

Klassifikation von hochauflösenden optischen
Multispektralbildern städtischer Gebiete mittels
Fuzzy-Methoden

von

Niklas Rega

September 2000

Physikalische Diplomarbeit
am Fachbereich Physik
der Universität Hamburg
II. Institut für Experimentalphysik
Arbeitsgruppe CENSIS, Fernerkundung

Gutachter: Prof. Dr. L. Dreschler-Fischer und Prof. Dr. H. Spitzer

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Methoden	2
1.3	Aufbau der Diplomarbeit	4
2	Theoretische Grundlagen	7
2.1	Theorie der Fernerkundung	7
2.1.1	Fernerkundung	7
2.1.2	Multispektralbilder	7
2.1.3	Strahlung	8
2.1.4	Reflektanzbilder	13
2.2	Theorie der Fuzzy-Logik	15
2.2.1	Einführung	15
2.2.2	Zugehörigkeitsfunktion	15
2.2.3	Mengenoperationen	17
2.3	Theorie der Neuronalen Netze	19
2.3.1	Künstliches Neuron	20
2.3.2	Verdeckte Schicht	20
2.3.3	Der <i>backpropagation</i> Algorithmus	21
2.4	Theorie der Klassifikation	24
2.4.1	Klassische Klassifikationsverfahren	24
2.4.2	Fuzzy-Klassifikationsverfahren	32
2.4.3	Gütemaße für Klassifikationen	39
2.5	Fusion von fuzzy-klassifizierten Karten	44
2.5.1	Konvexe Linearkombination	44
2.5.2	Fusion mittels eines Neuronalen Netzes	45
3	Daten	47
3.1	Herkunft und Gewinnung von Reflektanzbildern	47
3.2	Detektor: DAEDALUS AADS 1268	49
3.2.1	Bildgeometrie und Verzerrungen	49
3.2.2	Kalibration	51

4	Klassenauswahl und Testgebiete	53
4.1	Referenzgebiete	53
4.2	Klassenauswahl	55
4.2.1	Klassenauswahl für die Bodenversiegelungskarte	56
4.2.2	Klassen des Amtes für Stadtforschung und Statistik Nürnberg	56
4.2.3	Auswahl für die Klassifizierung relevanter Klassen	58
4.3	Klassenauswahl in den Testgebieten	60
4.3.1	Gebiet: Andernacherstraße	60
4.3.2	Gebiet: Thon	63
4.3.3	Gebiet: Rennweg	65
4.3.4	Gebiet: Innenstadt	68
4.3.5	Gebiet: Gesamtszene	70
5	Klassifikation & Fusion	77
5.1	Unüberwachte Klassifikation	78
5.1.1	<i>Fuzzy-C-Means</i> (FCM)	78
5.1.2	<i>Fuzzy-C-Means</i> mit Kontext (SFCM)	79
5.2	Überwachte Klassifikation	81
5.2.1	Maximum Likelihood (ML)	81
5.2.2	<i>Fuzzy k-nearest-neighbor</i> (FKNN)	88
5.3	Fusion klassifizierter Daten	94
5.3.1	Gewichtete konvexe Linearkombination (FLK)	94
5.3.2	Neuronales Netz (FNN)	99
5.4	Zusammenfassung	104
5.4.1	Kanalauswahl: Alle Kanäle und IKONOS Kanäle	104
5.4.2	Kanalauswahl: 9 aus 10 Kanälen	106
6	Bewertung der klassenspezifischen Gütemaße	109
6.1	Testgebiet: Andernacherstr.	109
6.2	Testgebiet: Innenstadt	112
6.3	Testgebiet: Rennweg	114
6.4	Testgebiet: Thon	118
6.5	Testgebiet: Gesamtszene	123
6.6	Zusammenfassung	127
7	Zusammenfassung	129
7.1	Klassenauswahl & Validierungskarten	129
7.2	Klassifikationsergebnisse	131
7.3	Vergleich mit aktueller Forschung	132
7.4	Abschließende Betrachtung	133
8	Ausblick	135

Literaturverzeichnis	137
A Tabellen	141
A.1 Testgebiet: Andernacherstr.	141
A.2 Testgebiet: Innenstadt	144
A.3 Testgebiet: Rennweg	147
A.4 Testgebiet: Thon	150
A.5 Testgebiet: Gesamtszene	153

Abbildungsverzeichnis

2.1	Spektrale Strahldichte von schwarzen Körpern	9
2.2	Sonnenspektrum auf der Erdoberfläche	10
2.3	Reflektion an Oberflächen	12
2.4	Linguistische Beschreibung von Zuständen	16
2.5	Aufbau eines dreischichtigen neuronalen Netzes	19
2.6	Beispiel einer sigmoiden Aktivierungsfunktion	21
2.7	Ortsraum vs. Merkmalsraum	25
2.8	Wahrscheinlichkeitsdichtefunktionen aus [DH73]	26
2.9	Schematische Darstellung des ISODATA Algorithmus für zwei Klassen	30
2.10	Schematische Darstellung des FCM Algorithmus für zwei Klassen	35
2.11	Umgebungspotential für Fuzzy-c-Means mit Kontext	36
2.12	Schematische Darstellung des KNN Algorithmus für zwei Klassen	38
2.13	Beispiel für die Berechnung von $s_4(A, B)$	43
3.1	Industriegebiet Andernacher Str. CIR Luftbild	48
3.2	DAEDALUS AADS 1268	50
3.3	Panoramaverzerrung in Abhängigkeit von Scanwinkel.	51
4.1	Die vier Testgebiete (Kanal 6)	54
4.2	Validierungskarte Andernacherstr.	62
4.3	Nürnberg Andernacherstr. Kanal 6	62
4.4	Validierungskarte Stadtrandgebiet	64
4.5	Nürnberg Stadtteil Thon Kanal 6	64
4.6	Validierungskarte Rennweg	67
4.7	Nürnberg Stadtteil Rennweg Kanal 6	67
4.8	Validierungskarte Innenstadt	69
4.9	Nürnberger Altstadt Kanal 6	69
4.10	Validierungskarte Gesamtszene	71
4.11	Spektren der ausgewählten Klassen	74
4.12	Spektren der ausgewählten Klassen	75
5.1	FCM mit 5 Klassen	80
5.2	SFCM mit 5 Klassen	80
5.3	FCM mit 10 Klassen	80
5.4	SFCM mit 10 Klassen	80
5.5	ML Klassifikation aller Kanäle, Testgebiet: Andernacherstr.	84

5.6	ML Klassifikation IKONOS Kanäle Testgebiet: Andernacherstr.	84
5.7	ML Klassifikation aller Kanäle, Testgebiet: Gesamtszene	86
5.8	ML Klassifikation IKONOS Kanäle Gesamtszene	87
5.9	FKNN Klassifikation aller Kanäle, Testgebiet: Andernacherstr.	90
5.10	FKNN Klassifikation IKONOS Kanäle Testgebiet: Andernacherstr.	90
5.11	FKNN Klassifikation aller Kanäle, Testgebiet: Gesamtszene	92
5.12	FKNN Klassifikation IKONOS Kanäle Gesamtszene	93
5.13	FLK Klassifikation aller Kanäle, Testgebiet: Andernacherstr.	96
5.14	FLK Klassifikation IKONOS Kanäle Testgebiet: Andernacherstr.	96
5.15	FLK Klassifikation aller Kanäle, Testgebiet: Gesamtszene	97
5.16	FLK Klassifikation IKONOS Kanäle Gesamtszene	98
5.17	FNN Klassifikation aller Kanäle, Testgebiet: Andernacherstr.	101
5.18	FNN Klassifikation IKONOS Kanäle Testgebiet: Andernacherstr.	101
5.19	FNN Klassifikation aller Kanäle, Testgebiet: Gesamtszene	102
5.20	FNN Klassifikation IKONOS Kanäle Gesamtszene	103
6.1	Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FNN)	111
6.2	Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FKNN)	111
6.3	Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FLK)	111
6.4	Testgebiet Andernacherstr.: Gütemaße PAUA (ML)	111
6.5	Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FNN)	113
6.6	Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FKNN)	113
6.7	Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FLK)	113
6.8	Testgebiet Innenstadt: Gütemaße PAUA (ML)	113
6.9	Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FNN)	117
6.10	Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FKNN)	117
6.11	Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FLK)	117
6.12	Testgebiet Rennweg: Gütemaße PAUA (ML)	117
6.13	Spektren der Klassen "Betonplatten", "Giebeldach, schwarz" und "Kiesdach" im Testgebiet Thon	119
6.14	Spektren der Klassen "Betonplatten", "Giebeldach, schwarz" und "Kiesdach" im Testgebiet Rennweg	119
6.15	Testgebiet Thon: Gütemaße PAUA (ML) für unterschiedliche Trainingspi- xelanzahl	120
6.16	Testgebiet Thon: Gütemaße PAUA und FPAUA (FNN)	122
6.17	Testgebiet Thon: Gütemaße PAUA und FPAUA (FKNN)	122
6.18	Testgebiet Thon: Gütemaße PAUA und FPAUA (FLK)	122
6.19	Testgebiet Thon: Gütemaße PAUA (ML)	122
6.20	Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FNN)	125
6.21	Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FKNN)	125
6.22	Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FLK)	125
6.23	Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (ML)	125

Tabellenverzeichnis

2.1	Aufbau Konfusionsmatrix	40
2.2	Beispiel <i>User's Accuracy UA</i>	40
2.3	Beispiel <i>Producer's Accuracy PA</i>	41
2.4	Beispiel <i>Overall Accuracy OA</i>	41
3.1	Wellenlängenbereiche des DAEDALUS Detektors	49
4.1	Nutzungstypen des Amtes für Statistik Nürnberg	57
4.2	Klassenauswahl aus [Kul97]	59
4.3	Klasseneinteilung im Testgebiet Andernacherstr.	60
4.4	Klasseneinteilung im Testgebiet Thon	63
4.5	Klasseneinteilung im Testgebiet Rennweg	65
4.6	Klasseneinteilung im Testgebiet Innenstadt	68
4.7	Klasseneinteilung für Gesamtszene	72
5.1	Wellenlängen der IKONOS Kanäle	77
5.2	Tabelle zur Bewertung von Kappa-Werten.	81
5.3	Kappa-Werte in Abhängigkeit von der Anzahl der Trainingspixel pro Klasse	82
5.4	12 Gebiete von besonderem Interesse im Testgebiet Andernacherstr.	85
5.5	Kappa-Werte der ML Klassifikation für die verschiedenen Testgebiete	88
5.6	Kappa-Werte der FKNN Klassifikation für die verschiedenen Testgebiete	91
5.7	Kappa-Werte der Klassifikation durch FLK für die verschiedenen Testgebiete	95
5.8	Kappa-Werte der Klassifikation durch FNN für die verschiedenen Testgebiete	100
5.9	Kappa-Werte der verschiedenen Klassifikationsverfahren auf unterschiedlichen Testgebieten	105
5.10	Kappa-Werte der Kanalauswahl 9 aus 10	106
6.1	Klassen Testgebiet:Andernacherstr.	110
6.2	Konfusionsmatrix für ML Klassifikation, Testgebiet: Andernacherstr.	110
6.3	Klassen Testgebiet:Innenstadt	112
6.4	Konfusionsmatrix für ML Klassifikation, Testgebiet: Innenstadt	114
6.5	Klassen Testgebiet: Rennweg	114
6.6	Konfusionsmatrix für ML Klassifikation, Testgebiet: Rennweg	116
6.7	Klassen Testgebiet: Thon	118
6.8	Konfusionsmatrix für ML Klassifikation, Testgebiet: Thon	121
6.9	Klassen Gesamtszene	123

6.10	Konfusionsmatrix für ML Klassifikation, Gesamtszene	126
7.1	Vergleich verschiedener Arbeiten zur Klassifikation von Multispektralaufnahmen	133
A.1	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Andernacherstr. . .	142
A.2	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet:Andernacherstr. . .	143
A.3	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Innenstadt	145
A.4	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Innenstadt	146
A.5	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Rennweg	147
A.6	Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebiet: Rennweg; ohne Kanal 1 bis 5	148
A.7	Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebietes: Rennweg; ohne Kanal 6 bis 10	149
A.8	Kappa-Wert, PAUA und FPAUA Gütemaße; Testgebiet:Thon	150
A.9	Kappa-Wert, PAUA und FPAUA Gütemaße Kanalauswahl 9 aus 10 ; ohne Kanal 1 bis 5; Testgebiet: Thon	151
A.10	Kappa-Wert, PAUA und FPAUA Gütemaße Kanalauswahl 9 aus 10 ; ohne Kanal 6 bis 10; Testgebiet: Thon	152
A.11	Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Gesamtszene . . .	154
A.12	Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebiet: Gesamtszene; ohne Kanal 1 bis 3	155
A.13	Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebiet: Gesamtszene; ohne Kanal 4 bis 6	156
A.14	Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebiet: Gesamtszene; ohne Kanal 7 bis 10	157

Kurzzusammenfassung

Das Thema dieser Diplomarbeit ist der Vergleich unterschiedlicher Fuzzy- und Fusionsmethoden zur Klassifikation von Multispektralaufnahmen städtischer Gebiete. Die Methoden wurden nicht nur untereinander verglichen, sondern auch mit der statistischen Methode der Maximum Likelihood (ML) Klassifikation. Als Datensatz dienten 10-kanalige Multispektralaufnahmen der Stadt Nürnberg aus dem Sommer 1997. Die Aufnahmen wurden mit dem DAEDALUS AADS 1268 Detektor vom Deutschen Zentrum für Luft- und Raumfahrt e.V. (DLR) Oberpfaffenhofen gemacht.

Die unterschiedlichen Verfahren wurden auf vier Testgebieten und einer aus diesen Testgebieten kombinierten Gesamtszene getestet.

Die Genauigkeit der Klassifikation wurde mit drei verschiedenen Gütemaßen bestimmt, dem Kappa-Wert, dem Produkt aus *Producers* und *Users Accuracy*, sowie dem Fuzzy Produkt aus *Producers* und *Users Accuracy*. Das letzte Gütemaß wurde von Jäger und Benz von der Fachgruppe SAR-Expertensysteme in Oberpfaffenhofen [JB00] eingeführt. Dieses Gütemaß wurde für die gewichtete konvexe Linearkombination (FLK) von Zugehörigkeitskarten genutzt, einem der beiden Fusionsverfahren, die getestet wurden. Das zweite Fusionsverfahren fusioniert die Zugehörigkeitskarten mittels eines dreischichtigen neuronalen Netzes (FNN), das mit *back-propagation* trainiert wurde.

Die Zugehörigkeitskarten wurde durch den Fuzzy *k-nearest-neighbor* Algorithmus (FKNN) erzeugt, der auf dem Artikel von Keller et. al. [KGG85] basiert. Dieses Klassifikationsverfahren wurde ebenfalls mit der ML Klassifikation verglichen.

Außerdem wurden die Konsequenzen einer Reduktion der berücksichtigten Kanäle des Multispektralbilds untersucht. Die verschiedenen Klassifikationen wurden mit vier, den Kanälen des IKONOS Satelliten entsprechenden Kanälen, gemacht.

Es zeigte sich, daß die ML Klassifikation die besten Ergebnisse lieferte. Die Kappa-Werte der Testszene Andernacherstr. lagen zwischen 0.902 (ML) und 0.687 (FLK). Die anderen Gebiete wurden nicht ganz so gut bewertet. Die Reduktion der Kanalanzahl führte beim Gebiet Andernacherstr. zur Abnahmen der Klassifikationsgenauigkeit. Die Kappa-Werte lagen zwischen 0.87 (ML) und 0.598 (FLK).

Die Arbeit gliedert sich wie folgt: Zuerst wird eine Einführung in den theoretischen Hintergrund gegeben. Danach werden die verwendeten Klassen und Testgebiete vorgestellt. In den beiden folgenden Kapitel werden die Klassifikationsergebnisse gezeigt und ihre Genauigkeit analysiert. Zum Schluß wird eine Zusammenfassung der Ergebnisse und der entstanden Probleme gebracht und, nicht zu vergessen, ein Ausblick für weitere Untersuchungen gegeben.

Abstract

The topic of this master thesis was a comparison of different fuzzy classification and fusion approaches of multi-spectral images of urban areas. The approaches were also compared with the statistical maximum likelihood approach (ML). For the test a data set of 10-channel multi-spectral images is used. The data set was recorded with the multi-spectral

detector DAEDALUS AADS 1268 by the German Aerospace Center (DLR) Oberpfaffenhofen. The scene was taken in summer 1997 and shows the urban area of Nuremberg. The different methods are tested on four different subsets and one combined scene of the four subsets.

The accuracy of the classification was determined with three different measures, the kappa-coefficient, the product of the producers and users accuracy and the fuzzy product of the producers and users accuracy. The last measure was introduced by Benz and Jäger [JB00] from the DLR SAR-Expertsystems Group Oberpfaffenhofen. It was used for a weighted convex linear-combination of membership maps (FLK), one of the two fusion approaches. The second fusion approach was the fusion of membership maps with a three layer neuronal network (FNN), which was trained by back-propagation. The membership maps, which were used for the fusion, were generated by the fuzzy k-nearest-neighbor algorithm (FKNN) based on the article of Keller et al. [KGG85]. This classification method was also compared with the ML classification.

We also made an analysis of the consequences which result if the number of channels are reduced. The four channels, which were selected, were the ones used by the satellite IKONOS.

It was shown that the ML classification produced the best results. For the testscene Andernacherstr. the kappa-coefficients were between 0.902 (ML) and 0.687 (FLK). The reduction of the channel number led to a decrease in the classification accuracy. The kappa-coefficients were between 0.87 (ML) and 0.598 (FLK).

The structure of the thesis is as follows. First the theoretical background is reviewed. Thereafter follows a description of the classes and testscenes, which are used for the classification. Then there are two chapters about the classification results and their accuracies. At the end a summary of the results and some problems encountered is given. Last but not least ideas for future investigations are suggested.

1 Einleitung

Diese Diplomarbeit ist im Zeitraum Oktober 1999 bis September 2000 am II. Institut für Experimentalphysik des Fachbereichs Physik der Universität Hamburg, Projektgruppe “Physikalische Grundlagen der Fernerkundung“ entstanden. Das Thema lautet “Klassifikation von hochauflösenden optischen Multispektralbildern städtischer Gebiete mittels Fuzzy-Methoden“. Die Betreuung fand durch Herrn Prof. Dr. Hartwig Spitzer und Herrn Dipl. Phys. André Rothkirch statt. Durch die Lage der Arbeitsräume der Arbeitsgruppe im Fachbereich Informatik, Abteilung kognitive Systeme (KOGS), kam der Kontakt zur Zweitgutachterin Frau Prof. Dr. Leonie Dreschler-Fischer zustande. Während der Diplomarbeit absolvierte ich einen dreimonatigen Forschungsaufenthalt beim DLR¹ Oberpfaffenhofen. Dort arbeitete ich in der Gruppe um Frau Dr. Ursula Benz im Institut für Hochfrequenztechnik und Radarsysteme, Abteilung SAR² Technologie, Fachgruppe SAR-Expertensysteme, mit Herrn Dr. Gunther Jäger zusammen an einem *Multi Channel Classification Tool*. Zielsetzung dieses Aufenthaltes war es, die dort entwickelten Algorithmen zur Klassifikation von Radarbildern auf optischen Daten zu testen und weiterzuentwickeln. Die Algorithmen zeichnen sich durch die Verwendung von Fuzzy-Methoden und einer allgemeinen Anwendbarkeit aus.

Die Daten, die für den Test der Verfahren benutzt wurden, stammen von einer Überfliegung der Stadt Nürnberg im Sommer 1997 und wurden mittels des DAEDALUS Sensors AADS 1268 an Bord eines Flugzeuges des DLR aufgezeichnet. Es handelt sich dabei um multispektrale Luftbildaufnahmen in 11 Kanälen im Wellenlängenbereich von $0.42 \mu m$ bis $13 \mu m$. Der Thermalkanal von $8 - 13 \mu m$ wird in dieser Arbeit nicht verwendet.

1.1 Motivation

Die Arbeitsgruppe für Naturwissenschaft und Internationale Sicherheit in der Universität Hamburg (Center for Science and International Security - CENSIS), zu der die Projektgruppe “Physikalische Grundlagen der Fernerkundung“ gehört, beschäftigt sich u.a. mit der Untersuchung von Klassifikationsmethoden zur Interpretation von Luftbildaufnahmen. Der Anwendungshorizont umfaßt die Klassifikation von städtischen Gebieten und die Unterstützung von Verifikation und Vertrauensbildung im Rahmen des *Open-Skies* Vertrages. Die immensen Mengen an Bildmaterial, die dabei anfallen, stellen den menschlichen Interpretier vor ein großes Problem. Wie soll er entscheiden, in welchen Regionen

¹DLR - Deutsches Zentrum für Luft- und Raumfahrt e.V.

²SAR - Synthetisches Appatur Radar

er nach militärischen Anlagen suchen soll? Ist kein Vorwissen über die aufgenommenen Gebiete vorhanden, muß die Szene mühsam abgesucht werden. Dabei kann leicht etwas übersehen werden. Die Klassifikation soll helfen, interessante Bereiche hervorzuheben.

Als Anwendungsgebiet ist nicht nur die Nutzung für die Verifikation zu sehen. Es gibt auch andere Nutzer, die von automatisch klassifizierten Luftbilddaufnahmen städtischer Gebiet profitieren können. Dazu zählen u.a. die Stadtplanungs-, Bodeninformations- und Umweltämter. In deren Bedarfsbeschreibung liegt ein Anwendungsbezug, den die in dieser Arbeit vorgenommenen Klassifikationen haben. Es wurde versucht, Klassen auszuwählen, die für die Ämter von Interesse sind.

Dabei habe ich mich u.a. an der Auswahl des Umweltamtes der Stadt Nürnberg für eine Realnutzungskarte orientiert. Eine weitere Klasseneinteilung dient zur automatischen Bestimmung eines Versiegelungskatasters. Hier habe ich nur einen möglichen Weg dort hin beschrieben. In einer Studie von der Universität Vechta beschreibt Matthias Möller [Mat99], daß für ein gutes Versiegelungskataster mindestens eine Bodenauflösung von 0.25 m gegeben sein sollte. Netzband et. al. und Bayer et. al. haben dagegen Untersuchungen mit Hilfe des DAEDALUS Detektors in Hinblick auf die Erstellung eines Versiegelungskatasters vorgenommen [NM97, BH97]. Die Bodenauflösung ihrer Untersuchungen betrug 2 m. Welche Auflösungsgenauigkeit für einen potentiellen Nutzer erforderlich ist, wurde nicht ermittelt.

Diese Diplomarbeit ist auch eine Fortsetzung der Untersuchungen, die in der Diplomarbeit von Daniel Kulbach [Kul97] gemacht wurden. Kulbach hat in der Arbeit einen systematischen Vergleich von den statistischen Klassifikationsverfahren *Minimum Distance* und *Maximum Likelihood* (ML) vorgenommen. In dieser Diplomarbeit wird der Vergleich auf Klassifikationsverfahren, die mit Fuzzy-Methoden arbeiten, ausgedehnt. Als Vergleich zu den klassischen statistischen Verfahren wird die ML Klassifikation benutzt.

Die hier verwendeten Fuzzy-Verfahren zur Klassifikation wurden zum Teil bei CENSIS von R. Wiemker entwickelt (unüberwachte Fuzzy-Klassifikationsalgorithmen), zum Teil beim DLR (überwachte Fuzzy-Klassifikationsalgorithmen und Fusionsalgorithmen). Die Programme wurden an die jeweiligen Anforderungen angepaßt und erweitert. Die Programme sind alle unter der Entwicklungsumgebung IDL³ 5.3 geschrieben und sowohl auf MS Windows NT als auch Unix Systemen nutzbar.

1.2 Methoden

Ein Ziel dieser Arbeit ist der Test und Vergleich unterschiedlicher Fuzzy-Klassifikationsverfahren. Unter Klassifikation versteht man die Einteilung einer Menge in bestimmte Klassen. Bei Bilddaten werden die einzelnen Bildpunkte (Pixel) verschiedenen Klassen zugewiesen. Diese Klassen unterscheiden sich durch bestimmte Merkmale, im Falle von Multispektralbildern z.B. durch die Pulshöhen der einzelnen Spektralkanäle. Diese

³IDL - Interactive Data Language, Software von Research Systems, Inc. In Deutschland erhältlich bei CRESO GmbH Talhofstraße 32a D-82205 Gilching

Merkmale spannen einen Merkmalsraum auf. In diesem Merkmalsraum liegen die Pixel in Klassen ähnlicher (z.B. spektraler) Signatur vor. Ein Klassifikationsverfahren kann nun automatisch diese Klassen detektieren und somit auch im Ortsraum der Bilddaten eine Klassenzuweisung vornehmen.

Die Klassifikationsverfahren teilen sich in zwei verschiedene Gruppen auf. Bei den *unüberwachten* Verfahren wird der Merkmalsraum automatisch in eine bestimmte Anzahl von Klassen eingeteilt. Einer der bekanntesten Algorithmen, der diese Einteilung vornimmt, ist der ISODATA. Die *überwachte* Klassifikation erlernt eine Klasseneinteilung des Merkmalsraumes durch die Vorgaben, die ein Anwender gibt. Dabei werden z.B. anhand der Bilddaten bestimmte Bereiche markiert, die der Nutzer als zu einer Klasse gehörend annimmt. Aus diesen Daten werden Klassifikatoren berechnet, mit denen sich die übrigen Pixel einer Szene klassifizieren lassen. Ein häufig verwendetes Verfahren ist die Maximum Likelihood Klassifikation.

