leq L_0$ so dass $\Psi(1, L_1) - \Psi(1, M_1) = \tilde{k}_2$ erfüllt ist.

     b) Überprüfe ob $\Psi(2, L_1) - \Psi(2, M_1) \leq \tilde{k}_3$ ist. Wenn nicht, dann wiederhole a) und b) bis beide Bedingungen erfüllt sind.
4. Sind L und M bestimmt, dann kann μ durch Gl. 3.35 bestimmt werden

Für das Amplitudenbild kann nach dem gleichen Schema vorgegangen werden. Hierzu muss die linke Seite des Gleichungssystems (Gleichungen 3.39 - 3.40) mit $4 \cdot \tilde{k}_2$ und $8 \cdot \tilde{k}_3$ ersetzt werden.

In [16] und [23] wurde die Güte der abgeschätzten Parameter durch die log-Momente überprüft. Die Parameter der Nakagami-Verteilung lassen sich durch die Methoden der Log-Momente (MoLC), die Momentmethode und die Maximum-Likelihood Methode bestimmen. Um eine Aussage über die Güte der abgeschätzten Parameter zu machen, wurden die drei Verfahren mit Hilfe des Mean Square Error (MSE) Kriteriums verglichen. Mit der MoLC wurden hierbei die besten Ergebnisse erzielt.

3.5. Validierungen des Fisher-Modells

Für die Parameterabschätzung der Fisher-Verteilung wurden fünf Klassen aus dem Amplitudenbild des TerraSAR-X Bildes von Fuhrberg ausgesucht. Für jede Klasse wurden die Parameter der Fisher-Verteilung bestimmt. In der Tabelle sind die berechneten Parameter der einzelnen Klassen sowie die Anzahl der Stichproben innerhalb der Klassen eingetragen.

Klasse	μ	**L**	**M**	**Anzahl der Pixel**
Wald	99.73	0.93	3.44	13400
Acker *hell*	165.92	0.98	13.69	17700
Acker *mittel*	102.45	0.93	18.05	18400
Acker *dunkel*	73.30	0.97	17.77	15200
Siedlung	86.64	0.97	1.25	10900

Tabelle 3.1.: Abgeschätzte Parameter der Fisher-Verteilung für verschiedene Klassen des TerraSAR-X Bildes von Fuhrberg

Um einen visuellen Vergleich zwischen der abgeschätzten Fisher-Verteilung und den tatsächlichen Verteilungen der Daten zu ermöglichen, wurden zusätzlich für die gleichen Klassen Histogramme erstellt. In Abbildung 3.5 sind die ausgewählten Klassen und darunter die abgeschätzten Fisher-Verteilungen mit den jeweiligen Histogrammen zu sehen. Vergleicht man die Histogramme der einzelnen Klassen mit den abgeschätzten Fisher-Verteilungen, so ist eine sehr gute Anpassung der Verteilungen an die Daten zu erkennen. Eine Besonderheit der Verteilung ist, dass sowohl natürliche Flächen, wie z.B. Wald und Acker, als auch städtische Gebiete mit der Verteilung gut angepasst werden können. In Abbildung 3.5 e) sieht man, dass städtische Gebiete, welche durch einen „heavy tail“ im Histogramm gekennzeichnet sind, gut mit der Fisher-Verteilung angepasst werden können.

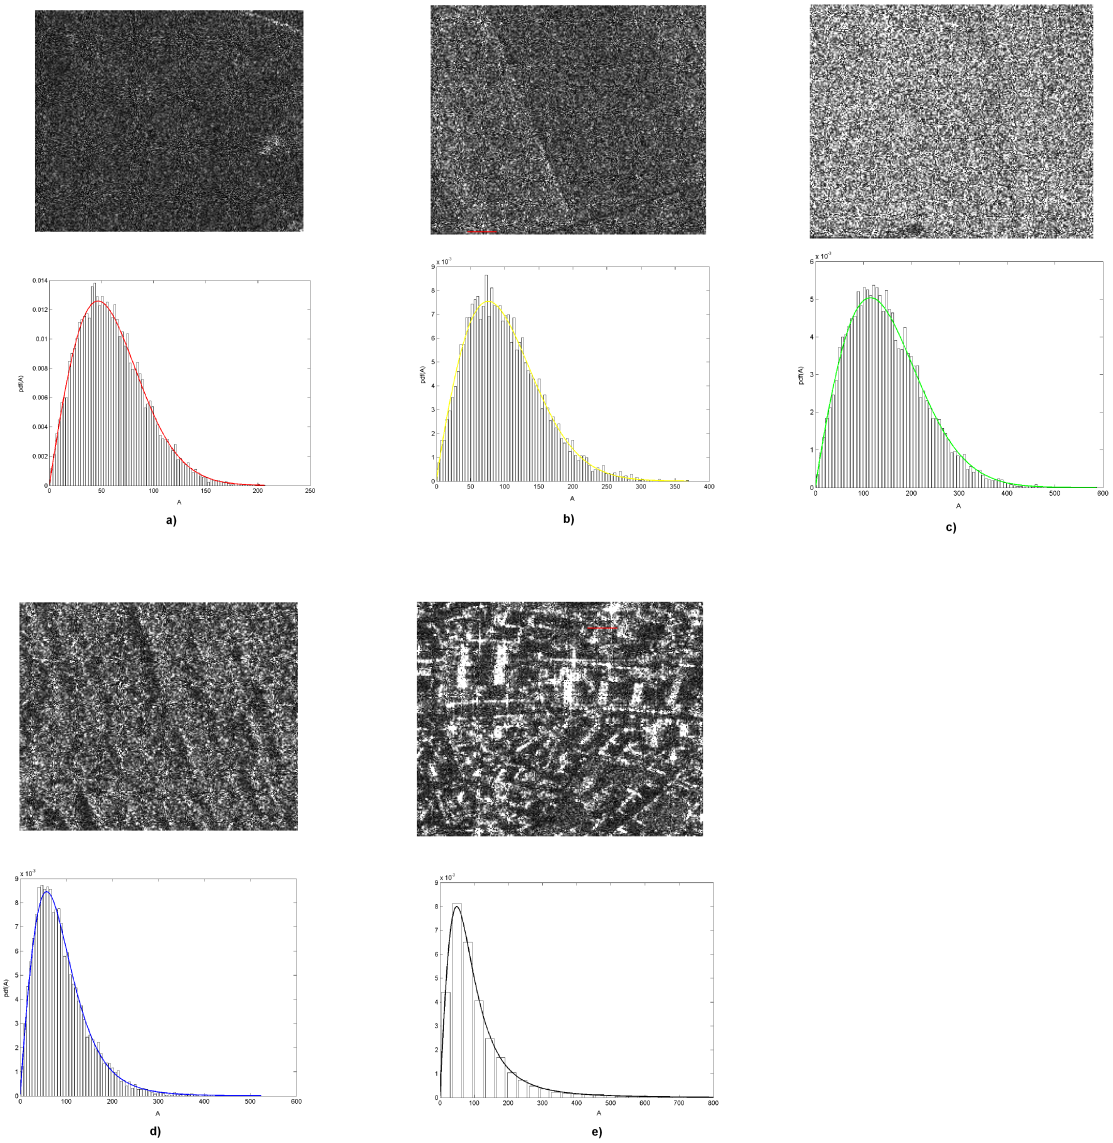

Abb. 3.5.: Abschätzung der Fisher-Verteilung für verschiedene Klassen der Fuhrberg SAR-Szene. Der gelbe Bereich stellt das Histogramm der Daten dar a) Klasse Acker *dunkel*, b) Klasse Acker *hell*, c) Klasse Acker *mittel*, d) Klasse Wald und e) Klasse Siedlung

4. Klassifikation mit Markoff-Zufallsfeldern

Die Klassifikation der SAR-Szene erfolgt in dieser Arbeit durch die Kombination der Sensorstatistik und der Modellierung der Nachbarschaftsbeziehung mittels eines Markoff-Zufallsfeldes. Die Kombination basiert auf der Bayes-Statistik, sodass das Bayes-Theorem angewendet werden kann. Entsprechend wird die Statistik der SAR-Daten im Likelihood-Term modelliert während Nachbarschaften im a priori-Term berücksichtigt werden.

In Abschnitt 2.4 wurde bereits beschrieben, dass SAR-Bilder dem Speckle-Effekt unterliegen und diese sich besonders ungünstig auf die Erkennung von Objektklassen auswirken. Die Objektklassen wirken körnig und erschweren den Klassifikationsprozess. Anderseits verschlechtert eine Speckle-Filterung vor die Klassifikation die räumliche Auflösung. Um eine Speckle-Filterung zu vermeiden wurden Markoff-Zufallsfelder ausgewählt, welche die Kontinuität innerhalb der Objektklassen bewahren. Hierbei geht man von der Annahme aus, dass der Speckle-Effekt sich auf lokal begrenzte Gruppen von Pixeln bezieht. Die Formulierung der Kontinuität der Objektklassen durch das Markoff-Zufallsmodell bewirkt, dass die Entscheidung, ob ein Pixel zu einer Objektklasse angehört, nicht nur von lokalen Daten (SAR-Statistik im Likelihood-Term), sondern auch von Eigenschaften benachbarter Pixel abhängt. Durch die Berücksichtigung der Nachbarschaften wird der kontinuierliche Verlauf der Objektklasse über größere Regionen hinweg unterstützt und der Speckle-Effekt reduziert, ohne die Auflösung und damit den Informationsgehalt der Daten zu reduzieren.

Hauptziel dieses Kapitels ist die Modellierung des Markoff-Zufallsfeldes für die Klassifikation. Zunächst wird in Abschnitt 4.1 ein kurzer Überblick über Klassifikationsansätze in der Radarfernerkundung gegeben. In Abschnitt 4.2 werden Allgemeine Begriffe und mathematische Grundlagen, die zum Verständnis von Markoff-Zufallsfeldern benötigt werden, eingeführt. Die praktische Anwendung von Markoff-Zufallsfeldern ist durch ihre Äquivalenz zur Gibbs-Verteilung gegeben welche in Abschnitt 4.3 beschrieben wird. Die Klassifikation wird durch die Modellierung des Markoff-Zufallsfeldes bestimmt, welche in Abschnitt 4.4 behandelt wird. Schließlich wird in Abschnitt 4.5 ein numerisches Verfahren vorgestellt, mit dem das Markoff-Modell gelöst werden kann.

4.1. Klassifikationsansätze in der Radarfernerkundung

In diesem Abschnitt wird kurz auf die wesentlichen Methoden und Ansätze der Klassifikation von Bildern in der Fernerkundung eingegangen. Weiterhin werden verschiedene Klassifikationsansätze aus der Literatur beschrieben, die auf Radarbilder angewendet werden können. Ziel dieses Abschnittes ist es in erster Linie einen groben Überblick über die Klassifikationsmöglichkeiten von Radarbildern zu geben.

Allgemeines

In der Fernerkundung bedeutet Klassifikation die Zusammenfassung von Objekten (Pixel, Segmente) zu Objektklassen (Klassen, Label) basierend auf Merkmalen oder Eigenschaften der Objekte. Die Art und Anzahl der Objektklassen werden vom Nutzer festgelegt. Die Vorgehensweise einer Klassifikation kann pixelbasiert oder auf Basis von Bildsegmenten erfolgen. Im ersteren Fall stellt jeder Pixel ein Objekt dar und jede Objektklasse enthält Objekte mit ähnlichen Merkmalen. Die Klassifikation ist mathematisch betrachtet eine eindeutige Abbildung des gesamten Merkmalraumes auf die Menge der Objektklassen, wobei der Merkmalsraum aus der Menge aller Zustände der Merkmale entsteht. Er kann auch als ein mehrdimensionaler Raum interpretiert werden, wobei die Dimensionen durch die Merkmale des Merkmalsvektors aufgespannt werden. Im Merkmalsraum ist jede Dimension durch den Wertebereich des entsprechenden Merkmals begrenzt. Die Abbildung 4.1 verdeutlicht das Prinzip der Abbildung des Merkmalraums auf die Objektklassen.

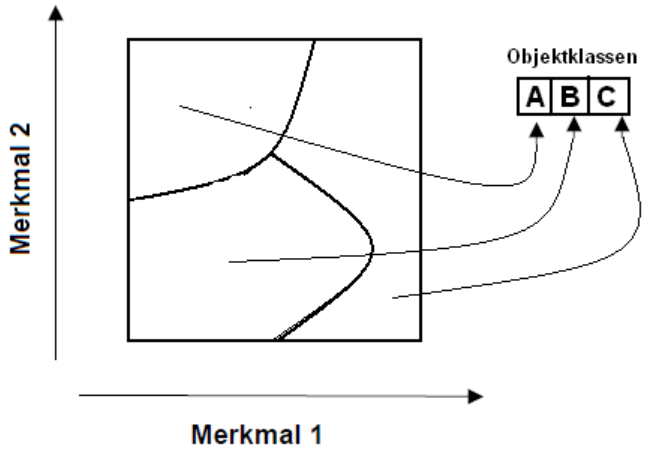

Abb. 4.1.: Abbildung des Merkmalraums auf die Menge der Objekte

Hierbei wird jeder Bildpunkt in einem zwei-dimensionalen Merkmalsraum dargestellt. Aufgrund von zwei Merkmalen (z.B. Grauwert und Grauwertgradient) werden die Bildpunkte den Objektklassen (A, B und C) zugeordnet. Die Objektklassen sind durch Cluster im Merkmalsraum charakterisiert.

Überwachte und unüberbewachte Klassifikation

Für die Abbildung des Merkmalsraums auf die Objektklassen existieren zwei Möglichkeiten:

- überwachte und die unüberwachte Klassifikation

Bei der unüberwachten Klassifikation suchen zumeist iterativ arbeitende Algorithmen nach Clustern ähnlicher Merkmale im Merkmalsraum, wodurch eine Art Vorklassifizierung stattfindet. In einem zweiten Schritt erfolgt die Zuordnung vorklassifizierter Objekte auf die Menge der Objektklassen. Zu den bekanntesten Algorithmen gehört der „K-Means Algorithmus“ (vgl. [25]).

Im Gegensatz dazu wird bei der überwachten Klassifikation jedes Objekt direkt auf die Objektklassen abgebildet. Die Segmentierung des Merkmalraums erfolgt durch eine sogenannte Musterklasse, die meist durch eine statistische Beschreibung der jeweiligen Objektklasse definiert ist. Ein Vergleich des konkreten Objektes mit allen vorhandenen Musterklassen ermöglicht eine Auswahl des am besten passenden Musters, wodurch ein Objekt den entsprechenden Objektklassen zugeordnet werden kann.

Die Beschreibung einer Musterklasse erfolgt durch Auswerten verwendeter Merkmale in Bildbereichen bekannter Objektklassen. Diese werden auch als Trainingsgebiete bezeichnet, da sie in der ersten Phase der Klassifikation (auch Trainingsphase genannt) die Abbildung des Merkmalraums auf die Objekte festlegen. Die eigentliche Klassifikation, also das Abbilden einzelner Pixel auf die Objektklassen aufgrund einer Abbildungsvorschrift, erfolgt in einem zweiten Schritt. Eine bekannte überwachte Klassifikation ist die Maximum-Likelihood-Klassifikation [26], in der von einem normalverteilten Datensatz ausgegangen wird. Hierbei kann beispielsweise eine Objektklasse durch den Mittelwert und die Standardabweichung im eindimensionalen Merkmalsraum charakterisiert werden.

Klassifikationsansätze für Radarbilder

Aus den Prinzipien der Radarfernerkundung können eine Reihe von Informationen für eine Klassifikation verwendet werden. Neben der Intensität und Amplitude für verschiedene Wellenlängen und Polarisationen können auch aus der komplexen Streumatrix eine Reihe weiterer Parameter extrahiert werden. Hierfür bieten sich beispielsweise die Polarisationsparameter aus der Eigenwertkomposition an [27]. Eine Erweiterung der Datenbasis kann durch die Kohärenz dargestellt werden, wenn multitemporale SAR-Daten [28] zur Verfügung stehen.

Es gibt in der Literatur eine Reihe von Klassifikationstechniken, deren Anwendung meist auf den jeweiligen Datentyp angepasst wird. Das Ergebnis des Klassifizierungsprozesses hängt in der Regel von zwei wichtigen Entscheidungen ab:

- Die Klassifikationsmethode erlaubt es eine Entscheidung zwischen allen Klassen zu treffen.
- Durch einen Satz aus Parametern werden Klassen charakterisiert. Durch diese wird dann im Klassifikationsprozess eine Entscheidung getroffen.

Im Hinblick auf die Klassifikationsmethoden sind besonders zwei verschiedene Ansätze zu nennen:

- Bayes-Ansätze, die a priori-Wissen über die statistische Verteilung der Parameter berücksichtigen
- Ansätze wie etwa neuronale Netze [29], [30] oder Ansätze aus der angewandten Mathematik wie Support-Vector-Machine (SVN) [31]

Bezüglich der Parameter, die für die Klassifikation verwendet werden können, seien im Folgenden einige Beispiele aus der Literatur genannt:

- Radiometrie (Amplitude bzw. Intensität)

- Varianz oder Variationskoeffizient einer Region
- Texturparameter: Parameter des Markoff-Modells, Parameter aus der Cooccurrence-Matrix [32]
- Strukturelle Parameter: Länge, Breite, Oberfläche, ...
- Polarimetrische Parameter [33], falls Multi-Polarimetrsiche Daten vorhanden sund
- Parameter der Kohärenz der Interferometrische Phasen [34], falls Daten aus der Interferometrie vorhanden sind

Für die Klassifikation von Radarbildern ist die meistbenutzte Methode der Bayes-Ansatz, welcher auch in dieser Arbeit angewendet und später noch genauer erläutert wird. Dieser Ansatz ist auf die radiometrische Information (Amplitude) beschränkt und wird auf ein einzelnes Radarbild angewendet. Jede Klasse der Szene wird durch einen eindimensionalen Merkmalsraum in Form einer Wahrscheinlichkeitsdichtefunktion der Amplitude beschrieben, und die Klassifikation erfolgt ausschließlich auf Grundlage dieses einzigen Merkmals. Dieses Merkmal kann beispielsweise für jede Klasse in einer überwachten Phase gelernt oder unter Verwendung geeigneter Algorithmen wie Expectation-Maximization [35] immer wieder geschätzt werden.

Weiterhin unterscheidet man in der Literatur [34] zwischen pixelbasierten- und Texturbasierten Methoden:

- *Pixelbasierte Methoden*: Jedes Pixel wird unabhängig von seinem Nachbarn klassifiziert. Nur der radiometrische Wert der Pixel wird für den Klassifikationsprozess berücksichtigt. Durch den unbehandelten Specke-Effekt ergeben sich durch diese Methode für SAR-Amplitudenbilder schlechte Ergebnisse.
- *Texturbasierte Methoden*: Diese Methoden basieren auf der Annahme, dass der Zustand eines Pixels an den Zustand der Nachbarn gebunden ist. Die Pixel sind nicht mehr im Vergleich zu ihrer einzigen Wahrscheinlichkeit in jeder Klasse geordnet, sondern auch im Vergleich zu denjenigen ihrer Nachbarn. Diese Methode, die am häufigsten verwendet wird, basiert auf Verteilung der Kovarianzmatrix. Sie spiegelt die statistischen Abhängigkeiten einer ausgewählten Nachbarschaft wieder. Diese Methode wird oft bei geringer auflösenden Bilddaten verwendet.

