



Forschungsberichte
aus
dem Institut
für Höchstfrequenztechnik
und Elektronik
der
Universität Karlsruhe (TH)

Herausgeber:
Prof. Dr.-Ing. W. Wiesbeck

Martin Fritzsche

Anwendung von Verfahren der Mustererkennung zur Detektion von Landminen mit Georadaren

Band 30

Copyright: Institut für Höchstfrequenztechnik und Elektronik
Universität Karlsruhe (TH)

alle Rechte vorbehalten

Druck: Druckerei Gunter Dünnbier, 02779 Großschönau,
Tel. 035845-36757

ISSN: 0942-2935

Vorwort des Herausgebers

Die Globalisierung der letzten zehn Jahre als Folge der erhöhten Mobilität und Kommunikation hat Politik, Wirtschaft und Gesellschaft in neue, erweiterte Interessens- und Verantwortungsbereiche geführt. Während Politik und Wirtschaft in der Regel mit Nachdruck und nachhaltig ihre eigenen Interessen verfolgen, haben die Gesellschaften in vielen Ländern ihre Verantwortung für weltweite humanitäre Aktionen wahrgenommen. Infolge dieser Verantwortung entstand in den Industrienationen weltweit das Interesse an einer Lösung der Folgen lokaler Kriege. Insbesondere die Ermöglichung einer angemessenen Beweglichkeit in früheren Kriegsgebieten durch die Beseitigung von verstreuten Minen, Minenfeldern und nicht gezündeten Sprengkörpern steht hier im Vordergrund. Infolge des gesellschaftlichen Interesses an diesem Thema haben Organisationen und Gruppierungen wie die Vereinten Nationen und die Europäische Gemeinschaft Förderungen für Forschungsarbeiten und Einsatzarbeiten zur Minenbeseitigung bereit gestellt.

Die vorliegende Dissertation von Dr. Martin Fritzsche leistet mit ihrem Beitrag "unsupervised classification" einen wesentlichen Beitrag zur Lösung des Problems der Identifizierung der Minen. Vom Standpunkt des Einsatzes von Personen zur Minendetektion und Räumung wäre eine hundertprozentige Klassifikation wünschenswert. Diese wird sich aus technisch offensichtlichen Gründen nie realisieren lassen. Die vorliegende Arbeit liefert jedoch die bisher besten Ergebnisse auf diesem Gebiet. Durch den Einsatz optimaler und optimierter Algorithmen wird bei ausreichend gutem Datenmaterial eine auch für die Praxis ausreichende Klassifizierungsrate erreicht.

Ich wünsche der vorliegenden Arbeit eine hervorragende Verbreitung vor allem in Fachkreisen, um andere Arbeiten zu befruchten und das Gesamtproblem der Minendetektion und Räumung einer befriedigenden Lösung zuzuführen.

Prof. Dr.-Ing. Werner Wiesbeck
- Institutsleiter -

**Forschungsberichte aus dem
Institut für Höchstfrequenztechnik und Elektronik
der Universität Karlsruhe (TH)**

Herausgeber: Prof. Dr.-Ing. Werner Wiesbeck

- Band 1 Daniel Kähny
Modellierung und meßtechnische Verifikation polarimetrischer, mono- und bistatischer Radarsignaturen und deren Klassifizierung
- Band 2 Eberhardt Heidrich
Theoretische und experimentelle Charakterisierung der polarimetrischen Strahlungs- und Streueigenschaften von Antennen
- Band 3 Thomas Kürner
Charakterisierung digitaler Funkssysteme mit einem breitbandigen Wellenausbreitungsmodell
- Band 4 Jürgen Kehrbeck
Mikrowellen-Doppler-Sensor zur Geschwindigkeits- und Weg-messung - System-Modellierung und Verifikation
- Band 5 Christian Bornkessel
Analyse und Optimierung der elektrodynamischen Eigenschaften von EMV-Absorberkammern durch numerische Feldberechnung
- Band 6 Rainer Speck
Hochempfindliche Impedanzmessungen an Supraleiter / Fest- elektrolyt-Kontakten
- Band 7 Edward Pillai
Derivation of Equivalent Circuits for Multilayer PCB and Chip Package Discontinuities Using Full Wave Models
- Band 8 Dieter J. Cichon
Strahlenoptische Modellierung der Wellenausbreitung in urbanen Mikro- und Pikofunkzellen
- Band 9 Gerd Gottwald
Numerische Analyse konformer Streifenleitungsantennen in mehrlagigen Zylindern mittels der Spektralbereichsmethode
- Band 10 Norbert Geng
Modellierung der Ausbreitung elektromagnetischer Wellen in Funksystemen durch Lösung der parabolischen Approximation der Helmholtz-Gleichung

**Forschungsberichte aus dem
Institut für Höchstfrequenztechnik und Elektronik
der Universität Karlsruhe (TH)**

- Band 11 Torsten C. Becker
Verfahren und Kriterien zur Planung von Gleichwellennetzen für den Digitalen Hörrundfunk DAB (Digital Audio Broadcasting)
- Band 12 Friedhelm Rostan
Dual polarisierte Microstrip-Patch-Arrays für zukünftige satellitengestützte SAR-Systeme
- Band 13 Marcus Demmler
Vektorkorrigiertes Großsignal-Meßsystem zur nicht-linearen Charakterisierung von Mikrowellentransistoren
- Band 14 Andreas Froese
Elektrochemisches Phasengrenzverhalten von Supraleitern
- Band 15 Jürgen v. Hagen
Wide Band Electromagnetic Aperture Coupling to a Cavity: An Integral Representation Based Model
- Band 16 Ralf Pötzschke
Nanostrukturierung von Festkörperflächen durch elektrochemische Metallphasenbildung
- Band 17 Jean Parlebas
Numerische Berechnung mehrlagiger dualer planarer Antennen mit koplanarer Speisung
- Band 18 Frank Demmerle
Bikonische Antenne mit mehrmodiger Anregung für den räumlichen Mehrfachzugriff (SDMA)
- Band 19 Eckard Steiger
Modellierung der Ausbreitung in extrakorporalen Therapien eingesetzter Ultraschallimpulse hoher Intensität
- Band 20 Frederik Küchen
Auf Wellenausbreitungsmodellen basierende Planung terrestrischer COFDM-Gleichwellennetze für den mobilen Empfang
- Band 21 Klaus Schmitt
Dreidimensionale, interferometrische Radarverfahren im Nahbereich und ihre meßtechnische Verifikation

**Forschungsberichte aus dem
Institut für Höchstfrequenztechnik und Elektronik
der Universität Karlsruhe (TH)**

- Band 22 Frederik Küchen, Torsten C. Becker, Werner Wiesbeck
Grundlagen und Anwendungen von Planungswerkzeugen für den digitalen terrestrischen Rundfunk
- Band 23 Thomas Zwick
Die Modellierung von richtungsaufgelösten Mehrwegegebäudefunkkanälen durch markierte Poisson-Prozesse
- Band 24 Dirk Didascalou
Ray-Optical Wave Propagation Modelling Arbitrarily Shaped Tunnels
- Band 25 Hans Rudolf
Increase of Information by Polarimetric Radar Systems
- Band 26 Martin Döttling
Strahlenoptisches Wellenausbreitungsmodell und Systemstudien für den Satellitenmobilfunk
- Band 27 Jens Haala
Analyse von Mikrowellenheizprozessen mittels selbstkonsistenter finiter Integrationsverfahren
- Band 28 Eberhard Gschwendtner
Breitbandige Multifunktionsantennen für den konformen Einbau in Kraftfahrzeuge
- Band 29 Dietmar Löffler
Breitbandige, zylinderkonforme Streifenleitungsantennen für den Einsatz in Kommunikation und Sensorik
- Band 30 Martin Fritzsche
Anwendung von Verfahren der Mustererkennung zur Detektion von Landminen mit Georadaren

Anwendung von Verfahren der Mustererkennung zur Detektion von Landminen mit Georadaren

Zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS

von der Fakultät für

Elektrotechnik

der Universität Fridericiana Karlsruhe

genehmigte

DISSERTATION

von

Dipl.-Geophys. Martin Fritzsche

aus Darmstadt

Tag der mündlichen Prüfung:	25.6.2001
Hauptreferent:	Prof. Dr.-Ing. Werner Wiesbeck
Korreferent:	Prof. Dr.-Ing. Gerd Wanielik
Karlsruhe:	Juni 2001

Vorwort

Wesentliche Grundlagen der vorliegende Arbeit entstanden im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Forschungszentrum der DaimlerChrysler AG in Ulm.

Für die Annahme als Dissertation sowie wichtige Hinweise und Anregungen danke ich Herrn Prof. Dr.-Ing. Werner Wiesbeck. Bei Herrn Prof. Dr.-Ing. Gerd Wanielik bedanke ich mich für die bereitwillige Übernahme des Korreferats.

Mein Dank für die Durchführung der Freiluftvermessungen von Kugelobjekten sowie zahlreiche interessante Diskussionen zum Thema Georadar gilt Herrn David Daniels von ERA Technology in England. Herrn Dr. John Curtis vom US Army Corps of Engineers (Waterways Experiment Station) danke ich für die freundliche Überlassung der an Bodenproben gewonnenen Messdaten, die eine Bestimmung dielektrischer Bodeneigenschaften ermöglichten.

Meinem Kollegen Herrn Dipl.-Ing. Otto Löhlein verdanke ich die in vielen Diskussionen erhaltenen Anregungen, die zu einem besseren Verständnis der Tücken der Georadar-signalverarbeitung beitrugen. Die Software zur Organisation des Zugriffs auf die in dieser Arbeit verwendeten Messdaten an vergrabenen Objekten entstand im Rahmen eines von uns bearbeiteten Projekts zur Untersuchung der Sensordatenfusion für die Detektion von Landminen. Meinem Kollegen Herrn Dr.-Ing. Helmuth Eggers danke ich ebenfalls für zahlreiche Anregungen und die kritische Durchsicht des Manuskripts.

Großer Dank gilt meinem Vater, nicht nur für die kritische Durchsicht des Manuskripts, sondern auch für seine inhaltlichen Anregungen und seinen Zuspruch.

Mein unschätzbare Dank gilt meiner Frau Karin, für ihre enorme Unterstützung und Geduld als zeitweilig „alleinerziehende Mutter“ unserer beiden überaus lebhaften Söhne Niklas und Tim. Vor allem letzterer verhalf seinem Vater immer wieder dazu auch nachts für eine optimale Rechnerauslastung zu sorgen.

Inhaltsverzeichnis

1. Einleitung.....	1
1.1 Das Problem der Landminen.....	1
1.2 Stand der Technik.....	2
1.3 Zielsetzung und Gliederung der Arbeit.....	4
2. Grundlagen des Georadarverfahrens	7
2.1 Georadar-Systeme	8
2.1.1 Impulsradare.....	8
2.1.2 <i>Stepped-</i> und <i>Swept-Frequency</i> Radare.....	8
2.1.3 Antennen	9
2.1.4 Eindringtiefe.....	9
2.1.5 Auflösungsvermögen	10
2.1.6 Signalmodell.....	11
2.1.7 Datenbeispiel.....	12
2.1.8 Signalverarbeitung	12
2.2 Ausbreitung elektromagnetischer Wellen in dielektrischen Medien.....	18
2.2.1 Physikalische Grundlagen	18
2.2.2 Modellierung der Wellenausbreitung in verlustbehafteten Böden.....	21
2.2.3 Dielektrische Eigenschaften von Sprengstoffen	26
2.2.4 Modellierung und Charakterisierung von Bodenclutter.....	27
2.3 Streuung an Kugeln in realen Böden.....	31

2.3.1	Streuung an Vollkugeln und Kugelschalen	32
2.3.2	Simulationsergebnisse.....	34
3.	Objektdetektion	39
3.1	Erzeugung von Horizontalprojektionen	41
3.2	Detektion kreisförmiger Objekte	47
3.2.1	Hintergrundkompensation.....	48
3.2.2	Kantenverstärkung und Kantendetektion.....	48
3.2.3	Hough-Transformation	50
3.2.4	Kombination mehrerer Projektionen.....	52
3.3	Kombination von Detektion und Signalklassifikation	54
4.	Extraktion von Merkmalen aus Zeitsignalen.....	57
4.1	Die Bedeutung der Merkmalsextraktion	57
4.2	Klassische Verfahren der Zeit-Frequenz-Analyse	59
4.2.1	Kurzzeit-Fourier-Transformation	59
4.2.2	Quadratische Zeit-Frequenz-Transformation	61
4.3	Wavelet-Transformation	62
4.3.1	Kontinuierliche Wavelet-Transformation.....	62
4.3.2	Multiresolution-Analyse und diskrete Wavelet-Transformation	66
4.3.3	Wavelets und Filterbänke	70
4.3.4	Die Wahl eines geeigneten Wavelets.....	74
4.4	Wavelet-Packet-Transformation	76
4.4.1	Die Bestimmung der <i>besten Basis</i>	77

4.4.2	Die Bestimmung der am <i>besten diskriminierenden Basis</i>	80
4.5	Multiwavelets	81
4.6	Translationsinvariante Wavelet-Transformationen	83
4.7	Von Koeffizienten zu Merkmalen	87
4.7.1	Direkte Verwendung von Koeffizienten als Merkmale	88
4.7.2	Berechnung von Merkmalen aus Koeffizienten	89
4.7.3	Dimensionsreduktion	90
4.7.4	Klassifikation	93
4.8	Wavelet-Netze	94
4.8.1	<i>Matching Pursuits</i> zur Signalrepräsentation	95
4.8.2	<i>Matching Pursuits</i> zur Signalklassifikation	97
4.9	Alternative Verfahren der Zeit-Frequenz-Analyse	101
4.9.1	Fourier-Spektren	101
4.9.2	Prony-Verfahren	103
5.	Daten	105
5.1	Simulationen	105
5.2	Messungen an Kugeln in Luft	107
5.3	Messungen an vergrabenen Objekten	109
6.	Ergebnisse	113
6.1	Verifikation des Detektionsverfahrens	113
6.2	Klassifikation simulierter Streusignale	116
6.3	Klassifikation in Luft vermessener Kugeln	118

6.4	Klassifikation vergrabener Objekte	120
6.5	Kombination von Detektion und Klassifikation	121
6.6	Bewertung der Methoden zur Merkmalsextraktion	123
7.	Zusammenfassung	125
	Liste häufig verwendeter Symbole und Abkürzungen	129
	Literaturverzeichnis.....	133
	Anhang	143
A.1	Polynomklassifikator	143
A.2	Optimierung mit dem <i>Threshold-Accept</i> -Verfahren.....	145

1. Einleitung

Die Sinnesorgane des Menschen erlauben zwar die Erfassung der Umwelt und das Leben und Überleben unter vielfältigen Bedingungen, aufgrund der Begrenztheit der Wahrnehmung im akustischen und elektromagnetischen Spektrum ist es ihm jedoch nicht möglich in den Erdboden „hineinzusehen“. Menschen, die aufgrund ihrer Lebensumstände gezwungen sind sich in vermintem Gebiet zu bewegen, leben im wahrsten Sinne des Wortes auf unsicherem Terrain. Zum Aufspüren und Beseitigen dieser Bedrohung ist man daher auf moderne technische Hilfsmittel angewiesen. Mit dem hier formulierten Problem der Sichtbarmachung von Objekten oder Strukturen, die unterhalb einer Grenzfläche liegen, wird man in vielen Anwendungen konfrontiert, z.B. bei Baugrunduntersuchungen. In kaum einer dieser Anwendungen steht man allerdings vor derart enormen Schwierigkeiten wie bei der Minensuche, was sich anhand eines einfachen Gedankenbeispiels veranschaulichen lässt: Platziert man 100 scharfe Plastikminen auf einer Fläche von der Größe eines Fußballplatzes, so werden erfahrene Experten diese innerhalb weniger Stunden geräumt haben. Sind die gleichen Minen jedoch nur einen Zentimeter tief vergraben, steht man vor einem Problem für das auch nach 50 Jahren intensiver Bemühungen noch keine zufriedenstellende technische Lösung existiert.

1.1 Das Problem der Landminen

In vielen Regionen der Erde, in denen bewaffnete Konflikte stattgefunden haben, stellen Minen vor allem für die Zivilbevölkerung eine tödliche Hinterlassenschaft mit verheerenden Folgen dar. Nach Schätzungen der UN existieren weltweit etwa 60 - 70 Millionen Minen in über 70 Ländern [Hid98]. Jeden Monat werden 2000 Menschen durch Minen getötet oder verstümmelt, die meisten davon Frauen und Kinder. Anti-Personenminen (APMs) kosten zwischen \$ 3 und \$ 30, die Kosten für ihre Beseitigung liegen zwischen \$ 300 und \$ 1000 pro Stück. Die Räumung von Minen ist extrem gefährlich, derzeit liegt die Rate bei einem Unfall pro 1000 - 2000 geräumter Minen. Mitunter bleiben Minen bis zu 50 Jahren nach dem Zeitpunkt ihrer Verlegung aktiv. Die enormen Kosten für medizinische Versorgung und Betreuung - eine Beinprothese kostet ungefähr \$ 125, Kinder brauchen etwa alle 6 Monate eine neue - übersteigen die finanziellen Möglichkeiten der Betroffenen [Min00]. Zudem stellen Minen oft ein Haupthindernis bei der Versorgung von Flüchtlingen, beim Wiederaufbau der Infrastruktur und der Wirtschaft eines Landes dar und führen zur Verarmung bzw. zur Unbewohnbarkeit ganzer Landstriche.

1.2 Stand der Technik

Im Gegensatz zur Minenräumung (engl. *demining*) für militärische Zwecke, wo in der Regel nur eine Bresche in ein Minenfeld geschlagen werden soll und geringere Detektionswahrscheinlichkeiten in Kauf genommen werden, ist bei humanitären Aufgaben die Räumung von Flächen und ihre Rückgabe an die Zivilbevölkerung oberstes Ziel.

Die bei der Minendetektion eingesetzte Technologie beschränkt sich heute in erster Linie auf Stocherstäbe (engl. *prodder*) sowie Metalldetektoren und Spürhunde, die darauf dressiert sind, Sprengstoffe zu riechen. Bei der Anwendung von Stocherstäben liegt ein *Deminer* auf dem Bauch oder kniet und stochert mit einem Metallstab oder einem Bajonett unter einem Winkel von etwa 30° Zentimeter für Zentimeter im Boden (s. Bild 1.1). Ein erfahrener Deminer schafft etwa 50 m² pro Tag. Programme zur Räumung von Minen beschreiben den erzielten Fortschritt üblicherweise in geräumten Quadratkilometern pro Jahr. In Afghanistan werden jedes Jahr etwa 25 km² Land von bis zu 20.000 Minen und anderen nicht explodierten Sprengkörpern (engl. *Unexploded Ordnance* - UXO) geräumt. Bei schätzungsweise 10 Millionen noch vorhandener Minen kann man folgern, dass die Räumung unter Beibehaltung des gegenwärtigen Räumfortschritts noch etwa 500 Jahre in Anspruch nehmen würde.



Bild 1.1 Nach wie vor werden bei der Minensuche neben Metalldetektoren vor allem Stocherstäbe eingesetzt, eine extrem gefährliche und zeitraubende Technik.

Die Detektion vergrabener Minen wird durch die Vielfalt ihrer Größe, Form und Zusammensetzung erschwert. Hinzu kommt die Vielfalt der Bodenverhältnisse und der klimatischen Bedingungen unter denen Minen angetroffen werden können. Aufgrund der zunehmenden Verbreitung von Plastikminen, mit teilweise extrem geringem Metallgehalt,

ist der Einsatz von Metalldetektoren oft problematisch. Hohe Detektionswahrscheinlichkeiten sind meist verbunden mit einer enormen Anzahl von Falschalarmen, verursacht durch Patronenhülsen, metallische Splitter, Schrott, etc. In Afghanistan liegt diese Rate mitunter bei 1000:1. Der Räumfortschritt ist daher oft sehr langsam, arbeitsintensiv und mit hohen Kosten verbunden. Dazu kommt, dass Metalldetektoren nur begrenzte Möglichkeiten bieten, gefährliche Gegenstände im Boden von ungefährlichen zu unterscheiden.

In den letzten Jahren wurden daher vermehrt Anstrengungen zur Überwindung der technischen Unzulänglichkeiten unternommen, mit dem Ziel Technologien zu entwickeln, die zum einen die Detektionsrate erhöhen, zum anderen die Falschalarmrate drastisch senken. Eine in Zusammenarbeit mit einer Minenräumorganisation durchgeführte Studie ergab, dass erst bei einem Falschalarm pro 10 m^2 geräumter Fläche die Schwelle zur Wirtschaftlichkeit erreicht wird [Dre99]. Die Anforderungen der US-Armee liegen noch deutlich darunter, nämlich bei $0.05/\text{m}^2$ [And99]. Einen ausführlichen Überblick über untersuchte Sensortechnologien und deren Potenzial für die Minendetektion findet man unter [Gro96, Sen94, Alt00]. Unter den alternativen Sensoren werden vor allem Bodenradare als besonders erfolgversprechend angesehen. Die Eigenschaft dieses Sensors, dielektrische Diskontinuitäten im Boden zu detektieren, stellt den Ausgangspunkt zur Detektion und Klassifikation vergrabener Objekte dar. Eine ausführliche Übersicht zum (amerikanischen) Stand der Technik, den Einsatz von Georadaren bei der Minen- und UXO-Detektion betreffend, wird in [And99] gegeben.

Bisher publizierte Arbeiten zur Minensuche mit Georadaren beschränken sich meist auf die Untersuchung von Detektionsverfahren, basierend auf der Durchführung von Hypothesentests. Einen Schwerpunkt dieser Arbeiten bildet in der Regel die Untersuchung von Verfahren zur Kompensation des Oberflächenechos, um dann die rückgestreuten Signale den Kategorien Mine oder Hintergrund zuordnen zu können. Oft beruhen die Resultate auf der Verarbeitung von Messungen die unter idealen Bedingungen aufgezeichnet wurden, z.B. in Sandboxen oder auf Messungen, die zumindest hinsichtlich der Boden- und Objekteigenschaften stark eingeschränkt sind. Die Ergebnisse sind daher eher von phänomenologischer Natur und meist nicht auf reale Bodenverhältnisse übertragbar, hinsichtlich Oberflächenbeschaffenheit, Grad der Bodeninhomogenität und Bodenfeuchte.

Für ein Detektionssystem, welches realen Anforderungen genügen soll, ist zudem die Kategorisierung in potentielle Minen und Hintergrund nicht ausreichend, da auch eventuell im Boden vorhandene ungefährliche Objekte eingeordnet werden müssen, sofern sie einen Alarm verursachen. Für das Ziel der Reduktion der Falschalarmrate ist

diese Anforderung zwingend. Mit einem reinen Detektionsansatz ist dies aber nicht zu leisten. Ein durchgängiges Konzept der Signalanalyse, von der Vorverarbeitung über die Detektion bis hin zur Erkennung wurde bisher kaum untersucht.

1.3 Zielsetzung und Gliederung der Arbeit

Die Beantwortung der Frage, ob sich im Boden vergrabene Minen anhand rückgestreuter charakteristischer Radarsignale von ebenfalls vorhandenen, aber ungefährlichen Objekten unterscheiden lassen, steht im Mittelpunkt dieser Arbeit. Es wird ein Lösungsweg vorgestellt, der Verfahren der Bildverarbeitung zur Objektdetektion mit Verfahren der Mustererkennung zur Kategorisierung von Signalen kombiniert. Ausgangspunkt bilden dreidimensionale Datensätze, erhalten durch flächige Abtastung der Bodenoberfläche.

Die physikalischen Grundlagen des Georadarverfahrens und der Ausbreitung elektromagnetischer Wellen in dielektrischen Medien werden in Kapitel 2 vorgestellt. Mithilfe von Simulationen wird die Streuung elektromagnetischer Wellen an Kugeln mit konzentrischem Aufbau untersucht, insbesondere im Hinblick auf objekttypische Streusignale, den Einfluss der Bodendämpfung sowie Kontraste der dielektrischen Materialeigenschaften. Diese Untersuchung schließt auch eine Diskussion der dielektrischen Eigenschaften von Sprengstoffen mit ein.

Die Detektionsleistung eines GPR-Systems ist nicht durch das Empfängerrauschen begrenzt, sondern durch Bodenclutter, verursacht durch Bodeninhomogenitäten. Anhand eines fraktalen Modells wird ein neuer Ansatz zur Simulation von Bodenclutter entwickelt, der ebenfalls in Kapitel 2 erläutert wird.

Die Leistungsfähigkeit von Algorithmen zur Detektion potentieller Objekte definiert sich nicht nur durch die Erkennungs- und Falschalarmrate, auch die Robustheit und der Rechenaufwand sind hinsichtlich einer praktischen Umsetzung von großer Bedeutung. Um diesem Anspruch zu genügen, muss die Anzahl der zu variierenden Eingangsgrößen eines Algorithmus möglichst begrenzt sein. Ein neuartiger Ansatz zur Reduktion dreidimensionaler GPR-Datensätze auf einige wenige horizontale Schnittbilder wird in Kapitel 3 vorgestellt.

In den Horizontalschnitten lassen sich mit Verfahren der Bildverarbeitung potenzielle Alarme lokalisieren, die möglicherweise auf ein vergrabenes Objekt zurückzuführen sind. Die Detektion wird als Vorstufe zur Klassifikation aufgefasst, d.h. die so bestimmten

Bildausschnitte fungieren als „*regions of interest*“ für die nachfolgende Merkmalsextraktion und Klassifikation.

Bisher sind keine Untersuchungen bekannt, die für umfangreiche Messdaten den Schritt von der Objektdetektion hin zur automatisierten Objektklassifikation vollziehen, d.h. der Einordnung einer Messung in die möglichen Klassen Mine, ungefährliches Objekt und Hintergrund (Clutter). Die dieser Vorgehensweise zugrunde liegende Annahme ist die, dass für Signale unterschiedlicher Kategorien objektspezifische, charakteristische Signaturen gefunden werden können. Zu betonen ist, dass mit einem Detektionsverfahren allein ein hypothetisches Objekt lediglich lokalisiert werden kann, die Frage um *was* es sich dabei handelt, kann nur mit Verfahren der Klassifikation beantwortet werden.

In Kapitel 4 wird erläutert wie sich, als Merkmale bezeichnete charakteristische Größen, auf Grundlage von Verfahren der Zeit-Frequenz-Analyse, aus eindimensionalen Signalen extrahieren lassen. Anhand einer vergleichenden Untersuchung verschiedener Analysemethoden wird die für die bearbeitete Problemstellung der Klassifikation von Radarsignalen am besten geeignete Transformation ermittelt. Detaillierte Arbeiten zu diesem Thema sind im Zusammenhang mit der Minendetektion bisher nicht bekannt.

Ein vielversprechendes Analyseverfahren ist die Ende der 80er Jahre eingeführte Wavelet-Transformation, die seither eine sprunghaft ansteigende Verbreitung gefunden hat [Dau88, Mal89]. Sogenannte *Wavelets* wurden bisher nicht nur in der Sprachverarbeitung, z.B. [Kad92], der Bildkompression, z.B. [Ant92] oder der Fusion von Bildfolgen [Roc99], sondern auch in der Klassifikation verwendet, siehe z.B. die Arbeiten von Englehart zur Klassifikation myoelektrischer Signale [Eng98]. Dabei wird die Eigenschaft der Mehrfachauflösung benutzt, die es gestattet, charakteristische Eigenschaften eines Signals in mehreren Auflösungsstufen zu bestimmen.

Die im Rahmen dieser Arbeit zur Verfügung stehenden Daten, die in Kapitel 5 kurz dokumentiert werden, entstanden durch umfangreiche Messreihen an Minen und anderen Objekten in unterschiedlichen Böden.

Zur Lösung der Klassifikationsaufgabe gibt es zum einen den Ansatz der Modellierung, zum anderen einen statistischen Ansatz. Der erste Ansatz verwendet Kenngrößen (Merkmale), die aus einem Modell abgeleitet werden können, birgt aber die prinzipielle Schwierigkeit, dass sich ein vollständiges physikalisches System, bestehend aus Sensor, Boden und den darin vergrabenen Objekten, aufgrund der großen Komplexität nicht-idealisierte Verhältnisse der Modellierung meist entzieht.

Der zweite Ansatz basiert auf der Mustererkennung, dem *Lernen aus Beispielen*. Anhand einer möglichst repräsentativen Lernstichprobe wird ein Klassifikationsalgorithmus so adaptiert, dass er die ihm – nach der Trainingsphase – präsentierten Testbeispiele möglichst der richtigen Klasse zuweist. Im konkreten Fall heißt das: Der Rechner lernt mit Minen assoziierte Radarsignale von denen der anderen beiden Klassen (andere Objekte, Hintergrund) zu trennen.

Aufgrund der Einschränkungen des ersten Ansatzes wird in dieser Arbeit der zweite Weg beschritten. Ausgehend von dem durch die Detektionsstufe gelieferten Ergebnis, besteht die schwierigste der zu lösenden Aufgaben in der Identifikation möglichst aussagekräftiger Merkmale hoher Trennschärfe, zur Beschreibung charakteristischer Unterschiede der zu verschiedenen Klassen gehörenden Radarsignale.

Damit gliedert sich die Aufgabe in vier Teile:

- Modellierung von Kugelstreuern in realen Böden: Untersuchung der Frequenzabhängigkeit dielektrischer Materialgrößen anhand von Messungen, die im für GPR relevanten Frequenzbereich von 0.5 – 4 GHz an Bodenproben durchgeführt wurden (Kapitel 2).
- Untersuchung eines neuen Ansatzes zur Detektion von Objekten aus dreidimensionalen Datensätzen, die durch Aufzeichnung von Radarsignalen auf einem horizontalen zweidimensionalen Abtastraster erhalten wurden (Kapitel 3).
- Untersuchung von Verfahren der Zeit-Frequenz-Analyse zur Extraktion von Merkmalen, welche die Eingangsgrößen für den zu adaptierenden Klassifikationsalgorithmus bilden (Kapitel 4).
- Verifikation des Ansatzes zur Objektdetektion anhand von Felddaten. Verifikation des Mustererkennungsansatzes anhand simulierter Daten, für in Luft vermessene Kugelobjekte und primär für Messungen an tatsächlichen Minen und anderen vergrabenen Objekten (Kapitel 6).

2. Grundlagen des Georadarverfahrens

Der Begriff des Georadars, im Englischen als *Ground Probing oder Ground Penetrating Radar* (GPR) bezeichnet, steht für einen weiten Bereich elektromagnetischer Techniken mit deren Hilfe sich Objekte oder Schichtverläufe im Boden lokalisieren lassen. Seit den 70er Jahren haben sich Georadare zu einem wichtigen Hilfsmittel für die archäologische Prospektion und die Ingenieurgeophysik entwickelt, beispielhaft erwähnt seien hier nur [Dol74, Mor74] und [Ann77]. Immer häufiger werden Georadare für Baugrunduntersuchungen, zur Ortung von Kabeln und Leitungen im Untergrund sowie zur Detektion von Leckagen an Kanälen eingesetzt. Weitere Anwendungen sind luft- oder satellitengestützte Untersuchungen der Erdoberfläche sowie Messungen mit fahrzeuggestützten Systemen, bspw. für die Vermessung von Straßenbelägen. Ein neues Einsatzgebiet ist die Detektion von Blindgängern (engl. *Unexploded Ordnance – UXO*), als Beispiel hierfür seien nur [Che97a] und [Hal98] genannt. GPR-Systeme zur Detektion von Antipersonenminen (APMs) befinden sich gegenwärtig noch im Entwicklungsstadium.

Zur Beurteilung der Eignung eines Georadarsensors für die Detektion im Boden vergrabener Objekte sind vor allem die folgenden Punkte von Bedeutung [Dan88]:

- Einkopplung des Sendesignals in den Boden;
- der Einfluss des Bodens, bedingt durch Streuung an Inhomogenitäten deren charakteristische Größe im Bereich der Wellenlänge liegt;
- hohe Dynamik, um ein möglichst hohes Signal-Rausch- bzw. Signal-Clutterverhältnis zu erzielen;
- Eindringtiefe, bestimmt durch die Bodendämpfung sowie
- die horizontale und vertikale Auflösung und
- die Stärke der an einem vergrabenen Objekt rückgestreuten Signale.

Die oben angeführten Punkte werden in Abschnitt 2.1 behandelt. Die Grundlagen der Ausbreitung elektromagnetischer Wellen in dielektrischen Medien werden in Abschnitt 2.2 zusammengefasst. Im gleichen Abschnitt findet sich auch eine auf der Vermessung von Proben basierende Beschreibung der frequenzabhängigen dielektrischen Eigenschaften von Böden und Sprengstoffen, die zur Modellierung der Wellenausbreitung in verlustbehafteten Böden dienen. Am Beispiel vergrabener Kugeln wird in Abschnitt 2.3 die Abhängigkeit rückgestreuter Signale von den Materialparametern und dem strukturellen Aufbau eines Objekts untersucht.

2.1 Georadar-Systeme

2.1.1 Impulsradare

Signale deren momentane relative Bandbreite ρ größer als 0.25 ist, werden auch als *Ultra-Wideband* bezeichnet [Tay95]. Die relative Bandbreite ist definiert durch

$$= 2 \frac{f_H - f_L}{f_H + f_L}, \quad (2.1)$$

mit f_H und f_L als oberer bzw. unterer Grenzfrequenz der Bandbreite. Eine Möglichkeit zur technischen Realisierung einer großen Bandbreite ist die untere Grenzfrequenz gegen Null streben zu lassen. Die resultierende Art von Puls wird als Basisbandpuls bezeichnet, Systeme die solche Pulse verwenden, als *Impulsradare*. Um eine große Bandbreite zu erhalten, müssen die Pulse extrem kurz sein, typischerweise im Bereich von Nanosekunden oder darunter. Die Mehrheit der kommerziell verfügbaren Georadarsysteme sind Impulsradare, für die Minendetektion liegt der Frequenzbereich typischerweise im Bereich von 0.5 – 4 GHz. Die Wahl dieses Frequenzbereichs ist ein Kompromiss zwischen der gewünschten Auflösung, der zu erzielenden Eindringtiefe und des frequenzabhängigen Effekts von Bodeninhomogenitäten, dem sogenannten Bodenclutter. Hierauf wird im Folgenden noch genauer eingegangen.

2.1.2 Stepped- und Swept-Frequency-Radare

Anstatt eine große Bandbreite mit einem einzigen Puls zu erzeugen, haben frequenzmodulierte (FM) Systeme eine geringe momentane Bandbreite und erreichen die Breitbandigkeit durch Änderung der Mittenfrequenz. *Stepped-Frequency-Radare* strahlen für ein gewisses Zeitintervall eine kontinuierliche Welle (CW¹) mit einer bestimmten Frequenz ab, die schrittweise verändert wird, um den gewünschten Frequenzbereich abzudecken. Die Amplituden und Phasen des empfangenen Signals können als Abtastwerte der Fourier-Transformation angesehen werden. Bei gleichabständiger Abtastung erhält man das Zeitsignal mithilfe einer inversen schnellen Fourier-Transformation (FFT).

Swept-Frequency-Radare senden frequenzmodulierte kontinuierliche Wellen (FMCW), oft mit einer linearen Frequenzmodulation. Das empfangene Signal wird mit dem gleichen Frequenzgesetz demoduliert. Unter den kommerziell erhältlichen Georadaren sind FMCW-Systeme weniger gebräuchlich.

¹ Von engl. *Continuous Wave*.

2.1.3 Antennen

Fast alle in GPR-Systemen eingesetzten Antennen sind breitbandig. Auch wenn die momentane Bandbreite bei FM-Systemen schmal ist, muss die Antenne doch in der Lage sein breitbandig abzustrahlen. Da die Diskussion der verschiedenen Antennentypen und ihrer Charakteristika über den Rahmen dieser Arbeit hinausgehen würde, sei nur der Vollständigkeit halber erwähnt, dass bei den am meisten verbreiteten GPR-Systemen Dipol- oder Hornantennen verwendet werden. Eine detaillierte Diskussion dieser Thematik findet sich in [Dan96].

In der Regel werden GPR-Systeme mit getrennten Sende- und Empfangsantennen konzipiert, die unmittelbar nebeneinander angebracht sind. Bistatische Messungen mit variablem Antennenabstand sind somit im Prinzip möglich, in der Praxis wird davon allerdings wenig Gebrauch gemacht.

2.1.4 Eindringtiefe

Die Eindringtiefe definiert die Tiefe in der die Feldstärke des einfallenden Pulses auf $1/e$ abgeklungen ist. Die wesentlichen Verlustfaktoren sind [Dan96]:

- Einkopplungsverluste beim Übergang Luft-Boden;
- Bodendämpfung;
- Geometrischer Ausbreitungsverlust;
- Re-Transmissionsverluste beim Übergang Boden-Luft.

Neben dem Oberflächenecho ist die Bodendämpfung der bedeutendste Verlustfaktor. Der geometrische Ausbreitungsverlust spielt eine eher untergeordnete Rolle, da bei der Ortung flachliegender Objekte im Boden die Fernfeldbedingung und damit die Abhängigkeit der Leistung des Empfangssignals vom inversen Abstand (zur vierten Potenz) eigentlich nicht gegeben ist. Aus der Summe aller Einflussgrößen lassen sich Anforderungen für die Dynamik eines GPR-Systems ableiten, die im Bereich >70 dB liegen sollte. In Tabelle 2.1 sind typische Dämpfungsverluste verschiedener Böden aufgeführt, die aufgrund unterschiedlicher Leitfähigkeiten eine große Streubreite aufzeigen.

Eine ausführliche Diskussion zum Einfluss der Bodenparameter auf die Wellenausbreitung findet sich in Abschnitt 2.2, wo auch quantitative Angaben anhand von Modellrechnungen gemacht werden, ausgehend von den durch Bodenuntersuchungen erhaltenen Messdaten.

Material	Verlust bei 100 MHz	Verlust bei 1 GHz
Ton (feucht)	5 - 300 dB/m	50 - 3000 dB/m
Lehm (feucht)	1 - 60 dB/m	10 - 600 dB/m
Sand (trocken)	0.01 - 2 dB/m	0.1 - 20 dB/m
Eis	0.1 - 5 dB/m	1 - 50 dB/m
Beton	0.5 - 2.5 dB/m	5 - 25 dB/m

Tabelle 2.1 Dämpfungsverluste bei 100 MHz und 1 GHz (aus [Dan96]).

2.1.5 Auflösungsvermögen

Ausschlaggebend für die vertikale Auflösung ist die effektive Bandbreite des empfangenen Signals, die sich folgendermaßen festlegen lässt: Sei $F(\)$ das Leistungsspektrum des Empfangssignals und $f(t)$ die zugehörige Autokorrelierte, dann kann die Auflösungsgrenze anhand deren Form festgelegt werden. Mit Δt als dem Abstand der beiden 3 dB-Punkte kann eine effektive Bandbreite definiert werden als

$$B_{eff} = 1/\Delta t . \quad (2.2)$$

Die Dämpfung der elektromagnetischen Wellen im Boden stellt den limitierenden Faktor für die vertikale Auflösung dar, da der Boden als Tiefpassfilter wirkt. Bei bekannter Ausbreitungsgeschwindigkeit v kann die zeitliche Auflösung in eine Tiefenauflösung umgerechnet werden

$$\Delta r = \frac{v}{2B_{eff}} . \quad (2.3)$$

Da feuchte Böden eine höhere Dielektrizitätszahl und daher eine geringere Ausbreitungsgeschwindigkeit aufweisen als trockene, sinkt die geforderte effektive Bandbreite um eine gegebene Auflösung zu erzielen. Dem wirkt die bei feuchten Böden erhöhte Dämpfung entgegen, die wiederum zu einer niedrigeren effektiven Bandbreite führt. Daraus lässt sich folgern, dass innerhalb bestimmter Frequenzbereiche die Auflösung nahezu unabhängig vom Dämpfungsverlust ist [Dan88].

Die horizontale Auflösung ist durch die Abstrahlcharakteristik der Antenne bestimmt, und kann durch Verwendung von Verfahren der Signalverarbeitung, ähnlich den synthetischen Aperturverfahren (SAR), verbessert werden (vgl. Abschnitt 2.1.8).

2.1.6 Signalmodell

Zur Aufnahme von Daten wird die Antenneneinheit mit möglichst konstanter Geschwindigkeit entlang der Bodenoberfläche geführt (vgl. Bild 2.1). Die Größe der von einem Punkstreuer zu beobachtenden Diffraktionshyperbel ist bestimmt durch die Antennenapertur und die lokale Bodendämpfung. Datenbeispiele finden sich in Abschnitt 2.1.7.

Das Empfangssignal setzt sich üblicherweise aus vier Anteilen zusammen:

- dem direkten Übersprechen zwischen Sende- und Empfangsantenne;
- dem Bodenecho, zusammengesetzt aus der Reflexion an der Oberfläche und der von den Bodeneigenschaften abhängigen Volumenstreuung;
- der Streuantwort eines eventuell vorhandenen Objektes und
- dem Messrauschen.




Bild 2.1 Messprinzip des Georadarsensors: Der Sensor, dargestellt als Sende- und Empfangseinheit, wird entlang der Oberfläche bewegt. Die Empfangssignale werden als Funktion des Ortes dargestellt. Theoretisch zeichnet sich die Streuantwort eines Punktreuers als Diffraktionshyperbel ab.

Clutter

Die Überlagerung der ersten beiden Anteile wird gewöhnlich als *Clutter* bezeichnet. Das direkte Überkoppeln von der Sende- auf die Empfangsantenne sowie reverberierende Ströme auf der Antenne sind insbesondere bei der Untersuchung oberflächennaher Bodenstrukturen problematisch. In diesem Fall wird die Streuantwort eines kleinen Objekts, in der Regel mit ohnehin schwacher Amplitude, vom Übersprechen und der

Reflexion an der Bodenoberfläche überlagert. Die spektrale Charakteristik ist zudem der des Nutzsignals sehr ähnlich. Möglichkeiten zur Unterdrückung dieser unerwünschten Signalanteile werden in Abschnitt 2.1.8 diskutiert.

Oft ist nicht das Fehlen eines ausreichend starken Signals vergrabener Minen oder UXOs das eigentliche Problem, sondern die Vielfalt des von der Oberfläche und dem Boden verursachten Clutters [Cari99]. Hinzu kommt der Einfluss der Systemparameter wie Orientierung der Antennen, Größe des Antennen-Footprints, Auflösung sowie das gewählte Frequenzband.

Bei breitbandigen Antennen ist eine gute Anpassung des Feed-Pulses keine leichte Aufgabe. Da konventionelle GPR-Antennen möglichst dicht an der Bodenoberfläche geführt werden müssen (im Falle der hier behandelten Problemstellung ohne diese zu berühren!), ändert sich die Antennencharakteristik, wenn die Bodeneigenschaften sich ändern. Ansätze zur Anpassung der Antennencharakteristik an den Boden mit dielektrischen Füllmaterialien werden in [Che00] vorgestellt. Ein Antennendesign, welches diesen Anforderungen möglichst gut entspricht, stellt eine große Erleichterung für die Signalverarbeitung dar und kann damit erheblich zur Steigerung der Detektionsleistung beitragen.

Ein neues Modell zur Simulation und quantitativen Beschreibung von Clutter wird in Abschnitt 2.2.4 vorgestellt.

2.1.7 Datenbeispiel

Bild 2.2 veranschaulicht die von einem Georadar gelieferten Messdaten. Bei der Datenakquisition wurde eine Antenne in äquidistanten Schritten von 2 cm längs eines geraden Messprofils in der Horizontalen verschoben (s. Bild 2.1). Die fortlaufend aufgezeichneten Signale lassen sich in Form eines Radargramms bildhaft darstellen. Der Nomenklatur von Daniels folgend [Dan96] werden in dieser Arbeit einzelne Radarsignale als *A-Scans* bezeichnet. Sie stellen die Bodenantwort an einem einzelnen Messpunkt dar (oberes Teilbild). Der Anteil des Zeitsignals bis etwa 1.5 ns stellt die Überlagerung des Oberflächenechos und des direkten Übersprechens zwischen Sende- und Empfangsantenne dar.

Ein entlang eines geradlinigen Profils aufgezeichnetes Radargramm wird als *B-Scan* bezeichnet und stellt einen vertikalen Schnitt durch den Untergrund dar (s. Bild 2.2, mittleres Teilbild). Durch die Aneinanderreihung gleichartiger Messungen ergibt sich die für GPR-Daten typische horizontale Balkenstruktur. Aufgrund einer leichten Neigung der

abgetasteten Bodenoberfläche nehmen die Einsatzzeiten entlang des Profils von links nach rechts ab. Der senkrechte weiße Strich markiert die Position des oben dargestellten Zeitsignals.




Bild 2.2 Beispiel einer typischen GPR-Messung: (oben) Bodenantwort an einem einzelnen Messpunkt; (Mitte): Vertikalschnitt durch den Boden, die weiße Linie bezeichnet die Position des abgebildeten Zeitsignals; (unten) durch Messung auf parallelen Profilen erhaltener Horizontalschnitt. Die weiße Linie markiert die Position des Vertikalschnitts (Mitte). In diesem Fall waren fünf metallhaltige Minen und eine Plastikmine vergraben, letztere ist hier nicht zu sehen (Position oben links im C-Scan).

Für den Fall paralleler Messprofile lassen sich auch Horizontalschnitte erzeugen, die als *C-Scan* bezeichnet werden (unteres Teilbild). Die Position des im mittleren Teilbild abgebildeten Vertikalschnitts ist ebenfalls durch eine weiße Linie markiert. In der Praxis ergeben sich solche 3D-Datensätze bspw. bei Verwendung eines quer zur Bewegungsrichtung angeordneten Antennenarrays.