Bei Fuzzy-Verfahren handelt es nun um eine Erweiterung bestehender klassischer Verfahren. Die klassischen Verfahren gehen von scharfen Mengen aus, d.h. ein Element gehört entweder zu einer Menge oder nicht. Die Fuzzy-Verfahren basieren hingegen auf der Fuzzy-Logik, die erlaubt, daß ein Element unterschiedliche Zugehörigkeiten zu verschiedenen Mengen haben darf. Die Methoden der Klassifikation mittels Fuzzy-Verfahren sind hinreichend bekannt und beschrieben. Die wesentlichen Beiträge hierzu stammen von Dunn [Dun73], Bezdek [BP92] und Keller et. al. [KGG85]. Gute Übersichtsartikel finden sich in [BP92] und [BB99].

Außerdem wurde die Fusion von klassifizierten Ergebnissen untersucht. Dabei wurden vorhandene Klassifikationsergebnisse derselben Szene miteinander kombiniert, um eine bessere Klassifikation zu erhalten. Die Klassifikationsergebnisse stammen aus den 10 Spektralkanälen des Daedalus Detektors, die zunächst kanalweise klassifiziert wurden. Die zur Fusion von Datensätzen verwendeten Verfahren basieren hauptsächlich auf den von Benz und Jäger entwickelten Methoden zur Bestimmung von Fuzzy-Gütemaßen und deren Nutzung zur Fusion [JB00, HJKH99, BJ99, Ben99b]. Die Fusionsverfahren sind zum einen über eine gewichtete konvexe Linearkombination implementiert worden, zum anderen mittels eines neuronalen Netzes.

Die Linearkombination fusioniert die Fuzzy-Ergebnisse einer Klassifikation, indem sie für jede Klassifikation und jede Klasse eine Gewichtung vornimmt, die sich aus der Genauigkeit der Klasse der jeweiligen Klassifikation ergibt und die so gewichteten Klassifikationen aufsummiert.

Ein *Gütemaß* dient zur Bewertung einer Klassifikation. Aufgrund einer Validierungskarte, in der manuelle Klassen eingetragen wurden, wird ein Klassifikationsergebnis getestet. Es wird überprüft, in welchen Gebieten die Klassen wiedererkannt und wo Fehlklassifikationen gemacht wurden. Daraus leiten sich die verwendeten Gütemaße ab.

Das Neuronale Netz, das ebenfalls zur Fusion genutzt wurde, ist dreischichtig und wurde mittels des *back-propagation* Algorithmus' trainiert. Es wurden ebenfalls Fuzzy-Klassifikationsergebnisse fusioniert. Zum Training bedarf es einer Validierungskarte. Mit dem neuronalen Netz ist es möglich, Klassifikationen mit unterschiedlicher Klassenanzahl zu fusionieren.

Eine Übersicht über weitere Fusionsmethoden kann man den Artikeln [Blo96, BS97] entnehmen. Die Verwendung von neuronalen Netzen zur Fusion von klassifizierten Daten, wie sie Hellmann et al. in [HJKH99] beschreiben, wird auch von Benediktsson et al. [BSE90] untersucht. Diese vergleichen die Verfahren zur Klassifikation mit neuronalen Netzen mit denen, die statistische Methoden, wie Maximum Likelihood, benutzen.

Weiterführende Literatur wird auch in den jeweiligen Kapiteln erwähnt.

1.3 Aufbau der Diplomarbeit

Die Diplomarbeit gliedert sich wie folgt:

Theorie. Zuerst werden die physikalischen Grundlagen der Fernerkundung beschrieben. Dann wird eine kurze Einführung in die Theorie der Fuzzy-Logik und der Neuronalen Netze gegeben. Abschließend wird die Theorie der Klassifikation und der Fusion erklärt.

Daten. In diesem Kapitel wird die Entstehung der multispektralen Luftbilder und der DAEDALUS Detektor beschrieben.

Klassenauswahl und Testgebiete. Die Klassenauswahl wurde unter der Prämisse gemacht, eine nutzerrelevante Klassifikation zu erhalten. Die Testgebiete entsprechen einer repräsentativen Auswahl städtischer Strukturen, die im Stadtgebiet Nürnberg zu finden sind. Zu den Testgebieten werden die Validierungskarten, die zur Bestimmung der Güte einer Klassifikation gebraucht werden, angegeben.

Klassifikation. Dieses Kapitel zeigt anhand der Testszene Andernacherstr. und der Gesamtszene die unterschiedlichen Klassifikationsergebnisse der einzelnen Verfahren. Es erfolgt eine erste Bewertung der Ergebnisse anhand der Kappa-Werte. Es wurde auch untersucht wie, sich die Klassifikationsgenauigkeit ändert, wenn man die Kanalanzahl reduziert. Die Reduktion bezieht sich auf die vier im IKONOS⁴ Satelliten verwendeten Kanäle, die mit DAEDALUS Kanälen übereinstimmen.

Bewertung der klassenspezifischen Gütemaße. Die Bewertung der Genauigkeit der Klassen, die in den Testgebieten erkannt wurden, wird in diesem Kapitel vorgenommen. Dazu werden die Gütemaße PAUA und FPAUA verwendet.

Zusammenfassung. In diesem Kapitel werden die Ergebnisse der Klassifikation und die aufgetretenen Probleme zusammengefaßt.

⁴Der IKONOS Satellit verfügt über vier Multispektralkanäle (blau, grün, rot und nahinfrarot) mit einer Bodenauflösung von 4 m und einen panchromatischen Kanal mit einer Bodenauflösung von 1 m. Der Sensor ist ein Zeilenarray, das eine 11 km breite Szene aufnehmen kann. Die Größe der Szene ergibt sich dann aus der Aufnahmedauer. Der Satellit wird von der Firma SpaceImaging, Inc. (www.spaceimaging.com) betrieben.

Ausblick. Es werden Ideen und Anregungen für neue Ansätze zur Klassifikation und für weitere Untersuchungen gegeben.

Anhang. Angabe der Tabellen, die als Grundlage der im Kapitel *Bewertung der klassenspezifischen Gütemaße* grafisch gezeigten Ergebnisse dienen.

2 Theoretische Grundlagen

2.1 Theorie der Fernerkundung

Die physikalischen Grundlagen der Erzeugung von digitalen multispektralen Luftbildern sollen im folgenden kurz dargestellt werden. Eine ausführlichere Darstellung findet sich u.a. in der Diplomarbeit von D. Kulbach [Kul97] und in Lehrbüchern [KS88, Ric99].

2.1.1 Fernerkundung

Fernerkundung bezeichnet das Arbeitsgebiet, in dem Daten über Objekte aus der Entfernung gewonnen werden. Das bedeutet im allgemeinen, daß Sensoren auf fliegenden Plattformen untergebracht sind, wie Satelliten oder Flugzeuge. Diese Sensoren registrieren Strahlung aus den unterschiedlichen Bereichen des elektromagnetischen Spektrums. Das können die reflektierte Sonnenstrahlung sein (passive Beleuchtung) oder reflektierte Radarwellen im cm-Bereich (aktive Beleuchtung).

Die vorliegenden Daten wurden von dem Zeilenscanner DAEDALUS AADS 1286 (nähere Beschreibung Kapitel 3.2) an Bord eines Flugzeuges der DLR aufgenommen. Es sind Daten, die durch passive Beleuchtung an einem wolkenarmen Sommertag entstanden sind. Sie überdecken den sichtbaren bis nahen infraroten Spektralbereich (420 nm bis 2500 nm). Weiterhin liegen auch Daten aus dem Wellenlängenbereich der Thermalstrahlung (10 μ m bis 13 μ m) vor. Bei den in folgendem gemachten Klassifikationen werden nur die ersten zehn Kanäle genutzt. Untersuchungen zu den aus Thermaldaten zu gewinnenden Informationen finden sich z.B. in [FPS99].

2.1.2 Multispektralbilder

Unter Multispektralbildern versteht man Bilder, die in verschiedenen Wellenlängenbereichen aufgenommen und in einem Datensatz gespeichert werden. Das Bild besteht aus Pixeln¹, die den Strahlungsfluß von einer korrespondierenden Fläche am Boden repräsentieren. Die Auflösung der Aufnahme ergibt sich aus der reellen Pixelgröße. Jedem Pixel wird ein Merkmalsvektor zugeordnet, dessen Werte die Intensität der detektierten Strahlung in den verschiedenen Wellenlängen darstellen. Im Falle des DAEDALUS AADS 1268 handelt es sich um digitalisierte Graustufenwerte (der Intensität) von 8 bit (entspricht

¹Pixel - picture elements

Werten von 0 bis 255). Die Aufnahmen mit den DAEDALUS Scanner ergeben einen elfkomponentigen Vektor, wovon für die weitere Untersuchung nur die ersten zehn Kanäle genutzt werden. Somit wird ein vereinfachtes Spektrum, das von einem Ort abgestrahlt wird, abgespeichert. Nähere Einzelheiten zum DAEDALUS Scanner finden sich im Kapitel 3.2. Um die Daten zu visualisieren, muß man sich entweder auf einen bestimmten Spektralbereich beschränken oder eine Datenfusion mehrerer Kanäle machen, wodurch ein RGB-Bild entsteht. Bei RGB Bildern werden drei Spektralkanäle dargestellt, denen die Farben Rot, Grün und Blau zugeordnet werden. Durch diese Farbmischung entstehen dann Farbbilder, die Farbfotos oder CIR ²-Fotos ähnlich sind.

2.1.3 Strahlung

Multispektralbilder setzen sich aus den unterschiedlichen Anteilen (Wellenlängenbereichen) der am Sensor nachgewiesenen Strahlung zusammen. Die spektrale Auflösung, d.h. die Genauigkeit, mit der die unterschiedlichen Anteile von einander getrennt werden können, hängt vom Detektor und der zu untersuchenden Wellenlänge ab. Bei der Aufnahme von passiv bestrahlten Luftbildern wird die spektrale Signatur der reflektierten Strahlung durch mehrere Faktoren beeinflusst.

- Spektrum der Sonnenstrahlung
- Zusammensetzung der Erdatmosphäre
- Reflektionsverhalten der bestrahlten Oberflächen
- Mechanismus der spektralen Aufspaltung im Detektor
- Andere Eigenschaften des Detektors

Sonnenstrahlung Die Sonnenstrahlung kann durch die Annahme modelliert werden, daß es sich bei der Sonne um einen *schwarzen Körper* handelt, dessen Strahlungsspektrum durch die *Planck'sche* Strahlungsfunktion beschrieben wird:

$$L_{\lambda}(T) = \frac{h \cdot c^2}{\lambda^5 \cdot (\exp(\frac{hc}{\lambda kT}) - 1)} \quad [\text{Wsr}^{-1}\text{m}^{-2}\mu\text{m}^{-1}] \quad (2.1)$$

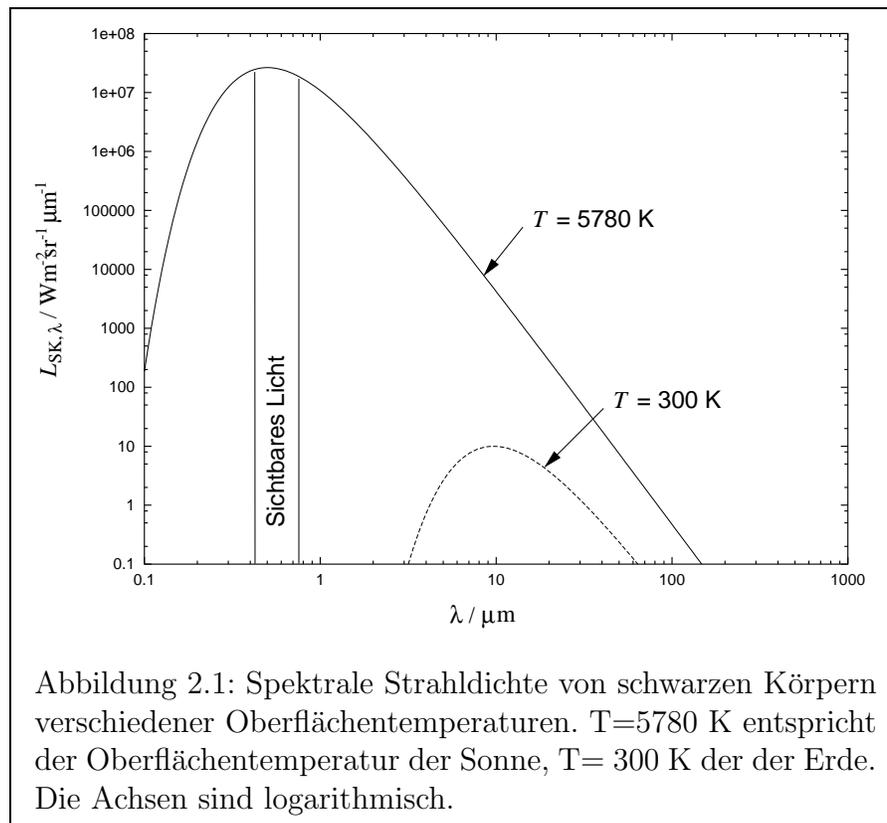
Aus der Messung des auf die Erdoberfläche einfallenden Intensitätsverlaufs der Sonnenstrahlung ergibt sich eine Oberflächentemperatur der Sonne von $T = 5780 \text{ K}$ ³. Damit

²Color Infra Red - Infrarot Falschfarben Aufnahme. Der Film ist auch im Infraroten stark empfindlich. Beim Entwickeln des Filmes werden die Infrarotanteile des Fotos rot dargestellt, die visuellen Bereiche verschieben sich entsprechend.

³folgt aus dem *Wien'schen* Verschiebungsgesetz, welches die Wellenlänge des Maximums der einfallenden Intensität λ_M mit der Temperatur T eines Schwarzkörpers korreliert:

$$\lambda_m T = 2,8978 \times 10^{-3} [mK] \quad (2.2)$$

kann man den Verlauf der spektralen Strahldichte der Einstrahlung angeben. Wie man anhand der Abbildung 2.1 erkennt, wird die meiste Strahlungsleistung im Bereich des sichtbaren Lichts eingestrahlt.



Mißt man das Sonnenspektrum außerhalb der Erdatmosphäre, ergibt sich eine etwas andere Verteilung, da die Sonne im Ultravioletten (UV) einige Wasserstoffabsorptionsbanden hat. Diese sind für den untersuchten Wellenlängenbereich nicht relevant. Dafür stellt man fest, daß die Sonne im Bereich des grünen Lichts (500 nm) stärker abstrahlt, als ein entsprechender Schwarzkörper.

Einfluß der Erdatmosphäre Die zweite Kurve in der Abbildung 2.1 beschreibt die Abstrahlung eines schwarzen Körpers der Temperatur $T = 300\text{ K}$, was in etwa der Oberflächentemperatur der Erde entspricht. Wie man sieht, liegt hier das Maximum im thermischen Infrarot. Die Sonnenstrahlung erreicht glücklicherweise nicht vollständig die Erdoberfläche, da sonst die UV Anteile sehr viel höher wären und damit das Leben auf der Erde so nicht möglich. Die Zusammensetzung der Atmosphäre beeinflusst die Sonneneinstrahlung erheblich. Dafür sind die Absorptionsbanden von Molekülen, H_2O , O_3 , CO_2 u.a. verantwortlich (s. Abb. 2.2). Hinzukommen verschiedene Streumechanismen, vor allem die *Rayleigh*- und *Mie*-Streuung (vgl. INFOBOX: *Streumechanismen in der Atmosphäre*).

Diese Streumechanismen führen dazu, daß man *Luftlicht* detektiert, das gar nicht mit den Objekten am Boden in Kontakt kam, und daß die Objekte nicht nur die einfallende Sonnenstrahlung reflektieren, sondern auch das gestreute (Himmels-)Licht. Diese atmosphärischen Einflüsse müssen für die Berechnung der Reflektanzbilder modelliert werden.

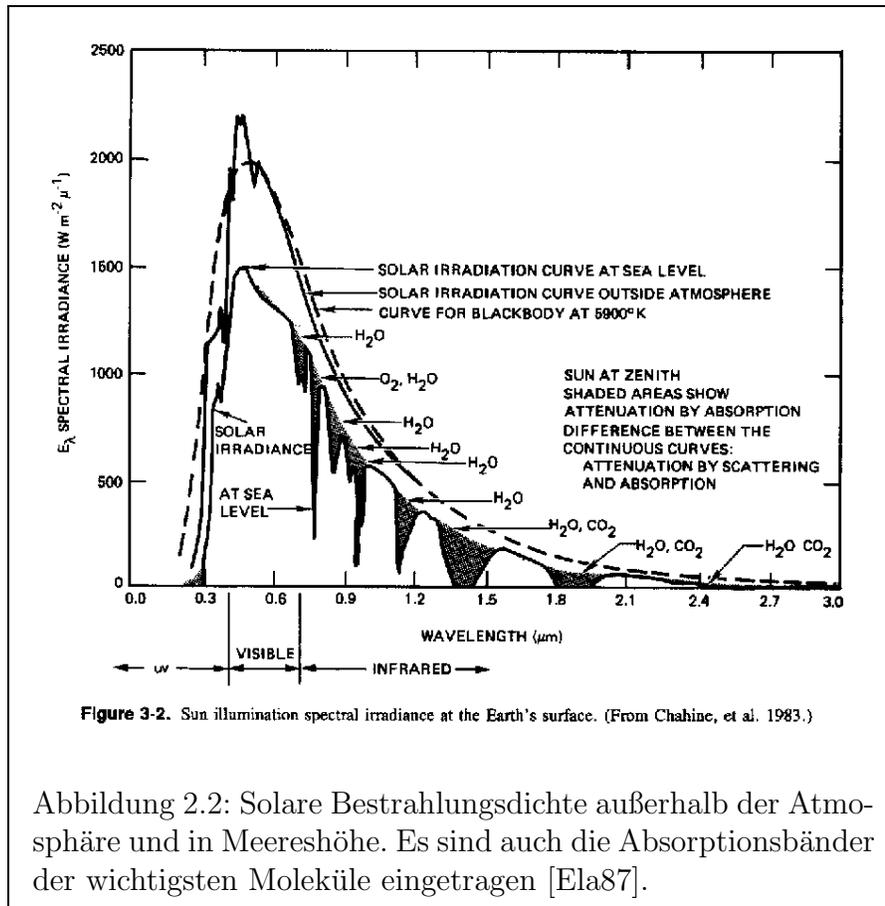
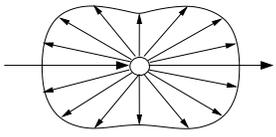
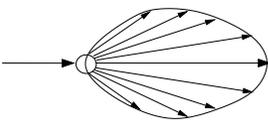


Abbildung 2.2: Solare Bestrahlungsdichte außerhalb der Atmosphäre und in Meereshöhe. Es sind auch die Absorptionsbänder der wichtigsten Moleküle eingetragen [Ela87].

INFOBOX:	Streumechanismen in der Atmosphäre
<p><i>Rayleigh</i>-Streuung:</p> 	<p>Die Wellenlänge der Strahlung λ ist viel größer als die Größe der Teilchen, an denen sich die Strahlung streut, wie z.B. Luftmoleküle. Die <i>Rayleigh</i>-Streuung ist stark wellenlängenabhängig. Der Wirkungsquerschnitt σ der Streuung ist umgekehrt proportional zur vierten Potenz der Wellenlänge λ, $\sigma \propto \lambda^{-4}$. Die Richtungsabhängigkeit der Streuung ergibt sich dadurch, daß die Strahlung die Elektronenhülle des Teilchens in eine Dipol-schwingung versetzt. Die <i>Rayleigh</i>-Streuung bedingt die blaue Farbe eines wolkenlosen Himmels [KS88, Ric99].</p>
<p><i>Mie</i>-Streuung:</p> 	<p>Die <i>Mie</i>-Streuung tritt ein, wenn die Wellenlänge der Strahlung ungefähr die gleiche Größenordnung hat, wie das Teilchen, an dem die Streuung geschieht. Das heißt, daß für die <i>Mie</i>-Streuung Aerosole und Staubteilchen verantwortlich sind. Die Streuung erfolgt hauptsächlich in Ausbreitungsrichtung und der Wirkungsquerschnitt σ ist umgekehrt proportional zur Wellenlänge λ $\sigma \propto \lambda^{-1}$.</p>

Reflektion an Oberflächen Die Reflektion einer Oberfläche setzt sich aus mehreren Anteilen zusammen. Zum einem die *diffuse* Streuung der Strahlung, welche im allgemeinen durch die Annahme eines *Lambert'schen* Strahlers beschrieben wird. Dessen Abstrahlungsverhalten ist proportional zum Einfallswinkel Θ_i der Beleuchtungsquelle und unabhängig vom Beobachtungswinkel: $\Phi_R \propto \cos(\Theta_i)$. Bei konstanter Einstrahlung nimmt die Einstrahllichte pro Einheitsfläche des Reflektors mit $\cos(\Theta_i)$ ab.

Diese Annahme trifft auf rauhe Oberflächen⁴ zu. Kraus und Schneider sprechen in [KS88] "Volumsstreuung", die sie durch Mehrfachreflektionen an der rauhen Oberfläche erklären. Für glatte Oberflächen gelten die Bedingungen der *gerichteten* Reflektion, wie man an spiegelnden Oberflächen sieht. In der Realität treten beide Formen der Reflektion auf. Um dieses von der Beleuchtungsgeometrie abhängige Abstrahlverhalten besser zu beschreiben, benutzt man die bidirektionale Reflektionsfunktion (BRDF) eines Oberflächenmaterials. Die BRDF ist im allgemeinen nicht bekannt und muß für jedes Material durch Messungen bestimmt werden. Die BRDF ausgewählter, städtischer Oberflächen, wurde in den Diplomarbeiten von [Mei96, Rot97] und in der Doktorarbeit von [Mei00] näher untersucht.

⁴In [KS88] wird das *Rayleigh*-Kriterium zur Beschreibung von rauhen Oberflächen angegeben:

"Eine Oberfläche ist für eine Strahlung der Wellenlänge λ glatt, die unter einem Winkel Θ zwischen Flächennormale und Strahlrichtung einfällt, wenn $h < \frac{\lambda}{8 \cos(\Theta)}$, wobei h die Standardabweichung der Oberflächenunebenheiten ist."

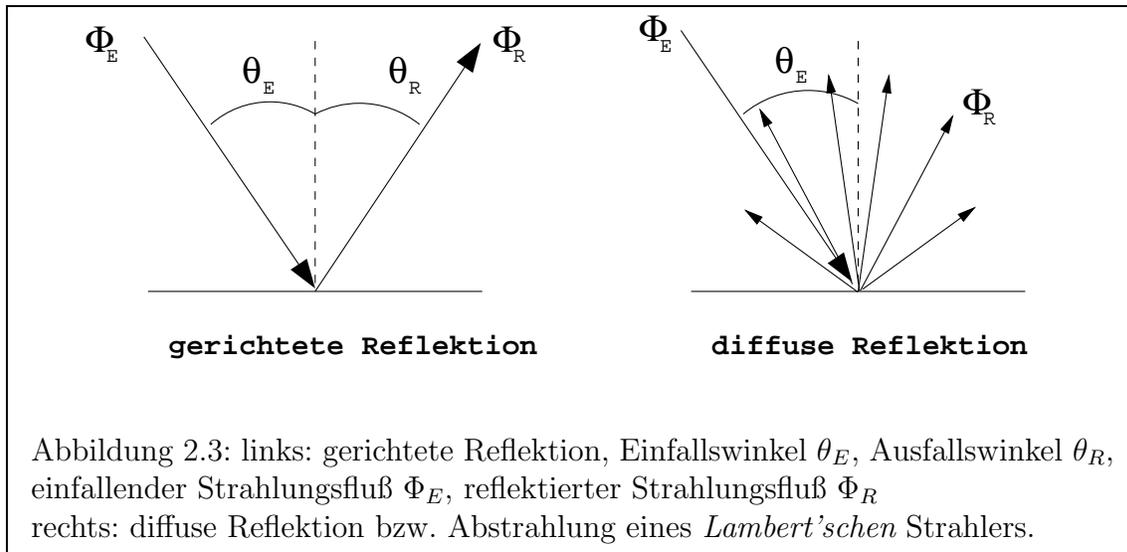
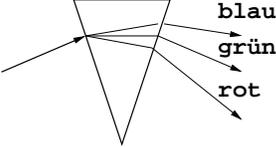
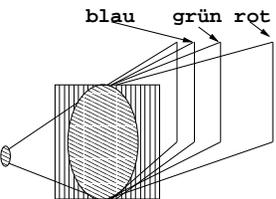


Abbildung 2.3: links: gerichtete Reflexion, Einfallswinkel θ_E , Ausfallswinkel θ_R , einfallender Strahlungsfluß Φ_E , reflektierter Strahlungsfluß Φ_R
rechts: diffuse Reflexion bzw. Abstrahlung eines *Lambert'schen* Strahlers.

Ein weiterer Anteil der Strahlung von Oberflächen ist durch die Emission gegeben. Die Emission ist wiederum durch die *Planck'sche* Strahlungsfunktion, sowie durch die *Kirchhoff'schen* Gesetze und Materialeigenschaften bestimmt. Um die *Planck'sche* Strahlungsfunktion benutzen zu können, muß man wieder die Annahme einer rauhen Oberfläche machen. Die *Kirchhoff'schen* Gesetze besagen einfach ausgedrückt, daß die Strahlung, die ein Körper absorbiert, auch wieder abgestrahlt werden muß, d.h. die Summe aus Reflektions-, Absorptions- und Transmissionskoeffizienten ist eins, $\rho + \alpha + \tau = 1$. Daraus ergibt sich, daß die spektrale Emissivität gleich der spektralen Absorption ist. Die Materialeigenschaften können die Emissivität dadurch beeinflussen, daß sie Absorptions- und Emissionslinien erzeugen.