Für diese Arbeit werden hochauflösende SAR-Amplitudenbilder verwendet. Die Klassifikation dieser Bilder hat sich allerdings gegenüber geringer auflösenden SAR-Bildern nicht vereinfacht. Der Speckle-Effekt, der einem starken multiplikativen Rauschen entspricht ist weiterhin vorhanden. Daher ist ein Klassifikationsansatz ohne Berücksichtigung der SAR-Statistik und die lokalen Textureigenschaften unumgänglich.

In dieser Arbeit erfolgt daher die Klassifikation innerhalb des Bayes-Ansatz durch die Kombination der Sensorstatistik und der Modellierung der Nachbarschaftsbeziehung mittels eines Markoff-Zufallsfeldes.

Dieser Ansatz ist durch drei interagierende Module in Orfeo Toolbox (OTB) [1] implementiert (siehe Abbildung 4.2)

Die wesentlichen Funktionalitäten der Module und deren Komponenten werden an dieser Stelle kurz zusammengefasst. Die zu diesen Modulen vertiefende Theorie wird im Rest des Kapitels behandelt.

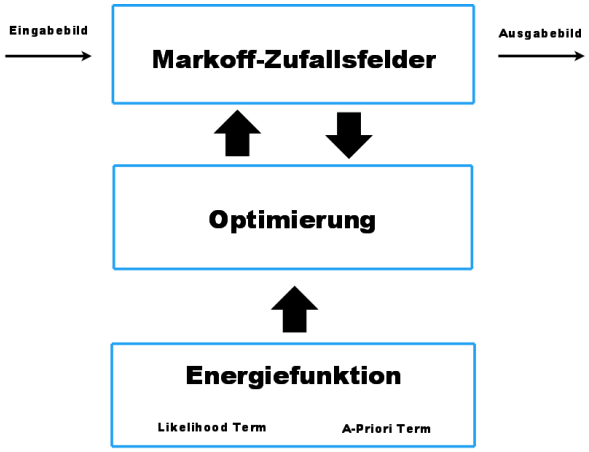

Abb. 4.2.: OTB MRF-Framework

In einem Markoff-Zufallsfeld F wird jeder Pixel einer Bildmatrix mit einer Zufallsvariable F_i verbunden. Aufgrund der Nachbarschaftsbeziehungen wird jedem Pixel ein Wert zugeordnet, der in der Zufallsvariable abgebildet ist. Dieser Wert kann in Form eines Labels aus einer Labelmenge L bzw. einer Objektklasse aus einer Menge von Objektklassen vorliegen.

Ist allen Pixeln des Markoff-Zufallsfeldes ein Label zugeordnet, so spricht man von einer Konfiguration f des Feldes bzw. einer Klassifikation. Eine Konfiguration mit der größten Wahrscheinlichkeit $P(f)$ stellt die optimale Klassifikation dar.

Durch die Äquivalenz von Markoff-Zufallsfeldern und Nachbarschafts-Gibbsfeldern wird die Bestimmung der Wahrscheinlichkeit $P(f)$ einer Konfiguration vereinfacht. Die praktische Anwendung erfolgt dann durch eine Energiefunktion $E(f)$. Durch diese wird dann die Wahrscheinlichkeit einer Konfiguration f bestimmt.

Die Energiefunktion setzt sich aus der Summe von priori- und Likelihood-Term zusammen. Der priori Term wird durch die Modellierung der Cliquenpotentiale berechnet. Durch ihr Design wird Vorwissen in einem Markoff-Zufallsfeld eingebracht. Mit dem Likelihood-Term werden die Daten modelliert. Die Modellierung der Energiefunktion bestimmt das Klassifikationsergebnis.

Die optimale Konfiguration des Markoff-Zufallsfeldes ergibt sich durch die a posteriori Wahrscheinlichkeit. Hierbei entspricht die maximale a posteriori Wahrscheinlichkeit der Minimierung der Energiefunktion. Durch einen Optimierungsprozess wird aus einer zufälligen

[1] http://www.orfeo-toolbox.org/otb

Menge von Konfigurationen die Konfiguration, welche die a posteriori Wahrscheinlichkeit ein Maximum besitzt, berechnet.

4.2. Mathematische Grundlagen und Begriffe

4.2.1. Zufallsfelder

Die Klassifikation eines Bildes kann als ein Labeling-Problem betrachtet werden. Dieses ist durch die Zuordnung einer Labelmenge L zu jeder Entität i aus einer Indexmenge S festgelegt.

Es sei S eine Indexmenge von m Entitäten mit

$$S = \{1, \ldots, m\} \tag{4.1}$$

wobei $1, \ldots, m$ die Indizes der Entitäten entsprechen. Eine Entität kann beispielsweise ein Pixel sein. Die Menge der Entitäten wird im Fall eines Bildes auf einem rechteckigen Gitter der Größe $n \times n$ definiert durch:

$$S = \{(i, j) | 1 \leq i, j \leq n\} \tag{4.2}$$

Die Elemente entsprechen den Koordinaten der Pixel eines Bildes. Im Allgemeinen ist die Reihenfolge der Entitäten in einem Markoff-Zufallsfeld nicht von Bedeutung, weil die Beziehung der Entitäten durch ein Nachbarschaftssystem bestimmt wird. Die Definition des Nachbarschaftssystems erfolgt später im Kontext der Markoff-Zufallsfelder. Daher wird bei einem $n \times n$ Bild ein Pixel (i, j) durch eine Nummer k indiziert, wobei k ein Wert aus $\{1, \ldots, m\}$ mit $m = n \cdot n$ ist.

Weiterhin sei eine Labelmenge L definiert durch eine Menge von M Labeln mit:

$$L = \{1, \ldots, M\} \tag{4.3}$$

Jede Entität $i \in S$ kann einem Label $f_i \in L$ zugeordnet werden.
Ist allen Entitäten ein Label aus der Labelmenge L zugeordnet, so wird

$$f = f_1, f_2, \ldots, f_m \tag{4.4}$$

als Labeling bezeichnet. Anschaulich kann f als eine Abbildungsfunktion aller Entitäten aus S zur Labelmenge L mit

$$f : S \rightarrow L \tag{4.5}$$

betrachtet werden (siehe Abbildung 4.3).

Bezüglich der Zufallsfelder wird eine Labeling[2] f auch als eine Konfiguration bzw. eine Realisation des Zufallsfeldes bezeichnet.

Wenn alle Entitäten der gleichen Labelmenge zugordnet werden können, dann ergibt sich die Menge aller möglichen Labelings durch den Konfigurationsraum

$$\mathbb{F} = L \cdot L \cdot \ldots L = L^m, \tag{4.6}$$

wobei m die Größe von S ist.

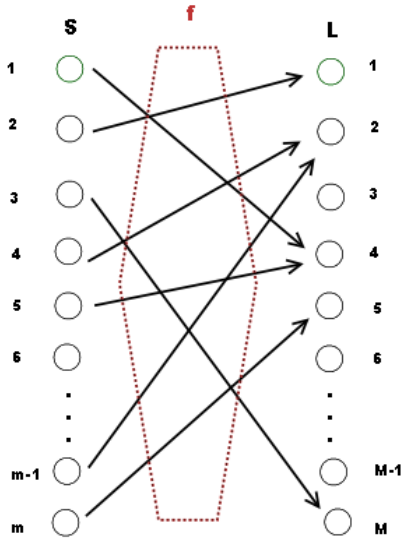

Abb. 4.3.: Labeling-Prinzip (gezeichnet nach [36])

Ist jeder Entität ein Label zugeordnet, wird es möglich, die Entität des Zufallfeldes im Kontext ihrer jeweiligen Nachbarn zu betrachten.

Ein Zufallsfeld $F = \{F_1, F_2, \ldots, F_m\}$ besteht aus eine Familie von Zufallsvariablen, die über die Menge der Entitäten S definiert sind. Jede Zufallsvariable F_i kann einen Label f_i aus L zu geordnet werden. Es werden folgende Notationen nach [36] festgelegt:

- $F_i = f_i$
  Bezeichnet das Ereignis, welches die Zufallsvariable F_i mit dem Label f_i belegt.

- $F = f$
  Bezeichnet das Verbundereignis $(F_1 = f_1, \ldots, F_m = f_m)$ wobei $f = f_1, f_2, \ldots, f_m$ der Konfiguration bzw. der Realisierung des Zufallsfeldes entspricht.

- $P(f_i)$
  Die Wahrscheinlichkeit, dass die Zufallsvariable F_i mit dem Label f_i belegt wird.

[2] Ein Labeling eines Feldes steht für die Klassifikation eines Bildes und ein Label für eine Klasse.

- $P(f)$
  Die Verbundwahrscheinlichkeit (bzw. bedingte Wahrscheinlichkeit), dass Zufallsfeld F die Konfiguration f hat (entspricht $P(F = f) = P(F_1 = f_1, \ldots, F_m = f_m)$)

Weiterhin sei $y = (y_1, \ldots, y_m)$ ein Beobachtungsvektor, wobei y_i dem Grauwert der Entität i (Pixel) entspricht.

4.2.2. Bayes-Theorem

In dieser Arbeit sollen zwei Informationsquellen fusioniert werden. Dies sind zu einem die Likelihood-Funktion und zum anderem das a priori-Wissen. Ein Ansatz zu Fusion mehrerer Informationsquellen ist durch das Bayes-Theorem gegeben. Diese ermöglicht mit Hilfe von Beobachtungen (bzw. Beobachtungsvektor) y den Kenntnisstand über die unbekannte Konfiguration f zu verbessern.

Sei L eine Menge von gesuchten Objektklassen und y eine Beobachtungsvektor wie oben. Sind weiterhin a priori-Wahrscheinlichkeit $P(y)$ und die Likelihood-Funktion $p(y|f)$ über des Beobachtungsvektor y bei gegebener Konfiguration f bekannt, dann erfolgt die optimale Abschätzung der Konfiguration f durch die Maximierung der a posteriori Wahrscheinlichkeit (Maximum A-Posteriori Possibility, MAP). Die a posteriori Wahrscheinlichkeit kann durch das Bayes-Theorem berechnet werden mit:

$$P(f|y) = \frac{p(y|f) \cdot P(f)}{p(y)} \tag{4.7}$$

Dabei stellt die Wahrscheinlichkeitsdichte p(y) des Beobachtungsvektors y eine Normierungskonstante des Datensatzes dar und hat keinen Einfluss auf die MAP-Lösung. In der Literatur wird die Bestimmung der MAP auch als Bayesches Labeling Problem bezeichnet. Dabei wird bei gegebener Beobachtung y die MAP optimale Konfiguration des Labelings gefunden mit:

$$f^* = argmax_{f \in \mathbb{F}} \, P(F = f|y) \tag{4.8}$$

Für die Bestimmung der MAP werden die a priori-Wahrscheinlichkeit und die Likelihood-Funktion benötigt. Die Likelihood-Funktion $p(y|F = f)$ ist durch die Statistik der Objektklassen in der Beobachtungsvektor y bestimmt. Die Bestimmung der a priori-Wahrscheinlichkeit stellt sich generell nach [36] als schwierig dar. Mit Hilfe eines Theorems kann diese aber mittels Markoff-Zufallsfeldern spezifiziert werden.

4.3. Markoff-Zufallsfelder und Gibbs-Verteilung

Eine wichtige Eigenschaft von Markoff-Zufallsfeldern, welche bereits in den vorherigen Abschnitten erwähnt wurde, ist die Möglichkeit zur Modellierung von Wissen über lokale Relationen. Von besonderer Bedeutung sind in diesem Zusammenhang die Begriffe Nachbarschaft und Clique. Für die praktische Anwendung von Markoff-Zufallsfeldern werden die äquivalenten Nachbarschafts-Gibbsfelder verwendet. Ihre gemeinsame Wahrscheinlichkeitsverteilung $P(f)$ ergibt sich aus der Summierung der Potentiale von Cliquen eines Nachbarschaftsystems.

Die Nachbarschafts-Gibbsfelder, Cliquen und Potentiale werden in diesem Abschnitt definiert.

Eine Nachbarschaft N_i verbindet eine Anzahl von Entitäten i des Zufallsfeldes zu Nachbarn mit Hilfe einer Nachbarschaftsrelation.

Ein Nachbarschaftssystem N bezüglich einer betrachteten Entität i bildet sich durch die Menge aller ausgewählten Nachbarschaftsrelationen der verbundenen Entitäten:

$$N = \{N_i | \forall_i \in S\} \tag{4.9}$$

Ein Zufallsfeld F ist ein Markoff-Zufallsfeld auf den Entitäten $i \in S$ hinsichtlich des Nachbarschaftsystems, wenn folgenden Bedingungen gelten:

$$P(f) > 0, \forall_i \in \mathbb{F} \tag{4.10}$$

$$P(f_i | f_{s-(i)}) = P(f_i, f_{N_i}) \tag{4.11}$$

Worin f_{N_i} die Menge aller Label der Nachbarschaften von der Entität i ist.

Die Gl. 4.10 beschreibt die Positivität der Wahrscheinlichkeit einer Verteilung und ist nach [36] immer erfüllt. Die lokale Charakteristik, also die eigentliche Markoff-Eigenschaft eines Markoff-Zufallsfeldes, wird durch die Gl. 4.11 beschrieben. Die bedingte Wahrscheinlichkeit besagt, dass die Wahrscheinlichkeit der Belegung einer Entität i durch ein Label f_i von den Labeln aller ihrer Nachbarn abhängt.

Das Aussehen eines Nachbarschaftsystems kann, abhängig von der Art der zu untersuchenden Entität, unterschiedlich sein. Zwei wesentliche Eigenschaften müssen jedoch alle gemeinsam haben:

1. Eine Entität ist kein Mitglied der eigenen Nachbarschaft (Irreflexivität) :

$$i \notin N_i \tag{4.12}$$

2. Gehört eine Entität i der Nachbarschaft der Entität i' an, ist i' Bestandteil der Nachbarschaft von i (Symmetrie):

$$i \in N_{i'} \leftrightarrow i' \in N_i \tag{4.13}$$

Markoff-Zufallsfelder sind allgemein auf Graphen definiert. Das Nachbarschaftssystem N und die Entitäten S konstruieren hierbei einen ungerichteten Graphen $\mathscr{G}(S,N)$. Die Knoten des Graphen entsprechen den Entitäten und die Kanten den Nachbarschaftsrelationen bezüglich eines Nachbarschaftsystems. Innerhalb eines Nachbarschaftssystems können Cliquen c unterschiedlicher Größe definiert werden.

Eine Clique ist eine Teilmenge der Entitäten S des ungerichteten Graphen, für die gilt dass alle Entitäten jeweils paarweise benachbart sein müssen. Eine Clique c kann aus einer

Entität $c = \{i\}$ (Einer-Clique) oder einem Paar von benachbarten Entitäten $c = \{i, j\}$ (Zweier-Cliquen) oder drei benachbarten Entitäten $c = \{i, j, k\}$ (Dreier-Cliquen) usw. bestehen.

Die Sammlung dieser Cliquen werden mit $C_1, C_2, C_3, \ldots$ bezeichnet wobei gilt:

$$C_1 = \{i | i \in S\} \tag{4.14}$$
$$C_2 = \left\{\left\{i, i'\right\} | i' \in N_{i'}, i \in S\right\} \tag{4.15}$$
$$C_3 = \left\{\left\{i, i', i''\right\} | i, i', i'' \in S \text{ sind miteinander benachbart}\right\} \tag{4.16}$$

Die Sammlung aller Cliquen bezüglich $\mathscr{G}(S, N)$ wird mit

$$C = C_1 \cup C_2 \cup C_3, \ldots \tag{4.17}$$

bezeichnet. Korrespondieren die betrachteten Entitäten mit den Pixeln einer Bildmatrix, dann entspricht die Anordnung der Entitäten einem regelmäßigen Gitter (siehe Abb. 4.4). Für die Konstruktion von Nachbarschaften wird nach [33] ein Ordnungssystem ausgewählt, bei dem die benachbarten Knoten nach ihrer Euklidischen Distanz ($dist(A, B)$) sortiert werden. Die Nachbarschaft lässt sich entsprechend formulieren:

$$N_i = \left\{i' \in S | [dist(Pixel_{i'}, Pixel_i]^2 \leq R, i' \neq i\right\} \tag{4.18}$$

R beschreibt die so genannte Ordnung der Nachbarschaft.

Angefangen mit der Nachbarschaft 0. Ordnung (d.h. die leere Menge) erhöht sich die Nachbarschaftsordnung um jeweils 1, wenn eine Gruppe von äquidistanten Knoten (hier bzgl. der 4-Nachbarschaft aufgrund der Veranschaulichung) zur Nachbarschaft hinzugefügt wird. In Abb. 4.4 d) sind Knoten bis zu 8. Ordnung für ein Gitter dargestellt. Damit entspricht das Vierer- Nachbarschaftsystem der 1. Ordnung (Abb.4.4 a)), das Achter-Nachbarschaftsystem der Nachbarschaft 2. Ordnung (Abb. 4.4 b) und das Zwölfer-Nachbarschaftsystem der 3. Ordnung (Abb. 4.4 c)).

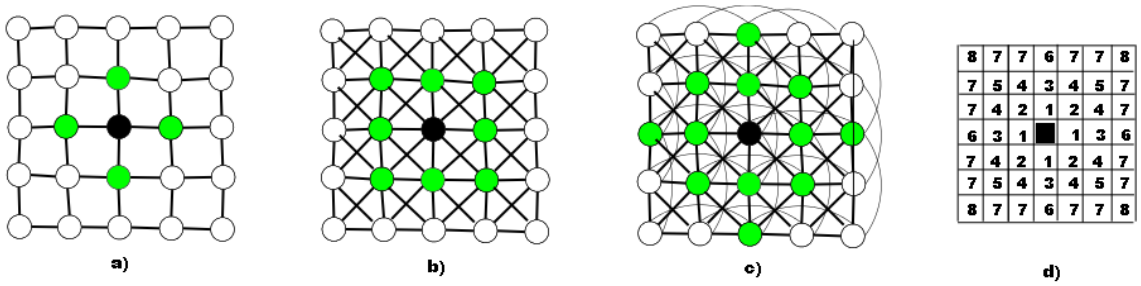

Abb. 4.4.: Graphendefinition für Nachbarschaften a) 1. Ordnung (4er-Nachbarschaft) b) 2. Ordnung (8er-Nachbarschaft), c) 3. Ordnung (12er-Nachbarschaft) auf einem 5×5 Gitter und d) Nachbarschaft bis 8. Ordnung (gezeichnet nach [37])

In Abb. 4.4 a-c) sind die Graphen dreier unterschiedlicher Nachbarschaften am Beispiel eines 5×5 Gitter dargestellt. Die Kreise symbolisieren die Knoten der Graphen. Die grün gefärbten Knoten entsprechen den Nachbarschaften des betrachteten schwarzen Knotens. Für die Nachbarschaft 1. Ordnung liegen lediglich eine Einer-Clique und zwei Zweier-Cliquen vor (Abb. 4.5 a). Für die 2. Ordnung liegen zusätzlich zwei Zweier- und vier Dreier- und eine Vierer-Clique vor (Abb. 4.5 b). Für die 3. Ordnung kommen noch zusätzlich zwei Zweier- und zwei Dreier-Cliquen mit geschwungener Kante dazu (Abb. 4.5 c). Mit Vergrößerung der Nachbarschaften steigt die Anzahl der Cliquen, die zu einem Gitter gehören, an.