Im gezeigten Beispiel waren sechs Minen vergraben, fünf metallhaltige und eine Plastikmine, die im dargestellten C-Scan nicht zu sehen ist. Die graukodierten Amplituden zeigen die in dieser Tiefe unterschiedliche Polarität der Streusignale. Die 1.5 x 1 m große Fläche wurde mit einem Raster von 2 x 2 cm gescannt. Der Vertikalschnitt zeigt recht deutlich die Streuung der drei Minen.

Die in der horizontalen Darstellung sichtbaren kreisförmigen Strukturen legen eine Verwendung dieser geometrischen Eigenschaften der gesuchten Objekte nahe. Darauf aufbauende Detektionsverfahren werden in Kapitel 3 vorgestellt.

2.1.8 Signalverarbeitung

In diesem Abschnitt werden kurz die in der Signalverarbeitung von GPR-Daten gängigen Verfahren skizziert.

Kompensation des Oberflächenechos

Statistischen Erhebungen zufolge liegen über 90 % der weltweit vergrabenen Antipersonenminen in einer Tiefe von weniger als 20 cm. Bei der Ortung dieser Objekte stellt daher das Oberflächenecho ein Hauptproblem dar, da es in der Regel aufgrund des hohen dielektrischen Kontrasts des Luft-Bodenübergangs den stärksten Signalanteil aufweist und daher die Streuantworten flachliegender Objekte maskiert.

In der Literatur existieren verschiedene Ansätze zur Unterdrückung dieses Signalanteils. Die einfachste und am wenigsten rechenaufwendige Methode der B-Scan-Prozessierung funktioniert wie folgt: Die innerhalb eines in horizontaler Richtung verschobenen Fensters der Breite N liegenden A-Scans werden gemittelt und vom aktuellen Scan $x_i(t)$ in der Mittenposition des Fensters subtrahiert:

$$\hat{x}_i(t) = x_i(t) - \frac{1}{N} \sum_{j=i-N/2}^{i+N/2} w_j x_j(t). \quad (2.4)$$

Die Koeffizienten w_j beschreiben eine Fensterfunktion, z.B. ein Hanning-Fenster, welches eine individuelle Wichtung der subtrahierten Scans gestattet. Bei einer Hintergrundkompensation mittels einer reinen Mittelwertbildung gilt $w_j \equiv 1$.

Die kompensierten Daten \hat{x}_i werden folglich über eine Hochpassfilterung in horizontaler Richtung erhalten, d.h. sich in horizontaler Richtung nur geringfügig ändernde Signalanteile werden unterdrückt. Die laterale Ausdehnung des Fensters sollte dabei deutlich größer dimensioniert sein als die typische Abmessung des gesuchten Objekts. Am Rand liegende Scans werden entweder von der Verarbeitung ausgenommen oder nach außen gespiegelt.

Dieser Ansatz funktioniert allerdings nur solange wie sich die Topographie der Oberfläche über die Länge der Ausdehnung des Schleppfensters nicht merklich ändert, ansonsten treffen die Oberflächenechos zu unterschiedlichen Zeiten am Empfänger ein, so dass kein sinnvolles Mittelwertsignal mehr gebildet werden kann. Außerdem darf die Magnitude der Oberflächenreflexion keine großen Variationen aufweisen. Anwendungsbeispiele für den Fall einer ebenen und einer welligen Oberfläche sind in Bild 2.3 dargestellt. Nur bei dem im oberen Teilbild dargestellten Fall kann die Reflexion an der Oberfläche gut unterdrückt werden. Zu erkennen sind oben drei, unten zwei von Minen verursachte Diffraktionen.

Ein Überblick über einige Verfahren der Filterung findet sich in [Fri95]. Ein weiterer Ansatz zielt darauf ab, möglichst diejenigen A-Scans, die einen Nutzsignalanteil in Form der Streuantwort eines Objekts haben, nicht zur Mittelung heranzuziehen [Car00]. Allerdings gelten auch hier die gleichen Nachteile bei der Anwendung auf geneigte bzw. unebene Oberflächen oder bei Vorhandensein von Bodenclutter. In einer weiteren Arbeit wird ein Verfahren zur linearen Prädiktion des Oberflächenechos im Spektralbereich vorgestellt [Fel98], die Funktionsweise allerdings nur für horizontale Oberflächen demonstriert.

Brunzell [Bru99] verwendet ein Optimierungsverfahren, um Radarsignale individuell in der Zeitrichtung so zu verschieben, dass die in jedem Scan enthaltenen Oberflächenechos entlang einer horizontalen Linie angeordnet werden. Danach wird die Kompensation durchgeführt und die Verschiebung rückgängig gemacht. Dieses in der seismischen Datenverarbeitung als *Datuming* bekannte Verfahren [Yil87] birgt in der praktischen Anwendung den Nachteil, dass es bei Variationen der Reflexionsamplitude aufgrund von Fluktuationen der Bodeneigenschaften, z.B. der Feuchte, Artefakte in den Daten verursachen kann und strenggenommen nur bei Wellenausbreitung in senkrechter Richtung anwendbar ist.

Ein interessantes Verfahren wird von Gunatilaka vorgeschlagen [Gun00]. In einem B-Scan wird sowohl der Zeitpunkt als auch die Amplitude der Reflexion an der Oberfläche segmentweise mit einem Polynom approximiert. Die Verwendung von autoregressiven

(AR) Modellen zur Beschreibung der Oberflächenreflexion bei der Detektion von Panzerminen (ATMs¹) wird von Yu et al beschrieben [Yu00].




Bild 2.3 Kompensation des Oberflächenechos durch Subtraktion eines gleitenden Mittelwertes (rechts). Die beiden Datensätze unterscheiden sich durch die Beschaffenheit der Oberflächen: oben geneigt aber glatt, unten mit welliger Topographie. Der schwarze Balken kennzeichnet das direkte Übersprechen zwischen Sende- und Empfangsantenne.

Zusammenfassend lässt sich feststellen, dass bei allen Verfahren die Gefahr besteht, Artefakte in den Daten zu generieren, d.h. die Signatur der einzelnen Radarsignale wird unter Umständen stark verändert. Da aber der in dieser Arbeit verfolgte Klassifikationsansatz

¹ Von engl. *Anti Tank Mine*.

von objekttypischen Signaturen ausgeht, wird deshalb auf eine Hintergrundkompensation verzichtet. Das in Kapitel 3 vorgestellte Verfahren zur Objektdetektion mit einem Projektionsverfahren macht die Durchführung einer Hintergrundkompensation in B-Scans vorteilhafterweise überflüssig.

Medianfilterung

Mitunter gibt es kurze „Aussetzer“ im Aufnahmeprozess, die sich dadurch äußern, dass einzelne A-Scans nachhaltig gestört sind. Da sich dies, bspw. bei der Extraktion der Merkmale, negativ auf die weitere Verarbeitung auswirken kann, empfiehlt sich die Anwendung eines Medianfilters in horizontaler Richtung.

Tiefenabhängige Verstärkungsfunktionen

Bei der Ortung von Objekten in größerer Tiefe bildet die Anwendung einer zeitabhängigen exponentiellen Verstärkungsfunktion eine Möglichkeit zur Kompensation des geometrischen Ausbreitungsverlusts und der Bodendämpfung. Aufgrund der flachen Tiefenlage der hier untersuchten Objekte wurde auf eine solche Verstärkung verzichtet.

Abbildungsverfahren

Zur Transformation der im Orts-Zeitbereich vorliegenden Messdaten lassen sich die aus der Seismik oder dem SAR-Prozessing bekannten Fokussierungs- oder Imaging-Verfahren einsetzen, mit denen eine Transformation vom Orts-Zeit-Bereich in den Orts-Tiefen-Bereich möglich ist. Dabei wird die längs den Ästen der Diffraktionshyperbel verstreute Energie kohärent summiert und in den Scheitel der Hyperbel abgebildet. Die bekanntesten Vertreter dieser Klasse von Verfahren sind zum einen die *Kirchhoff*- zum anderen die *Stolt*-Methode. Während bei der ersten eine Summation im Zeitbereich durchgeführt wird, auch bekannt unter dem Schlagwort *Diffraction Stack*, arbeitet die zweite im Frequenz-Wellenzahlraum [Yil87].

Diese Verfahren sind in zahlreichen Veröffentlichungen untersucht, beispielhaft seien hier nur [Joh95] und [Aze96] erwähnt. Sie sind zur Detektion von APMs nur bedingt geeignet. In der Regel lassen sie sich nur unter sehr eingeschränkten Bedingungen, die denen eines Sandkastens recht nahekommen, vorteilhaft einsetzen. Bei realen Bodenverhältnissen ist im Falle von in geringer Tiefe liegenden Minen nur der Scheitelbereich der Diffraktionshyperbel zu sehen, was die Verwendung von Imaging-Verfahren nicht generell als sinnvoll erscheinen lässt. Abgesehen vom je nach gewählten Verfahren verhältnismäßig hohen Rechenaufwand, ist eine möglichst präzise Kenntnis der Ausbreitungsgeschwindigkeit im Boden erforderlich. Nicht berücksichtigte Unebenheiten

der Bodenoberfläche sowie Bodeninhomogenitäten können sich ebenfalls negativ auf die zu erzielende Fokussierung auswirken. Der Grund ist, dass die Phasenbeziehung der kohärent zu summierenden Amplituden allein durch die Geometrie der Datenaufnahme bestimmt ist. Natürliche Zufälligkeiten des Ausbreitungsmediums beeinträchtigen daher die deterministische Phasenbeziehung und führen, je nach Amplitude und Maßstab der Variationen, zu Verzerrungen und Kontrastverlust.

Da auch hier, abgesehen von dem erhöhten Rechenaufwand, die Gefahr besteht Artefakte in den Daten zu verursachen, wird auf die Anwendung von Imaging-Verfahren verzichtet. Bei der Detektion von Panzerminen oder UXOs, die oft in größerer Tiefe liegen, ist deren Einsatz aber durchaus von Vorteil.

2.2 Ausbreitung elektromagnetischer Wellen in dielektrischen Medien

In Abschnitt 2.2.1 wird ein kurzer Abriss der wesentlichen Grundlagen der Ausbreitung ebener Wellen in dielektrischen Medien gegeben. Die Abhängigkeit maßgeblicher Parameter, wie Ausbreitungsgeschwindigkeit oder Dämpfung, von der Frequenz der in den Boden eingestrahlten Signale oder der Bodenfeuchtigkeit wird anhand von Modellrechnungen veranschaulicht. Um der Realität möglichst nahezukommen, kann dazu auf die Ergebnisse umfangreicher Labormessungen an Bodenproben zurückgegriffen werden. Im Rahmen dieser Laboruntersuchungen wurde die komplexe Dielektrizitätsfunktion verschiedener Bodenproben als Funktion der Frequenz und der Bodenfeuchte vermessen. Ferner standen auch an Sprengstoffsurrogaten aufgezeichnete Messdaten zur Verfügung. Diese Daten bilden die Grundlage der in den Abschnitten 2.2.2 und 2.2.3 beschriebenen Modellrechnungen zur Wellenausbreitung in verlustbehafteten Böden und zur transienten Streuung an kugelförmigen Objekten.

2.2.1 Physikalische Grundlagen

Die Ausbreitung elektromagnetischer Wellen im Boden wird durch die Maxwell-Gleichungen beschrieben. Nach Einführung der komplexen Dielektrizitätszahl ϵ^* und der komplexen Permeabilität μ^* lauten diese für quellenfreie Medien

$$\operatorname{rot} \mathbf{E} = -\mu^* \frac{\partial}{\partial t} \mathbf{H} \quad (2.5)$$

$$\operatorname{rot} \mathbf{H} = \epsilon^* \frac{\partial}{\partial t} \mathbf{E}, \quad (2.6)$$

wobei

$$\mu^* = \mu' + j\mu''$$

$$\mu^* = \mu' + j\mu''$$

mit

\mathbf{E} elektrisches Feld

\mathbf{H} magnetisches Feld

ϵ_0 Dielektrizitätszahl im Vakuum

ϵ_r relative Dielektrizitätszahl

μ_0 Permeabilitätskonstante im Vakuum

μ_r relative Permeabilität (= 1 für die meisten geologischen Materialien)

Aus ihnen lassen sich für das elektrische und magnetische Feld die Wellengleichungen aufstellen:

$$\nabla^2 \mathbf{E} = -\mu^* \frac{\partial^2 \mathbf{E}}{\partial t^2}, \quad (2.7)$$

$$\nabla^2 \mathbf{H} = -\mu^* \frac{\partial^2 \mathbf{H}}{\partial t^2}. \quad (2.8)$$

Für die Lichtgeschwindigkeit in Vakuum gilt

$$c = \frac{1}{\sqrt{\mu_0 \epsilon_0}}, \quad (2.9)$$

daraus folgt für die Ausbreitungsgeschwindigkeit in einem Dielektrikum

$$v = \frac{c}{\sqrt{\mu_r \epsilon_r}}. \quad (2.10)$$

Als Lösung der Gleichungen erhält man ebene Wellen. Bei Betrachtung eines \mathbf{E} -Felds in x-Richtung und Ausbreitung entlang der z-Achse gilt

$$E(z) = E_0 e^{-ikz}, \quad (2.11)$$

mit der Wellenzahl

$$k = \frac{\omega}{v} = \frac{2\pi}{\lambda}. \quad (2.12)$$

und der Kreisfrequenz ω . Bei den meisten Böden kann die Permeabilität als eine reelle Größe mit dem Wert $\mu_r = 1$ angesehen werden. Der dimensionslose Faktor

$$\tan \delta = \frac{\sigma}{\omega \epsilon} \quad (2.13)$$

wird als Verlustfaktor bezeichnet. Für geringe Leitfähigkeiten σ gilt

$$\tan \delta \approx \frac{\sigma}{\omega \epsilon}. \quad (2.14)$$

In einem absorbierenden Medium ist die Wellenzahl komplex und gegeben durch

$$k = \sqrt{\mu(\epsilon' + j\epsilon'')}. \quad (2.15)$$

Schreibt man k zerlegt in Real- und Imaginärteil als

$$k = \kappa - j\chi, \quad (2.16)$$

mit χ als Dämpfungsfaktor und κ als Phasenkonstante, folgt daraus

$$\chi = \frac{c}{2} \left[\frac{1}{2} \left(\sqrt{1 + \left(\frac{\epsilon''}{\epsilon'} \right)^2} - 1 \right) \right]^{\frac{1}{2}}, \quad (2.17)$$

$$\kappa = \frac{c}{2} \left[\frac{1}{2} \left(\sqrt{1 + \left(\frac{\epsilon''}{\epsilon'} \right)^2} + 1 \right) \right]^{\frac{1}{2}}. \quad (2.18)$$

Die Phasengeschwindigkeit ist dann gegeben durch

$$v = \frac{c}{\kappa} = c \left[\frac{1}{2} \left(\sqrt{1 + \left(\frac{\epsilon''}{\epsilon'} \right)^2} + 1 \right) \right]^{-\frac{1}{2}}. \quad (2.19)$$

Medien mit frequenzabhängiger Ausbreitungsgeschwindigkeit werden als dispersiv bezeichnet. Die exponentielle Abnahme der Energie einer elektromagnetischen Welle mit zunehmender Eindringtiefe ist bestimmt durch den Faktor $e^{-2\chi z}$. Drückt man die Dämpfung in Dezibel pro Meter aus, ergibt sich $\chi' = 8.6859 \chi$ dB/m.

Die Absorption elektromagnetischer Strahlung wird sowohl durch Ohm'sche als auch durch dielektrische Effekte verursacht. Das elektromagnetische Verhalten natürlicher und technisch hergestellter Materialien ist im Allgemeinen sehr komplex, weil diese sowohl dielektrische als auch leitende Eigenschaften aufweisen können. Ihr elektromagnetisches Verhalten wird durch das Verhalten der Materialkomponenten auf mikroskopischer

Ebene bestimmt. Nach Olhoeft [Olh98] sind die folgenden elektrischen Verlustmechanismen von Bedeutung: i) elektrische Leitfähigkeit, in der Regel verursacht durch Metallgehalt oder Salzwasser; ii) dielektrische Polarisationsrelaxation von Wassermolekülen, ein Effekt der bei Eis bei etwa 10^3 Hz auftritt und in Wasser bei 10^6 bis 10^{10} Hz sowie iii) die Streuung elektromagnetischer Wellen an geologischen Inhomogenitäten, deren charakteristische Größen im Bereich der Wellenlänge liegen. Bei Feinkies (von etwa Erbsengröße) tritt dieser Effekt ab etwa 1 GHz auf. Er kann verglichen werden mit dem unterschiedlichen Streuverhalten von Licht im sichtbaren Bereich: Im Unterschied zu einem Schneeball erscheint ein Eiswürfel aufgrund anderer Kornverteilung transparent.

2.2.2 Modellierung der Wellenausbreitung in verlustbehafteten realen Böden

Die dielektrischen Eigenschaften von Böden sind im Allgemeinen nur experimentell zu bestimmen. Gesteine und Böden sind Materialien mit komplexer Zusammensetzung aus einer Vielfalt von Mineralien in unterschiedlichsten Anteilen. Ihre dielektrischen Eigenschaften können auch innerhalb ähnlicher Böden eine große Variation aufweisen. Die meisten Böden enthalten Feuchtigkeit, oft verbunden mit einem gewissen Salzgehalt. Da die relative Dielektrizitätszahl von Wasser etwa um 81 liegt, reichen schon geringe Mengen Feuchtigkeit aus, um die relative Dielektrizität eines Bodens deutlich zu erhöhen.

Von Hippel [Hip54] führte bereits Untersuchungen zur Abhängigkeit der dielektrischen Bodeneigenschaften von Frequenz und Feuchtigkeitsgehalt durch. Allerdings wurde bei diesen Messungen die Frequenzachse nur in Zehnerpotenzen durchfahren. Daher liegen im hier interessierenden Frequenzbereich nur wenige Messpunkte vor.

Als Grundlagen der in dieser Arbeit durchgeführten Modellrechnungen dienten Bodenuntersuchungen, die 1998 auf dem *Jefferson Proving Ground* durchgeführt wurden, einem militärischen Übungsgelände der US Armee in Indiana [Cur98a]. Die Bodenproben wurden aus den Tiefen 10, 50 und 100 cm entnommen. Jede Probe wurde dreimal vermessen: zunächst mit dem natürlichen Wassergehalt, nach Trocknung an der Luft und dann bei einem Feuchtigkeitsgehalt nahe der Sättigung. Die Daten wurden als Real- und Imaginärteil der komplexen Dielektrizität von 45 MHz bis 5 GHz erhalten. Das Inkrement bei niedrigen Frequenzen betrug 5 MHz und wurde zu hohen Frequenzen hin vergrößert. Mit den in Abschnitt 2.2.1 angegebenen Gleichungen wurden Leitfähigkeit, Dämpfung, Verlustfaktor und die auf die Lichtgeschwindigkeit im Vakuum normierte Ausbreitungsgeschwindigkeit berechnet.

Für die Detektion oberflächennaher Objekte werden, aufgrund des Kompromisses zwischen Auflösung und Eindringtiefe, in der Regel GPR-Systeme mit einem Frequenz-

schwerpunkt von 0.5 – 4 GHz eingesetzt. Daher werden im Folgenden nur die Eigenschaften bei 1 GHz bzw. 2 GHz zur Beurteilung herangezogen. In Bild 2.4 ist der Verlauf des Realteils von ϵ_r , der Leitfähigkeit und der Dämpfung als Funktion der Bodenfeuchte angegeben. Die verschiedenen Symbole bezeichnen die Entnahmetiefe der Proben.

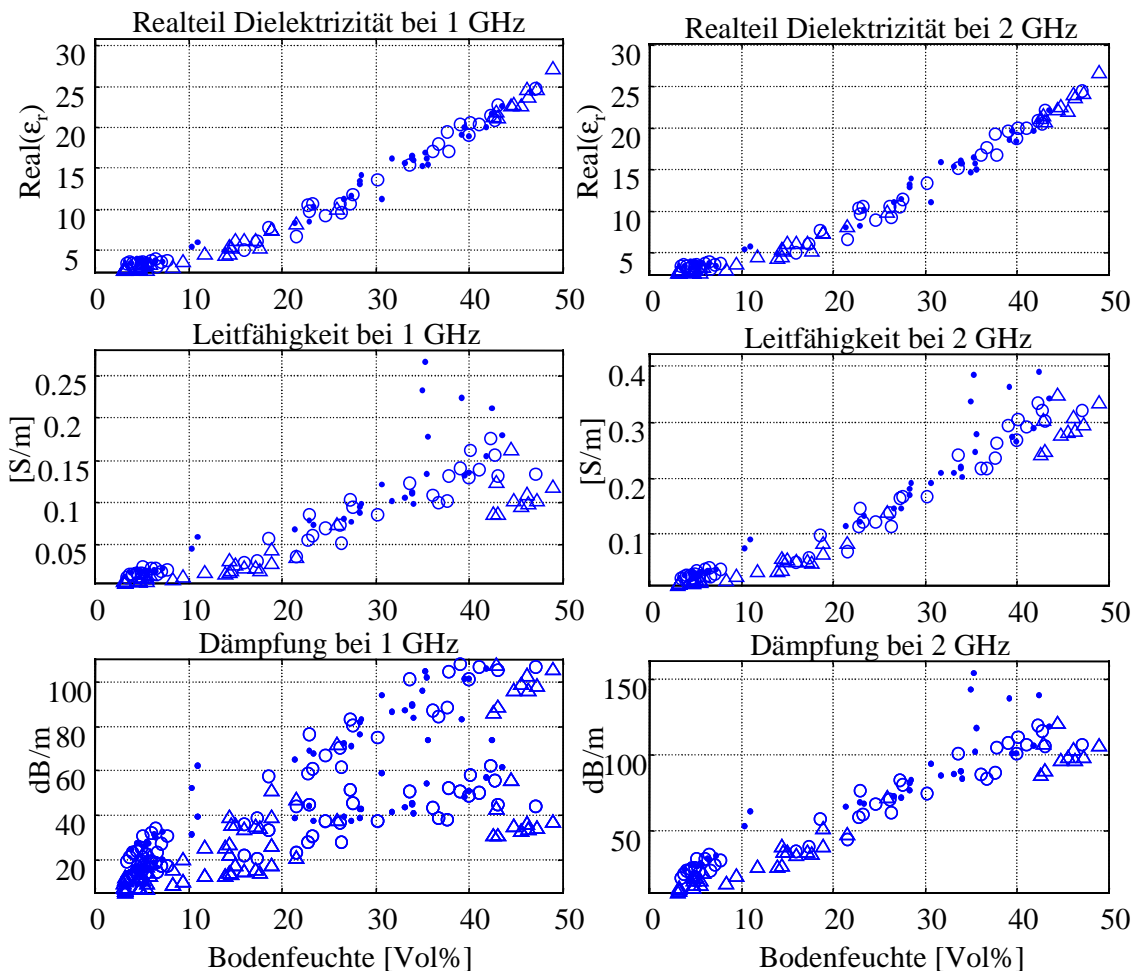


Bild 2.4 Verlauf verschiedener dielektrischer Größen als Funktion der Bodenfeuchte. Unterschiedliche Entnahmetiefen der Bodenproben sind durch verschiedene Symbole gekennzeichnet (10 cm / Dreiecke, 50 cm / Kreise, 100 cm / Punkte).

Aus der zufälligen Anordnung der Symbole lässt sich folgern, dass die Probentiefe offenbar keinen Einfluss auf den Wert der dielektrischen Größen hat und somit nur eine starke Abhängigkeit von der enthaltenen Feuchtigkeit gegeben ist. Der Realteil von ϵ_r zeigt einen nahezu linearen Anstieg bei zunehmender Feuchte. Bei einer Frequenz von 1 GHz weist die Dämpfung eine deutlich höhere Streuung auf, als dies bei 2 GHz der Fall ist. Die Graphen wurden auf Basis aller 117 durchgeführten Messungen erhalten. Curtis [Cur98a] betont, dass die an unterschiedlichen Lokationen des Geländes entnommenen

Proben einen recht ähnlichen Verlauf der dielektrischen Größen aufweisen. Daher werden die Simulationen zur Untersuchung der Streuung an Kugeln (s. Abschnitt 2.3) auf einen repräsentativen Messpunkt beschränkt.

Diskutiert werden die für drei unterschiedliche Feuchten erhaltenen Ergebnisse. Die angegebenen Prozentangaben der Feuchtigkeit beziehen sich immer auf das Probenvolumen, nicht auf das Gewicht der Probe. Im Einzelnen handelt es sich um Volumenanteile von 3 %, 12 % und 49 %.

In den Bildern 2.5 bis 2.7 sind für die drei Feuchtigkeitsanteile die interpolierten Verläufe des Real- und Imaginärteils von ϵ_r aufgetragen, außerdem die daraus berechneten Größen Leitfähigkeit, Verlusttangens, die auf die Lichtgeschwindigkeit im Vakuum normierte Phasengeschwindigkeit sowie die Dämpfung.




Bild 2.5 Dielektrische Eigenschaften eines Bodens bei geringer Bodenfeuchte (3 %). Die direkt aus den Messwerten erhaltenen Größen sind mit Punkten gekennzeichnet, die durchgezogenen Kurven wurden durch Interpolation erhalten.

Die Messwerte, bzw. die direkt aus den Messdaten berechneten Größen, sind als Punkte eingetragen. Zur gleichabständigen Frequenzabtastung wurde der Verlauf des Real- und Imaginärteils von ϵ_r mit einem Polynomansatz interpoliert (durchgezogene Linie). Die

Ausreißer in den Kurven bei 0.85 GHz, 1.7 GHz und höheren Frequenzen beruhen auf Resonanzen im Probenhalter.

Die Kurven veranschaulichen die deutliche Veränderung der dielektrischen Größen bei steigender Bodenfeuchte. Der Realteil der relativen Dielektrizität steigt bei 1 GHz von 2.6 bei 3 % Feuchte über 4.6 bei 12 % bis auf 27 bei 49 %. Die Ausbreitungsgeschwindigkeit nimmt entsprechend ab. Gleichzeitig nimmt die Dämpfung stark zu: bei 2 GHz von 10 dB/m bei trockenem Boden (3 % Feuchte) auf 25 dB/m bei 12 % Feuchte. Zusammen mit Bild 2.7, einem Beispiel extremer Feuchte, verdeutlichen diese drei Fälle die Abhängigkeit der für ein Georadar maßgeblichen Größen vom Feuchtigkeitsgehalt und zeigen somit auch die Grenzen der Einsatzmöglichkeiten des Sensors auf.




Bild 2.6 Dielektrische Eigenschaften eines Bodens bei mittlerer Bodenfeuchte (12 %). Die direkt aus den Messwerten erhaltenen Größen sind mit Punkten gekennzeichnet, die durchgezogenen Kurven wurden durch Interpolation erhalten.

Böden wirken als Tiefpassfilter, d.h. die Mittenfrequenz eines Signals verschiebt sich mit steigender Feuchte zu niedrigen Frequenzen. Dieser Effekt erschwert die Verwendung charakteristischer Signaturen zur Unterscheidung von Objekten, da die Information

bezüglich der „Feinstruktur“ eines Objekts unter Umständen verloren geht. Gleichmaßen macht dieser Effekt eine korrekte Modellierung eines objektspezifischen Streusignals bei Unkenntnis der Bodenparameter sehr schwierig.




Bild 2.7 Dielektrische Eigenschaften eines Bodens bei hoher Feuchte, nahe der Sättigung (49 % Wasseranteil). Die direkt aus den Messwerten erhaltenen Größen sind mit Punkten gekennzeichnet, die durchgezogenen Kurven wurden durch Interpolation erhalten.

Bild 2.8 veranschaulicht den Tiefpasseffekt des Bodens bei einer Transmission eines Pulses über eine Strecke von 30 cm. Die Schwerpunkte der Signalspektren liegen bei 1 bzw. 2 GHz. Die gezeigten Betragsspektren sind auf den Maximalwert des Pulsspektrums für Ausbreitung in Luft bezogen. Die spektralen Maxima verlagern sich bei zunehmendem Feuchtigkeitsgehalt zu niedrigeren Frequenzen hin.

Die spektrale Bandbreite nimmt beim 2 GHz-Puls deutlich stärker ab als beim 1 GHz-Puls. Dies zeigt, dass der Einsatz von GPR-Antennen mit großer Bandbreite, je nach Bodenbedingungen, nicht notwendigerweise zu einer nennenswerten Steigerung der Auflösung führt.

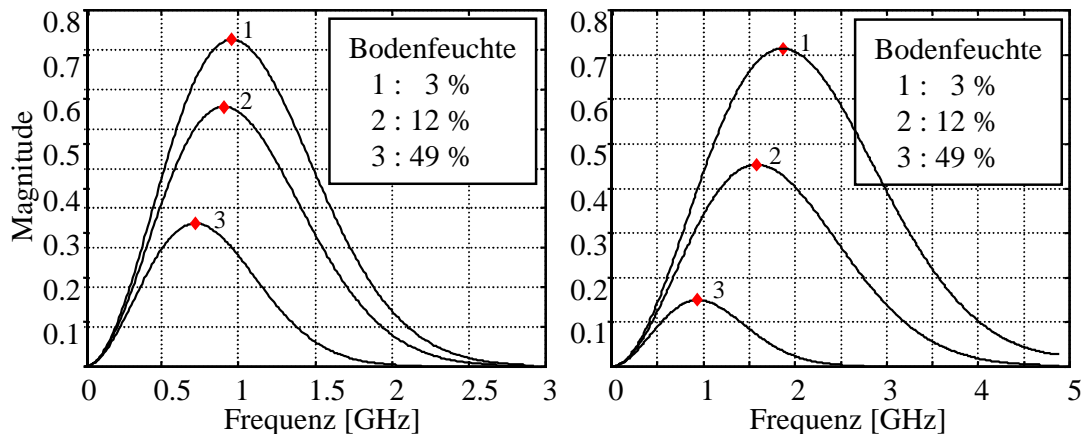


Bild 2.8 Transmission eines Pulses über eine Strecke von 30 cm Boden mit unterschiedlicher Feuchte. Die Maxima der Puls-Betragspektren für Pulse liegen bei 1 GHz (linkes Teilbild) bzw. 2 GHz (rechtes Teilbild). Die Spektren sind normiert auf die für Ausbreitung in Luft erhaltenen Maxima.

2.2.3 Dielektrische Eigenschaften von Sprengstoffen

Derzeit gibt es keinen weltweiten Überblick und keine Kontrolle über die bei der Minenherstellung verwendeten Explosivstoffe, inaktiven Materialien oder Surrogatminen. Die Charakteristika der produzierten Minen ändern sich von Jahr zu Jahr. Sogenannte SIMs (engl. *simulant mines*) dienen zur Verbesserung der Genauigkeit und Zuverlässigkeit von Messungen an Minen, die entweder zu Ausbildungszwecken oder für wissenschaftliche Untersuchungen durchgeführt werden. Fundierte Kenntnisse über die elektrischen Eigenschaften von Sprengstoffen sowie die Verwendung standardisierter SIMs würden die bessere Beurteilung des Bodeneinflusses vereinfachen.

Auf die gleiche Art und Weise wie die in Abschnitt 2.2.2 beschriebenen Versuche zur Bestimmung der frequenzabhängigen dielektrischen Eigenschaften von Böden, wurden von Curtis [Cur98b] Experimente an Surrogat-Sprengstoffen durchgeführt. Verwendet wurden Silikonmaterialien, deren elektromagnetische und thermische Eigenschaften denen gebräuchlicher Sprengstoffe, wie z.B. TNT, sehr nahekommen. Drei verschiedene Materialien wurden von Curtis untersucht. Bild 2.9 zeigt die dielektrischen Eigenschaften von *Dow Corning RTV 3110* als Funktion der Frequenz. Dieses Füllmaterial wird auch für die im Abschnitt 2.3 beschriebene Modellierung der Streuung an kugelförmigen Körpern verwendet. Die Messungen der Sprengstoffeigenschaften wurden bei 10°C durchgeführt, bei 30°C ist der Realteil von ϵ_r um etwa 2 % niedriger, somit ist der

Temperatureinfluss vernachlässigbar. Der Verlauf des Realteils von ϵ_r zeigt oberhalb von 1 GHz keine ausgeprägte Frequenzabhängigkeit.

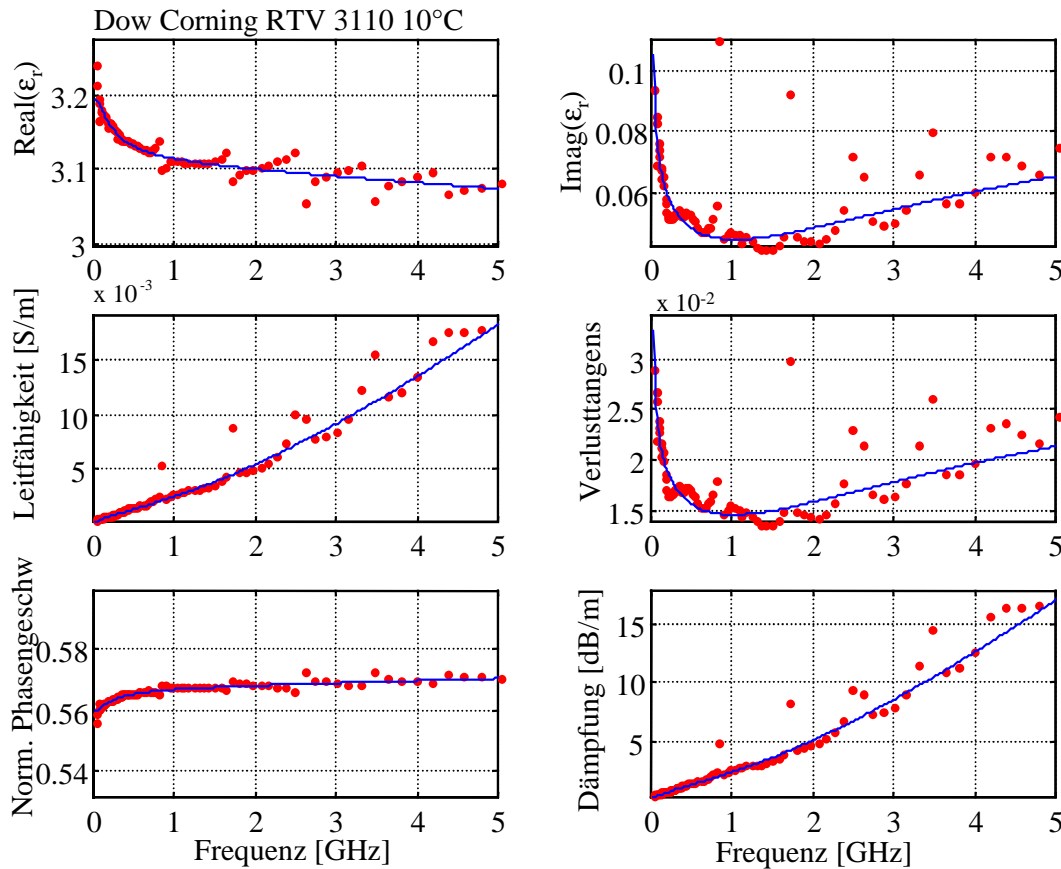


Bild 2.9 Dielektrische Eigenschaften des Surrogat-Sprengstoffs *Dow Corning RTV 3110*, einem Silikonmaterial. Die direkt aus den Messwerten erhaltenen Größen sind mit Punkten gekennzeichnet, die durchgezogenen Kurven wurden durch Interpolation erhalten.

In einer Arbeit von Koh und Arcone werden Messungen vorgestellt, die an vergrabenen SIMs durchgeführt wurden, unter besonderer Berücksichtigung des Einflusses winterlicher Bodenbedingungen [Koh99]. Die in dieser Veröffentlichung beschriebenen Ergebnisse beschränken sich allerdings auf Panzerminen, von vergleichsweise großem Durchmesser.

2.2.4 Modellierung und Charakterisierung von Bodenclutter

Wie in Kapitel 1 bereits erwähnt, ist die Leistungsfähigkeit des Georadarverfahrens primär durch den Bodenclutter eingeschränkt, während reine Rauschprozesse von eher untergeordneter Bedeutung sind. Die Ursachen des Bodenclutters sind zum einen

inhomogene dielektrische Eigenschaften des Bodens, bedingt durch Variationen der mineralischen Zusammensetzung und des Feuchtigkeitsgehalts. Diese Einflüsse sind zudem witterungsabhängig und können daher beträchtlichen Schwankungen unterworfen sein. Zum anderen bilden diskrete Objekte wie Steine, Wurzeln oder Feuchtigkeitseinschlüsse weitere Clutterquellen, die sich je nach Wellenlänge der einfallenden Strahlung, mehr oder weniger stark auswirken können.

Die Charakterisierung der Detektionsleistung eines GPR-Systems sollte möglichst mit einer Beschreibung des Bodenclutters einhergehen. Modelle zur Simulation und quantitativen Beschreibung von Clutter wurden bisher allerdings kaum entwickelt.

Ein geeignetes Modell zur Beschreibung zufälliger und doch bestimmten Einschränkungen unterworfenen natürlichen Formen ist das der fraktalen Brown'schen Bewegung (fBm) [Man68]. Seit einiger Zeit werden solche Modelle bei der Computermodellierung natürlicher Clutterphänomene eingesetzt und liefern realistische Simulationen von geologischem Terrain, Vegetation und Wolken. Es gibt Arbeiten zur Charakterisierung natürlicher Bildszenen [Pen84] oder hochauflösender SAR-Bilder mithilfe lokaler fraktaler Dimensionen [Bur89]. Neben ihrem natürlichen ästhetischen Appeal sind fBm-Modelle von Nutzen beim Entwurf physikalisch plausibler Modelle für die Analyse vielfältiger Prozesse in Ingenieur Anwendungen und in der Physik. Insbesondere bilden Modelle der fraktalen Brown'schen Bewegung den mathematischen Rahmen zur Beschreibung skaleninvarianter zufälliger Texturen und amorpher Clutter in natürlichen Szenen.

Diese Eigenschaften von fBm-Modellen legen es nahe, die Übertragbarkeit auf Georadardaten zu überprüfen. Es ist zu betonen, dass dabei nicht der Einfluss der Bodenoberfläche und ihrer Rauigkeit modelliert werden soll, sondern die Wirkung des Bodens als Volumenstreuer. Simulationen zur Beurteilung des Einflusses der Oberflächenrauigkeit auf die mit einem Imaging-Verfahren erzielten Ergebnisse wurden von Rappaport bereits anhand von Modellrechnungen untersucht [Rap98].

Eine auf einer Fläche definierte fraktale Brown'sche Funktion $f(x,y)$ lässt sich durch einen Zufallsprozess beschreiben, dessen mittelwertfreie und normalverteilte Inkremente folgender Bedingung gehorchen:

$$\left\langle \left| f(x,y) - f(x + \Delta x, y + \Delta y) \right|^2 \right\rangle = \left| \Delta x^2 + \Delta y^2 \right|^H, \quad (2.20)$$

mit $0 < H < 1$ als der sogenannten *Persistenz*, welche die *Rauigkeit* der Fläche beschreibt. Der Fall $H = 1$ korrespondiert mit einer glatten Fläche, $H = 0$ mit einer sehr rauen Textur. Ein solcher Zufallsprozess $f(x,y)$ lässt sich auch anhand eines Leistungsspektrums der Form

$$P(k_x, k_y) \propto \frac{1}{|k|} \quad (2.21)$$

$$\text{mit } = 8 - 2D \text{ und } |k| = \sqrt{k_x^2 + k_y^2}$$

und einem in $[0, 2\pi]$ gleichverteilten Phasenspektrum beschreiben [Bar88]. Im Falle gewöhnlicher euklidischer Objekte bezeichnet D die topologische Dimension. Für fraktale Flächen nimmt D einen Wert an, der die topologische Dimension überschreitet und für den $2 < D < 3$ gilt, ferner gilt $D = 3 - H$.

Gleichung (2.21) definiert ein isotropes Leistungsspektrum. Dieses Modell ist für die Simulation des Bodenclutters bei Georadaren weniger geeignet, da geologische Böden normalerweise in horizontaler Richtung eine deutlich geringere Variation aufweisen als in der Vertikalen. Aus diesem Grund wird die Verwendung eines anisotropen Leistungsspektrums vorgeschlagen:

$$P(k_x, k_z) \propto \frac{1}{|k|}, \quad (2.22)$$

$$\text{mit } (k_x, k_z) = \left[\left(k_x \cos(\vartheta) \right)^2 + \left(k_z \sin(\vartheta) \right)^2 \right]^{\frac{1}{2}} \text{ und } \vartheta = \arctan(k_z/k_x).$$

Analog zu (2.21) lässt sich damit ein anisotropes Leistungsspektrum über die beiden fraktalen Dimensionen $\gamma_x = 8 - 2D_x$ und $\gamma_z = 8 - 2D_z$ definieren. Die Variationen der Bodeneigenschaften in horizontaler und vertikaler Richtung werden durch die Wellenvektoren k_x bzw. k_z beschrieben. In Bild 2.10 ist ein Leistungsspektrum für den Fall $D_x = 2.5$ und $D_z = 2$ abgebildet. Der Anteil hoher räumlicher Frequenzen in horizontaler Richtung ist geringer als der in Vertikalrichtung. Mithilfe der inversen zweidimensionalen Fouriertransformation ergibt sich die fraktale Fläche $f(x, z)$ im Ortsbereich zu

$$f(x, z) = \text{Re} \left\{ \iint_{-\infty}^{+\infty} P(k_x, k_z) e^{j(k_x k_z)} e^{j(k_x x + k_z z)} dk_x dk_z \right\}, \quad (2.23)$$

mit dem gleichverteilten Phasenspektrum $\eta(k_x, k_z)$. Um daraus ein realistisches Clutter-Radargramm mit einer bestimmten Frequenzbandbreite zu erhalten, wird in vertikaler (Zeit-) Richtung eine Faltung mit einem Sendesignal vorgenommen. Als Quellpuls wird das in (2.35) definierte Ricker-Wavelet $g(t)$ mit einer Schwerpunktsfrequenz von 1 GHz verwendet. Mit $t = 2z/v$ erhält man das Clutter-Radargramm an jeder Position x_i aus dem Faltungsprodukt

$$f_g(x_i, t) = f(x_i, t) \otimes g(t). \quad (2.24)$$

Damit ergibt sich das zu Bild 2.10 korrespondierende Resultat im Orts-Zeitbereich, dargestellt in Bild 2.11 (Mitte).




Bild 2.10 Anisotropes Leistungsspektrum mit den Dimensionen $D_x = 2.5$ und $D_z = 2$.




Bild 2.11 Aus anisotropen Leistungsspektren und der Faltung mit einem Quellsignal in Zeitrichtung erhaltene Clutter-Radargramme im Ortsbereich, für verschiedene Werte der fraktalen Dimension D_x . Links: $D_x = 2$, Mitte: $D_x = 2.5$, rechts: $D_x = 3$. In allen drei Fällen gilt $D_z = 2$.

Um zu einer quantitativen Beschreibung von Clutter zu gelangen, braucht diese Vorgehensweise nur umgekehrt zu werden. Folgende Schritte sind dann durchzuführen:

- Berechnung des Leistungsspektrums $P(k_x, k_z)$ eines Radargramms;
- Berechnung der linearen Regression in der k_x - und k_z -Richtung, in der Form:

$$\log P(k_x, k_z) = C_x - \gamma_x \log k_x \quad \text{und} \quad \log P(k_x, k_z) = C_z - \gamma_z \log k_z.$$

Die fraktalen Dimensionen lassen sich unter Berücksichtigung der Konstanten C_x und C_z aus γ_x und γ_z berechnen. Man erhält somit ein einfaches Verfahren zur Charakterisierung von Clutter, anhand von lediglich zwei Parametern. Mithilfe dieses Ansatzes lassen sich sowohl die Magnitude der Fluktuationen wie auch deren räumliche Skale oder die Korrelationslänge anhand der anisotropen fraktalen Dimension in Abhängigkeit von der Energieverteilung des Spektrums beschreiben.

Die Fähigkeit zur Diskrimination vergrabener Minen von Clutter ist der Schlüssel zur Steigerung der mit einem Georadar zu erzielenden Detektionsleistung. Eine eingehende Untersuchung von Methoden zur quantitativen Beschreibung von Bodenclutter, für eine Vielzahl von Bodentypen, bildet zwar keinen Schwerpunkt dieser Arbeit, der hier vorgeschlagene Ansatz liefert aber doch Resultate die realen Radargrammen erstaunlich nahekommen und könnte daher von Interesse für weiterführende Arbeiten sein. Er könnte damit einen wichtigen Schritt darstellen, um von der Verwendung lokaler Bodenproben abzukommen und sich einer eher makroskopischen Betrachtung von Böden zuzuwenden.

2.3 Streuung an Kugeln in realen Böden

Die Simulation der Streuung elektromagnetischer Wellen an Minen unter realen Umgebungsbedingungen ist aufgrund der in der Regel komplizierten Objektgeometrie und der nicht hinlänglich bekannten Bodeneigenschaften kaum durchführbar. Die Intention der in diesem Abschnitt beschriebenen Arbeiten ist daher, anhand idealisierter Streuobjekte die Abhängigkeit der charakteristischen Signatur eines Objekts von folgenden Einflussgrößen zu untersuchen:

- Materialparameter (Kontrast der dielektrischen Eigenschaften, Dämpfung);
- Geometrischer Objektaufbau (Vollkugel, Kugelschale);
- Frequenzspektrum des einfallenden Radarpulses.

Die simulierten Streusignale bildeten die Grundlage für die Entwicklung und Beurteilung der in Kapitel 4 vorgestellten Zeit-Frequenz-Analyseverfahren zur Merkmalsextraktion.