Spektralanalyse Um einzelne Bereiche des elektromagnetischen Spektrums aufnehmen zu können, muß die Strahlung in unterschiedliche Wellenlängen aufgespalten werden. Dies kann mittels Gitter oder Prismen geschehen. Beim DAEDALUS AADS 1268 Detektor sorgt ein Prisma für die Aufspaltung des visuellen und nahinfraroten Anteils (s. Abb. 3.2). Der Detektor registriert die einfallende Strahlung mittels Fotodioden, die eine materialspezifische Empfindlichkeit haben (Tabelle 3.1), die bei der Berechnung der Reflektanzbilder berücksichtigt werden muß. Zu dem kann jeder Kanal noch einzeln kalibriert werden (3.2.2), um ein optimales Signal zu erhalten. Diese Kalibrierungsdaten müssen für die Erzeugung von Reflektanzbildern bekannt sein. Für den ferneren Infrarotbereich werden andere Aufspaltungstechniken (Dichroitische Filter) benutzt (vgl. INFO-BOX: *Funktionsweise optischer Bauteile zur Spektralzerlegung*).

INFOBOX:	Funktionsweise optischer Bauteile zur Spektralzerlegung
<p>Prisma:</p> 	<p>Durch die Wellenlängenabhängigkeit des Brechungsindex von Glas (Dispersion) für elektromagnetische Strahlung erreicht man eine Aufspaltung des Spektrums in unterschiedliche Wellenlängen. Blaues Licht wird weniger stark gebrochen als rotes Licht, so daß man wellenlängensensitiv die Intensität der Strahlung messen kann. Dies funktioniert nur in Wellenlängenbereichen, in denen Glas für elektromagnetische Wellen durchlässig ist. Also für sichtbares bis nahinfrarotes Licht.</p>
<p>Gitter:</p> 	<p>Eine andere Möglichkeit ist die Aufspaltung mittels eines Gitters. Die einzelnen Spalte des Gitters beugen das einfallende Licht, das zudem noch mit sich selbst interferiert. Das Hauptmaximum einer Wellenlänge λ befindet sich unter dem Winkel Θ, es gilt $\sin(\Theta) = \frac{n\lambda}{a}$, wobei n die Ordnung der Beugung ist, a der Abstand der Gitterlinien. Moduliert wird die Beugungsfigur durch die Interferenzen, die durch die schmalen Gitterlinien entstehen, mit $\sin(\Theta) = \frac{n\lambda}{b}$, wobei b die Linienbreite ist. Je höher die Dichte der Linien eines Gitters ist, um so besser ist die spektrale Auflösung $R = \frac{\lambda}{\Delta\lambda} = Nn$, N ist die Anzahl der Linien auf dem Gitter.</p>
<p>Dichroitische Filter:</p>	<p>Halbdurchlässige Spiegel, die nur bestimmte Wellenlängen reflektieren. Dichroitische Filter dienen dazu den, thermalen Anteil der Strahlung vom optischen und nahinfraroten zu trennen.</p>

2.1.4 Reflektanzbilder

Multispektralbilder geben die durch Reflexion, Emission und atmosphärische Streuung am Sensor registrierte Intensität wieder. Um zu vergleichbaren Aussagen zu kommen, müssen diese Intensitäten auf die Einstrahlung normiert werden und der Betrag des Luftlichtes muß subtrahiert werden. Die Zusammensetzung der einfallenden Strahlung muß bekannt sein, um den strahlungsunabhängigen Parameter Reflektanz zu berechnen.

$$\rho(\lambda) = \frac{\Phi_R}{\Phi_E} \quad [1] \quad (2.3)$$

Φ_R ist die spezifische Abstrahlung und Φ_E die einfallende Strahlung.

Die spezifische Abstrahlung wird i.a. durch die Annahme eines *Lambert'schen Strahlers* angenähert. Die einfallende Strahlung wird durch das MODTRAN und LOWTRAN Atmosphärenmodell beschrieben, das in [AKC⁺95] erklärt wird. Um die Reflektanzen zu

berechnen, sind Kalibrations- und Modellparametermessung nötig. Für die Klassifizierung von multispektralen Luftbildern ist die Berechnung von Reflektanzen und die Korrektur der Abbildungsverzerrung (s. Kapitel 3.2) nicht nötig, solange man nicht

- Vergleiche zwischen verschiedenen Aufnahmen (Änderungsdetektion, engl. *change detection*)
- Vergleiche mit anderen Karten
- Aussagen über Orte und Größe von Objekten
- Klassifikation mit Standardspektren

machen möchte.

Eine andere Möglichkeit die Daten zu normieren, ist die Messung von Vergleichsspektren mittels eines am Boden befindlichen Spektrometers.

2.2 Theorie der Fuzzy-Logik

Der Schwerpunkt dieser Diplomarbeit liegt auf der Anwendung von Fuzzy-Methoden zur Klassifizierung. Im folgendem Kapitel wird ein Einblick in die Theorie der Fuzzy-Logik und ihrer Anwendung im Bereich der Klassifikation gegeben. Der Bereich der Regeltechnik mit Fuzzy-Logik, der eine große industrielle Verbreitung erreicht hat, wird nicht betrachtet.

2.2.1 Einführung

Die Fuzzy-Logik ist eine Erweiterung der zwei-wertigen Mengenlehre auf unscharfe Mengen. Die erste theoretische Abhandlung zur Fuzzy-Logik stammt von Zadeh⁵ aus dem Jahre 1965 [Zad65]. Die Idee, nicht nur zwei-wertige Wahrheitswerte zu erlauben, stammt aus den zwanziger Jahren von Jan Lukasiewicz, der zunächst den zusätzlichen Wahrheitswert 0.5 einführte und dies auf eine kontinuierliche Skala ausdehnte⁶. Fuzzy-Logik ist der Versuch, menschliche Beschreibung mathematisch zu erfassen. Bei der Wahrnehmung seiner Umwelt nimmt der Mensch ständig Klassifizierungen vor. Doch benutzt er dazu nicht immer direkte Maßeinheiten, sondern bedient sich häufig Beschreibungen, die situationsgebunden sind. In einer Menge von Kindern ist eine erwachsene Person groß, unter anderen Erwachsenen ist diese Person vielleicht klein. Die Entscheidung hängt nicht von bestimmten festen Grenzen ab und ist zudem noch vom Kontext abhängig. In der Fuzzy-Logik versucht man Sätze, wie “rote Tomaten sind reif”, zu formalisieren, in dem man eine Fuzzy-Menge “reif” definiert, die von der Farbe der Tomate abhängt. “Reif” wird dabei als linguistische Variable bezeichnet. Logische Aussagen können dadurch so formuliert werden, daß sie unseren alltäglichen Erfahrungen entsprechen (nach [Drö94]).

Die Möglichkeit mit linguistischen Variablen, wie den linguistischen Werten “reif” oder “schnell” oder den linguistischen Modifikatoren “ziemlich” oder “wenig” rechnen zu können, hat eine Reihe von einfachen Systemen möglich gemacht, die vollständig beschrieben nur schwer oder gar nicht lösbar sind.

2.2.2 Zugehörigkeitsfunktion

In der Fuzzy-Mengenlehre betrachtet man meist ein Universum X , das im weiteren als fest vorgegeben angenommen wird. In diesem Universum X kann eine scharfe, klassische (engl. *crisp*) Teilmenge A aus X über eine charakteristische Funktion $u_A(x)$, $x \in X$ beschrieben werden. Die Funktion u_A weist jedem Element x , das zur Menge A gehört, den Wert 1 zu, allen anderen 0. Eine unscharfe Menge ist die Verallgemeinerung der charakteristischen Funktion, in dem man die Abbildung $u : X \rightarrow [0, 1]$ betrachtet und den Wert von $u_A(x)$ für ein festes $x \in X$ als den “Grad der Zugehörigkeit” von x zu A interpretiert.

⁵Professor Lofti A. Zadeh hat am 26.06.2000 vom FB Informatik der Universität Hamburg die Ehrendoktorwürde verliehen bekommen. Er gilt als Vater der *Fuzzy Set Theory*.

⁶Die Logik, die Lukasiewicz definierte, führt zu einer etwas seltsamen Aussage: $W(A \cup A) = \min(W(A) + W(A), 1)$ oder “es regnet, oder es regnet” hat einen anderen Wahrheitswert als “es regnet” [Drö94].

Rote Tomaten sind reif.
 Diese Tomate ist ziemlich rot.
 Also ist die Tomate ziemlich reif.

Rote Tomaten sind reif.
 Grüne Tomaten sind unreif.
 Diese Tomate ist gelb.
 Also ist sie etwa halbreif.

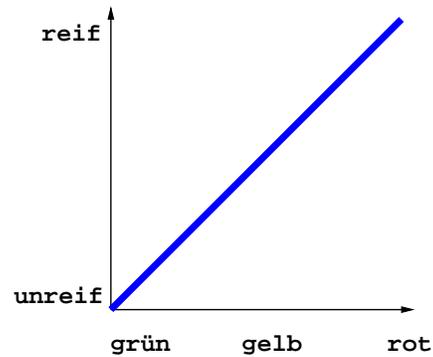


Abbildung 2.4: Dieses Beispiel aus [Drö94] zeigt einfache alltägliche “fuzzy-logische” Schlüsse und ihre fuzzy-methodische Umsetzung.
 Die Kurve rechts zeigt den Zusammenhang zwischen Farbe der Tomate und ihrem Reife-grad.

Die Funktion, die den Elementen einer Menge bestimmte Zugehörigkeiten zuordnet, wird Zugehörigkeitsfunktion genannt (engl. *membership function*). Diese Funktion kann durch Expertenwissen vorgegeben werden oder durch bestimmte Vorgaben aus den Daten selbst erzeugt werden. Die letztere Methode wird bei der Klassifikation angewandt. Bei der Verknüpfung mehrerer Fuzzy-Mengen werden Vereinigung, Durchschnitt und andere Operationen meist über t-Normen etc. interpretiert (s.u. 2.2.3).

Beispiele charakteristischer Funktionen *crisp* und *fuzzy*:

Charakteristische Funktion für Elemente $x \in X$ die zur Menge A gehören
 (*crisp*)

$$u_A : X \rightarrow \{0, 1\}$$

$$u_A(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \end{cases} \quad (2.4)$$

Zugehörigkeitsfunktion für reelle Zahlen sehr viel größer als Null (*fuzzy*)

$$u_A : X \rightarrow [0, 1]$$

$$u(x) = \begin{cases} \frac{x^2}{x^2+1}, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.5)$$

Für den Gebrauch von Fuzzy-Systemen sind zudem Vorschriften zur “Fuzzifizierung” der Eingangsdaten (charakteristische Funktion) und “Defuzzifizierung”, die Umrechnung von Fuzzy-Werten in “brauchbare” Werte, wie z.B. Klassen, notwendig. Die Fuzzy-Werte können allerdings als eine Aussage über die Ähnlichkeit einer Zuordnung zu einem Proto-

typen benutzt werden, weshalb diese Werte bei den Untersuchungen als *possibility maps* mit abgespeichert werden.

Bei den verwendeten Fuzzy-Klassifikationsverfahren handelt es sich um Erweiterungen herkömmlicher Klassifikationsverfahren. Diese nehmen eine “harte” Zuordnung von Elementen x zu bestimmten Klassen i vor, d.h. die Zugehörigkeit $u_i(x)$ ist für eine Klasse i gleich eins, $u_i(x) = 1$ und für alle anderen Klassen j mit $j \neq i$ gleich null, $u_{j \neq i}(x) = 0$. Bei Fuzzy-Klassifikationsverfahren wird eine “weiche” oder fuzzy Zuordnung $u_i(x)$ vorgenommen, $u_i(x)$ ist die Zugehörigkeit von x zur Klasse i . Dabei gilt, daß jedes Element x zu jeder Klasse i eine Zugehörigkeit $u_i(x)$ hat. Es gibt dabei verschiedene Möglichkeiten eine Fuzzifizierung durchzuführen. Es lassen sich zunächst zwei grundsätzlich Eigenschaften einer Fuzzifizierung angeben:

- a) probabilistisch, d.h. die Summe der Fuzzy-Werte eines Elements ist 1, $\sum_i u_i = 1$. Das entspricht einer Wahrscheinlichkeitsaussage (*probability*).
- b) possibilistisch, d.h. jedes Element x erhält eine Zugehörigkeit u_i größer Null und die Summe der u_i ist größer gleich Null, $\sum_i u_i \geq 0$. Die Zuordnung stellt die Möglichkeit dar, daß ein Element x zur Klasse i gehört.

Im weiteren wird die probabilistische Einteilung verwendet.

INFOBOX:	Zugehörigkeit vs. Wahrscheinlichkeit
<p>Der Wanderer in der Wüste</p> <p>Ein durstiger Wanderer findet in der Wüste eine Flasche mit einer unbekanntem Flüssigkeit. Welche Aussage hilft ihm mehr?</p> <ol style="list-style-type: none"> 1. Die Flüssigkeit ist mit einer Wahrscheinlichkeit von 99% trinkbar. 2. Die Flüssigkeit gehört zum Grad 0,99 zur Menge der trinkbaren Flüssigkeiten. <p>Die zweite Aussage ist hilfreicher, da eine ungenießbare Flüssigkeit eine Zugehörigkeit von 0 zu der Menge der trinkbaren Flüssigkeiten hat. Im ersten Fall besteht immer noch die Möglichkeit, daß es sich um Salzsäure handelt, wenn auch nur in einem von hundert Fällen.</p>	

2.2.3 Mengenoperationen

Um mit Hilfe der Fuzzy-Logik zu Ergebnissen zu kommen, braucht man Mengenoperationen, die Fuzzy-Mengen mit einander verknüpfen. Dabei kann man sich zwar an den

Verknüpfungen der klassischen Mengenlehre orientieren, stößt aber sofort auf Probleme, da man es nun nicht mehr mit scharfen Grenzen zu tun hat. Die Negation von “sehr schnell” ist nicht zwangsläufig “sehr langsam”. Die Mengenoperationen der Fuzzy-Logik lassen sich in z.B. zwei Klassen einteilen, die Klasse der t-Norm Operatoren (entspricht einer AND Verknüpfung oder Durchschnittsoperation) und der t-Konorm Operatoren ⁷ (entspricht einer OR Verknüpfung oder Vereinigungsoperation) [Bot98, Zim91]. Oftmals erweisen sich auch Mittelungsoperatoren als nützlich. Für die einfachen Rechenoperationen, die man mit Fuzzy-Mengen ausführt, lassen sich folgende Anweisungen zwischen zwei Fuzzy-Mengen A und B aus einer Menge X angeben.

AND oder Durchschnittsoperatoren, z.B.:

$$\text{Minimum:} \quad u_{A \cap B}(x) = \min [u_A(x), u_B(x)] \quad x \in X \quad (2.6)$$

$$\text{Algebraisches Produkt:} \quad u_{A \cdot B}(x) = u_A(x) \cdot u_B(x) \quad x \in X \quad (2.7)$$

OR oder Vereinigungsoperatoren, z.B.:

$$\text{Maximum:} \quad u_{A \cup B}(x) = \max [u_A(x), u_B(x)] \quad x \in X \quad (2.8)$$

$$\text{Algebraische Summe:} \quad u_{A+B}(x) = u_A(x) + u_B(x) - u_A(x) \cdot u_B(x) \quad x \in X \quad (2.9)$$

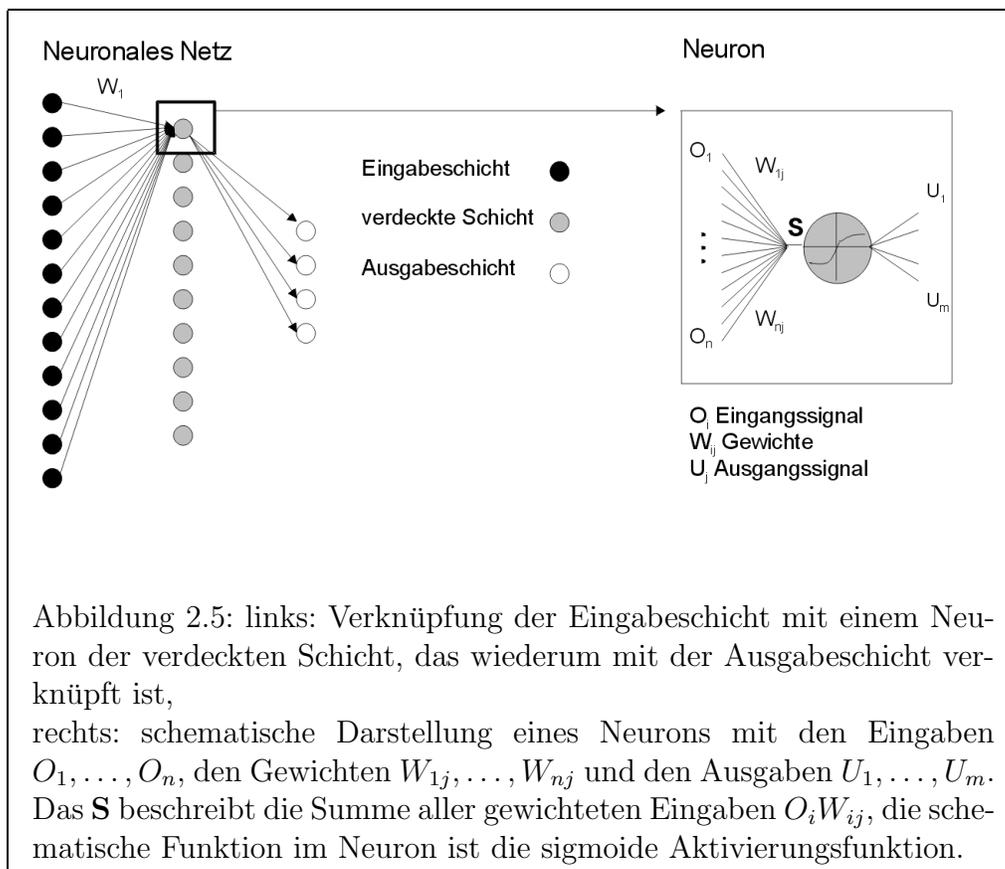
Diese einfachen Operationen sind ausreichend, um die relevanten Fuzzy-Gütemaße berechnen zu können.

⁷Die t(riangular)-Norm bzw. t-Konorm (oder s-Norm) sind zweistellige Funktionen $t : [0, 1] \times [0, 1] \rightarrow [0, 1]$ bzw. $s : [0, 1] \times [0, 1] \rightarrow [0, 1]$ die folgende Bedingung erfüllen (aus [Bot98]):

1. $t(0, 0) = 0$ und $t(1, \mu_A) = t(\mu_A, 1) = \mu_A$ bzw.
 $s(1, 1) = 1$ und $s(0, \mu_A) = t(\mu_A, 0) = \mu_A$
2. $t(\mu_A, \mu_B) \leq t(\mu_C, \mu_D) \forall \mu_A \leq \mu_C, \mu_B \leq \mu_D$ bzw.
 $s(\mu_A, \mu_B) \leq s(\mu_C, \mu_D) \forall \mu_A \leq \mu_C, \mu_B \leq \mu_D$
3. Kommutativität: $t(\mu_A, \mu_B) = t(\mu_B, \mu_A)$ bzw.
 $s(\mu_A, \mu_B) = s(\mu_B, \mu_A)$
4. Assoziativität: $t(\mu_A, t(\mu_B, \mu_C)) = t(t(\mu_A, \mu_B), \mu_C)$ bzw.
 $s(\mu_A, s(\mu_B, \mu_C)) = s(s(\mu_A, \mu_B), \mu_C)$

2.3 Theorie der Neuronalen Netze

Dies ist eine kurze Einführung in die Theorie der künstlichen neuronalen Netze, um eine Grundlage für das zweite Fusionsverfahren, das zur Klassifikation der Daten benutzt wurde, zu schaffen. Künstliche neuronale Netze (im weiteren nur neuronale Netze oder NN) sind entwickelt worden, um die Verarbeitung von Signalen im Gehirn besser verstehen zu lernen und diese zu simulieren. Neuronale Netze werden meist dort eingesetzt, wo eine Modellierung aufgrund eines physikalischen Modells nicht oder nur schwer möglich ist. Ein neuronales Netz besteht aus künstlichen Neuronen, die miteinander verknüpft sind. Bei der Art der Verknüpfung hat man sich am biologischen Beispiel orientiert.



Jedes künstliche Neuron (im weiteren nur Neuron) hat eine bestimmte Anzahl von Ein- und Ausgängen, die alle verschieden gewichtet werden können. Diese Gewichtungen sind durch Matrizen darstellbar. Im Neuron selbst wird nur dann ein Signal ausgelöst, wenn durch die Eingänge eine bestimmte "Aktivierungsenergie" hinein kommt, wobei diese "Aktivierungsenergie" entweder als Summe über alle gewichteten Eingänge oder über das Maximum der Eingänge berechnet wird. Diese Neuronen werden in Netzen zusammengeschaltet. Bei dem in dieser Arbeit getesteten neuronalem Netz handelt es sich

um ein Netz mit *feedforward* Struktur, d.h. jedes Neuron wirkt nur in eine Richtung. Es gibt keine Rückkopplungen.

Das Verhalten eines neuronalen Netzes bei einer Mustererkennung muß trainiert werden, indem man dem Netz Trainingsdaten präsentiert und die Gewichtung so einstellt, daß die Trainingsdaten die vorgegebenen Muster (Klassen) gut wiedergeben.

Einfache neuronale Netze arbeiten mit einer Eingabeschicht (*input layer*), einer verdeckten Schicht (*hidden layer*) und einer Ausgabeschicht (*output layer*). Jedes Neuron in der Eingabeschicht ist mit jedem Neuron in der verdeckten Schicht verbunden, die Neuronen der verdeckten Schicht sind wiederum alle mit den Neuronen der Ausgabeschicht verbunden. Gesucht sind nun Gewichtsmatrizen, die eine optimale Abbildung bestimmter Eingabemuster auf die gewünschten Ausgabemuster gewährleisten. Ein häufig benutztes Verfahren für dieses Training, ist das *backpropagation* Training, bei dem mittels eines Gradientenabstiegsverfahrens in der Fehlerfunktion ein minimaler Fehler gesucht wird.

Weitere Beschreibungen neuronaler Netze können unter anderem in [Bot98, Zel94] gefunden werden. Die folgenden Erklärungen sind ebenfalls diesen Büchern entnommen.

2.3.1 Künstliches Neuron

Ein künstliches Neuron hat folgende Bestandteile:

- Aktivierungszustand: beschreibt die Erregung des Neurons
- Aktivierungsfunktion: beschreibt die Veränderung des Aktivierungszustandes in Abhängigkeit von den Eingaben und des alten Aktivierungszustandes
- Ausgabefunktion: beschreibt die Ausgabe eines Neurons in Abhängigkeit vom Aktivierungszustand

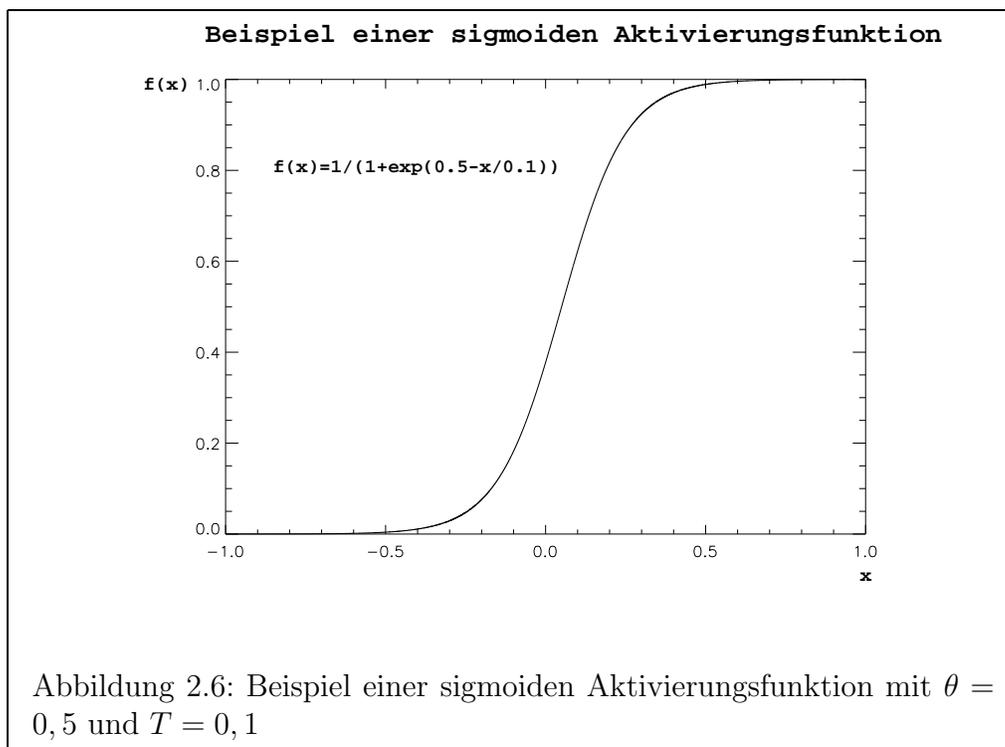
Diese Bestandteile lassen sich meist in Form einer einzigen Funktion, die dann wieder Aktivierungsfunktion genannt wird, zusammenfassen. Um das Lernen durch ein Gradientenabstiegsverfahren zu ermöglichen, muß diese Funktion differenzierbar sein, aber auch möglichst gut einen Sprung zwischen aktiv und inaktiv simulieren. Dazu werden häufig sigmoide (s-förmig) Funktionen, wie die logistische Aktivierungsfunktion (s. Abb. 2.6)

$$f_{log}(x) = \frac{1}{1 + \exp(\theta - x/T)} \quad (2.10)$$

benutzt, die um einen Schwellwert θ , der den Aktivierungsgrad angibt, ab dem das Neuron aktiviert ist, punktsymmetrisch ist. Eine Skalierung dieser Funktion ist mittels eines Temperaturparameters T möglich.