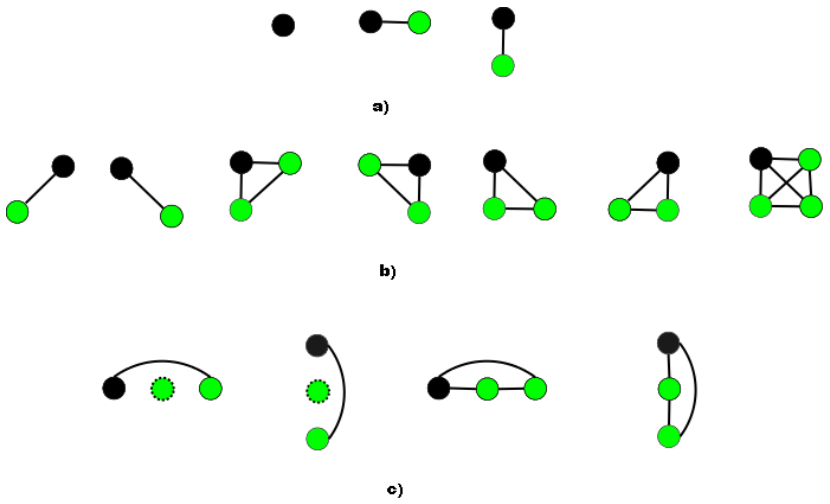

Abb. 4.5.: a) Cliquen einer Nachbarschaft 1. Ordnung, b) zusätzliche Cliquen einer Nachbarschaft 2. Ordnung und c) zusätzliche Cliquen einer Nachbarschaft 3. Ordnung (gezeichnet nach [37])

Für eine globale Betrachtung der Konfiguration f des Feldes ist die Bestimmung der Wahrscheinlichkeit der Konfiguration von $P(f)$ erforderlich. Die Ableitung der Wahrscheinlichkeit einer Konfiguration aus der bedingten Wahrscheinlichkeit des Markoff-Zufallsfeldes nach Gl. 4.11 ist jedoch schwer. Daher verwendet man in der Praxis ihre Äquivalenz zu Nachbarschafts-Gibbsfeldern nach dem Theorem von Hammersley und Clifford [38]. Mit ihrer Hilfe lässt sich die Wahrscheinlichkeit einer Konfiguration $P(f)$ in Form von Potentialen, die für Cliquen definiert werden, bestimmen. Das Theorem besagt, dass die Wahrscheinlichkeit einer Konfiguration f eines Markoff-Zufallsfeldes $P(f)$ mit Nachbarschaftssystem N äquivalent zu einer Gibbs-Verteilung ist mit

$$P(f) = \frac{1}{Z} e^{-U(f)} \tag{4.19}$$

wobei Z eine Normierungskonstante ist und $U(f)$ als Energiefunktion (in der Literatur [36] auch a priori-Energie) bezeichnet wird. Die Energiefunktion $U(f)$ wird als Summe aller Cliquenpotentiale in der Form

$$U(f) = \sum_{c \in C} V_c(f) = \sum_{i \in C_1} V_1(f_i) + \sum_{i,j \in C_2} V_2(f_i, f_j) + \dots \tag{4.20}$$

angegeben. Die Potentialfunktion V_c bildet die lokale Charakteristik eines Markoff-Zufallsfeldes auf das Nachbarschafts-Gibbsfelder ab und legt das Systemverhalten fest. Durch ihre Modellierung wird a priori-Wissen das Verhalten eines Markoff-Zufallsfeldes eingebracht. Es werden die Interaktionen der gelabelten Entitäten festgelegt, wobei die Modellierung der Potentialfunktion in Form einer Verteilungsfunktion dargestellt wird.

Das in Abschnitt 4.2.2 genannte Bayes-Theorem kann auch für die lokale Charakteristik des Markoff-Zufallsfeldes formuliert werden. Wird die Likelihood-Funktion in der Gibbs-Verteilung ausgedrückt, ergibt sich die bedingte Wahrscheinlichkeitsdichte einer Beobachtung y bei gegebener Konfiguration f durch

$$p(y|F = f) = \frac{1}{Z} e^{-U(y|f)} \tag{4.21}$$

wobei $U(y|f)$ auch als Likelihood-Energie bezeichnet wird. Die a posteriori Wahrscheinlichkeit der Gibbs-Verteilung lässt sich dann wie folgt formulieren:

$$P(F = f|y) = \frac{1}{Z} e^{-E(f)}. \tag{4.22}$$

Die a posteriori Energie $E(f)$ bzw. Energiefunktion setzt sich aus der Summe der a priori- und Likelihood-Energie zusammen mit:

$$E(f) = U(f|y) = U(f) + U(y|f) \tag{4.23}$$

Demzufolge lassen sich die Maximum a posteriori Wahrscheinlichkeit (MAP) bei gegebener Beobachtung y und die lokale Charakteristik eines Markoff-Zufallsfeldes F über ein Nachbarschaftssystem N durch Minimierung der Energiefunktion bestimmen mit:

$$f^* = argmin_{f \in \mathbb{F}} \, U(f|y) \tag{4.24}$$

Werden die in diesem Abschnitt besprochenen Eigenschaften des Markoff-Zufallsfeldes zusammengefasst, so lässt sich die Klassifikation mittels Markoff-Zufallsfeldern charakterisieren durch:

- Definition des Nachbarschaftssystems N und die Cliquenmenge C .
- Modellierung der Potentialfunktion $V_c(f)$ um $U(f)$ zu bestimmen
- Modellierung der Likelihood-Energie um $U(y|f)$ zu bestimmen
- Minimierung der a posteriori Energie bzw. MAP um das optimale Klassifikationsergebnis zu erzielen

Die Modellierung des Markoff-Zufallsfeldes für die Klassifikation der SAR-Szene erfolgt im nächsten Abschnitt.

4.4. Modellierung

Für die Klassifikation mit Markoff-Zufallsfeldern ist die Modellierung der Energiefunktion $E(f)$ entscheidend. Zuvor wird das Modell entsprechend Abschnitt 4.3 präzisiert:

Die Menge der Entitäten $S = \{1,\ldots,m\}$ indexiert die Pixel unseres Beobachtungvektors $y = (y_1,\ldots,y_m)$ bzw. die Grauwerte. Demzufolge wird mit y_i der Grauwert des Pixels i bezeichnet.

Die Labelmenge $L = (1,\ldots,M)$ besteht aus den Objektklassen, die jedem Pixel zugeordnet werden. Eine Konfiguration f entspricht einem Zustand des klassifizierten Bildes, wobei gilt:

$$f = (f_i \in L | i \in S) \tag{4.25}$$

Als Nachbarschaftssystem für einen Pixel i wird die 24-Nachbarschaft (5. Ordnung) ausgewählt mit:

$$N_i = \{j | dis(pixel_i, pixel) \leq 5\} \tag{4.26}$$

Die Cliquenmenge setzt sich aus Zweier-Cliquen zusammen, um vor allem die Rechenzeit gering zu halten, mit:

$$C = C_2 = \{\{i,j\} \,|\, j \in N_i, \forall_i \in S\} \tag{4.27}$$

Modellierung der Energiefunktion

Die Likelihood-Energie $U(y|f)$ mit der Fisher-Verteilung modelliert, wobei die Parameter der einzelnen Objektklassen in einer Trainingsphase definiert wurden. In den Abschnitt 3.4 und Kapitel 5 wird dieses Verfahren weitgehend erläutert. Für die Likelihood-Energie ergibt sich dann

$$\begin{aligned} U(y|f) &= \sum_{i \in S} -ln\ p_{Fisher}(y_i|f_i) \\ &= \sum_{i \in S} -ln \left(\frac{\Gamma(L_{f_i} + M_{f_i})}{\Gamma(L_{f_i}) \cdot \Gamma(M_{f_i})} \sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{2}{\mu_{f_i}} \frac{\left(\sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{y_i}{\mu_{f_i}}\right)^{2L_{f_i}-1}}{\left(1 + \left(\sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{y_i}{\mu_{f_i}}\right)^2\right)^{L_{f_i}+M_{f_i}}} \right) \end{aligned} \tag{4.28}$$

wobei μ_λ, L_λ und M_λ die Parameter der Fisher-Verteilung für die Objektklasse λ aus der Labelmenge L sind mit $\lambda \in L$.

Die a priori-Energie $U(f)$ wird durch die Modellierung des Potentialfunktion $V_c(f)$ bestimmt. Mit diesem Term wird Vorwissen in Form von Cliquenpotentialen innerhalb der Klassifikation eingebracht. Hierzu wurde dass Potts-Modell [39] angewendet:

$$V_2(f_i, f_j) = \begin{cases} \beta, & \text{falls } f_i \neq f_j \\ -\beta, & \text{falls} f_i = f_j \end{cases} \tag{4.29}$$

Das Potts-Modell dient zur Interaktion zwischen den klassifizierten Pixeln innerhalb der Cliquen des Nachbarschaftssystems. Dieses Modell wird angewendet, weil man davon ausgeht, dass der Speckle-Effekt (siehe Abschnitt 2.4) sich analog zu den Nachbarschaften auf lokal begrenzte Gruppen von Pixeln bezieht. Dem Potts-Modell liegt zugrunde, dass die Wahrscheinlichkeit für zwei benachbarte Pixel derselben Objektklasse anzugehören größer ist, als die Wahrscheinlichkeit unterschiedlicher Klassen anzugehören. Das Modell bewertet die Anzahl der ungleich ge-labelten Nachbarn bewertet. Das Potts-Modell wirkt somit als Regularisierungsterm zwischen der Glättung auf der einen Seite und der Reduzierung der Auswirkung des Speckle-Effekts auf der anderen Seite.

Folglich werden die Cliquen innerhalb eines Nachbarschaftssystems mit einem konstanten Wert β (siehe Gl. 4.29) bewertet. Haben die Pixel innerhalb einer Clique unterschiedliche Label, dann gibt es eine Bestrafung, in dem die Energie erhöht wird.

Die Existenz großer homogener Flächen (bzgl. der Klassen) wird dagegen belohnt, in dem die Energie verkleinert wird. Ein Beispiel dazu wird in Abbildung 4.6 gezeigt. Der Übersicht halber, werden hier nur drei Objektklassen bzw. Label (1=rot, 2=gelb und 3=grün) betrachtet. Die linke Abbildung stellt die Ausgangslage des ge-labelten Feldes im Nachbarschaftssystem durch das Datenmodell dar. Für das mittlere Pixel wird nach dem Potts-Modell die minimale Energie durch die rechte Konfiguration erreicht. Hierbei ergibt sich die minimale Energie für die Summe aller Zweier-Cliquen, wenn das betrachtete Pixel den Labelwert eins erhält.

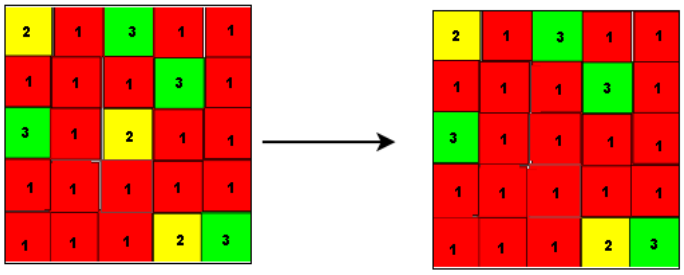

Abb. 4.6.: Labelkonfiguration durch Potts-Modell bzgl. 24er-Nachbarschaft und Zweier-Cliquen

Für die a apriori-Energie $U(f)$ ergibt sich dann durch das Potts-Modell:

$$U(f) = \sum_{i \in S} \sum_{j \in N_i} V_2(f_i, f_j) \tag{4.30}$$

Die Modellierung der Energiefunktion E(F) setzt sich dann nach der Gl. 4.23 aus der Summe der Gleichung 4.28 und 4.30 zusammen mit:

$$\begin{aligned} E(f) &= U(y|f) \\ &= \sum_{i \in S} -ln \left(\frac{\Gamma(L_{f_i} + M_{f_i})}{\Gamma(L_{f_i}) \cdot \Gamma(M_{f_i})} \sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{2}{\mu_{f_i}} \frac{\left(\sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{y_i}{\mu_{f_i}} \right)^{2L_{f_i}-1}}{\left(1 + \left(\sqrt{\frac{L_{f_i}}{M_{f_i}}} \frac{y_i}{\mu_{f_i}} \right)^2 \right)^{L_{f_i}+M_{f_i}}} \right) \\ &+ \alpha \cdot \sum_{i \in S} \sum_{j \in N_j} V_2(f_i, f_j) \end{aligned} \tag{4.31}$$

Der Faktor α ist ein Gewichtungsfaktor mit dem zwischen Glattheit (a priori-Energie) und Datentreue (Likelihood-Energie) gesteuert werden kann. Das optimale Verhältnis lässt sich experimentell ermitteln. In der Arbeit wurden die besten Ergebnisse mit einem Wert von 2,5 erzielt.

Das Resultat der Markoff-Klassifikation ist ein Feld von Labeln aus L, welches $P(f)$ maximiert oder die Energie $E(f)$ minimiert. Dies kann im allgemeinen Fall nur approximativ (siehe Gl. 4.24) mit stochastischen Algorithmen vorgenommen werden. Zur Energieminimierung wurde ein Metropolis Algorithmus in Verbindung mit Simulated Annealing [40] (deutsch: simulierte kontrollierte Abkühlung) angewendet, welcher im nächsten Abschnitt erläutert wird.

4.5. Optimierung

Allgemein lässt sich die maximale a posteriori Wahrscheinlichkeit bei einer geringen Anzahl von Konfigurationen f durch Ausrechnen und Vergleichen der a posteriori Wahrscheinlichkeiten aller $f \in \mathbb{F}$ bestimmen. Für sehr große Konfigurationsmengen, wie bei Markoff-Zufallsfeldern üblich, ist das Einsetzen aller Konfigurationen (Brute-Force) unmöglich. Aus diesem Grund kommen für die Bestimmung der optimalen Schätzung von f^* (aus Gl. 4.24) Suchverfahren zum Einsatz.

Bei den Sucherverfahren unterscheidet man zwischen stochastischen und deterministischen Verfahren. Bei stochastischen Verfahren werden beim Iterationsprozess zufällig neue Konfigurationen erzeugt, während bei dem deterministischen Verfahren jede neue Konfiguration durch die alten eindeutig festgelegt ist. In dieser Arbeit wurde ein stochastisches Verfahren durch ein Simulated Annealing basierend Metropolis Algorithmus angewendet.

Der Metropolis-Algorithmus ist ein Optimierungsalgorithmus zur Abschätzung der minimalen Energiefunktion. Dies erfolgt in zwei Schritten.

1. Auswahl von zufällig ausgewählten Konfigurationen f aus dem Konfigurationraums $\mathbb{F}$
2. Berechnung einer Konfiguration f für die $P(f)$ maximal bzw. E(F) minimiert wird

Durch den Metropolis-Algorithmus wird eine Reihe von zufälligen Konfigurationen generiert, um die optimale Konfiguration abzuschätzen. Dabei wird die folgende Methode angewendet:

1. Initialisiere eine zufällige Startkonfiguration f und wähle die Temperatur T[3] als konstant für die gesamte Laufzeit. Berechne anschließend $E(f)$.
2. Erzeuge durch einen Zufallsprozess bzw. einer feste Verteilung (z. B. Gleichverteilung) eine Konfiguration f' und bestimme $E(f')$. Hierbei soll sich f' um wenig Labelwerte von f unterscheiden bzw. Nachbar der Konfiguration f im Konfigurationsraum $\mathbb{F}$ sein.
3. Die Wahrscheinlichkeit, dass die Konfiguration f' angenommen wird, hängt ab von der Größe:

$$P_t(T) = \frac{P(f)}{P(f')} = e^{-\left(\frac{E(f)-E(f')}{T}\right)}$$

   - a) Falls $E(f') < E(f)$: $P_t > 1$ und die neue Konfiguration f' wird akzeptiert $\Rightarrow\ f = f'$
   - b) Falls $E(f') > E(f)$: Es wird die Konfiguration f' mit einer Wahrscheinlichkeit von P_t angenommen. Dadurch können lokale Minima wieder verlassen werden.
4. Wiederhole Schritt 2 bis eine Abbruchkriterium erfüllt ist und gebe f zurück.

Die obige Methode akzeptiert jede neue Konfiguration, welche energetisch günstiger ist, als die alte. Damit diese aber auch lokale Minima verlassen kann, wird mit einer gewissen Wahrscheinlichkeit auch ein energetisch schlechterer Zustand angenommen (vgl. Schritt 3b). Der Metropolis-Algorithmus garantiert aber keine globale Konvergenz bzw. ein globales Minimum. Dies kann aber durch die Kombination mit einem Simulated Annealing erreicht werden, in dem die Variable Temperatur T nicht mehr konstant genutzt wird. Man orientiert sich hierbei an Prozessen der Kristallbildung. Die Kristalle, die produziert wurden, haben nur dann eine optimale Struktur (minimale Energie), wenn das Rohmaterial erst erhitzt und dann langsam abgekühlt wird. Auf diese Verfahren baut das Simulated Annealing auf. Es gibt verschiedene Methoden für das Simulated Annealing, aber alle haben eines gemeinsam: Die Temperatur wird nicht festgesetzt, sondern variiert. Dadurch können vorübergehend schlechtere, also energiereichere Zustände akzeptiert werden, deren Temperatur im Laufe des Iterationsverfahrens sinkt.

Das Simulated Annealing baut auf dem Metropolis-Algorithmus auf. Dabei wird der Metropolis Algorithmus bei einer Anfangstemperatur T (hoher Wert) mit einer bestimmten Anzahl von erfolgreichen Schritten ausgeführt. Danach wird die Temperatur reduziert und das obige Verfahren fortgesetzt. Im Wesentlichen müssen folgende Schritte durchgeführt werden:

[3] In der Gibbsverteilung aus der Gl. 4.19 wird die Variable T eingebracht

1. Initialisiere T und f
2. Wiederhole bis $T = 0$
    - i) Führe Metropolis-Algorithmus bis zu einem erfolgreichen Schritt aus
    - ii) Verringere T
3. Gebe f zurück

Durch den Wert der Variablen T wird die stochastische Suche gesteuert. Für hohe Werte von T werden hohe Schwankungen in den Energiewerten der Konfigurationen akzeptiert. Diese Schwankungen verringern sich mit der Senkung der Temperatur bis für $T = 0$ keine Erhöhung der Energie, also keine Verschlechterung mehr möglich ist. Das Abkühlungsschema bzw. die Schrittweite der Temperatur ist einer der wichtigsten Strategieparameter: Schneller Abkühlungsprozess birgt das Risiko in einem lokalen Minimum einzuschwingen, während langsames Abkühlen mit hoher Wahrscheinlichkeit auf ein globales Minimum, allerdings in Verbindung mit hohem Rechenaufwand, führt.

5. Ergebnisse

Im Folgenden werden die erzielten Klassifikationsergebnisse zweier TerraSAR-X Bilder vorgestellt. Hierfür wurden zahlreiche Klassifikationsläufe mit verschiedenen Parametern innerhalb der Markoff-Klassifikation durchgeführt. Es werden jeweils die besten Ergebnisse dargestellt. Die Güte der Klassifikationsergebnisse wird nummerisch bewertet und dient als Grundlage für eine Aussage über die Eignung von SAR-Bildern im Hinblick auf verschiedene ATKIS-Objekte.

Ausgehend von den Eigenschaften der zu untersuchenden TerraSAR-X Bilder in Abschnitt 5.1 wird die Klassifikationsstrategie in Abschnitt 5.2 behandelt. In den Abschnitten 5.3 und 5.4 werden die erzielten Ergebnisse dargestellt und evaluiert. Auf Grundlage dieser Ergebnisse wird in Abschnitt 5.5 die Eignung von SAR-Bildern zur Fortführung und Verifikation von ATKIS bewertet.