Die ausschließliche Betrachtung von Kugelobjekten stellt dabei sicherlich eine drastische aber naheliegende Vereinfachung dar, die jedoch zum Verständnis der auftretenden Phänomene und zur Beurteilung ihres Einflusses auf die Klassifikation sinnvoll erscheint.

Ausführliche Untersuchungen des Bodeneinflusses auf die Detektierbarkeit und die Möglichkeiten zur Diskrimination von Objekten sind nicht bekannt. Von Carin, Geng und Sullivan an der Duke-University (North-Carolina) durchgeführte Arbeiten zum Vergleich gemessener Minensignaturen mit für rotationssymmetrische Minen simulierten Daten, wurden in [Vit97], [Gen98, Gen99] und [Sul99] präsentiert. Mit den in diesen Veröffentlichungen detaillierten Verfahren zur elektromagnetischen Modellierung wurden zwar Fortschritte in Bezug auf die Beschreibung vergrabener Objekte erzielt, diese Arbeiten hatten allerdings nicht die Zielsetzung Objekte anhand ihrer Signatur zu unterscheiden.

Die Streuung elektromagnetischer Wellen an Kugeln ist in der Literatur ausführlich behandelt, siehe z.B. [Ker69]. Nur wenige Arbeiten hingegen befassen sich mit der transienten Streuung an Vollkugeln oder Kugeln mit Schalenbau in realen absorbierenden Medien mit frequenzabhängigen Eigenschaften.

2.3.1 Streuung an Vollkugeln und Kugelschalen

Betrachtet wird der Fall einer monochromatischen ebenen Welle, die auf eine Kugel mit einem konzentrischen Aufbau aus zwei homogenen Schichten einfällt. Der Radius der inneren Kugel wird mit r_a , der äußere Kugelradius mit r_b bezeichnet. Die Wellenzahlen in den drei betrachteten Medien (innere Kugel, Kugelschale, umgebendes Medium) lassen sich mit der Wellenlänge λ im umgebenden Medium schreiben als

$$k_3 r_a = 2 \pi r_a / \lambda = m_1 ; \quad k_2 r_b = 2 \pi r_b / \lambda = m_2 ; \quad (2.25)$$

$$\text{und } m_1 = \frac{k_1}{k_3} ; \quad m_2 = \frac{k_2}{k_3}, \quad (2.26)$$

mit m_1 und m_2 als den Brechungsindizes zwischen der inneren Kugel bzw. der Kugelschale und dem umgebenden Medium. Für homogene Kugeln gilt $m_1 = m_2$. Das einfallende elektrische Feld ist definiert durch

$$\mathbf{E}_{in} = E_0 \mathbf{e}_x e^{[j(\omega t + kz)]}, \quad (2.27)$$

mit E_0 als Feldamplitude und \mathbf{e}_x als Einheitsvektor in x -Richtung, der die Polarisations Ebene der sich in negativer z -Richtung ausbreitenden Welle beschreibt. Im Fernfeld (Abstand $r \gg r_a$) kann die gestreute Welle geschrieben werden als

$$\mathbf{E}_{sc} = E_0 \frac{e^{[j(\omega t + kr)]}}{r} [\mathbf{e} S_1(\theta) \cos(\phi) - \mathbf{e}_\phi S_2(\theta) \sin(\phi)], \quad (2.28)$$

mit θ und ϕ als Elevations- und Azimutwinkel und \mathbf{e}_θ bzw. \mathbf{e}_ϕ als Einheitsvektoren sowie

$$\begin{Bmatrix} S_1 \\ S_2 \end{Bmatrix} = \sum_{n=1}^{\infty} \frac{2n+1}{n(n+1)} \left[a_n \begin{Bmatrix} \pi_n(\cos(\theta)) \\ \tau_n(\cos(\theta)) \end{Bmatrix} + b_n \begin{Bmatrix} \tau_n(\cos(\theta)) \\ \pi_n(\cos(\theta)) \end{Bmatrix} \right]. \quad (2.29)$$

Für $\theta = \pi$ ist die Einfallsrichtung gleich der Ausfallrichtung. Dies entspricht dem Fall der Rückstreuung bei kolokaler Anordnung von Sende- und Empfangsantenne. Die Funktionen $\pi_n(\theta)$ und $\tau_n(\theta)$ sind definiert durch

$$\pi_n(\theta) = \frac{P_n^{(1)}(\cos(\theta))}{\sin(\theta)}, \quad \tau_n(\theta) = \frac{dP_n^{(1)}(\cos(\theta))}{d\theta}. \quad (2.30)$$

$P_n^{(1)}(\cdot)$ bezeichnet die assoziierte Legendre-Funktion der ersten Art und ersten Ordnung vom Grad n . Die Streukoeffizienten a_n und b_n hängen von den Brechungsindizes m_1 und m_2 , den Radien r_a und r_b sowie den Streuparametern α und β ab. Die längliche Definition dieser Koeffizienten findet man z.B. in [Ker69]. Wächst der Brechungsindex der äußeren Kugelschale gegen unendlich, erhält man den Grenzfall einer perfekt leitenden Kugel. In diesem Fall reduzieren sich die Ausdrücke für die Streukoeffizienten auf

$$a_n = -\frac{j_n(\alpha)}{n_n(\alpha)}, \quad b_n = \frac{j_n(\beta)}{n_n(\beta)}. \quad (2.31)$$

Hierin sind $j_n(kr)$ und $n_n(kr)$ mit $\alpha = kr$ die sphärische Bessel- bzw. Hankelfunktion, gegeben durch

$$j_n(kr) = \sqrt{\frac{\pi kr}{2}} J_{n+1/2}(kr), \quad n_n(kr) = \sqrt{\frac{\pi kr}{2}} H_{n+1/2}^{(2)}(kr). \quad (2.32)$$

Im Folgenden werden nur die Fälle $\phi = 0$, bzw. $\phi = \pi/2$ betrachtet, d.h. der elektrische Feldvektor ist parallel bzw. senkrecht zu der Ebene, die durch die Einfallsrichtung und die Streurichtung θ aufgespannt wird. Mithilfe der Fouriertransformation lässt sich der Fall monochromatischer einfallender Wellen auf Pulse verallgemeinern

$$G(\omega) = \int_{-\infty}^{+\infty} g(t) e^{-j\omega t} dt, \quad g(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} G(\omega) e^{j\omega t} d\omega, \quad (2.33)$$

mit dem einfallendem Puls $g(t)$ und dessen Spektrum $G(\omega)$. Damit ergibt sich das gestreute Signal aus

$$\begin{Bmatrix} E_{\perp}(\alpha, t) \\ E_{\parallel}(\alpha, t) \end{Bmatrix} = \frac{E_0}{2kr} \int_{-\infty}^{+\infty} G(\alpha) \begin{Bmatrix} S_1(\alpha, t) \\ S_2(\alpha, t) \end{Bmatrix} e^{j(\omega t - kr)} d\alpha, \quad (2.34)$$

unter Berücksichtigung von $\alpha = \omega r_a / c$. Für die im nächsten Abschnitt vorgestellten Modellrechnungen wird ein Ricker-Wavelet verwendet, definiert durch [Ric44]

$$g(t) = (1 - 2\pi^2 f_M^2 t^2) e^{-\pi^2 f_M^2 t^2}, \quad (2.35)$$

mit der Mittenfrequenz f_M des Signalspektrums, gegeben durch

$$G(f) = \frac{2}{\sqrt{\pi}} \frac{f^2}{f_M^3} e^{-f^2/f_M^2}. \quad (2.36)$$

Definiert man die Bandbreite als Abstand der 3 dB-Punkte, ergibt sich für $f_M = 1$ GHz bzw. 2 GHz eine Bandbreite von 1.15 GHz bzw. 2.3 GHz.

2.3.2 Simulationsergebnisse

Bild 2.12 zeigt die für eine homogene Kugel ($\epsilon_r = 3$, $r = 5$ cm) erhaltene Rückstreuung ($\theta = \phi$) für $\phi = 0$ als Funktion der relativen Dielektrizitätszahl des umgebenden Mediums. Der Wertebereich für ϵ_r der Umgebung liegt zwischen 1 und 20, d.h. das erste Signal stellt die Streuung in Luft dar. Verwendet wurde ein 2 GHz-Ricker-Puls.

Neben der Scheitelreflexion sind zwei weitere Moden zu erkennen, die auf umlaufende Kriechwellen zurückzuführen sind. Unterschieden werden innere und äußere Kriechwellen, die sich mit der Wellenausbreitungsgeschwindigkeit in der Kugel bzw. der des umgebenden Mediums ausbreiten. Anhand des konstanten zeitlichen Versatzes zwischen der Scheitelreflexion und dem ersten Auftreten der Kriechwelle für $\epsilon_r > 3$ kann man schließen, dass es sich um eine innere Mode handelt. Bemerkenswert ist, dass im Fall der von Luft umgebenen Kugel die Primärreflexion nicht die stärkste Amplitude aufweist. Ferner existieren noch weitere Moden, z.B. die des *Glory Rays*, darstellbar durch einen in die Kugel refraktierten Strahl, welcher an der Rückseite der Kugel reflektiert wird und diese parallel zum einfallenden Strahl wieder verlässt. Ab $\epsilon_{r, \text{Boden}} > 3$ kehrt sich die Polarität der Primärreflexion um. Dies kann für die Untersuchung charakteristischer Signaturen von Bedeutung sein, da der Kontrast für ein und dasselbe Objekt durch die Feuchte im umgebenden Boden bestimmt wird.

Zur Modellierung der dielektrischen Eigenschaften von Böden bzw. Sprengstoffen wird auf die in den Abschnitten 2.2.2-3 diskutierten Messungen zurückgegriffen. Da neben dem geometrischen Aufbau eines Objekts sowie dem Spektrum des einfallenden Pulses

die Materialeigenschaften den größten Einfluss auf die Radarsignatur haben, ermöglicht dies einen weitgehenden Realitätsbezug.

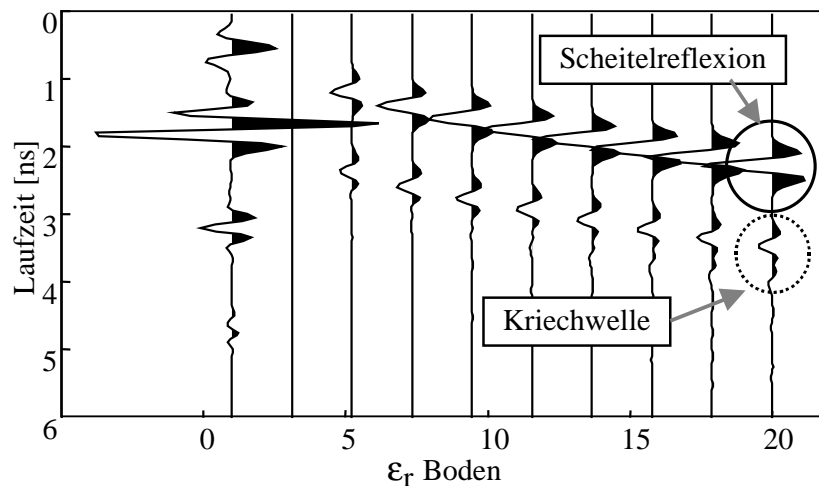


Bild 2.12 Streuung an einer dielektrischen Vollkugel ($\epsilon_r = 3$, $r = 5$ cm) als Funktion der relativen Dielektrizitätszahl der umgebenden Mediums. Das Signal links entspricht der Kugelstreuung in Luft.

Das für die Simulationen zugrunde gelegte Modell besteht aus einer in jeweils gleichen Boden aber mit unterschiedlicher Feuchte (3 %, 12 % bzw. 49 %) vergrabenen Kugel von 10 cm Durchmesser, umgeben von einer Luftschicht mit 1 mm bzw. 10 mm Dicke. Die Motivation für diese Wahl ist die in zahlreichen Veröffentlichungen geäußerte Vermutung, dass die in einer Mine oft vorhandenen Lufttaschen einen wesentlichen Einfluss auf die Objektsignatur haben.

Die bei 1 GHz bzw. 4 GHz auftretenden Wellenlängen sind in Tabelle 2.2 angegeben. Nur bei hohen Bodenfeuchten und hohen Frequenzen liegt aufgrund der abnehmenden Ausbreitungsgeschwindigkeit die Wellenlänge im Bereich der Dicke des Luftspalts.

Feuchte	λ bei 1 GHz [cm]	λ bei 4 GHz [cm]
3 %	18	4
12 %	14	3.6
49 %	6	1.5

Tabelle 2.2 Wellenlängen im Frequenzbereich von 1 bis 4 GHz für die in den Bildern 2.13 und 2.14 verwendeten Böden.

Bild 2.13 zeigt die erhaltenen Streuantworten als Funktion der Mittenfrequenz des Quellsignals, in der linken Spalte für den Luftspalt mit 1 mm, rechts für 10 mm. Die Scheiteltiefe der Kugel beträgt 15 cm. Sowohl die Streusignale in Bild 2.13 als auch die in Bild 2.14 gezeigten sind jeweils auf die maximale Betragsamplitude der einzelnen Graphen normiert.




Bild 2.13 Streuung an einer vergrabenen Kugel (Durchmesser 10 cm), bestehend aus einem Sprengstoffkern ($\epsilon_r = 3.1$), umgeben von einer konzentrischen Luftschicht zur Simulation von in Minen vorhandenen Lufttaschen.

Anhand der den in Bild 2.13 dargestellten Ergebnissen lassen sich folgende Schlussfolgerungen ableiten:

- Für den Fall von 3 % Feuchte und einem Luftspalt von 1 mm Dicke (oben links) ist die Polarität der Primärreflexion gegenüber der ab 12 % Feuchte erhaltenen gedreht, da hier die relative Dielektrizitätszahl des Bodens einen kleineren Wert

als die von Sprengstoff aufweist (vgl. Bild 2.5 und 2.13). Aufgrund der geringen Bodendämpfung ist keine Abnahme der Streuamplituden bei wachsender Frequenz zu beobachten.

- Bei 12 % Feuchte und hohen Frequenzen (Teilbild Mitte rechts in Bild 2.13) wirkt der Luftspalt als Differenzierer des Quellsignals, bedingt durch die Superposition der an den Grenzflächen Boden-Luftspalt und Luftspalt-Kern stattfindenden Reflexionen mit entgegengesetzter Polarität. Umlaufende Kriechwellen sind ebenfalls zu beobachten.
- Schon bei 12 % Bodenfeuchte ist der Einfluss der Dämpfung sichtbar. Umlaufende Kriechwellen sind nur noch mit schwacher Amplitude zu beobachten (Mitte links, Mitte rechts). Erst ab einer Frequenz von 2 GHz sind die Primärreflexion und die Kriechwelle deutlich getrennt.
- Aufgrund der Tiefpasscharakteristik des Bodens bei hoher Feuchte (unten links, unten rechts) ist kein Effekt des Luftspalts mehr festzustellen. Die Zunahme der Bodendämpfung auf die Signalamplitude zu hohen Frequenzen hin ist stark ausgeprägt.

In Bild 2.14 wurde eine andere Darstellungsart dieser Ergebnisse gewählt. Hier sind die Streusignale bei konstanter Mittenfrequenz des Sendepulses als Funktion der Dicke des Luftspalts aufgetragen. Bei hoher Dämpfung ist keinerlei Abhängigkeit von der Größe des Luftspalts mehr festzustellen. In den anderen beiden Fällen ist zu beobachten wie der zeitliche Abstand des Einsetzens der Primärreflexion und der Kriechwelle linear abnimmt. Der Grund ist die abnehmende Weglänge, welche die mit der Ausbreitungsgeschwindigkeit des Kerns umlaufende Kriechwelle zurückzulegen hat.

Zusammenfassend kann festgehalten werden, dass die Signatur der Streuung bei starker Bodendämpfung kaum eine Abhängigkeit von der inneren Objektstruktur zeigt, während bei schwacher Dämpfung ein deutlicher Einfluss auf die Signatur zu beobachten ist. Auf der Grundlage weiterer Simulationen, für Kugeln mit unterschiedlichen Materialeigenschaften und innerem Aufbau, werden die in Kapitel 4 diskutierten Verfahren zur Berechnung signaltypischer Kenngrößen, zum Zwecke der Objektrennung, verifiziert. Die hierfür modellierten Kugelstreuer werden in Kapitel 5 näher beschrieben. Die zugehörigen Ergebnisse der Klassifikation finden sich in Kapitel 6.




Bild 2.14 Streuung an einer vergrabenen Kugel (Durchmesser 10 cm), bestehend aus einem Sprengstoffkern ($\epsilon_r = 3.1$), umgeben von einer konzentrischen Luftschicht zur Simulation von in Minen vorhandenen Lufttaschen.

3. Objektdetektion

In der Literatur existieren zahlreiche Ansätze zur Minendetektion mit Georadaren, die sich auf die Auswertung zweidimensionaler Radargramme (B-Scans) stützen, wobei in der Regel einzelne Streusignale (A-Scans) isoliert betrachtet werden. Die in vielen Veröffentlichungen präsentierten Ergebnisse wurden auf Grundlage einer vergleichsweise geringen Anzahl von Messungen erhalten und sind daher von eher phänomenologischer Natur. Nachfolgend werden verschiedene bekannte Ansätze kurz skizziert, bevor ein neu entwickeltes Detektionsverfahren vorgestellt wird, welches anhand der in Kapitel 5 beschriebenen Messdaten verifiziert wird.

In den Arbeiten von Carevic [Car99] und Brunzell [Bru99] wird das Detektionsproblem als binärer Hypothesentest für individuelle Radarsignale formuliert:

H_0 : gemessenes Signal besteht aus Hintergrund plus Rauschen;

H_1 : gemessenes Signal besteht aus Objektstreuung plus Rauschen.

Zunächst führen beide eine Unterdrückung des Oberflächenechos durch. Carevic stellt ein Verfahren vor, bei dem die Signale mit einem Nutzanteil möglichst nicht zur Bestimmung des Hintergrundsignals herangezogen werden sollen, um dieses nicht zu verfälschen. In Brunzells Ansatz werden drei Vorgehensweisen unterschieden: Bei der ersten werden nur Abtastwerte einzelner Signale zu einem bestimmten Zeitpunkt betrachtet und als mittelwertfrei und normalverteilt angenommen, mit der Varianz σ_0^2 unter H_0 und der Varianz σ_1^2 unter H_1 , mit $\sigma_1^2 \gg \sigma_0^2$. Über einen Schwellwert wird entschieden, welche Hypothese wahr ist. Die Detektions- bzw. Falschalarmwahrscheinlichkeiten sind definiert als:

$$P_D = P(\text{Entscheidung } H_1 \text{ ist wahr} \mid H_1 \text{ ist wahr});$$

$$P_{FA} = P(\text{Entscheidung } H_1 \text{ ist wahr} \mid H_0 \text{ ist wahr}).$$

Bei der zweiten Vorgehensweise betrachtet Brunzell nicht die einzelnen Abtastwerte, sondern die Gesamtheit aller Abtastwerte eines A-Scans, unter der Annahme einer multidimensionalen Normalverteilung, mit linearer Unabhängigkeit der Abtastwerte verschiedener Zeitschritte. Brunzell selbst äußert Zweifel an der Haltbarkeit dieser Annahme, da zwischen zeitlich aufeinanderfolgenden Abtastwerten immer eine Korrelation besteht. Bei der dritten Vorgehensweise werden Blöcke benachbarter A-Scans betrachtet. Da das Verfahren nur an zwei in einer Sandbox vermessenen Objekten demonstriert wird, erscheint seine Praxistauglichkeit unsicher.

Carevic benutzt eine Wavelet-Packet-Transformation und definiert die Statistik der Detektion anhand der Energie einer bestimmten Anzahl der höchsten Koeffizienten. Nur wenn in einem B-Scan eine gewisse Anzahl aufeinanderfolgender A-Scans über einer Schwelle liegende Werte produzieren, wird eine Detektion angezeigt.

In einer weiteren Arbeit von Yu et al wird ebenfalls ein Hypothesentest für die Detektion eingesetzt [Yu00]. Das hier verwendete GPR-System besteht aus einer Anordnung von vier S/E-Antennenpaaren. Die Teststatistik wird aus den drei Differenzsignalen benachbarter Empfangsantennen gebildet. Während die Möglichkeit, mehr Informationen in Form parallel aufgezeichneter Signale zu berücksichtigen, sicherlich von Vorteil ist, besteht bei einer Differenzbildung immer die Gefahr, dass eine Änderung der Bodeneigenschaften über der Länge des Arrays Fehlalarme hervorruft.

Iskander untersucht die Eignung der Kurzzeit-Spektralanalyse und der Wigner-Ville-Verteilung zur Erzeugung von Teststatistiken T_1 und T_2 , um eine Trennung zwischen Hintergrund- und Minensignalen vornehmen zu können [Isk00]. Er definiert die Statistiken zu

$$T_1 = \frac{1}{NM} \sum_{t_n} \sum_{f_n} [S_B(t, f) - S_T(t, f)]^2$$

und $T_2 = \frac{1}{NM} \sum_{t_n} \sum_{f_n} [W_B(t, f) - W_T(t, f)]^2$, (3.1)

mit $N \cdot M$ Stützstellen der Zeit-Frequenz-Ebene und S_B bzw. S_T als den Kurzzeitspektrogrammen von reinen Hintergrund (Boden-) - bzw. Objektsignalen und W_B bzw. W_T als den entsprechenden Wigner-Ville-Verteilungen [Hay85]. Problematisch bei der Anwendung dieses Verfahrens ist die Notwendigkeit das Hintergrundsignal kontinuierlich neu schätzen zu müssen, da sich die Bodeneigenschaften entlang des Messprofils ändern können. Außerdem darf in S_B , bzw. W_B kein Signalanteil eines zu detektierenden Objekts enthalten sein.

Ein prinzipieller Nachteil aller oben skizzierten Verfahren liegt in der isolierten Betrachtung einzelner Scans. Aufgrund der hohen Korrelation benachbarter Signale sind diese keinesfalls als unabhängig anzusehen. Bei einer hinreichend dichten flächigen Abtastung wird ein Objekt von mehr als einem Abtastpunkt aus beobachtet. Das aber heißt, dass sich die Leistungsfähigkeit und die Robustheit eines Detektionsverfahrens anhand einer Auswertung von Nachbarschaftsbeziehungen deutlich steigern lassen. Die Verarbeitung dreidimensionaler Datensätze eröffnet zudem die Möglichkeit einer Auswertung der Form potenzieller Objekte mit Verfahren der Bildverarbeitung.

In diesem Kapitel wird ein neues Verfahren vorgestellt, mit dem sich auf einfache Art und Weise die horizontale Position von Objekten in dreidimensionalen Datensätzen lokalisieren lässt. Die verschiedenen Verarbeitungsschritte des implementierten Detektionsalgorithmus zeigt das Flussdiagramm in Bild 3.1. Das Verfahren zur Erzeugung horizontaler Projektionen aus 3D-Daten wird in Abschnitt 3.1 vorgestellt. In Abschnitt 3.2 wird beschrieben wie sich daraus kreisförmige Objekte extrahieren lassen. In Abschnitt 3.3 schließlich wird erläutert wie der Schritt hin zur Klassifikation vollzogen werden kann, ausgehend von den erhaltenen Detektionen.

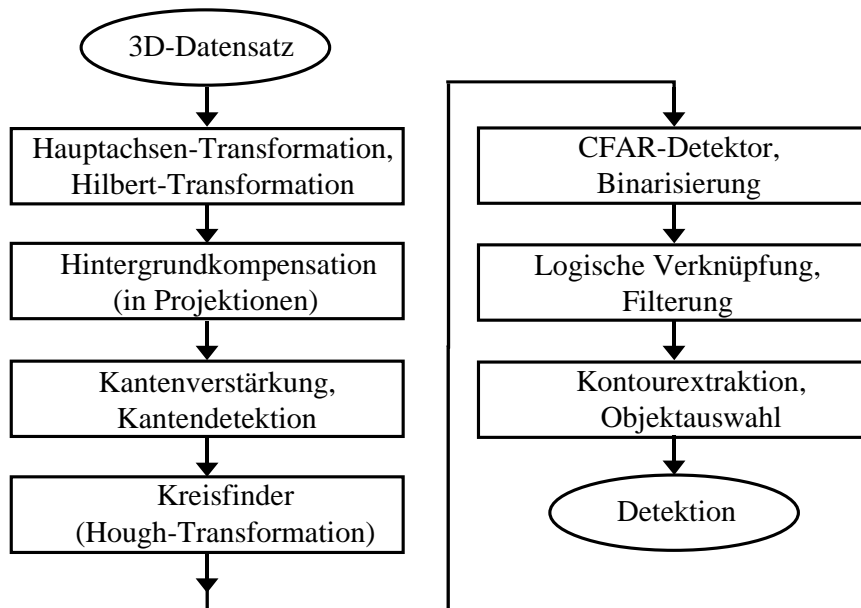


Bild 3.1 Flussdiagramm der einzelnen Verarbeitungsschritte des vorgeschlagenen Detektionsalgorithmus anhand horizontaler Projektionen.

3.1 Erzeugung von Horizontalprojektionen

Erfolgt die Datenerfassung mit einem Georadarsystem entweder durch gleichmäßige Abtastung in x- und y-Richtung oder mit einem entlang einer Koordinatenachse verschobenen Arraysystem, bestehend aus einer Vielzahl von Antennen, die quer zur Bewegungsrichtung angeordnet sind, besteht die Möglichkeit der graphischen Datenwiedergabe in der Form horizontaler Schnittbilder. Diese Flächen stellen die Amplitudenverteilung aller aufgenommen Radarsignale eines 3D-Datenwürfels zu einem festen Zeitpunkt dar. Solche horizontalen Schnittbilder durch den Untergrund erscheinen dem menschlichen Auge wesentlich leichter zugänglich als die ein höheres Maß an Interpretation erfordernden vertikalen Tiefenschnitte, mit den für Georadare typischen

Signalmustern. Im Boden liegende Objekte können so eher anhand ihrer Form festgestellt werden, während in einem senkrechten Schnittbild nur ein Ausschnitt einer Streuhyperbel ausgemacht werden kann.

Eine Folge von horizontalen Schnitten zeigt Bild 3.2. Jedes Bild repräsentiert die Amplitudenverteilung bei konstanter Zweiwegelaufzeit. Bei den vergrabenen sechs Objekten handelt es sich um fünf Metall- und eine Plastikmine, welche die schwächste Rückstreuung liefert (Verlegeposition oben links). Die erste Schnittfläche (bei 2 ns) liegt unmittelbar unter der Oberfläche. Bei einer Dielektrizitätszahl von $\epsilon_r = 5$ ergibt sich für die abgebildeten Ebenen ein vertikaler Abstand von etwa 2.7 cm. Die horizontale Ausdehnung beträgt 1 x 1.5 m, bei einer in x- und y-Richtung äquidistanten Abtastung von 2 cm. Die Minen treten durch ihre Kreisform hervor, weiß bezeichnet positive, schwarz negative Amplituden. Ab einer Tiefe von 6 ns dominiert der Bodenclutter. Die Signalamplituden zeitlich direkt aufeinanderfolgender Ebenen sind stark korreliert, d.h. ein Datenwürfel enthält ein großes Maß an redundanter Information.




Bild 3.2 Horizontalschnitte durch den Untergrund, erhalten als Flächen konstanter Zweiwegelaufzeit. Die Bilder entsprechen jeweils einer Fläche von 1 x 1.5 m.

Betrachtet man die zeitliche Abfolge der Horizontalschnitte in Form einer Filmsequenz, entsteht ein visueller Eindruck, der zur Detektion von Objekten äußerst hilfreich ist. Während die durch Bodenclutter hervorgerufenen Signalanteile über der Zeit mehr oder weniger stark fluktuieren, erscheinen tatsächlich vorhandene Gegenstände ortsfest. Die von ihnen ausgehenden Streuung lässt sich, je nach Tiefenlage, innerhalb eines gewissen Zeitfensters beobachten. Um diese Wahrnehmungsleistung des menschlichen Auges nachzuahmen, wurde eine Transformation gesucht, mit deren Hilfe sich redundante Informationen unterdrücken lassen und ein ganzer Datenwürfel auf einige wenige Horizontalflächen reduziert werden kann. Eine Transformation die dies leistet, ist die Hauptachsentransformation, die auch als *Karhunen-Loève-Transformation* oder *Principal-Component-Analysis* bekannt ist.

Für einen Datenwürfel mit N_x bzw. N_y Abtastwerten in horizontaler Richtung und N zeitlichen Abtastwerten lässt sich folgende Matrix definieren:

$$\mathbf{X} = X_{t,l} \quad \text{mit} \quad X_{t,l} = x_{m,n}(t), \quad l = m + (n-1) \cdot N_x, \quad m \in [1; N_x], \quad n \in [1; N_y]. \quad (3.2)$$

Nach (3.2) wird der Datenwürfel in eine zweidimensionale Matrix so umsortiert, dass jede horizontale Ebene in einer Zeile dieser Matrix steht. Die Anzahl der Zeilen ist somit gegeben durch die Anzahl der Abtastwerte N , die Anzahl der Spalten durch $L = N_x \cdot N_y$, mit $l \in [1; L]$.

Die N Abtastwerte pro Signal spannen einen N -dimensionalen Raum auf, der nun möglichst geschickt auf einen M -dimensionalen Unterraum projiziert werden soll. Genau dies leistet die Hauptachsentransformation, die als Abfolge einer Translation und einer Rotation veranschaulicht werden kann. Die Hauptachsentransformation (HAT) wird aus den ersten beiden statistischen Momenten, dem Erwartungswert $\boldsymbol{\mu}$ und der Kovarianzmatrix \mathbf{K} berechnet [Sch96]:

$$\begin{aligned} \boldsymbol{\mu} &= \mathbb{E}\{\mathbf{X}\}, \\ \mathbf{K} &= \mathbb{E}\{(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T\}. \end{aligned} \quad (3.3)$$

Die Berechnung erfolgt mittels der Lösung der Eigenwertaufgabe mit der Kovarianzmatrix \mathbf{K} und liefert Paare von Eigenwerten λ_m und Eigenvektoren \mathbf{b}_m , die der Größe der Eigenwerte nach in absteigender Reihenfolge sortiert werden. Die wichtigsten mathematischen Zusammenhänge sind in den folgenden Gleichungen dargestellt:

$$\begin{aligned} \mathbf{W} &= \mathbf{B}^T \cdot (\mathbf{X} - \boldsymbol{\mu}), \\ \hat{\mathbf{X}} &= \mathbf{B} \cdot \mathbf{W} + \boldsymbol{\mu}. \end{aligned} \quad (3.4)$$

\mathbf{B} ist die rechteckige $N \times M$ -Matrix der spaltenweise angeordneten Eigenvektoren, die im vorliegenden Fall auch als *Eigensignale* bezeichnet werden können. \mathbf{W} enthält spaltenweise die transformierten und verkürzten Signale. Die rekonstruierten Signale $\hat{\mathbf{X}}$ sind nur der Vollständigkeit halber angegeben, für die weitere Verarbeitung werden sie hier nicht benötigt. Der Rekonstruktionsfehler R^2 lässt sich direkt aus den Eigenwerten berechnen:

$$R^2 = \mathbb{E}\left\{|\mathbf{X} - \hat{\mathbf{X}}|^2\right\} = \sum_{m=M+1}^N \lambda_m. \quad (3.5)$$

Damit kann der zu tolerierende Rekonstruktionsfehler über die Anzahl der berücksichtigten Eigenwerte vorgegeben werden. Bis auf einen Rekonstruktionsfehler lässt sich damit jedes Eingangssignal als gewichtete Superposition der Eigensignale darstellen.

Die erste Gleichung in (3.4) impliziert, aufgrund der Subtraktion des Erwartungswerts μ von jeder Horizontalfläche konstanter Laufzeit, die einfachste Form einer Hintergrundkompensation (vgl. Abschnitt 2.1.8). Die vertikale Dimension der resultierenden Matrix \mathbf{W} (s. Glg. 3.2) ist nicht mehr die Zeit, sondern korrespondiert mit den sortierten Eigenwerten. Durch Umkehrung des Sortiervorgangs in (3.2) erhält man die gesuchte transformierte Darstellung des Datenwürfels, mit der von N auf M reduzierten Anzahl von Ebenen. Jeder beitragende Eigenwert liefert eine Projektionsfläche. Die HAT zeichnet sich auch dadurch aus, dass die transformierten Signale und damit die Projektionen de-korreliert sind.

Durch die HAT geht der zeitliche Bezug der Horizontalflächen zueinander verloren. Dies eröffnet die Möglichkeit von vorneherein nicht die Zeitsignale sondern deren Betragspektren zu transformieren. Für die in Bild 3.3 gezeigten Ergebnisse wurde daher dieser Weg gewählt. Zu diesem Zweck wird in den Gleichungen (3.3) bis (3.5) die Matrix \mathbf{X} durch $|\mathbf{S}\{\mathbf{X}\}|$ ersetzt, mit $\mathbf{S}\{\cdot\}$ als der Fouriertransformierten von \mathbf{X} . Dies hat den Vorteil eines deutlich verminderten Rechenaufwands, da bei 256 Abtastwerten pro Signal die Eigenwerte einer 256×256 großen Kovarianzmatrix berechnet werden müssen, während bei der Verwendung von Spektren eine Einschränkung auf die Nutzbandbreite des Signals vorgenommen werden kann. Bei den zur Verfügung stehenden Daten erwies sich die Verwendung von 40 Spektralkoeffizienten als völlig ausreichend, entsprechend einer Grenzfrequenz von 4 GHz, bei einer Schwerpunktsfrequenz des Sendesignals von ungefähr 1 GHz.

Werden anstelle von Zeitsignalen deren Spektren verwendet, lassen sich die erhaltenen Eigenvektoren als *Eigenspektren* auffassen, mit denen sich das Spektrum eines beliebigen Eingangssignals des 3D-Datensatzes in orthogonale Bestandteile zerlegen lässt. Der

Frequenzgehalt der Eigenspektren verschiebt sich bei zunehmenden Eigenwerten zu hohen Frequenzen, woraus ein wachsender Grad der in den Projektionen sichtbaren Feinstruktur resultiert (s. Bild 3.3). Bei niedrigen Eigenwerten ist nur die räumliche Grobstruktur erkennbar, mit der allerdings auch der größte Anteil der Energie verbunden ist (da die niedrigen Eigenwerte den größten Beitrag zur Rekonstruktion leisten). Das z.B. dem Eigenwert λ_{23} zugeordnete Bild zeigt von den Bildecken ausgehende Wellenmuster, die auf Reflexionen an den Ecken des Versuchsaufbaus zurückzuführen sind.




Bild 3.3 Horizontalschnitte durch den Untergrund, erhalten mit Hilfe einer Hauptachsentransformation. Auffällig ist der ansteigende Frequenzgehalt bei höheren Eigenwerten, während niedrige Eigenwerte die in den Daten enthaltene Grobstruktur wiedergeben.

Gleichwohl die Anwendung einer Hauptachsentransformation eine sehr effektive Methode ist, um die in einem 3D-Datensatz enthaltene Information zu komprimieren und Redundanz zu unterdrücken, bleibt ein grundsätzliches Problem ungelöst: Sind innerhalb eines abgetasteten Areal gleichzeitig stark *und* schwach streuende Objekte vorhanden, können letztere aufgrund des schlechten Kontrasts unter Umständen kaum mehr detektiert werden. Ein Beispiel zeigt Teilbild λ_3 in Bild 3.3. Dort erkennt man unten rechts einen kreisförmigen Fleck hoher Amplitude (weiß), während das Objekt darüber (Mitte rechts im gleichen Bild) kaum wahrnehmbar ist. In der Praxis könnte dies zur Folge haben, dass eine in unmittelbarer Nachbarschaft einer Metallmine liegende Plastikmine übersehen wird.

Mit einer verhältnismäßig einfachen Maßnahme lässt sich hier Abhilfe schaffen. Verwendet werden dazu nicht nur die Projektionen \mathbf{W} , sondern deren Hilbertransformierte, bezeichnet als $H\{\mathbf{W}\}$. An jeder horizontalen Position (m, n) wird ein Vektor aus den Werten aller Bilder λ_i an der betreffenden Position gebildet, entsprechend einer Spalte der Matrix \mathbf{W} . Dann wird jeder der so entstandenen Vektoren hilberttransformiert.

Die Hilbert-Transformation einer Funktion $f(t)$ ist gegeben durch [Tit26]

$$H\{f(t)\} = \frac{1}{2\pi} \int_{-\infty}^{\infty} f(\omega) e^{i\frac{\omega}{2} \operatorname{sgn}(\omega)} e^{i\omega t} d\omega, \quad (3.6)$$

mit $\operatorname{sgn}(\omega) = \pm 1$ für $\omega \gtrless 0$.

Mithilfe der Hilbert-Transformation werden alle Fourierkomponenten der Funktion $f(t)$ um $\pi/2$ phasenverschoben. Damit erhält man für jede Horizontalposition ein analytisches Signal, dessen Realteil aus der ursprünglichen Spalte der Matrix \mathbf{W} gebildet wird und dessen Imaginärteil sich aus ihrer Hilbertransformierten ergibt.

Bild 3.4 zeigt das Ergebnis für die zu den ersten vier Eigenwerten gehörigen Bilder. Die obere Zeile zeigt jeweils die Realteile (vgl. Bild 3.3), in der unteren Zeile die um $\pi/2$ phasenverschobenen zugehörigen Imaginärteile. Besonders im Falle des Bildes λ_3 wird der erzielte Unterschied deutlich (siehe markierter Kreis). Während das markierte Objekt im Realteil kaum zu erkennen ist, wird es aufgrund der Phasenverschiebung im Imaginärteil deutlich sichtbar.

Da neben den „realen Bildern“ nun auch noch deren Imaginärteile berücksichtigt werden müssen, verdoppelt sich der Aufwand der anschließenden Bildverarbeitung zur Detektion kreisförmiger Objekte, die Detektionswahrscheinlichkeit wird jedoch deutlich erhöht. Das in diesem Abschnitt beschriebene Verfahren zur Gewinnung aussagekräftiger horizon-

taler Ansichten in geringer Anzahl aus einem dreidimensionalen Datensatz ist mit einem geringen Rechenaufwand verbunden und erfordert nur einen einzigen Eingabeparameter, der die Anzahl der Eigenwerte bzw. der Projektionsflächen festlegt. Die auf dieser Vorverarbeitung aufbauenden Operationen der Bildverarbeitung werden im folgenden Abschnitt detailliert.




Bild 3.4 Ergebnis der Hilbert-Transformation der Horizontalprojektionen in vertikaler Richtung. Das durch einen gestrichelten Kreis markierte Objekt ist im Realteil (oben) kaum zu erkennen, tritt aber aufgrund der Phasenverschiebung im Imaginärteil deutlich hervor.

3.2 Detektion kreisförmiger Objekte

Die Mehrheit der weltweit eingesetzten Minentypen haben eine runde Form, bzw. erscheinen unter den mit Georadaren zu erzielenden Auflösungen als kreisförmig. Dies rechtfertigt den Einsatz eines Algorithmus zur Detektion kreisförmiger Objekte zur Auswertung von horizontalen Schnittbildern (C-Scans). Für Objekte mit eher länglicher Form existieren alternative formbasierte Ansätze, die aber mit einem höheren Aufwand verbunden sind. Die Diskussion der einzelnen Verarbeitungsschritte erfolgt in der durch das Flussdiagramm von Bild 3.1 vorgegebenen Reihenfolge. Auf den ersten Verarbeitungsblock (Hauptachsentransformation, Hilbert-Transformation) wurde bereits in Abschnitt 3.1 eingegangen.

3.2.1 Hintergrundkompensation

Bei der Verarbeitung, aller in Kapitel 5 näher beschriebenen Datensätze, erwies es sich in einigen Fällen als vorteilhaft, in den mithilfe der Hauptachsen- und Hilbert-Transformation erhaltenen Projektionen eine Kompensation des Grauwert Hintergrunds vorzunehmen, um bspw. eine gleichmäßige Zunahme der Amplituden innerhalb eines Bildes in einer Richtung herauszurechnen. Damit lässt sich eine Korrektur der Amplitudenverteilung erzielen und die Kontraste Mine – Hintergrund verbessern. Die Tiefpasscharakteristik eines Bildes wird zu diesem Zweck mit einem zweidimensionalen Regressionsalgorithmus beschrieben. Die Koeffizienten des Polynoms werden so bestimmt, dass der quadratische Fehler der Abweichung zwischen dem Bild \mathbf{Z} und seiner Approximation minimiert wird. Die Terme von \mathbf{P} lauten $p_{ij} = x^i \cdot y^j; i, j = 0, 1, \dots, N_p$, damit ergibt sich der Fehler zu

$$E = \min_{\{A\}} \sum_x \sum_y |Z_{x,y} - \mathbf{A} \cdot \mathbf{P}^T|^2, \quad (3.7)$$

mit den zu \mathbf{P} gehörigen Koeffizienten a_{ij} als den Elementen des Vektors \mathbf{A} . Sowohl in x - als auch in y -Richtung wird die Ordnung zu $N_p = 3$ gewählt. Die resultierende Approximationsfläche wird vom Eingangsbild abgezogen. Diese Prozedur wird für alle Projektionen durchgeführt, darf aber nicht mit den in Abschnitt 2.1.8 beschriebenen Verfahren zur Unterdrückung des Oberflächenechos verwechselt werden.

3.2.2 Kantenverstärkung und Kantendetektion

Die nachfolgend beschriebene *Hough-Transformation* zur Detektion von Kreisen in Bildern benötigt Binärbilder als Input. Diese sollen möglichst so beschaffen sein, dass Pixel entlang von dominanten Kanten im Bild auf eins gesetzt sind, alle anderen auf Null.

Beim Betrachten der Bilder 3.3 und 3.4 fällt auf, dass die abgebildeten Minen sich oft aus einer konzentrischen Anordnung von Ringen ähnlicher Betragsamplitude, aber mit wechselndem Vorzeichen, zusammensetzen. Dieser Effekt beruht auf dem Wechsel des Vorzeichens in der Amplitude eines Diffraktionshyperboloids entlang einer horizontalen Schnittebene. Um die entlang kreisförmiger Kanten liegenden Pixel zu betonen, kann daher ein spezieller 2D-Filter eingesetzt werden, dessen Größe in Pixeln in etwa den Dimensionen der gesuchten Objekte entspricht. Bild 3.5 zeigt die verwendete Filtermaske: eine Kreisscheibe mit konstantem Wert 1, im Abstand von einigen Pixeln umgeben von einem Kreisring mit dem Wert -1 .

Die Faltung mit dieser Maske liefert in jeder Pixelposition des Bildes einen Näherungswert der Ableitung in radialer Richtung und betont somit den Übergang zwischen zwei konzentrischen Ringen hoher Amplitude mit unterschiedlichem Vorzeichen. Der innere Ring von Nullen, fungiert als „blinde Zone“ und dient zur Verminderung des Einflusses des Übergangsbereichs benachbarter Ringe.

Der Filter kann auch als polarer Kantendetektor verstanden werden, der die Differenz des Integrals über eine Kreisfläche und einen Kreisring innerhalb vorgegebener Radien beschreibt. Die Integration erfolgt bei digitalen Bilddaten in Form einer Summation und lässt sich schreiben als

$$\mu_{\Delta r} = \frac{\sum_{\forall x,y \mid a \leq \sqrt{x^2+y^2} \leq b} f(x,y)}{\sum_{\forall x,y \mid a \leq \sqrt{x^2+y^2} \leq b} 1}, \quad (3.8)$$

mit a und b als innerem bzw. äußerem Radius des Kreisrings. Der Wert des Integrals ist auf die Fläche normiert, der gesuchte polare Gradient ergibt sich als Differenz zweier Integrale, wobei für die Kreisscheibe $a = 0$ gilt.




Bild 3.5 Zweidimensionaler Filteroperator zur Verstärkung kreisförmiger Kanten in Bildern

Zur Detektion von Bildkanten lässt sich wiederum ein zweidimensionaler Filteroperator einsetzen. Einer der bekanntesten, der sogenannte *Sobel*-Operator, ist gegeben durch

$$h_s = \frac{1}{8} \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}. \quad (3.9)$$

Die Anwendung des Operators h auf ein Bild u liefert nach einer Schwellwertbildung der Gradienten g_x horizontale Kanten, die vertikal orientierten ergeben sich mit dem transponierten Filter analog aus g_y

$$g_x = h_s \otimes u, \quad g_y = h_s' \otimes u. \quad (3.10)$$

Durch eine gewichtete Überlagerung der beiden Filter lassen sich Kanten mit beliebiger Orientierung finden. Besteht keine Vorzugsrichtung werden die Gewichte gleich gewählt. Für die Prozessierung wurde allerdings ein Canny-Filter verwendet, der die besseren Ergebnisse liefert, da er zusätzlich eine *Non-Maximum-Unterdrückung* durchführt, d.h. Punkte, die keine lokalen Extrema darstellen, werden unterdrückt [Can86].

3.2.3 Hough-Transformation

Mithilfe einer Hough-Transformation lassen sich aus einem binären Kantenbild geometrische Strukturen wie Linien oder Kreise extrahieren [Hou62]. Dabei werden räumlich ausgedehnte Strukturen aus einem Bildraum in einen Parameterraum, den sogenannten Hough-Raum abgebildet, in dem sie an wenigen Stellen lokalisiert sind. Die Dimension des Hough-Raums hängt von der abzubildenden geometrischen Struktur ab. Eine beliebige Gerade ist im Zweidimensionalen durch ihre Steigung und den Achsenabschnitt definiert, der Hough-Raum wird folglich durch diese beiden Größen aufgespannt. Die entlang einer Geraden im Bildraum liegenden Pixel werden so in einem Punkt des Hough-Raums akkumuliert. Wenn die Gerade perfekt auf einen Punkt im Houghraum abgebildet werden kann, entspricht der Eintrag der Anzahl der Pixel längs der Gerade.