2.3.2 Verdeckte Schicht

Die verdeckte Schicht (engl. *hidden layer*) in einem neuronalen Netz dient nur der Informationsverarbeitung innerhalb des Netzes. Die Anzahl der verdeckten Schichten und die



Anzahl der Neuronen in diesen Schichten beeinflusst die Flexibilität des Netzes. Zu große Flexibilität kann dazu führen, daß ein Netz zu speziell arbeitet und die Erkennung von Mustern dadurch an Robustheit verliert, d.h. z.B. auf Rauschen empfindlich reagiert.

Die verdeckte Schicht i ist über Gewichtsmatrizen w_{ij} mit der Schicht j vor ihr und über w_{ip} mit der Schicht p hinter ihr verbunden. Hat man nur eine verdeckte Schicht, sollte die Anzahl der Neuronen in der verdeckten Schicht zwischen der jeweiligen Anzahl in der Eingabe- und Ausgabeschicht liegen. Es hat sich als sinnvoll erweisen, die Anzahl der *hidden neurons* auf

$$N_{hidden} = (2N_{input} + N_{output})/3 \quad (2.11)$$

zu setzen.

2.3.3 Der *backpropagation* Algorithmus

Der *backpropagation* Algorithmus ist ein Lernverfahren, das auf einem Gradientenabstiegsverfahren beruht. Es wird der Fehler E der Gewichtsmatrizen $W = (w_1, \dots, w_n)$ bei einer gegebenen Trainingsmenge $T = (t_{11}, \dots, t_{jn})$ berechnet und minimiert, indem man den steilsten Abstieg innerhalb dieser Fehlerfläche sucht. Die Gewichte w_1, \dots, w_n sind dabei über alle Trainingsmuster p aufsummiert, $w_i = \sum_{j=1}^p w_{ij}$. Die Fehlerfunktion $E(W) = E(w_1, \dots, w_n)$ mit den Gewichten $W = (w_1, \dots, w_n)$ zu den Trainingsmustern wird meist über den quadratischen Abstand zwischen einer Trainingseingabe oder Aus-

gabe einer Neuronenschicht o_{pj} und Referenzeingabe t_{pj} bestimmt

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2. \quad (2.12)$$

Es gibt noch weitere Möglichkeiten, eine Fehlerfunktion wie in Gleichung 2.12 zu definieren. In [Bis95] wird die “*Cross-Entropy*“ im Bereich der Klassifikation als am besten geeignet angenommen. Die Änderung der Gewichtsmatrizen wird proportional zum Gradienten $\nabla E = \frac{\partial E(W)}{\partial w_{ij}}$ der Fehlerfunktion vorgenommen

$$\Delta W = -\eta \nabla E(W), \quad (2.13)$$

wobei η ein Lernfaktor ist, der die Schrittweite der Änderung bestimmt. Hierbei muß man darauf achten, daß η weder zu groß gewählt wird, wodurch man über Minima in der Fehlerfläche hinwegspringt, noch zu klein, da der Algorithmus sonst sehr langsam konvergiert.

Für eine semilineare Aktivierungsfunktion f_{act} läßt sich dann ein einfacher Lernalgorithmus realisieren, der *backpropagation* Algorithmus. Wie der Name *backpropagation* schon andeutet, wird bei diesem Lernverfahren das Netz von hinten (*back*) nach vorne durchlaufen (*propagation*).

Die Fehlerfunktion wird dadurch optimiert, daß man die Gewichtsmatrizen w_{ij} verändert. An jeder Zelle j ist die Netzeingabe net_{pj} eines Musters p durch

$$net_{pj} = \sum_i o_{pi} w_{ij} \quad (2.14)$$

gegeben. Die Ausgabe (engl. *output*) der Zelle j ist dann

$$o_j = f_{act}(net_{pj}). \quad (2.15)$$

Der Fehler $E(W)$ und die daraus resultierende Änderung der Gewichte ΔW ergibt sich mit Gleichung 2.13 zu:

$$\Delta W = -\eta \nabla E(W) \quad (2.16)$$

$$\Delta w_{ij} = -\eta \frac{\partial E(W)}{\partial w_{ij}} \quad (2.17)$$

$$= \sum_p -\eta \frac{\partial E_p}{\partial w_{ij}} \quad (2.18)$$

$$\frac{\partial E(W)}{\partial w_{ij}} = \frac{\partial E_p}{\partial net_{pj}} \cdot \frac{\partial net_{pj}}{\partial w_{ij}}. \quad (2.19)$$

$$(2.20)$$

Mit Gleichung 2.14 ergibt sich für den zweiten Term

$$\frac{\partial net_{pj}}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_i o_{pi} w_{ij} = o_{pi}. \quad (2.21)$$

Der erste Term der Gleichung 2.16 läßt sich als ein Fehlersignal δ_{pj} definieren

$$\delta_{pj} = -\frac{\partial E_p}{\partial w_{ij}}. \quad (2.22)$$

Dieses Fehlersignal δ_{pj} ergibt zusammen mit dem Lernfaktor η und der Eingabe die Änderung der Werte der Gewichtsmatrizen:

$$\Delta_p w_{ij} = \eta o_{ij} \delta_{ij} \quad (2.23)$$

Die Fehlerfunktion der Ausgabeschicht läßt sich einfach aus der Ableitung der Fehlerfunktion berechnen. Die Ableitung an dieser Stelle ist die Differenz zwischen erwarteter Eingabe o_{pj} und Trainingseingabe t_{pj}

$$\delta_{pj} = -\frac{\partial E_p}{\partial o_{pj}} = (t_{pj} - o_{pj}). \quad (2.24)$$

Bei einer verdeckten Schicht kommt hinzu, daß man über alle gewichteten Fehler der Nachfolgezellen summieren muß

$$\delta_{pj} = f'_{act}(net_{pj}) \sum_k \delta_{pk} w_{jk}, \quad (2.25)$$

wobei f'_{act} ist die Ableitung der Aktivierungsfunktion. Mit dem Fehlersignal δ_{pf} werden die Gewichtsmatrizen neu berechnet (Gl. 2.23). Für die logistische Aktivierungsfunktion ergibt sich in der *online*-Version des *backpropagation*-Algorithmus', d.h. daß nach der Präsentation jedes Trainingsamples die Gewichtsmatrizen angepaßt werden, folgende Form des Fehlersignals:

$$\delta_{ij} = \left\{ \begin{array}{ll} o_{ij}(1 - o_{ij})(t_{pj} - o_{pj}) & \text{falls } j \text{ Ausgabezelle ist} \\ o_{ij}(1 - o_{ij}) \sum_k \delta_{pk} w_{jk} & \text{falls } j \text{ verdeckte Zelle ist} \end{array} \right\} \quad (2.26)$$

2.4 Theorie der Klassifikation

Unter Klassifikation versteht man die Zusammenfassung von Objekten mit gemeinsamen Merkmalen. Diese Merkmale werden durch Messungen von Eigenschaften der Objekte quantitativ erfaßt. Diese Meßwerte können in einem Merkmalsraum dargestellt werden, der als Koordinaten die unterschiedlichen Merkmalswerte hat. Eine Klassifikation läßt sich mathematisch als Häufung von Objekten, die einen Cluster oder eine Klasse bilden, in diesem Merkmalsraum beschreiben (vgl. INFOBOX: *Ortsraum vs. Merkmalsraum*). Die Zuordnung einzelner Objekte zu Klassen im Merkmalsraum geschieht aufgrund von statistischen Methoden, die auf den schottischen Pfarrer *Bayes* zurückgehen (Kapitel 2.4.1.1). Im Fall von Multispektralbildern sind die Merkmale die Pulshöhen einzelner Spektralkanäle, und die Klassen sind *typische* mittlere Spektren. Diese werden durch einen mittleren Merkmalsvektor und eine Kovarianzmatrix beschrieben, welche die Streuung und Korrelation der Kanäle wiedergibt. Es können auch andere Merkmale als Grundlage zur Clusterbildung dienen, wie z.B. der räumliche Zusammenhang (Kreise) oder die Textur einer Fläche (im Ortsraum).

Im folgendem werden die Grundlagen der verwendeten Verfahren vorgestellt. Dabei wird zwischen klassischen Verfahren und den Verfahren, die mit Fuzzy-Methoden arbeiten, unterschieden.

2.4.1 Klassische Klassifikationsverfahren

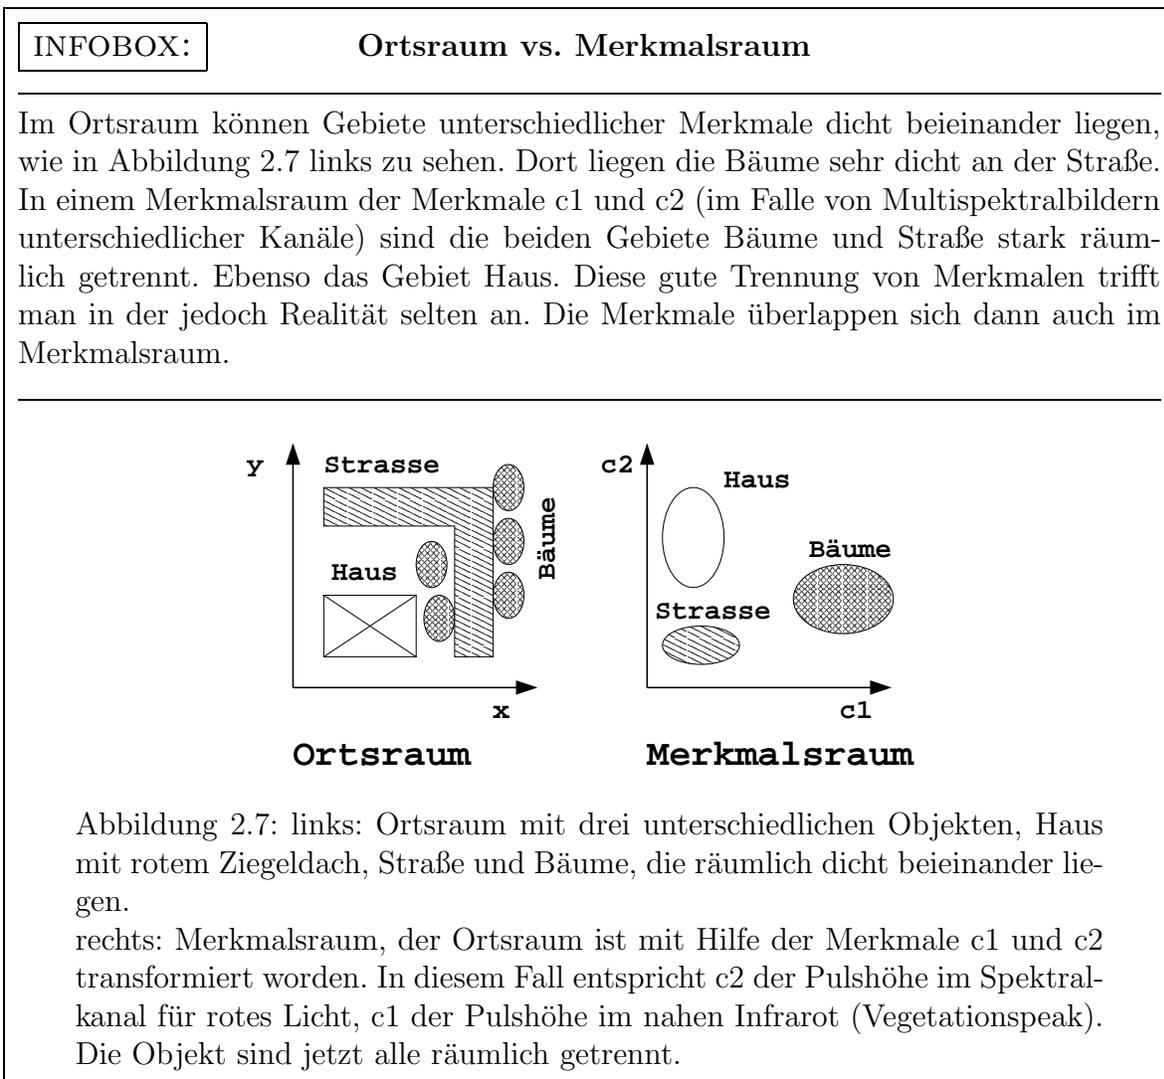
Die klassischen Verfahren basieren auf der Entscheidungstheorie von *Bayes*, die zunächst erklärt wird.

2.4.1.1 *Bayes'sche* Entscheidungstheorie

Um die Entscheidung zu treffen, zu welcher Klasse ein Merkmalsvektor gehört, muß man ein Entscheidungskriterium finden. Diese Entscheidung wird durch Annahmen beeinflusst. Nach *Bayes* lassen sich diese Annahmen dazu benutzen, den Zusammenhang zwischen der A PRIORI Wahrscheinlichkeit $P(\omega_i)$ und der A POSTERIORI Wahrscheinlichkeit $P(\omega_i|\vec{x})$ zu definieren. Die A PRIORI Wahrscheinlichkeit gibt an, wie wahrscheinlich es ist, daß ein Merkmal \vec{x} zu einer der Klassen ω_i gehört. Im einfachsten Fall nimmt man an, daß dieses für alle Klassen gleich ist. Die A POSTERIORI Wahrscheinlichkeit gibt die Wahrscheinlichkeit an, daß ein Merkmal \vec{x} zu der Klasse ω_i gehört. Diese Wahrscheinlichkeit kann durch Beobachtung gewonnen oder durch eine vorgegebene Wahrscheinlichkeitsdichtefunktion $p(\vec{x}|\omega_i)$ berechnet werden, weshalb man auch von bedingter Wahrscheinlichkeit spricht. Diese Berechnung geschieht mittels des *Theorems von Bayes* (Gl. 2.27).

Theorem von Bayes:

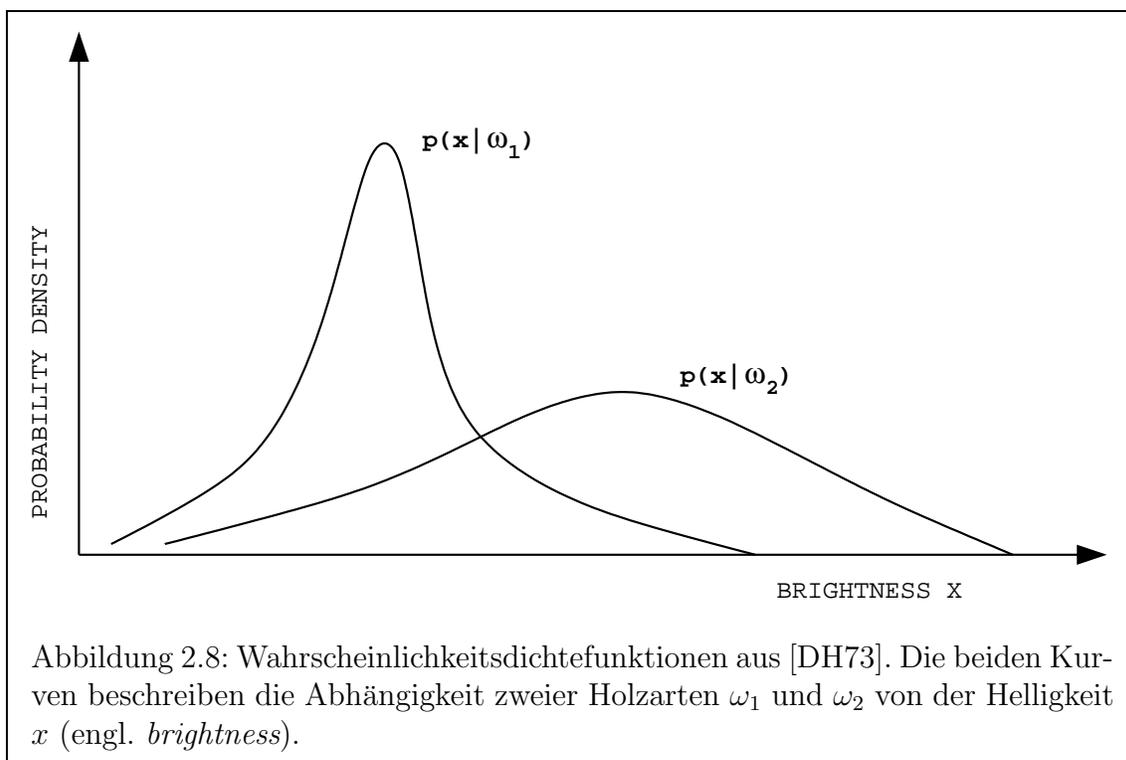
$$P(\omega_j|\vec{x}) = \frac{p(\vec{x}|\omega_j)P(\omega_j)}{p(\vec{x})} \quad p(\vec{x}) = \sum_{j=1}^n p(\vec{x}|\omega_j)P(\omega_j) \quad (2.27)$$



Dabei ist \vec{x} der Merkmalsvektor, $\Omega = \{\omega_1, \dots, \omega_n\}$ ist die Menge der möglichen Klassen, $P(\omega_j)$ die A PRIORI Wahrscheinlichkeit der Klasse ω_j , $P(\omega_j|\vec{x})$ die A POSTERIORI Wahrscheinlichkeit der Klasse ω_j und $p(\vec{x}|\omega_j)$ die Wahrscheinlichkeitsdichte der Klasse ω_j . $p(\vec{x})$ ist ein Skalenfaktor, der dafür sorgt, daß die Summe der bedingten Wahrscheinlichkeiten "ein Merkmal wird einer Klasse zugeordnet" gleich eins ist, $\sum_{i=1}^c P(\omega_i|\vec{x}) = 1$ (probabilistisches Clustern). Der Skalenfaktor $p(\vec{x})$ ist für alle Merkmale gleich und hat keinen Einfluß auf die Aussage, welche A POSTERIORI Wahrscheinlichkeit am größten ist. Für die Bestimmung der Klassenzuweisung kann er vernachlässigt werden.

Die Entscheidung, daß das Merkmal \vec{x} der Klasse ω_i zugeordnet wird, findet statt, wenn $P(\omega_i|\vec{x}) > P(\omega_j|\vec{x}) \forall j \neq i$. Diese Entscheidungsregel *minimiert* die Fehlklassifizierungsrate. In der Abbildung 2.8 sind zwei Wahrscheinlichkeitsdichtefunktionen $p(x|\omega_{1,2})$ (engl. *probability density function*) aus einem Beispiel von [DH73] dargestellt. Die beiden

Kurven beschreiben die Abhängigkeit zweier Holzarten ω_1 und ω_2 von der Helligkeit x (engl. *brightness*).



Unter der Annahme, daß die A PRIORI Wahrscheinlichkeiten für alle Klassen gleich groß sind, hängt die Entscheidung also nur von der bedingten Wahrscheinlichkeitsdichte $p(\vec{x}|\omega_i)$, der Ähnlichkeit zwischen Merkmal und *typischen* Klassenzentrum, der *Likelihood* ab.

Um die bestmögliche Entscheidung zu treffen, nehme man die Entscheidungsmöglichkeiten $A = \{\alpha_1, \dots, \alpha_c\}$ und ordne jeder Entscheidung $(\alpha_i|\omega_j)$ die Kosten $\lambda(\alpha_i|\omega_j)$ zu. λ ist eine Kostenfunktion zu. Nun läßt sich für jede Entscheidung das bedingte Risiko

$$R(\alpha_i|\vec{x}) = \sum_{j=1}^n \lambda(\alpha_i|\omega_j) P(\omega_j|\vec{x}) \quad (2.28)$$

berechnen. Eine optimale Entscheidung wird dann getroffen, wenn $R(\alpha_i|\vec{x})$ minimal ist.

Beispiel aus [DH73]: Zwei-Kategorien Klassifikation.

Gegeben seien zwei bedingte Risikofunktionen $R(\alpha_i|\vec{x})$ zu den Entscheidungen α_i , $i = 1, 2$:

$$\begin{aligned} R(\alpha_1|\vec{x}) &= \lambda_{11}P(\omega_1|\vec{x}) + \lambda_{12}P(\omega_2|\vec{x}) \\ R(\alpha_2|\vec{x}) &= \lambda_{21}P(\omega_1|\vec{x}) + \lambda_{22}P(\omega_2|\vec{x}) \end{aligned} \quad (2.29)$$

Die Kosten der jeweiligen A POSTERIORI Wahrscheinlichkeit $P(\omega_i|\vec{x})$ werden mit $\lambda_{i,j}$ mit $i = 1, 2$ und $j = 1, 2$ angegeben. Eine Entscheidung für ω_1 wird dann getroffen, wenn $R(\alpha_1|\vec{x}) < R(\alpha_2|\vec{x})$. bzw.

$$\begin{aligned} (\lambda_{21} - \lambda_{11})p(\vec{x}|\omega_1)P(\omega_1) &> (\lambda_{12} - \lambda_{22})p(\vec{x}|\omega_2) \\ P(\omega_2)R(\alpha_1|\vec{x}) &< R(\alpha_2|\vec{x}) \\ \frac{p(\vec{x}|\omega_1)}{p(\vec{x}|\omega_2)} &> \frac{(\lambda_{12} - \lambda_{22})P(\omega_2)}{(\lambda_{21} - \lambda_{11})P(\omega_1)} \end{aligned} \quad (2.30)$$

Um das Beispiel mit Leben zu füllen, nehmen wir wieder das Holzbeispiel auf. Die gemessene Helligkeit habe einen Wert $x = 80\%$. Die Kosten $\lambda_{i,j}$ sind durch die Kostenfunktion aus Gleichung 2.31 gegeben, d.h. eine falsche Entscheidung verursacht maximale Kosten (1) eine richtig keine (0). Seien die A PRIORI Wahrscheinlichkeiten $P(\omega_1) = 0,8$ bzw. $P(\omega_2) = 0,2$ und die Wahrscheinlichkeitsdichten $p(x = 0,8|\omega_1) = 0,1$ bzw. $p(x = 0,8|\omega_2) = 0,3$, dann läßt sich nach Gleichung 2.30 überprüfen, ob das Holz zur Holzart ω_1 gehört:

$$\frac{p(\vec{x}|\omega_1)}{p(\vec{x}|\omega_2)} = \frac{0,1}{0,3} = 1/3 > \frac{(\lambda_{12} - \lambda_{22})P(\omega_2)}{(\lambda_{21} - \lambda_{11})P(\omega_1)} = \frac{0,2}{0,8} = 1/4$$

Das heißt, daß das Holz zur Klasse ω_1 gehört, obwohl die Wahrscheinlichkeitsdichte bei einer Helligkeit von 80% deutlich kleiner ist als die der Holzart ω_2 . Die unterschiedlichen A PRIORI Wahrscheinlichkeiten ermöglichen diese Entscheidung. Wären die A PRIORI Wahrscheinlichkeiten gleich groß, würde nur die Wahrscheinlichkeitsdichte eine Aussage über die Zugehörigkeit der Holzarten machen.

Die Gleichung 2.30 wird auch als *Likelihood Ratio* bezeichnet, da sie nur von der Ähnlichkeit der Merkmale abhängt.

Die Risikofunktion kann mittels einer einfachen Kostenfunktion

$$\lambda(\alpha_i|\omega_j) = \begin{cases} 0 & i = j \\ 1 & i \neq j \end{cases} \quad (2.31)$$

in eine Entscheidungsfunktion umgewandelt werden, die jedem Merkmal \vec{x} eine Klasse ω_i zuordnet. Die Kostenfunktion λ ergibt sich aus der Annahme, daß man genauso viele

Entscheidungsmöglichkeiten hat wie Klassen. Bei der Suche nach der besten Entscheidung wird man versuchen, den Fehler möglichst klein zu halten. Der Fehler läßt sich einfach bestimmen. Er ist maximal, wenn man bei der Klasse ω_i die Entscheidung α_j mit $j \neq i$ wählt. Um damit eine Entscheidungsfunktion für \vec{x} zu finden, nimmt man das Negative der Risikofunktion:

$$g_i(\vec{x}) = -R(\alpha_i|\vec{x}), \quad g_i(\vec{x}) \quad i = \{1, \dots, c\}$$

$g_i(\vec{x})$ heißt Entscheidungsfunktion zur Klasse ω_i .

Mit dem *Theorem von Bayes* ergibt sich $g_i(\vec{x}) = P(\omega_i|\vec{x})$, damit liegt das Maximum der Entscheidungsfunktion beim Maximum der A POSTERIORI Wahrscheinlichkeit.

Die Analyse eines Merkmalsraumes nach Klasseneinteilungen geschieht mittels Klassifikatoren.

Ein Klassifikator ordnet **dann** einem Merkmalsvektor \vec{x} eine Klasse ω_i zu, **wenn** $g_i(\vec{x}) > g_j(\vec{x}) \forall j \neq i$.

D.h. ein Klassifikator besteht aus einem Satz von Entscheidungsfunktionen. Als Computerprogramm stellt ein Klassifikator einen Automaten dar, der eine gegebene Menge von Merkmalen in Klassen einteilt. Wenn die Entscheidungsfunktionen stetige Funktionen sind, ändert eine monotone Funktion, die darauf angewendet wird, nicht das Verhalten der Funktion. Das Maximum bleibt an der gleichen Stelle. Damit ergibt sich mit dem *Bayes'schen* Theorem eine andere Möglichkeit die Entscheidungsfunktion zu definieren, indem man den natürlichen Logarithmus auf die Gleichung 2.27 anwendet:

$$g_i(\vec{x}) = \ln p(\vec{x}|\omega_i) + \ln P(\omega_i) - \ln p(\vec{x})$$

Der Nenner aus dem *Bayes'schen* Theorem $p(\vec{x})$ ist für alle g_i gleich und kann daher vernachlässigt werden. Ist die A PRIORI Wahrscheinlichkeit $P(\omega_i)$ für alle Klassen gleich, entfällt der Summand ebenfalls. Damit ergibt sich, daß die Entscheidungsfunktionen nur von der Wahrscheinlichkeitsdichte abhängen.