5.1. Datengrundlage

Für die Arbeit wurden zwei Bilder vom deutschen Radarsatelliten TerraSAR-X verwendet. Beim ersten Bild handelt es sich um eine Aufnahme der Stadt Fuhrberg in der Region Hannover und beim zweiten Bild um die Hauptstadt Algier Algeriens.

Beide SAR-Daten standen zunächst im „Single Look Slant Range Complex“ (SSC) Format zur Verfügung. Dieses Datenformat beinhaltet neben der Amplitudeninformation die Phase des SAR-Signals als komplexen 32 Bit Datensatz. Um eine bildliche Darstellung zu erhalten, wurde die Amplitude berechnet (siehe Abschnitt 3.2.1). Für die spätere Klassifikation wurde keine Projektion in Ground Range Geometrie durchgeführt (siehe Abschnitt 2.2), sondern direkt die Originaldaten in Slant Range Geometrie verwendet. Dadurch werden die,auftretenden Artefakte durch die Projektion und Interpolation auf die Ground Range Geometrie, vermieden.

Der TerraSAR-X Satellit kann in verschiedenen Polarisationen und Abbildungsmodi bzw. Auflösungsstufen betrieben werden. Die Fuhrberg-Aufnahme wurde im Spotlight Modus (SL) und mit horizontaler Polarisation (HH) im X-Band aufgenommen. Die Auflösung liegt bei ca. 2 Metern in Azimut und 1 Meter in Range .

Die Algerien-Szene wurde im High Resolution Spotlight (HS) Abbildungsmodus und ebenfalls mit horizontaler Polarisation (HH) im X-Band aufgenommen. Sie besitzt jedoch mit ca. 1.1 Metern Auflösung in Azimut und 0.6 Meter in Range eine wesentlich bessere Auflösung als die Fuhrberg Szene. Die wesentlichen Eigenschaften der beiden Datensätze sind in der Tabelle 5.1 zusammengefasst.

Fuhrberg	
Modus	Single Polarization Spotlight (SL)
Auflösung in Slante Range	1m
Auflösung in Azimut	2m
Range pixel spacing	0.9m
Azimut pixel spacing	1.3m
Radiometrische Auflösung	32 Bit
Polarisation	HH
Algier	
Modus	High Resolution Single Polarization Spotlight (HS)
Auflösung in Slante Range	0.6m
Auflösung in Azimut	1.1m
Range pixel spacing	0.5m
Azimut pixel spacing	0.8m
Radiometrische Auflösung	32 Bit
Polarisation	HH

Tabelle 5.1.: Verwendete Datensätze

5.2. Klassifikationsstrategie

Die Klassifikationsstrategie in dieser Arbeit erfolgt in vier Schritten und ist in Abbildung 5.1 dargestellt. Sie setzt sich aus einer optionalen Speckle-Filterung, einer Trainingsphase, der Klassifikation mittels Markoff-Zufallsfeldern und einem Postprocessing zusammen. Diese Schritte werden im Folgenden kurz erläutert:

1. Es wurde bei einem der zu untersuchenden Datensätze eine Speckle-Filterung auf die gesamte Szene angewendet. Hierzu wurde ein effektives Verfahren zur Reduzierung des multiplikativen Rauschens bei gleichzeitiger Erhaltung von Bilddetails durch den Lee-Filter [41] verwendet. Der Lee-Filter ist ein adaptiver Filter, welcher ein statistisches Modell des multiplikativen Rauschens, ähnlich dem Produktmodell aus Abschnitt 3.2.3, zugrunde liegt. Ein gefiltertes Pixel errechnet sich aus seiner lokalen Umgebung. Hierbei wird mit Hilfe einer linearen Regression die Minimierung des quadratischen Fehlers innerhalb des multiplikativen Rauschmodells erzielt.

2. In einer überwachten Phase wurde für die Aufgabe relevante Objektklassen durch die Fisher-Verteilung (siehe 3.3) charakterisiert. Hierzu wurden manuell Trainingsregionen aus der gesamten Szene für die interessierenden Klassen ausgewählt. Hierbei ist eine Anzahl von genügend großen Trainingsregionen erforderlich, die die einzelnen Klassen in ihren Grauwerten und ihrer Textur hinreichend repräsentieren. Bei der Auswahl der Trainingsregionen ist besonders zu beachten, dass diese geschlossen in sich homogen sind. Für jede Klasse wurden mehrere Regionen aus der gesamten Szene ausgewählt und die Pixelwerte zu einem Datensatz zusammengefasst. Im Allgemeinen nimmt mit der Größe der Lernstichprobe die Anpassung der Klassen durch die Verteilung zu. Für jeden zusammengefassten Datensatz bezüglich der einzelnen Klassen wurden die Parameter der Fisher-Verteilung nach dem Verfahren aus Abschnitt 3.4.3 abgeschätzt.

3. In diesem Schritt erfolgt die Klassifikation mittels des Markoff-Modells aus Abschnitt 4.4. Hierbei wurden die antrainierten Parameter der Fisher-Verteilung für jede Klasse verwendet.

4. Durch eine Postprocessing werden zusammengehörende Subklassen zu einer Klasse zusammengefasst.

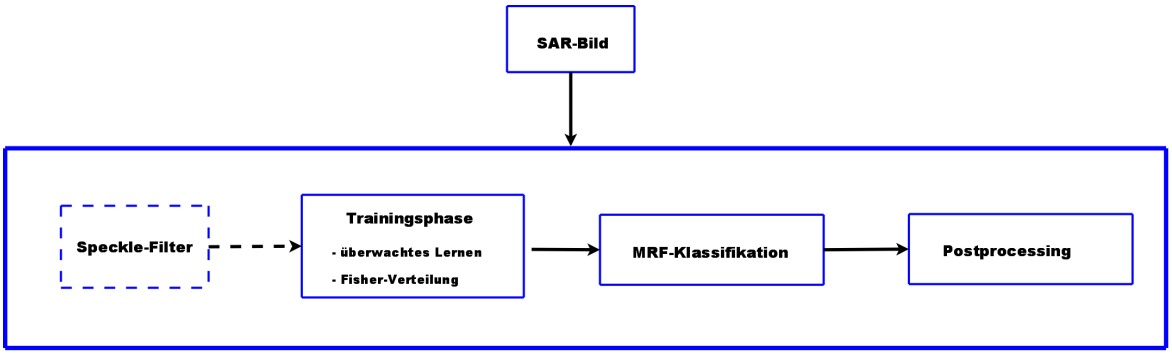

Abb. 5.1.: Klassifikationsstrategie

Auswertungsmethode der Klassifikationsgenauigkeit

Um das Klassifikationsergebnis beurteilen zu können, wurde eine Konfusionsmatrix [42] verwendet. Hierzu wurde zunächst ein Referenzbild erstellt, in der die untersuchten Klassenregionen im Bild markiert wurden. Hierbei wurden kleine Flächen, wie beispielsweise Straßen in Siedlungsbereichen, nicht berücksichtigt.

Innerhalb der Konfusionsmatrix beschreibt jede Zeile der Matrix eine Klasse aus dem Referenzbild und jede Spalte die klassifizierten Klassen. Der jeweilige Eintrag innerhalb der Matrix gibt an, wie viele Pixel der reellen Klasse (Zeile) mit den klassifizierten Klassen (Spalte) übereinstimmen. Wird die Anzahl der Einträge auf die jeweilige Anzahl der Pixel in der reellen Klasse bezogen, so ergibt sich eine prozentuale Darstellung. Im Idealfall stehen in den Diagonalen jeweils 100 Prozent, an allen anderen Positionen jeweils 0. Mit dieser Darstellung wird erlaubt eine Differenzierung der Genauigkeit in einzelnen Klassen vorzunehmen. Es ergibt sich ein Hinweis darauf, in welcher Klasse die falsch klassifizierten Pixel abgebildet wurden.

Ein sehr oft angewandtes Schema für die Beurteilung der Übereinstimmung von Klassifizierungsergebnissen und Referenzdaten wird in [43] benutzt. Die drei besten Kategorien werden dabei folgendermaßen definiert:

- almost perfect 81% - 100% (beinahe perfekt)
- substantial 61% - 80% (angemessen)
- moderate 41% - 60% (mittelmäßig)

5.3. Klassifikationsergebnisse der TerraSAR-X Bilder von Fuhrberg

Die Klassifikation wurde für das Original TerraSAR-X Amplitudenbild sowie für eine Speckle reduzierte Version durchgeführt. Für die Speckle Reduktion wurde der Lee-Filter verwendet.

5.3.1. Trainingsphase (Anlernen des Klassifikators)

Die Fuhrberg-Szene (Abbildung 5.2) ist landwirtschaftlich geprägt und besonders durch große Waldflächen, verschiedene Ackerflächen, Siedlungs- sowie kleine Industriegebiete charakterisiert. Für die Klassifikation wurden daher diese Klassen untersucht.

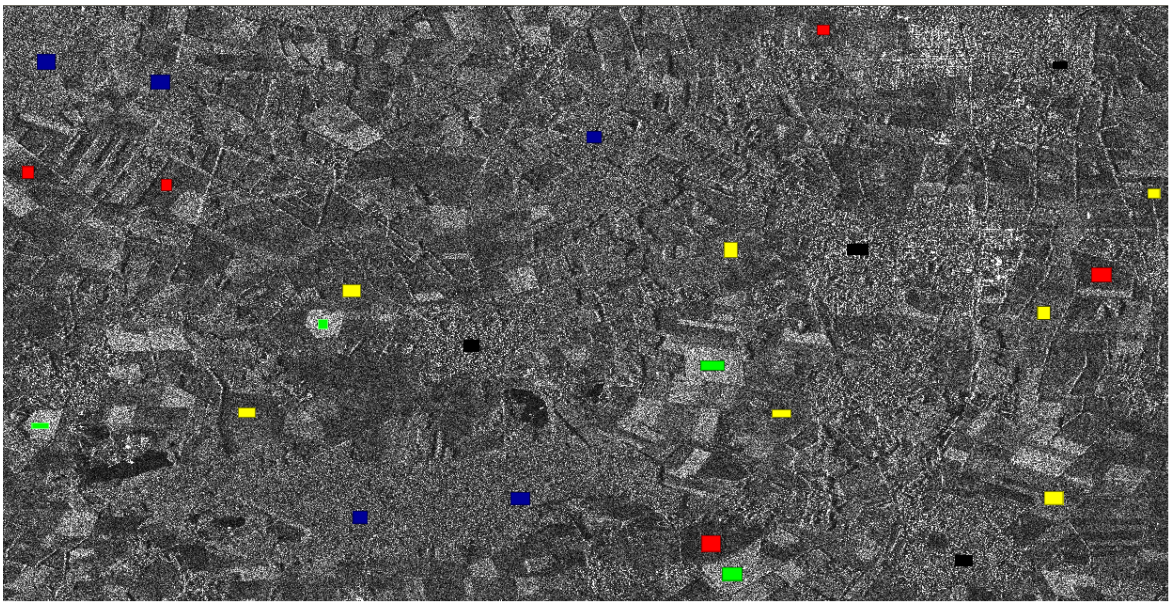

Abb. 5.2.: Original TerraSAR-X Szene von Fuhrberg mit markierten Trainingsregionen Acker *dunkel* (rot), Acker *mittel* (gelb), Acker *hell* (grün), Wald (blau) und Siedlung/Industrie (schwarz)

Dichte Waldflächen sind im Allgemeinen durch eine konstante Volumenstreuung (siehe Abschnitt 2.3.2) charakterisiert. Die Höhe des Bewuchses spielt hier keine Rolle, da die Streuung aufgrund der hohen Bepflanzungsdichte bereits im Bereich der Baumkronen erfolgt. In den Grauwerten ergibt sich daher keine große Schwankung. Anderseits werden weniger dichte Wälder von Radarwellen unterschiedlich stark durchdrungen. Dies kann durch eine hohe Vielzahl von Streutypen beschrieben werden.

Die Grauwerte in Ackerflächen sind dagegen in Abhängigkeit von der Rauigkeit der Oberfläche charakterisiert. Je nach Beschaffenheit der Oberfläche ergeben sich dunkle (leicht diffuse Streuung des Radarsignals) bis helle Grauwerte (stark diffuse Streuung des Radarsignals). Ein Beispiel dafür ist in Abbildung 5.3 a-c) zusehen. Die von Menschen erschaffenen künstlichen Objekte wie Siedlungsbereiche und Industriegebiete sind durch hohe Rückstrahlwerte bzw. sehr helle Grauwerte gekennzeichnet. Siedlungsbereiche sind besonders durch ein vielfältiges Erscheinungsbild geprägt, erkennbar an einzelnen voneinander entfernten

Punktstreuern (siehe Abbildung 5.3 e). Industriegebiete sind durch hohe Dielektrizitätswerte aufgrund metallischer Baustoffe gekennzeichnet und somit meist mit hohen Grauwerten dargestellt. Weiterhin sind die geometrischen Effekte, wie z.B. Radarschatten, die durch das Aufnahmeverfahren und die Geländeform verursacht werden, an dieser Stelle zu erwähnen (siehe Abschnitt 2.3.1). Diese wurden im Klassifikationsansatz allerdings nicht explizit, z.B. als Objektmerkmal, berücksichtigt.

Für die Klassifikation wurden die drei Klassen:

- Wald,
- Ackerland/Grünland, und
- Siedlung/Industrie

ausgewählt. Eine Differenzierung zwischen Siedlung und Industrie konnte nicht vorgenommen werden, weshalb sie zu einer Klasse zusammengefasst wurde.

In der Trainingsphase wurden mit einer Vielzahl von Lernstichproben aus der gesamten Fuhrberg-Szene die Klassen durch die Fisher-Verteilung antrainiert. Hierzu wurde die Klasse Acker/Grünland aufgrund unterschiedlicher Ausprägungen der Grauwerte in drei Klassen (Acker *hell*, Acker *mittel* und Acker *dunkel*) unterteilt. In einem Postprocessing-Schritt wurde diese nach der Klassifikation zu einer einzigen Klasse (Ackerland/Grünland) zusammen gefasst. In Abbildung 5.3 sind beispielhaft ausgewählte Musterklassen für die Trainingsphase dargestellt.

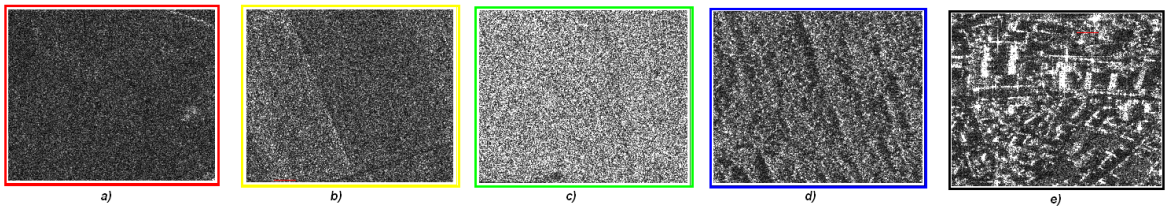

Abb. 5.3.: Lernstichprobe (Musterklasse) für die Klassen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald und e) Siedlung/Industrie

Die während der Trainingsphase verwendeten Lernstichproben aus der gesamten Fuhrberg-Szene sind in Abbildung 5.2 dargestellt. Hierbei entsprechen die rot markierten Bereiche den Lernstichproben für Acker *hell*, die gelb markierten denen für Acker *mittel*, die grün markierten für Acker *dunkel*, die blau markierten für Wald und die schwarz markierten für Siedlung/Industrie.

Die abgeschätzten Parameter der Fisher-Verteilung und die Anzahl der Stichproben, die in der Trainingsphase für jede Klasse verwendet wurden, sind dem Anhang zu entnehmen.

Die Fisher-Verteilungen der einzelnen antrainierten Klassen sind in Abbildung 5.4 a-e) sowie eine Gegenüberstellung der Verteilungen in Abbildung 5.4 f) dargestellt. Bereits an dieser Stelle ist hervorzuheben, dass keine eindeutige Trennung der Klasse Wald (blau) mit den

Klassen Acker dunkel (rot) und Acker *mittel* auf Basis eines einzigen Features (Grauwerte) gegeben ist. Die Ursache für die unzureichende Differenzierung dieser Klassen ist die starke Variation der jeweiligen Grauwerte.

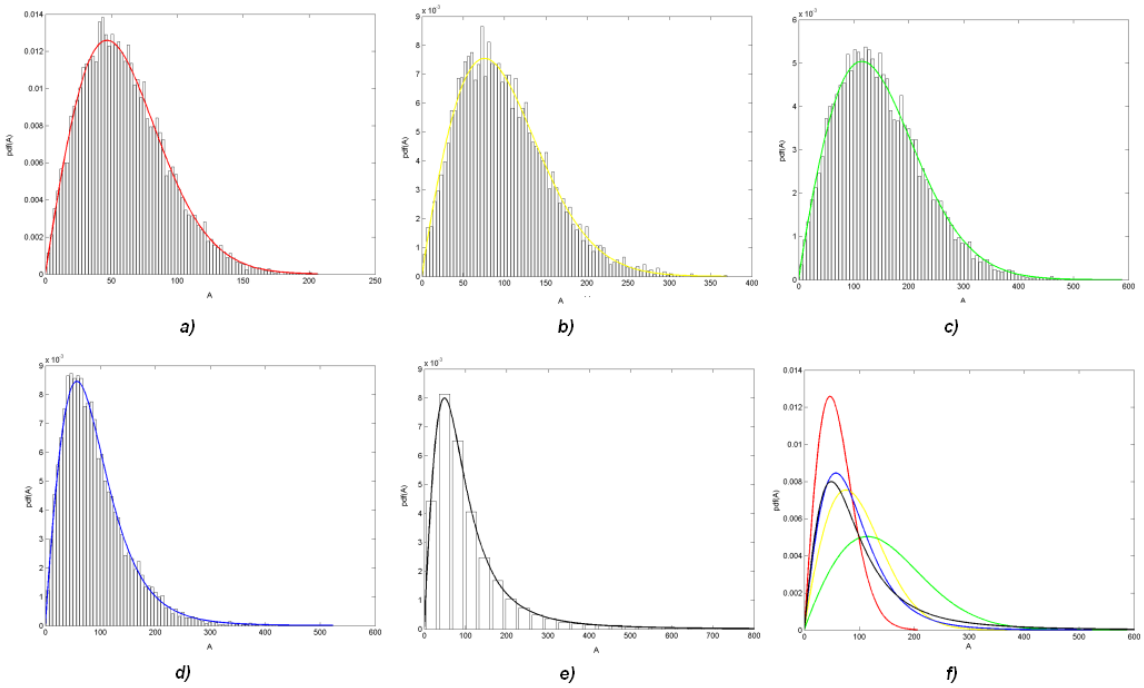

Abb. 5.4.: Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen

Es wurde weiterhin eine Untersuchung mit gefilterten Daten vorgenommen. Hierzu wurde zunächst der Lee-Filter auf die Fuhrberg-Szene aus Abbildung 5.2 angewendet und anschließend die identischen Trainingsgebiete ausgewählt. Die abgeschätzten Parameter der Fisher-Verteilungen sind dem Anhang zu entnehmen.