Ein Kreis mit Radius r_k und dem Mittelpunkt $(x = x_m, y = y_m)$ ist definiert durch

$$(x - x_m)^2 - (y - y_m)^2 = r_k^2, \quad (3.11)$$

mit den Wertepaaren (x, y) der auf dem Kreis im Bildraum liegenden Punkte. Für den dreidimensionalen Parameterraum $(\hat{x}, \hat{y}, \hat{z}) \in \mathfrak{R}^3$ gilt damit $(\hat{x} = x_m, \hat{y} = y_m, \hat{z} = r_k)$. Die Aufgabe der Hough-Transformation besteht nun darin, diese Größen aus den Punkten im Bildraum zu ermitteln.

Jeder Punkt im Bildraum wird im Parameterraum in einen Kegel abgebildet, dessen Spitze bei $\hat{z} = 0$ liegt und der sich bis ins Unendliche ausdehnt. Der Kegel entspricht der Ortskurve aller Parameterkombinationen, da sich ein Kreis nicht mit einem Punkt eindeutig beschreiben lässt. Werden mehrere Punkte in den Parameterraum abgebildet, so werden entsprechend viele sich schneidende Kegel erzeugt. Liegen diese Punkte alle auf demselben Kreis im Bildraum, so schneiden sich die Kegel alle im Punkt

($\hat{x} = x_m, \hat{y} = y_m, \hat{z} = r_k$). Offensichtlich kann bei gegebener Bilddimension und bekannter Objektgröße der Bereich von r_k auf einige wenige diskrete Werte eingegrenzt werden. Für die bearbeitete Aufgabenstellung richtet sich dieser Bereich nach der im Bild zu beobachtenden Größe der Minen. Die Diskretisierung des Parameterraums geschieht in der Regel entsprechend der Auflösung des Bildraums. Der Rechenaufwand ist proportional zur Anzahl der gesetzten Pixel des zu transformierenden Binärbilds.

Eine Veranschaulichung der Funktionsweise der Transformation zur Lokalisierung von Kreisen liefert Bild 3.6. Oben links ist der Bildraum mit dem zu transformierenden Binärbild dargestellt. Die anderen Bilder stellen Ebenen im Hough-Raum für jeweils einen konstanten Radius dar, der betreffende Wert ist angegeben. Jeder einzelne Pixel im Bildraum wird im Hough-Raum auf einen Kreis abgebildet, die Überlagerung gleicht einem *Doughnut*, der sich immer enger zusammenzieht, je näher man dem tatsächlichen Radius kommt, hier 3 bzw. 5 Pixel. Nur in diesem Fall schneiden sich alle Kreise im gesuchten Bildmittelpunkt. Die Gerade kann in keinem Fall fokussiert werden.




Bild 3.6 Beispielhafte Anwendung der Hough-Transformation zur Kreisdetektion. Das Binärbild oben links enthält zwei Kreise mit unterschiedlichen Radien von $r = 3$ bzw. $r = 5$ Pixeln. Nur bei den entsprechenden Radialebenen im Hough-Raum werden die Kreise korrekt fokussiert. Die Höhe der akkumulierten Einträge ist an den Balken abzulesen.

In der praktischen Anwendung stellt sich oft das Problem, dass die gesuchten Kreise im Bildraum nicht vollständig vorhanden sind oder keine perfekte Kreisform haben. Daraus resultiert eine schlechtere Lokalisierung des Kreises, d.h. die Maxima im Hough-Raum sind nicht optimal fokussiert, sondern „verschmiert“. Zur Selektion von Maxima wird dann eine Schwellwertbildung durchgeführt und nur diejenigen kreisförmigen Kanten,

deren Einträge im Houghraum größer als eine bestimmte Schwelle sind, werden weiterverarbeitet.

Der Umstand, dass mehr als nur ein Bild bzw. eine Projektion der gleichen Szene verarbeitet werden kann (vgl. Bild 3.4), wirkt sich hier vorteilhaft auf die Detektionswahrscheinlichkeiten aus, da sich die Kreisdetektionen verschiedener Projektionen kombinieren lassen. Die Art und Weise wie dies geschehen kann, wird in den folgenden Abschnitten erläutert.

3.2.4 Kombination mehrerer Projektionen

Der in Bild 3.1 dargestellte Verarbeitungsablauf zur Kreisdetektion wird auf die zu den ersten vier Eigenwerten korrespondierenden Bildern und den daraus erhaltenen Hilberttransformierten angewendet (vgl. Bild 3.4 und Abschnitt 3.1). Insgesamt sind damit pro Datensatz acht Bilder der gleichen Versuchsanordnung zu verarbeiten. Diese Anzahl bildet einen Kompromiss zwischen der Minimierung des Rechenaufwands und der Maximierung der zu berücksichtigenden Informationen.

Die gesamte Verarbeitungskette, mit den für eine einzelne Projektion erhaltenen Zwischenergebnissen, ist in Bild 3.7 dargestellt. Links die mithilfe der Hauptachsen-Transformation erhaltene Projektion $\text{Re}\{\lambda_1\}$ (vgl. Bilder 3.3 bzw. 3.4), daneben das Ergebnis der Hough-Transformation. Da der Parameterraum für Kreise dreidimensional ist, wird die dritte Dimension ($\hat{z} = r_k$) durch eine Maximabbildung kollabiert, d.h. an jeder Pixelposition wird das Maximum über alle Werte von r_k gesucht. Damit ergibt sich das zweite Bild von links aus:

$$\max_{\{R\}} \{ \text{Hou}\{\text{Re}(_)\} \} \quad . \quad (3.12)$$

Von den in diesem Beispiel vergrabenen sechs Minen sind nur fünf zu erkennen. Die Anwendung eines CFAR-Detektors² [Sko90] liefert das in der Mitte von Bild 3.7 dargestellte Resultat. CFAR-Detektoren werden vor allem in der Radarbildauswertung zur Detektion von Punktzielen eingesetzt. Der verwendete Detektor entspricht der in Bild 3.5 dargestellten Filtermaske, mit dem Unterschied, dass sowohl die im inneren Kreis als auch die im Ringbereich liegenden Pixel mit dem gleichen Vorzeichen gewertet werden. Gebildet wird das Verhältnis der innerhalb der Kreisscheibe (Radius a) liegenden Pixelwerte zur Summe der innerhalb des Rings (Radius b bis c) liegenden Werte

² Von engl. *Constant False Alarm Rate*.

$$\frac{\sum_{\forall x,y \mid 0 \leq \sqrt{x^2+y^2} \leq a} f(x,y)}{\sum_{\forall x,y \mid b \leq \sqrt{x^2+y^2} \leq c} f(x,y)}. \quad (3.13)$$

Damit ergibt sich ein Maß für den Kontrast eines Bildpixels zwischen seiner unmittelbaren Umgebung (innerer Kreis) und der weiter entfernten Umgebung (äußerer Ring).

Der nächste Schritt besteht aus einer Binarisierung des CFAR-Ergebnisses durch Anwendung eines adaptiven Schwellwerts. Der Schwellwert wird so gewählt, dass ein vorgegebener Prozentsatz der Bildpixel hoher Amplitude oberhalb der Schwelle liegt. Sind ausschließlich schwach ausgeprägte Maxima vorhanden, lässt sich so die Wahrscheinlichkeit erhöhen, dass auch diese in die weitere Verarbeitung mit einbezogen werden. Wenn allerdings keine auf tatsächlichen Objekten beruhenden Maxima existieren, erhöht sich bei dieser Vorgehensweise die Falschalarmrate. In diesem Fall wäre ein fester Schwellwert eine mögliche Alternative. Für die zur Verfügung stehenden Messdaten erwies sich eine Schwelle im Bereich von 10 – 20 % der Bildpixel als sinnvoll.

Das Ergebnis der Binarisierung ist im vierten Teilbild (von links) in Bild 3.7 zu sehen. Die durchgezogenen Kreise bezeichnen die Verlegeposition von fünf Metallminen, eine Plastikmine ist durch einen gestrichelten Kreis markiert. Neben den sechs Minen sind drei weitere Fehldetektionen zu erkennen, die allerdings anhand ihrer geringen Fläche nicht als gesuchte Objekte in Frage kommen und ausgeschlossen werden können.

Der bis hier beschriebene Verarbeitungsablauf wird parallel auf alle Projektionen angewendet. Danach stehen acht Binärbilder zur Verfügung, vier aus den Real- und weitere vier aus den Imaginärteilen der hilbertransformierten Projektionen λ_{1-4} (vgl. Bild 3.4). Da in den Einzelbildern nicht immer die gleichen „Flecken“ detektiert werden, können die N Binärbilder b_j über eine logische Verundung verknüpft werden:

$$\tilde{B} = \bigcup_{j=1}^N b_j, \quad \text{mit } N = 8. \quad (3.14)$$

Bei dieser Vorgehensweise werden allerdings die in jedem Einzelbild enthaltenen Fehldetektionen übernommen. Es ist daher sinnvoll, nur diejenigen Pixel zu berücksichtigen, die in mehreren Binärbildern Bestandteil einer Detektion sind. Formal lässt sich dies beschreiben durch:

$$\tilde{B} = \left(\sum_{j=1}^N b_j \right) \geq . \quad (3.15)$$

Da theoretisch nur tatsächlich vorhandene Objekte konsistent an der gleichen Position detektiert werden, lässt sich mit dieser Vorgehensweise eine deutliche Verringerung der Falschalarmrate erzielen. Die Wahl von δ ergibt sich als Kompromiss zwischen einer möglichst geringen Anzahl von Falschalarmen und einer maximierten Detektionswahrscheinlichkeit. Die Wahl von $\delta = 4$ erwies sich als geeignet.

Eine weitere Verminderung der Falschalarme wird möglich, wenn auch ihre geometrische Form im kombinierten Binärbild berücksichtigt wird. Mit einem kontourfindenden Verfahren zur Bestimmung geometrischer Attribute für jedes einfach zusammenhängende Gebiet in einem Binärbild, lassen sich Kriterien aufstellen, mit denen eine weitere Selektion durchgeführt werden kann [Mand90]. Jedes dieser Gebiete wird als ein hypothetisches Objekt aufgefasst und kann z.B. durch seine in Pixeln gemessenen Fläche, seinen Umfang und das Verhältnis von Höhe zu Breite des umschreibenden Rechtecks charakterisiert werden. Anhand dieser Attribute können Objekte, deren Fläche außerhalb eines definierten Bereichs liegt oder deren Aspektverhältnis deutlich von 1 abweicht, ausgeschlossen werden. Um ein „Ausfransen“ der Randkurve zu vermeiden, wird anschließend von den verbleibenden Objekten die konvexe Hülle berechnet.

Das Endergebnis der Prozessierung ist in Bild 3.7 (e) zu sehen. Alle acht Binärbilder wurden kombiniert und anhand geometrischer Formattribute eine Selektion vorgenommen. Das in diesem Abschnitt beschriebene Detektionsverfahren wurde auf alle zur Verfügung stehenden Datensätze angewendet. Die Ergebnisse werden in Kapitel 6 diskutiert.




Bild 3.7 Verarbeitungskette der Objektdetektion: a) Ausgangsbild (aus HAT, vgl. Bild 3.3); b) Ergebnis der Hough-Transformation zur Kreisdetektion; c) Anwendung eines CFAR-Detektors auf b); d) Binarisierung; e) logische Verknüpfung aller Binärbilder, Anwendung von Formkriterien zur Selektion. Die tatsächlichen Positionen der vorhandenen Metall- bzw. Plastikminen sind durch Kreise markiert (durchgezogene bzw. gestrichelte Linie).

3.3 Kombination von Objektdetektion und Signalklassifikation

Ein Detektionsverfahren liefert immer nur eine binäre Entscheidung, eine Aussage über Typ oder Gefährdungspotenzial eines vermuteten Objekts kann nicht getroffen werden. Dies ist nur dann möglich, wenn weitere Informationen direkt aus den gemessenen Signalen gewonnen werden können. In dem in dieser Arbeit entwickelten Verfahren dient die Detektion als Vorstufe zur Klassifikation. Nur die innerhalb der Begrenzungslinie eines hypothetischen Objekts liegenden A-Scans werden für die weitere Verarbeitung herangezogen (s. Teilbild e) in Bild 3.7). Damit lässt sich eine enorme Reduktion des für die Merkmalsextraktion erforderlichen Rechenaufwandes erzielen, da nur ein Bruchteil der gemessenen Signale weiterverarbeitet werden müssen. Die Vorgehensweise ist in Bild 3.8 graphisch veranschaulicht.




Bild 3.8 Die Detektion dient als Vorstufe zur Klassifikation. Nur die innerhalb der Begrenzungslinie (weiß) einer Detektion liegenden Radarsignale werden für die weitere Verarbeitung herangezogen.

Das in diesem Kapitel vorgestellte Detektionsverfahren bringt gegenüber einem rein auf der Verarbeitung von vertikalen Tiefenschnitten beruhenden Ansatz deutliche Vorteile, da die Prozessierung horizontaler Schnittflächen eine Auswertung von Formkriterien erlaubt. In diesem Zusammenhang am wichtigsten sind zum einen die Fläche eines hypothetischen Objekts, zum anderen das Aspektverhältnis des umschreibenden Rechtecks. Auf diesem Wege lässt sich eine drastische Reduktion der Falschalarmrate erreichen.

Der Ansatz zur Kombination der in mehreren Horizontalflächen erhaltenen Detektionen über eine logische Verknüpfung eignet sich ferner auch für den Einsatz in solchen GPR-Systemen, bei denen der Boden gleichzeitig mit mehreren Antennen unterschiedlicher Bandbreite – und daher unterschiedlicher Eindringtiefe – bestrahlt wird.

Die beschriebene Vorgehensweise bietet sich immer dann an, wenn die Bodenoberfläche flächig abgetastet wird und die Messdaten somit in Form eines (x,y,t) -Datenwürfels vorliegen. Wie bereits bemerkt, ist dies z.B. dann der Fall, wenn das zu untersuchende Terrain mit einem fahrzeuggestützten Array-System oder mit einem quer zur Fahrtrichtung bewegten Sensor abgetastet wird. In diesem Fall kann die Hauptachsentransformation anstatt in vertikaler Richtung auch in Fahrtrichtung ausgeführt werden.

Wie hier nicht weiter ausgeführte Rechnungen ergaben, konzentriert sich das Oberflächenecho hauptsächlich im ersten Eigenwert. Wenn dieser demzufolge bei der Rekonstruktion nach (3.4) unterdrückt wird, lässt sich eine deutliche Reduktion dieses störenden Signalanteils erzielen. Der Ansatz funktioniert allerdings nur solange, wie sich die Oberflächentopographie in der Koordinatenrichtung, in der die Transformation ausgeführt wird, nur geringfügig ändert.

4. Extraktion von Merkmalen aus Zeitsignalen

Ein Georadar liefert an jedem Messpunkt Zeitsignale, die ein bestimmtes Maß an Information über den durchleuchteten Untergrund enthalten. Während für manche Aufgabenstellungen eine integrale Größe, wie z.B. die Signalenergie, zur Beantwortung der Frage *wo* sich ein vergrabenes Objekt befindet ausreichend sein kann, ist zur Feststellung um *was* es sich handelt, eine Betrachtung der Signalstruktur erforderlich.

Zu diesem Zweck werden in diesem Kapitel Methoden der Zeit-Frequenz-Analyse zur Bildung charakteristischer Merkmale aus eindimensionalen Zeitsignalen untersucht, mit deren Hilfe eine Trennung in die Klassen Mine, andere Objekte und Hintergrund vorgenommen werden kann. In Abschnitt 4.2 wird kurz auf die bekanntesten Vertreter der linearen und quadratischen Zeit-Frequenz-Analyse eingegangen. Einen Schwerpunkt der Untersuchungen bilden die Wavelet-Verfahren, deren Stand in den Abschnitten 4.3 bis 4.5 wiedergegeben wird. Im Falle der Wavelet-Packet-Transformationen wird insbesondere auf die Frage eingegangen, welche Basis am besten zur Signaltrennung geeignet ist. Es wird eine Alternative zu den bekannten Methoden vorgestellt, bei der die Wahl der Basis direkt aus der erzielten Erkennungsleistung abgeleitet werden kann.

Eine besondere Bedeutung kommt der Verwendung verschiebungsinvarianter Transformationen zu. Ein effizienter Ansatz zur entsprechenden Modifikation der Wavelet-Transformation, der auch auf *Wavelet-Packets* und *Multiwavelets* erweiterbar ist, wird in Abschnitt 4.6 vorgestellt.

Methoden zur optimalen Selektion bzw. Reduktion von Merkmalen, gebildet anhand von Transformationskoeffizienten, werden in Abschnitt 4.7 vorgestellt. Eine Alternative zu den orthogonalen Transformationen bilden die in Abschnitt 4.8 beschriebenen Wavelet-Netze. Schließlich wird in Abschnitt 4.9 kurz auf weitere bekannte Methoden der Zeit-Frequenz-Analyse eingegangen. Die mit den verschiedenen Verfahren erzielten Erkennungsleistungen werden in Kapitel 6 einander gegenübergestellt und bewertet.

4.1 Die Bedeutung der Merkmalsextraktion

Die Bildung von Merkmalen aus Signalen oder Bildern hat eine zentrale Bedeutung für die Mustererkennung und stellt mit die größte Herausforderung bei der Lösung einer Klassifikationsaufgabe dar. Gleichgültig ob es sich um seismische Daten, Börsenkurse, Musikaufzeichnungen oder Satellitenbilder handelt, die eingesetzten Sensoren liefern

meist pro Zeiteinheit eine große Menge Daten. Daraus ergibt sich die Anforderung, je nach Aufgabenstellung, möglichst die wichtige von der unwichtigen bzw. redundanten Information zu trennen. Diese Strategie wird auch als *Dimensionsreduktion* bezeichnet. Je geringer die Anzahl der berücksichtigten Dimensionen ist, desto geringer ist der Aufwand des Klassifikators und desto besser sind seine Fähigkeiten zur Generalisierung des Problems.

Oft lassen sich markante Merkmale in der Signal- oder Bildanalyse durch Kanten, Spikes oder transiente Übergänge in Form einer lokalen Information, entweder im Zeit- oder Frequenzbereich oder in beiden beschreiben¹. Um z.B. die durch unterirdische Nuklear-explosionen verursachten seismischen Signale von natürlichen Erdbebensignalen zu unterscheiden, kann man sich auf die Untersuchung der Frequenzcharakteristik der Primärwellen stützen, die innerhalb eines bestimmten Zeitfensters auftreten.

Statistische Ansätze machen kaum Annahmen über die Struktur der betrachteten Daten, während sogenannte syntaktische oder strukturelle Methoden versuchen, diese möglichst gut zu beschreiben. Voraussetzung für eine erfolgreiche Anwendung ist, dass erkennbare Strukturen überhaupt vorhanden sind. Während es für Menschen ganz natürlich ist, strukturelle Merkmale zur visuellen Orientierung und Erkennung zu verwenden, erweist es sich jedoch oft als sehr schwierig, diese Art der Verarbeitung auf Computern zu implementieren. Die Anwendungen der syntaktischen Merkmalsextraktion beschränken sich daher auf spezifische Probleme, wie z.B. die Erkennung von Objekten in Bildern anhand ihrer Umrisslinien (Kanten). Letztere lassen sich eventuell in eine mathematisch handhabbarere Beschreibung transformieren. Dies gilt z.B. für die Detektion von Kreisen (s. Abschnitt 3.2). Allerdings enthalten auch die statistischen Methoden Regeln des strukturellen Ansatzes, da bei der Verwendung von Orthogonaltransformationen Signale ebenfalls in Grundbausteine zerlegt werden (bspw. in Sinus- und Kosinusschwingungen bei der FFT).

Der Ablauf des Klassifikationsprozesses ist in Bild 4.1 graphisch dargestellt.




Bild 4.1 Modell der Klassifikation mit dem Schritt der Dimensionsreduktion.

¹ In Bezug auf Bilder umfasst dies auch räumliche Koordinaten und Wellenzahlen.

4.2 Klassische Verfahren der Zeit-Frequenz-Analyse

Das primäre Ziel der Signalanalyse ist diejenigen Informationen aus einem Signal „herauszufiltern“, die für eine bestimmte Aufgabenstellung relevant sind. Zeit-Frequenz-Repräsentationen kombinieren die Analyse des Zeit- mit der des Frequenzbereichs und können ein aufschlussreiches Bild der zeitlichen Lokalisierung spektraler Charakteristiken liefern. Die Anwendungen umfassen alle Bereiche der Signalverarbeitung: Signalkompression, Filterung, Rauschunterdrückung, Detektion, Klassifikation und Visualisierung. Die gebräuchlichen Transformationen lassen sich in zwei Gruppen einteilen: die der *linearen* Methoden, mit der *Fourier-Kurzzeit-Spektralanalyse* und der *Wavelet-Transformation* als den bekanntesten Vertretern, und die der *quadratischen* Methoden mit der fundamentalen Wigner-Ville-Verteilung.

Kernpunkt der linearen Methoden ist die Zerlegung eines Signals $x(t)$ in eine Anzahl von N Bestandteilen oder Zeit-Frequenz-Atomen nach dem Schema

$$x(t) = \sum_{k=0}^{N-1} a_k \Phi_k(t), \quad (4.1)$$

mit $\Phi_k(t)$ als den Zeit-Frequenz-Atomen (oder Basisfunktionen) und a_k als den zugehörigen Koeffizienten. Wünschenswerte Eigenschaften der Basisfunktionen sind Orthogonalität, gute Lokalisierungseigenschaften sowohl im Zeit- als auch im Frequenzbereich sowie die Möglichkeit der effizienten Implementierung auf einem Rechner, also einem möglichst geringen Rechenaufwand.

Quadratische Methoden beruhen auf einer Schätzung des momentanen Leistungsspektrums, mithilfe einer bilinearen Operation auf dem Signal $x(t)$.

4.2.1 Kurzzeit-Fouriertransformation

Während die klassische Fouriertransformation von stationären Signalen ausgeht, werden bei der Kurzzeit-Spektralanalyse lokale Frequenzspektren betrachtet, indem eine zeitlich lokale Fensterfunktion eingeführt wird. Betrachtet wird ein Zeitsignal $x(t)$, das innerhalb eines endlichen Fensters $g(t-\tau)$, zentriert bei t , als stationär angenommen wird. Die Fouriertransformation des gefensternten Signals liefert die als STFT³ bezeichnete Transformation, welche das Signal in die zweidimensionale (t,f) -Ebene abbildet

$$STFT(t, f) = \int x(\tau) g^*(\tau - t) e^{-j 2\pi f \tau} d\tau, \quad (4.2)$$

³ Von engl. *Short Time Fourier Transform*.

mit $g^*(t)$ als der konjugiert komplexen Funktion von $g(t)$. Die Zeit-Frequenzauflösung der STFT ist einzig durch die Wahl der Fensterfunktion festgelegt. Für eine Fensterfunktion $g(t)$ mit der Fouriertransformierten $G(f)$ lässt sich die zeitliche Auflösung Δt und die Frequenzauflösung Δf , auch als mittlere quadratische Bandbreite bezeichnet, angeben als [Mar87]

$$\Delta f^2 = \frac{\int f^2 |G(f)|^2 df}{\int |G(f)|^2 df}. \quad (4.3)$$

Die korrespondierende mittlere quadratische zeitliche Ausdehnung ist definiert durch

$$\Delta t^2 = \frac{\int t^2 |g(t)|^2 dt}{\int |g(t)|^2 dt}. \quad (4.4)$$

Die Auflösung in Zeit und Frequenz kann nicht beliebig klein werden, ihr Produkt ist nach unten durch das Heisenberg'sche Unschärfepinzipp begrenzt [Pap85]

$$\Delta t \cdot \Delta f \geq \frac{1}{4\pi}, \quad (4.5)$$

d.h. eine hohe Zeitauflösung geht immer mit einer niedrigen Frequenzauflösung einher und umgekehrt. Eine gaußförmige Fensterfunktion ist die einzige Funktion für die das Gleichheitszeichen in der Ungleichung (4.5) gilt. Die STFT mit diesem speziellen Fenster wurde erstmals von Gabor eingeführt und wird daher auch als *Gabor-Transformation* bezeichnet [Gab46].

Bei Zeit-Frequenz-Transformationen der Form (4.2) ist mit der Wahl der Fensterfunktion sowohl die Zeit- als auch die Frequenzauflösung für alle Zeiten bzw. alle Frequenzen festgelegt. Dies entspricht einer Kachelung der (t,f) -Ebene in rechteckige Zellen gleicher Fläche, definiert durch das Zeit-Bandbreiten-Produkt (4.5). Zum Vergleich: eine Dirac-Basis hat eine optimale Lokalisierung in der Zeit, aber keine Frequenzauflösung, während die Fourierbasis optimale Frequenzlokalisierung aber keine Zeitauflösung besitzt. Die Kacheln sind in diesem Fall also senkrecht zueinander orientiert, vgl. Bild 4.3.

Der Umstand, dass die Elemente in welche die Zeit-Frequenz-Ebene bei beliebiger Wahl der Abtastung eingeteilt ist, immer gleich sind, stellt einen wesentlichen Nachteil der STFT dar.

4.2.2 Quadratische Zeit-Frequenz-Transformationen

Die quadratischen oder bilinearen Transformationen bilden eine Alternative zur linearen STFT. Die Fundamentalform der quadratischen Zeit-Frequenz-Transformationen bildet die *Wigner-Ville-Verteilung* (WVD) [Wig71], die eine zweidimensionale Beschreibung der Signalenergie in der Zeit-Frequenz-Ebene erlaubt:

$$WVD(t, f) = \frac{1}{2\pi} \int_{-\infty}^{\infty} x(t + \tau/2) x^*(t - \tau/2) e^{-j2\pi\tau} d\tau. \quad (4.6)$$

Die WVD ist eine nichtlineare Transformation des Signals $x(t)$ und hat die unangenehme Eigenschaft des Auftretens von Kreuztermen, die durch die Quadrierung des Signals entstehen. Dies hat zur Folge, dass die Transformation der Summe zweier Signale sich durch die Kreuzterme von der Summe der beiden transformierten Signale unterscheidet. Mithilfe einer Fensterfunktion $f(t)$ in Zeitrichtung lassen sich in Frequenzrichtung oszillierende Terme glätten. Diese Form einer quadratischen Transformation wird auch als Pseudo-Wigner-Ville-Verteilung (PWVD) bezeichnet:

$$PWVD(t, f) = \frac{1}{2\pi} \int_{-\infty}^{\infty} f(\tau) x(t + \tau/2) x^*(t - \tau/2) e^{-j2\pi\tau} d\tau \quad (4.7)$$

Damit ist erkennbar, dass die WVD bzw. PWVD aus mehreren Gründen für die Mustererkennung nur bedingt geeignet ist:

- Die schon oben angesprochenen Interferenz- oder Kreuzterme generieren eine artifizielle Information in den Daten, die zur Beeinträchtigung der Erkennungsleistung führen kann, da der Klassifikator etwas mitlernt, was eigentlich nicht vorhanden ist.
- Der erforderliche Rechenaufwand ist deutlich größer als der einer FFT oder Wavelet-Transformation.
- Quadratische Transformationen erzeugen eine große Redundanz, da nach der Transformation eine bedeutend höhere Anzahl diskreter Werte weiterverarbeitet werden muss als vorher. Dies gilt insbesondere wenn die Fensterfunktion Abtastwert für Abtastwert in der Zeitrichtung verschoben wird (gilt auch bei der STFT).
- Nach Durchführung der Transformation steht man daher vor dem Problem, Merkmale aus einer zweidimensionalen Verteilung zu gewinnen, d.h. man hat das Problem der Merkmalsextraktion aus eindimensionalen Signalen lediglich in einen höherdimensionalen Raum verlagert.

Die PWVD bietet zwar eine hohe Auflösung, die Verwendung einer anderen Repräsentation aber, mit schlechterer Auflösung und einer angepassten Kachelung der Zeit-Frequenz-Ebene, erfordert deutlich weniger Koeffizienten. Genau dieser Umstand ist die Motivation für die Verwendung der im folgenden Abschnitt beschriebenen Wavelet-Transformation.

4.3 Wavelet-Transformation

In der Literatur tauchte der Begriff der Wavelet-Transformation (WT) 1984 [Gros84] zum ersten Mal auf. Schon bald erwies sich die WT als ein leistungsfähiges Werkzeug in der Signalanalyse, welches Ideen aus der Mathematik, der Physik und der Signalverarbeitung vereint und eine sprunghafte Entwicklung neuer mathematischer Methoden auslöste. Einen Überblick über die Geschichte und die ausführlichen mathematischen Grundlagen der Wavelet-Transformation findet sich in den Arbeiten von [Chu92], [Dau92] und [Mey92].

In den folgenden Abschnitten wird auf die wesentlichen mathematischen Grundlagen der Wavelet-Transformation, der Wavelet-Packet-Transformation und der Multiwavelet-Transformation eingegangen. Eine besondere Bedeutung kommt der Betrachtung sogenannter verschiebungsinvarianter Transformationen zu, eine Eigenschaft, die für die Bildung von Merkmalen aus Wavelet-Koeffizienten von großer Wichtigkeit ist.

4.3.1 Kontinuierliche Wavelet-Transformation

Die kontinuierliche Wavelet-Transformation (engl. *Continuous Wavelet Transform*, CWT) analysiert ein Signal durch Berechnung des L^2 -Skalarprodukts mit dilatierten oder verschobenen Versionen eines sogenannten *Wavelets* Ψ , definiert durch

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \left(\frac{t-b}{a} \right). \quad (4.8)$$

Die Basisfunktionen $\psi_{a,b}(t)$ entstehen durch Dilatation und Translation einer prototypischen Funktion $\psi(t)$, die auch als „Mutter-Wavelet“ bezeichnet wird. Der Vorfaktor in (4.8) dient zur Normierung des Wavelets. Die kontinuierliche Wavelet-Transformation eines Signals $x(t)$ ergibt sich aus dem Innenprodukt der Waveletfunktionen mit dem zu untersuchenden Signal:

$$CWT_x(a,b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt = \langle x(t), \psi_{a,b}(t) \rangle. \quad (4.9)$$

Der Skalenparameter a lässt sich mit dem Maßstab einer Landkarte vergleichen: große Werte von a führen zu einer Dehnung des Wavelets, d.h. nur die globalen oder tief-frequenten Eigenschaften eines Signals werden betrachtet. Eine Verkleinerung von a bewirkt eine Stauchung des Wavelets, somit können auch schnelle zeitliche bzw. räumliche Variationen erfasst werden. Die Variation von a ermöglicht also die Untersuchung eines Signals in verschiedenen Frequenzbändern, der Parameter b die separate Betrachtung unterschiedlicher Signalausschnitte.

Um die Auflösungsbegrenzung der STFT zu überwinden (s. Abschnitt 4.2.1), kann man sich vorstellen die Auflösungen Δt und Δf in der Zeit-Frequenz-Ebene zu variieren, um so zur Eigenschaft der Mehrfachauflösung (engl. *Multiresolution*) zu gelangen. Insbesondere wenn man sich die Analyse als Filterbank vorstellt, muss die zeitliche Auflösung mit der zentralen Frequenz des Analysefilters anwachsen. Daher gilt:

$$\Delta f \sim f. \quad (4.10)$$

Anstelle einer gleichabständigen Aufteilung der Frequenzachse ergibt sich so eine logarithmisch gleiche Einteilung. Wenn (4.10) erfüllt ist, ändern sich sowohl Δf als auch Δt mit der Frequenz. Beide erfüllen die Heisenberg-Bedingung (4.5), aber nun wird die Zeitauflösung bei hohen Frequenzen beliebig hoch, während die Frequenzauflösung bei niedrigen Frequenzen beliebig gut wird, wie Bild 4.2 veranschaulicht.




Bild 4.2 Aufteilung der Frequenzachse im Fall a) der STFT (gleichförmig) und b) der WT (logarithmisch).

Die verschiedenen Einteilungen der Zeit-Frequenz-Ebene sind in Bild 4.3 noch einmal dargestellt.




Bild 4.3 Einteilung der Zeit-Frequenz-Ebene mittels der Koeffizienten der verschiedenen diskreten Transformationen.

Bedingungen zur Existenz von Wavelets

Ein Wavelet hat eine zeitlich endliche Ausdehnung, in dem Sinne, dass seine Amplitude vom Zentrum weg auf Null abfällt, d.h. einen kompakten Träger besitzt. Daher der Name Wavelet, für „kleine Welle“, der außerdem darauf hindeutet, dass es sich um eine oszillierende Funktion handelt. Dazu muss folgende Bedingung erfüllt sein:

$$0 < c := 2\pi \int_{\mathfrak{R}} \frac{|\hat{(\cdot)}|^2}{|\cdot|} d < \infty, \quad (4.11)$$

mit $\hat{(\cdot)}$ als der Fourier-Transformierten von (t) . Nicht jede Funktion (t) führt zu brauchbaren Transformationen. Mit der Definition in (4.9) ist die Invertierbarkeit der Transformation für alle $f \in L^2(\mathfrak{R})$ nur gegeben, wenn die Funktion Ψ eine weitere Zulässigkeitsbedingung hinsichtlich ihres Mittelwerts erfüllt:

$$\int_{\mathfrak{R}} (t) dt = 0 \Leftrightarrow \hat{(\cdot)}(0) = 0. \quad (4.12)$$

Die Fourier-Transformierte ist derart lokalisiert, dass nur Frequenzen eines bestimmten Frequenzbereichs abgedeckt werden. Außerhalb dieses Bereichs fällt sie ab, wobei der Abfall zu hohen Frequenzen hin mit der *Glattheit* der Funktion korrespondiert. Je glatter die Funktion ist, desto steiler ist dieser Abfall. Zu tiefen Frequenzen hin wird der Abfall der Fourier-Transformierten durch die Anzahl der verschwindenden Momente bestimmt. Ein Wavelet hat N verschwindende Momente, wenn für $0 \leq p < N$ gilt

$$\int_{\mathfrak{R}} t^p (t) dt = 0. \quad (4.13)$$

Da nach (4.12) die Fourier-Transformierte für $= 0$ verschwindet und auf ein Intervall beschränkt ist, zeigen Wavelets eine *Bandpass-Charakteristik*.

Vor allem für Anwendungen in der Datenkompression, aber auch für die Bildung von Merkmalen aus Wavelet-Koeffizienten, ist die Wahl des geeigneten Wavelets von großer Wichtigkeit. Die Auswahl sollte immer so erfolgen, dass ein Signal mit einer möglichst geringen Anzahl von Koeffizienten repräsentiert werden kann. Für die in dieser Arbeit untersuchten Radarsignale (vgl. Bild 2.2), die keine plötzlichen Sprünge oder Unstetigkeiten im Signalverlauf aufweisen, ist die Verwendung eines Wavelets mit einem möglichst glatten Verlauf von Vorteil.

Bild 4.4 zeigt drei unterschiedliche Wavelets: links die einfachste Form eines Haar-Wavelets, in der Mitte ein Daubechie-4-Wavelet und rechts ein Spline-Wavelet. Zur Repräsentation von GPR-Signalen erweist sich das Spline-Wavelet als sehr gut geeignet. Auf ein „Rezept“ zur Auswahl eines geeigneten Wavelet-Typs wird in Abschnitt 4.3.4 noch näher eingegangen.




Bild 4.4 Beispiele für den prinzipiellen Verlauf von Wavelets: a) ein Haar-Wavelet, b) ein Daubechie-4-Wavelet, c) ein symmetrisches Spline-Wavelet.

Die Diskretisierung von (4.9) gestattet zwar die Implementierung der CWT auf einem Rechner, liefert aber keine wirklich diskrete Transformation, sondern nur eine abgetastete Version der kontinuierlichen Transformation, verbunden mit einer aufwendigen Berechnung zahlreicher Innenprodukte. Außerdem weist sie, was die Rücktransformation angeht, einen hohen Grad an unnötiger Redundanz auf.

Ein Durchbruch in dieser Richtung wurde 1987 erzielt, als der von S. Mallat geprägte Begriff der *Multiresolution-Analyse* (MRA) zur Bildkompression [Mal87, Mal89] mit der Idee der Wavelets verknüpft wurde. Der Übergang zur diskreten Wavelet-Transformation (DWT) erfolgt durch die Wahl der Parameter $a = a_0^j$ bzw. $b = k \cdot b_0 \cdot a_0^i$, mit ganzzahligen Werten von j und k . Für die Implementierung auf einem Rechner wird üblicherweise $a_0 = 2$ und $b_0 = 1$ gewählt, die so erhaltene Basis wird als *dyadische Basis* bezeichnet. Die diskreten Waveletfunktionen sind dann definiert durch:

$$\psi_{i,k}(t) = 2^{-i/2} \psi(2^{-i}t - k), \quad (4.14)$$

analog zum Übergang von der kontinuierlichen Fourier-Transformation zur Fourier-Reihe. Damit ist eine wesentlich höhere Effizienz möglich. Die dyadische Form vereinfacht auch die Anforderungen an das Mutter-Wavelet um eine weitere wünschenswerte Eigenschaft: die Orthogonalität der Analysefunktionen ermöglicht eine effiziente Repräsentation. Die dyadische DWT ist die gebräuchlichste Form und wird daher im Folgenden der Einfachheit halber als Wavelet-Transformation bezeichnet.

4.3.2 Multiresolution-Analyse und Diskrete Wavelet-Transformation

Mit der von Mallat eingeführten *Multiresolution-Analyse* lässt sich ein Zusammenhang herstellen zwischen der diskreten Wavelet-Transformation und perfekt rekonstruierenden Filterbänken mit kritischer Abtastung, einem rekursiven Verfahren zur Berechnung der DWT sowie einer Vorschrift zur Konstruktion zulässiger Wavelet-Basisfunktionen.

Die MRA lässt sich auf alle quadratisch integrierbaren Funktionen aus $L^2(\mathfrak{R})$ anwenden. Sie unterteilt den Raum in Unterräume, sogenannte Skalierungsräume V_i , die geschachtelt sind:

$$\{0\} \subset \cdots \subset V_2 \subset V_1 \subset V_0 \subset V_{-1} \subset V_{-2} \subset \cdots \subset L^2(\mathfrak{R}). \quad (4.15)$$

Jeder dieser Skalierungsräume beschreibt die Funktion in einer anderen Auflösung, größeres i entspricht dabei einer „gröberen“ Auflösung. Es gilt

$$\bigcap_{i \in \mathbb{Z}} V_i = \{0\} \quad \text{und} \quad \overline{\bigcup_{i \in \mathbb{Z}} V_i} = L^2(\mathfrak{R}). \quad (4.16)$$

In jedem Raum existieren Basisfunktionen, die sogenannten Skalierungsfunktionen, die zusammen mit ihren Translationen den Raum orthonormal aufspannen. Die Darstellungen einer Funktion in benachbarten Skalierungsräumen sind einander ähnlich, wenn eine Funktion $f(t)$ Element von V_i ist, so ist $f(2t)$ Element von V_{i-1} :

$$f(t) \in V_i \Leftrightarrow f(2t) \in V_{i-1}. \quad (4.17)$$

Der Waveletraum W_i wird als orthogonales Komplement zweier benachbarter Skalierungsräume V_i und V_{i-1} definiert, so dass V_i als direkte Summe

$$V_i = V_{i+1} \oplus W_{i+1} \quad \text{und} \quad V_{i+1} \perp W_{i+1} \quad (4.18)$$

darstellbar ist. Zusätzlich gilt, dass alle Waveleträume zueinander orthogonal sind

$$\bigcap_{\forall i} W_i = \{0\}. \quad (4.19)$$

Beim Übergang von V_i nach V_{i+1} gehen „Details“ verloren, diese werden auf den Raum W_i abgebildet. Um ein beliebiges Signal des Raumes V_i fehlerfrei rekonstruieren zu können, sind somit zwei Signale notwendig: Das Signal des Skalierungsraumes V_{i+1} und das Signal des Wavelettraumes W_{i+1} . Die den Waveletraum aufspannenden Basisfunktionen sind die Waveletfunktionen $\psi(t)$. Durch Iteration ergibt sich, dass ein beliebiger Skalierungsraum als die direkte Summe der Waveleträume größerer Indizes i bestimmt werden kann

$$V_i = W_{i+1} \oplus W_{i+2} \oplus W_{i+3} \oplus W_{i+4} \cdots, \quad (4.20)$$

d.h. ein Signal mit einer gegebenen Auflösung lässt sich als Summe von Detailsignalen darstellen. Die Waveleträume enthalten die „Details“ der Funktion. Aus der Orthogonalität der Waveleträume ergibt sich, dass ein bestimmtes Detail auf *genau einen* Waveletraum abgebildet wird, Signale aus benachbarten Waveleträumen also unkorreliert sind.

Ausgangspunkt für die weitere mathematischen Formulierung ist die Zwei-Skalen-Relation $V_0 \subset V_{-1}$ und folgendes Theorem, nach dem eine *Skalierungsfunktion* $\phi(t)$ in V_0 existiert, so dass

$$\{\phi_k^i(t)\}_{k \in \mathbb{Z}} = \{2^{-i/2} \phi(2^{-i}t - k)\}_{k \in \mathbb{Z}} \quad (4.21)$$

eine orthonormale Basis in V_i darstellt. Die Funktion $\phi(t)$ muss eine Zwei-Skalen-Differenzgleichung erfüllen, in der die verschachtelte Struktur der V_i -Räume zum Ausdruck kommt:

$$\phi(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_0(k) \cdot \phi(2t - k). \quad (4.22)$$

Da für die Waveleträume wegen (4.18) auch $W_0 \in V_{-1}$ gilt, kann eine entsprechende Gleichung auch für die Basisfunktionen der Waveleträume, die sogenannten *Waveletfunktionen*, aufgestellt werden:

$$\psi(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} g_0(k) \cdot \phi(2t - k). \quad (4.23)$$

(4.22) wird als *Waveletgleichung* bezeichnet. (4.22) und (4.23) bilden die Schlüsselgleichungen zur Wavelet-Transformation. Die Funktionen

$$\{\Psi_k^i(t)\}_{k \in \mathbb{Z}} = \{2^{-i/2} \psi(2^{-i}t - k)\}_{k \in \mathbb{Z}} \quad (4.24)$$

beschreiben die zusätzlichen Details zweier aufeinanderfolgender Approximationen. Die Filterkoeffizienten $h_0(k)$ bzw. $g_0(k)$ ergeben sich aus dem inneren Produkt der Skalierungs- bzw. Waveletfunktionen mit ihren skalierten und translatierten Versionen

$$h_0(k) = \langle \phi(t), \sqrt{2} \phi(2t - k) \rangle \quad \text{bzw.} \quad g_0(k) = \langle \psi(t), \sqrt{2} \phi(2t - k) \rangle. \quad (4.25)$$

Nachfolgend werden die Bedingungen an die Skalierungsfunktionen und deren Bedeutung für die Koeffizienten noch einmal zusammengefasst

$$\int_{\mathfrak{R}} \phi(t) dt = 1 \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} h_0(k) = \sqrt{2}, \quad (4.26)$$

$$\int_{\mathfrak{R}} \phi(t) \phi(t - m) dt = \delta(m) \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} h_0(k) h_0(k - 2m) = \delta(m), \quad (4.27)$$

$$\{\phi(t - m)\} \text{ orthonormale Basis von } V_0 \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} |h_0(k)|^2 = 1, \quad m \in \mathbf{Z}. \quad (4.28)$$

Für die Waveletfunktionen gilt entsprechend

$$\int_{\mathfrak{R}} \psi(t) dt = 0 \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} g_0(k) = 0, \quad (4.29)$$

$$\int_{\mathfrak{R}} \psi(t) \psi(t - m) dt = \delta(m) \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} g_0(k) g_0(k - 2m) = \delta(m), \quad (4.30)$$

$$\{\psi(t - m)\} \text{ orthonormale Basis von } W_0 \quad \rightarrow \quad \sum_{k \in \mathbf{Z}} |g_0(k)|^2 = 1. \quad (4.31)$$

Die Berechnung der diskreten Wavelet-Transformation erfolgt auf Grundlage der Skalierungs- und Waveletgleichungen (4.22) und (4.23) mittels eines rekursiven Berechnungsverfahrens. Methoden zur Lösung dieser Gleichungen findet man bei [Str96]. Die Filterkoeffizienten $h_0(k)$ und $g_0(k)$ kann man als Lösung von trigonometrischen Polynomen erhalten. Je höher die Anzahl der verschwindenden Momente des Wavelets, siehe (4.13), umso höher der Grad der in V_0 darstellbaren Polynome. Gilt z.B. $p = 2$, können lokal konstante oder lineare Funktionen repräsentiert werden.

Für eine diskrete Signalfolge $s(n)$ existiert nur eine begrenzte Anzahl von Auflösungsstufen, insbesondere ist die feinste Auflösung durch die Abtastung selbst vorgegeben. Diese Stufe wird hier zu $i = 0$ gesetzt. Für die Skalierungskoeffizienten s_{i+1} der $(i+1)$ -ten Stufe folgt dann

$$s_{i+1}(n) = \sum_k h_0(k) \cdot s_i(2n - k). \quad (4.32)$$

Entsprechend folgt für die Waveletkoeffizienten d_{i+1} der $(i+1)$ -ten Stufe

$$d_{i+1}(n) = \sum_k g_0(k) \cdot s_i(2n - k). \quad (4.33)$$

Wenn zusätzlich die nullte Zerlegungsstufe gleich der Eingangsfolge $s(n)$ gewählt wird

$$s_0(n) = s(n), \quad (4.34)$$

ist die diskrete Wavelet-Transformation durch (4.26) bis (4.28) vollständig festgelegt. Die Wavelet-Koeffizienten können durch eine rekursive Filteroperation mit den Analysefiltern $h_0(k)$ bzw. $g_0(k)$ und einer nachfolgenden Abwärtstastung aus den Skalierungskoeffizienten der vorhergehenden Zerlegungsstufe bestimmt werden. Wird die DWT einer N Abtastwerte umfassenden Signalfolge vollständig, d.h. bis zur letztmöglichen Stufe $L = \log_2(N)$ durchgeführt, so entstehen insgesamt $2^L - 1$ Waveletkoeffizienten und ein Skalierungskoeffizient.