Geometrisch betrachtet sind die Entscheidungsgrenzen, wo $g_i(\vec{x}) = g_j(\vec{x})$, Hyperflächen im Merkmalsraum.

2.4.1.2 Unüberwachte Klassifikation

Die unüberwachte Klassifikation dient der Klassifikation von großen bzw. unüberschaubaren Datenmengen. Dazu gehören auch multidimensionale Merkmalsräume, wie die DAEDALUS Luftbilder, da hier sowohl eine große Menge von Daten vorliegt, als auch die Cluster nicht ohne weiteres eindeutig erkennbar sind. Die Projektion aus einem höherdimensionalen Raum auf eine Ebene kann Clustergrenzen überlagern, was eine "menschliche" Einteilung erschwert, wenn nicht sogar unmöglich macht. Um unüberwacht zu klassifizieren, braucht man die Vorgabe eines Klassifikators, die Anzahl der Klassen oder ein Gütemaß für Klasseneinteilung (z.B. die Dichte der Merkmale im Cluster [HKK97]), ein Abbruchkriterium, sowie Startwerte. Die unüberwachte Klassifikation mittels der *Maximum Likelihood* Methode ist nicht möglich, da Aussagen über die Korrelation getroffen

werden müssen, die nicht bekannt ist. Eine Möglichkeit besteht in der Klassifikation mittels der *Minimum Distance* Methode, da hier nur der Abstand⁸ zwischen zufällig vorgegebenen Klassenzentren $\vec{\mu}_i$ und den Merkmalsvektoren \vec{x} berechnet zu werden braucht. Der Algorithmus, der diese Klassifikation vornimmt, heißt ISODATA.

ISODATA Algorithmus ISODATA steht für *Iterative-Self-Organizing-Data-Analysis-Techniques-A* und läßt sich durch folgen vier Schritte beschreiben.

1. Zufällige Auswahl von Startwerten für die Klassenzentren $\mu_{1,0}, \dots, \mu_{i,0}$
2. Klassifiziere die Daten mit *Minimum Distance*
3. Berechne anhand der gefundenen Klassen die Klassenzentren neu

$$\mu_{i,j} = \frac{\sum_{\vec{x} \in X_i} P(\omega_i | \vec{x}) \vec{x}}{\sum_{\vec{x} \in X_i} P(\omega_i | \vec{x})}$$

Dabei nimmt $P(\omega_i | \vec{x})$ nur Werte von 0 oder 1 an, je nachdem ob \vec{x} zur Klasse ω_i gehört (1) oder nicht (0).

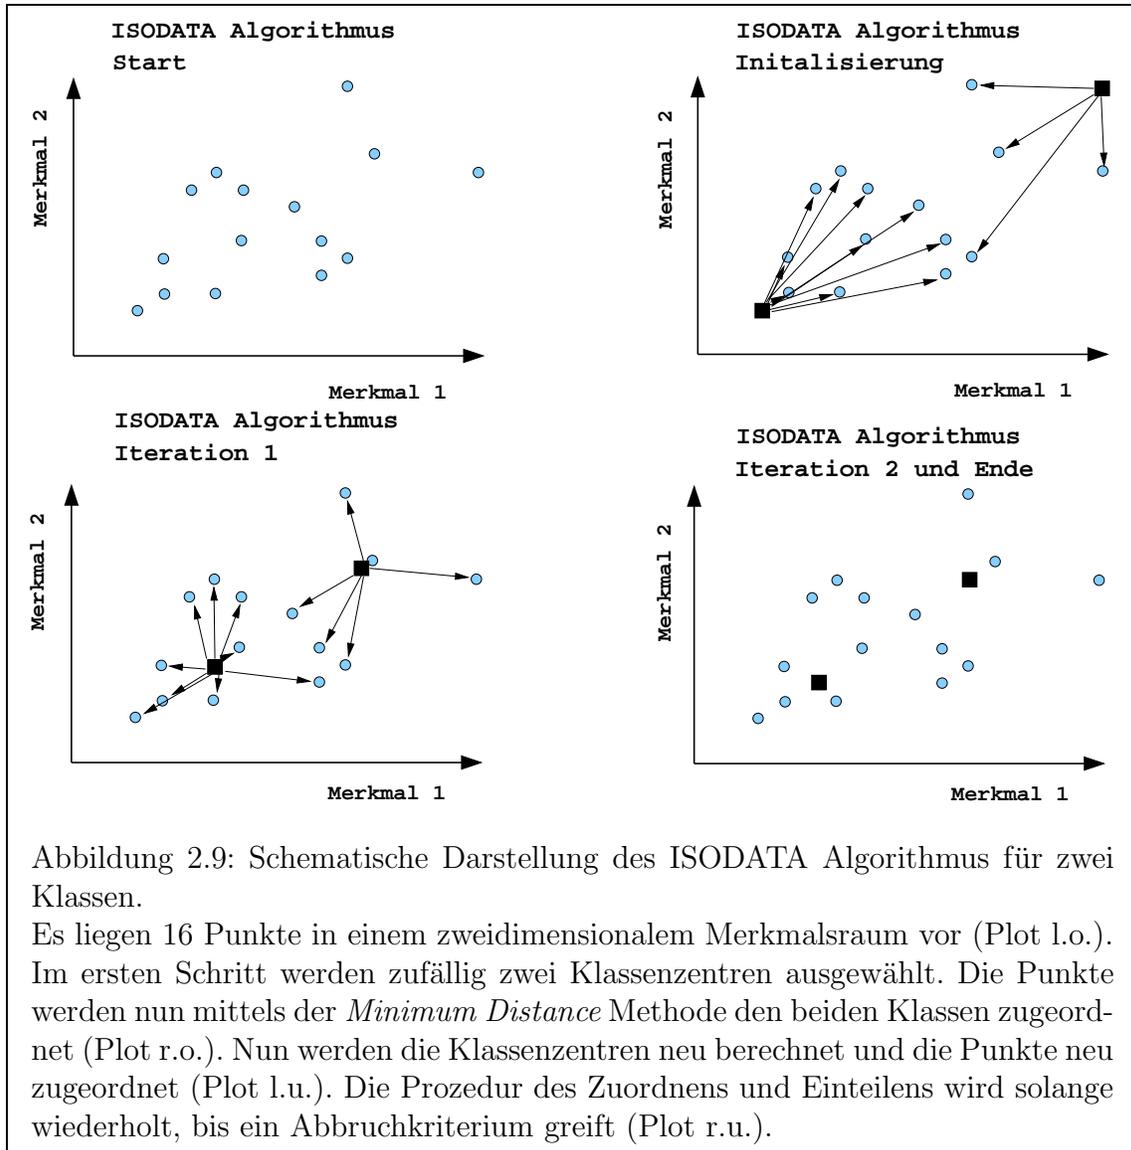
4. Gehe zu 1. solange bis ein Abbruchkriterium greift.

Abbruchkriterien:

- $\frac{\mu_{i,j} - \mu_{i,j-1}}{\mu_{i,j}} < \varepsilon$
- Anzahl der Iterationen $> N$.

Das erste Abbruchkriterium ist ein relatives Abbruchkriterium, das die relative Änderung der Klassenzentren zwischen zwei Iterationen berechnet. Erst wenn die Mittelwerte sich nicht mehr (oder nur geringfügig) ändern, bricht der Algorithmus ab. Weshalb man manchmal auch von *migrating means*, wandernden Mittelwerten, spricht. Die zweite Abbruchbedingung ist ein Tribut an die Rechenzeit, die man verbrauchen will. In Abbildung 2.9 ist der Algorithmus schematisch dargestellt. Ein anderer Name dieses Algorithmus' hat sich durch den Vergleich zu Fuzzy-Clustering Verfahren ergeben, *Hard-c-Means* (harte c-Mittelwertbildung), wobei c sich auf die Anzahl der Klassen bezieht.

⁸Es gibt verschiedene Möglichkeiten Abstände zwischen Vektoren zu definieren. Bei der gestesteten *Minimum Distance* Methode wurde der euklidische Abstand $d(x, y) = \|x - y\| = \sqrt{\sum_i (x_i - y_i)^2}$ benutzt, wobei i ein Index ist, der die einzelnen Komponenten von x und y durchläuft. Im Program wird der quadratische euklidische Abstand benutzt, da das Wurzelziehen eine aufwendige Operation ist, die viel Rechenzeit kostet.



2.4.1.3 Überwachte Klassifikation

Die überwachte Klassifikation unterscheidet sich von der unüberwachten Klassifikation dadurch, daß bei der überwachten Klassifikation Trainingsdaten ausgewählt werden, anhand derer ein Klassifikator trainiert wird. Bei überwachten Klassifikationsverfahren, die auf *Bayes'sche* Entscheidungstheorie beruhen, macht der Anwender Aussagen über die Wahrscheinlichkeitsdichte und die A PRIORI Wahrscheinlichkeiten. Geht man von um die Klassenzentren normalverteilten Merkmalsvektoren \vec{x} aus, so gibt es verschiedene Techniken, den Merkmalsraum aufzuteilen. Es wird für die klassischen Verfahren das *Minimum Distance* und das *Maximum Likelihood* Verfahren vorgestellt.

Minimum Distance Beim *Minimum Distance* Verfahren werden aus den vorgegebenen Trainingselementen durch einfache Mittelwertbildung Prototypen $\vec{\mu}_i$ für die jeweilige Klasse i berechnet.

Entscheidungsfunktion des *Minimum Distance* Klassifikators:

$$g_i(\vec{x}) = -2\vec{\mu}_i^T \vec{x} + \vec{\mu}_i^T \vec{\mu}_i \quad (2.32)$$

Die Entscheidungsgrenzen entsprechen Hyperflächen. \vec{x} ist der Merkmalsvektor, für den eine Entscheidung getroffen werden soll, i die Klasse. \vec{x} wird der Klasse mit dem größten $g_i(\vec{x})$ zu geordnet.

Bei der Klassifikation werden die Elemente mit diesen Prototypen verglichen und der Klasse mit maximaler Ähnlichkeit zugeordnet.

Maximum Likelihood Bei der *Maximum Likelihood* Klassifikation geht man davon aus, daß

- a) alle Klassen die gleiche A PRIORI Wahrscheinlichkeit haben
- b) die Elemente einer Klasse normalverteilt sind, d.h. die Wahrscheinlichkeitsdichten $p(\vec{x}, \omega_j)$ entsprechen einer multivariaten Normalverteilung.

Die Parameter der Normalverteilung sind zum einem der Mittelwert oder das Klassenzentrum einer Klasse $\vec{\mu}_i$, zum anderen die Kovarianzmatrix

$$\Sigma_i = E[(\vec{x} - \vec{\mu}_i)^T (\vec{x} - \vec{\mu}_i)], \quad (2.33)$$

welche die mehrdimensionale Varianz der Verteilung beschreibt.

Entscheidungsfunktion des *Maximum Likelihood* Klassifikators

Mehrdimensionale Normalverteilung der Dimension d :

$$N(\vec{\mu}_i, \Sigma_i) = \frac{\exp(-\frac{1}{2}(\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{\mu}_i))}{2\pi^{d/2} \|\Sigma_i\|^{1/2}} \quad (2.34)$$

Durch Logarithmieren des *Bayes'schen Theorems* erhält man:

$$g_i(\vec{x}) = \left(-(\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{\mu}_i) \right) + \ln |\Sigma_i| \quad (2.35)$$

Das ist eine quadratische Gleichung, so daß die Entscheidungsgrenzen *Hyperquadriken* entsprechen (Parabeln, Hyperbeln oder Ellipsen im 2D).

Diese Parameter ermittelt man aus einer Auswahl von Trainingselementen je Klasse, wobei man darauf achten muß, genügend viele Trainingselemente zu nehmen, um eine aussagekräftige Statistik zu erhalten [DH73, Kul97]. Die Klassifikation ordnet den Elementen der zu klassifizierenden Menge, mit der Gleichung 2.35 zu jeder Klasse eine Zugehörigkeitswahrscheinlichkeit zu. Die Klasse eines Elements bestimmt sich aus der maximalen Wahrscheinlichkeit.

2.4.2 Fuzzy-Klassifikationsverfahren

Bei den Fuzzy-Klassifikation Verfahren handelt es sich um klassische Algorithmen, die nicht mehr nur mit scharfen Mengen arbeiten, sondern als Ergebnisse mehrere Karten (entsprechend der Anzahl der Klassen) liefern, die jeweils Aussagen über die Zugehörigkeit eines Pixels zu jeder Klasse enthalten. Diese Karten lassen sich über eine einfache Maximumsbildung oder mit Hilfe von bestimmten Fusionsverfahren (Kapitel 2.5) in eine Klassenkarte umrechnen.

2.4.2.1 Unüberwachte Fuzzy-Klassifikation

In Anlehnung an die klassischen unüberwachten Verfahren zur Klassifikation hat man entsprechende Fuzzy-Algorithmen entwickelt. Diese sollen die Vorteile der unscharfen Klassengrenzen nutzen, um eine bessere Clustereinteilung zu bekommen. Das Hauptproblem der unüberwachten Klassifikation bleibt: Der Nutzer hat keine Möglichkeit die Klassenwahl zu beeinflussen.

Fuzzy-c-Means Der *Fuzzy-c-Means*-Algorithmus (FCM) wurde von Dunn [Dun73] entwickelt. Bezdek [BP92] verallgemeinerte den Algorithmus und zeigte seine Konvergenz.

Um eine optimale Klasseneinteilung zu erreichen, muß man eine Bewertungsfunktion finden, um die Güte einer Klassifikation einzuschätzen. Für die Menge der Fuzzy-Klassifikationen $F(K)$ der Menge X , mit $K = c_1, \dots, c_i$ der Menge der möglichen Klassen, nimmt man eine Bewertung nach einer Verallgemeinerung der Methode der kleinsten

Fehlerquadrate⁹ vor. Die Bewertungsfunktion, die man dafür minimieren muß, lautet:

$$b(u) = \sum_{x \in X} \sum_{c \in K} (u_c(x))^m \cdot d^2(x, c) \text{ mit } u : X \rightarrow F(K) \quad (2.36)$$

- Distanzmaß $d(x, c)$: Ähnlichkeit zwischen Merkmalsvektor $x \in X$ und Klassenzentrum $c \in K$, meist euklidisch $d(x, c) = \|x - c\|$.
- $K = \{c_1, \dots, c_i\}$ Menge der Klassen.
- *Fuzzifier* m : Der Exponenten m gibt an, wie schnell die Zugehörigkeit vom Klassenzentrum weg abfällt. Es zeigt sich, daß $m = 2$ eine gute Wahl ist. $m = 1$ entspricht *Hard-c-Means*
- Zugehörigkeitsfunktion: $u_c(x)$

Bezdek zeigt in [BP92], daß die Bewertungsfunktion b dann minimal ist, wenn die Zugehörigkeit sich wie folgt berechnet

$$u_c(x) = \begin{cases} \frac{d^2(x,c)^{-1/(m-1)}}{\sum_{j \in K} d^2(x,j)^{-1/(m-1)}} & : \forall I_x = \{\emptyset\} \\ \sum_{j \in I_x} u_j(x) = 1 & : \forall I_x \neq \{\emptyset\}, c \in I_x \\ 0 & : \forall I_x \neq \{\emptyset\}, c \notin I_x \end{cases} \quad (2.37)$$

$$I_x := \{j \in K \mid d(x, j) = 0\} \quad (2.38)$$

I_x ist die Menge der Merkmale x , die mit einem Klassenzentrum c übereinstimmen. Die I_x Menge sollte bei punktförmigen Klassenzentren immer eins sein, ansonsten hätte man zwei gleiche Klassen und könnte eine streichen. Der zweite Fall ergibt sich aus der Bedingung des probabilistischen Clusterings: Die Summe aller Zugehörigkeiten von einem Merkmal muß eins sein, $\sum_{i=1}^c u_i(\vec{x}) = 1$. Der dritte Fall beschreibt die Möglichkeit, daß ein Merkmal eine Zugehörigkeit von 0 hat und zu keiner Klasse gehört. Diese Möglichkeit sollte gar nicht vorkommen. Im Falle nicht punktförmiger Cluster, wie Kreisen oder Ringen, sind diese Bedingungen wichtig.

Mit der Zugehörigkeitsfunktion

$$u_c(x) = \frac{d^2(x, c)^{\frac{-1}{(m-1)}}}{\sum_{j \in K} d^2(x, j)^{\frac{-1}{(m-1)}}}, \quad (2.40)$$

kann man nun $b(u)$ minimieren, um eine optimale Klasseneinteilung zu finden.

⁹Bei der Methode der kleinsten Fehlerquadrate minimiert man eine Bewertungsfunktion b , um eine optimale Anpassung der Parameter eines Modells an die gegebenen Daten zu berechnen. Die Bewertungsfunktion b wird meist über die Differenz zwischen Daten und dem Modell definiert. Die Verallgemeinerung besteht nun darin, daß die Bewertungsfunktion abhängig von einer Zugehörigkeitsfunktion u wird.

Satz von Bezdek:

Ist b minimal, dann gilt mit $u_{i,j} = u_{c_i}(x_j)$

$$c_i = \frac{\sum_{j=1}^n u_{i,j}^m x_j}{\sum_{j=1}^n u_{i,j}^m} \quad (2.41)$$

c_i sind die neuen Klassenzentren.

Damit kann man den *Fuzzy-c-Means* Algorithmus beschreiben:

1. initialisiere (zufällig) Klassenzentren: $c_{i,0}$
2. bestimme $c_{i,j}$, wobei j der Iterationslaufindex ist
3. wenn $\frac{c_{i,j} - c_{i,j-1}}{c_{i,j}} > \varepsilon$ dann 2. sonst Abbruch

In Abbildung 2.10 ist der Ablauf des Algorithmus schematisch dargestellt.

In der überwachten Klassifikation wird ein Schritt aus dem FCM für das *fuzzy nearest prototype* Verfahren benutzt [KGG85]. Dabei werden aus der Menge der Trainingselemente Y c Prototypen μ_i , $i = \{1, \dots, c\}$ bestimmt, deren Zugehörigkeiten über den FCM-Algorithmus berechnet werden.

Bezdek hat den FCM noch weiter entwickelt. Dabei wird der Exponent variabel gehalten und in Iterationsschritten lernend verändert, was zu einer schnelleren Konvergenz führt. Das Verfahren ist als Lernender-Fuzzy-Vektor-Quantisierer (LFVQ) bekannt.

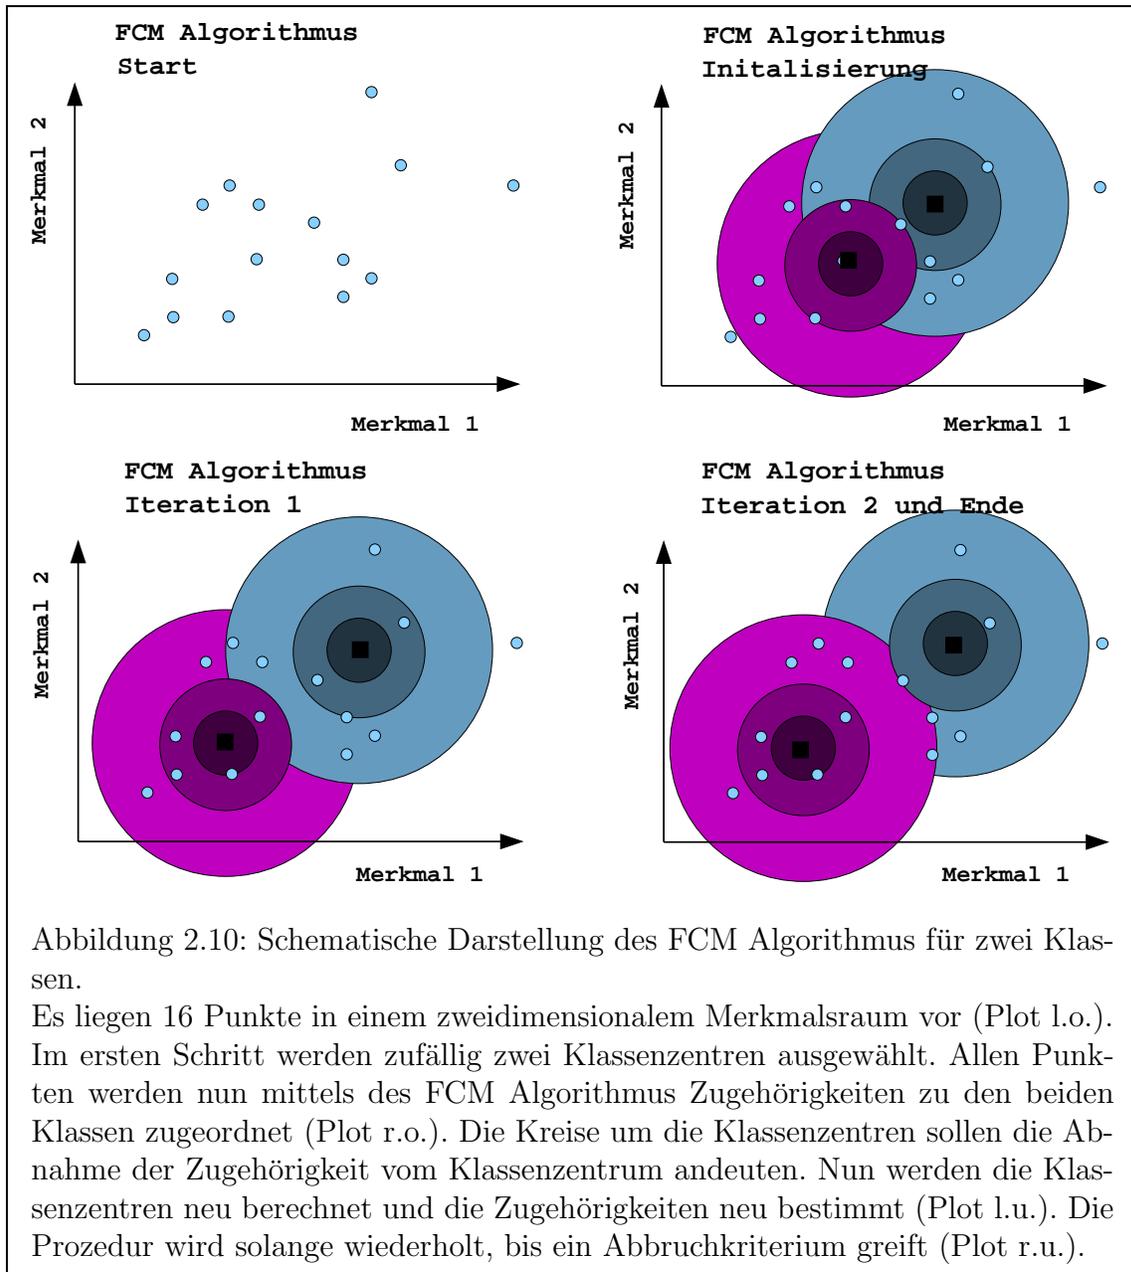
Fuzzy-c-Means mit Kontext Die Verbesserung der Klassifikation durch Kontext, d.h. durch einen Einfluß der umgebenden Pixel, wurde von R. Wiemker [Wie97] untersucht. Basierend auf den *Fuzzy-c-Means* Algorithmus wird zusätzlich eine Zugehörigkeitsfunktion definiert. Dazu definiert man ein Umgebungspotential, daß den Einfluß der Umgebung auf das zentrale Pixel beschreibt (s. Abb. 2.11).