Die abgeschätzten Fisher-Verteilungen für die einzelnen Traningsregionen sind in Abbildung 5.5 a-e) dargestellt. Eine Gegenüberstellung der abgeschätzten Verteilungen ist in Abbildung 5.5 f) dargestellt. Hierbei ist besonders gut zu beobachten, dass die verschiedenen Acker-Klassen und teilweise auch die Klasse Wald homogener ausgeprägt sind, dies liegt an einem relativ schmalen und hohen Verlauf der Grauwerthäufigkeit. Die Trennbarkeit zwischen den Klassen Wald und Acker wurden gegenüber das Originalversion teilweise verbessert.

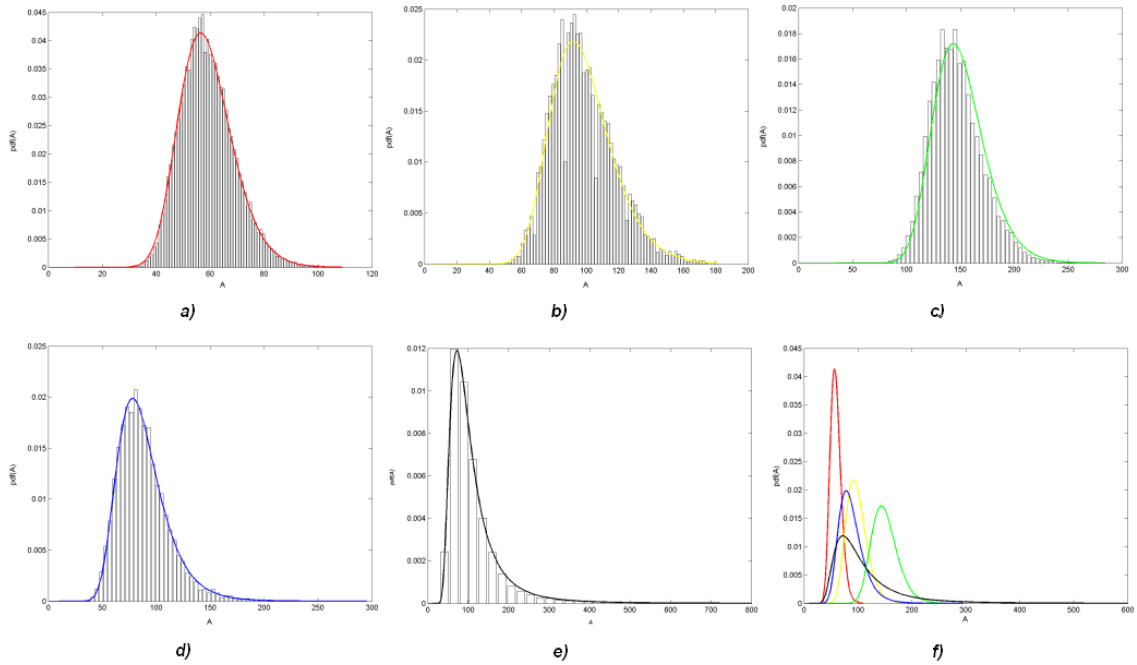

Abb. 5.5.: Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen

5.3.2. Ergebnis Region Fuhrberg

In diesem Abschnitt wird das Ergebnis der Klassifikation vorgestellt. Hierzu wurde eine 3519×2243 Pixel große Region aus der Fuhrberg-Szene ausgewählt. Das Ergebnis der Klassifikation ist in Abbildung 5.6 zu sehen. Die Konfusionsmatrix mit den prozentualen Werten für die Detektionsraten der Klassen ist in Tabelle 5.2 dargestellt. Die Werte der Diagonalen repräsentieren den Anteil der korrekt klassifizierten Pixel. Die geringste Übereinstimmung liegt bei der Klasse Wald bei lediglich 31 Prozent. Die besten Ergebnisse wurden bei der Klasse Ackerland/Grünland mit 58 Prozent erreicht.

Für die Klasse Siedlung/Industrie wurden 49 Prozent richtig klassifizierte Pixel erzielt. Weitere Bereiche der in der Referenz als Siedlung ausgewiesenen Flächen bilden sich in den SAR-Daten nicht ab, was auf ungünstige Orientierung der Gebäude oder auf Pflanzenbewuchs vor den Gebäuden zurückzuführen ist. Je nach Art des auftretenden Bewuchses werden die Bereiche als Wald oder Ackerland klassifiziert.

Alle Klassen sind nach dieser Untersuchung unzuverlässig abgebildet. Bei der Verwendung der Original-Daten entsteht praktisch keine zusammenhängende Fläche mehr, da eine mehr oder minder willkürliche Klassenzuordnung aufgrund der erheblichen Signalvariation durch Speckle erfolgt. Eine Trennung der Klassen Wald und Ackerland/Grünland ist nach dieser Auswertung mit einem einzelnen Merkmal (dem Grauwert) nicht möglich. Eine starke Verbesserung der Ergebnisse könnte mit zusätzlichen Merkmalen erzielt werden.

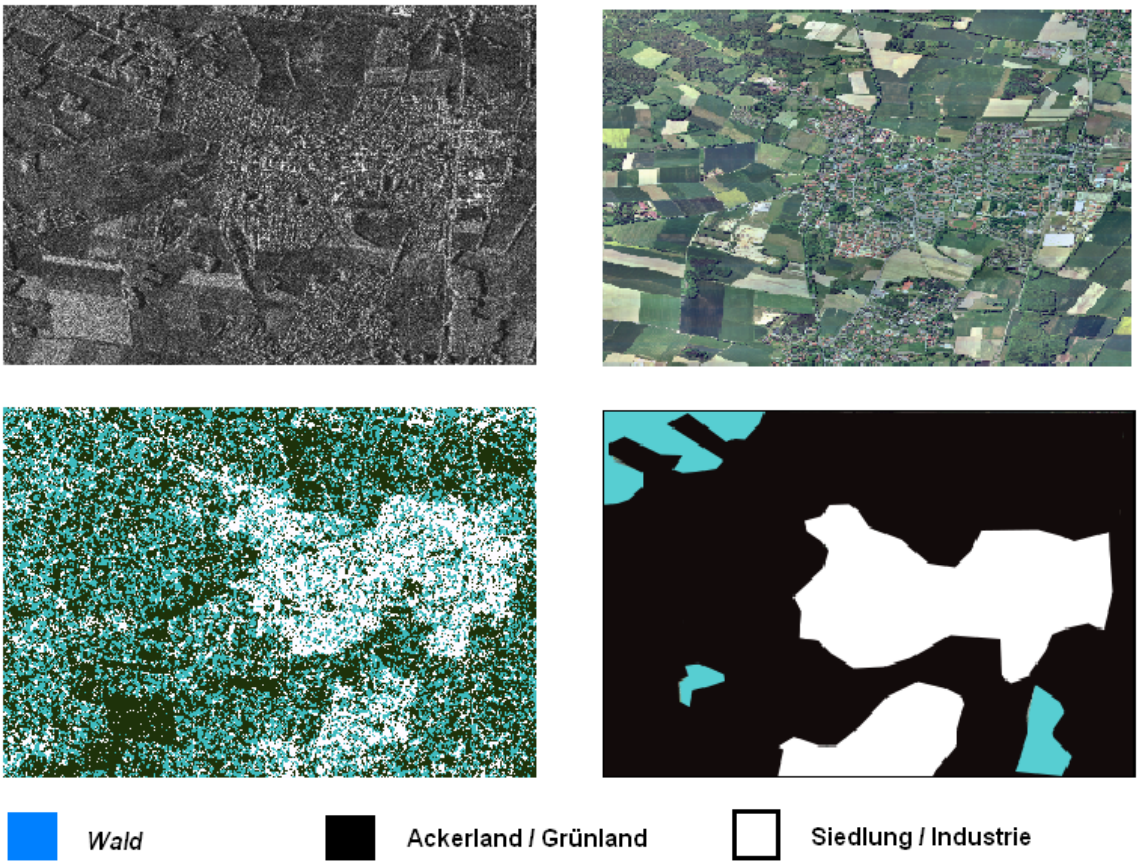

Abb. 5.6.: Klassifikationsergebnis: oben links TerraSAR-X Bild Fuhrberg, oben recht optisches Bild, unten links klassifiziertes Bild und unten rechts Referenzbild

		Klassifikation		
		Siedlung/Industrie	Ackerland/Grünland	Wald
Referenz	Siedlung/Industrie	49 %	25 %	26 %
	Ackerland/Grünland	12 %	58 %	30 %
	Wald	18 %	51 %	31 %

Tabelle 5.2.: Konfusionsmarix für die Klassifikation der Fuhrberg-Szene

5.3.3. Ergebnis Region Fuhrberg mit Speckle-Filter

In diesem Abschnitt sind die Ergebnisse der Klassifikation der Region Fuhrberg aus Abschnitt 5.3.2 mit einer vorherigen Speckle-Filterung mittels Lee-Filter dargestellt. Das Ergebnis der Klassifikation ist in Abbildung 5.7 zu sehen. Die zugehörige Konfusionsmatrix ist in Tabelle 5.3 abgebildet. Die Klasse Siedlung/Industrie zeigt mit etwa 59 Prozent Übereinstimmung das qualitativ beste Ergebnis.

Im Vergleich zu ungefilterten Daten hat sich hierbei die Übereinstimmung um ca. 10 Prozent erhöht. Dagegen hat sich die Übereinstimmung der Klasse Ackerland/Grünland mit 52 Prozent etwas verschlechtert. Die Klasse Wald konnte lediglich zu 30 Prozent richtig

eingestuft wurden. Auch bei dieser Auswertung treten viele Fehlklassifikationen zwischen den Klassen Wald und Ackerland/Grünland auf. Eine zuverlässige Trennung zwischen diesen beiden Klassen ist auch bei einer Speckle reduzierten Region aus dem TerraSAR-X Bild von Fuhrberg nicht anhand eines einzigen Merkmals möglich.

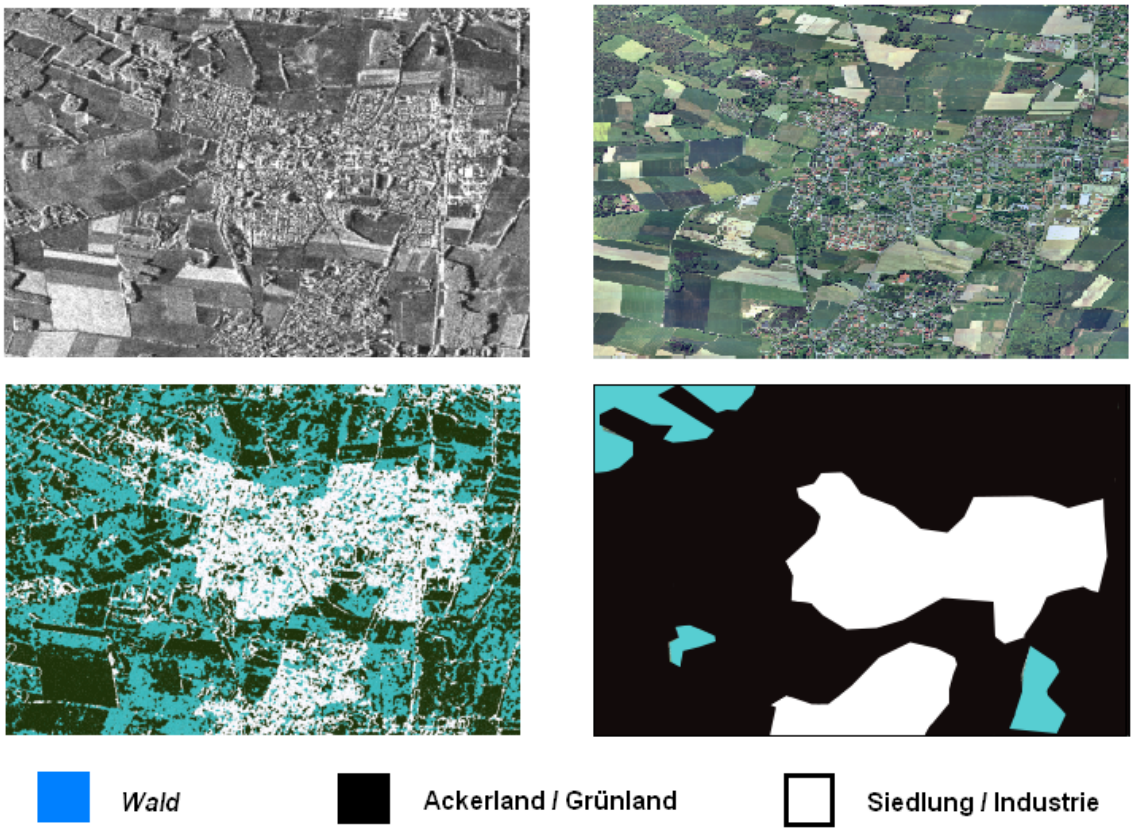

Abb. 5.7.: Klassifikationsergebnis: oben links TerraSAR-X Bild Fuhrberg (Lee-Filter), oben recht optisches Bild, unten links klassifiziertes Bild und unten rechts Referenzbild

		Klassifikation		
		Siedlung/Industrie	Ackerland/Grünland	Wald
Referenz	Siedlung/Industrie	59 %	21 %	20 %
	Ackerland/Grünland	8 %	52 %	40 %
	Wald	14 %	56 %	30 %

Tabelle 5.3.: Konfusionsmarix für die Klassifikation der Fuhrberg-Szene (Lee-Filter)

5.4. Klassifikationsergebnisse des TerraSAR-X Bildes von Algier

In diesem Abschnitt wird das Klassifikationsergebnis des TerraSAR-X Bildes von Algier vorgestellt. Die Untersuchungen wurden direkt an den Originaldaten und ohne eine vorherige Speckle-Filterung durchgeführt.

5.4.1. Trainingsphase (Anlernen des Klassifikators)

Die TerraSAR-X Aufnahme der Stadt Algier ist in der Abbildung 5.8 abgebildet. Ein Großteil der Szene ist durch verschiedene Arten von Ackerflächen charakterisiert. Weiterhin ist die Szene durch die Landebahn des Flughafens Algiers, Straßen sowie Siedlungs- und Industrieflächen geprägt.

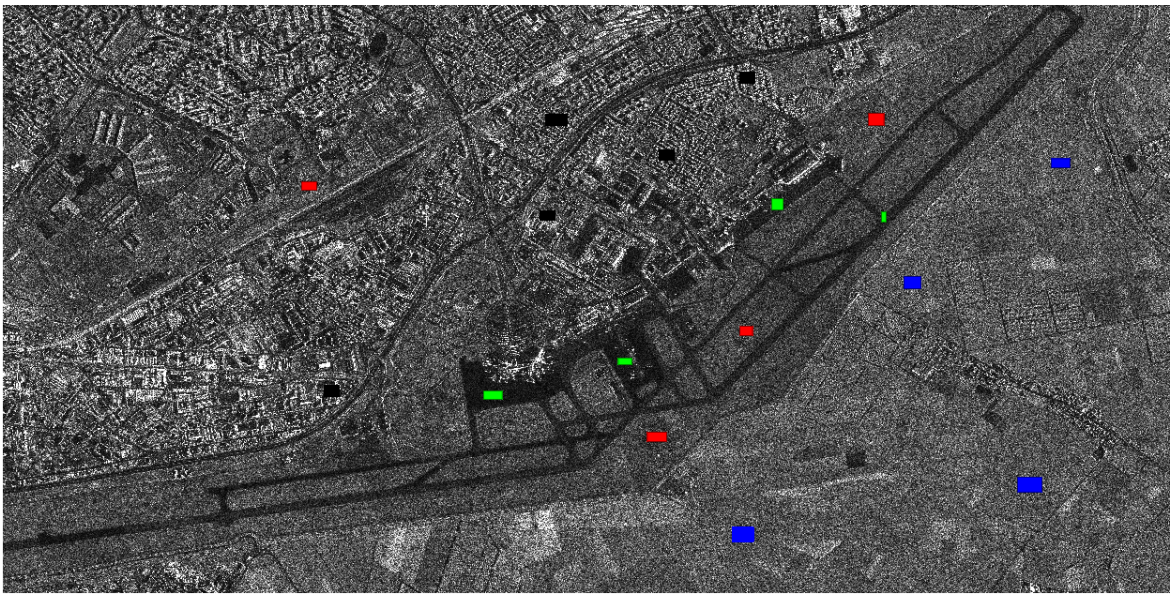

Abb. 5.8.: Trainingsgebiete in der TerraSAR-X Szene Algier, Boden *hell* (blau), Boden *mittel* (rot), Boden *dunkel* (grün), Siedlung/Industrie (schwarz)

Für die Klassifikation wurden die Klassen

1. Ackerland/Grünland,
2. Siedlung/Industrie und
3. Straße/Landebahn

ausgewählt. Als besonders interessant ist hierbei die Klasse Straße/Landebahn anzusehen. Während bei optischen Sensoren Straßen ähnlich wie Gebäude abgebildet werden, sind sie in SAR-Daten nicht immer als solche zu identifizieren. Die glatte Oberfläche bewirkt eine Totalreflexion der Radarwellen, sodass ein sehr schwaches Signal am Sensor gemessen wird. Deshalb sind diese Flächen auf dem Radarbild sehr dunkel charakterisiert.

Während der Trainingsphase wurde wieder eine Reihe von Lernstichproben aus der gesamten Algier Szene aus der Abbildung 5.8 entnommen. Hierbei sind die Stichproben Boden *dunkel* (blau markiert) der Klasse Straße/Landebahn zuzuordnen. Die Klasse Ackerland/Grünland wurde aufgrund unterschiedlicher Ausprägungen während der Trainingsphase unterteilt in die Subklassen Boden *mittel* (rot markiert) und Boden *hell* (grün markiert) antrainiert. Die Trainingsregionen für die Klasse Siedlung/Industrie sind schwarz markiert. In Abbildung 5.9 ist für jede Klasse exemplarisch eine Lernstichprobe dargestellt.

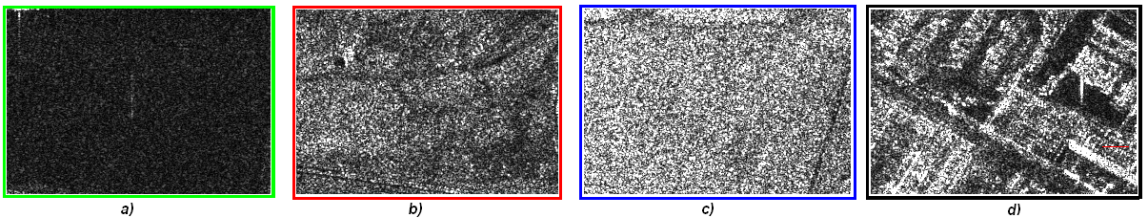

Abb. 5.9.: Lernstichprobe für die Klassen a) Boden *dunkel*, b) Boden *mittel*, c) Boden *hell* und d) Siedlung/Industrie

Die abgeschätzten Parameter der Fisher-Verteilung für die Lernstichproben und die gesamte Anzahl verwendeter Stichproben der jeweiligen zu untersuchenden Klassen in den Trainingsphasen sind dem Anhang zu entnehmen. Die abgeschätzten Fisher-Verteilungen für die Lernstichproben der Klassen sind in Abbildung 5.10 a-d) abgebildet. Die Gegenüberstellung der einzelnen Verteilungen ist in Abbildung 5.10 e) dargestellt. Hierbei ist wie erwartet eine Trennung der Klassen Boden dunkel (grüne Verteilung) mit den Klassen Boden Mitte mittel und Boden hell (rote und blaue Verteilung) zu sehen.