Bild 4.5 Beispiel der Multiskalen-Darstellung eines Signals. Oben links das Originalsignal, darunter die Approximationen (A_{1-3}), rechts die Detailssignale (D_{1-3}), mit abnehmender Auflösung.

Bild 4.5 zeigt ein Beispiel einer Multiskalen-Darstellung. Oben links ist das Originalsignal gezeigt, in der Spalte darunter die sukzessiven Approximationen abnehmender Auflösung. Die rechte Spalte zeigt jeweils die zugehörigen Detailssignale. Durch Addition

des Tiefpasssignals einer Stufe mit dem zugehörigen Detailsignal, ergibt sich gemäß (4.18) jeweils das Approximationssignal der nächsthöheren Stufe.

Analog zur DWT kann auch die inverse diskrete Wavelet-Transformation (IDWT) aus der Wavelet- und Skalierungsgleichung abgeleitet werden:

$$s_i(n) = \sum_k h_1(n-2k) \cdot s_{i+1}(k) + \sum_k g_1(n-2k) \cdot d_{i+1}(k). \quad (4.35)$$

Die Signalrekonstruktion erfolgt wie auch die Signalanalyse rekursiv, durch eine Aufwärtstastung der Signalfolge, d.h. durch Einfügen von Nullen zwischen zwei aufeinanderfolgenden Abtastwerten, mit anschließender Filterung durch die Synthesefilter $h_1(k)$ bzw. $g_1(k)$, wie aus Bild 4.6 ersichtlich. Entsprechend (4.25) ergeben sich die Koeffizienten der Synthesefilter aus den Synthese-Basisfunktionen. Bei der orthogonalen Wavelet-Transformation erhält man die zugehörigen Filterkoeffizienten durch Spiegelung der Analysefilter.

4.3.3 Wavelets und Filterbänke

Wie im letzten Abschnitt dargestellt, kann eine Zerlegungsstufe der rekursiv durchgeführten DWT als Teilbandzerlegung des Eingangssignals in Hochpass- und Tiefpassanteil (der weiterverarbeitet wird) aufgefasst werden. Dies lässt sich auch als Anwendung einer Zweikanal-Filterbank beschreiben. Im Folgenden wird kurz auf die Zusammenhänge zwischen der DWT und Zweikanal-Filterbänken mit exakter Signalrekonstruktion eingegangen.

Bild 4.6 illustriert die Anwendung einer Zweikanal-Filterbank zur Analyse und Synthese eines Signals, anhand der im letzten Abschnitt beschriebenen Skalierungs- und Waveletfilter. Die Lücke in Bild 4.6 bezeichnet die Stelle an der Signale für eine Übertragung




Bild 4.6 Zweikanal-Filterbank zur Signalanalyse (linker Teil) und Signalsynthese (rechter Teil).

oder Speicherung kodiert werden können. Die Summation des Approximations- und des Detailsignals liefert das rekonstruierte Eingangssignal $\hat{s}(n)$.

Durch Kaskadierung des Analyseblocks in Bild 4.6 gelangt man zu der in Bild 4.7 dargestellten Filterbankstruktur der DWT. In jeder Stufe wird der Skalierungsfiler auf den verbliebenen Tiefpassanteil angewendet, gefolgt von einer Unterabtastung. Der Hochpassanteil bleibt unverändert. Das rekonstruierte Signal $\hat{s}(n)$ in Bild 4.6 wird nur dann dem Eingangssignal $s(n)$ entsprechen, wenn die verwendeten Filter *ideale Rekonstruktionseigenschaften* besitzen.




Bild 4.7 Filterbankstruktur der diskreten Wavelet-Transformation. Durch Anwendung des Skalierungsfilters h_0 auf den zuletzt erhaltenen Tiefpassanteil, gefolgt von einer Unterabtastung, gelangt man zur einer Approximation des Signals mit einer größeren Auflösung. Die Hochpassanteile bleiben unverändert.

Für die z-Transformierte des rekonstruierten Signals $\hat{S}(z)$ gilt

$$\hat{S}(z) = \frac{1}{2} \cdot [H_0(z) \cdot H_1(z) + G_0(z) \cdot G_1(z)] \cdot S(z) + \frac{1}{2} \cdot [H_0(-z) \cdot H_1(z) + G_0(-z) \cdot G_1(z)] \cdot S(-z) \quad (4.36)$$

Um am Ausgang des Gesamtsystems das ursprüngliche Signal unverändert zu erhalten, d.h. eine exakte Signalrekonstruktion zu erreichen, müssen die folgenden beiden Bedingungen erfüllt sein [Str96]:

$$H_0(z) \cdot H_1(z) + G_0(z) \cdot G_1(z) = 2z^{-l}, \quad (4.37)$$

$$H_0(-z) \cdot H_1(z) + G_0(-z) \cdot G_1(z) = 0. \quad (4.38)$$

Die erste Bedingung entspricht der Forderung, dass das rekonstruierte Signal verzerrungsfrei am Ausgang anliegt und allenfalls eine Verzögerung z^{-l} aufgrund der Verwendung

realer Filter aufweist, d.h. es muss gelten $\hat{s}(n) = s(n-l)$. Durch die zweite Bedingung wird erreicht, dass die innerhalb der beiden unterabgetasteten Teilbänder vorhandenen Aliasing-Anteile bei der Signalsynthese eliminiert werden. Dies kann durch

$$H_1(z) = -G_0(-z) \quad \text{und} \quad G_1(z) = H_0(-z) \quad (4.39)$$

erfüllt werden, so dass sich die beiden Synthesefilter $H_1(z)$ und $G_1(z)$ direkt aus den Analysefiltern $H_0(z)$ bzw. $G_0(z)$ ergeben. Prinzipiell können die orthogonale Wavelet-Transformation, bei der die Analyse- und Synthesefilter identisch sind sowie die *biorthogonale* Wavelet-Transformation, bei der zur Signalanalyse und – Synthese unterschiedliche Basissysteme bzw. Filter zum Einsatz kommen, unterschieden werden. Die sich daraus für die jeweiligen Filter ergebenden Anforderungen werden nachfolgend kurz aufgeführt. Bei der *orthogonalen* DWT ergeben sich die folgenden im z - und Zeitbereich formulierten Anforderungen an die Filter [Str96]:

$$\begin{aligned} H_1(z) &= H_0(z^{-1}) & h_1(k) &= h_0(-k) \\ G_0(z) &= H_0(-z^{-1}) \quad \text{bzw.} & g_0(k) &= (-1)^k h_0(-k) \\ G_1(z) &= -H_0(-z) & g_1(k) &= (-1)^{k-1} h_0(-k). \end{aligned} \quad (4.40)$$

Der Analyse-Hochpass $g_0(k)$ ergibt sich aus dem Tiefpass durch zeitliche Umkehr der Impulsantwort und Modulation mit dem Faktor $(-1)^k$, der den Tiefpass in einen Hochpass umwandelt. Da die Synthesefilter durch zeitliche Umkehr aus den Analysefiltern erhalten werden, ist das Gesamtsystem in Bild 4.6 durch die Wahl von $H_0(z)$ bzw. $h_0(k)$ festgelegt.

Biorthogonale Wavelets

Die Orthogonalitätsbedingung stellt eine starke Einschränkung bei der Konstruktion von Wavelets dar. So ist es nicht möglich, ein orthogonales Wavelet mit kompaktem Träger zu konstruieren, welches gleichzeitig auch noch symmetrisch ist. Einzige Ausnahme bildet das Haar-Wavelet (vgl. Bild 4.4 a). Aus Sicht der Signalverarbeitung ist die wesentliche Folgerung aus der Orthogonalität, dass man zur Analyse und Synthese eines Signals dasselbe Wavelet verwenden kann. Die Einschränkung auf Biorthogonalität heißt Paare $\{\psi, \tilde{\psi}\}$ von Funktionen zu suchen, deren Dilatation und Translation

$$\begin{aligned} \{\psi_k^i\}_{k \in \mathbb{Z}} &= \{2^{-i/2} \psi(2^{-i} t - k)\}_{k \in \mathbb{Z}} \\ \{\tilde{\psi}_k^i\}_{k \in \mathbb{Z}} &= \{2^{-i/2} \tilde{\psi}(2^{-i} t - k)\}_{k \in \mathbb{Z}} \end{aligned} \quad (4.41)$$

biorthogonale Basen des $L^2(\mathfrak{R})$ in dem folgenden Sinn bilden:

$$\langle \psi_k^i, \tilde{\psi}_{k'}^{i'} \rangle = \delta_{i,i'} \delta_{k,k'}. \quad (4.42)$$

Die Konstruktion derartiger biorthogonaler Wavelets erfolgt ebenfalls mittels der Skalierungsfunktionen $\{\phi, \tilde{\phi}\}$ und den dazugehörigen Skalierungsgleichungen [Lou94]

$$\phi(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_0(k) \cdot \phi(2t - k), \quad \tilde{\phi}(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_0(k) \cdot \tilde{\phi}(2t - k). \quad (4.43)$$

Man nennt $\tilde{\phi}$ die duale Skalierungsfunktion und $\tilde{\psi}$ das duale Wavelet. Die für die praktische Anwendung wesentlichen Ergebnisse lassen sich wie folgt zusammenfassen [Str96]:

$$\begin{aligned} H_1(z) &= G_0(-z) & h_1(k) &= (-1)^k g_0(k) \\ G_1(z) &= -H_0(-z) \quad \text{bzw.} & g_1(k) &= (-1)^{k-1} h_0(k) \end{aligned} \quad (4.44)$$

Aus dem Analyse-Hochpass ergibt sich durch Modulation der Synthese-Tiefpass, entsprechend folgt der Synthese-Hochpass aus dem Analyse-Tiefpass.

Die Filter müssen gewisse Zulässigkeitsbedingungen erfüllen, damit sich aus der Filterbank auch eine Wavelet-Transformation ergibt. Diese hier nur für die orthonormale Wavelet-Transformation wiedergegebenen Bedingungen lauten

$$\begin{aligned} H_0(z=1) &= \sqrt{2} & G_0(z=1) &= 0 \\ H_0(z=-1) &= 0 \quad \text{und} & G_0(z=-1) &= \sqrt{2} \end{aligned} \quad (4.45)$$

Der Filter $h_0(k)$ entspricht einem auf den Betrag $\sqrt{2}$ normierten Tiefpass, $g_0(k)$ einem Hochpass. Im Falle orthonormaler Wavelets kann aus (4.31) auch

$$|H_0(z)|^2 + |H_0(-z)|^2 = 2 \quad (4.46)$$

abgeleitet werden. Die Filter $H_0(z)$ und $H_0(-z)$ sind leistungskomplementäre Quadratur-Spiegelfilter, wobei sich alle benötigten Filter als modulierte Versionen eines Tiefpassfilters ergeben. Es lässt sich festhalten, dass zwar aus jedem zulässigen Basissystem der diskreten Wavelet-Transformation eine Zweikanal-Filterbank mit perfekter Rekonstruktion abgeleitet werden kann, umgekehrt jedoch nicht alle perfekt rekonstruierenden Zweikanal-Filterbänke auch auf zulässige Wavelet- bzw. Skalierungsfunktionen führen [Str96].

In der praktischen Anwendung werden die zur Konstruktion der Basisfunktionen benötigten Filterkoeffizienten einer perfekt rekonstruierenden Zweikanal-Filterbank gemäß (4.37) und (4.38) vorgegeben und dann in der rekursiven Anwendung der Skalierungs- und Waveletgleichung (4.32) und (4.33) eingesetzt.

Erforderlicher Rechenaufwand der DWT

Ein wichtiges Charakteristikum des diskreten Algorithmus ist seine relativ geringe Komplexität. Unabhängig von der Zerlegungstiefe des in Bild 4.7. gezeigten Baums ist die Komplexität linear in der Anzahl der Abtastwerte, mit einem Faktor der von der Länge der verwendeten Filter abhängt. Anhand eines Gedankenexperiments kann dies leicht nachgewiesen werden. Angenommen die erste Stufe benötigt typischerweise C_0 Rechenoperationen pro Abtastwert, dann wird auch für die zweite Stufe die gleiche Anzahl von Rechenoperationen erforderlich sein. Aufgrund der Unterabtastung verringert sich dieser Aufwand aber auf $C_0/2$ pro Abtastwert. Die Gesamtanzahl der erforderlichen Operationen ist daher begrenzt durch

$$C_{total} = C_0 + \frac{C_0}{2} + \frac{C_0}{4} + \dots < 2C_0. \quad (4.47)$$

Dies beweist die Effizienz des Algorithmus. Zum Vergleich: Für eine FFT sind bei einer Signallänge von N Abtastwerten $O(N \log_2 N)$ Rechenoperationen erforderlich.

4.3.4 Die Wahl eines geeigneten Wavelets

Die Anforderungen an die Wavelet- und Skalierungsfunktion bzw. an die sich daraus ergebenden Filterkoeffizienten können sehr unterschiedlich sein. Denkbare Forderungen sind i) gute Frequenzselektivität der Filterbank; ii) Linearphasigkeit von Analyse- und Synthesefilter; iii) geringe Alias-Anteile in den Teilbändern; iv) kurze Filterlängen zur Minimierung des Aufwands; oder v) eine möglichst große „Ähnlichkeit“ zwischen dem untersuchten Signal und dem verwendeten Wavelet.

Der letzte Punkt ist für die vorliegende Aufgabenstellung am wichtigsten, da eine große Ähnlichkeit zu einer geringen Anzahl von Transformationskoeffizienten mit signifikanter Amplitude führt, d.h. ein Maximum an Information wird auf eine geringe Anzahl an Koeffizienten konzentriert. Dies erleichtert die Weiterverarbeitung der Koeffizienten zum Zwecke der Merkmalsbildung (s. Abschnitt 4.7).

Benötigt wird ein Gütemaß zur Beurteilung der Eignung verschiedener Typen von Wavelets für die Zerlegung gegebener Signale. Dieses Maß wird auch als *Informations-Kostenfunktion* bezeichnet, die auch bei der Signal- und Bildkompression eingesetzt wird. Letztendlich wird die „Energiekonzentration“ der Transformationskoeffizienten gemessen. Eine natürliche Wahl ist die von Coifmann und Wickerhauser als Kostenfunktion vorgeschlagene *Shannon-Entropie* [Coi92].

Die Entropie einer Sequenz $\mathbf{u} = \{u_i\}$ ist definiert durch

$$H = -\sum_i p_i \log(p_i), \quad (4.48)$$

mit der normierten Energie $p_i = \frac{|u_i|^2}{\|\mathbf{u}\|^2}$ und der Konvention $p \cdot \log(p) = 0$ für $p = 0$.

Die gleiche Kostenfunktion lässt sich auch zur Festlegung eines Basissystems bei der Wavelet-Packet-Transformation anwenden, worauf im nächsten Abschnitt noch näher eingegangen wird. Eine beispielhafte Transformation eines Chirpsignals mit den in Bild 4.4 abgebildeten Wavelet-Typen ist in Bild 4.8 gezeigt.




Bild 4.8 Beispielhafte Transformation eines Chirpsignals a) mit verschiedenen Wavelet-funktionen: b) Haar, c) Daubechie-4, d) Spline-Wavelet (vgl. Bild 4.4). Dargestellt sind die Koeffizienten der ersten vier Transformationsstufen, die Bänder sind nach aufsteigender Frequenz angeordnet.

Das transformierte Chirpsignal hat 512 Abtastwerte, vier Transformationsstufen wurden durchgeführt, d.h. der Tiefpassanteil besteht aus $2^9 / 2^4 = 2^5$ Koeffizienten. Der Algorithmus liefert die Koeffizienten der einzelnen Stufen, gemäß der Filterbankstruktur in Bild 4.7. Die zum Tiefpassanteil gehörigen 32 Koeffizienten stehen in Bild 4.8 b) bis d)

jeweils ganz links, gefolgt von den Sequenzen der Detailkoeffizienten der vier Stufen (mit den Sequenzlängen 32, 64, 128, 256). Der Vorteil des biorthogonalen Spline-Wavelets ist offensichtlich, es findet eine deutlich bessere Konzentration der Energie auf die Koeffizienten der tieferen Oktaven statt, als dies bei den beiden Daubechie-Wavelets der Fall ist. Aus diesem Grund wird nachfolgend zur Verarbeitung der Georadarsignale auch dieser Typ von Wavelet verwendet. Biorthogonale Spline-Wavelets sind in [Dau92] ausführlich beschrieben.

4.4 Wavelet-Packet-Transformation

Bei der DWT wird eine Einteilung der Frequenzachse in Oktaven vorgenommen. Jede Stufe repräsentiert ein Frequenzband, welches die halbe Breite der nächsthöheren und somit die doppelte Breite der darunterliegenden Stufe aufweist. Im Gegensatz dazu ist die zeitliche Auflösung doppelt so hoch wie auf der darunterliegenden Stufe und halb so hoch wie auf der nächsthöheren Stufe. Diese Eigenschaft der DWT bereitet Probleme bei der genauen Lokalisierung höherer Frequenzen, da eine schlechte Frequenzauflösung zu Gunsten einer hohen Zeitauflösung in Kauf genommen wird.

Die von Coifmann und Wickerhauser entwickelte *Wavelet-Packet-Transformation* (WPT) ist eine wesentlich vielfältigere Transformation und stellt eine verallgemeinerte Form der WT dar. Sie liefert eine Familie orthogonaler Basissysteme, mit der DWT als einem Spezialfall [Coi92]. Geht man von der Filterbank in Bild 4.7 aus, erhält man eine vollständige Zerlegung des Eingangssignals durch Hinzufügen von Zweikanal-Filterbänken auch an den Ausgängen des Hochpassfilters. Die vollständige Zerlegung benötigt $O(N \log_2 N)$ Rechenoperationen und liefert eine gleichmäßige Frequenzaufteilung. Bei Durchführung der WPT bis zur dritten Stufe ergibt sich die in Bild 4.9 gezeigte Struktur.

Die bei jeder Stufe der Transformation entstehenden Unterräume bilden eine disjunkte Überdeckung des gesamten Frequenzbereichs des Eingangssignals. Daraus folgt, dass die WPT mit vollständigem Zerlegungsbaum – bei Speicherung aller Zwischenstufen – eine redundante Repräsentation ist. Bei der Transformation eines Signals mit N Abtastwerten und L Stufen erhält man am Ausgang $N \cdot L$ Koeffizienten.

Die WPT erlaubt eine genauere Frequenzlokalisierung charakteristischer Signalanteile im Eingangssignal und bietet zudem die Möglichkeit der Festlegung eines je nach Aufgabenstellung geeigneten Schemas zur Bestimmung einer orthonormalen Basis. Die Basis legt fest, welche Zwischenstufen weiter zerlegt werden und welche nicht.




Bild 4.9 Filterbankstruktur der diskreten Wavelet-Packet-Transformation, mit vollständiger Zerlegung des Eingangssignals bei 3 Stufen. Die zur „klassischen“ Wavelet-Transformation gehörigen Filteroperationen sind grau unterlegt.

4.4.1 Die Bestimmung der besten Basis

Eine beliebige Menge disjunkter Unterräume, die eine vollständige Überdeckung der Frequenzachse aufweisen, bilden eine orthonormale Basis. Die Wavelet-Transformation stellt nur ein Mitglied aus der Familie möglicher orthonormaler Basen dar, die sich aus verschiedenen großen Subbändern (zu verschiedenen Stufen gehörig) zusammensetzen. Bei einer maximalen Zerlegungstiefe von L Stufen existieren $2^{2^{(L-1)}}$ verschiedene orthonormale Basissysteme, bei vollständiger Zerlegung eines Signals mit 256 Abtastwerten liefert dies ungefähr $3.4 \cdot 10^{38}$ Möglichkeiten! Ein wesentliches Ergebnis der Arbeiten von Coifmann und Wickerhauser war die Entwicklung eines effizienten Schemas zur adaptiven Zerlegung eines Signals, mit dessen Hilfe anhand einer Kostenfunktion die *beste Basis* ermittelt werden kann. Ziel war die Entwicklung effizienter und flexibler Algorithmen zur Bildkompression [Coi92].

Zur Bewertung der Güte eines Basissystems wird die von Coifmann vorgeschlagene Kostenfunktion verwendet. Für die Suche nach der *besten Basis* wird somit in jedem Subband die Entropie der Koeffizienten nach (4.48) bestimmt. Die Ausgänge einer Filterung (einschließlich Dezimierung) werden als Knoten bezeichnet. An jedem Knoten wird der Wert der Kostenfunktion mit der Summe der Kosten aus den beiden zusammen-

gehörenden darunterliegenden „Söhnen“ verglichen. Sind die Kosten höher, wird der aktuelle „Vaterknoten“ beibehalten, sind sie niedriger, werden die Söhne gewählt und die Bewertung fortgesetzt. Um einen schnellen Algorithmus zu erhalten, muss die Kostenfunktion additiv sein, da sonst in jedem Knoten die Kosten über alle Elemente einer Basis neu bestimmt werden müssten. Zu diesem Zweck wird auf die Energienormierung in (4.48) verzichtet. Neben diesem *Top-down*-Algorithmus ist auch eine *Bottom-up*-Realisierung möglich, ausgehend von einer vollständigen Zerlegung und beginnend in der tiefsten Stufe. Bild 4.10 zeigt ein Rechenexempel zur Bestimmung der besten Basis.

53 (48)								Stufe	0
27 (24)				21					1
13		11 (10)		12		11		2	
6	8	5	5	7	6	5	8	3	

Bild 4.10 In den Knoten sind die Kosten einer vollständigen Zerlegung bis Stufe 3 angegeben. Ist die Summe zweier „Söhneknoten“ niedriger als der des „Vaterknotens“ darüber, ist sie in Klammern vermerkt und wird dann für die weitere Zerlegung herangezogen. Die resultierende *beste Basis* ist grau unterlegt.

Bild 4.11 zeigt eine beispielhafte Anwendung der WPT. Das Eingangssignal ist oben abgebildet (Stufe 0), nachfolgend die in den einzelnen Stufen erhaltenen Koeffizienten aller Subbänder⁴. Jedes Subband deckt die gesamte Zeitachse ab. Die orthonormale Basis der WT ist grau unterlegt.

Bild 4.12 zeigt die für das Signal in Bild 4.11 ermittelte beste Basis (grau unterlegt), die deutlich niedrigere Kosten verursacht, als die Wavelet-Basis (-436.9 vs. -166.5). Die Bestimmung der besten Basis erfolgt für eine festgelegte Klasse von Signalen im voraus, so dass die Berechnung der Koeffizienten nach einem festen Schema durchgeführt wird. Die Notwendigkeit, jedes Signal vollständig zu zerlegen, kann damit entfallen.

Der Vollständigkeit halber sei noch erwähnt, dass in der Literatur noch die *Best Level Basis* genannt wird, welche als Basis diejenige Zerlegungsstufe angibt, die den niedrigsten Wert der Kostenfunktion liefert. Für das hier untersuchte Chirpsignal liegt das Minimum der Kostenfunktion bei der fünften Stufe, mit einem Kostenwert von -429.8.

⁴ Im Folgenden werden die ab Stufe 1 in Bild 4.10 durch Boxen gekennzeichneten Frequenzbänder als Subband bezeichnet.

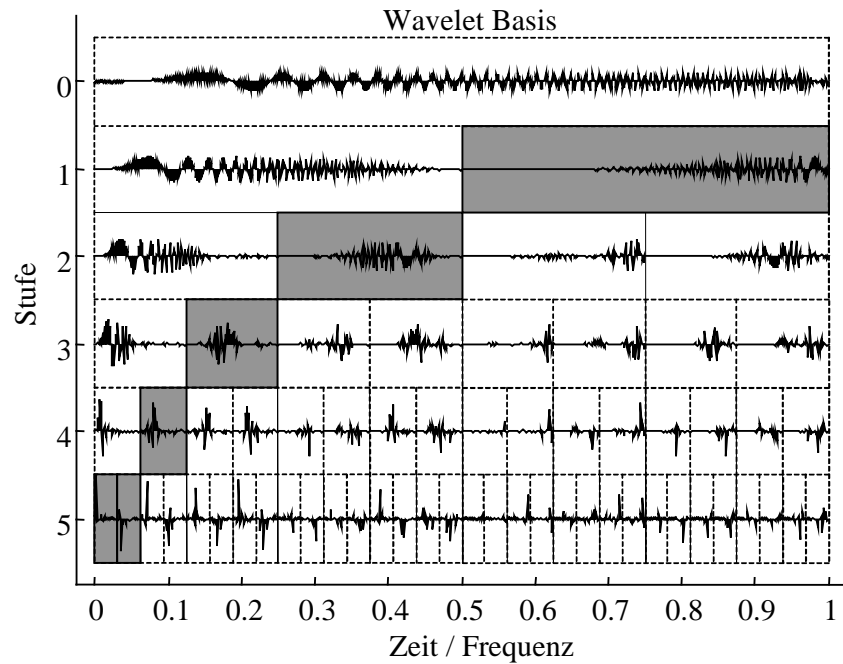


Bild 4.11 Beispielhafte Anwendung der WPT. Ausgehend vom Eingangssignal (Stufe 0) sind die in jedem Subband erhaltenen Koeffizienten abgebildet. Die Basis der WT ist grau unterlegt. Der zugehörige Wert der Kostenfunktion beträgt -166.5.




Bild 4.12 Beispielhafte Anwendung der WPT. Die ermittelte *beste Basis* ist grau unterlegt. Der zugehörige Wert der Kostenfunktion beträgt -436.9 (vgl. Bild 4.11).

4.4.2 Die Bestimmung der am besten diskriminierenden Basis

Die im letzten Abschnitt beschriebene Vorgehensweise zur Konstruktion einer besten Basis, auf dem Wege der Minimierung einer Kostenfunktion, ist im Sinne der Klassifikation nicht vorteilhaft. Die Festlegung einer orthonormalen Basis ist Bedingung zur fehlerfreien Rekonstruktion eines Signals, liefert aber nicht die Voraussetzung zur Trennung verschiedener Signalkategorien. Der Energieanteil in einigen Subbändern kann für alle Signalklassen ähnlich hoch sein, während signifikante Unterschiede auf relativ schwache Energieanteile in anderen Subbändern zurückzuführen sein können. Bei Verwendung einer besten Basis, die für alle Signalklassen gleich ist, werden aber genau diese Unterschiede nicht erfasst.

Ist eine vollständige Baumstruktur gegeben, gilt es eine optimale Auswahl von Knoten zu treffen, welche die bestmögliche Trennung gestattet. Selbst für einen Baum geringer Tiefe, mit einer geringen Anzahl von Knoten, ist die Durchführung einer vollständigen Suche prohibitiv teuer. Der *Best-Basis (BB)* Algorithmus wurde daher von Saito weiterentwickelt, indem statt der Entropie als Kostenfunktion alternative Funktionen zur Bewertung der Trennbarkeit von Signalklassen eingeführt wurden [Sai94]. Der so modifizierte Algorithmus verwendet ein statistisches *Diskriminanzmaß*, welches eine Aussage über die Trennschärfe eines Subbands macht.

Die Eingangsgrößen dieser Diskriminanzfunktion, die über alle zur Verfügung stehenden Signale gebildet wird, bilden nicht die WPT-Koeffizienten selbst, sondern z.B. die Energie der Koeffizienten eines Subbands. Somit wird jedes Subband bzw. jeder Knoten, durch einen skalaren Wert repräsentiert. Die Gesamtanzahl der zu bewertenden Größen entspricht folglich der Anzahl der Subbänder. Bei einer WPT mit L Stufen ergeben sich damit

$$N_p = \sum_{i=1}^L 2^i = 2^{L+1} - 2 \quad (4.49)$$

Merkmale. An jedem Vaterknoten wird der Beitrag zur Klassentrennung bestimmt und mit dem Beitrag der beiden Söhneknoten verglichen. Abgesehen von der Bewertungsfunktion ist der von Saito vorgeschlagene *Local-Discriminant-Basis (LDB)* Algorithmus mit dem BB-Algorithmus identisch.

Eine anderer Ansatz zur Bestimmung einer am besten diskriminierenden Basis geht von einer vollständigen WPT-Baumstruktur aus und wendet dann ein *Pruning-Verfahren* an, indem sukzessiv alle Knoten ausgesondert werden, die nicht zur Klassentrennbarkeit beitragen. Eine einfache aber unzuverlässige Realisierung ist die Auswahl aus einer Liste, in der alle Merkmale nach ihrer Trennschärfe sortiert sind [Ete98].

Delfs schlägt ein Verfahren der klassenabhängigen Merkmalsselektion zur Bildung der besten Basis vor, bei dem die Differenzen der zu unterschiedlichen Klassen gehörigen WPT-Koeffizienten direkt als Merkmale verwendet werden [De198]. Ein Nachteil dieses Ansatzes ist die erforderliche zeitliche Ausrichtung der Signale, da für die Erkennung ausschlaggebende Signalanteile zu verschiedenen Zeiten erfasst werden können. Da die Ausrichtung über eine hinreichend große Anzahl von Signalen aller Klassen und eine ausreichende Anzahl möglicher Verschiebungen durchgeführt werden muss, bedeutet dies einen hohen Rechenaufwand (s. auch Abschnitt 4.7).

Die oben aufgeführten Ansätze führen oft nur zu einer suboptimalen Lösung, da bestehende lineare Abhängigkeiten zwischen einzelnen Merkmalen nicht berücksichtigt werden. Merkmalskollektive lassen sich daher kaum anders als mit Hilfe der Erkennungsleistung darauf aufbauender Erkennungssysteme bewerten. Das in dieser Arbeit eingesetzte Verfahren des Polynomklassifikators gestattet die Aufstellung einer Rangordnung $rank(y)$ der verwendeten Merkmale, entsprechend ihres Beitrags zur Minderung des Erkennungsfehlers. Gegenseitige Abhängigkeiten zwischen Merkmalen werden dabei berücksichtigt (s. Anhang A.1 und [Sch96]). Eine optimale Auswahl an Merkmalen bzw. Knoten folgt somit direkt aus dem Ergebnis des Klassifikators. Anhand simulierter Daten wird ein Vergleich verschiedener Basen durchgeführt (s. Abschnitt 6.2).

Verschiedene Diskriminanzmaße zur Bewertung von Merkmalen werden in Abschnitt 4.7.3 vorgestellt. Anzumerken bleibt, dass die unter dem Gesichtspunkt der Eignung zur Diskrimination ausgewählten Subbänder im Allgemeinen keine komplette Basis darstellen, was aber für die Klassifikationsaufgabe unerheblich ist. Die nach dem hier eingeführten Selektionsverfahren ausgewählten Merkmale werden im Weiteren als *Best Discriminant Incomplete Basis* (BDIB) bezeichnet.

4.5 Multiwavelets

Multiwavelets stellen eine Erweiterung der skalaren Wavelets dar. Als wesentlicher Unterschied werden anstelle einer Skalierungs- und einer Waveletfunktion zwei oder mehr Funktionen verwendet. Statt mit den in Abschnitt 4.3.2 eingeführten Tiefpass- bzw. Hochpassfiltern, werden Matrizen der Größe $r \times r$ verwendet. Üblicherweise wird r zu 2 gewählt. Das bekannteste Multiwavelet, formuliert von Geronimo, Hardin und Massopust (GHM), wird gebildet durch zwei Skalierungsfunktionen mit folgenden Eigenschaften, die im skalaren Fall (außer für Haar-Wavelets mit Approximationsgrad $p=1$) unvereinbar sind [Ger94]:

- beide Skalierungsfunktionen haben einen kompakten Träger;
- beide Skalierungsfunktionen sind symmetrisch, die Waveletfunktionen bilden ein symmetrisch / antisymmetrisches Paar;
- alle ganzzahlig verschobenen Skalierungsfunktionen sind zueinander orthogonal;
- das System hat Approximationseigenschaften zweiter Ordnung (d.h. die Anzahl verschwindender Momente beträgt $p = 2$).

Diese Eigenschaften können von einer für Matrizen formulierten Zwei-Skalen-Relation abgeleitet werden, mit den Matrixkoeffizienten \mathbf{h}_k und \mathbf{g}_k als 2×2 Matrizen [Str94]

$$\begin{bmatrix} \mathbf{h}_3(t) \\ \mathbf{h}_2(t) \end{bmatrix} = \sum_k \mathbf{h}_k \begin{bmatrix} \mathbf{h}_3(2t-k) \\ \mathbf{h}_2(2t-k) \end{bmatrix}, \quad (4.50)$$

für die Waveletgleichung gilt

$$\begin{bmatrix} \mathbf{g}_3(t) \\ \mathbf{g}_2(t) \end{bmatrix} = \sum_k \mathbf{g}_k \begin{bmatrix} \mathbf{g}_3(2t-k) \\ \mathbf{g}_2(2t-k) \end{bmatrix}. \quad (4.51)$$

Es werden also zwei Skalierungs- und zwei Waveletfilter benötigt, die sich in Matrixform schreiben lassen. Multifilter benötigen mehr als einen Datenkanal am Eingang, daher ist vor der ersten Stufe der Transformation eine *Vor-Filterung* erforderlich. Diese Vor-Filterung wird auch Multiwavelet-Initialisierung genannt und kann entweder mit kritischer Abtastung oder überabgetastet durchgeführt werden. Die naheliegendste Möglichkeit ist die Verdopplung des Eingangssignals. Diese überabgetastete Repräsentation ist für die Merkmalsextraktion am besten geeignet [Strel97]. Strela bezeichnet diese Variante als „repeated row“-Input. Damit ergibt sich die in Bild 4.13 dargestellte Multiwavelet-Filterbank als Realisierung einer Multiwavelet-Transformation (MWT). Bei der Filterung eines Signals mit N Abtastwerten ergeben sich $2N$ Koeffizienten am Ausgang (4 Kanäle à $N/2$ Koeffizienten). Die kritische Abtastung, mit nur N Koeffizienten am Ausgang, erzeugt keine Redundanz und eignet sich daher am besten für Kompressionsanwendungen.

Zur Filterung der Georadarsignale wird nicht das oben angeführte GHM-Multiwavelet gewählt, sondern ein sogenanntes *bihermisches* Multiwavelet⁵, welches Approximationseigenschaften vierter Ordnung besitzt und daher zur Repräsentation „glatter“ Signale besser geeignet ist. Das verwendete Multiwavelet ist in Bild 4.14 abgebildet. Oben die beiden symmetrischen Skalierungsfunktionen, unten die antisymmetrischen Waveletfunktionen.

⁵ In der Nomenklatur von Strela als 'bih32s' bezeichnet [Stre97].




Bild 4.13 Multiwavelet-Filterbank mit Verdopplung des Eingangssignals. Im Unterschied zur skalaren Wavelet-Transformation sind die Filter g_0 und h_0 Matrixfilter.




Bild 4.14 Für die Filterung der Georadarsignale verwendetes Multiwavelet. Oben die beiden symmetrischen Skalierungsfunktionen, unten die antisymmetrischen Waveletfunktionen.

4.6 Translationsinvariante Wavelet-Transformationen

Die in den vorangegangenen Abschnitten dargestellten Multiresolution-Verfahren weisen, bedingt durch die im Analyseteil durchgeführte Unterabtastung, eine teilweise ausgeprägte Verschiebungsabhängigkeit auf. Insbesondere bei der Bildung von Merkmalen kann dies negative Folgen haben. An einem einfachen Beispiel lässt sich dies veranschaulichen: zwei in unterschiedlichen Tiefen liegende, identische Objekte lassen sich nur dann der gleichen Klasse zuordnen, wenn aus den jeweiligen Radarsignalen auch die gleichen Merkmale resultieren.

Da die Translationsinvarianz der Transformationskoeffizienten bei der DWT infolge der Unterabtastung verloren geht, ergibt sich eine einfache Translation der Koeffizienten bei einem verschobenen Signal nur dann, wenn die Verschiebung gleich einem ganzzahligen Vielfachen aller während der Signalanalyse auftretenden Abtastfaktoren ist, d.h. nur wenn gilt

$$\Delta = k \cdot 2^{i_0} \quad \text{mit } k \in \mathbf{Z}. \quad (4.52)$$

Im Folgenden wird daher eine translationsinvariante Erweiterung der diskreten Wavelet-Transformation eingeführt, die hier als SIDWT bezeichnet wird⁶. Ziel ist eine Anpassung der DWT derart, dass eine Translation des Eingangssignals zwar zu einer Translation der Koeffizienten, nicht aber zu deren Modifikation führt. Das bedeutet für eine bis zur i_0 -ten Stufe durchgeführten SIDWT die Realisierung folgender Abbildung

$$s(n) \rightarrow \{d_1(n), d_1(n), \dots, d_{i_0}(n), s_{i_0}(n)\}. \quad (4.53)$$

Für eine nach obiger Definition invariante Multiresolution-Darstellung muss daher bei einer Verschiebung des Eingangssignals um Δ Abtastwerte gelten

$$s(n - \Delta) \rightarrow \{d_1(n - \Delta), d_1(n - \Delta), \dots, d_{i_0}(n - \Delta), s_{i_0}(n - \Delta)\}, \quad (4.54)$$

d.h. bei der SIDWT kann die Transformierte des verschobenen Signals auch durch eine Translation der Koeffizienten des ursprünglichen Signals bestimmt werden. Die einfachste aber aufwendigste Realisierung besteht darin, die DWT für alle möglichen zirkularen Verschiebungen des Eingangssignals zu berechnen. Beylkin [Bey92] zeigte, dass sich dabei bei einer Signallänge von N Abtastwerten nur $N \log_2 N$ verschiedene Koeffizienten ergeben und entwickelte ein effizientes Berechnungsschema. Eine andere Realisierungsmöglichkeit wurde von Shensa [She92] vorgeschlagen. Die Grundüberlegung besteht darin, bei der Signalanalyse auf die Abtastung zu verzichten und stattdessen die Filter in jeder Zerlegungsstufe zu modifizieren. Die Skalierungskoeffizienten der $(i+1)$ -ten Stufe ergeben sich dann zu:

$$s_{i+1}(n) = \sum_k h_0(2^i k) \cdot s_i(n - k), \quad (4.55)$$

und analog die Waveletkoeffizienten zu:

$$d_{i+1}(n) = \sum_k g_0(2^i k) \cdot s_i(n - k). \quad (4.56)$$

⁶ Von engl. *shift invariant discrete wavelet transform*.

Dies entspricht einer nicht unterabgetasteten Version von (4.32) bzw. (4.33). Wie auch bei der DWT wird die nullte Zerlegungsstufe zu $s_0(n) = s(n)$ festgelegt und damit die SIDWT vollständig beschrieben. Die Filter $h_0(2^i k)$ und $g_0(2^i k)$ der i -ten Zerlegungsstufe entstehen durch Einfügen von $2^i - 1$ Nullen zwischen den Koeffizienten der Prototyp-Filter $h_0(k)$ bzw. $g_0(k)$, was zur Bezeichnung *à-trous*-Algorithmus führte⁷. Durch das Einfügen der Nullen wird die Grenzfrequenz der Analysefilter auf jeder Zerlegungsstufe halbiert.

Ein wesentlicher Nachteil des *à-trous*-Algorithmus ist die Redundanz der sich ergebenden Darstellung. Dies gilt vor allem für die Erweiterung auf Wavelet-Packet-Transformationen. Aus diesem Grund wurde in dieser Arbeit ein alternatives Verfahren entwickelt, mit dem keine Redundanz verbunden ist und das im Vergleich zum Berechnungsaufwand der DWT oder WPT einen vertretbaren Mehraufwand bedeutet.

Bei der modifizierten WT werden in jeder Zerlegungsstufe eine um einen Abtastwert zyklisch verschobene und eine unverschobene Version des Eingangssignals transformiert. Anhand des Minimums einer für jeden der beiden resultierenden Koeffizientensätze berechneten Kostenfunktion wird entschieden, mit welcher Version die Zerlegung fortgeführt wird [Fri96]. Die in jeder Stufe zu bestimmenden Kosten J werden in Abhängigkeit von einer ganzzahligen Verschiebung m ermittelt:

$$J_m \{s_{i+1}(n), d_{i+1}(n)\} = J_m \left\{ \sum_k h_0(k) \cdot s_i(2n - k + m) \right\} + J_m \left\{ \sum_k g_0(k) \cdot s_i(2n - k + m) \right\}, \quad m \in \{0,1\}. \quad (4.57)$$

Als additive Kostenfunktion wird wiederum die in (4.48) eingeführte Entropie ohne Normierung verwendet. Für eine beliebige Verschiebung eines Signals um Δ beschränkt sich der Wertebereich von m infolge der Unterabtastung auf $\text{mod}(\Delta, 2)$. Nach der Dezimierung stehen damit entweder die geradzahligen oder ungeradzahligen Abtastwerte der Eingangsstufe für die weitere Zerlegung zur Verfügung.

Dieser Algorithmus lässt sich gleichermaßen zur Modifikation der WPT wie auch der MWT einsetzen. Damit stehen die hier als SIWPT (von engl. *shift invariant discrete wavelet packet transform*) und SIMWT (von engl. *shift invariant multiwavelet transform*) bezeichneten Transformationen für die Berechnung translationsinvarianter Merkmale zur Verfügung. Der Rechenaufwand ist lediglich doppelt so groß, wie jener der her-

⁷ Von franz. *trous* Löcher.

kömmlichen Verfahren, die keine Translationsinvarianz besitzen. Ein ähnlicher Algorithmus für WPTs wurde unabhängig von Cohen [Coh95] publiziert. Delfs beschreibt ein Schema für allgemeine translationsinvariante Filterbänke [Del97]. Arbeiten zur Anwendung verschiebungsinvarianter MWTs zur Merkmalsextraktion sind bisher nicht bekannt.

Eine beispielhafte Anwendung der SIDWT ist in Bild 4.15 gezeigt. Teilbild a) zeigt das Eingangssignal. Jede Spalte der in b) abgebildeten Matrix enthält eine Kopie dieses Signals, mit einer sich von links nach rechts jeweils um einen Abtastwert pro Spalte ändernden Verschiebung. Die in c) dargestellten Werte der Entropie, berechnet aus den DWT-Koeffizienten jeder Zerlegungsstufe, zeigen periodische Änderungen in Abhängigkeit von der Verschiebung. In d) ist die zugehörige Entropie aller WT-Koeffizienten eines Signals dargestellt. Die Summenentropie aller SIDWT-Koeffizienten ist durch die gestrichelte Linie markiert. Sie stellt das Minimum der Kostenfunktion dar. Teilbild e) demonstriert die mit der SIDWT erzielte Invarianz, unabhängig von der Verschiebung hat die Kostenfunktion für jede Oktave einen konstanten Wert.




Bild 4.15 Beispielhafte Anwendung der translationsinvarianten DWT: a) Eingangssignal; b) verschobene Kopien des Eingangssignals, spaltenweise angeordnet; c) oktavweise berechnete Entropien der DWT-Koeffizienten; d) Entropie aller DWT-Koeffizienten eines Signals (durchgezogene Linie) bzw. aller SIDWT-Koeffizienten (gestrichelte Linie); e) Entropien oktavweise berechneter SIDWT-Koeffizienten.

Die Verwendung der SIDWT bzw. SIWPT hat auch einen Einfluss auf die Bestimmung der besten Basis (vgl. Abschnitt 4.4.1). In Bild 4.16 sind die anhand der herkömmlichen DWT bzw. der SIDWT erhaltenen Werte der Kostenfunktion einander gegenübergestellt. Diejenigen Zerlegungsstufen, bei denen der Verschiebungsparameter für $m = 1$ zu einer Absenkung der Kostenfunktion führt, sind fett markiert. Teilbild a) zeigt die Wavelet-Basis, für die normierte Entropie ergab sich $H = 3.1$ für die DWT, 1.3 für die SIDWT und $H = 0.6$ für die SIWPT (Teilbild b). Die nicht gezeigte beste Basis liefert $H = 0.9$. Das Minimum der Entropie, gleichbedeutend mit der kompaktesten Beschreibung, wird somit mit der SIWPT erreicht.




Bild 4.16 Vergleich der Zerlegung des Eingangssignals aus Bild 4.14 mit herkömmlichen und verschiebungsinvarianten Transformationen. Die fett markierten Linien kennzeichnen die Stufen, bei denen eine Verschiebung zu einer Absenkung der Kostenfunktion führte.

4.7 Von Koeffizienten zu Merkmalen

Die in den Abschnitten 4.3 bis 4.6 beschriebenen Multiresolution-Verfahren liefern Koeffizienten, welche die Informationen enthalten, anhand derer ein Klassifikator über die Klassenzugehörigkeit eines Signals entscheiden soll. Jedes Signal wird durch einen Vektor charakterisiert, den sogenannten *Merkmalsvektor* oder das *Muster*, der für alle Signale auf die gleiche Art und Weise berechnet wird und der als Input für den Klassifikator dient.

Ziel der Merkmalsselektion bzw. -reduktion ist die Eliminierung von Merkmalen die statistische Abhängigkeiten von anderen aufweisen oder keinen Beitrag zur Klassentrennung leisten.

Für die Verarbeitung der Koeffizienten stehen prinzipiell zwei Möglichkeiten zur Verfügung: i) die direkte Übergabe der Koeffizienten an den Klassifikator oder ii) die Berechnung von aussagekräftigen Kenngrößen aus den Koeffizienten.