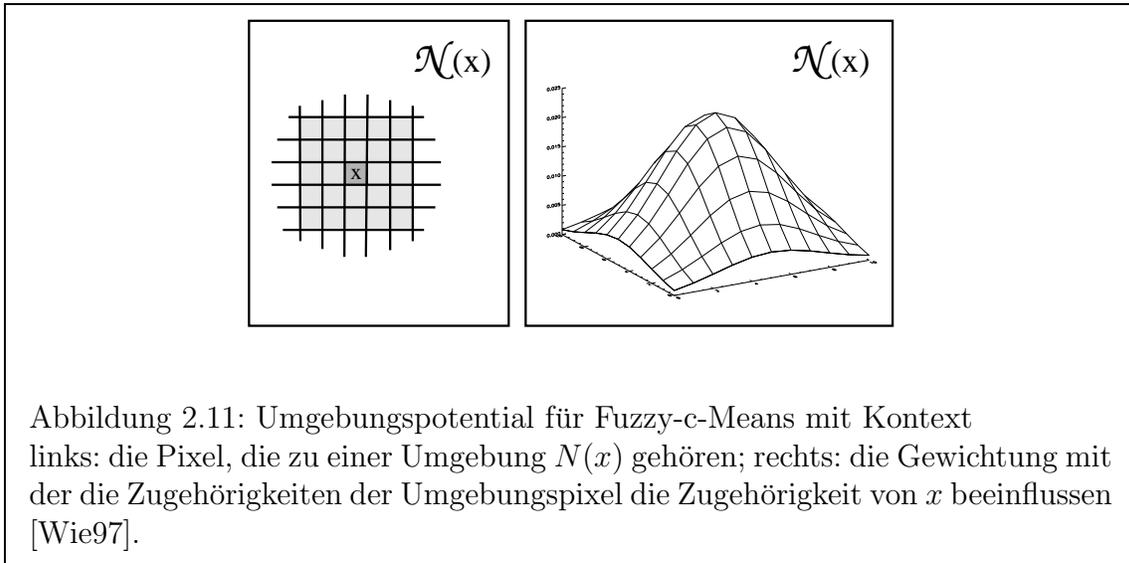
$$U_k(x) = \sum_{x \in X} [1 - u_k(x)] \quad (2.42)$$

X gibt dabei die Menge der Pixel an, die berücksichtigt werden. Es wird nur die jeweilige Zugehörigkeit zu einer Klasse verändert, nicht der Merkmalsvektor selbst. Auf Bildern kann man sich X als ein quadratisches Fenster mit einer Ausdehnung von 3, 5 oder $2n+1$ Pixeln, entsprechend einem X von 9, 25 oder $(2n+1)^2$ Elementen vorstellen. Daraus ergibt sich eine ‘Umgebungszugehörigkeit’:

$$H_k(x) = \frac{\exp(-\beta U_k(x))}{Z} \quad (2.43)$$

Diese ist von β und $U_k(x)$ abhängig. Die Konstante β gibt den Einfluß an, den das Umgebungspotential haben soll, und muß größer als Null gewählt werden. Der Nenner Z





ist eine Normierungskonstante und nicht weiter notwendig. Je größer die Ähnlichkeit der Zugehörigkeit ist, desto kleiner wird $U_k(x)$ und damit die Umgebungszugehörigkeit größer. Nach dem ersten Iterationsschritt läßt sich dann die zusammengesetzte Zugehörigkeitsfunktion berechnen:

$$G_k(x) = \frac{U_k(x) \cdot H_k(x)}{\sum_{i \in K} [U_{k_i}(x) \cdot H_{k_i}(x)]} \quad (2.44)$$

2.4.2.2 Überwachte Fuzzy-Klassifikation

Im Zuge der Entwicklung von Fuzzy-Algorithmen zur Klassifikation wurden auch überwachte Verfahren entwickelt. Diese haben wieder den Vorteil, daß der Nutzer vorher die Klassen bestimmen kann. Die Idee ist, daß man eine Datenbank mit Referenzmerkmalen anlegt und somit auch ohne Nutzereingriff neue Szenen klassifizieren kann. Die folgenden überwachten Verfahren wurden getestet:

- *Fuzzy Comparison of Parameters (FCOP)*: Ermittelt die Häufigkeitsverteilung bestimmter Werte innerhalb einer Umgebung und beschreibt diese durch Fuzzy-Regeln. Diese Verfahren hat gewisse Nachteile (u.a. Reduktion der Auflösung) (siehe auch [Reg00]), so daß die Anwendbarkeit auf optischen Daten nicht näher untersucht wurde. Es ist für SAR-Daten besser geeignet, da diese stark verrauscht sind, was bei diesem Verfahren berücksichtigt wird. Näheres zu dieser Methode ist in [Ben99a, Ben99b] zu finden.
- *Fuzzy k-nearest-neighbor*: Die zu klassifizierenden Elemente werden mit Trainingselementen verglichen. Die Zuordnung erfolgt über die größte Ähnlichkeit zu k Trainingselementen. Die Zugehörigkeiten der Trainingselemente zu einer Klasse können dabei entweder als "crisp", d.h. jedes Element gehört mit einer Zugehörigkeit von 1

zu einer Klasse oder über eine “*Fuzzy-c-Means*” Zuweisung festgelegt werden. Dieser Algorithmus wird anschließend erklärt.

Fuzzy-k-nearest-neighbor Die Klassifikation mittels der Methode der nächsten Nachbarn ist eine verbesserte Version der Klassifikation mittels der *Minimum Distance* Methode. Die Idee des “klassischen” *k-nearest-neighbor* Verfahren beruht darin, daß man aus den Trainingselementen nicht mehr nur einen Prototypen errechnet, sondern alle Elemente als einen Trainingsdatensatz beibehält. Die zu klassifizierenden Elemente werden mit jedem Trainingselement verglichen. Die *k* ähnlichsten Elemente bestimmen die Klasse. Es kann gezeigt werden, daß bei genügend großer Anzahl von Trainingselementen der Fehler asymptotisch gegen den minimalen Fehler der *Bayes’schen* Entscheidungstheorie konvergiert [CH67, RFL86].

Die Fuzzy-Variante des *k-nearest-neighbor* Algorithmus wird in einem Artikel von Keller, Gray und Givens aus dem Jahr 1985 beschrieben [KGG85].

Er funktioniert wie folgt:

1. Lege die Trainingselemente (Trainingspixel) y_{in} , $n = \{1, \dots, N\}$ für jede Klasse i fest. Diese y_{in} bilden die Trainingsmenge $Y_i = y_{in}$ der Klasse i . Die Anzahl N der Trainingselemente in Y_i wird vorgegeben.
2. Bestimme für jedes Element x (Pixel) aus der zu untersuchenden Menge X (Bildaten) die k nächsten Nachbarn x_{ij} , $j = \{1, \dots, k\}$ zur Klasse i bezüglich eines Abstandes¹⁰

$$d(x, y_i) = \|x - y_i\|^2 \quad (2.45)$$

aus der Trainingsmenge Y_i . Dabei werden die k x_{ij} über den minimalen Abstand ausgewählt. Die Anzahl k der nächsten Nachbarn wird vorgegeben.

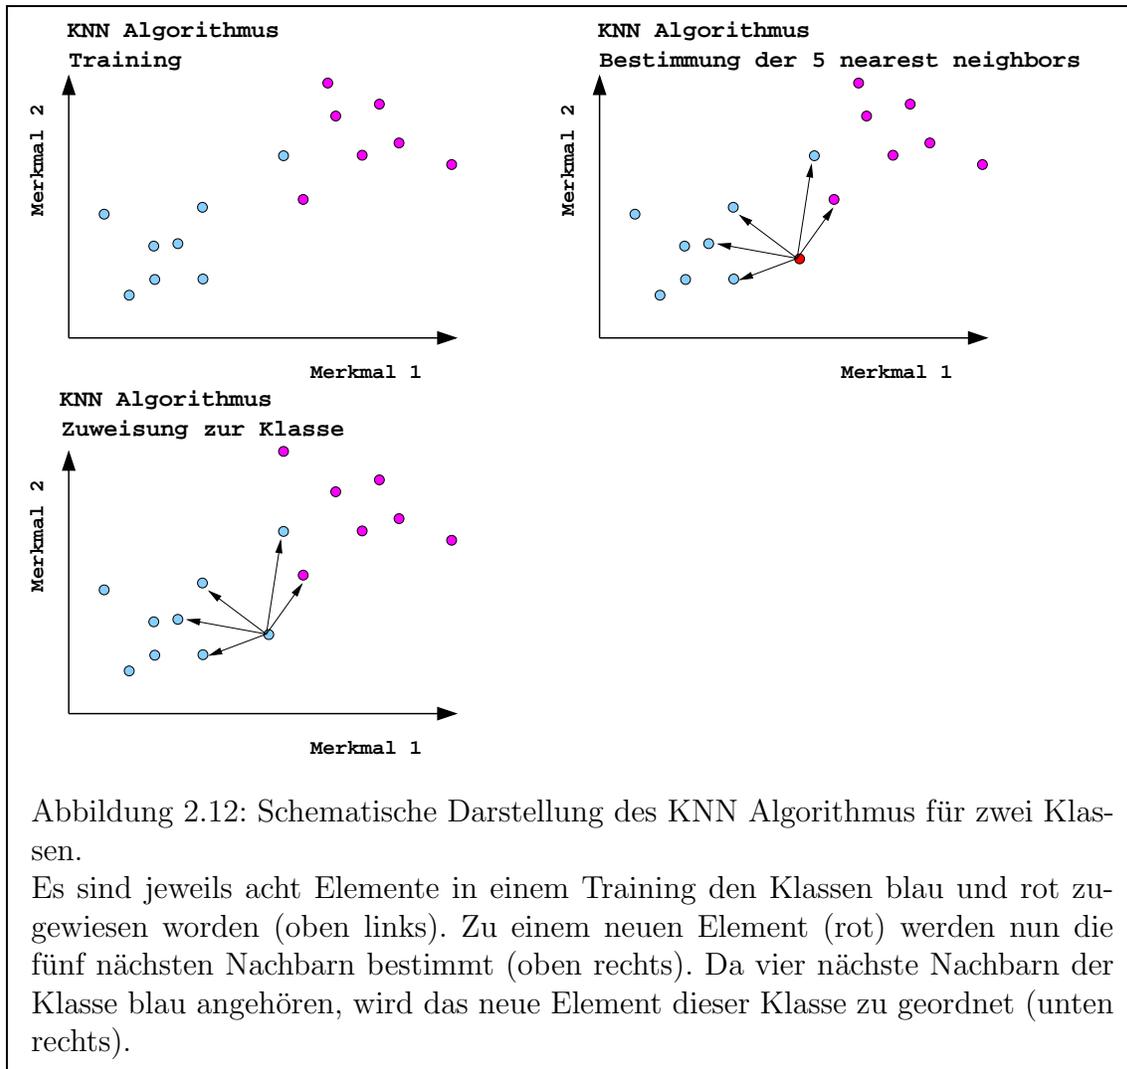
3. Berechne die Zugehörigkeit $u_i(x)$ des Elementes x zu jeder Klasse i mittels:

$$u_i(x) = \frac{\sum_{j=1}^k u_{ij} \|x - x_{ij}\|^{-\frac{2}{m-1}}}{\sum_{j=1}^k \|x - x_{ij}\|^{-\frac{2}{m-1}}}, \quad (2.46)$$

die x_{ij} sind die k nächsten Nachbarn.

In Abbildung 2.12 wird der KNN Algorithmus schematisch erklärt. Im Plot links oben werden die Trainingselemente der beiden Klassen (blau und magenta) bestimmt. Die jeweils acht Elemente dienen als Basis für die Klassifikation. Bei der Klassifizierung wird nun ein neues Element (rot) über ein Abstandsmaß mit den Elementen der Trainingsmenge verglichen. Die fünf nächsten Nachbarn bestimmen dann die Klasse des neuen Elements. In der Abbildung wird das rote Element der Klasse blau zugeordnet, da es zu

¹⁰Empfohlen werden nach Jäger fünf nächste Nachbarn und 30 Trainingspixel pro Klasse



vier Elementen der blauen Klasse näher liegt im Gegensatz zu nur einen Element der roten Klasse. Das neue Element wird nicht in die Trainingsklasse integriert. Die Fuzzy-Version des Algorithmus' berechnet jetzt die anhand der k nächsten Nachbarn jeder Klasse i , die Zugehörigkeit zu dieser Klasse für jedes Element x der Menge X .

Dabei läßt sich noch entscheiden, wie die Zugehörigkeiten u_{ij} der Trainingselemente aussehen sollen. In dem Programm MFIAS, das ich für die Untersuchungen benutzt habe, sind drei Möglichkeiten realisiert, die Zugehörigkeit festzulegen:

1. Jedes Trainingselement y_{in} einer Klasse i erhält eine Zugehörigkeit von eins und null zu allen anderen Klassen: $u_{ij} = \delta_{ij}$
2. Die Zugehörigkeit der k nächsten Nachbarn x_{ij} $j = \{1, \dots, k\}$, zur Klasse i wird über ein Ähnlichkeitsmaß zum Prototypvektor μ_i (durch Mittelwertbildung der Trai-

ningselemente y_{in} der Klasse i berechnet) bestimmt:

$$u_{ij}(x_j) = \frac{\sum_l x_{jl} \wedge \mu_{il}}{\sum_l x_{jl} \vee \mu_{il}}, \quad (2.47)$$

l ein Index, der die Anzahl der Komponenten von x durchläuft.

3. Aus der Menge der Trainingselemente Y_i wird für jede Klasse i ein Prototyp μ_j bestimmt und jedes Trainingselement y erhält nun mittels des *Fuzzy-c-Means*-Algorithmus eine Zugehörigkeit $u_{ij}(y)$ zu jeder Klasse i .

2.4.3 Gütemaße für Klassifikationen

Um eine Klassifikation hinsichtlich ihrer Genauigkeit zu bewerten, muß man sich auf Maßzahlen bzw. Gütemaße einigen. Die Genauigkeit wird durch einen Vergleich des Klassifikationsergebnisse mit einer Testszene bestimmt. Die Gütemaße ergeben sich aus dem Verhältnis zwischen richtig klassifizierten Elementen und Fehlklassifikationen. Die Fehlklassifikationen können verschiedene Ursachen haben:

- a) Die geometrische Auflösung erzeugt Mischpixel, in denen mehrere Klassen gleichzeitig auftreten.
- b) Die gewählten Unterscheidungsparameter sind nicht ausreichend, um gewisse Klassen zu trennen.

Im folgenden werden verschiedene Gütemaße vorgestellt, die sich in zwei Klassen einteilen lassen, Gütemaße zur Bewertung von scharfen (engl. *crisp*) Klassifikationen mit scharfen Validierungsdaten und Gütemaße für Fuzzy-Klassifikationen, die im Kapitel 2.4.2 beschrieben werden, mit scharfen oder *fuzzy* Validierungsdaten.

2.4.3.1 Crisp-Gütemaße

Diese Gütemaße sind schon länger bekannt und etabliert. Aufgrund einer Referenzkarte wird die Konfusionsmatrix berechnet.

Die Konfusionsmatrix A wird aus der Klassifikation C und der Referenzkarte R gebildet, indem die Anzahl der Pixel in den Schnittmengen je Klasse der beiden Karten aufgetragen wird

$$A = (a_{jk})_{j,k=1,\dots,N}, \quad a_{jk} = |R_k \cap C_j|, \quad (2.48)$$

j und k stehen für die Klassen der Klassifikation und werden durchpermutiert.

In den Spalten wird die Anzahl der Pixel der Klasse j der Klassifikation gezählt, die in Gebieten der Referenzklassen $1, \dots, j$ liegen. In den Zeilen wird die Anzahl der Pixel des Referenzgebietes der Klasse i gezählt, die den Klassen $1, \dots, j$ der Klassifikation entsprechen. Der Wert a_{23} entspricht also der Anzahl der Pixel, die als zur Klasse 3

Ref./Klassif.	Klasse1	Klasse2	Klasse3	Klasse4	Klasse5
Klasse1	a_{11}	a_{21}	a_{31}	a_{41}	a_{51}
Klasse2	a_{11}	a_{22}	a_{32}	a_{42}	a_{52}
Klasse3	a_{11}	a_{23}	a_{33}	a_{43}	a_{53}
Klasse4	a_{11}	a_{24}	a_{34}	a_{44}	a_{54}
Klasse5	a_{11}	a_{25}	a_{35}	a_{45}	a_{55}

Tabelle 2.1: Schematische Darstellung der Konfusionsmatrix für fünf Klassen. Die Koeffizienten a_{ij} stehen für die Anzahl der Pixel, die im Referenzgebiet der Klasse i als zur Klasse j zugehörig klassifiziert wurden. D.h. a_{ii} sind die Koeffizienten für richtig klassifizierte Gebiete. Ist die Matrix diagonal, hat man eine in dem Testgebiet vollständig korrekte Klassifikation.

zugehörig klassifiziert wurden, aber im Referenzgebiet der Klasse 2 liegen. Diese Pixel sind also falsch klassifiziert worden.

Bei einer perfekten Klassifikation wäre die Matrix diagonal. Aus der Abweichung von diesem Idealfall werden nun verschiedene Gütemaße (engl. *accuracies*) berechnet (s. auch [JB00, RFL86]).

User's accuracy Die *User's Accuracy UA* oder auch Zuweisungsgenauigkeit ist ein Gütemaß, das den prozentualen Anteil der Pixel wiedergibt, die als zur Klasse i gehörig klassifiziert wurden, die auch im Referenzgebiet der Klasse i liegen

$$UA(i) = \frac{a_{ii}}{\sum_k a_{ik}}. \quad (2.49)$$

REF(i)/KLA(k)	Klasse1	Klasse2	Σ_Z
Klasse1	50	20	70
Klasse2	10	40	50
Σ_S	60	60	90

Tabelle 2.2: Beispiel zur Berechnung der *User's Accuracy UA*:

$$UA(Klasse1) = 50/60 = 83,3\%$$

$$\text{und } UA(Klasse2) = 40/60 = 66,6\%$$

Producer's accuracy Die *Producer's accuracy PA* oder auch Wiedererkennungsgenauigkeit ist ein Gütemaß, das den prozentualen Anteil an Pixeln wiedergibt, die im Refe-

renzgebiet der Klasse i korrekt klassifiziert wurden

$$PA(i) = \frac{a_{ii}}{\sum_k a_{ki}}. \quad (2.50)$$

REF(i)/KLA(k)	Klasse1	Klasse2	Σ_Z
Klasse1	50	20	70
Klasse2	10	40	50
Σ_S	60	60	90

Tabelle 2.3: Beispiel zur Berechnung der *Producer's Accuracy PA*:
 $UA(Klasse1) = 50/70 = 71,2\%$ und
 $UA(Klasse2) = 40/50 = 80,0\%$

Overall accuracy Die *Overall accuracy OA* oder Gesamtgenauigkeit ist ein Gütemaß, das die prozentuale Genauigkeit der gesamten Klassifikation wiedergibt

$$OA = \frac{\sum_i a_{ii}}{\sum_{ik} a_{ik}}. \quad (2.51)$$

REF(i)/KLA(k)	Klasse1	Klasse2	Σ_Z
Klasse1	50	20	70
Klasse2	10	40	50
Σ_S	60	60	90

Tabelle 2.4: Beispiel zur Berechnung der *Overall Accuracy OA*:
 $UA(Klasse1) = 90/120 = 75\%$

Kappa-Wert Der Kappa-Wert ist ein weiteres, häufig benutztes Gütemaß:

$$\kappa = \frac{p_0 - p_z}{1 - p_z} \quad (2.52)$$

$$p_0 = \sum_i \frac{a_{ii}}{N} \quad p_z = \sum_i \left(\sum_j \frac{a_{ij}}{N} \cdot \sum_j \frac{a_{ji}}{N} \right)$$

p_0 entspricht der Anzahl der richtig klassifizierten Pixel, p_z der (zufällig) falsch klassifizierten Pixel. Der Nenner $1 - p_z$ dient der Normierung auf die Anzahl der richtig

klassifizierten Pixel. $\kappa = 0$ entspräche einer zufälligen Verteilung von Pixeln. Ist $\kappa < 0$, ist die Klassifikation schlechter als eine zufällige, was auf einen systematischen Fehler hinweist.

Es läßt sich auch ein statistischer Fehler $\sigma_\infty^2(\kappa)$ des Kappa-Werts angeben. Dieser Fehler gilt zwar nur für unendlich Große Testmengen, kann aber als gute Näherung auch für endlich Mengen benutzt werden. Eine genaue Herleitung des Fehlers befindet sich in [BFH75]. Für den Fehler $\sigma_\infty^2(\kappa)$ gilt:

$$\begin{aligned}\sigma_\infty^2(\kappa) &= \frac{1}{N} \left\{ \frac{p_0(1-p_z)}{(1-p_z)^2} + \frac{2(1-p_0)(2p_0p_z-p_3)}{(1-p_z)^3} + \frac{(1-p_0)^2(p_4-4p_z^2)}{(1-p_z)^4} \right\} \\ p_3 &= \sum_i \frac{a_{ii}(a_{i+} + a_{+i})}{N^2} \\ p_4 &= \sum_{ij} \frac{a_{ij}(a_{j+} + a_{+i})^2}{N^3}\end{aligned}\tag{2.53}$$

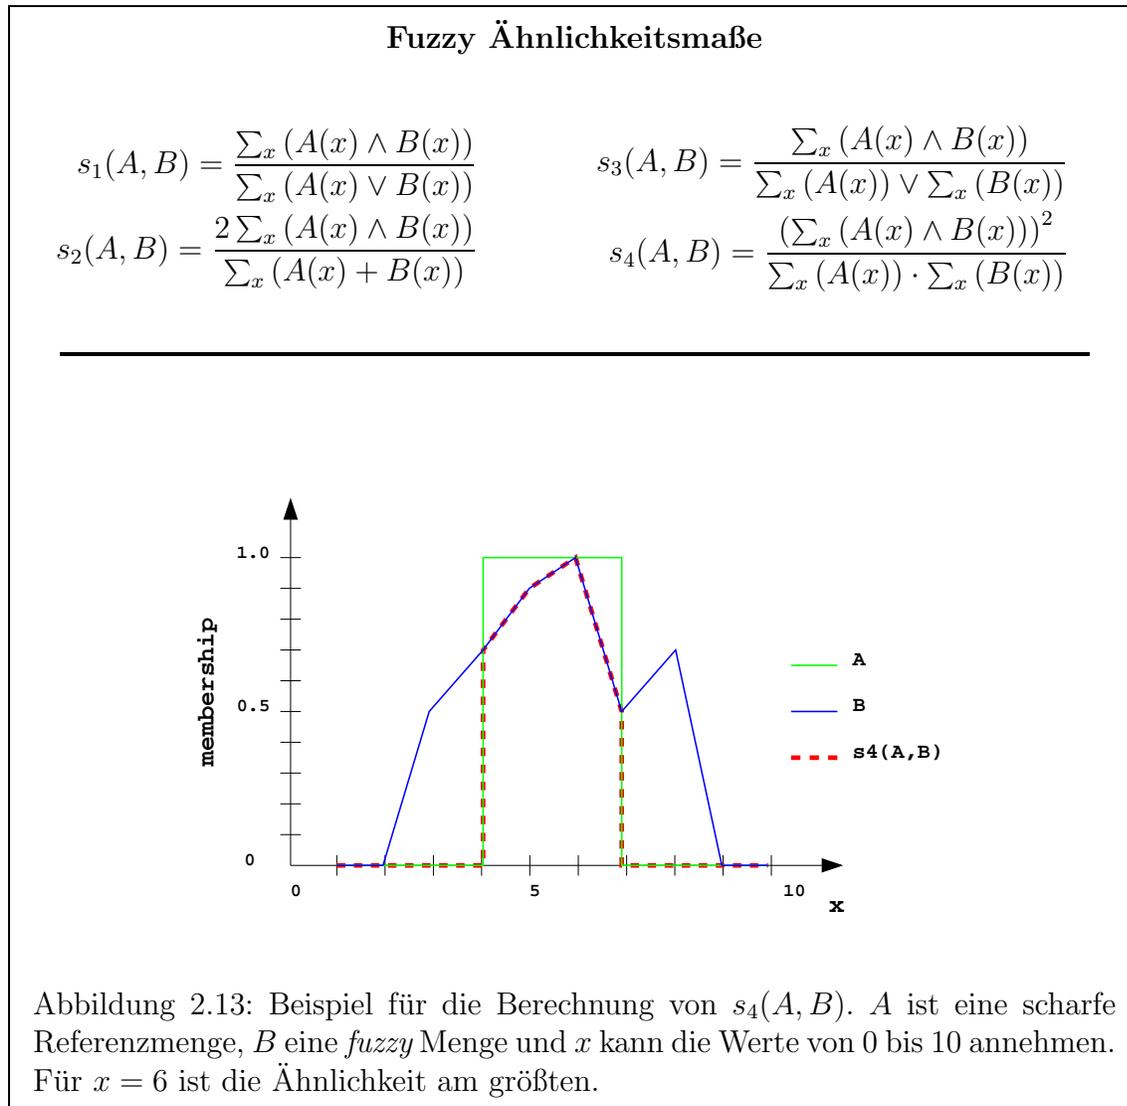
2.4.3.2 Fuzzy-Gütemaße

Für Fuzzy-Klassifikationen müssen die oben beschriebenen Gütemaße verändert werden, da nun jedes Pixel zu mehreren Klassen gehören kann. Um eine Vergleichbarkeit zweier Fuzzy-Mengen (Klassifikationen) zu erreichen, braucht man ein Ähnlichkeitsmaß für diese Mengen. Jäger und Benz definieren in [JB00] folgendes Ähnlichkeitsmaß:

Definition 2.1: Ein Fuzzy-Ähnlichkeitsmaß ist eine Abbildung $s : [0, 1]^X \times [0, 1]^X \rightarrow [0, 1]^X$, die zwei Fuzzy-Mengen $A, B \in [0, 1]^X$ einen "Grad der Ähnlichkeit" $s(A, B) \in [0, 1]$ zuweist, wobei folgende Bedingung erfüllt werden:

- (S1) $s(A, A) = 1$ für jede Fuzzy-Menge A
- (S2) $s(A, B) = s(B, A)$ für alle Fuzzy-Mengen A, B
- (S3) $s(A, C) \leq s(A, B) \cap s(B, C)$ wenn $A \subset B \subset C$

Mit Hilfe dieser Definition lassen sich nun verschiedene Ähnlichkeitsabbildungen definieren, die als Gütemaße fungieren können.