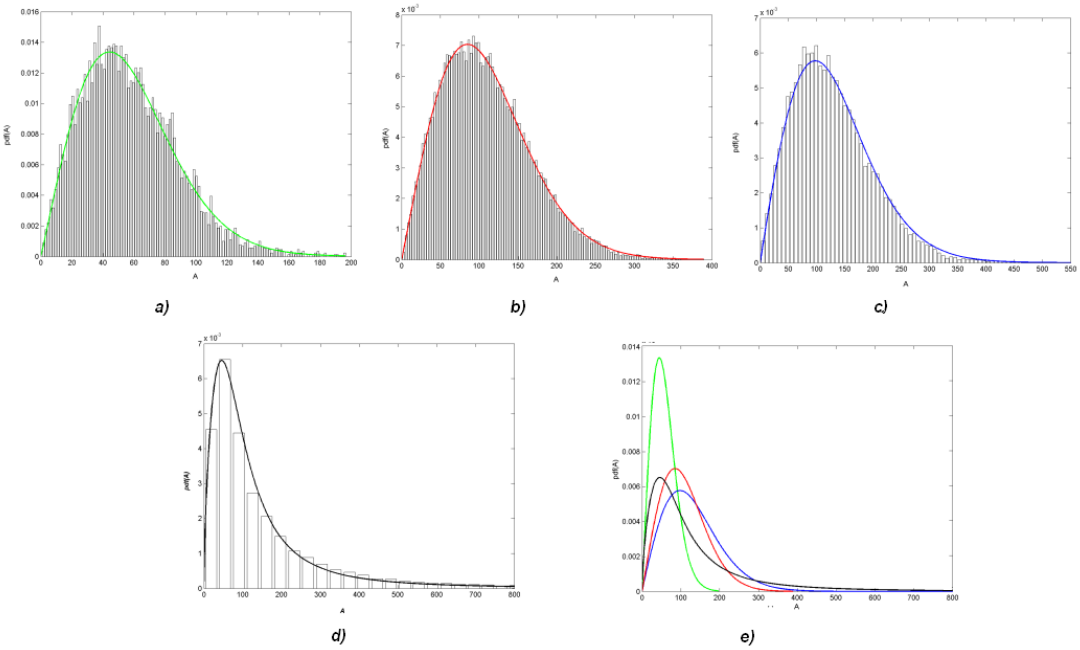

Abb. 5.10.: Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Boden *dunkel*, b) Boden *mittel*, c) Boden *hell*, d) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen

5.4.2. Ergebnis Region Algier

In diesem Abschnitt wird das Ergebnis der Klassifikation vorgestellt. Hierzu wurde aus dem TerraSAR-X Bild Algier (siehe Abbildung 5.8) eine Testregion der Größe 3885×3743 ausgewählt und klassifiziert. In einem Postprocessing Schritt wurden dann die Subklassen Boden *mittel* und Boden *hell* zu einer Klasse Ackerland/Grünland zusammen gefasst.

Das Ergebnis der Klassifikation ist in Abbildung 5.11 abgebildet. Für die Auswertung des Klassifikationsergebnisses wurde wieder eine Konfusionsmatrix bestimmt, welche in Tabelle A.5 abgebildet ist. Die Klasse Ackerland/Grünland weist einen sehr guten Wert von 82 Prozent an richtig klassifizierte Pixel auf. Dies ist vor allem mit der besseren Auflösung und der verbesserten Abgrenzung der Grauwerte zu den restlichen Klassen (vgl. Abbildung 5.10 e) zu begründen. Für die Klasse Siedlung/Industrie ist mit 56 Prozent richtig klassifizierter Pixel etwa die gleiche Ungenauigkeit wie bei der Untersuchung der Fuhrberg-Szene erzielt wurden.

Dies ist in diesem Fall mit der Beschaffenheit des Testbildes zu begründen. Innerhalb von Siedlungsflächen befinden sich u.a. viele Freiflächen wie z.B. Straßen, Dächer und Radarschatten. Diese werden aufgrund der Abbildungsgeometrie dunkel abgebildet und deshalb den Klassen Straße und Ackerland/Grünland zugeordnet. Daher könnte die Klassifizierung zwar richtig sein, aber wird aufgrund der nicht berücksichtigten Details im Stadtbereich im Referenzbild als falsch klassifiziert.

Bei der Klasse Straße/Landebahn ist mit 66 Prozent Genauigkeit ein relativ gutes Ergebnis erzielt worden. Auch hier sind die Fehlklassifikationen aufgrund der Abbildungsgeometrie eines SAR-Systems (z.B. Radarschatten, Dächer, etc.) zu begründen.

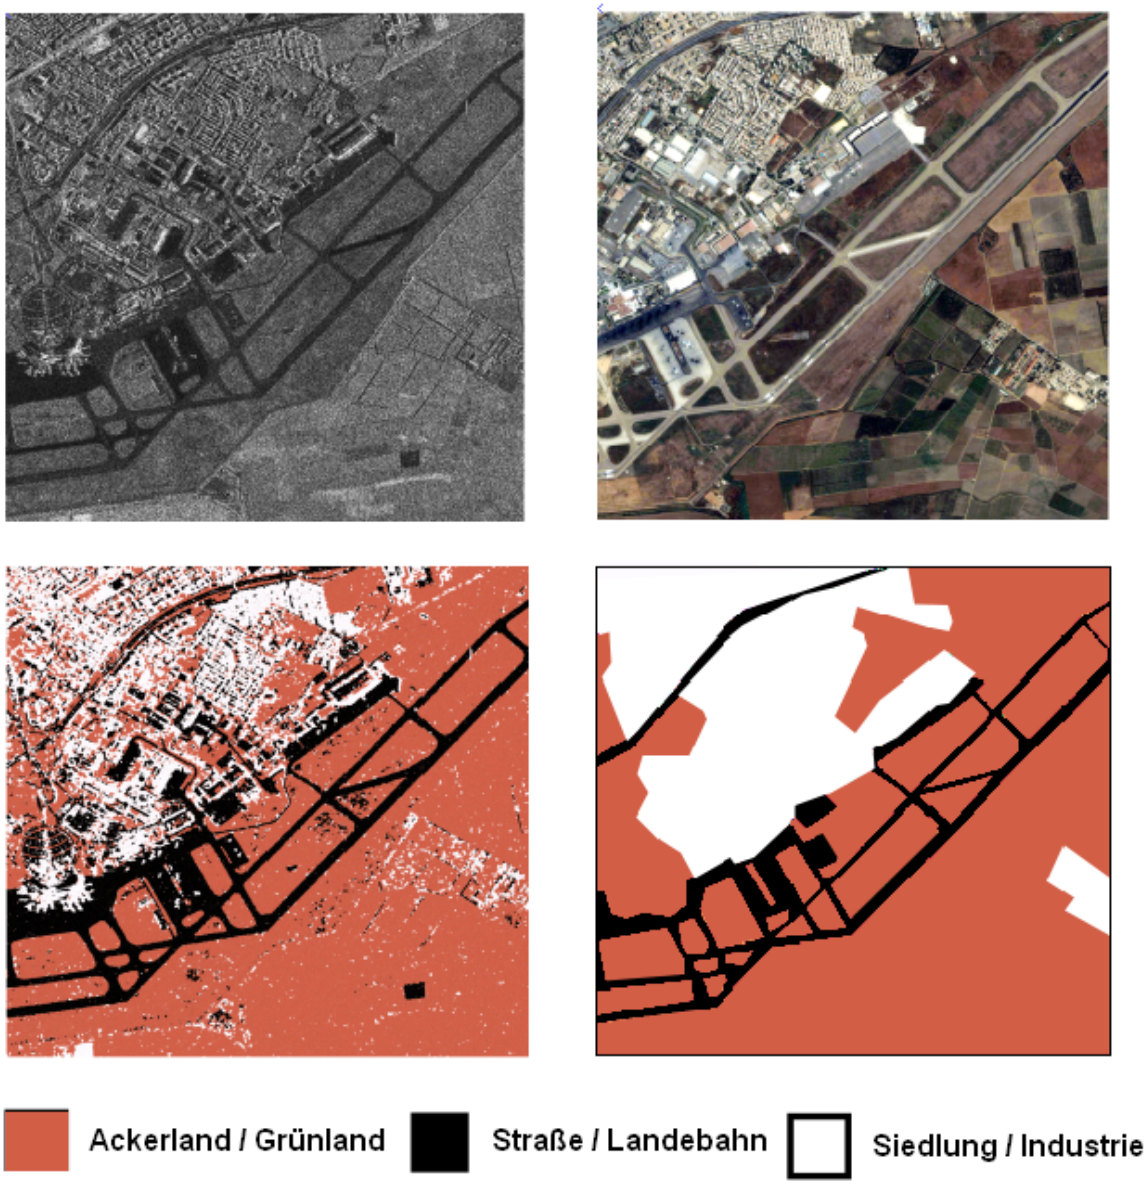

Abb. 5.11.: Klassifikationsergebnis: oben links Originalbild, oben rechts klassifiziertes Bild, unten links optisches Bild und unten rechts Referenzbild

		Klassifikation		
		Acker-/Grünland	Siedlung/Industrie	Straße/Landebahn
Referenz	Acker-/Grünland	82 %	11 %	7 %
	Siedlung/Industrie	24 %	56 %	20 %
	Straße/Landebahn	20 %	14 %	66 %

Tabelle 5.4.: Konfusionsmatrix für die Klassifikation der Algier-Szene

5.5. Bewertung der Ergebnisse im Hinblick auf die ATKIS Datenbasis

In diesem Kapitel wurden zwei TerraSAR-X Bilder unterschiedlicher Auflösung untersucht, um eine Beurteilung über die Eignung von hochauflösenden SAR-Bildern als Grundlage für die ATKIS-Daten treffen zu können.

Die erste Untersuchung erfolgte anhand der Fuhrberg-Szene mit einer Auflösung von ca. 1 Meter in Range und 2 Metern in Azimut. Die Klassen Siedlung und Industrie wurden zu einer Klasse zusammengefasst, da sich ihre Differenzierung als unzureichend herausgestellt hat. Weiterhin wurden die Klassen Ackerland/Grünland und Wald berücksichtigt. Bei der Evaluation der Klassifikationsergebnisse stellten die Klassen Siedlung/Industrie und Ackerland/Grünland mit ca. 58 Prozent die besten Übereinstimmungen dar. Die Klasse Wald wurde lediglich mit 30 Prozent Genauigkeit eingestuft. Insgesamt fällt das Ergebnis für die TerraSAR-X Daten der Region Fuhrberg, aufgrund unzureichender Abbildung der zu untersuchenden Klassen nicht zufriedenstellend aus. Eine Fortführung und Verifikation der ATKIS Datenbasis mit den untersuchten Klassen Ackerland/Grünland und Wald ist nach den erzielten Ergebnissen unter Berücksichtigung eines einzigen Merkmals sowie einer Polarisation und eines Zeitpunktes nicht möglich. Die Klasse Siedlung ist ebenfalls nicht sehr zuverlässig abgebildet und anhand dieses Ansatzes und gegebenen Vorrausetzungen der verfügbaren Daten noch nicht für ATKIS geeignet.

Die zweite Untersuchung wurde für eine TerraSAR-X Aufnahme von Algier mit einer Auflösung von ca. 0.6 Metern in Range und 1.1 Metern in Azimut durchgeführt. Hierzu wurden die Klassen Ackerland/Grünland, Siedlung/Industrie sowie die Klasse Straße als Repräsentant für die Subklassen Landebahn und Straße ausgewählt. Mit der Klasse Ackerland/Grünland wurde mit 82 Prozent Übereinstimmung ein sehr gutes Resultat erzielt. Eine Fortführung der ATKIS Datenbasis wäre aufgrund des Ergebnisses durchaus vorstellbar. Es muss jedoch erwähnt werden, dass die Klasse Wald in dieser Szene nicht vorhanden ist und das gute Ergebnis darauf zurückzuführen sein kann.

Bei der Klasse Siedlung/Industrie wurden etwa die gleichen Ergebnisse wie bei der ersten Untersuchung erzielt. Die Semantik der Abbildung von Siedlungsbereichen in SAR-Bilddaten impliziert große Fehler bei der Klassifizierung. Das Auftreten der typischen Doppelreflexion in Siedlungen unterliegt der (zufälligen) Anordnung von Gebäuden und Bepflanzung, sodass nur ein kleiner, wenig kompakter Teil des tatsächlich besiedelten Gebietes abgebildet wird. Ein weiterer Grund für die nicht zuverlässige Klassifikation von Siedlungsbereichen ist auf das Referenzbild zurückzuführen. Hierbei wurden Siedlungsbereiche und Industriegebiete nicht detailliert abgebildet. Daher könnte die Klassifizierung richtig, jedoch aufgrund des Referenzbildes falsch bewertet sein.

Für die Klasse Straße/Landebahn wurde mit einer Genauigkeit von 66 Prozent ein gutes Ergebnis erzielt, wenn man die Problematik der Abbildung dieses Objektes bei optischen Sensoren berücksichtigt. Straßen werden aufgrund spektraler Eigenschaften bei optischen Sensoren ähnlich wie Gebäude abgebildet. Eine Fortführung und Verifikation von ATKIS Datenbasis durch Kombination von optischen und Radarsensoren könnte somit noch bessere Ergebnisse liefern.

6. Zusammenfassung und Ausblick

In diesem Kapitel wird zunächst eine Zusammenfassung der Masterarbeit präsentiert. Abschließend werden die aus der Arbeit erzielten Schlussfolgerungen sowie Ansatzpunkte für zukünftige Verbesserungen dargestellt.

6.1. Zusammenfassung

Ziel dieser Masterarbeit war es die Eignung von SAR-Bildern für eine Fortführung und Verifikation von ATKIS Datenbasis zu untersuchen. Hierzu stand ein bereits bestehendes Verfahren zur Klassifikation von optischen Bilddaten zur Verfügung, welche auf SAR-Amplitudenbilder angepasst und zusätzlich erweitert wurde. Das Klassifikationsverfahren basiert auf dem Bayes-Theorem, in dem Nachbarschaftsrelationen mittels Markoff-Zufallsfeldern (a apriori-Term) modelliert sowie Sensorstatistik durch die Likelihood-Term abgeschätzt werden.

Der bereits existierende Ansatz geht bei der Wahl des Likelihood-Terms von einer Gauss-Verteilung aus. Diese Annahme ist jedoch für die verwendeten Merkmale der Amplitudenbilder nur annäherend erfüllt. Die statistische Eigenschaft eines SAR-Signals wird im Wesentlichen von der multiplikativen Störung des Speckle-Effektes bestimmt. Dadurch wirken homogene Flächen, wie z.B. Ackerflächen, sehr körnig. Weiterhin können Siedlungsbereiche in SAR-Bildern, die durch ihre Heterogenität (z.B. Wiesen und Dächer) gekennzeichnet sind, mit dem existierenden Likelihood-Term nur sehr ungenau modelliert werden.

Im Rahmen dieser Arbeit wurde daher eine möglichst korrekte Modellierung der Sensorstatistik gesucht, um diese in den obigen Likelihood-Term integrieren zu können. Hierbei stellte sich die Fisher-Verteilung als idealer Kandidat heraus. Diese Verteilung ist besonders durch ihre Flexibilität gekennzeichnet. Die Untersuchungen zeigten, dass sich mit der Fisher-Verteilung Siedlungsbereiche sowie ländliche Regionen im SAR-Amplitudenbild charakterisieren lassen. Eine weitere Besonderheit der Fisher-Verteilung lag in ihrer Parametrisierung. Diese konnte nicht durch klassische Ansätze, wie beispielsweise MOM oder ML, durchgeführt werden. Daher wurde eine spezielle Technik auf Basis der „Second-Kind Statistics“ verwendet.

Innerhalb des bestehenden Klassifikationsansatzes wurden der Likelihood-Term durch die Fisher-Verteilung sowie der a priori-Term durch das Potts-Modell angepasst.

Für die Klassifikation wurden zwei hochauflösende Amplitudenbilder vom deutschen Radarsatelliten TerraSAR-X verwendet. Hierbei wurden innerhalb einer Trainingsphase die interessierenden Klassen durch die Fisher-Verteilung angepasst. Die Güte der Klassifikationsergebnisse wurde anhand einer Konfusionsmatrix bewertet.

Für die erste Testregion, mit einer Auflösung von ca. 1 Meter in Range und 2 Metern in Azimut, wurde die Klassifikation auf das originale Amplitudenbild sowie einer Speckle reduzierten Version durchgeführt. Für die zu untersuchenden Klassen Wald, Siedlung/Industrie und Ackerland/Grünland wurden für beide Spezifikationen keine zufriedenstellenden Ergebnisse erzielt, was auf die Nutzung eines einzigen Merkmales (Grauwerte) sowie der zu geringen Auflösung zurückzuführen ist.

Für die zweite Testregion, mit einer Auflösung von ca. 0.6 Metern in Range und 1.1 Metern in Azimut, wurden wesentlich bessere Ergebnisse erzielt. Hierbei wurden die Klassen Ackerland/Grünland, Straße/Landebahn sowie Siedlung/Industrie untersucht. Besonders bei den beiden zuerst genannten Klassen ist für eine Fortführung und Verifikation von ATKIS in Verbindung von optischen Bilddaten Potential vorhanden. Bei der Klasse Siedlung/Industrie wurde auch bei dieser Testregion kein zufriedenstellendes Ergebnis erzielt, was auf die Semantik der Abbildung von Siedlungsbereichen in SAR-Bilddaten und vor allem an der sehr groben Referenz zurückzuführen ist. Die Klassifikation für diese Klasse ist daher sehr detaillierter als vergleichende Referenzbild.

6.2. Schlussfolgerung und Ausblick

Das in dieser Arbeit verwendete Klassifikationsverfahren ist für hochauflösende TerraSAR-X Bilder nur bedingt geeignet. Zwar lassen sich die einzelnen Klassen optimal durch die Fisher-Verteilung anpassen sowie der Speckle-Effekt durch die Modellierung der Nachbarschaftsrelationen reduzieren, jedoch lassen sich nicht alle Klassen auf Basis eines einzigen Merkmals eindeutig im Merkmalsraum trennen. Besonders die Klassen Ackerland/Grünland und Wald sind schwer zu differenzieren.

Für die Klasse Siedlung/Industrie sind teilweise zufriedenstellende Ergebnisse erzielt wurden, was besonders auf das sehr grobe erstellte Referenzbild zurückzuführen ist. Ein detaillierteres Referenzbild wurde sicherlich noch zu besseren Ergebnissen führen.

Weiterhin sind die meisten Klassen aufgrund der hohen Auflösung der TerraSAR-X Bilder sehr texturreich geprägt. Die räumliche Beziehung zwischen den Grauwerten wird allerdings nicht hinreichend mit Markoff-Zufallsfeldern und durch die Statistik 1. Ordnung berücksichtigt, was bei vielen Texturen eine differenzierte Beschreibung verhindert.

Für zukünftige Arbeiten bietet es sich daher an zusätzliche Texturmerkmale mit in den bestehenden Klassifikationsansatz zu integrieren. Hierfür könnten sich besonders Verfahren aus der Statistik 2. Ordnung eignen. Der bekannteste Ansatz für die Charaktersierung der Texturmerkmale ist die Co-occurrence-Matrix [32]. Für diese Matrix können verschiedene Merkmale berechnet werden. In [44] werden hierfür beispielsweise 14 verschiedene Maße angegeben, welche auch als Haralick-Parameter bezeichnet werden. Weiterhin können mit der Berechnung des Korrelationskoeffizienten [45] die drei unabhängigen Maße Kontrast, Inverser Moment und Korrelation ausgewählt werden, um diese als Basis für die Klassifikation anzuwenden. Als dritter Ansatz eignet sich für die Beurteilung der Ausprägung der Textur verschiedener Klassen die Bestimmung des Variationskoeffizienten.