4.7.1 Direkte Verwendung von Koeffizienten als Merkmale

Diese Möglichkeit hat den Vorteil, dass keine Informationen berücksichtigter Frequenzbänder verloren gehen. Eine Selektion der Auflösungsstufen bzw. Subbänder ist allerdings unbedingt erforderlich, da sonst die Merkmalsvektoren eine nicht mehr handhabbare Länge erhalten, d.h. die Dimension des Merkmalsraums wäre zu groß. In der Regel kann eine Einschränkung auf diejenigen Frequenzbänder erfolgen, die dem Spektrum des Eingangssignal entsprechen. Im Falle der Wavelet-Packet-Transformation kann eine sinnvolle Vorauswahl durch die am besten diskriminierende Basis erfolgen (s. Abschnitt 4.4.2).

Eine Schwierigkeit bei der direkten Verwendung von Koeffizienten liegt darin, dass verschiebungsinvariante Transformationen für gegeneinander verschobene, ansonsten aber gleiche Signale, zwar identische Koeffizienten liefern, diese aber entsprechende Verschiebungen aufweisen. Dies macht eine zeitliche Ausrichtung der Koeffizienten innerhalb der selektierten Subbänder erforderlich.

Eine Möglichkeit hierfür ist die Koeffizienten einer Anzahl M verschiedener Signale um maximal $\pm\Delta$ Abtastwerte so gegeneinander zu verschieben, dass ihr paarweise gemessener euklidischer Abstand minimiert wird [Del98]

$$E = \min_{\{l\}} \sum_{i=1}^M \sum_{\substack{j=1 \\ i \neq j}}^M \sum_{l=-\Delta}^{\Delta} |d_i(n) - d_j(n-l)|^2. \quad (4.58)$$

Die Auswertung von (4.58) ist sehr aufwendig, da eine möglichst hohe Anzahl von Signalpaarungen (d_i, d_j) berücksichtigt werden muss. Bei der Übertragung dieses Ansatzes auf Minendaten wäre zudem zu berücksichtigen, dass die Bestimmung einer optimalen Lösung durch die variierende Tiefenlage der Objekte erschwert wird.

Daher wird hier ein anderer Weg gewählt. Sei E die Energie einer Sequenz von Koeffizienten $\mathbf{u} = \{u_i\}$ der Länge N , dann gilt für die normierte kumulative Energie

$$E_c(n) = \frac{1}{E} \sum_{i=1}^n |u_i|^2, \quad n \leq N. \quad (4.59)$$

In Abhängigkeit von einer zyklischen Verschiebung mit der Distanz Δ lässt sich die kumulative Energie der verschobenen Koeffizienten angeben als

$$E_c(n) = \frac{1}{E} \sum_{i=1}^n |u_{j(i)}|^2, \quad j = \text{mod}(i + \Delta, N). \quad (4.60)$$

Im Folgenden wird derjenige Wert von Δ bestimmt, für den E_c am schnellsten anwächst und einen definierten Schwellwert $\gamma \cdot E$ erreicht ($0 < \gamma < 1$)

$$\max_{\{\Delta\}} \left\{ \sum_{i=1}^n E_c(i) \right\} \geq \gamma \cdot E. \quad (4.61)$$

Diese Prozedur ist wenig rechenaufwendig, da jedes Signal einzeln und nicht in Kombination mit anderen betrachtet wird. Pro Signal müssen lediglich alle möglichen Verschiebungen berücksichtigt werden. Die Anwendung auf MWT-Koeffizienten niedriger Oktaven lieferte für einen Wert von $\gamma = 0.95$ gute Ergebnisse (s. Kapitel 6). Dabei ist allerdings zu bemerken, dass sich die Erkennungsraten für höhere Oktaven zunehmend verschlechtern, da dann aufgrund der geringeren Dezimierung eine größere Anzahl von Koeffizienten betrachtet werden muss, was die Anfälligkeit gegenüber Rauschen bzw. Clutter erhöht.

4.7.2 Berechnung von Merkmalen aus Koeffizienten

Eine Alternative zur direkten Verwendung von Koeffizienten bildet die Berechnung statistischer Momente aus den Koeffizienten einzelner Subbänder. Der Vorteil dieses Ansatzes ist die geringe Anzahl und die gleichzeitige Verschiebungsinvarianz der resultierenden Merkmale. Die mit einer WPT erhaltenen Koeffizienten eines Signals mit N Abtastwerten lassen sich mit der Zerlegungsstufe L , dem Index des Subbands n und dem innerhalb eines Subbands laufenden Index der Koeffizienten k schreiben als

$$\mathbf{u} = \{u_{l,n,k}\}, \quad \text{mit } 1 \leq l \leq L, 1 \leq n \leq 2^l, 1 \leq k \leq N/2^l. \quad (4.62)$$

Der tatsächliche Wertebereich von (l,n) hängt von der verwendeten Basis ab. Die Koeffizienten der beiden Ausgangskanäle einer MWT (s. Abschnitt 4.5) lassen sich auf die gleiche Weise verrechnen. Das statistische Moment m -ter Ordnung ist definiert als

$$M_m = \sum_{k=1}^K [u_{l,n,k} - M_0]^m, \quad \text{mit } K = N/2^l \quad \text{und} \quad M_0 = \frac{1}{K} \sum_{k=1}^K u_{l,n,k}. \quad (4.63)$$

Für jedes Subband können u.a. folgende Merkmale berechnet werden, die neben den statistischen Momenten noch weitere Größen umfassen können:

- | | | |
|--|---|--------|
| 1. Mittelwert | $M_0;$ | |
| 2. Standardabweichung | $\sqrt{\frac{M_2}{K-1}};$ | |
| 3. Schiefe | $\frac{M_3}{(M_2)^{3/2}};$ | |
| 4. Kurtosis | $\frac{M_4}{(M_2)^2} - 3;$ | |
| 5. Normierte Energie | $\frac{1}{E_s} \sum_{k=1}^K u_{l,n,k} ^2,$ mit $E_s = \sum_{i=1}^N s_i ^2;$ | |
| 6. Normierte Entropie | $\sum_{k=1}^K p_k \log(p_k),$ mit $p_k = u_{l,n,k} ^2 / E_s;$ | |
| 7. Betragsmittelwert | $\frac{1}{K} \sum_{k=1}^K u_{l,n,k} ;$ | |
| 8. Max. Betrag der Abweichung vom Mittelwert | $\max_{\{k\}} \{ u_{l,n,k} - M_0 \}.$ | (4.64) |

Die oben aufgeführten Größen wurden anhand der resultierenden Erkennungsraten bewertet. Die Berechnungen nach 2.), 6.), 7.) und 8.) wurden daraufhin in die engere Auswahl genommen. Verfahren zur Abschätzung der Trennschärfe von Merkmalen sowie zur Dimensionsreduktion werden im nächsten Abschnitt behandelt.

4.7.3 Dimensionsreduktion

Durch die Bildung von Merkmalen wird ein Signal $\mathbf{x} = \{x_i\}$, mit $i = 1, 2, \dots, N$ Abtastwerten auf einen Merkmalsvektor $\mathbf{y} = \{y_m\}$, mit $m = 1, 2, \dots, M$ abgebildet. Üblicherweise gilt für die Dimension des Merkmalsraums $M \ll N$. Nicht jedes nach (4.64) berechnete oder nach Abschnitt 4.7.1 erhaltene Merkmal ist gleichermaßen zur Trennung verschiedener Klassen geeignet. Hochdimensionale Merkmalsräume machen die Adaption des Klassifikators sehr aufwendig, eine Reduktion der Dimension ist daher meist erforderlich. Prinzipiell stehen hierfür zwei Vorgehensweisen zur Verfügung: entweder die gezielte Auswahl von Merkmalen oder die Projektion der Merkmalsvektoren auf ein Basissystem mit reduzierter Dimension.

Merkmalsselektion

Verfahren der Merkmalsselektion haben zum Ziel aus der Gesamtheit vorhandener Merkmale anhand eines bestimmten Kriteriums die beste Untermenge zu ermitteln. Üblicherweise wird hierfür die Kenntnis der Klassenzugehörigkeit verwendet, daher auch die Bezeichnung als „überwachte“ Auswahlverfahren. Ein wünschenswerter Vorteil ist, dass die Merkmale erhalten bleiben, was die Interpretation ihres Nutzens unter Umständen erleichtert. Wenn die zur Klassentrennung erforderliche Information über viele Merkmale „verschmiert“ ist, kann sich das Weglassen von Merkmalen eventuell nachteilig auswirken.

Die Gesamtheit aller Merkmalsvektoren einer Klasse k (aus N_c möglichen) mit N_k Signalen lässt sich schreiben als

$$Y^k = \{y_n^k\}, \text{ mit } k = 1, 2, \dots, N_c \text{ und } n = 1, 2, \dots, N_k. \quad (4.65)$$

Jeder Merkmalsvektor y_n^k bildet eine Spalte der Matrix Y^k . Der Einfachheit halber wird zunächst ein Zweiklassen-Problem angenommen. Zur weiteren Vereinfachung werden die Merkmale einzeln und nicht in Kombinationen mit anderen betrachtet. Sei N_p bzw. N_q die Anzahl der Muster der Klassen mit den Klassenindizes p bzw. q , dann ergibt sich mit der oben gemachten Annahme, dass die Berechnung der Diskriminanzmaße des m -ten Merkmals anhand der m -ten Zeilen der Matrizen Y^p bzw. Y^q erfolgen kann. Die entsprechenden Zeilen werden im Folgenden als p_m bzw. q_m bezeichnet. Ein Diskriminanzmaß für das m -ten Merkmal kann dann definiert werden durch $D(p_m, q_m)$ [Bas89]. Nachfolgend sind drei der bekanntesten Berechnungsvarianten aufgeführt:

1. **Fisher-Index** [Fis50]:

$$D(p_m, q_m) \doteq \frac{(\mu(p_m) - \mu(q_m))^2}{\sigma^2(p_m) + \sigma^2(q_m)}, \quad (4.66)$$

mit dem Mittelwert $\mu(\cdot)$ bzw. der Varianz $\sigma^2(\cdot)$ der m -ten Zeile.

2. **Symmetrische relative Entropie** [Kul51]:

$$D(p_m, q_m) \doteq u_p \log \frac{u_p}{u_q} + u_q \log \frac{u_q}{u_p}. \quad (4.67)$$

Die skalaren Größen u_p bzw. u_q repräsentieren wahlweise den Mittelwert oder die Varianz der m -ten Zeile der beiden Klassen. Der erste Term für sich genommen wird

auch als *Kullback-Leibler-Distanz* bezeichnet, die aber durch den Nachteil der Asymmetrie zwischen den beiden Klassen gekennzeichnet ist.

3. *Euklidischer Abstand:*

$$D(\mathbf{p}_m, \mathbf{q}_m) \doteq \|u_p - u_q\|, \quad (4.68)$$

mit der obigen Definition von u_p bzw. u_q . Existieren mehr als zwei Klassen, werden für alle $\binom{N_c}{2}$ Paarkombinationen die Werte für $D(\mathbf{p}_m, \mathbf{q}_m)$ summiert [Sai94]:

$$D(\{\mathbf{p}_k\}_{k=1}^{N_c}) \doteq \sum_{i=1}^{N_c-1} \sum_{j=i+1}^{N_c} D(\mathbf{p}_m^i, \mathbf{q}_m^j). \quad (4.69)$$

Alternativ zur oben dargestellten Bildung von Paarkombinationen kann die Bewertung einzelner Merkmale auch durch die Betrachtung einer Klasse gegen eine Restklasse erfolgen, die durch die Vereinigung aller übrigen Klassen gebildet wird. Statt dem paarweisen Modus ergibt sich daraus eine „einer gegen alle“-Bewertung. Beide Alternativen lassen sich auch bei der Bestimmung der Klassengrenzen im Merkmalsraum mit dem Polynomklassifikator einsetzen (s. Anhang A.1) und [Sch96].

Bewertet man statt einzelner Merkmale Kombinationen von Merkmalen, steigt der Rechenaufwand enorm an, eine erschöpfende Suche nach der besten Untermenge ist daher im Allgemeinen nicht durchführbar. Folglich kann nur eine suboptimale Lösung angestrebt werden. Wie schon bei der Bestimmung der am besten diskriminierenden Basis (vgl. Abschnitt 4.4.2) lassen sich dafür sogenannte *Add-On-* oder *Knock-Out-*Methoden einsetzen.

Beim Add-On-Verfahren wird zunächst für jedes einzelne Merkmal die Trennschärfe bestimmt. Danach wird versuchsweise jedes der verbleibenden Merkmale mit dem ersten kombiniert, um das beste Merkmalspaar zu bestimmen. Dieser Prozess wird iteriert, bis eine festgelegte Anzahl von Merkmalen erreicht ist. Diese Vorgehensweise ist der des Knock-Out-Verfahrens sehr ähnlich, nur dass hier ein Weglassen von Merkmalen bis zur Erreichung einer bestimmten Anzahl erfolgt.

In beiden Fällen gelten die in Abschnitt 4.4.2 getroffenen Aussagen, dass ein Kollektiv von Merkmalen eigentlich nur anhand der Erkennungsrate bewertet werden kann, da ansonsten statistische Abhängigkeiten zwischen Merkmalen unberücksichtigt bleiben.

Die Kriterien (4.66) bis (4.68) wurden für die in Abschnitt 2.3 simulierten Radarsignale untersucht, die Ergebnisse werden in Abschnitt 6.2 diskutiert. Abgesehen davon, dass

sich im Allgemeinen nicht die gleiche Rangfolge selektierter Merkmale ergibt, weichen die resultierenden Erkennungsraten kaum voneinander ab. Voraussetzung ist allerdings, dass die Dimension der Merkmalsvektoren ausreichend groß gewählt wird, da ansonsten zur Trennung beitragende, nützliche Informationen unberücksichtigt bleiben.

Merkmalsprojektion

Das bekannteste Verfahren zur Projektion von Merkmalen ist das Verfahren der Hauptachsentransformation, auf das in Abschnitt 3.1 bereits eingegangen wurde. Zur Durchführung einer HAT muss in (3.3) lediglich die Matrix \mathbf{X} durch die Matrix der spaltenweise angeordneten Muster \mathbf{Y}^k aller Klassen ersetzt werden. Die Festlegung der Dimension der transformierten Merkmalsvektoren erfolgt entweder durch Vorgabe der Anzahl zu berücksichtigender Eigenwerte in (3.3) oder durch Vorgabe eines Rekonstruktionsfehlers nach (3.5). Da keine Klassenzugehörigkeiten in die Rechnung eingehen, wird dieses Verfahren auch als „unüberwacht“ bezeichnet. Eine Alternative hierzu bildet das Verfahren der *linearen Diskriminanzanalyse* [Sch96], bei dem im Gegensatz zur HAT Klassenzugehörigkeiten berücksichtigt werden. Da mit diesem Verfahren für die bearbeitete Aufgabenstellung nur deutlich schlechtere Ergebnisse erzielt werden konnten, wird auf nähere Erläuterungen verzichtet.

4.7.4 Klassifikation

Formal besteht das Ziel der statistischen Mustererkennung darin, die gemachten Beobachtungen $\mathbf{x} \in \mathbf{X} \subset \mathfrak{R}^N$, im Merkmalsraum repräsentiert durch die Merkmale $\mathbf{y} \in \mathbf{Y} \subset \mathfrak{R}^M$, einer der möglichen Klassen $w \in \mathbf{W} \equiv \{w^{(1)}, w^{(1)}, \dots, w^{(K)}\}$ im Entscheidungsraum zuzuordnen. Diese Operation kann auch als eine Abbildung verstanden werden:

$$\mathbf{F} : \mathbf{y} \mapsto w. \quad (4.70)$$

Der gesuchte Zusammenhang zwischen Messdaten und Ergebnis der Klassifikation wird durch Beispiele beschrieben. Es gibt eine *Lernstichprobe*, anhand der die Abbildung optimiert wird und eine *Teststichprobe*, mit der man sich anhand statistischer Maße vom Effekt überzeugen kann [Sch96]. Dabei dient die Teststichprobe zur Simulation des praktischen Betriebs, in dem die richtige Entscheidung des Erkennungssystems natürlich nicht bekannt ist. Um einen robusten Klassifikator zu erhalten, ist man darauf angewiesen, dass die Lernstichprobe einen möglichst repräsentativen Querschnitt „auftretender Fälle“ beinhaltet.

Der mustererzeugende Prozess wird durch die Verbundwahrscheinlichkeit $P(\mathbf{y}, w)$ beschrieben, mit \mathbf{y} als Merkmalsvektor und w als Klasse, die die Bedeutung bezeichnet. Das Erkennungssystem erzeugt aus dem gegebenen Merkmalsvektor \mathbf{y} über die Abbildungsfunktion einen Wert \hat{w} , als Schätzwert für die wahre Bedeutung. Die Optimierung des Systemverhaltens hat dann zum Ziel, den Unterschied zwischen geschätzter und wahrer Bedeutung zu minimieren. Mit dem Merkmalsvektor als Argument werden sovieler Unterscheidungsgrößen $d_k(\mathbf{y})$ berechnet, wie Klassen eingeführt wurden.

Im Weiteren soll nicht näher auf die bekannten Klassifikationsalgorithmen eingegangen werden. Bei dem eingesetzten Verfahren handelt es sich um Polynomklassifikatoren, die den wichtigen Vorteil haben, dass die Koeffizientenmatrix analytisch bestimmt werden kann, d.h. eine iterative Adaption, wie z.B. bei *neuronalen Netzen*, ist nicht erforderlich. Ein weiterer Vorteil ist die Möglichkeit einer Bewertung der Merkmale hinsichtlich ihres Beitrags zur Erkennungsleistung. Dieser Punkt wurde in Abschnitt 4.4.2 bereits angesprochen. Die wesentlichen Grundlagen dazu finden sich in Anhang A.1, ansonsten sei hier auf das Buch von Schürmann verwiesen [Sch96].

Die Bewertung der genannten Verfahren zur Merkmalsbildung bildet einen der wesentlichen Inhalte dieser Arbeit, nicht die Weiterentwicklung der Klassifikationsmethoden. Bei der untersuchten Aufgabenstellung sind auch bei Anwendung alternativer Verfahren keine gravierenden Abweichungen der Erkennungsleistungen zu erwarten. In einer Arbeit von Löhlein und Fritzsche [Löh98] wurde bereits ein Vergleich verschiedener Verfahren vorgenommen, allerdings auf der Grundlage anderen Datenmaterials von geringerem Umfang als dem hier verwendeten. Als Alternativen zu dem in dieser Arbeit eingesetzten Polynomklassifikator sind insbesondere die in [Löh98] untersuchten *Hidden Markov Modelle* zu nennen, die vor allem in der Spracherkennung und der Erkennung gebundener Handschrift zum Einsatz kommen [Kal91].

4.8 Wavelet-Netze

In diesem Abschnitt wird eine Erweiterung des *Matching Pursuit* Verfahrens (MP) vorgestellt, einer allgemeinen Prozedur zur Berechnung adaptiver Signalrepräsentationen [Mal93]. Adaptiv heißt in diesem Zusammenhang, dass sowohl die Parameter der analytisch gegebenen Waveletfunktionen als auch ihre Form über die Minimierung einer Fehlerfunktion erfolgen kann. Von grundlegender Bedeutung ist dabei der von Szu, Kadambe und Telfer [Szu92] geprägte Begriff des *Superwavelets*, als einer Linearkombination adaptiver Wavelets.

Mit den bisher beschriebenen Multiresolution-Verfahren wird ein Signal auf eine Bibliothek festgelegter orthogonaler Funktionen projiziert. Für die Signalklassifikation ist aber nicht eine möglichst effiziente Repräsentation, sondern die Erfassung der Differenzen von Signalen von Interesse. Ziel des nachfolgend beschriebenen Verfahrens ist die Konstruktion eines Basissystems von Superwavelets derart, dass durch Projektion der Signale auf diese Superwavelets möglichst getrennte Cluster entstehen. Der Anspruch der Orthogonalität des Basissystems kann dabei fallengelassen werden. Wesentlicher Punkt ist, dass die Ermittlung geeigneter Waveletfunktionen zur Konstruktion dieses Basissystems „datengetrieben“ ist, d.h. die zur Projektion verwendeten Waveletfunktionen stehen nicht von vornherein fest. Dieser Ansatz soll als Alternative zur Erzeugung geeigneter Merkmale bewertet werden.

4.8.1 Matching Pursuits zur Signalrepräsentation

Ausgangspunkt ist eine Bibliothek J_R von Waveletfunktionen, gebildet aus skalierten Kopien einer analytisch definierten Mutterfunktion $\psi(t)$. Der Index R kennzeichnet die Verwendung dieser Bibliothek zur Signalrepräsentation. Prinzipiell können auch mehrere Bibliotheken verschiedener Funktionen zu einer solchen zusammengefasst werden. Jedes Element von J_R wird als ein Atom bezeichnet. J_R stellt eine Untermenge von Γ dar, der Menge aller möglichen Wavelets eines Typs. Wie in (4.1) beschrieben, lässt sich ein Signal $x(t)$ allgemein darstellen als

$$x(t) = \sum_{\gamma \in \Gamma} w^\gamma \psi_\gamma(t) \quad (4.71)$$

oder näherungsweise

$$\hat{x}(t) = \sum_{\gamma \in \Gamma} w^\gamma \psi_\gamma(t) + R, \quad (4.72)$$

mit dem Residuum R und den Amplituden w^γ . Zum Aufbau der Funktionenbibliothek werden Gaborfunktionen verwendet:

$$\psi(t) = \cos(\pi n t') \cdot e^{-\pi t'^2} \quad \text{mit } t' = (t-b)/a, \quad (4.73)$$

mit dem Skalierungsfaktor a , der zeitlichen Translation b und der Anzahl der Zyklen n . Diese Parameter lassen sich in Vektorform schreiben als $\gamma = [w, a, b, n]$, mit der Amplitude w . Die Matching-Pursuit-Prozedur zur Repräsentation von $x(t)$, anhand von maximal N_w Wavelets, besteht dann aus den folgenden Schritten:

- Initialisierung: $\hat{x}_0 = 0, R_0 = x$;

- Update: $\hat{x}_k = \hat{x}_{k-1} + w_k$, $R_k = x - \hat{x}_k$, $k = 1, 2, \dots, N_w$;
- Abbruchkriterium: $\|R_k\| = \sum_{k=1}^N |x - w_k|^2 < \epsilon$. (4.74)

Zum Start wird das Residuum mit dem Eingangssignal initialisiert, das rekonstruierte Signal wird zu null gesetzt. Bei jedem Iterationsschritt k wird die Kreuzkorrelationsfunktion zwischen allen Atomen aus J_R und R als Ähnlichkeitsmaß berechnet. Damit wird eine Zerlegung des Residuums mittels einer Projektion auf die Elemente der Bibliothek vorgenommen, bei Berücksichtigung aller möglichen Translationen der Atome. Aufgrund der Korrelation entfällt die Notwendigkeit zeitlich verschobene Kopien eines Atoms in der Bibliothek zu halten. Das Atom, welches bei einer bestimmten Translation die beste Korrelation liefert, wird zur Adaption verwendet. Wenn ein vorgegebener Fehler unterschritten wird oder eine Maximalanzahl von Wavelets verwendet wurde, wird die Iteration beendet.

In Bild 4.17 ist ein Beispiel einer MP-Adaption dargestellt. Mit wachsender Anzahl beiträger Wavelets nimmt der relative Fehler $\|x - \hat{x}\| / \|x\|$ ab.




Bild 4.17 Matching-Pursuit-Approximation mit adaptiven Wavelets. Das durch Superposition entstehende Signal ist gestrichelt gezeichnet, oben mit 3, in der Mitte mit 25 Atomen. Die untere Kurve beschreibt den relativen Fehler als Funktion der Anzahl beitragender Wavelets.

Wesentlich für die Effizienz dieses Algorithmus zur Signaladaption ist die Größe und Zusammensetzung der Bibliothek \mathbf{J}_R . Für die Diskretisierung des Skalenparameters a wird eine logarithmisch äquidistante Abtastung gewählt. Durch Verwendung von N_v Stimmen pro Oktave wird eine bessere Frequenzauflösung erzielt:

$$a = 2^{\lfloor l - (N_v - n) / N_v \rfloor}, \quad \text{mit } l = L_0, \dots, L_1 \quad \text{und } n = 1, 2, \dots, N_v. \quad (4.75)$$

Nachteile des MP-Verfahrens treten eventuell dann auf, wenn bei den ersten Iterationen nicht sofort die „Hauptbeiträge“ gefunden werden. Wäre dies der Fall, müsste der Algorithmus etliche Wavelets darauf verwenden, diesen Anfangsfehler wieder wettzumachen. Durch eine sorgfältige Auswahl der Bibliotheksfunktionen kann dieses Risiko aber minimiert werden.

4.8.2 Matching Pursuits zur Signalklassifikation

Zum Entwurf eines verschiebungsinvarianten Algorithmus werden im Folgenden statt der Signale selbst deren Autokorrelationsfunktionen verwendet, die jeweils auf Verschiebung null normiert werden. Um eine möglichst hohe Effizienz bei gleichzeitig geringem Rechenaufwand zu erzielen, wird hier eine neue Vorgehensweise zum Aufbau der Bibliothek von Atomen vorgeschlagen.

Es wird klassenweise eine Clusterung der Autokorrelierten durchgeführt, mit jeweils $N_{cl,i}$ Clusterzentren pro Klasse i . Für alle Paarkombinationen von Clustern mit verschiedener Klassenzugehörigkeit wird dann die gemittelte Differenz der Autokorrelierten $c(t)$ für N_r Signale pro Cluster bestimmt. Damit ergibt sich für den i -ten Cluster der p -ten Klasse und den j -ten Cluster der q -ten Klasse folgende Differenz

$$A_{(i,j)}^{(p,q)}(t) = \frac{1}{N_r} \sum_{r=1}^{N_r} c_{r,i}^p(t) - c_{r,j}^q(t). \quad (4.76)$$

Bei N_c Klassen erhält man somit

$$N_d = \sum_{\substack{i,j=1 \\ i \neq j}}^{N_c} N_{cl,i} \cdot N_{cl,j} \quad (4.77)$$

Differenzen. Da der Vergleich aller Signalpaarungen für alle möglichen Kombinationen von Clustern zu rechenaufwendig wäre, wird die Berechnung auf eine zufällig ausgewählte Menge von N_r Signale pro Cluster eingeschränkt. Die so erhaltenen Differenzsignale $A(t)$ werden dann nach dem in Abschnitt 4.8.1 vorgestellten Verfahren adaptiert. Die zur Adaption beitragenden Wavelets bilden die im nächsten Schritt zur Berechnung

der Superwavelets benötigte Bibliothek \mathbf{J}_K . Der Index K kennzeichnet die Verwendung dieser Bibliothek zur Signalklassifikation.

Der prinzipielle Unterschied zu der von Szu und Kadambe [Szu92] veröffentlichten Methode der Signalklassifikation besteht zum einen darin, dass sich die Bibliothek in dem hier vorgestellten Ansatz ausschließlich aus Atomen zusammensetzt, die einen Beitrag zur Klassentrennung leisten, zum anderen erfolgt die Optimierung der Superwavelets immer für Paare von Klassen.

Bei der Approximation werden die Parameter einer frei definierbaren Anzahl von Wavelets optimiert, indem die quadratische Abweichung zwischen Signal und Signalapproximation nach (4.74) minimiert wird. Bei der Signalklassifikation dagegen, wird die mittlere quadratische Abweichung zwischen einer Sollvorgabe, welche die gewünschte Klassenzugehörigkeit bezeichnet und einer Entscheidungsfunktion minimiert. Bei einer paarweisen Betrachtung hat die Sollvorgabe den Wert null oder eins.

In dem hier entwickelten Verfahren wird die Konstruktion der Superwavelets ebenfalls für alle N_d Clusterkombinationen durchgeführt. Für den Cluster i mit N_i und den Cluster j mit N_j Autokorrelierten lässt sich der quadratische Fehler im k -ten Iterationsschritt angeben als

$$E_k^{(i,j)} = \sum_{n=1}^{N_i+N_j} |r_{n,k}^{(i,j)} - v_n^{(i,j)}|^2, \quad (4.78)$$

mit dem Residuum $r_{n,k}^{(i,j)}$, welches mit der Sollvorgabe d_n initialisiert wird, und der Entscheidungsfunktion v_n , gegeben durch

$$v_n^{(i,j)} = (u_n^{(i,j)}) \text{ mit } u_n^{(i,j)} = \sum_{t=1}^T c_n^{(i,j)}(t) \left(\sum_{l=1}^k w_{l-i}(t) \right) = \langle c_n(t), sw_k^{(i,j)}(t) \rangle, \quad k \leq N_w, \quad (4.79)$$

mit der Sigmoidfunktion $(u) = 1/(1 + e^{-u})$, die beliebige Werte der Eingangsgröße u auf einen Wert im Intervall $[0,1]$ abbildet. Der Term in eckigen Klammern bezeichnet das Innenprodukt zwischen einer Autokorrelierten c_n und einem Superwavelet sw , welches durch Superposition von maximal N_w Waveletfunktionen γ entsteht.

Bei jedem Iterationsschritt werden die Elemente des Parametervektors $\mathbf{p} = [w, a, b, n]$ desjenigen Atoms aus \mathbf{J}_K , welches den größten Beitrag zur Fehlerreduktion liefert, über ein Optimierungsverfahren so adaptiert, dass das resultierende Wavelet $\tilde{\psi}$ ein Minimum der Fehlerenergie in der Umgebung von \mathbf{p} darstellt. Als Optimierungsverfahren kann die *Methode des steilsten Abstiegs* [Papa98] eingesetzt werden, unter Verwendung des Gradientenvektors

$$\mathbf{g}_k = \left[\frac{\partial E_k}{\partial w_k}, \frac{\partial E_k}{\partial a_k}, \frac{\partial E_k}{\partial b_k}, \frac{\partial E_k}{\partial n_k} \right]. \quad (4.80)$$

Aus den in jedem Iterationsschritt bestimmten Wavelets wird sukzessive das Superwavelet „zusammengesetzt“ und nach jedem Schritt aktualisiert (die Indizierung der Clusterzugehörigkeit (i,j) wird hier weggelassen)

$$sw_k = sw_{k-1} + w_{k \cdot k}. \quad (4.81)$$

Für das Residuum gilt

$$r_{n,k} = r_{n,k-1} - \langle c_n, sw_k \rangle. \quad (4.82)$$

Die Methode des steilsten Abstiegs hat den Nachteil, dass nicht immer das globale Optimum, sondern lediglich ein Nebenminimum gefunden wird. Daher wird hier auch das *Threshold-Accept-Verfahren* von Dueck [Due93] untersucht [s. Anhang A.2]. Dieses Optimierungsverfahren ist der Methode des *Simulated Annealing* [Kin88] sehr ähnlich. Der Unterschied besteht in der Akzeptanzregel der Verschlechterung eines gegebenen Zustands. Beim Simulated Annealing wird mithilfe eines Zufallsexperiments entschieden, ob eine Verschlechterung akzeptiert wird oder nicht, während beim Threshold-Accept-Algorithmus nach einiger Zeit die Differenz abgesenkt wird, um die ein neu eingenommener Zustand schlechter sein darf als der alte. Laut Dueck verfängt sich Simulated Annealing leichter in lokalen Minima und zeigt eine langsamere Konvergenz als das Threshold-Accept-Verfahren.

Wird die Berechnung der Superwavelets nicht für eine paarweise Klassentrennung durchgeführt, sondern nach dem „einer-gegen-alle“-Schema, lässt sich der entsprechende Algorithmus in Form eines einfachen Netzwerks beschreiben (Bild 4.18). Den Input bilden direkt die zu trennenden Signale bzw. deren normierte Autokorrelationsfunktion. Die Eingangsschicht beschreibt das Innenprodukt zwischen den Signalen und den Atomen der Bibliothek. Jedes Additionsglied bildet eine gewichtete Summe der Innenprodukte. Dies entspricht einer Projektion auf Superwavelets. Die Ergebnisse dieser Projektion werden über eine Schwellwertfunktion geleitet und liefern die Entscheidungsfunktion.

Die Selektion beitragender Wavelets sowie die Adaption ihrer Parameter erfolgen iterativ nach (4.78), durch Minimierung des mittleren quadratischen Fehlers am Ausgang des Netzes. Ziel ist Entscheidungsvektoren zu erhalten, die möglichst die Form von Einheitsvektoren haben, bspw. $\mathbf{d} = [1,0,0]^T$ für eine Zugehörigkeit des untersuchten Musters zu Klasse 1.




Bild 4.18 Input des Wavelet-Netzes bilden direkt die zu klassifizierenden Signale (bzw. deren Autokorrelierte). Jedes Additionsglied bildet durch gewichtete Summation ein Superwavelet, welches nach einer Schwellwertbildung die Entscheidungsfunktion liefert. Dargestellt ist ein Netzwerk zur Trennung von 3 Klassen.

Bei diesem *Wavelet-Netz* oder *Wavelet-Perzeptron* handelt es sich um einen linearen Klassifikator, genauer gesagt um einen linearen Funktionalklassifikator [Sch96]. Bei paarweiser Klassifikation muss für jede Kombination zweier Cluster mit unterschiedlicher Klassenzugehörigkeit ein Netz mit nur einem Ausgang gebildet und diese Ausgänge dann miteinander verrechnet werden, um zu einer Entscheidung zu gelangen.

Geht man von einem Dreiklassen-Problem aus, ergeben sich bei 2 Clustern pro Klasse nach (4.77) 12 Superwavelets. Bild 4.19 zeigt ein Beispiel von aus Messdaten erhaltenen Superwavelets. Um das vorgestellte MP-Verfahren im direkten Vergleich mit den anderen in diesem Kapitel vorgestellten Methoden zur Merkmalsbildung beurteilen zu können, werden die Superwavelets nur zur Generierung von Merkmalen eingesetzt, die dann wiederum als Eingangsgrößen eines Klassifikators dienen.

Die wesentlichen Vorteile des vorgeschlagenen Wavelet-Netz-Algorithmus sind i) die besondere Wahl der Bibliotheksfunktionen anhand von Differenzautokorrelationsfunktionen, ii) die Optimierung der Waveletfunktionen derart, dass die mit den Superwavelets erzielte Diskriminanz und nicht die Güte der Approximation maximiert wird sowie iii) die Adaption der Superwavelets derart, dass immer Paarkombinationen von Klassen betrachtet werden. Ferner iv) der Ansatz, dass pro Klasse mehr als ein Superwavelet verwendet werden kann, was zu einer Erhöhung der Trennschärfe beiträgt.

Die Summe dieser Eigenschaften erlaubt im Unterschied zur WT, WPT oder MWT, mit ihren festgelegten Funktionsbibliotheken, eine datenadaptive Anpassung der Funktionen, die zur Diskrimination eingesetzt werden.




Bild 4.19 Beispiele von aus Messdaten erhaltenen Superwavelets, für drei Klassen mit jeweils 2 Clustern pro Klasse.

4.9 Alternative Verfahren der Zeit-Frequenz-Analyse

Eine Alternative zu den Multiresolution-Verfahren bilden die in den Abschnitten 4.2.1 und 4.2.2 bereits angesprochenen linearen oder quadratischen Zeit-Frequenz-Verfahren. Deren Nachteil liegt zum einen im Rechenaufwand, zum anderen in der großen Redundanz der erhaltenen Repräsentationen, die dazu führt, dass das Problem der Bildung von Merkmalen lediglich von einem ein- in einen zweidimensionalen Raum verlagert wird. Eine Möglichkeit zur Reduktion der mittels einer WVD erhaltenen Zeit-Frequenz-Repräsentation bildet die Singularwert-Zerlegung (SVD⁸). Die verwertbare Signalinformation ist auf wenige Singularwerte konzentriert, die zudem invariant gegenüber Verschiebungen in Zeit und Frequenz sind [Mari85]. Der erforderliche Rechenwand liegt allerdings deutlich über dem der Multiresolution- oder FFT-Verfahren, daher wurde die SVD-Methode hier nicht berücksichtigt.

4.9.1 Fourier-Spektren

Die Verwendung von Betragsspektren, erhalten mithilfe einer FFT, bietet eine einfache Möglichkeit zur Extraktion von Merkmalen aus Zeitsignalen. Entweder werden geeignete

⁸ Von engl. *Singular Value Decomposition*.

Spektralkoeffizienten selektiert oder es wird bspw. eine Hauptachsentransformation zur Dimensionsreduktion eingesetzt (s. Abschnitt 4.7.3). Hier wird der zweite Weg gewählt. Zur Verringerung des Rechenaufwands können die zu berücksichtigenden Spektralkoeffizienten entsprechend der Signalbandbreite beschränkt werden. Da in erster Linie die Signatur eines Signals und nicht dessen Amplitude Aufschluß über den zu bestimmenden Objekttyp gibt, werden Leistungsdichtespektren mit einer vorgegebenen Dynamik D_S verwendet, d.h. es wird eine Normierung der Spektren $S\{x_i\}$ jedes Signals x_i nach folgender Vorschrift durchgeführt (das Argument $\{x_i\}$ wird hier der Übersichtlichkeit halber weggelassen):

$$S_n = D_S + 20 \log_{10} \left(\max \left\{ \frac{(S - S_{\min})}{(S_{\max} - S_{\min})}, 10^{-\frac{D_S}{20}} \right\} \right), \quad (4.83)$$

mit S_{\min} und S_{\max} als dem Minimum bzw. Maximum aller Signalspektren.

Bild 4.20 zeigt beispielhaft die ersten 8 Eigenvektoren bzw. Eigenspektren, die aus den verfügbaren Felddaten berechnet wurden, sortiert nach in der Größe abfallenden Eigenwerten, für eine Dynamik von $D_S = 30$ dB.




Bild 4.20 Zu den ersten 8 Eigenwerten λ_{1-8} gehörige Eigenvektoren bzw. Eigenspektren.

Dargestellt sind jeweils die ersten 32 Werte der Eigenvektoren, die aufgrund des Frequenzgehalts der verarbeiteten Signale hinreichend sind. Die nach (4.83) erhaltenen Spektren werden auf die mithilfe der HAT nach (3.3) erhaltenen Eigenvektoren bzw. Eigenspektren projiziert und liefern so die gesuchten Merkmalsvektoren, deren Länge durch die Anzahl der Eigenvektoren festgelegt ist. Die mit diesem Spektralansatz erhaltenen Ergebnisse werden in Kapitel 6 denen mittels der Multiresolution-Verfahren gewonnenen gegenübergestellt.

4.9.2 Prony-Verfahren

Die CNR-Methode komplexer natürlicher Resonanzen⁹ stellt einen weiteren Ansatz zur mathematischen Beschreibung von Georadarsignalen dar. Physikalische Grundlage ist die Annahme, dass auf ein Objekt einfallende elektromagnetische Strahlung hoher Bandbreite charakteristische Resonanzen hervorruft, anhand derer sich verschiedene Typen von Objekten unterscheiden lassen. Durch Superposition von M exponentiell gedämpften Sinusschwingungen wird ein Zeitsignal folgendermaßen approximiert:

$$s(n) = \sum_{k=1}^M a_k e^{b_k n}, \quad (4.84)$$

mit den komplexen Amplituden a_k und den komplexen Polen $b_k = -\gamma_k + i\omega_k$. Im Gegensatz zu b_k nimmt a_k Werte an, die sowohl von der Objektorientierung als auch von der anregenden Quelle abhängig sind. Chen und Peters verbinden die CNR-Methode mit einem von ihnen als *Late-Time Spectrum* (LTS) Technik eingeführten Verfahren, bei dem der zeitlich zuerst beim Empfänger ankommende Teil eines Signals nicht in die Verarbeitung mit einbezogen wird, um den Einfluss des Oberflächenechos und oberflächennahen Clutters zu vermindern [Che97b]. Das LTS-Verfahren erfordert allerdings eine nur schwer durchführbare Ausrichtung der A-Scans in Zeitrichtung zur Korrektur oberflächenbedingter oder bodenbedingter Laufzeitvariationen.

Die Stärke der inneren Resonanzen ist abhängig vom dielektrischen Kontrast zwischen einem Objekt und seiner Umgebung. Je geringer der Kontrast, desto höher ist die Dämpfung. Der Wert für ε_r von Plastikminen liegt im Allgemeinen im Bereich von 2 bis 6, der von trockenem Sand bei 3 bis 5, d.h. die Kontraste sind relativ gering. Dies führt zu einer großen Instabilität der Pole. Das Verfahren erscheint daher eher für die Ortung und Klassifikation größerer Objekte, wie z.B. metallische Blindgänger oder ATMs geeignet, weniger für APMs.

⁹ Von engl. *Complex Natural Resonances*.

Im Gegensatz zu den in Abschnitt 4.8 vorgestellten Wavelet-Netzen werden mit dem Prony-Ansatz nicht die Unterschiede zwischen Funktionen erfasst, sondern es wird versucht die zu trennenden Signale zu approximieren, um dann die komplexen Pole als Merkmale für die Klassentrennung heranzuziehen.

Einen Überblick über den Einsatz von Prony-Verfahren für GPR-Untersuchungen wird in [Che97] und [Car00] gegeben. Die dort präsentierten Ergebnisse beschränken sich auf die Auswertung von wenigen Messungen und lassen daher keinen Rückschluß auf eine allgemeine Anwendbarkeit des Verfahrens zu. Für einige der im Rahmen dieser Arbeit zur Verfügung stehenden Datensätze wurden die komplexen Größen nach (4.84) anhand eines modifizierten Prony-Verfahrens [Osb95] bestimmt und auf ihre Eignung als Merkmale überprüft. Eine Trennung verschiedener Klassen oder die Unterscheidung zwischen Objekten und Hintergrundsignalen war nicht möglich.

5. Daten

Bevor in Kapitel 6 die Ergebnisse der Anwendung der entwickelten Verfahren zur Objektdetektion und merkmalsbasierten Klassifikation vorgestellt werden, wird in den folgenden drei Abschnitten zunächst eine kurze Übersicht und Beschreibung der verwendeten Daten gegeben. Um die Tragfähigkeit des Ansatzes zur Unterscheidung von Objekten anhand charakteristischer Signaturen bewerten zu können, wurde in mehreren Schritten vorgegangen.

Im ersten Schritt soll eine Verifikation auf der Grundlage simulierter Streusignale erfolgen. Simulationen, frei von Messfehlern und störenden Umgebungseinflüssen, ermöglichen eine erste Beurteilung der erreichbaren Erkennungsleistung und bildeten den Ausgangspunkt zur Entwicklung der in Kapitel 4 beschriebenen Verfahren zur Berechnung von Merkmalen.

Im nächsten Schritt werden Messdaten verwendet, die durch Freiluftvermessung von Kugeln mit unterschiedlicher Größe und Materialzusammensetzung erhalten wurden. Derartige Streuexperimente gestatten eine Untersuchung anhand von realen Messdaten, ohne den störenden Einfluss der Oberflächenreflektion oder des Bodenclutters.

Schließlich wird die Verarbeitungskette, bestehend aus einer Detektionsstufe, der Merkmalsextraktion und der Klassifikation, auf Messdaten angewendet, die an vergrabenen Objekten gewonnen wurden.

5.1 Simulationen

Wie in Abschnitt 2.3 beschrieben, wurde die Streuung elektromagnetischer Wellen an Kugeln mit konzentrischem Aufbau simuliert. Wesentlich dabei ist, dass für das verwendete Modell die Kugeln in reale, verlustbehaftete Böden eingebettet sind, mit frequenzabhängigen dielektrischen Parametern, die durch Messungen an Bodenproben erhalten wurden (s. Abschnitt 2.2.2). Insgesamt wurden für die Simulation 62 verschiedene Bodenproben verwendet, die bei verschiedenen Feuchtigkeitsgehalten (bezogen auf das Volumen der Probe) vermessen worden waren. Proben mit einem Wassergehalt von mehr als 25 % wurden aufgrund der extremen Dämpfung nicht berücksichtigt.

Um festzustellen, ob Abhängigkeiten zwischen der Erkennungsrate und der Bodenfeuchte bestehen, wurde eine Einteilung der Feuchte in Intervalle vorgenommen. Tabelle 5.1 zeigt die Anzahl vermessener Proben in den einzelnen Intervallen, in Schritten von 5 %.

Bodenfeuchte [Volumenprozent]	Anzahl Bodenproben
0 - 5	17
5 - 10	20
10 - 15	8
15 - 20	8
20 - 25	9

Tabelle 5.1 Anzahl zur Simulation verwendeter Bodenproben, sortiert nach dem volumetrischen Feuchtegehalt.

Modelliert wurde die Rückstreuung dreier Kugeln mit unterschiedlichem inneren Aufbau. Alle drei besitzen einen äußeren Durchmesser von 10 cm sowie eine PVC-Hülle von 5 mm Dicke, unterscheiden sich aber hinsichtlich des inneren Kerns, wie in Bild 5.1 dargestellt. Links eine mit Sprengstoff gefüllte Kugel, in der Mitte eine Hohlkugel und rechts eine mit PVC beschichtete Metallkugel. Die dielektrischen Eigenschaften des verwendeten Sprengstoffsurrogats sind in Bild 2.9 angegeben. Im Bereich von 1-2 GHz liegt der betreffende Wert für ϵ_r bei ungefähr 3.1.



Bild 5.1 Modellierte Kugelobjekte. Der Durchmesser aller Kugeln beträgt 10 cm, die Dicke der PVC-Hülle jeweils 5 mm.

Für jede der drei Kugeln wurden für alle 5 Feuchtigkeitsintervalle die rückgestreuten Signale für Sendepulse mit einem Frequenzschwerpunkt zwischen 1 GHz bis 5 GHz berechnet, in Schritten von 1 GHz. Als Pulsform diente der in (2.35) definierte Ricker-Puls. Für jede der resultierenden 25 Parameterkombinationen wurden 200 Streusignale von jeweils 6.4 ns Dauer (bei 128 Abtastwerten) berechnet. Sowohl die Bodenprobe im jeweiligen Feuchteintervall als auch die Tiefenlage des Kugelmittelpunkts im Bereich 5.5 cm bis 24.5 cm wurden zufällig gewählt. Die Einschränkung der Tiefe erscheint

sinnvoll, da statistischen Erhebungen zufolge über 90 % der weltweit vergrabenen Landminen in einer Tiefe von weniger als 20 cm liegen.