Die Abbildung s_3 entspricht dem verallgemeinerten Minimum von *Producer's* und *User's Accuracy*

$$FA_{s_3}(i) = PA(i) \wedge UA(i). \quad (2.54)$$

Die Abbildung s_4 entspricht dem verallgemeinerten Produkt von *Producer's* und *User's Accuracy*

$$FA_{s_4}(i) = PA(i) \cdot UA(i). \quad (2.55)$$

In den Untersuchung wird das Fuzzy Produkt aus *Producer's* und *User's Accuracy* verwendet. Das Beispiel in Abbildung 2.13 zeigt eine *fuzzy* Menge B und eine scharfe Referenzmenge A . Das Produkt aus beiden ist gestrichelt eingezeichnet. In Zahlen sieht die Rechnung für die beiden Produkte s_3 und s_4 wie folgt aus:

$$A = (0, 0, 0, 1, 1, 1, 1, 0, 0, 0)$$

$$\begin{aligned}
B &= (0, 0, 0.5, 0.7, 0.9, 1, 0.5, 0.7, 0, 0) \\
s_4(A, B) &= \frac{(\sum \min(A, B))^2}{\sum A \cdot \sum B} \\
&= \frac{(\sum \min((0, 0, 0, 1, 1, 1, 1, 0, 0, 0), (0, 0, 0.5, 0.7, 0.9, 1, 0.5, 0.7, 0, 0)))^2}{\sum(0, 0, 0, 1, 1, 1, 1, 0, 0, 0) \cdot \sum(0, 0, 0.5, 0.7, 0.9, 1, 0.5, 0.7, 0, 0)} \\
&= \frac{(\sum(0, 0, 0, 0.7, 0.9, 1, 0.5, 0, 0, 0))^2}{4 \cdot 4.3} \\
&= \frac{9.61}{17.2} = 0.559 \\
s_3(A, B) &= \frac{(\sum \min(A, B))}{\max(\sum A, \sum B)} \\
&= \frac{(\sum \min((0, 0, 0, 1, 1, 1, 1, 0, 0, 0), (0, 0, 0.5, 0.7, 0.9, 1, 0.5, 0.7, 0, 0)))}{\max(\sum(0, 0, 0, 1, 1, 1, 1, 0, 0, 0), \sum(0, 0, 0.5, 0.7, 0.9, 1, 0.5, 0.7, 0, 0))} \\
&= \frac{(\sum(0, 0, 0, 0.7, 0.9, 1, 0.5, 0, 0, 0))}{\max(4, 4.3)} \\
&= \frac{3.1}{4.3} = 0.689
\end{aligned}$$

Die beiden anderen Abbildungen s_1 , s_2 sind Verallgemeinerung zweier anderer Maße, der *Hellden's* und der *Short's Accuracy*. Jäger und Benz zeigen auch, daß im *crisp* Fall die eingeführten Fuzzy-Gütemaße den klassischen *Crisp*-Gütemaßen *producer's* und *user's accuracy*, bzw. daraus abgeleiteten Größen, entsprechen.

2.5 Fusion von fuzzy-klassifizierten Karten

Unter Fusion versteht man die Zusammenfassung unterschiedlicher Daten oder Klassifikationen, um einen Informationsgewinn zu erhalten. Die hier getesteten Fusionsverfahren basieren auf der Fusion von Fuzzy-Klassifikationen. Diese Fuzzy-Klassifikationen können auf Daten aus unterschiedlichen Quellen (optische und SAR Daten) basieren, oder z.B. aus den verschiedenen Spektralkanälen einer Quelle entstanden seien. In dieser Arbeit wurden zehn Spektralkanäle des DAEDALUS Sensors kanalweise klassifiziert und dann fusioniert. Dabei werden die vorher beschriebenen Gütemaße als Gewichtungsfaktoren benutzt. Es wurden zwei verschiedene Fusionsverfahren getestet, eine konvexe Linearkombination von Fuzzy-Klassifikation [BJ99] und eine Fusion mittels eines drei-schichtigen neuronalen *feedforward* Netzes, das mit *backpropagation* trainiert wird [JBS00].

2.5.1 Konvexe Linearkombination

Die konvexe Linearkombination fusioniert verschiedene Fuzzy-Klassifikationen eines Gebietes. Die Fuzzy-Klassifikationen wurden mit einem der vorher beschriebenen Verfahren bestimmt. Die erhaltenen N Klassifikationen F^1, \dots, F^N (z.B. entsprechend den Kanälen,

aus denen ein multispektrales Bild besteht) ordnen jedem Pixel für jede der K Klassen eine Zugehörigkeit zu: $F^i = (u_1^i, \dots, u_k^i)$ zu. Diese Werte genügen den Bedingungen der probabilistischen Fuzzy-Klassifikation, d.h. $0 \leq u_k^i \leq 1$ $\sum_k u_k^i = 1$, mit $i = 1, \dots, N$ und $k = 1, \dots, K$. Die Klassifikationen fusioniert man über eine konvexe Linearkombination der Fuzzy-Klassifikationen:

$$F = \lambda_1^1 F^1 + \dots + \lambda_N^k F^N, \quad \sum_{i,k} \lambda_i^k = 1, \quad (2.56)$$

(s. [BJ99]), zu einer neuen Klassifikation F . Die konvexe Linearkombination bedingt, daß die Zugehörigkeiten u_i der einzelnen Pixel auch nach der Fusion wieder im Intervall $[0, 1]$ liegen und die Summe über alle Klassen eins ist. Die λ_i^k sind Gewichte, welche die Güte der Klassifikation F^i bei der Klasse k beschreiben. Diese Gewichte lassen sich aus der Konfusionsmatrix oder Fuzzy-Gütemaßen ableiten.

2.5.2 Fusion mittels eines Neuronalen Netzes

Wie bei der Fusion über die konvexe Linearkombination werden verschiedene Klassifikationen zusammengeführt. Der wesentliche Vorteil der Fusion mittels eines neuronalen Netzes zur Fusion mittels einer konvexen Linearkombination ist, daß die einzelnen Klassifikationen jetzt unterschiedliche Klassenanzahlen haben dürfen. Auch braucht keine Information über die Güte der einzelnen Klassifikationen gegeben sein.

Das neuronale Netz verfügt dabei über drei Schichten, eine Eingabeschicht mit $N_{input} = \sum_{k=1}^N n_k$ Neuronen, wobei N die Anzahl der Klassifikationen ist und n_k die Anzahl der Klassen der k -ten Klassifikation, einer verdeckten Schicht mit

$$N_{hidden} = (2N_{input} + N_{output}) / 3 \quad (2.57)$$

Neuronen und N_{output} Neuronen in der Ausgabeschicht. N_{output} entspricht der Anzahl der gewünschten Klassen. Eine Referenzkarte, die N_{output} Klassen haben muß, dient zum Training des Netzes mittels des *backpropagation* Algorithmus. Nach dem Training wird das Netz mit den gelernten Gewichtungen auf die Klassifikationen angewandt und man erhält eine neue Klassifikation. Dieses Ergebnis kann entweder *crisp* dargestellt werden, indem man jeweils die maximale Aktivierung (größte Zugehörigkeit) als Klasse annimmt, zu welcher der Pixel gehört, oder weiterhin als Fuzzy-Klassifikation. Jeder Pixel hat dann eine bestimmte Zugehörigkeit zu einer Klasse, womit man unsichere Klassifikationen besser erkennen kann [JBS00].

3 Daten

Für die Untersuchungen, die im Rahmen dieser Diplomarbeit gemacht werden, wurden aus dem Bildmaterial des Nürnberg-Überflugs von 1997 vier repräsentative Testgebiete ausgewählt. Im folgenden wird kurz die Art der Datennahme und Vorverarbeitungen beschrieben.

3.1 Herkunft und Gewinnung von Reflektanzbildern

Die Daten, auf denen die Verfahren getestet wurden, sind 10-kanalige, digitale 8-bit, optische und nahinfrarote Luftbilder, die vom Flugzeug aus aufgenommen wurden. Es wurde nur eine Panoramaentzerrung und eine Atmosphärenkorrektur, aber keine Geocodierung vorgenommen. Durch die Atmosphärenkorrektur erhält man Reflektanzbilder (Kap. 2.1.4), d.h. den Quotienten aus Einstrahlung und Abstrahlung. Das Reflektanzbild sollte unabhängig von der Sonneneinstrahlung sein, da sowohl die direkte als auch indirekte Strahlung berücksichtigt werden. Leider verbleiben Unterschiede zwischen direkt beleuchteten und nur indirekt beleuchteten Flächen (u.a. BRDF Effekte, unzureichende Atmosphären-Daten und -Modelle).

Die Luftbilder wurden am Mittag des 26. August 1997 bei sonnigem Wetter über Nürnberg aufgenommen. Es wurde aus verschiedenen Flughöhen aufgenommen:

- 300 m entspricht einer Nadir¹-Auflösung vom ca. 0,80 m
- 900 m entspricht einer Nadir-Auflösung von ca. 2,40 m

Die zur Validierung der Bodendaten gemachten CIR-Luftfotos wurden aus 900 m Höhe mit einem Maßstab von 1:6000 gemacht. In Abbildung 3.1 ist die mit 600 dpi eingescannte Aufnahme des Testgebietes *Andernacherstr.* zu sehen. Die Flugrichtung war ungefähr Ost-West, was dazu führt, daß die gezeigten Bildausschnitte nicht genordet sind.

Der Sensor und das Flugzeug wurden vom Institut für Optoelektronik des DLR gestellt und kalibriert. Die Umrechnung von Pulshöhen in Reflektanzen erfolgte später mit Hilfe der in Kapitel 2.1.4 beschriebenen Verfahren.

¹Nadir ist die Richtung, die genau senkrecht von Flugzeug zum Boden führt.



Abbildung 3.1: Industriegebiet Andernacher Str. CIR-Luftbild.

3.2 Detektor: DAEDALUS AADS 1268

Der DAEDALUS AADS 1268² ist ein Zeilenscanner zur Aufnahme digitaler multispektraler Luftbilder. In Abbildung 3.2 ist ein schematischer Aufbau des Detektors dargestellt. Es wird die Intensität der einfallenden Strahlung in 11 Wellenlängenbereichen (s. Tab.3.1) zwischen $0.42\mu\text{m}$ und $13\mu\text{m}$ gemessen. Die einzelnen Detektoren liefern elektronische Signale, die proportional zur Strahlungsleistung sind. Diese Signale werden mittels eines A/D Wandlers³ in jeweils 8 Bit (entspricht 256 verschiedenen Werten) aufgezeichnet. Dies führt zu Problemen bei Kanälen, die einen großen Intensitätsbereich aufweisen (z.B. Kanal 4 ist bei einem Reflektanzwert von 135^4 gesättigt). Es kommt entweder zu einer Sättigung im oberen Intensitätsbereich (z.B. spiegelnde Metalldächer) oder zu einer (zu) wenig differenzierten Abstufung im niedrigen Intensitätsbereich (Schattengebiete).

Kanalnummer	$\lambda_1[\mu\text{m}]$	$\lambda_2[\mu\text{m}]$	$\Delta\lambda[\mu\text{m}]$	Detektormaterial
1	0.42	0.45	0.03	Si
2	0.45	0.52	0.07	Si
3	0.52	0.60	0.08	Si
4	0.605	0.625	0.02	Si
5	0.63	0.69	0.06	Si
6	0.695	0.75	0.055	Si
7	0.76	0.90	0.14	Si
8	0.91	1.05	0.14	Si
9	1.55	1.75	0.2	InSb
10	2.08	2.35	0.27	InSb
11	8.5	13.0	4.5	HgCdTe

Tabelle 3.1: Wellenlängenbereiche des DAEDALUS Detektors;
 λ_1 Wellenlängenbereichsanfang; λ_2 Wellenlängenbereichsende; $\Delta\lambda$ Bandbreite

Der Name Zeilenscanner leitet sich daraus ab, daß der Scanner nur aus einem Sensor pro Kanal besteht, der über eine Optik beleuchtet wird. Diese Optik bildet mit einem Scanspiegel (s. Abb. 3.2) eine Bildzeile auf den Sensor ab.

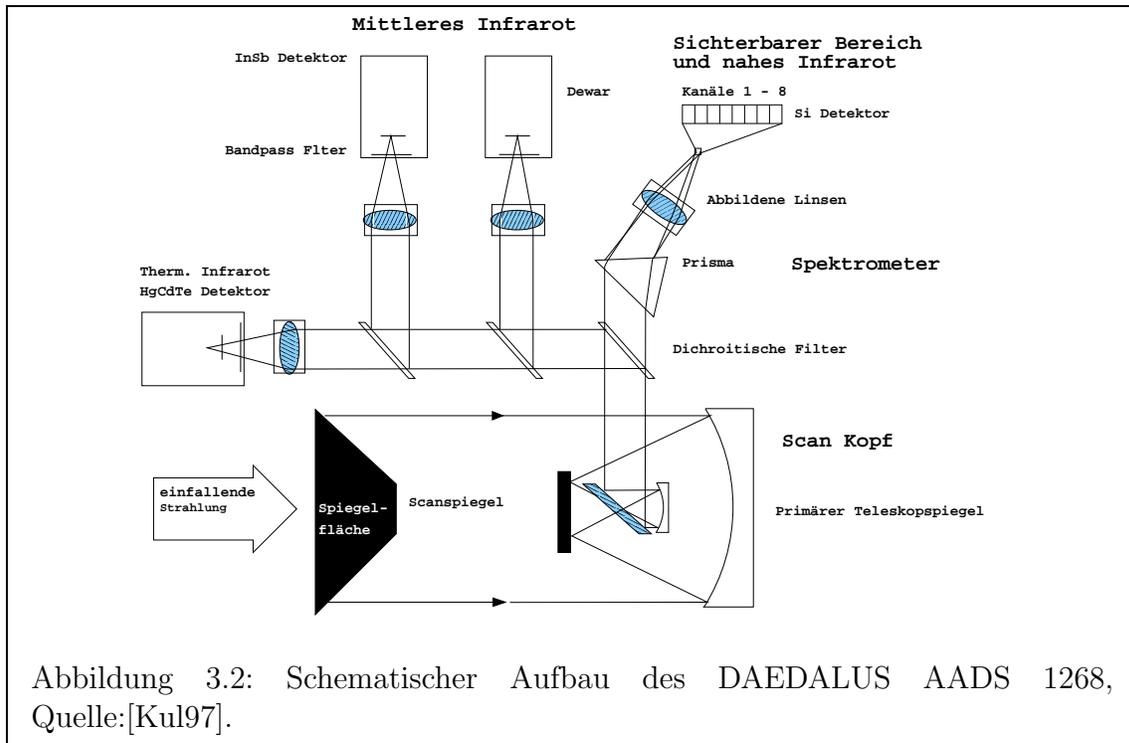
3.2.1 Bildgeometrie und Verzerrungen

Bildgeometrie Die Bildgeometrie der Aufnahmen des DAEDALUS ist durch die optischen Bauteile und die Flugbahn bestimmt. Erst durch die Flugzeugbewegung entsteht

²Hersteller Daedalus Enterprises Inc. (USA)

³Analog/Digital Wandler digitalisiert analoge Signale, wie z.B. unterschiedliche Spannung, in diskrete Werte.

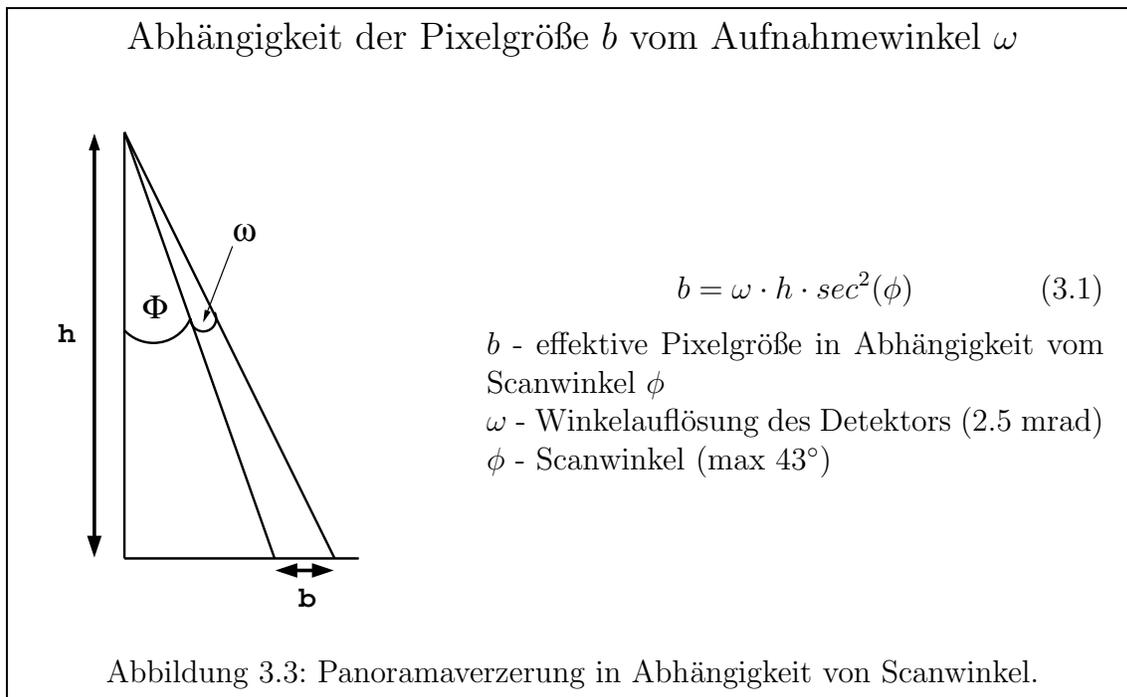
⁴Reflektanzwerte werden in dieser Arbeit nicht in Prozent, sondern in Werten von 0 bis 255 angegeben (entsprechend den 8 Bit der DAEDALUS Daten)



ein Bild, dessen Größe von der Flughöhe, der Spiegelauslenkung und der Länge des überflogenen Gebietes abhängt.

Aus der Flughöhe und der Frequenz, mit welcher der Scanner betrieben wird, resultiert eine Schrittweite der Aufnahmen von 0.12° . Dabei durchläuft der Scanspiegel einen Winkelbereich von $+43^\circ$ nach -43° Off-Nadir. Dadurch entsteht eine Flugstreifenbreite von 716 Pixeln. Die Fläche, die ein Pixel darstellt, ergibt sich aus der Fenstergröße des Detektors (engl. *instantaneous field of view (IFOV)*), dem Auslenkungsgrad des Scanspiegels und der Flughöhe. Das IFOV beträgt $2,5$ mrad. Das entspricht einer Nadir-Pixelbreite von 2.5 m und einer Zeilenbreite von 1.87 km (s. Gl.3.1) bei einer Flughöhe von 1000 m.

Verzerrungen Durch den Schwenkbereich von insgesamt 86° kommt es zu einer Panoramaverzerrung (s. Abb. 3.3). Diese Verzerrung bewirkt, daß die Pixel zum Rand hin eine größere Fläche darstellen als die Pixel im Nadir-Bereich und auch nicht ortstreu abgebildet werden (eine Straße senkrecht zur Flugrichtung wird S-förmig abgebildet). Diese Panoramaverzerrung kann man durch eine entsprechende Transformation rückgängig machen. Dabei werden u.a. die Pixel zum Rand hin vervielfacht, so daß jeder Pixel die gleiche Bodenfläche darstellt. Bei den DAEDALUS Daten wird dabei die Breite des Flugstreifens von 716 Pixeln auf 1000 Pixel erhöht. Andere Verzerrungen kommen durch die Flugzeugbewegungen hinzu. Diese Verzerrungen setzen sich aus globalen und lokalen Verzerrungen zusammen und müssen über ein lokales Transformationsverfahren herausgerechnet werden (z.B. das Akima Registrierungsverfahren s. [Zen00, Ric99]).



3.2.2 Kalibration

Die Kalibration des DAEDALUS Sensors wurde von der DLR in Oberpfaffenhofen vorgenommen. Die Kalibration dient zur Umrechnung von Werten, die an dem A/D Wandler gemessen werden, in die physikalische Größe Strahlungsfluß. Die Kalibrationsdaten lagen unserer Arbeitsgruppe vor, um einen Vergleich mit eigenen Messung machen zu können. Dazu wurden von unser Arbeitsgruppe Vergleichsspektren von sechs ausgewählten Flächen während des Überfluges gemessen [RKS98]. Die Messungen wurden mit einem hochauflösenden Radiospektrometer vom Typ IRIS Mark IV der Firma GER (USA) gemacht. Das Spektrometer verfügt über 862 Kanäle im Bereich von 300 nm bis 2500 nm. Mit Testflächen läßt sich die Kalibrierung der DAEDALUS Daten überprüfen und gegebenenfalls korrigieren. Es ergaben sich Abweichungen zwischen den Meßwerten des DAEDALUS und des IRIS Spektrometers. Die Untersuchung ergab einen Unterschied zwischen den IRIS und DAEDALUS Messung der zwischen $2\% \pm 1.2\%$ (Kanal 3, 9 Uhr morgens) und $76\% \pm 12.2\%$ (Kanal 10, 12 Uhr mittags) liegt⁵. Die verwendeten Daten wurden daher nicht auf die IRIS Messungen korrigiert. Dies hat bei der Annahme eines linearen Transformationsansatzes für die Klassifikation keine Bedeutung. Durch eine lineare Transformation der einzelnen Kanäle würde nur die Länge der Merkmalsvektoren verändert, nicht aber ihre Lage zueinander.

⁵persönliche Mitteilung von A. Rothkirch

4 Klassenauswahl und Testgebiete

Aus den 900 m Überfliegungsdaten wurden vier Testgebiete ausgewählt, die repräsentativ für das Stadtgebiet Nürnberg stehen. Ein Industriegebiet (Andernacherstr. , Abb. 4.1 unten links), zwei Innenstadtgebiete (Stadtteil Rennweg und Altstadtzentrum mit Pegnitz, Abb. 4.1 oben rechts und oben links) und ein Stadtrandgebiet (Stadtteil Thon, Abb. 4.1 unten rechts). In diesen Teilgebieten wurden Referenzgebiete für die Validierung der Klassifikation markiert. Die Auswahl der Testgebiete soll dazu dienen, die unterschiedlichen Klassen darzustellen, die bei der Klassifizierung städtischer Gebiete vorkommen.

4.1 Referenzgebiete

Um Trainingsgebiete für die Klassifikation zu erhalten und die Ergebnisse der Klassifikation bewerten zu können, muß man Referenzgebiete auswählen. Diesen Gebieten weist man per Hand bestimmte Klassen zu und erstellt so eine Validierungskarte (oder engl. *groundtruth map*).

Bei den zur Klassifikation benutzten 900 m Aufnahmen gab es einige Schwierigkeiten, eine gute Zuordnung zu machen, da selbst im Nadirbereich die Pixelauflösung ca. 2.5 m beträgt. Das bedingt, daß z.B. Bürgersteige nur ein Pixel breit sind. Trotzdem lassen sich auch auf diesen Bildern Oberlichter und Lüftungsanlagen erkennen, die bei der Einteilung von Dachklassen ausgeklammert werden müßten, um möglichst genaue Aussagen machen zu können. Um ein gutes Verhältnis zwischen dem Zeitaufwand der Erstellung der Validierungskarte und dem Ergebnis einer Klassifikation zu erreichen, muß man sich für eine begrenzte Genauigkeit bei der Auswahl der Trainingsgebiete entscheiden. Dadurch und durch die Ungenauigkeiten, welche durch die Interpretation der Luftfotos entstehen, lassen sich Fehlzuzuweisungen einzelner Pixel bei der Erstellung der Validierungskarte nicht vermeiden. Daraus folgt, daß bei der Angabe von Gütemaßen (s. Kap.2.4.3) noch der Unsicherheitsfaktor dieser Fehlzuzuweisung berücksichtigt werden muß.

In der Abbildung 3.1 auf Seite 48 ist eine Validierungskarte des Testgebietes Andernacherstraße zu sehen. Es sind Flächen der Klassen aus Tabelle 4.3 auf Seite 60 markiert. Die Zuordnungen der Pixel zu bestimmten Klassen ist nicht einfach. Man kann nur schwer entscheiden, wo z.B. ein Dach endet und eine Straße anfängt. Scheinbar gleich aussehende Gebiete können spektral unterschiedlich sein. Man muß bei der Auswahl die Spektren der Pixel betrachten, um Unterschiede, die man nicht in einem Spektralkanal sehen kann, zu erkennen. Bei der Auswahl der Gebiete oder Objekte sollte man sich nicht immer an sehr eindeutigen Signaturen orientieren, da ja auch Flächen klassifiziert werden sollen, die



Abbildung 4.1: Die vier Testgebiete Andernacherstr. (u.l.), Thon (u.r.), Altstadt (o.l.), Innenstadt (u.l.) im Kanal 6 der Multispektralbilder. Der Kanal wurde mittels der IDL Funktion *hist_equal* aufgehellt. Die einzelnen Sub-Bilder sind jeweils 400×400 Pixel groß.

für die menschliche Wahrnehmung noch zu erkennen sind, aber keine eindeutig spektrale Signatur haben. Bei der Vegetation ist der Vergleich mit den CIR-Fotos (s. Abb.4.1), auf denen die Vegetation stark rot ist, da Pflanzen ihre maximale Abstrahlung im Infraroten haben, sehr nützlich. Es zeigte sich ein großer Unterschied zwischen regelmäßig bewässerten Flächen (auf dem CIR-Foto stark rot), wie Feldern oder Sport- und Tennisplätzen und Wiesen, die brachliegen und im Sommer austrocknen (auf dem CIR-Foto rotbraun). Um eine möglichst gute Einschätzung der Flächen vornehmen zu können, sollte man eine Begehung der Gebiete machen, die man als Testgebiete gewählt hat. Schatten ist eine weitere Quelle, die Probleme verursacht. In Schattengebieten ist die Pulshöhe sehr niedrig, was zu Fehlklassifizierung führt, da diese Flächen dann eine sehr große Ähnlichkeit zu anderen spektralen Signaturen, wie z.B. Wasser, haben. Man könnte versuchen, Schatten als eigene Klasse zu klassifizieren und diese Klasse bei der Bewertung ausblenden¹. Zu den Dachklassen, die im Industriegebiet benutzt werden, kommen in den anderen Testgebieten noch weitere hinzu, da es z.B. im Innenstadtbereich geneigte Ziegeldächer (im weiteren Giebeldächer genannt) unterschiedlicher Farbe gibt. Außerdem sind die Gebäude höher, so daß im Off-Nadir-Bereich große Fasadflächen zu sehen sind, die stark reflektieren.