Neben Informationen der Textureigenschaften bieten sich zusätzlich die Verwendung von

multitemporalen [46] und multipolarimetrischen [47] Radardaten an soweit diese zu Verfügung stehen.

Alternativ zu dem in dieser Arbeit verwendeten Klassifikationsansatz zeigen Forschungsarbeiten die Eignung von Neuronalen Netzen [30] sowie die Fuzzy-Logik [48] als Klassifikationsprozess für SAR-Bilder. Beide Ansätze sind hierbei besonders geeignet für Nutzung und Fusion mehrerer Informationsebenen, um die Klassifikation zu optimieren.

Literaturverzeichnis

[1] MÜLLER, S.: *Extraktion baulich geprägter Flächen aus Fernerkundungsdaten zur Qualitätssicherung flächenhafter Geobasisdaten*. Stuttgart : Ibidem-Verl., 2007 (Wissensbasierte Bildauswertung 9). – ISBN 9783898218597

[2] LIEDTKE, C.E. ; BUCKNER, J. ; PAHL, M. ; STAHLHUT, O.: Knowledge Based System for the Interpretation of Complex Scenes. (2001)

[3] BUSCH, A. ; GERKE, M. ; GRÜNREICH, D. ; HEIPKE, C. ; LIEDTKE, C.E. ; MÜLLER, S.: Automatisierte Verifikation topographischer Geoinformationen unter Nutzung optischer Fernerkundungsdaten: Systemdesign und praktische Ergebnisse. 2005. – Forschungsbericht

[4] HEIPKE, C. ; LIEDTKE, C. E. ; MÜLLER, S. ; WEIS, M.: Automatische Qualitätssicherung von Geoinformation mit Hilfe von Luftbildern. o.J.. – Forschungsbericht

[5] ALBERTZ, J.: *Einführung in die Fernerkundung*. 3., aktualisierte und erw. Aufl. Darmstadt : Wiss. Buchges., 2007. – ISBN 9783534198788

[6] BAMLER, R. ; ADAM, N. ; HINZ, S. ; EINEDER.M: SAR-Interferometrie für geodätische Anwendungen. 2008. – Forschungsbericht

[7] WESSEL, B.: *Automatische Extraktion von Straßen aus SAR-Bilddaten*, Fakultät für Bauingenieur-und Vermessungswesen der Technischen Universität München, Diss., 2006

[8] KLAUSING, H. ; HOLPP, W.: *Radar mit realer und synthetischer Apertur*. München : Oldenbourg, 2000. – ISBN 3486234757

[9] BAYER, T.: Korrektur reliefbedingter radiometrischer Verzerrungen in geocodierten Seasat-A SARBildern am Beispiel des Szenenausschnittes Bonn und Umgebung / DLR-Forschungsbericht. 1990. – Forschungsbericht

[10] ULABY, F.T. ; DOBSON, M.C.: *Handbook of radar scattering statistics for terrain*. Artech House, 1989 (The @Artech House remote sensing library). – ISBN 0890063362

[11] GOODMAN, J. W.: Some fundamental properties of speckle. (1976)

[12] OLIVER, C. ; RALEIGH, N.C ; QUEGAN, S.: *Understanding synthetic aperture radar images*. 2004 (@SciTech radar and defense series)

[13] DUDA, R.O. ; HART, P.E. ; STORK, D.G.: *Pattern classification:*. 2. ed. New York [u.a.] : Academic Internet Publications, 2006. – ISBN 1428813837

[14] JÄHNE, B. ; 6 (Hrsg.): *Digitale Bildverarbeitung*. Springer, 2005

[15] KRYLOV, V. ; G.MOSER ; SEBASTIANO, B. ; SERPICO, J.Z.: Modeling the statistics of high resolution SAR images. (2008)

[16] TISON, C. ; NICOLAS, J.M. ; TUPIN, F. ; MAITRE, H.: A new statistical model for Markovian classification of urban areas in high-resolution SAR images. 42 (2004), Oktober, Nr. 10, S. 2046–2057

[17] NICOLAS, J.M. ; TUPIN, F.: Gamma mixture modeled with ßecond kind statistics": application to SAR image processing. In: *Proc. IEEE International Geoscience and Remote Sensing Symposium IGARSS '02* Bd. 4, 2002, S. 2489–2491

[18] BATIR, N.: On some properties of digamma and polygamma functions. (2005)

[19] RADE, L. ; WESTERGREN, B. ; P.VACHENAUER (Hrsg.): *Springers mathematische Formeln*. 3., durchges. Aufl. Berlin [u.a.] : Springer, 2000. – ISBN 3540675051

[20] TISON, C. ; NICOLAS, J.M. ; TUPIN, F.: Classification of X-band high resolution SAR images over urban areas: Markovian segmentation using Mellin transform. In: *Proc. 2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*, 2003, S. 110–114

[21] NICOLAS, J.M.: *Application de la transformee de Mellin : etude des lois statistiques de l imagerie coherente*, Departement Traitement du Signal et des Images Groupe Traitement et Interpretation des Images, Diss., 2006

[22] MOSER, G. ; ZERUBIA, J. ; SERPICO, S.B.: Dictionary-based stochastic expectation-maximization for SAR amplitude probability density function estimation. 44 (2006), Januar, Nr. 1, S. 188–200

[23] TISON, C. ; NICOLAS, J.M. ; TUPIN, F.: Accuracy of fisher distributions and log-moment estimation to describe amplitude distributions of high resolution SAR images over urban areas. In: *Proc. IEEE International Geoscience and Remote Sensing Symposium IGARSS '03* Bd. 3, 2003, S. 1999–2001

[24] NICOLAS, J.M.: A fisher-MAP filter for SAR image processing. In: *Proc. IEEE International Geoscience and Remote Sensing Symposium IGARSS '03* Bd. 3, 2003, S. 1996–1998

[25] ASGHARBEYGI, N. ; MALEKI, A.: Geodesic K-means clustering. In: *Proc. 19th International Conference on Pattern Recognition ICPR 2008*, 2008, S. 1–4

[26] XIUPING, J. ; RICHARDS, J.A: Efficient maximum likelihood classification for imaging spectrometer data sets. 32 (1994), März, Nr. 2, S. 274–281

[27] BAO, M.: Classification of multi-temporal SAR images and INSAR coherence images using adaptive neighborhood model and simulated annealing approach. (2001)

[28] OUARZEDDINE, M. ; SOUISSI, B. ; BELHADJ-AISSA, A.: ClassIfication of polarImetrIc sar images based on scattering mechanism. (o.J.)

[29] JACOB, A.M. ; E.M. ; FERNANDES, D.: SAR image classification using a neural classifier based on Fisher criterion. In: *Proc. VII Brazilian Symposium on Neural Networks SBRN 2002*, 2002, S. 168–172

[30] BURINI, A. ; PUTIGNANO, C. ; FRATE, F. D. ; LICCIARDI, G. ; PRATOLA, C. ; SCHIAVON, G. ; SOLIMINI, D.: TerraSAR-X/SPOT-5 Fused Images for Supervised Land Cover Classification. In: *Proc. IEEE International Geoscience and Remote Sensing Symposium IGARSS 2008* Bd. 5, 2008, S. V–373–V–376

[31] TAN, C.P. ; KOAY, J.Y. ; LIM, K.S. ; H.T ; EWE ; CHUAH, H.T.: ClassIfication of multi-temporal sar images for rice crops using combined entropy decomposition and support vector machine technique. (2007)

[32] KASAPOGLU, N.G. ; ERSOY, O. ; YAZGAN, B.: Feature extraction of SAR data based on eigenvector of texture samples. In: *Proc. IEEE International Geoscience and Remote Sensing Symposium IGARSS '04* Bd. 5, 2004, S. 3042–3045

[33] CLOUDE, S.R. ; POTTIER, E.: An entropy based classification scheme for land applications of polarimetric SAR. 35 (1997), Januar, Nr. 1, S. 68–78

[34] KRÄTZSCHMAR, E.: Vorstellung unterschiedlicher Klassifikationsverfahren in der Radar-Fernerkundung / Technische Universität Dresden Fakultät Forst-, Geo- und Hydrowissenschaften Institut für Kartographie. 1992. – Forschungsbericht

[35] SAKUMA, J. ; KOBAYASHI, S.: Non-parametric expectation-maximization for Gaussian mixtures. In: *Proc. 9th International Conference on Neural Information Processing ICONIP '02* Bd. 1, 2002, S. 517–522

[36] LI, S.Z.: *Markov random field modeling in computer vision*. Tokyo : Springer, 1995 (Computer science workbench). – ISBN 4431701451

[37] KLONOWSKI, J.: *Segmentierung ind Interpretation digitaler Bilder mit Markoff-Zufallsfelder*, Institut für Theoretische Geodäsie der Universität Bonn, Diss., 1997

[38] GEMAN, S. ; GEMAN, D.: Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. (1984), November, Nr. 6, S. 721–741

[39] WU, F. Y.: The Potts model. In: *Rev. Mod. Phys.* 54 (1982), Jan, Nr. 1, S. 235–268

[40] RIMSCHA, M.: *Algorithmen kompakt und verständlich*. 1. Aufl. Wiesbaden, 2009 (Programmiersprachen, Datenbanken und Softwareentwicklung)

[41] LEE, J.S.: Digital Image Enhancement and Noise Filtering by Use of Local Statistics. (1980), März, Nr. 2, S. 165–168

[42] LEWIS, H.G. ; BROWN, M.: A generalized confusion matrix for assessing area estimates from remote sensing imagery. In: *International Journal of Remote Sensing* 16 (2001), S. 3223–3235

[43] LANDIS, J.R. ; KOCH, G.G.: The Measurement of Observer Agreement for Categorical Data. In: *International Biometric Society* 33 (1977), S. 159–174

[44] HARALICK, R.M. ; SHANMUGAM, K. ; DINSTEIN, H.: Textural Features for Image Classification. 3 (1973), November, Nr. 6, S. 610–621

[45] PAUDYAL, D.R. ; EIUMNOH, A. ; ASCHBACHER, J.: Textural information in SAR images for land-cover applications. In: *Proc. International Geoscience and Remote Sensing Symposium IGARSS '95. 'Quantitative Remote Sensing for Science and Applications'* Bd. 2, 1995, S. 1020–1022

[46] MELGANI, F. ; SERPICO, S.B.: A Markov random field approach to spatio-temporal contextual image classification. 41 (2003), November, Nr. 11, S. 2478–2487

[47] HOEKMAN, D.H. ; VISSERS, M.A.M.: A new polarimetric classification approach evaluated for agricultural crops. 41 (2003), Dezember, Nr. 12, S. 2881–2889

[48] BUJOR, F. ; TROUVE, E. ; VALET, L. ; NICOLAS, J.M. ; RUDANT, J.P.: Application of log-cumulants to the detection of spatiotemporal discontinuities in multitemporal SAR images. 42 (2004), Oktober, Nr. 10, S. 2073–2084

Abbildungsverzeichnis

1.1. optisches Satellitenbild von IKONOS (links) und Radarbild vom TerraSAR-X (rechts). Während optische Bilder die chemischen Eigenschaften der Erdoberfläche abbilden, sind in Radarbildern die physikalischen Eigenschaften erfasst. 2

2.1. Das Elektromagnetische Spektrum. Markiert sind Frequenzband der IKONOS-Kanäle (orange) und des von TerraSAR-X genutzten X-Bandes (nach [5]). 5
2.2. SAR-Aufnahmegeometrie (nach [6]) 6
2.3. Auflösung in Entfernung und Grundrissebene (nach [7]) 8
2.4. Geometrische Auflösung in Azimut: Länge des synthetischen Apertur L_{sa} (nach [7]) 9
2.5. Geometrische und radiometrische Effekte im SAR-Bild (nach[9]) 10
2.6. Rückstreumechanismen: Oberflächen- und Volumenstreuung (nach [7]) . . 14
2.7. (a) Einzelne Streuelemente in einer Auflösungszelle und ihre rückgestreuten Wellen als Vektoren (Länge: Signalstärke, Richtung: Phase); (b) Signal als Summe der rückgestreuten Wellen einzelner Streuelemente (nach [7]). . . . 15
2.8. a) körnige Erscheinung von homogenen Flächen (Ackerflächen) auf einem Radarbild, b) konstruktive- destruktive Interferenz und resultierende Helligkeitswerte 16

3.1. Beispiel für Speckle: (a) X-Band Radaraufnahme einer Landschaft,(b) Hilstogramm (Amplitude) und (c) Rayleigh-Verteilung 22
3.2. Verteilungen des empirischen Modells: a) Log-Normal-, b) Weibul- und c) Nakagami-Rice-Verteilung 25
3.3. K-Verteilung mit $\mu = 0$ 27
3.4. Fisher-Verteilung für das Amplitudenbild mit unterschiedlichen Parametereinstellungen a) $\mu = 1, M = 1$ und $L = 1, 2, 5, 10$, b) $\mu = 1, L = 1, M = 1, 2, 5, 10$ (Beschriftung der Abbildung Größer) 29
3.5. Abschätzung der Fisher-Verteilung für verschiedene Klassen der Fuhrberg SAR-Szene. Der gelbe Bereich stellt das Histogramm der Daten dar a) Klasse Acker *dunkel*, b) Klasse Acker *hell*, c) Klasse Acker *mittel*, d) Klasse Wald und e) Klasse Siedlung 35

4.1. Abbildung des Merkmalraums auf die Menge der Objekte 37
4.2. OTB MRF-Framework 40
4.3. Labeling-Prinzip (gezeichnet nach [36]) 42
4.4. Graphendefinition für Nachbarschaften a) 1. Ordnung (4er-Nachbarschaft) b) 2. Ordnung (8er-Nachbarschaft), c) 3. Ordnung (12er-Nachbarschaft) auf einem 5×5 Gitter und d) Nachbarschaft bis 8. Ordnung (gezeichnet nach [37]) 45

4.5. a) Cliquen einer Nachbarschaft 1. Ordnung, b) zusätzliche Cliquen einer Nachbarschaft 2. Ordnung und c) zusätzliche Cliquen einer Nachbarschaft 3. Ordnung (gezeichnet nach [37]) 46
4.6. Labelkonfiguration durch Potts-Modell bzgl. 24er-Nachbarschaft und Zweier-Cliquen 49

5.1. Klassifikationsstrategie 55
5.2. Original TerraSAR-X Szene von Fuhrberg mit markierten Trainingsregionen Acker *dunkel* (rot), Acker *mittel* (gelb), Acker *hell* (grün), Wald (blau) und Siedlung/Industrie (schwarz) 56
5.3. Lernstichprobe (Musterklasse) für die Klassen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald und e) Siedlung/Industrie 57
5.4. Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen . . 58
5.5. Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker *dunkel*, b) Acker *mittel*, c) Acker *hell*, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen . . 59
5.6. Klassifikationsergebnis: oben links TerraSAR-X Bild Fuhrberg, oben recht optisches Bild, unten links klassifiziertes Bild und unten rechts Referenzbild 60
5.7. Klassifikationsergebnis: oben links TerraSAR-X Bild Fuhrberg (Lee-Filter), oben recht optisches Bild, unten links klassifiziertes Bild und unten rechts Referenzbild 61
5.8. Trainingsgebiete in der TerraSAR-X Szene Algier, Boden *hell* (blau), Boden *mittel* (rot), Boden *dunkel* (grün), Siedlung/Industrie (schwarz) 62
5.9. Lernstichprobe für die Klassen a) Boden *dunkel*, b) Boden *mittel*, c) Boden *hell* und d) Siedlung/Industrie 63
5.10. Abgeschätzte Fisher-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Boden *dunkel*, b) Boden *mittel*, c) Boden *hell*, d) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen 63
5.11. Klassifikationsergebnis: oben links Originalbild, oben rechts klassifiziertes Bild, unten links optisches Bild und unten rechts Referenzbild 65

A.1. Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregioen a) Acker dunkel, b) Acker mittel, c) Acker hell, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen 79
A.2. Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker dunkel, b) Acker mittel, c) Acker hell, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen . . 79
A.3. Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Boden dunkel, b) Boden mittel, c) Boden hell, d) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen 80
A.4. Klassifikationsergebnis : oben links TerraSAR-X Bild Fuhrberg, oben rechts optisches Bild und unten links klassifiziertes Bild und unten rechts Referenzbild 81
A.5. Klassifikationsergebnis : oben links TerraSAR-X Bild Fuhrberg (Lee-Filter), oben rechts optisches Bild und unten links klassifiziertes Bild und unten rechts Referenzbild 82

A.6. Klassifikationsergebnis : oben links Originalbild, oben rechts klassifiziertes Bild und unten links optisches Bild und unten rechts Referenzbild 83

Tabellenverzeichnis

3.1. Abgeschätzte Parameter der Fisher-Verteilung für verschiedene Klassen des TerraSAR-X Bildes von Fuhrberg 34

5.1. Verwendete Datensätze 54
5.2. Konfusionsmarix für die Klassifikation der Fuhrberg-Szene 60
5.3. Konfusionsmarix für die Klassifikation der Fuhrberg-Szene (Lee-Filter) . . 61
5.4. Konfusionsmatrix für die Klassifikation der Algier-Szene 65

A.1. Abgeschätzte Parameter der Fisher-Verteilungen 78
A.2. Abgeschätzte Parameter der Gauss-Verteilungen 80
A.3. Konfusionsmarix für die Klassifikation der Fuhrberg-Szene 81
A.4. Konfusionsmarix für die Klassifikation der Fuhrberg-Szene (Lee-Filter) . . 82
A.5. Konfusionsmarix für die Klassifikation der Algier-Szene 83

A. Anhang

In diesem Kapitel sind die Klassifikationsergebnisse dargestellt, die durch die Verwendung der Gauss-Verteilung als Likelihood-Funktion innerhalb der Markoff-Klassifikation verwendet wurden. Für die Trainingsphase wurden die identischen Trainingsregionen wie aus Kapitel 5 verwendet.

A.1. Tabellen und Diagramme aus der Trainingsphase

Abgeschätzte Paramter der Fisher-Verteilungen

In der Tabelle A.1 sind die abgeschätzten Parameter sowie die Anzahl der Stichproben in der Trainingsphase in den Abschnitten 5.3.1 und 5.4.1 verwendet wurden, dargestellt.

Fuhrberg				
Klasse	L	M	μ	Anzahl der Pixel
Acker dunkel	0.99	26.01	66.96	17800
Acker mittel	0.95	26.34	110.44	7700
Acker hell	0.96	36.62	166.36	12500
Wald	0.96	2.86	89.54	11100
Siedlung/Industrie	0.98	1.16	83.60	20500
Fuhrberg (Lee-Filter)				
Klasse	L	M	μ	Anzahl der Pixel
Acker dunkel	18.12	17.61	58.04	17800
Acker mittel	18.32	10.55	95.39	7700
Acker hell	28.35	15.23	146.95	12500
Wald	16.10	5.58	82.86	11100
Siedlung/Industrie	50.00	83.45	83.45	20500
Algier				
Klasse	L	M	μ	Anzahl der Pixel
Boden dunkel	63.00	1.02	14.00	5900
Boden mittel	120.42	1.02	18.08	32000
Boden hell	142.35	0.98	9.40	20000
Siedlung/Industrie	93.36	0.82	0.79	24900

Tabelle A.1.: Abgeschätzte Parameter der Fisher-Verteilungen

Es wurden für die identschen Trainingsregionen wie aus den Abschnitten 5.3.1 und 5.4.1 auch die Parameter der Gauss-Verteilung abgeschätzt. Die Parameter sind der Tabelle A.2 zu entnehmen. Die abgeschätzten Gauss-Verteilungen sowie die Gegenüberstellungen dieser Verteilungen sind in den Abbildungen A.1 und A.2 für die Fuhrberg Testregion und in Abbildung A.3 für die Algier Testregion dargestellt.