Die Simulation wurde für eine monostatische Anordnung von Sende- und Empfangsantenne durchgeführt und auf die Berechnung von Scheitelscans (lotrecht über der Kugel) eingeschränkt. Aufgrund der Rotationssymmetrie der modellierten Objekte weisen die erhaltenen Signaturen, bei den für GPR-Systeme üblichen Aperturen unter denen ein Objekt „gesehen“ werden kann, auch für bistatische Antennenanordnungen kaum Variationen auf.

Zur Erzeugung der Lern- und Testdaten wurden die für jede Kombination von Feuchte und Pulsspektrum erhaltenen Signale mittels einer zufälligen Auswahl in zwei Gruppen im Größenverhältnis 2:1 aufgeteilt.

5.2 Messungen an Kugeln in Luft

Die Anwendung der vorgeschlagenen Verfahren zur objektbezogenen Unterscheidung von Radarsignaturen lässt sich am einfachsten anhand von Messungen verifizieren, die weder durch den Einfluss der Bodenoberfläche, noch durch Cluttereffekte beeinträchtigt sind. Dies erfordert eine Vermessung der Testobjekte in Luft als umgebendem Medium. Die auf diese Weise vermessenen Kugeln sind in Tabelle 5.2 aufgeführt.

Kugeltyp	Durchmesser [cm]	ϵ_r
Holz	6	≈ 2
Styropor	8	≈ 1
Glas	4	5-10
Plastik, hohl	7.5	≈ 1
Plastik, sandgefüllt	7.5	≈ 2.5
Metall	10	-

Tabelle 5.2 In Luft vermessene Kugeln. Die Wandstärke der Plastikkugeln beträgt 3 mm.

Bei der Durchführung dieser Experimente wurden die Kugeln einzeln in eine für den Radarsensor „unsichtbare“ Plastiktüte gelegt und in etwa einem Meter Abstand mehrere Male auf die Antenne zu und zurück bewegt. Durch die Bewegung entsteht die hyperbel-

förmige Struktur der Echos, die in Bild 5.2 deutlich zu sehen ist. Die ausgewählten Objekte wurden von der Firma *ERA Technology* (England) mit dem *Superscan*[®]-Pulsradar vermessen, sowohl mit einer 1 GHz- als auch mit einer 2 GHz-Dipolantenne.




Bild 5.2 Beispiel einer in Luft vermessenen, sandgefüllten Plastikkugel: a) Rohdaten der 1 GHz-Antenne; b) wie a), nach Kompensation der direkten Überkopplung zwischen Sende- und Empfangsantenne; c) Rohdaten der 2 GHz-Antenne; d) wie c), nach Kompensation. Die hyperbelförmigen Echos entstehen durch Hin- und Herbewegung der Objekte in Richtung der Antenne. Für die Klassifikation wurden alle A-Scans eines „Objektpakets“ herangezogen, angedeutet durch den vertikalen Balken in d).

Die obere Reihe in Bild 5.2 zeigt die Messungen mit der 1 GHz-Antenne, links die Rohdaten, rechts nach Anwendung einer Kompensation zur Unterdrückung der direkten Überkopplung zwischen Sende- und Empfangsantenne (in jeder Bildzeile wurde der Mittelwert subtrahiert). Unten die entsprechend für die 2 GHz-Antenne erhaltenen Messdaten. Die durch die inneren Resonanzen der Kugel hervorgerufenen Reverberationen äußern sich durch in Zeitrichtung verschobene Hyperbeln mit wechselnder Polarität.

Zur Klassifikation wurde pro Objekt ein Paket benachbarter Scans herangezogen, wie in Teilbild d) in Bild 5.2 durch den vertikalen Balken angedeutet. Insgesamt wurden 72 Pakete für die 1 GHz-Messungen und 60 Pakete für die 2 GHz-Messungen „ausgeschnitten“, d.h. die folgende Merkmalsextraktion wurde nur auf die Pakete angewendet. Zur Erzeugung der Lern- und Testdaten wurden jeweils die Pakete aller Datensätze gleicher Sendefrequenz in eine Zufallsreihenfolge gebracht und im Verhältnis 2:1 aufgeteilt (vgl. Abschnitt 5.1).

An dieser Stelle ist zu betonen, dass eine Zufallsaufteilung einzelner Radarscans (als Spalten der Radargramme in Bild 5.2) nicht notwendigerweise zum gleichen Resultat führt, da dann keine objektbezogene Separation der Messdaten mehr gegeben ist. Bei dieser Vorgehensweise wären im Allgemeinen bessere Erkennungsergebnisse zu erwarten, da oft der Fall eintreten wird, dass unmittelbar benachbarte A-Scans, die eine hohe Korrelation aufweisen, dem Lern- bzw. Testset zugeordnet sind. Somit wäre jedes Paket gleichermaßen (im Verhältnis 2:1) sowohl in den Trainings- als auch in den Testdaten vertreten.

5.3 Messungen an vergrabenen Objekten

Die in dieser Arbeit untersuchten GPR-Daten wurden begleitend zu einem von der EU geförderten Projekt [Dre99] aufgezeichnet, mit dem Ziel Ansätze der Multisensorfusion für die Minendetektion zu entwickeln [Fri00]. Die Messkampagne wurde von Thomson Detexis (Frankreich) auf dem Gelände des *Joint Research Centre* (JRC) in Ispra (Italien) durchgeführt, einer europäischen Forschungseinrichtung. Als Radarsensor wurde ebenfalls ein *Superscan*[®]-Pulsradar der Firma *ERA Technology* (England) mit einer 1 GHz-Dipolantenne eingesetzt.

Vier verschiedene Typen von Antipersonenminen wurden vermessen (s. Bild 5.3): sowohl mit hohem als auch mit vernachlässigbarem Metallgehalt, ferner eine große Anzahl von Clutterobjekten. Angaben zur Größe der Minen finden sich in Tabelle 5.3. Aus Sicherheitsgründen durften die Minen keinen Sprengstoff enthalten. Sie wurden daher von Experten der italienischen Armee mit Sprengstoffsurrogaten entsprechend präpariert.




Bild 5.3 Verwendete Typen von Antipersonenminen: a) MAUS/1, b) AUPS, c) VAR/40, d) Valsella-VSMK2. Bei b) bis d) handelt es sich um Plastikminen. Weitere Angaben, auch zur Größe, finden sich in Tabelle 5.3.

Neben den Minen wurden noch weitere Objekte vermessen: Patronenhülsen; Sicherheitspins (der Minen); Aluminiumstücke von 10 bzw. 50 mm Größe und zerdrückte Cola-dosen. An metallfreien, natürlichen Objekten wurden vermessen: Steine unterschiedlicher Größe (ungefähr 3 bis 8 cm Durchmesser); mehrere Holzstücke; Wurzeln und in die Bodenoberfläche eingedrückte Löcher.

Minentyp	Durchmesser	Höhe	Metallgehalt
Maus/1	89 mm	46 mm	hoch
AUPS	102 mm	36 mm	0.5 g
Var40	78 mm	45 mm	gering
Valsella VSMK2	61 mm	32 mm	gering

Tabelle 5.3 Vermessene Typen von Antipersonenminen. Bis auf den ersten Typ handelt es sich bei allen Minen um Plastikminen mit extrem geringem Metallgehalt.

Vier Bodentypen standen zur Verfügung: i) Feld, mit relativ glatter Oberfläche; ii) sandiger, trockener Untergrund; iii) das in Ispra vorhandene Terrain (gemähte Wiese) und iv) ein mit aufgeworfenem, lockerem Erdreich bedeckter Boden, vergleichbar einem umgepflügten Acker. Aus Tabelle 5.4 wird ersichtlich, wie sich die Messungen auf die untersuchten Objekt- und Bodentypen aufteilen.

Bodentyp \ # Objekte	Metallminen	Plastikminen	Objekte (metallisch)	Objekte (dielektr.)	Falsch-alarne	Σ
Feld (glatt)	13	41	22	33	51	160
sandig	10	36	18	6	33	103
Wiese	10	26	6	6	24	72
lockeres Erdreich	0	4	12	10	18	44
Σ	33	107	58	55	126	379

Tabelle 5.4 Aufteilung der durchgeführten Messungen nach Objektkategorie und Bodentyp. Pro Datensatz wurden 3 zufällig positionierte Falschalarne ausgewählt.

Um die Reproduzierbarkeit der Messungen zu gewährleisten und Positionsfehler auszuschließen, wurden die Antennen an einer computerkontrollierten Positionierungsvorrichtung befestigt. Pro 3D-Messung wurde ein Areal von $1 \times 1.5 \text{ m}^2$ auf einem $2 \times 2 \text{ cm}$

Raster abgetastet. An jedem Messpunkt wurde ein Signal von 12.8 ns Länge mit 256 Abtastwerten aufgezeichnet. Bei trockenem Sandboden ($\epsilon_r \approx 4$) entspricht dies einem Tiefenbereich von einem knappen Meter. Bild 2.2 zeigt ein Beispiel der erhaltenen Messdaten.

Insgesamt standen 42 3D-Datensätze zur Verfügung. Da der Erkennungsalgorithmus auch mit *False-Positives* trainiert werden muss, wurde aus jedem Datensatz an jeweils drei zufällig ausgewählten Positionen eine Stichprobe des reinen Boden- bzw. Hintergrundsignals entnommen (s. Spalte *Falschalarme* in Tabelle 5.4). Dabei wurde ein Mindestabstand von vier Abtastwerten zwischen der horizontalen Position der Stichprobe und den tatsächlich vorhandenen Objekten eingehalten. Dieser Wert ergab sich als mittlerer Radius der Detektionen.

Die Verlegetiefe der Objekte schwankte zwischen 0 und 10 cm, ihre räumliche Lage wurden ebenfalls variiert (0° oder 30° Neigung gegen die Horizontale). Eine möglichst große Vielfalt dieser experimentellen Bedingungen ist eine wichtige Voraussetzung für die auf Objektsignaturen aufbauende Erkennung, da die Streueigenschaften Abhängigkeiten von der Orientierung des Streukörpers zur einfallenden Strahlung aufweisen können. Nur wenn jeder Minentyp mehrfach aufgenommen wird, kann davon ausgegangen werden, dass die erhaltene Datenbasis und somit der adaptierte Klassifikator auch wirklich repräsentativ sind. Nach den Erfahrungen von Minenräumexperten ist die räumliche Lage von Minen in manchen Regionen rein zufällig. Dies gilt zum Beispiel in Ländern wie Mozambique oder El Salvador, wo während der Regenzeit große Erdmassen, mit den darin enthaltenen Minen, weggeschwemmt werden.

Da für die Messungen nur ein begrenzter Zeitraum zur Verfügung stand, war die Einbeziehung jahreszeitlicher Variationen der Umgebungsparameter nicht möglich. Der Grad der Bodenfeuchtigkeit wies aber über die Dauer der Experimente durchaus Schwankungen auf. Für die praktische Umsetzung eines Erkennungssystems kann eine Einschränkung des adaptierten Klassifikationsalgorithmus auf unterschiedliche Boden- und Klimabedingungen unter Umständen sinnvoll sein, d.h. je nach äußeren Bedingungen ließe sich dann ein anderer Erkenner einsetzen.

Um den Einfluss des Antennenabstands vom Boden auf die Detektionsleistung zu bewerten, wurden die Messungen bei 10 bzw. 15 cm Abstand durchgeführt. Die dazu in [Fri00] veröffentlichten Ergebnisse ergaben keine diesbezügliche Abhängigkeit der Detektionsrate, daher wird im Folgenden auf eine Unterscheidung der beiden Fälle verzichtet.

Der in Abschnitt 5.2 bereits beschriebenen Vorgehensweise folgend, wurden zur Erzeugung der Lern- und Testdatensätze sowohl die Objekte als auch die Hintergrundproben in eine Liste eingetragen. Durch zufällige Auswahl wurde dann eine Aufteilung im Verhältnis 2:1 auf Lern- und Testset vorgenommen.

Eine alternative Methode zur gewählten Aufteilung in Lern- und Testdaten ist das sogenannte „leave-one-out“-Verfahren, bei dem alle Muster (hier die zu einem potenziellen Objekt zugehörigen Scans) bis auf eines den Lerndaten zugeordnet werden. Der adaptierte Klassifikator wird dann auf das verbliebene Muster angewendet. Diese Prozedur wird entsprechend der Anzahl der Muster wiederholt, jedes Mal wird ein anderes weggelassen. Die Erkennungsrate wird dann über alle Wiederholungen gemittelt. Aufgrund der hohen Anzahl hier betrachteter Objekte wurde dieses Verfahren in dieser Arbeit nicht eingesetzt.

Um dennoch eine Aussage über den Einfluss der zufälligen Aufteilung in Lern- und Testset auf die Erkennungsleistung machen zu können, wurde die Auswahl- und Trainingsphase mindestens 10 Mal wiederholt. Aus der Standardabweichung der erzielten Klassifikationsergebnisse lässt sich ableiten, wie gut der Generalisierungsschritt von den Lern- auf die Testdaten gelingt. Bei großen Abweichungen der Erkennungsraten zwischen den beiden Datensätzen ist davon auszugehen, dass der Klassifikator entweder an die Lerndaten überadaptiert ist oder diese nicht repräsentativ sind.

6. Ergebnisse

Die erfolgreiche Anwendung des neuen Auswerteverfahrens zur Detektion von Landminen wird in Abschnitt 6.1 anhand von aus Messungen gewonnenen 3D-Datensätzen verifiziert. Die prinzipielle Eignung charakteristischer Radarsignaturen zur Trennung von Objekten unterschiedlicher Geometrie oder Materialeigenschaften wird in Abschnitt 6.2 zuerst für simulierte Daten nachgewiesen. In Abschnitt 6.3 erfolgt der Nachweis für reale Messdaten zunächst anhand von Streuexperimenten, die nicht an vergrabenen, sondern an Kugeln in Luft durchgeführt wurden. Im nächsten Schritt werden in Abschnitt 6.4 die Verfahren zur Merkmalsbildung und Klassifikation auf die Gesamtheit aller vergrabenen Objekte angewendet, um dann im entscheidenden letzten Schritt in Abschnitt 6.5 mit der Datenauswertung der tatsächlich detektierten Objekte verknüpft zu werden. Eine Bewertung der entwickelten Zeit-Frequenz-Analyseverfahren, hinsichtlich ihrer Eignung zur Merkmalsextraktion, findet sich in Abschnitt 6.6.

6.1 Verifikation des Detektionsverfahrens

Die in Bild 3.1 detaillierte Folge von Verarbeitungsschritten wurde auf alle 42 zur Verfügung stehenden 3D-Datensätze angewendet. Mittels der Hauptachsentransformation wurde eine Reduktion auf 4, bzw. nach Durchführung der Hilberttransformation auf 8 horizontale Projektionen vorgenommen, die dann entsprechend der in Abschnitt 3.2 beschriebenen Verfahren zur Detektion kreisförmiger Objekte ausgewertet wurden.

Ein Objekt wird dann als erfolgreich detektiert gewertet, wenn der Mittelpunkt der Fläche eines hypothetischen Objekts innerhalb einer kreisförmigen Halo mit Radius r_H um die korrekte Position liegt. Der Wert von r_H ergab sich als mittlerer Radius aller erhaltenen Detektionen zu 4 Abtastwerten, dies entspricht einem Durchmesser von 16 cm. Die Abmessungen dieses Halo sind eine charakteristische Größe des Sensors. Befindet sich mehr als ein Objekt innerhalb dieses Bereichs, so können diese nicht getrennt geortet werden. Dies kann direkte Auswirkungen auf die zu bestimmenden Detektions- und Falschalarmwahrscheinlichkeiten haben. Daher wurde dieser Umstand bei der Planung und Durchführung der Messkampagne berücksichtigt und alle Objekte in ausreichendem horizontalen Abstand zueinander platziert.

Bezeichnet A die Fläche des abgetasteten Areal und N_{Obj} die Anzahl der darin verlegten Objekte, beträgt die Anzahl der maximal möglichen Falschalarme:

$$N_{FA} = (A - N_{Obj} \cdot \pi \cdot r_H^2) / (\pi \cdot r_H^2). \quad (6.1)$$

Anstelle von Falschalarmwahrscheinlichkeiten wird im Folgenden die Anzahl der Falschalarme pro Fläche angegeben. In der Praxis erlaubt dieser Quotient einen besseren Vergleich unterschiedlicher Sensoren, aufgrund der Unabhängigkeit vom *Footprint* des Sensors oder den charakteristischen Abmessungen der gesuchten Objekte.

Die Bilder 6.1 und 6.2 zeigen den auch als *ROC-Kurven*¹⁰ bezeichneten Verlauf der Detektionswahrscheinlichkeiten (PD) in Abhängigkeit von der Anzahl der Falschalarme (FA) pro m². Zu ihrer Berechnung wurde die auf die Ergebnisse der CFAR-Prozessierung angewendete Binarisierungsschwelle so variiert, dass zwischen 10 und 20 % aller Pixel eines C-Scans oberhalb der Schwelle lagen (vgl. Bild 3.7). Die Detektionsraten werden zum einen für die Gesamtheit aller Messungen angegeben (s. Bild 6.1), zum anderen getrennt nach Bodentyp (s. Bild 6.2), um den Einfluss der Bodeneigenschaften auf die Detektionsleistung aufzuzeigen.

Geht man von einem Falschalarm pro m² aus, werden alle metallhaltigen Minen gefunden. Dies ist nicht weiter erstaunlich, da diese Minen deutliche Echos hervorrufen, die schon anhand ihrer Energie relativ einfach zu orten sind. Immerhin 71 % der Plastikminen werden detektiert. Negativ auf die Detektionsleistung wirkt sich hier aus, dass im Fall des vierten Bodentyps (Acker, mit lockerer Erde) keine einzige Plastikmine detektiert werden konnte (s. Bild 6.2). Im Gegensatz zu den 87 % der metallhaltigen Objekte (keine Minen), werden nur 59 % der nichtmetallischen Objekte (keine Minen) detektiert.




Bild 6.1 Erzielte Detektionswahrscheinlichkeiten (PD) in Abhängigkeit von der Anzahl der Falschalarme (FA) pro m². Die verschiedenen Symbole bezeichnen die einzelnen Objektkategorien.

¹⁰ Von engl. *Receiver Operating Characteristics*.

Bei gleicher Detektionswahrscheinlichkeit (PD) für Plastikminen ist die Falschalarmrate deutlich geringer als in dem von Fritzsche und Löhlein [Fri00] beschriebenen Verfahren, mit dem lediglich eine FA von $2.5/m^2$ erreicht wird. Die Detektionsrate für metallische Objekte liegt hier ebenfalls deutlich höher (um über 30 %). Die erzielte Verbesserung resultiert zum einen aus der robusten Vorverarbeitung in Form der Hauptachsentransformation, zum anderen aus der in Abschnitt 3.2 eingeführten logischen Verknüpfung der in den einzelnen Projektionsflächen ermittelten Detektionen.

Die Abhängigkeit der PD vom Bodentyp wird in Bild 6.2 deutlich. Während die metallhaltigen Minen immer detektiert werden (im Boden vom Typ 4 waren keine vergraben, s. Tabelle 5.4), sind für Plastikminen Schwankungen der PD von über 20 % festzustellen. Im lockeren Erdreich können Plastikminen nicht detektiert werden, allerdings ist zu berücksichtigen, dass in diesem Fall insgesamt nur 4 Minen vergraben waren. Dieser Umstand kann aber nicht darüber hinwegtäuschen, dass solche Bodenbedingungen zumindest dem hier eingesetzten GPR-System große Schwierigkeiten bereiten.

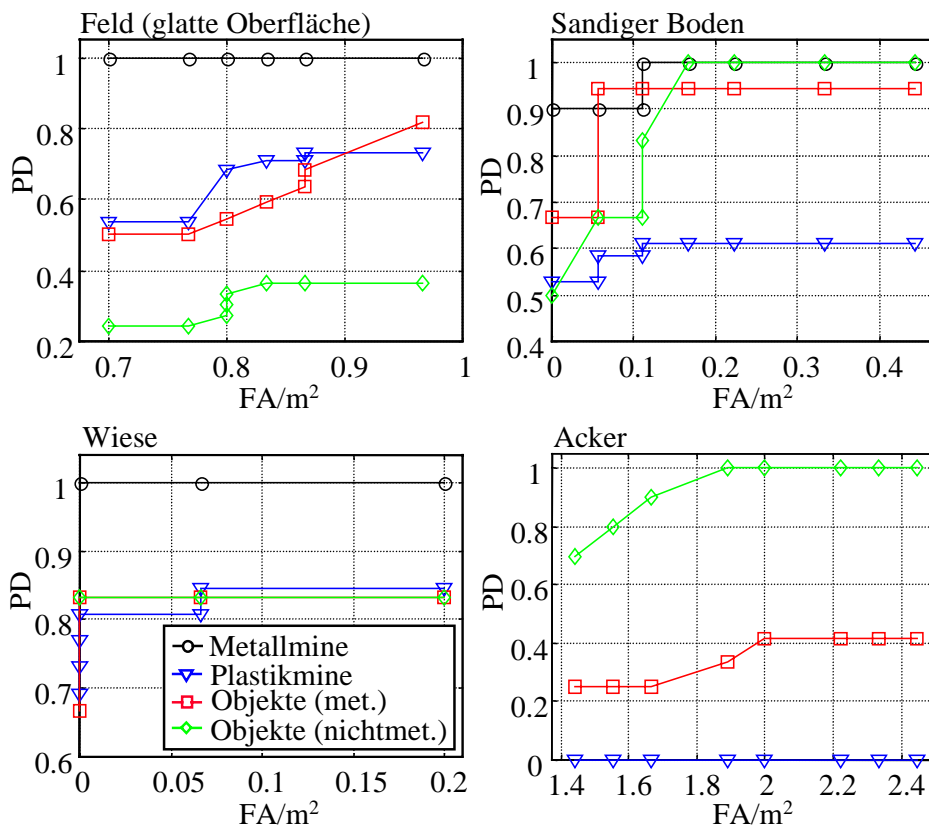


Bild 6.2 Erzielte Detektionswahrscheinlichkeiten (PD) in Abhängigkeit von der Anzahl der Falschalarme (FA) pro m^2 für vier verschiedene Bodentypen. Die verschiedenen Symbole bezeichnen die einzelnen Objektkategorien.

Die teilweise sprunghaften Anstiege der ROC-Kurven sind darauf zurückzuführen, dass mitunter bei einer geringfügigen Änderung der Binarisierungsschwelle eine größere Anzahl von Objekten sichtbar wird, die vorher unterhalb der Schwelle lag. Die Kurven der einzelnen Objektkategorien zeigen einen mit ansteigender Anzahl von Falschalarmen abflachenden Verlauf, mit Ausnahme der Kurve für metallische Objekte in Bild 6.2. Daher wäre auch bei einer weiteren Absenkung der Binarisierungsschwelle keine Steigerung der Detektionswahrscheinlichkeiten zu erwarten.

Tabelle 6.1 zeigt eine Übersicht der Detektionsergebnisse bei einem Falschalarm pro m², zusammengefasst für alle Böden.

Objekt-kategorie	Metallmine	Plastikmine	Objekte (metallisch)	Andere Objekte
PD	100 % (33/33)	71 % (76/107)	86 % (50/58)	58 % (32/55)

Tabelle 6.1 Detektionswahrscheinlichkeiten bei einem Falschalarm pro m². Die Angaben in Klammern bezeichnen wie viele Objekte einer Kategorie von den tatsächlich vorhandenen detektiert wurden.

Diese Resultate zeigen, dass mit dem hier vorgeschlagenen Detektionsverfahren nicht nur alle Metallminen und ein Großteil der Plastikminen, sondern auch ein relativ hoher Anteil der metallischen Objekte gefunden werden. Da auch Metallteile in Regionen, in denen bewaffnete Konflikte stattgefunden haben, häufig zu finden sind, ist die Fähigkeit zur Unterscheidung von Alarmen mit oder ohne Gefährdungspotenzial ein wichtiger Beitrag zur Beschleunigung der Räumprozedur. Eine Abgrenzung relevanter Detektionen gegen Falschalarme, die durch natürliche Objekte im Boden hervorgerufen werden, wie Steine, Wurzeln etc., ist für die Steigerung der Effizienz von Räumoperationen ebenfalls von Vorteil.

6.2 Klassifikation simulierter Streusignale

Vorrangiges Ziel der Verarbeitung simulierter Streusignale ist der direkte Vergleich der Leistungsfähigkeit der in Kapitel 4 vorgestellten Orthogonaltransformationen sowie der verschiedenen Methoden der Merkmalsselektion bzw. –projektion. Ferner wird untersucht, ob eine Abhängigkeit der Erkennungsleistung von der Frequenz des Quellsignals bzw. vom Feuchtegehalt des Bodens nachzuweisen ist.

Alle Signale werden mit einer vierstufigen verschiebungsinvarianten Wavelet-Packet-Transformation (SIWPT) transformiert. Dabei wird aufgrund der in Abschnitt 4.3.4 beschriebenen vorteilhaften Eigenschaften ein Spline-Wavelet verwendet, das auch für alle folgenden Untersuchungen eingesetzt wird. Nach (4.49) ergeben sich für eine Zerlegung mit vier Stufen 32 Subbänder. Die für die Klassifikation herangezogenen Merkmale können dann durch Berechnung der in (4.63) aufgelisteten statistischen Größen erhalten werden. Somit ergibt sich aus den Koeffizienten eines Subbands jeweils ein Merkmal.

Um eine Aussage hinsichtlich der Eignung der verschiedenen Merkmalstypen zur Klassentrennung machen zu können, bei gleichzeitiger Begrenzung des Rechenaufwands, werden zunächst nur die zu einer Wavelet-Basis gehörenden Subbänder ausgewertet. Anhand der Klassifikationsergebnisse ergaben sich als die drei am besten geeigneten Merkmalstypen die Standardabweichung, die normierte Entropie und der Betragsmittelwert. Aufgrund recht geringer Differenzen wird im Weiteren nur noch die normierte Entropie berücksichtigt (eine Kombination der Merkmale verschiedenen Typs liefert keine Verbesserung).

Bild 6.3 zeigt den direkten Vergleich der mit den vorangehend beschriebenen Verfahren erhaltenen Erkennungsergebnisse, für den Fall des 1 GHz Quellsignals und in Abhängigkeit von der Anzahl der berücksichtigten Merkmale. Die Wavelet-Transformation (WT) mit fünf Merkmalen (vier Detailsignale und ein Tiefpasssignal) schneidet am schlechtesten ab, gefolgt von der Best-Level (BL)- bzw. Best-Basis-Zerlegung (BB), die beide nahezu den gleichen Wert ergeben. Die Abkürzung BDIB bezeichnet die mithilfe des Polynomklassifikators bestimmte *Best-Discriminant-Incomplete-Basis* (s. Abschnitt 4.4.2). Die Anwendung der Hauptachsentransformation (HAT) auf alle 32 Merkmale der vierstufigen SIWPT, zur Reduktion der Länge der Merkmalsvektoren, führt durchweg zu den besten Ergebnissen, die auch den durch Anwendung des Selektionsverfahrens der BDIB überlegen sind. Unter den Wavelet-Methoden werden mit der verschiebungsinvarianten Multiwavelet-Transformation (SIMWT), mit fünf Zerlegungsstufen berechnet, die besten Resultate erhalten.

Von der Gesamtheit der Verfahren liefert jedoch die Anwendung einer HAT auf energienormierte Betragsspektren die besten Resultate. Die Anzahl der Merkmale entspricht hier der Anzahl der berücksichtigten Eigenwerte. Die Energienormierung ist unbedingt erforderlich, da ansonsten Kugeln, mit Streusignalen geringer Amplitude, lediglich anhand der Signalenergie von stark streuenden Kugeln unterschieden werden könnten.

Die in Bild 6.3 dargestellten Ergebnisse beweisen, dass es prinzipiell möglich ist, an Objekten gestreute Signale unterschiedlichen Kategorien zuzuordnen. Eine hinreichend große Anzahl an Merkmalen vorausgesetzt, wird mit allen Verfahren, mit Ausnahme der einfachen verschiebungsinvarianten Wavelet-Transformation (SIWT), eine Fehlerrate von 1 % unterschritten.




Bild 6.3 Vergleich der Erkennungsfehler der beschriebenen Verfahren als Funktion der Anzahl zur Klassifikation verwendeter Merkmale. Die Ergebnisse beziehen sich auf den Fall des 1 GHz Sendepulses, zusammengefasst für alle Feuchteanteile des Bodens.

Eine Abhängigkeit der Erkennungsleistung vom Frequenzschwerpunkt des einfallenden Quellsignals (1-5 GHz) oder der Bodenfeuchte kann nicht festgestellt werden. Dies lässt darauf schließen, dass die frequenzabhängigen Cluttereigenschaften des Bodens, infolge von Inhomogenitäten sowie die Reflexion an der Oberfläche eine wesentliche Ursache der bei der praktischen Anwendung der Signaldiskrimination auf Georadarsignale auftretenden Schwierigkeiten sind. Bei den Simulationen wurde aber der das Objekt umgebende Boden als homogenes Medium modelliert.

6.3 Klassifikation in Luft vermessener Kugeln

Die Verarbeitung realer Daten, erzeugt durch Messungen an Kugeln, ohne den Einfluss eines umgebenden Bodens oder der Oberfläche desselben, bildet den nächsten logischen Schritt in der Evaluierung des hier verfolgten Ansatzes zur Trennung von Signalen.

Tabelle 6.2 gibt einen Überblick der auftretenden Klassifikationsfehler, bezogen auf die Testdaten, für die Methoden mit den besten Ergebnissen. Im Unterschied zum vorangehenden Abschnitt beziehen sich die Fehler hier nicht auf einzelne Signale, sondern auf ganze Objekte. Die vom Klassifikator für jeden einzelnen Scan eines Objektpakets (s. Bild 5.2) getroffenen Klassenzuordnungen wurden dabei zu einer Gesamtentscheidung zusammengefasst. Die aufgeführten Fehler errechneten sich aus der Mittelung von jeweils 10 verschiedenen Zufallsaufteilungen von Lern- und Testdaten (vgl. Abschnitt 5.3), d.h. die Adaption des Klassifikators wurde entsprechend wiederholt. Die Standardabweichung des Erkennungsfehlers auf den Testdaten beträgt etwa 1.5 %.

Methode	Antennenfrequenz [GHz]	Fehler [%]
Betragsspektren (norm.)	1	3.4
SIMWT-Koeffizienten	1	5.4
SIMWT-Merkmale	1	6.8
Betragsspektren (norm.)	2	2.6
SIMWT-Koeffizienten	2	4.8
SIMWT-Merkmale	2	4.6

Tabelle 6.2 Mit verschiedenen Verfahren zur Bildung von Merkmalen erhaltene Klassifikationsfehler in Abhängigkeit vom Frequenzmaximum des Sendepulses.

Neben den energienormierten Betragsspektren wurden zum einen die pro Subband berechneten Standardabweichungen der mit einer 6-stufigen SIMWT erhaltenen Koeffizienten als Merkmale verwendet (14 Merkmale pro Scan), zum anderen direkt die nach (4.60) verschobenen SIMWT-Koeffizienten der beiden untersten Subbänder (16 Merkmale pro Signal). Mit der 2 GHz-Antenne werden durchweg bessere Ergebnisse erzielt als mit der 1 GHz-Antenne. Die in beiden Fällen auftretenden Fehler sind vor allem auf Verwechslungen zwischen der Holz- und der Glaskugel zurückzuführen.

Festzuhalten bleibt, dass die besondere Eignung von Wavelet-Verfahren zur Beschreibung zeitlich lokalisierter Signale sowohl bei den simulierten als auch bei den in Luft vermessenen Kugeln keine Vorteile gegenüber der Verwendung von Betragsspektren ergab.

6.4 Klassifikation vergrabener Objekte

Um die Leistungsfähigkeit des Klassifikationsansatzes zunächst unabhängig vom Ergebnis der Detektionsstufe bewerten zu können, wurde zuerst die Gesamtheit aller vergrabenen Objekte betrachtet. Jedem Objekt wurden die innerhalb eines kreisförmigen Gebietes von 16 cm Durchmesser liegenden A-Scans zugeordnet. Die bekannte Objektposition bildete jeweils den Mittelpunkt des Kreises, der Durchmesser folgt aus dem gewählten Radius von 4 Rasterpunkten, bei einem Abtastintervall von 2 cm. Damit ergaben sich 61 zu berücksichtigende Einzelsignale pro Objekt.

Der so erhaltenen Auswahl an Signalen wurden zur Adaption des Klassifikators ergänzend für jeden 3D-Datensatz mehrere Falschalarme angefügt, um eine Abgrenzung der auf tatsächlichen Objekten beruhenden Streusignale gegen Bodenclutter zu erreichen (s. Abschnitt 5.3). Die Entscheidung, welcher der drei Klassen (Mine, andere Objekte, Hintergrund) ein solches Objektpaket zuzuordnen ist, wurde als Mehrheitsentscheidung der 61 Einzelentscheidungen definiert.

Wie in Abschnitt 5.3 beschrieben, wurde auch hier eine wiederholte zufällige Aufteilung der Objekte in Lern- und Testdaten vorgenommen. In Tabelle 6.3 sind die mittleren Klassifikationsfehler für die Testdaten aufgelistet. Es wird unterschieden zwischen einer Betrachtung aller Objekte in allen vier Böden (s. Spalte „Alle Böden“) und getrennt nach Bodentypen, d.h. hier wurde für jeden Bodentyp (s. Tabelle 5.4) ein gesonderter Klassifikator trainiert. Bei gleichzeitiger Berücksichtigung aller Bodentypen und 10-facher Wiederholung der Stichprobenauswahl beträgt die Standardabweichung der Erkennungsraten zwischen 2 und 4 %, d.h. das Verfahren arbeitet recht robust.

Aus den SIMWT-Transformationskoeffizienten wurden die Merkmale mittels der im vorangehenden Abschnitt beschriebenen Vorgehensweise erhalten. Bei der Berechnung der Superwavelets der Wavelet-Netze (Zeile 3 in Tabelle 6.3) wurden für Klasse 1 (Minen) 3 Cluster und für die Klassen 2 (Objekte) bzw. 3 (Hintergrund) jeweils 2 Cluster verwendet. Nach (4.76) ergeben sich damit 16 Superwavelets. Somit stimmt die Länge der resultierenden Merkmalsvektoren nahezu mit den bei den anderen Verfahren in Tabelle 6.3 verwendeten 14 Dimensionen überein. Zeile 4 zeigt das mithilfe des BDIB-Verfahrens zur Merkmalsselektion erhaltene Ergebnis, Zeile 5 das Resultat der nach (4.64) erfolgten Auswahl der am besten diskriminierenden Merkmale, hier als BDF (für *Best Discriminating Features*) bezeichnet. Die Verwendung der 16 SIWPT-Koeffizienten der vom Frequenzgehalt her tiefsten 4 Subbänder (bei einer 6-stufigen Zerlegung) als Merkmale, liefert das Resultat von Zeile 6, die entsprechenden SIWPT-Koeffizienten der untersten drei Subbänder (16 Koeffizienten: 1-4, 5-8, 9-16), die den gleichen

Frequenzbereich abdecken, das der Zeile 7. In jeder Spalte ist jeweils das beste Ergebnis schattiert hervorgehoben.

Zeile 8 schließlich zeigt die mithilfe von energienormierten FFT-Betragspektren erhaltenen Erkennungsraten. Mit einer HAT wurden die Betragspektren, der in Abschnitt 4.9.1 beschriebenen Vorgehensweise folgend, auf ebenfalls 14 Dimensionen reduziert.

Methode \ Bodenkategorie		Alle Böden	Feld (Typ 1)	sandig Typ 2	Wiese Typ 3	Acker Typ 4
1	SIMWT – Koeff.	48.5	34.4	39.2	8.1	37.3
2	SIMWT – Merkmale	52.3	40.2	50.7	15.4	34.4
3	Wavelet-Netze	51.3	48.5	49.4	33.2	48.1
4	SIWPT – BDIB	53.2	49.6	51.7	20.4	37.5
5	SIWPT – BDF	54.8	52.6	51.7	20.8	45.0
6	SIWPT – Koeff.	56.6	48.6	49.1	22.7	44.4
7	SIWT	56.4	57.5	55.6	29.2	40.1
8	Betragspektren	53.8	53.3	38.9	42.4	55.0

Tabelle 6.3 Mit den beschriebenen Verfahren zur Merkmalsbildung erhaltene prozentuale Erkennungsfehler, für alle Böden bzw. getrennt nach Bodentyp (s. Tabelle 5.4). Die besten Ergebnisse jeder Spalte sind schattiert dargestellt.

Es ist zu betonen, dass aufgrund der bei der Merkmalsbildung berücksichtigten Subbänder bei allen drei Formen der Wavelet-Transformation immer der gleiche Frequenzgehalt der Daten in die Rechnung einging. Eine vergleichende Bewertung der verschiedenen Verfahren wird in Abschnitt 6.5 vorgenommen.

6.5 Kombination von Detektion und Klassifikation

Da das Verfahren der SIMWT-Koeffizienten, wie aus Tabelle 6.3 ersichtlich, die niedrigsten Erkennungsfehler erzielt, wurde es auch zur Auswertung der Ergebnisse der Detektionsstufe herangezogen. Die Anwendung der vorangehend beschriebenen Prozedur zur Merkmalsbildung erfolgte dabei lediglich auf die innerhalb der Umrisslinie hypothetischer Objekte liegenden A-Scans, wie in den Bildern 3.7 und 3.8 graphisch dargestellt ist.

Bezogen auf die Gesamtheit aller detektierten Objekte (s. Tabelle 6.1) ließ sich bei gleichzeitiger Betrachtung aller Böden damit ein Erkennungsfehler von 30.6 % erreichen. Die Vertauschungsmatrix in Tabelle 6.4 zeigt die Verwechslungen zwischen den drei Klassen auf. In Spaltenrichtung sind die wahren Entscheidungen, in Zeilenrichtung die tatsächlich erhaltenen aufgetragen. Die Summe über alle Einträge der Matrix liefert die zu klassifizierenden 222 hypothetischen Objekte, mit folgender Zusammensetzung: 33 Metallminen, 72 Plastikminen, 40 metallhaltige Objekte, 33 metallfreie Objekte und 44 Falschalarme (bei 0.71 FA/m²).

Idealer Weise sollte die Vertauschungsmatrix eine Diagonalform haben. Die Nebendiagonalelemente bezeichnen die Falschalarme. Um zu einer Bewertung des mit diesen Fehlentscheidungen verbundenen Risikos zu kommen, lassen sich für jede falsche Entscheidung *Kosten* angeben. Korrekte Entscheidungen verursachen keine Kosten. Offensichtlich sind diese Kosten für *False-Positives* (in Tabelle 6.4 hell schattiert dargestellt) deutlich geringer als für *False-Negatives* (dunkel schattiert). Während der erste Fall nur ein überflüssiges Stochern im Boden bedeutet oder das Ausgraben eines ungefährlichen Objekts – was aber die Räumungskosten in die Höhe treibt – sind mit dem zweiten Typ von Falschalarm möglicherweise der Verlust des Sensors oder schlimmeres verbunden, da dann eine Mine übersehen wurde. Hier liegt daher das Hauptrisiko.

Soll \ Ist	Minen	Objekte	Hintergrund
Minen (Metall u. Plastik)	88 (84 %)	7 (7 %)	10 (9 %)
Andere Objekte	15 (21 %)	44 (60 %)	14 (19 %)
Hintergrund	9 (20 %)	13 (30 %)	22 (50 %)

Tabelle 6.4 Aus der Klassifikation detektierter Objekte resultierende Vertauschungsmatrix. Die vertikale Position gibt die gewünschte Klasse an, die horizontale die vom Klassifikator tatsächlich zugeordnete. Dunkel schattierte Felder bezeichnen die *False-Negatives*, hell schattierte die *False-Positives*. Die Zahlen in Klammern bezeichnen die relativen Anteile.

Fasst man die Klassen *Objekte* und *Hintergrund* zusammen, reduziert sich zwar der Fehler auf etwa 18 %, zu einer deutlichen Verringerung der Kosten trägt dies allerdings nicht bei, da Verwechslungen zwischen diesen beiden Klassen keine großen Kosten verursachen. Eine sinnvolle Definition einer Kostenmatrix ist sehr schwierig und kann eigentlich nur vom Betreiber eines Minenräumsystems getroffen werden. Daher werden an dieser Stelle nur Erkennungsfehler und nicht die damit einhergehenden Kosten betrachtet.

Knapp 84 % der zu klassifizierenden Minen werden als solche erkannt. Fasst man die Ergebnisse der Detektions- und Klassifikationsstufe zusammen, werden mit 71 % detektierter Plastikminen somit 59.5 % richtig zugeordnet.

Die Frage nach der Variabilität der Minensignale wurde beantwortet, indem ein Klassifikator trainiert wurde, der lediglich zwischen metallhaltigen und Plastikminen zu unterscheiden hatte. Ausgehend von SIMWT-Merkmalen ließ sich eine Erkennungssicherheit von über 90 % erzielen. Dies eröffnet die Möglichkeit nicht nur zwischen Objekten der Kategorien Mine und „Nicht-Mine“ zu trennen, sondern auch eine Aussage hinsichtlich des Minentyps zu treffen.

6.6 Bewertung der Methoden zur Merkmalsextraktion

Angewendet auf simulierte Streusignale lassen sich mit allen vorgestellten Verfahren sehr geringe Fehlerraten erzielen (vgl. Bild 6.3). Allerdings bietet die Verwendung von Betragsspektren in Verbindung mit einer Hauptachsentransformation zur Dimensionsreduktion den Vorteil, dass mit einer deutlich geringeren Anzahl von Merkmalen das gleiche Ergebnis erreicht wird. Unter den Wavelet-Methoden schneidet die verschiebungsinvariante Multiwavelet-Transformation am besten ab.

Das gleiche gilt für die Auswertung der in Luft vermessenen Kugeln (s. Tabelle 6.2). Auch hier ergeben sich leichte Vorteile zugunsten der Betragsspektren – die Fehler sind etwa 2 % geringer – gegenüber den Wavelet-Methoden. Zumindest für den 1 GHz-Fall ist die direkte Verwendung von SIMWT-Koeffizienten der Bildung von Merkmalen (Entropie) aus Subbändern überlegen. Die Fehler in der Erkennungsrate differieren hier um über 2 %.

Betrachtet man die in Tabelle 6.3 angegebenen Erkennungsfehler, stellt man fest, dass sich für reale Messungen an vergrabenen Objekten die Verhältnisse zwischen Wavelet- und Spektralverfahren umkehren. Die SIMWT führt auf die mit Abstand geringsten Fehler, wobei auch hier die direkte Verwendung der Koeffizienten in vier von fünf Fällen besser ist als die pro Subband gebildeten Entropiemerkmale.

Eine plausible Erklärung für den 5 %-Vorteil der SIMWT gegenüber der FFT ist, dass die Signalspektren in erster Linie durch das Spektrum des Sendesignals sowie durch die Reflexion an der Bodenoberfläche und den Bodenclutter bestimmt werden. Statistische Variationen dieser Anteile können zu größeren Änderungen im Spektrum führen als die durch Streuung an einem Objekt verursachten. Während zeitlich lokalisierte

Signalanteile, die auf einen Streukörper schließen lassen, sich über viele Koeffizienten im Signalspektrum „verschmieren“, können diese Anteile vor allem mit Multiwavelets besser isoliert werden. Die getroffene Wahl des Multiwavelet-Typs (s. Bild 4.14) erweist sich hier zur Repräsentation von Georadarsignalen als besonders vorteilhaft.

Vergleicht man die für alle Bodenkategorien erhaltenen Fehlerraten (in Spalte 2 in Tabelle 6.3) schneiden die Wavelet-Netze etwas besser ab als die aus Subbändern gebildeten SIMWT-Merkmale. Bei getrennter Betrachtung der einzelnen Bodentypen jedoch sind die Wavelet-Netze schlechter. Zwei Auswahlverfahren zur Selektion der SIWPT-Merkmale wurden vorgestellt, in denen unterschiedliche Kriterien zur Bestimmung der Trennschärfe zum Einsatz kommen. Das mithilfe des Klassifikators vorgenommene Ranking der Merkmale, hinsichtlich ihrer Eignung zur Reduktion des Schätzfehlers (BDIB-Verfahren), liefert dabei geringfügig bessere Ergebnisse als die BDF-Methode, bei der die Merkmale anhand einer Diskriminanzfunktion selektiert werden (s. Abschnitt 4.7.3). Die mit der SIWT gewonnenen Merkmale erweisen sich hier als am wenigsten aussagekräftig.

Insgesamt muss festgehalten werden, dass auch mit dem besten der hier untersuchten Verfahren keine für die vorliegende Aufgabenstellung erforderliche Trennschärfe erzielt werden konnte. Der Grund dafür liegt weniger in der Unzulänglichkeit der Verfahren, sondern vielmehr in der hohen Ähnlichkeit, die Cluttersignale mit und ohne Nutzsignalanteil untereinander aufweisen.

Die hier detaillierten Ergebnisse, die auf einer systematischen Untersuchung verschiedener Verfahren der Zeit-Frequenz-Analyse beruhen, ermöglichen aber zum ersten Mal eine umfassende Bewertung der Signalanalyse zum Zwecke der Klassifikation von Georadarsignalen, die weit über die bis dato in der Literatur beschriebenen Ansätze hinausgehen.