Trainigsphase: Abgeschätzte Gauss-Verteilungen Fuhrberg

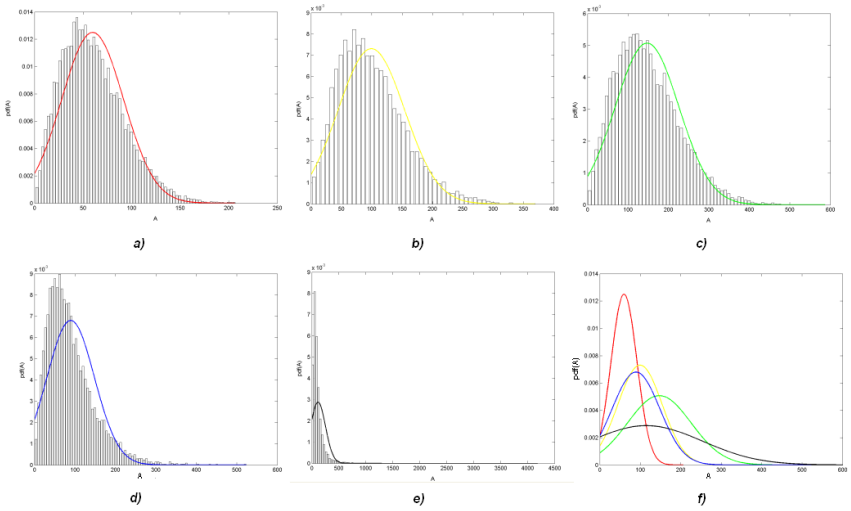

Abb. A.1.: Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregioen a) Acker dunkel, b) Acker mittel, c) Acker hell, d) Wald, e) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen

Trainigsphase: Abgeschätzte Gauss-Verteilungen Fuhrberg (Lee-Filter)

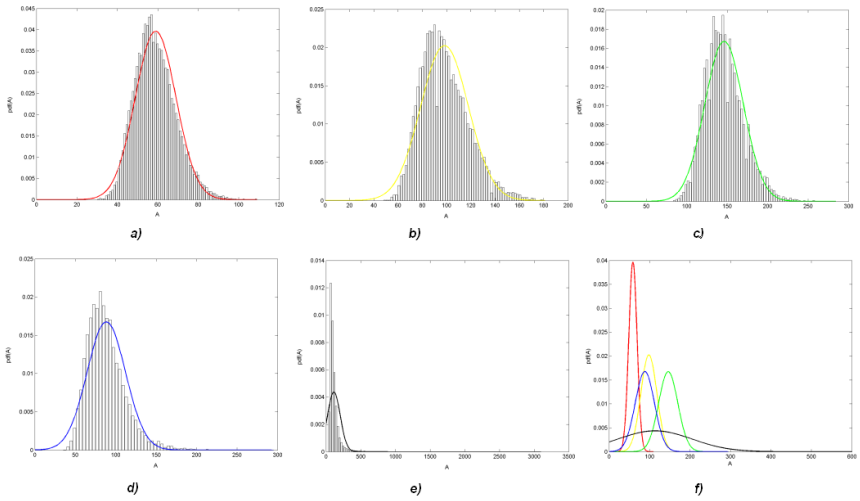

Abb. A.2.: Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Acker dunkel, b) Acker mittel, c) Acker hell, d) Wald, e) Siedlung/-Industrie und f) Gegenüberstellung der Fisher-Verteilungen

Die Ergebnisse aus den Abildungen A.1, A.2 und A.3 veranschaulichen, dass die relative Häufigkeit der Lernstichproben aus der Klasse Siedlung/Industrie nicht durch eine Gauss-Verteilung angenähert werden kann. Dagegen können die restlichen Klassen nur grob angenähert werden.

Trainigsphase: Abgeschätzte Gauss-Verteilungen Algerien

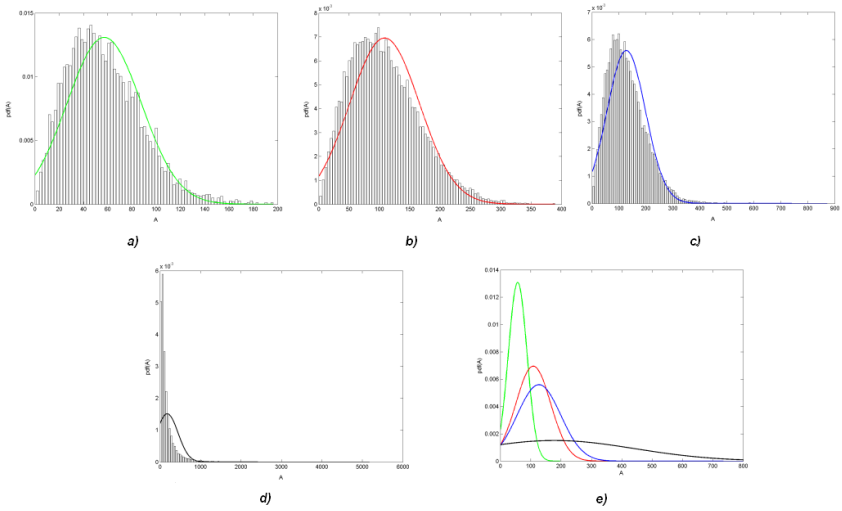

Abb. A.3.: Abgeschätzte Gauss-Verteilungen und zugehörige Histogramme (Balken) der Trainingsregionen a) Boden dunkel, b) Boden mittel, c) Boden hell, d) Siedlung/Industrie und f) Gegenüberstellung der Fisher-Verteilungen

Fuhrberg			
Klasse	μ	σ	Anzahl der Pixel
Acker dunkel	59.83	31.92	17800
Acker mittel	99.41	54.60	7700
Acker hell	147.06	78.69	12500
Wald	89.40	58.68	11100
Siedlung/Industrie	114.45	138.68	20500
Fuhrberg (Lee-Filter)			
Klasse	μ	σ	Anzahl der Pixel
Acker dunkel	58.91	10.06	17800
Acker mittel	98.27	19.71	7700
Acker hell	146.13	23.85	12500
Wald	88.37	23.82	11100
Siedlung/Industrie	113.38	91.58	20500
Algier			
Klasse	μ	σ	Anzahl der Pixel
Boden dunkel	57.07	30.48	5900
Boden mittel	108.43	57.39	32000
Boden hell	127.08	71.28	20000
Siedlung	177.57	264.25	24900

Tabelle A.2.: Abgeschätzte Parameter der Gauss-Verteilungen

A.2. Klassifikationsergebnisse unter Verwendung des Gauss-Modells

A.2.1. Ergebnisse Furhberg

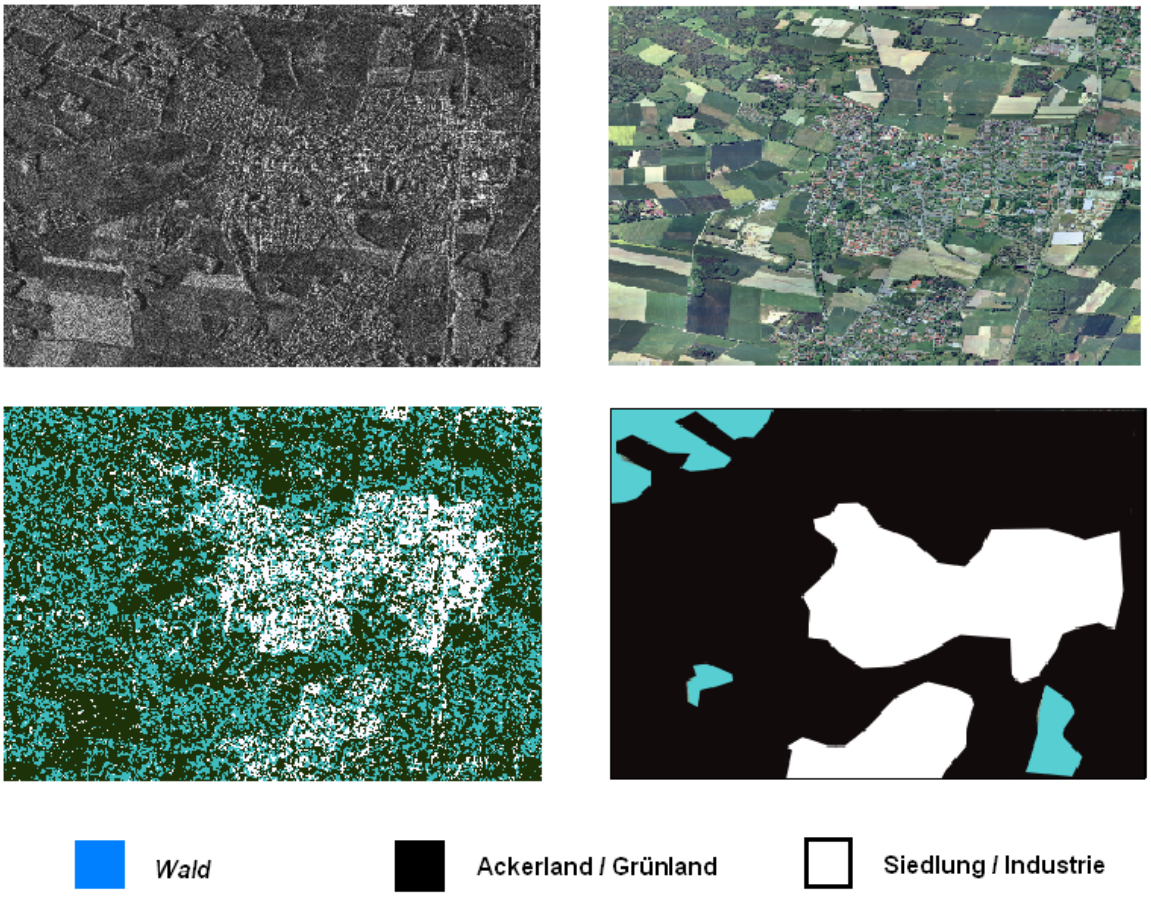

Abb. A.4.: Klassifikationsergebnis : oben links TerraSAR-X Bild Fuhrberg, oben rechts optisches Bild und unten links klassifiziertes Bild und unten rechts Referenzbild

		Klassifikation		
		Siedlung/Industrie	Ackerland/Grünland	Wald
Referenz	Siedlung/Industrie	36 %	38 %	25 %
	Ackerland/Grünland	4 %	65 %	30 %
	Wald	6 %	60 %	34 %

Tabelle A.3.: Konfusionsmarix für die Klassifikation der Fuhrberg-Szene

A.2.2. Ergebnisse Furhberg mit Speckle-Filter

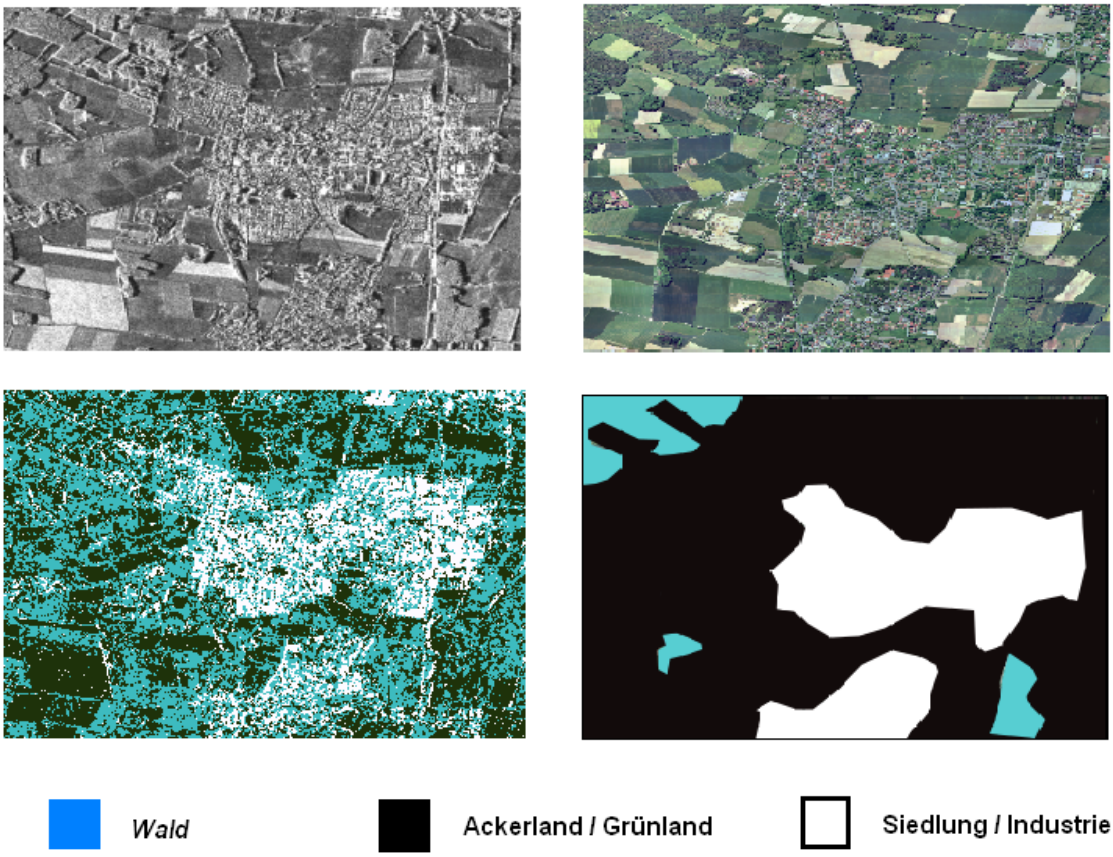

Abb. A.5.: Klassifikationsergebnis : oben links TerraSAR-X Bild Fuhrberg (Lee-Filter), oben rechts optisches Bild und unten links klassifiziertes Bild und unten rechts Referenzbild

		Klassifikation		
		Siedlung/Industrie	Ackerland/Grünland	Wald
Referenz	Siedlung/Industrie	42 %	21 %	36 %
	Ackerland/Grünland	5 %	52 %	43 %
	Wald	7 %	52 %	41 %

Tabelle A.4.: Konfusionsmarix für die Klassifikation der Fuhrberg-Szene (Lee-Filter)

A.2.3. Ergebnisse Algier

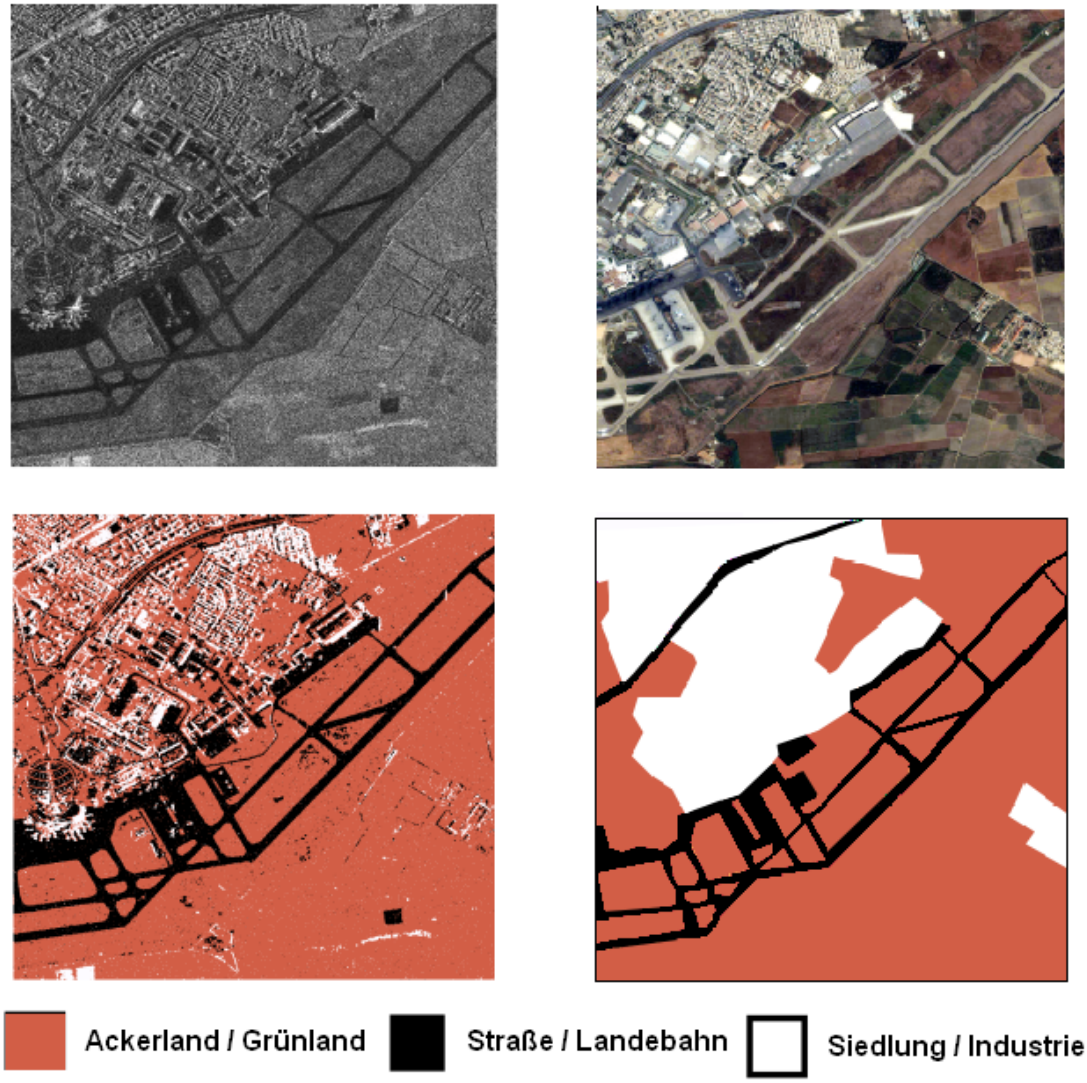

Abb. A.6.: Klassifikationsergebnis : oben links Originalbild, oben rechts klassifiziertes Bild und unten links optisches Bild und unten rechts Referenzbild

		Klassifikation		
		Acker-/Grünland	Siedlung/Industrie	Straße/Landebahn
Referenz	Acker-/Grünland	88 %	5 %	6 %
	Siedlung/Industrie	48 %	32 %	20 %
	Straße/Landebahn	28 %	7 %	65 %

Tabelle A.5.: Konfusionsmarix für die Klassifikation der Algier-Szene

Beim Vergleich zwischen den Ergebnissen aus den Abschnitten 5.3 - 5.4 (Fisher-Modell) und den Abschnitten A.2.1 - A.2.3 (Gauss-Modell) sind besonders beim ersteren Modell wesentlich bessere Resultate bezüglich der Klasse Siedlung/Industrie erzielt wurden. Bei den anderen untersuchenden Klassen wurde etwa die gleichen Genauigkeiten erreicht.