7. Zusammenfassung

Bei den gegenwärtig weltweit zur Minendetektion eingesetzten Technologien handelt es sich fast ausschließlich um Spürhunde, Stocherstäbe und im Wesentlichen um Metalldetektoren. Für die Ortung von fast metallfreien Plastikminen sind letztere jedoch nur bedingt geeignet. Aufgrund der Eignung von Radarverfahren zum Aufspüren dielektrischer Kontraste im Untergrund wurden in den letzten Jahren vermehrt Anstrengungen unternommen feldtaugliche Georadarsysteme zu entwickeln. Oberstes Ziel ist dabei die Steigerung der Detektionswahrscheinlichkeit, bei gleichzeitiger Reduktion der teilweise enormen Falschalarmraten.

Gegenstand dieser Arbeit ist die Entwicklung und Verifizierung neuer Verfahren zur Auswertung von Georadardaten für die Detektion und Klassifikation vergrabener Landminen. Erstmals wird ein durchgängiges Konzept zum Aufbau eines Erkennungssystems vorgestellt, das sich aus zwei wesentlichen Elementen zusammensetzt: einer Detektionsstufe zur Ortung von Objekten und einer Klassifikationsstufe, mit der eine Zuordnung eines potenziellen Objekts zu einer von drei möglichen Klassen getroffen werden kann. Unterschieden werden erstens Minen, zweitens ungefährliche Objekte und drittens Falschalarme, die nicht durch vergrabene Objekte, sondern durch Bodenclutter hervorgerufen werden. Ursache dieses Clutters sind Bodeninhomogenitäten, variierender Feuchtigkeitsgehalt, unregelmäßige Topographie der Oberfläche sowie der Bodenbewuchs.

Den Ausgangspunkt der Entwicklung des vorgestellten Detektionsverfahrens bilden durch Aufzeichnung von Streusignalen an der Bodenoberfläche auf einem gleichmäßigen Raster entstandene dreidimensionale Datensätze. Es wird gezeigt, wie sich mithilfe eines Projektionsverfahrens diese Datenwürfel auf wenige horizontale Schnittflächen reduzieren lassen, in denen hypothetische Objekte mit bisher nicht erreichter Sicherheit anhand ihrer Form lokalisiert werden können. Damit erweist sich der hier gewählte formbasierte Ansatz der isolierten Betrachtung einzelner Radarsignale als deutlich überlegen. In diesem Zusammenhang wird auch eine Vorgehensweise präsentiert, die eine deutliche Steigerung der Detektionswahrscheinlichkeiten schwach streuender Objekte, die in unmittelbarer Nachbarschaft zu starken Streuern liegen, ermöglicht. Beispielsweise für die Detektion von Plastikminen, die neben einer metallhaltigen Mine oder einer Panzermine liegen, ist dies von großer Bedeutung.

Zentraler Ansatzpunkt dieser Arbeit ist die These, dass sich Streusignale anhand ihrer charakteristischer Signaturen einer der drei oben angeführten Klassen zuordnen lassen.

Dies erfordert für jedes einzelne Radarsignal die Berechnung von Merkmalen zur Erfassung der Charakteristika jeder Signalklasse. Zu diesem Zweck werden verschiedene Verfahren der Zeit-Frequenz-Analyse untersucht und bewertet. Die Frage um *was* es sich bei einem von der Detektionsstufe gelieferten hypothetischen Objekt handelt, wird dann mit Verfahren der statistischen Mustererkennung beantwortet.

Der Nachweis der Machbarkeit wird zunächst anhand von Simulationen für Kugelstreuer mit konzentrischem Aufbau geführt. Zur Modellierung des Bodeneinflusses auf die Erkennungsleistung werden dabei erstmals Daten eingesetzt, die durch die Vermessung einer großen Anzahl von Bodenproben in dem für Georadare relevanten Frequenzbereich von 0.5 – 4 GHz entstanden. Im nächsten Schritt werden ebenfalls an Kugeln vorgenommene Freiluftmessungen ausgewertet. In beiden Fällen zeigt sich, dass Kugeln unterschiedlichen Typs mit hoher Erkennungssicherheit diskriminiert werden können.

Die Ergebnisse der Simulationen weisen nicht auf einen deutlichen Einfluss moderater Bodenfeuchten oder des Signalspektrums des Sendepulses auf die Erkennungssicherheit hin. Dies legt den Schluss nahe, dass die in der Praxis auftretenden Probleme primär durch den Bodenclutter und die Reflexionen an der Bodenoberfläche, die Minenechos maskieren können, hervorgerufen werden. Die Grenzen der Leistungsfähigkeit des Georadarverfahrens bei hohen Bodenfeuchten werden ebenfalls anhand der Simulationen und der Auswertung der Bodendaten aufgezeigt.

Die Verifikation des implementierten Detektionsverfahrens erfolgt anhand von Messdaten, die in einer umfangreichen Messkampagne an vergrabenen Objekten gewonnen wurden. Dabei wurden nicht nur Minen, sondern auch andere Objekte wie Patronenhülsen, Metallteile, Steine, Wurzeln etc. in unterschiedlichen Böden vermessen. Bei einer Falschalarmrate von einer Fehldetektion pro m^2 werden 100 % der metallhaltigen Minen und 71 % der Plastikminen gefunden. Das vorgeschlagene Verfahren zeichnet sich durch eine große Robustheit, eine geringe Anzahl festzulegender Parameter und einen geringen Rechenaufwand aus.

Verschiedene Verfahren der Zeit-Frequenz-Analyse werden entsprechend ihrer Eignung zur Bildung aussagekräftiger Merkmale bewertet. Insbesondere werden Wavelet- und Spektralverfahren miteinander verglichen. Die Merkmale stellen die Eingangsgrößen für den zu adaptierenden Klassifikator dar. Es wird dargelegt, welche besondere Bedeutung dabei einer sorgfältigen Wahl der für die Transformation eingesetzten Waveletfilter zukommt. Der Entwurf verschiebungsinvarianter Transformationen spielt eine zentrale Rolle, um Abhängigkeiten von der Tiefenlage der Objekte zu eliminieren. Das vorgestellte Verfahren zur hierfür erforderlichen Modifikation der Wavelet-Trans-

formation lässt sich gleichermaßen auf diskrete Wavelet-, Wavelet-Packet- und auf Multiwavelet-Transformationen anwenden und erfordert gegenüber den herkömmlich definierten Transformationen lediglich den doppelten Rechenaufwand.

Das Verfahren der Multi-Wavelets erwies sich unter allen untersuchten Methoden als am besten geeignet. Bezogen auf die Gesamtheit aller vermessenen Objekte wurde damit ein Erkennungsfehler von 48.5 % erzielt. Fasst man die Ergebnisse der Detektions- und Klassifikationsstufe zusammen werden 59.5 % der Minen der richtigen Kategorie zugeordnet. Bezogen auf die Gesamtheit der detektierten Minen werden 84 % richtig zugeordnet.

Zu betonen ist, dass die präsentierten Ergebnisse ausgehend von zahlreichen Feldexperimenten und nicht mit einigen wenigen „Sandkastenmessungen“ erhalten wurden. In reinem Sand wären deutlich höhere Erkennungsraten zu erzielen. Ein primäres Anliegen dieser Arbeit war jedoch, die Anwendbarkeit von Methoden der Bild- und Signalverarbeitung sowie statistischer Lernverfahren in einem realitätsnahen Umfeld zu bewerten. Dabei stellten sich der Bodenclutter und der Einfluss der Bodenoberfläche als die wesentlichen limitierenden Faktoren heraus.

Von einem zuverlässigen Einsatz von Georadaren zur Minendetektion, der den von der UN formulierten Anforderungen (von 99.6 % Detektionswahrscheinlichkeit) gerecht wird, ist man derzeit noch ein gutes Stück entfernt. Die vorliegende Arbeit zeigt aber neue Wege zur Verbesserung der Detektionseigenschaften und zur Unterscheidung gefährlicher von ungefährlichen vergrabenen Objekten auf und leistet damit einen Beitrag zur Entwicklung verbesserter Georadarsysteme.

Ausblick

Anstrengungen zur Steigerung der Leistungsfähigkeit solcher Systeme sollten sich in erster Linie auf die Weiterentwicklung der Hardware konzentrieren. Dabei sollte die Untersuchung polarimetrisch messender Antennenkonfigurationen und die mit ihnen zu erzielende Steigerung der Detektionswahrscheinlichkeiten und Diskriminationseigenschaften im Vordergrund stehen. Eine nennenswerte Verbesserung der Systemleistung ist in diesem Zusammenhang vor allem für im Vergleich zu APMs größeren ATMs zu erwarten.

Darüber hinaus erscheint nur mit Verfahren der Sensorfusion eine Steigerung der Erkennungsleistung bei gleichzeitiger Reduktion der Falschalarmrate möglich. Einen Schwerpunkt der technischen Entwicklung bilden hierbei die Kombination von Metalldetektoren mit Georadaren, die allerdings nicht als orthogonale sondern allenfalls als

komplementäre Sensoren betrachtet werden können, da sie beide insbesondere auf Metallteile im Untergrund reagieren [Cre00, For00]. In [Fri00] werden die dieser Arbeit zugrunde liegenden Feldmessungen, die auch mit Metalldetektoren durchgeführt wurden, mit Methoden der Sensorfusion untersucht, die beschriebenen Ergebnisse zeigen das Potenzial der Sensorfusion auf, basieren aber noch nicht auf den in dieser Arbeit entwickelten Verfahren.

In [Bha00] wird ein fahrzeuggestütztes System, bestehend aus einem GPR, einem Metalldetektor und einem vorausschauenden Infrarotsensor vorgestellt. Die Eignung von IR-Sensoren zur Minendetektion ist allerdings eingeschränkt, da bei vergrabenen Minen in erster Linie die Spuren der Verlegung, infolge lokal veränderter Bodeneigenschaften, detektiert werden können. Dieser Effekt läßt in der Regel im Laufe der Zeit, aufgrund von Witterungseinflüssen und überwuchender Vegetation, stark nach.

Eine Alternative bildet die Kombination von Metalldetektoren mit einem auf der Streuung thermischer Neutronen basierenden Sensorprinzip, bei dem die charakteristische Rückstreuung der in Sprengstoff enthaltenen Stickstoffanteile ausgewertet wird [Orp96].

Liste häufig verwendeter Abkürzungen und Symbole

Abkürzungen

APM	<u>A</u> nti- <u>P</u> ersonen- <u>M</u> ine
ATM	Panzermine (<u>A</u> nti- <u>T</u> ank - <u>M</u> ine)
BB	<u>B</u> est <u>B</u> asis
BDF	<u>B</u> est <u>D</u> iscriminating <u>F</u> eatures
BDIB	<u>B</u> est <u>D</u> iscriminant <u>I</u> ncomplete <u>B</u> asis
CWT	Kontinuierliche Wavelet-Transformation (<u>C</u> ontinuous <u>W</u> avelet <u>T</u> ransform)
DWT	<u>D</u> iskrete <u>W</u> avelet- <u>T</u> ransformation
FA	<u>F</u> alschalarm
FFT	schnelle Fourier-Transformation (<u>F</u> ast <u>F</u> ourier <u>T</u> ransform)
GPR	<u>G</u> round <u>P</u> enetrating <u>R</u> adar (auch <u>G</u> round <u>P</u> robing <u>R</u> adar)
HAT	<u>H</u> auptachsen- <u>T</u> ransformation
IDWT	<u>I</u> nverse <u>D</u> iskrete <u>W</u> avelet- <u>T</u> ransformation
MRA	<u>M</u> ulti <u>r</u> esolution- <u>A</u> nalyse
MWT	<u>M</u> ulti <u>w</u> avelet- <u>T</u> ransformation
PD	Detektionswahrscheinlichkeit (<u>P</u> robability of <u>D</u> etection)
Radar	<u>R</u> adio <u>d</u> etection <u>a</u> nd <u>r</u> anging
ROC	<u>R</u> eceiver <u>O</u> perating <u>C</u> haracteristics
SIMWT	<u>S</u> hift <u>I</u> nvariant <u>D</u> iscrete <u>M</u> ulti- <u>W</u> avelet <u>T</u> ransform
SIWPT	<u>S</u> hift <u>I</u> nvariant <u>D</u> iscrete <u>W</u> avelet <u>P</u> acket <u>T</u> ransform
SIWT	<u>S</u> hift <u>I</u> nvariant <u>D</u> iscrete <u>W</u> avelet <u>T</u> ransform
STFT	Kurzzeit-Fourier-Transformation (<u>S</u> hort <u>T</u> ime <u>F</u> ourier <u>T</u> ransform)
UXO	Blindgänger (<u>U</u> nexploded <u>O</u> rdnance)
WPT	<u>W</u> avelet- <u>P</u> acket- <u>T</u> ransformation
WT	<u>W</u> avelet- <u>T</u> ransformation

WVD Wigner-Ville-Distribution

Formelzeichen

a	Skalenfaktor
a_n, b_n	Streukoeffizienten
b	zeitliche Translation
B_{eff}	effektive Bandbreite
c	Lichtgeschwindigkeit im Vakuum ($c = 2.99725 \cdot 10^8$ m / s)
$d_i(n)$	Waveletkoeffizienten der i -ten Auflösungsstufe
$d_k(\mathbf{y})$	Element des Entscheidungsvektors
D	topologische Dimension
D	Diskriminanzmaß
$\mathbf{e}_x, \mathbf{e}_\theta, \mathbf{e}_\phi$	Einheitsvektoren
$E\{\cdot\}$	Erwartungswert
E_o	Amplitude des elektrischen Feldes
E	euklidischer Abstand bzw. Fehlerenergie
\mathbf{E}	komplexer Vektor der elektrischen Feldstärke
g_o, g_1	Analyse- bzw. Synthese-Hochpassfilter
h_o, h_1	Analyse- bzw. Synthese-Tiefpassfilter
G_o, G_1	Analyse- bzw. Synthese-Hochpassfilter (z -Transformierte)
H_o, H_1	Analyse- bzw. Synthese-Tiefpassfilter (z -Transformierte)
\mathbf{H}	komplexer Vektor der magnetischen Feldstärke
H	Entropie
$H\{\cdot\}$	Hilbert-Transformation
$Hou\{\cdot\}$	Hough-Transformation
J	Kostenfunktion
\mathbf{J}_K	Funktionenbibliothek zur Signalklassifikation
\mathbf{J}_R	Funktionenbibliothek zur Signalrepräsentation

\mathbf{K}	Kovarianzmatrix
L	Anzahl der Transformationsstufen der Wavelet-Zerlegung
M	Dimension des Merkmalsraums
M_m	statistisches Moment m -ter Ordnung
N	Anzahl der Abtastwerte eines Zeitsignals
N_x, N_y	Anzahl der Abtastwerte in x - und y -Richtung
$P(k_x, k_y)$	zweidimensionales Leistungsspektrum
P_D	Detektionswahrscheinlichkeit
P_{FA}	Falschalarmwahrscheinlichkeit
k, k_x, k_z	Wellenzahlen
r	Abstand bzw. Radius
R	Rekonstruktionsfehler bzw. Residuum
$s(n), s_o(n)$	diskrete Signalfolge
$s_i(n)$	Skalierungskoeffizienten der i -ten Auflösungsstufe
$S\{\cdot\}$	Fouriertransformation
t	Zeit
v	Ausbreitungsgeschwindigkeit im Boden
$x(t)$	eindimensionales Signal
\mathbf{y}	Merkmalsvektor
\mathbf{Y}	Matrix aller spaltenweise angeordneten Merkmalsvektoren
\mathbf{W}	Matrix der transformierten Merkmalsvektoren
V_i	Skalierungs-Raum
W_i	Wavelet-Raum
\mathbf{X}	Matrix aller spaltenweise angeordneten Zeitsignale
$\hat{\mathbf{X}}$	Matrix aller rekonstruierten Zeitsignale
α, β	Streuparameter
χ	Dämpfungsfaktor

δ	Schwellwert
Δ	diskrete zeitliche Translation
f	Frequenzauflösung
r	Tiefenauflösung
t	Zeitauflösung
ϵ^*, ϵ_0	komplexe Permittivität bzw. Permittivität des Vakuums
ϵ_r	komplexe relative Permittivität
ϕ	Elevationswinkel
$\phi(t)$	Skalierungsfunktion
Φ	Zeit-Frequenz-Atom
γ_x, γ_z	fraktale Dimensionen in x - und z -Richtung
η	zweidimensionales Phasenspektrum
κ	Phasenkonstante
λ	Wellenlänge
μ	Erwartungswert der Merkmalsvektoren
μ^*, μ_0	komplexe Permeabilität bzw. Permeabilität des Vakuums
μ_r	komplexe relative Permeabilität
θ	Azimuthwinkel
σ	Leitfähigkeit
ω	Kreisfrequenz
${}_{a,b}(t)$	kontinuierliche Waveletfunktion
${}_{i,k}(t)$	diskrete Waveletfunktion

Literaturverzeichnis

- [Alt01] Altmann, J., *Neue Technologien für die Minensuche*. Physik in unserer Zeit, Spezial: Physik und Abrüstung, Nr. 1, 2001
- [And99] Andrews, A., Ralston, J., Tuley, M., *Research on Ground-Penetrating Radar for Detection of Mines and Unexploded Ordnance: Current Status and Research Strategy*. Institute for Defence Analysis, IDA Dokument D-2416, December 1999
- [Ann77] Annan, A.P., *Impulse radar applied to ice-thickness and fresh water bathymetry: Reports of Activities*. B, Geological Survey Canada, 1977
- [Ant92] Antonini, M. et al, *Image Coding using Wavelet Transforms*. IEEE Trans. on Image Processing. Vol. 1, 1992, S. 205-220
- [Aze96] Azevedo, S. et al, *Microradar development*. Engineering Research, Development and Technology, FY95 Thrust Area Report UCRL53868-95, Lawrence Livermore National Laboratory, Livermore, Ca, 1996
- [Bar88] Barnsley, M., *The science of fractal images*. Springer-Verlag
- [Bas89] Basseville, M., *Distance measures for signal processing and pattern recognition*. Signal Processing, Vol. 18, No. 4, 1989, S. 349-369
- [Bha00] Bhatia, J, et al, *Sensor Data Fusion for Mine Detection from a Vehicle-mounted System*. Proc. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (FL), April 2000
- [Bey92] Beylkin, G., *On the representation of operators in bases of compactly supported wavelets*. SIAM, Journ. Numerical Analysis, Vol. 29, No. 6, 1992, S. 1716-1740
- [Bru99] Brunzell, H., *Detection of Shallowly Buried Objects Using Impulse Radar*. IEEE Trans. on Geoscience and Remote Sensing, Vol. 37, Nr. 2, 1999
- [Bur89] Burl, C.M. et al, *Texture discrimination in synthetic aperture radar imagery*. In: Proceedings 22nd Asilomar Conference, Dec. 1989, S. 399-404
- [Can86] Canny, J.F., *A computational approach to edge detection*. IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 8, 1986, S. 679-698

- [Car97] Carevic, D. et al, *Modelling GPR-Echos from Land Mines using Linear Combinations of Exponentially Damped Sinusoids*. SPIE Conf. Proc. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3079, Orlando (FL), April 1997
- [Car99] Carevic, D., *Clutter Reduction and Detection of Minelike Objects in Ground Penetrating Radar Data Using Wavelets*. SPIE Conf. Proc. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3710, Orlando (FL), April 1999
- [Car00] Carevic, D., *An Approach to Characterising Ground Probing Radar Target Echoes for Landmine Recognition*. Defence Science and Technology Operation Australien, Bericht-Nr. DSTO-TR-0680
- [Cari99] Carin, L., Geng, N., McClure, M., Sichina, J., Nguyen, L., *Ultra-Wide-Band Synthetic Aperture Radar for Mine-Field Detection*. IEEE Antennas and Propagation Magazine, Vol. 41, No. 1, 1999, S. 18
- [Cha97] Chan, L.C. et al, *A Characterization of Subsurface Radar Targets*. Proc. IEEE, Vol. 67, Nr. 7, 1979
- [Che97a] Chen C.C., Peters L., Jr., *Design and Development of Enhanced Ground Penetrating Radar Systems for the Detection and Classification of Unexploded Ordnances and Land Mines*. Ohio State University, Electro Science Lab, Joint Technical Report 733346-1, 733946-1, 730181-3, September 1997
- [Che97b] Chen, C.C., Peters L., Jr., *Buried unexploded ordnance identification via complex natural resonances*. IEEE Trans. on Antennas and Propagation, Vol. 45, 1997, S. 1645-1654
- [Che00] Chen, C.C., Higgins, M. B., *UWB Full-Polarimetric Horn-Fed Bow-Tie (HFB) GPR Antenna for Buried Unexploded Ordnance (UXO) Detection*. IGARSS 2000
- [Chu92] Chui, C., *An Introduction to Wavelets*. Academic Press, New York 1992
- [Coh95] Cohen, I., *Shift Invariant Wavelet Packet Bases*. Proc. 20th Int. Conf. On Acoustics, Speech and Signal Processing, Detroit, Mich., 1995
- [Coi92] Coifmann, R.R., Wickershauser, M.V., *Entropy-based algorithms for best basis selection*. IEEE Trans. on Information Theory, Vol. 38, 1992, S. 713-718

-
- [Cre00] Cremer, F. et al, *Towards an operational sensor-fusion system for anti-personnel landmine detection*. Proc. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (Fl), April 2000
- [Cur98a] Curtis, J.O., *Site Characterisation Investigations in Support of UXO Technology Demonstrations, Jefferson Proving Ground Indiana*. Technical Report GL-98-20, Sept. 1998
- [Cur98b] Curtis, J.O., *Data Report, Dielectric Properties of Selected Silicone Rubbers*. Febr. 1998
- [Dan88] Daniels, D.J. et al, *Introduction to subsurface radar*. Proc. IEE, F, 135, 1988, S. 278-317
- [Dan96] Daniels, D.J, *Surface Penetrating Radar*. IEE Radar, Sonar, Navigation and Avionics Series 6, 1996
- [Dau88] Daubechies, I., *Orthonormal Bases of Compactly Supported Wavelets*. Comm. Pure Appl. Math., Vol. 41, 1988, S. 909-996
- [Dau92] Daubechies, I., *Ten Lectures on Wavelets*. SIAM, 1992
- [Del97] Delfs, C., Jondral, F., *New aspects on Classification Using Translation-Invariant Wavelet Packet Transforms*. IEEE UK Symposium on Appl. of Time-Frequency and Time-Scale Methods, Warwick, 1997, S. 1569-1572
- [Del98] Delfs, C., *Zeit-Frequenz-Signalanalyse: Lineare und quadratische Verfahren sowie vergleichende Untersuchungen zur Klassifikation von Klaviertönen*. Dissertation der Fakultät für Elektrotechnik, Universität Karlsruhe, 1998
- [Dol74] Dolphin, L.T. et al, *An underground electromagnetic sounder experiment*. Geophysics, Vol. 39, 1974, S. 46-55
- [Dre99] Executive Summary of the DREAM programme (Data Fusion as a Remedy Against Mines). EC Kontrakt DGIII, EP 26331. Bericht angefertigt von Thomson CSF Detexis, DaimlerChrysler, ERA Technology, Ebinger, 1999.
- [Due93] Dueck, G., Scheuer, T., Wallmeier, H.-M., *Toleranzschwelle und Sintflut: neue Ideen zur Optimierung*. Spektrum der Wissenschaft, März 1993

- [Eng98] Englehart, K., *Signal Representation for Classification of the Transient Myoelectric Signal*. Dissertation, University of New Brunswick, Fredericton, New Brunswick, Canada, 1998
- [Ete98] Etemad, K., Chellapa, R., *Separability-Based Multiscale Basis Selection and Feature Extraction for Signal and Image Classification*. IEEE Trans. on Image Proc., Vol. 7, 1998, S. 1453-1465
- [Fel98] Felbach, D., Detlefsen, J., *Methods of Background Subtraction for Ground Penetrating Radar*. International Radar Symposium IRS 98, München, 15.-17. September 1998
- [Fis50] Fisher, R.A., *The use of multiple measurements in taxonomic problems*. Annals of Eugenics, Vol. 7, S. 179-188, Reprinted in *Contributions to Mathematical Statistics*, John Wiley, New York, 1950
- [For00] Fortuny, J. et al, *Multi Sensor Mine Signature Measurements at the JRC*. Proc. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (Fl), April 2000
- [Fri95] Fritzsche, M., *Detection of buried landmines using ground penetrating radar*. Proc. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 2496, Orlando (Fl), April 1995
- [Fri96] Fritzsche, M., *Waveletbasierte Zeit-Frequenzanalyse und Klassifikationsverfahren*. DaimlerBenz, Technischer Bericht, F3-96-009, 1996
- [Fri00] Fritzsche, M., Löhlein, O., *Sensor Fusion for the Detection of Landmines*. Journ. of Subsurface Sensing Technologies and Applications. Vol. 1, Nr. 2, 2000, S. 247-267
- [Gab46] Gabor, D., *Theory of Communication*. Journ. Inst. Electrical Engineering, Vol. 93, 1946, S. 429-457
- [Gen98] Geng, N., Carin., L., *Ultrawideband Scattering from and the Resonances of Buried Dielectric Mines*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3392, Orlando (Fl), April 1998
- [Gen99] Geng, N., Jackson, D.R., Carin., L., *On the Resonances of a Dielectric BOR Buried in a Dispersive Layered Medium*. IEEE Trans. on Antennas and Propagation, Vol. 48, Nr.9, 1999

- [Ger94] Geronimo, J.S., Hardin, D.P., Massopust, P.R., *Fractal functions and wavelet expressions based on several scaling functions*. Journ. Approx. Theory, Vol. 78, 1994, S. 373-401
- [Gros94] Grossmann A., Morlet, J., *Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape*. . SIAM, Journ. Math. Analysis, Vol. 15, No. 4, 1984, S. 723-736
- [Gro96] Gross, B., Bruschini, C., 1996, *Sensor technologies for the detection of anti-personnel mines. A survey of current research and system developments*. International Symposium on Measurement and Control in Robotics ISMCR'96, 9.-11. Mai, Brüssel
- [Gun00] Gunatilaka, A.H., Baertlein, B.A., *A subspace decomposition technique to improve GPR imaging of anti-personnel mines*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (Fl), April 2000
- [Hal98] Halmann J.J., Shubert, K.A., Ruck, G.T., *SAR processing of ground penetrating radar data for buried UXO detection: results from a surface-based system*. IEEE Trans. on Antennas and Propagation, Vol 46, 1998, S. 1023-1027
- [Hay85] Haykin, S.(ed.), *Array Signal Processing*. Prentice Hall Processing Series, 1985
- [Hid98] *Hidden Killers, 1998, The global landmine crisis*. Bericht des US Departement of State, Bureau of Political-Military Affairs by the Office of Humanitarian Demining Programs. Im World Wide Web unter:
http://www.state.gov/www/global/arms/rpt_9809_demine_ch3a.html
- [Hip54] Von Hippel, A.R. (Ed.), *Dielectric Materials and Applications*. MIT Press, 314
- [Hou62] Hough, Paul, V.C., *Method and Means for Recognizing Complex Patterns*. United States Patent Office, Patent 3,069,654, December 18th, 1962
- [Isk00] Iskander, D.R., Zoubir, A.M., Chant, I., *Time-varying Spectrum Based Detection of Landmines Using Ground Penetrating Radar*. Proc. Intern. GPR-Conference 2000, Perth, Australien

- [Jäh93] Jähne, B., *Digitale Bildverarbeitung*. 3. Auflage, Springer-Verlag, 1993
- [Joh95] Johannsen E.M., Mast, J.E., *Imaging algorithms for synthetic aperture ultra-wideband radar*. Engineering Research, Development and Technology, FY95 Thrust Area Report UCRL53868-93, Lawrence Livermore National Laboratory, Livermore, Ca, 1995
- [Kad92] Kadambe, S., Boudreaux-Bartels, G.F., *Application of the Wavelet Transform for the Pitch Detection of Speech Signals*. Special Issue on Wavelet Transforms and Multiresolution Signal Analysis, IEEE Trans. on Inform. Theory, Vol. 38, 1992, S. 917-924
- [Kal91] Kaltenmayer, A., *Modellbasierte Worterkennung Spracherkennungssystemen für großen Wortschatz*. VDI Verlag, Düsseldorf, 1991
- [Ker69] Kerker, M., *The Scattering of Light and other electromagnetic radiation*. Academic Press, New York 1969
- [Kin88] Kinzel, W., *Optimieren durch simuliertes Ausglühen*. Spektrum der Wissenschaft, April 1988
- [Koh99] Koh, G., Arcone, S.A., *Radar Detection of Simulant Mines Buried in Frozen Ground*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3710, Orlando (Fl), April 1999
- [Kul51] Kullback, S., Leibler, R.A., *On information and sufficiency*. Annals of Mathematics and Statistics, Vol. 22, 1951, S. 79-86
- [Löh98] Löhlein, O., Fritzsche M., *Classification of GPR data for mine detection based on hidden Markov models*. EUREL Conference on the detection of abandoned landmines, 12-14 October 1998, Edinburgh, UK
- [Lou94] Louis, A.K., Maaß, P., Rieder A., *Wavelets*. Teubner Studienbücher, 1994
- [Mac98a] *MACADAM trials execution report* – TME/DM/1998/3728/PH/IG. Report prepared by Thomson Detexis. Im WWW unter: <http://apl-database.jrc.it>
- [Mac98b] *MACADAM trials restoration report* – TME/MLK/SM99/4818/PH/IG. Report prepared by Thomson Detexis

-
- [Mal87] Mallat, S., *A multiresolution representation: the wavelet model*. In: Proc. IEEE Workshop on Computer Vision, Miami, Florida, 1987, S. 112-136
- [Mal89] Mallat, S., *A theory of multiresolution signal decomposition: the wavelet representation*. IEEE Trans PAMI, Vol. 11, 1989, S. 674-693
- [Mal89] Mallat, S., Zhang, Z., *Matching Pursuits with time-frequency dictionaries*. IEEE Trans. on Signal Proc., Vol 41, No. 12, 1993
- [Man68] Mandelbrot, B.B., Wallis, J.W., *Fractional Brownian Motions, fractional noises and applications*. SIAM Review, Vol. 10, 1968, S. 422-437
- [Mand90] Mandler, E., Oberländer, M.F., *One-pass encoding of connected component analysis in multi-valued images*, Proc. 10th Int. Conf. On Pattern Recognition, 16.-21.6.1990, Atlantic City, New Jersey
- [Mar87] Marple, S.L., *Digital Spectral Analysis with Applications*. Prentice-Hall, Englewood Cliffs, New Jersey, 1987
- [Mari85] Marinovic, N., Eichmann, G., *An expansion of the Wigner distribution and its applications*. Proc. ICASSP-85, S. 1021-1024
- [Mey92] Meyer, Y., *Wavelets and Operators*. Cambridge University Press, 1992
- [Min00] Mine Facts 2000. Im World Wide Web unter:
<http://etros1.vub.ac.be/minedet/groundbase/minefacts/html/minefacts.html>
- [Mor74] Morey, R.M., *Continuous subsurface profiling by impulse radar*. Am. Soc. Civ. Eng., 1974, S. 213-232
- [Olh98] Olhoeft, G.R., *Electrical, magnetic and geometric properties that determine ground penetrating radar performance*. In Proc. Von GPR'98, 7. Int. Conf. On Ground Penetrating Radar, May 27-30, 1998, The University of Kansas, Lawrence, KS, USA, S. 177-182
- [Orp96] Orphan, V.J., *Demining Tools: Telerobotic vehicular multisensor system, handheld miniature mine detector and enhanced K-9 system*. In: *Improving Technologies for Humanitarian Clearance*, National Research Council, Washington DC, 17.1.-19.1.1996. Im World Wide Web unter: www.saic.com

- [Os95] Osborne, M.R., Smyth, G.K., *A modified Prony algorithm for fitting sums of exponential functions*. SIAM Journ. Sci. Statist.Comput., Vol. 16, 1995, S. 119-138
- [Pap85] Papoulis, A., *Probability, Random Variables and Stochastic Processes*. McGraw-Hill, New York, 1965
- [Papa98] Papageorgiou, M., *Optimierung. Statische, dynamische, stochastische Verfahren für die Anwendung*. 2. Auflage, Oldenbourg-Verlag, 1998
- [Pen84] Pentland, A., *Fractal-Based Description of Natural Scenes*. IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 6, 1984, S. 661-674
- [Rap98] Rappaport, C., et al., *Frequency Domain Simulation of Focused Array Radar Returns from Buried Mines in Clutter*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3392, Orlando (FL), April 1998
- [Ric44] Ricker, N., *Wavelet functions and their polynomials*. Geophysics, Vol. 9, 1944, S. 314-323
- [Roc99] Rockinger, O., *Multiresolution-Verfahren zur Fusion dynamischer Bildfolgen*. Dissertation der Fakultät für Elektrotechnik, Technische Universität Berlin, 1999
- [Sai94] Saito, N., *Local Feature Extraction and its Applications using a Library of Bases*. Ph.D. Thesis, Dep. of Mathematics, Yale University, New Haven, CT USA, Dec. 1994
- [Sch96] Schürmann, J., *Pattern Classification – A Unified View of Statistical and Neural Approaches*. Wiley-Interscience, New York, 1996
- [Sen94] *Sensor Technology Assessment for ordnance and explosive waste detection and location*. Bericht des Jet Propulsion Laboratory Pasadena Mai 1994, im Auftrag des US Army Corps of Engineers, Huntsville Division
- [She92] Shensa, M.J., *The discrete wavelet transform: Wedding the à trous and Mallat algorithms*. IEEE Trans. Signal Proc., Vol. 40, No. 10, 1992, S. 2465-2482
- [Sko90] Skolnik, M.I., *Radar Handbook*. 2. Ausg., McGraw-Hill, New York, 1990

-
- [Str94] Strang, G., Strela, V., *Orthogonal multiwavelets with vanishing moments*. Journ. Optical Engineering, Vol. 33, No. 7, 1994
- [Str96] Strang, G., Nguyen, T., *Wavelets and Filter Banks*. Wellesley-Cambridge Press, Wellesley, 1996
- [Stre97] Strela, V., Heller, P.N., Strang, G., Topiwala, H., Heil, C., *The application of multiwavelet filter banks to image processing*. IEEE Trans. Image Processing., Vol. 8, 1999, S. 548-563, (unter: <http://www.mcs.drexel.edu/~vstrela>)
- [Su199] Sullivan, A., Geng, N., Carin, L., Nguyen, L., Sichina, J., *Performance analysis for radar detection of buried anti-tank and anti-personnel land mines*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 3710, Orlando (Fl), April 1999
- [Szu92] Szu, H.H., Telfer, B., Kadambe, S., *Neural network adaptive wavelets for signal representation and classification*. Journ. Optical Engineering, Vol. 31, No. 9, 1992
- [Tay95] Taylor, J.D., *Introduction to Ultra-Wideband Radar Systems*. CRC Press 1995
- [Tit26] Titchmarsh, E.C., *Conjugate trigonometrical integrals*. Proceedings of the London Mathematical Society (Reihe 2), Vol. 24, 1926, S. 109-130
- [Vit97] Vitebsky, S., Carin, L., Ressler, M.A., Francis, H.L., *Ultra-Wideband, Short-Pulse Ground Penetrating Radar: Simulation and Measurement*. IEEE Trans. on Geoscience and Remote Sensing, Vol. 35, No. 3, 1997, S. 762-772
- [Wig32] Wigner, E.P., *On the Quantum Correction for Thermodynamic Equilibrium*. Physical Review, Vol. 40, 1932
- [Yil87] Yilmaz, Ö., *Seismic Data Processing*. Society of Exploration Geophysics, Series Investigations in Geophysics, Vol. 2, 1987
- [Yu00] Yu, S.H. et al, *Automatic Mine Detection based on Multiple Features*. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (Fl), April 2000
- [Yu00] Yu, S.H., Miller, E.L., Sower G., *Combined High-dimensional Analysis of Variance (HANOVA) and Sequential Probability Ration Test (SPRT) to Detect*

Buried Mines. SPIE Conf. Detection and Remediation Technologies for Mines and Minelike Targets, Vol. 4038, Orlando (Fl), April 2000

Anhang A

A.1 Polynomklassifikator

Die Optimierung der Schätzfunktion $\mathbf{d}(\mathbf{v})$ bezüglich der Zielvektoren (Klassenvorgaben) \mathbf{y} mithilfe eines Quadratmittellansatzes $E\{|\mathbf{y} - \mathbf{d}|^2\}$ führt auf die Rückschlußwahrscheinlichkeiten des mustererzeugenden Prozesses. Eine naheliegende Möglichkeit zur Konstruktion der Unterscheidungsfunktionen $d_k(\mathbf{v})$ (mit dem Klassenindex k) ist der Polynomansatz [Sch96].

Der Polynomklassifikator besteht aus zwei Schichten (vgl. Bild A.1). Die erste Schicht berechnet polynomiale (multiplikative) Kombinationen der ursprünglichen Merkmale. Diese Kombinationen werden auch als erweiterte Merkmale bezeichnet und mit einer sogenannten *Polynomstrukturliste* $\mathbf{x}(\mathbf{v})$ beschrieben. Jede Komponente $\mathbf{x}_s(\mathbf{v})$ dieser Liste ist ein ausgewähltes Produkt \prod_s verschiedener Merkmale v_m : $\mathbf{x}_s(\mathbf{v}) = \prod_s v_m^i$. Die zweite Schicht ist eine Linearkombination (über die Koeffizientenmatrix \mathbf{A}) dieser erweiterten Merkmale. Eine kompakte mathematische Beschreibung des Polynomklassifikators ist:

$$\mathbf{d}_{PC}(\mathbf{v}) = \mathbf{A}^T \cdot \mathbf{x}(\mathbf{v}). \quad (\text{A.1})$$

In Bild A.1 ist ein vollständiger quadratischer Klassifikator für zwei Merkmale und drei Klassen angegeben, wie er auch in dieser Arbeit verwendet wurde (mit einer größeren Anzahl von Merkmalen). Der konstante Term $v_0 = 1$ repräsentiert das Glied nullten Grades. Die Auswahl der Polynomstrukturliste erfolgt durch den Anwender, während die Adaption von \mathbf{A} anhand der Trainingsdaten geschieht. Ein wichtiger Vorteil des Polynomklassifikators ist, dass eine analytische Lösung zur Adaption der Gewichtsmatrix \mathbf{A} existiert, wenn der Schätzfehler $E\{|\mathbf{y} - \mathbf{d}|^2\}$ minimiert wird:

$$E\{\mathbf{x} \mathbf{x}^T\} \cdot \mathbf{A} = E\{\mathbf{x} \mathbf{y}^T\}. \quad (\text{A.2})$$

Sind die einzelnen Klassen in der Menge verfügbarer Muster unterschiedlich häufig vertreten, ist es sinnvoll, die Momentenmatrix $E\{\mathbf{x} \mathbf{x}^T\}$ durch Summation klassenweise bestimmter Momentenmatrizen zu berechnen:

$$E\{\mathbf{x} \mathbf{x}^T\} = \sum_{k=1}^K m_k E\{\mathbf{x}_k \mathbf{x}_k^T\}, \quad (\text{A.3})$$

mit der Klassenanzahl K . Werden die Mischungskoeffizienten m_k zu $\frac{1}{K}$ gewählt, ergeben sich „ausgeglichene“ Klassen.

Um die Matrix A zu erhalten, wird die Schlüsselgleichung (A.2) in der Regel mit einem Gauß-Jordan-Algorithmus gelöst. Im Allgemeinen kann dabei nicht angenommen werden, dass die Momentenmatrix $E\{\mathbf{x} \mathbf{x}^T\}$ nichtsingulär und damit invertierbar ist, da unter den Komponenten von \mathbf{x} lineare Abhängigkeiten bestehen. Schürmann [Sch96] schlägt geeignete Pivotstrategien vor, die diese Abhängigkeiten berücksichtigen. Dabei wird eine Reihenfolgeliste der Polynomterme aufgestellt, entsprechend ihres Beitrags zur Minderung der Reststreuung, aus der sich eine Rangfolge der verwendeten Merkmale ableiten lässt. Genau dieser Umstand wurde bei der Bestimmung der am besten diskriminierenden Basis in Abschnitt 4.4.2 eingesetzt.

Für den Fall, dass zwei oder mehr Ausgänge nur geringfügig unterschiedliche Werte d_k liefern, besteht die Möglichkeit der Rückweisung, die im Prinzip wie eine weitere Klasse behandelt werden kann. Ein geeignetes Kriterium ist das sogenannte RAD-Kriterium [Sch96], das als euklidische Distanz zum nächstgelegenen Klassenvektor \mathbf{e}_i (Einheitsvektor) definiert ist:

$$r_{\min}^2(d) = \min_{\{i\}} |\mathbf{d} - \mathbf{e}_i|^2. \quad (\text{A.4})$$

Alle Entscheidungen für die $r_{\min}^2(d)$ größer als ein Schwellwert ist, werden zurückgewiesen.




Bild A.1 Vollständiger quadratischer Polynomklassifikator für zwei Merkmale und drei Klassen. Der konstante Term $v_0 = 1$ repräsentiert das Glied nullten Grades.

Prinzipiell können die Grenzen der Klassengebiete auf zwei unterschiedliche Arten bestimmt werden. Im ersten Fall wird immer eine einzelne Klasse gegen eine Restklasse, bestehend aus der Vereinigung aller übrigen Klassen, betrachtet („einer-gegen-alle“). Eine Alternative, die oft zu besseren Ergebnissen führt, aber auch mit einem höheren

Rechenaufwand verbunden ist, ist die paarweise Betrachtung von Klassen. In diesem Fall werden die Trennflächen im Merkmalsraum immer nur für eine Paarkombination von Klassen bestimmt, während alle anderen Klassen außer acht gelassen werden. Um zu einer Klassenentscheidung zu gelangen, müssen dann alle durch den paarweisen Vergleich entstandenen Einzelentscheidungen miteinander verrechnet werden. Für ein Dreiklassen-Problem entspräche eine mögliche Vorgehensweise der beim Skatspielen: am Schluß des Spiels werden paarweise die Punktedifferenzen zwischen allen Spielern berechnet und addiert. Der Spieler (die Klasse) mit der höchsten Punktzahl hat dann gewonnen.

A.2 Optimierung mit dem *Threshold-Accept* Verfahren

Der zur Optimierung der Superwavelets verwendete Algorithmus beruht auf dem Verfahren von Dueck [Due93]. Das Funktionsprinzip des implementierten Algorithmus lässt sich folgendermaßen zusammenfassen:

1. Wähle in der gegebenen Aufgabenstellung irgendeine Lösung (einen Zustand x im Zustandsraum X) als Ausgangspunkt.
2. Wähle einen Nachbarzustand y von x , der durch lokale Veränderung (Mutation) aus x hervorgeht.
3. Vergleiche die beiden Zielfunktionswerte $f(x)$ und $f(y)$. Ist $f(y)$ um mehr als δ schlechter als $f(x)$ verwirf y ; bleibe bei x stehen und suche einen neuen Nachbarzustand von x . Ist aber $f(y)$ mindestens so groß wie $f(x) - \delta$, ist also $f(y)$ höchstens um δ schlechter als $f(x)$, so gehe zum Zustand y über, d.h. y wird akzeptiert. Fahre von y aus weiter fort.
4. Wenn nach mehreren Versuchen keine Verbesserung auftritt, erhöhe einen Zähler um eins. Hat dieser Zähler einen vorgegebenen Wert erreicht, reduziere δ und setze den Zähler wieder auf null. Auf diese Art wird mit Annäherung an das Optimum die Schwelle δ langsam auf null abgesenkt. Ein Wert von null bedeutet, dass keine Verschlechterungen akzeptiert werden.

Die Vorgehensweise kann man sich veranschaulichen mit einem Wanderer, der in einer Gebirgsregion den höchstgelegenen Punkt erreichen will. Wenn er bei jedem Schritt bergauf geht, wird er voraussichtlich nicht auf dem höchsten Gipfel landen. Wenn er dagegen nach einer gewissen Zeit auch mal eine Verschlechterung in Kauf nimmt, hat er

die Chance von einem niedrigen Gipfel herunter ins Tal zu kommen, um dann von dort auf einen höheren Gipfel zu finden.

Den Ausgangspunkt der Optimierung zur Bestimmung der Superwavelets in Abschnitt 4.8.2 bildet jeweils der Parametervektor $\boldsymbol{\gamma}$, durch den die Atome der Bibliothek festgelegt sind. Bei jeder Iteration des TA-Algorithmus wird per Zufallsexperiment bestimmt, welche der in $\boldsymbol{\gamma}$ enthaltenen Größen mutiert wird. Die Mutation geschieht durch zufällige Variation der betreffenden Größe innerhalb eines vorgegebenen Bereichs.

Lebenslauf

Persönliche Daten:

Name: Martin Fritzsche
Geburtsdatum: 3. September 1961
Geburtsort: Darmstadt
Familienstand: verheiratet, 2 Kinder

Schulbildung:

1968 – 1972 Grundschule in Neckarrems und Friedrichshafen
1972 – 1981 Gymnasium in Markdorf, Baden (Abschluss: Abitur)

Wehrdienst:

1981 – 1982 Grundwehrdienst in Sigmaringen

Studium und Berufsweg:

1982 – 1988 Studium der Geophysik an der Universität Karlsruhe
Schwerpunkt: Ausbreitung seismischer Wellen im Untergrund
Mitarbeit in Forschung und Lehre
Sept. 1988 Diplom in Geophysik an der Universität Karlsruhe
1988 – 1989 Mitarbeit in Forschung und Lehre am Institut für Geophysik
1989 – 1991 Mitarbeiter im Forschungs & Entwicklungsbereich von
British Petroleum (London).
Seit Febr. 1992 Mitarbeiter am DaimlerChrysler-Forschungsinstitut für Muster-
erkennung, Signal- und Bildverarbeitung in Ulm