4.2 Klassenauswahl

Vor der Klassifizierung wurde eine Suche nach anwendungsnahen Klassen durchgeführt. Dabei wurden verschiedene Objektartenkataloge (OK) untersucht, die zum Teil regionalen Charakter haben, zum Teil bundesweit standardisiert sind (z.B. ATKIS-OK²). Diese OK dienen als Grundlage für die Katasterämter bei der Erstellung von Flächennutzungsplänen. OK sind für digitale GIS³, die eine CAD⁴ Schnittstelle haben und somit direkt mit Architekten und Planungsbüros zusammenarbeiten, konzipiert. Die Fülle und Genauigkeit der Angaben macht eine direkte Nutzung des Objektartenkatalogs von ATKIS nicht möglich, da die digitalen Karten nicht die Probleme der Vegetation, der Verdeckung durch die Höhe von Objekten oder der Abschattung haben. Es wurde aber deutlich, welchen Anspruch Städteplaner an den Informationsgehalt einer Karte haben.

Bei einem Gespräch mit Herrn Seidler⁵ vom Amt für Geoinformation und Bodenkunde in Nürnberg ergaben sich weitere Erkenntnisse über die möglichen Anwendung für eine

¹Die Ausblendung von Schattengebieten erfolgt über Schattenfilter, die bestimmte Merkmale ausnutzen, um Schatten zu erkennen. Dabei gibt es zwei grundsätzlich Vorgehensweisen. 1. Schatten zeichnet sich durch niedrige Reflektanzen aus. Durch das Setzen eines Schwellwerts in einem entsprechendem Kanal, kann man Schattenpixel selektieren. Hierbei muß man beachten, daß man auch andere Flächen mit selektiert, die von sich aus niedrige Reflektanzen haben. 2. Man versucht über Umgebungsmerkmale Schatten zu detektieren, wie z.B. dunkle Flächen neben Hausdächern sind Schatten.

²ATKIS-OK - Amtliches Topographisches-Kartographisches Informationssystem Objektartenkatalog, von der Arbeitsgemeinschaft der Vermessungsverwaltungen definiert.

³GIS - Geographische Informationssysteme

⁴CAD - Computer Aided Design

⁵Dipl. Ing. Frank Seidler, Abteilungsleiter, Stadt Nürnberg - Amt für Geoinformation und Bodenkunde, Abteilung Topographie und Kartographie, Bauhof 5, 90402 Nürnberg

Klassifikation von Multispektralbildern städtischer Gebiete. Herr Seidler nannte u.a. die Bestimmung der versiegelten Fläche auf einem Grundstück. Diese versiegelte Fläche dient als Bemessungsgrundlage für die Berechnung bestimmter Abgaben. Die automatische Berechnung der Versiegelung eines Grundstück, die durch den Vergleich einer georeferenzierten Versiegelungskarte mit vorhandenen Grundstückskarten erfolgen könnte, wäre ein potentiell Einsatzgebiet. Eine andere Anwendung könnte die Klassifizierung nach Klassen des Amtes für Stadtforschung und Statistik Nürnberg sein, welches städtische Flächen nach der Realnutzung einteilt. Die Karte des Raumbezugsnetzes hat in digitaler Form eine Auflösung von 1:5000, d.h. daß die DAEDALUS Daten ausreichend sein müßten.

4.2.1 Klassenauswahl für die Bodenversiegelungskarte

In Nürnberg gibt es eine Abgabe, die sich nach der Fläche des versiegelten Bodens auf einem Grundstück richtet. Eine automatische Erkennung und Überprüfung der Bodenversiegelung wäre deshalb sehr hilfreich. Für eine Detektion der Versiegelung muß eine Auswahl getroffen werden, die eine gute Trennung möglich macht. Es ist am einfachsten sich die Klassen zu überlegen, die keiner Versiegelung entsprechen.

- Vegetation: Bäume, Wiesen, Felder(bewirtschaftet)
- Sand, Erde, Ackerflächen (unbewirtschaftet)
- Gewässer: Flüsse, Seen

Die Einteilung in drei Klassen für die Versiegelung geschieht aufgrund der Tatsache, daß es eine Klasse "Wasser" gibt, die häufiger bei der Klassifikation mit Schatten wechselt wird und deshalb gesondert betrachtet werden sollte.

4.2.2 Klassen des Amtes für Stadtforschung und Statistik Nürnberg

Das Amt für Stadtforschung und Statistik der Stadt Nürnberg hat in Zusammenarbeit mit dem Umweltamt eine Karte über die Realnutzung der städtischen Flächen erstellt, die auch `Online` abrufbar ist ⁶. Die Berechnung der Nettoflächen erfolgt mit Hilfe des Raumbezugsnetzes. Die Realnutzung wurde über eine Erhebung des Umweltamtes bestimmt. Bei dieser Erhebung könnte eine automatische Klassifikation helfen. Das Amt hat dabei 42 verschiedene Nutzungsarten definiert (s. Tab. 4.1).

In der Tabelle fällt auf, daß es viele Klassen gibt, die einen sehr hohen Informationsgehalt haben, der sich direkt aus der Nutzung ergibt (z.B. "Zoo" oder "Bahnbegleitgrün"). Um diese Informationsklassen durch eine Klassifikation abbilden zu können, bedarf es weiterer Informationen über die Objekte. Die Klasse "Bahnbegleitgrün" ließe sich durch die Nachbarschaft von den Klassen "Schienen" und "Vegetation" definieren. Eine Klasse

⁶www.nuernberg.de

nutz	fntk	Art	nutz	fntk	Art
0	46	Plätze (Festpl.)	5	44	Friedhöfe
0	70	Straßen	5	45	Kleingärten
0	73	Straßenbegleitgrün	5	48	Sportplätze
0	75	Parkpl. und Verkehrsknotenpunkte	5	49	Wochenendgeb.
1	11	Blockrand	6	47	Brachen
1	12	Einzelhausbebauung	6	51	Acker
1	13	Hochhäuser	6	52	Gärtnereien, Gemüseanbauf.
1	14	Blockbebauung	6	53	Koppeln und Reitplätze
1	15	Reihenhäuser	6	55	Gewächshäuser
1	16	Villen	6	56	Grünland
1	17	Zeilenbeb.	7	31	Laubwald
1	21	Landw. Betriebe	7	32	Mischwald
1	22	Kerngeb. und Dorfreste	7	33	Nadelwald
2	50	Industrie	8	81	Fließende Gewässer
3	90	Infrastruktur	8	82	Kanal
4	71	Bahnbegleitgrün	8	83	Stehende Gewässer
4	76	Bahnanlagen	9	61	Steinbrüche
5	40	Zoo	9	62	Mülldeponie
5	41	Parks und Grünanlagen	9	63	Sandgruben
5	42	Freibäder	9	64	Milit. Anlagen
5	43	Campingplatz	9	72	Flughafen

Tabelle 4.1: Nutzungstypen des Amt für Statistik Nürnberg

fntk: Kategorien des Umweltamtes; **nutz**: Kategorien für die Flächendarstellung in einer **Online**-Karte.

“Campingplatz” läßt sich hingegen nicht aus Form oder der Lage von Klassen zueinander ableiten. Für solche Klassen muß eine manuelle Einteilung erfolgen.

4.2.3 Auswahl für die Klassifizierung relevanter Klassen

Die Zielsetzung der Klassenauswahl ist eine möglichst genaue automatische Klassifikation der Klassen. Dabei muß man einen Kompromiß finden zwischen Klassen, die sich spektral gut unterscheiden lassen und Klassen, die für einen potentiellen Nutzer interessant sind. Diese Klassen sollten

1. eindeutig sein, so daß sie durch verschiedene Klassifikationsverfahren identifizierbar sind,
2. in den Testgebieten vorkommen, da sonst keine Möglichkeit besteht, Klassifikatoren zu finden,
3. weitere Merkmale enthalten, die nicht nur eine spektrale Information wiedergeben. Hierbei kann es sich z.B. um die Form eines Segments (Hausdach) oder die direkte Umgebung eines Segments handeln⁷. Denkbar ist auch, die Entfernung von bestimmten Segmenten zueinander zu bewerten.

Der letzte Punkt wird in dieser Arbeit nicht weiter untersucht. In der Diplomarbeit von [Kul97] werden die in Tabelle 4.2 gezeigten Klassen benutzt. Diese Klassen dienen als Orientierung für die Auswahl der in dieser Arbeit benutzten Klassen. Die Bemerkung versiegelt bzw. nicht-versiegelt in Tabelle 4.2 zielt auf eine mögliche Nutzung (s. Kap. 4.2.1) der Klassifikation ab.

⁷Das Arbeitsgebiet objektorientierte Klassifikation ist Thema aktueller Forschung (Schlüsselthema bei der ISPRS 2000 Konferenz in Amsterdam). In der Arbeitsgruppe wird die Segmentierung bei der automatischen Detektion von Schattengebieten benutzt, um dunkle Hausdächer, die ein großes Verhältnis von Umfang zu Fläche aufweisen, von Schattengebieten zu trennen.

versiegelt	Material	nicht-versiegelt	Material
Industriefläche (Flachdach)	Metall	Wald (Bäume)	Vegetation
Industriefläche (Flachdach)	Asphalt		
Industriefläche (Flachdach)	Kiesel		
Wohnbaufläche (Spitzdach (bel))	Ziegel (rot)	Grünland (sch)	Vegetation
Wohnbaufläche (Spitzdach (sch))	Ziegel (rot)	Grünland (bel)	Vegetation
Fassade	Beton	Ackerland (bew)	Mischung: Er- de Vegetation
Fassade	Gestein		
Fassade	Ziegel		
Strasse (bel)	Asphalt	Ackerland (unbew.)	Mutterboden
Strasse (sch)	Asphalt	Vegetationslose Fläche	Sand
Bürgersteig	Asphalt	Schienenbahn	Mischung: Me- tall, Holz und Gestein
Parkplatz	Beton	Gewässer	Wasser
Fahrzeuge (Sonder- klasse)	Metall (farbig?)		
Markierungen (Son- derklasse)	weisse Farbe		
Vorfeld (Flughafen)	Beton		

Tabelle 4.2: Klassen aus der Diplomarbeit von D. Kulbach [Kul97]; Aufteilung in versiegelte und nicht-versiegelte Fläche.

4.3 Klassenauswahl in den Testgebieten

Die Auswahl der Klassen für die Testgebiete basiert auf den im vorherigen Abschnitt beschriebenen Klassen. Dabei wurden sowohl der optische Eindruck (maßgeblich die Helligkeit), den die Aufnahmen machen, als auch spektrale Signaturen zur Einteilung der Klassen benutzt. Es zeigt sich, daß es z.B. nicht reicht eine Klasse “Hausdächer” zu wählen, da diese zum einem sehr stark in der Helligkeit schwanken (Sonnenstand), zum anderem aus unterschiedlichen Materialien bestehen, die verschiedene spektrale Signaturen haben. Die verschiedenen Dachklassen bilden die größte Oberklasse mit 10 verschiedenen Unterklassen (s. Tabelle 4.7).

4.3.1 Gebiet: Andernacherstraße

Dieses Testgebiet gehört zu den in der Forschungsgruppe am häufigsten untersuchten Gebieten, da hier zu den Überflügen bodenbegleitende Messungen gemacht wurden. Die Andernacherstraße liegt in einem kleinen Gewerbegebiet im nördlichen Nürnberg, in der Nähe befindet sich der Nürnberger Flughafen. Umgeben ist das Gebiet von einem Naturschutzgebiet im Norden und Westen.

Klassen-Nr.	Bezeichnung	Pixelanzahl	Prozentanteil
1	Flachdach, schwarz	1291	0.8
2	Flachdach, dunkel	3341	2.0
3	Flachdach, hell	1608	1.0
4	Metalldach	1370	0.8
5	Kiesdach	3048	1.9
6	Straße	3474	2.1
7	Betonplatten	1023	0.6
8	Bäume	3709	2.3
9	Vegetation, trocken	1923	1.2
10	Vegetation, feucht	1991	1.2
11	Wasser	1207	0.7
12	Sand	287	0.1
	Gesamt	24272	15.1

Tabelle 4.3: Klasseneinteilung im Testgebiet Andernacherstraße. In der Spalte “Pixelanzahl”, ist die Anzahl der Pixel angegeben, die pro Klasse markiert wurden, um für das Training bzw. die Berechnung der Gütemaße zu fungieren. In der Spalte dahinter steht der jeweilige prozentuale Anteil am Bild. In der letzten Zeile ist die Gesamtanzahl der Pixel, die für die Validierung ausgesucht wurden, angegeben.

Die Einteilung der Klassen erfolgte hauptsächlich auf Grund der CIR-Fotos. In den ersten Versuchen habe ich mehr Klassen benutzt. Die in Tabelle 4.3 angegebenen Klassen sind die Auswahl, mit der ich am DLR die ersten Tests der Klassifikationsverfahren gemacht habe und die sich als sehr gut erwiesen. Die Tabelle 4.3 beschreibt die Klassen der Testszene. Die erste Spalte enthält die Klassennummer, mit der die Klasse in der Karte markiert ist. Die zweite Spalte enthält die Bezeichnung der Klasse und trägt damit die Information, die ein Nutzer verwenden kann. Die Spalten drei und vier geben die Anzahl der Trainingspixel an, die pro Klasse im Bild zur Verfügung stehen und deren prozentualen Anteil am Gesamtbild. Die Validierungskarte ist in Abbildung 4.2 dargestellt. Zur besseren Orientierung ist in Abbildung 4.3 der Kanal 6 des Multispektralbilds als Graustufenbild dargestellt. Dieses Bild ist mit der IDL Funktion `hist_equal`⁸ bearbeitet worden, um eine hellere Darstellung zu erhalten. Für die anderen Testgebiete sind in den nachfolgenden Abschnitten entsprechende Tabellen zu finden. Auffällig ist die Unterscheidung von drei Flachdach-Klassen, die mit Teerpappen gedeckt sind. Die Unterschiede kommen daher, daß die Teerpappe verschiedene Körnung hat und die Teerpappe unterschiedlich stark ausgebleicht ist. Die beiden Vegetationsarten sind auf den trockenen Sommer '97 zurückzuführen. Die feuchte Vegetation ist dort zu finden, wo die Fläche bewässert wird. Die Bewässerung kann man u.a. an runden Flecken, die von Sprengleranlagen stammen, erkennen. Die trockene Vegetationsklasse läßt häufig schon den trockenen Boden darunter erahnen. Das hat zur Folge, daß bei der Klassifikation keine einheitlichen Flächen mit trockener Vegetation erkannt werden, sondern dazwischen immer wieder Sand zu sehen ist. Die Klasse "Bäume" unterscheidet sich hauptsächlich durch die weite Streuung ihrer Reflektanzwerte von den anderen Vegetationsklassen. Die Klasse Sand ist mit Schotter vermischt. Beide Materialien reflektieren sehr stark, was zu einer ähnlichen Signatur führt wie die von Metalldächern.

⁸Die `hist_equal` Funktion verändert das Histogramm eines Bildes, d.h. die Verteilung der Grauwerte, so daß die Verteilung gleichmäßiger zwischen 0 und 255 liegt.

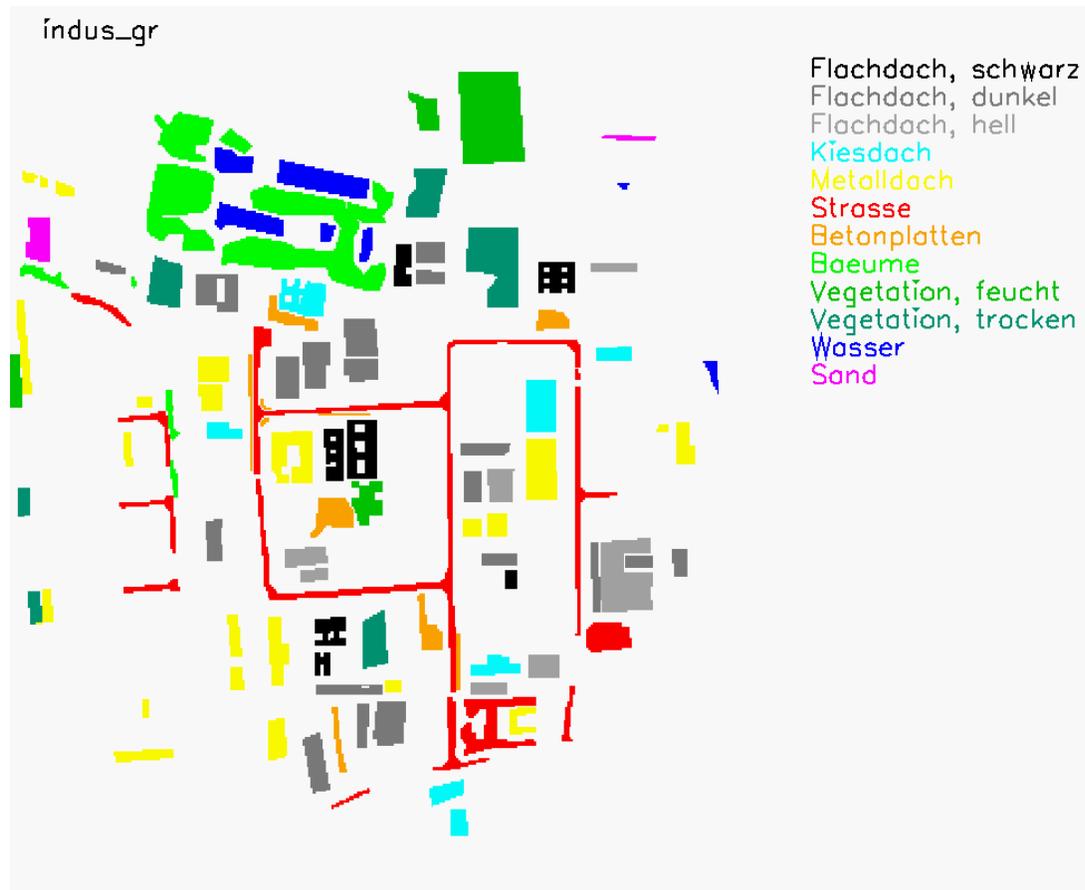


Abbildung 4.2: Validierungskarte Andernacherstr.: Nürnberg Andernacherstr., die Einteilung erfolgte nach der Klassenauswahl aus Tabelle 4.3. Die Klassen Kiesdach und Metalldach sind in der Legende falsch zugeordnet worden. Metalldach ist hellblau und Kiesdach gelb.



Abbildung 4.3: Nürnberg Andernacherstr. im Kanal 6 des Multispektralbilds. Der Kanal wurde mittels der IDL Funktion *hist_equal* aufgehellt.

4.3.2 Gebiet: Thon

Das Gebiet Thon wurde als Beispiel eines Stadtrandgebietes gewählt. Hier finden sich unterschiedliche Siedlungsformen, wie Einzel- und Reihenhausbauung, Industriegebäude, wie z.B. Lagerhallen, Bauernhöfe und die dazugehörigen Felder. Die Validierungskarte ist in Abbildung 4.4 dargestellt. Zur besseren Orientierung ist in Abbildung 4.5 der Kanal 6 des Multispektralsbilds als Graustufenbild dargestellt.

Klassen-Nr.	Bezeichnung	Pixelanzahl	Prozent
1	Flachdach, schwarz	1203	0.7
2	Flachdach, dunkel	279	0.1
3	Metалldach	328	0.2
4	Flachdach, braun	309	0.1
5	Kiesdach	910	0.5
6	Giebeldach, schwarz	2754	1.7
7	Giebeldach, beleuchtet	321	0.2
8	Straße	1811	1.1
9	Betonplatten	170	0.1
10	Sand	402	0.2
11	Wasser	62	0.0
12	Bäume	470	0.2
13	Vegetation, trocken	1532	0.9
14	Feld, Typ 1	900	0.5
15	Feld, Typ 2	782	0.4
16	Feld, Typ 3	200	0.1
	Gesamt	12433	7.7

Tabelle 4.4: Klasseneinteilung im Testgebiet Thon. Die drei verschiedene Feldtypen lassen sich wie folgt beschreiben: Typ 1 - hoher Bewuchs, hell; Typ 2 - flacher Bewuchs, dunkel; Typ 3 - hoher Bewuchs, dunkel.

In der Spalte "Pixelanzahl", ist die Anzahl der Pixel angegeben, die pro Klasse markiert wurden, um für das Training bzw. die Berechnung der Gütemaße zu fungieren. In der Spalte dahinter steht der jeweilige prozentuale Anteil am Bild. In der letzten Zeile ist die Gesamtanzahl der Pixel, die für die Validierung ausgesucht wurden, angegeben.

Bei den Wohnhäusern mit Giebeldächern macht sich der Einfluß der BRDF und der Unterschied zwischen direkter und diffuser Beleuchtung besonders stark bemerkbar. In diesem Testgebiet stehen die meisten Häuser so, daß zum Zeitpunkt der Aufnahme beide Hausdachhälften gleichmäßig beleuchtet wurden. D.h. eine Unterscheidung in beleuchtete bzw. schattige Hausdächer war nicht notwendig. Die Klasse "Giebeldach, schwarz"

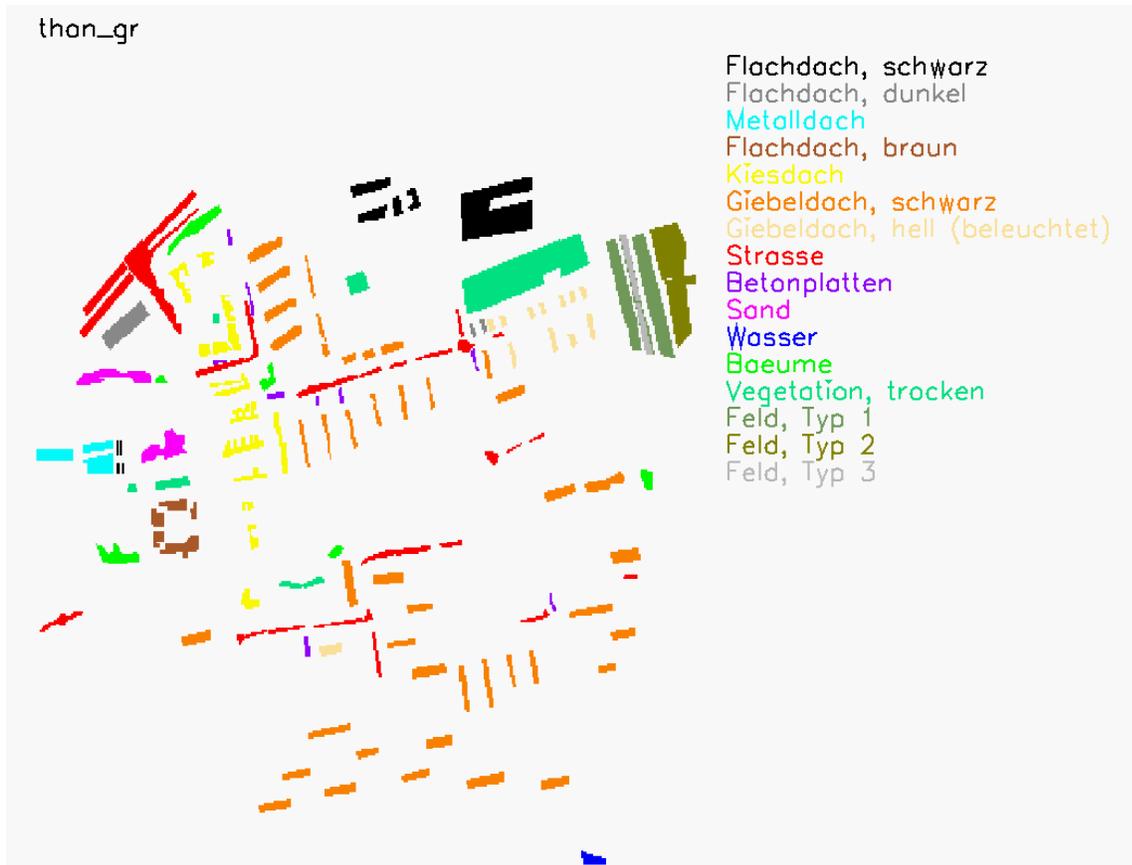


Abbildung 4.4: Validierungskarte Stadtrandgebiet:
Nürnberg Stadtteil Thon, die Einteilung erfolgte nach der Klassenauswahl aus Tabelle 4.4.



Abbildung 4.5: Nürnberg Stadtteil Thon, im Kanal 6 der Multispektralbilder. Der Kanal wurde mittels der IDL Funktion *hist_equal* aufgehellt.

ist durch die schwarzen Dachziegel gegeben, nicht durch den Einfluß von Schatten. Die unterschiedlichen Feldtypen wurden nur mit Nummern bezeichnet, da eine eindeutige Zuordnung zu Nutzungsarten nicht möglich war. Die Klasse Wasser ist nur mit 62 Pixeln vertreten, da nur eine sehr kleine Wasserfläche im Ausschnitt vorhanden ist.

4.3.3 Gebiet: Rennweg

Der Stadtteil Rennweg ist ein typisches Innenstadtgebiet.

Wie man in Abbildung 4.7 sehen kann, sind die Wohnhäuser in Blockbebauung gebaut. Am unteren Bildrand fängt der Stadtpark mit einer Teichanlage an. Am linken Bildrand ist ein Geschäfts- und Bürobegäude zu sehen, das ein Berufsbildungszentrum beherbergt. In der Straße am unteren Bildrand verläuft eine Straßenbahn.

Klassen-Nr.	Bezeichnung	Pixelanzahl	Prozentanteil
1	Flachdach, dunkel	1032	0.6
2	Flachdach, schwarz	314	0.1
3	Flachdach, braun	189	0.1
4	Kiesdach	306	0.1
5	Giebeldach, beleuchtet	952	0.5
6	Giebeldach, schattig	631	0.3
7	Giebeldach, schwarz	463	0.2
8	Bäume	1258	0.7
9	Vegetation, trocken	357	0.2
10	Vegetation, feucht	166	0.1
11	Sand	481	0.3
12	Wasser	89	0.0
13	Straße	1198	0.7
14	Betonplatten	321	0.2
15	Parkplatz, hell	120	0.0
	Gesamt	7877	4.9

Tabelle 4.5: Klasseneinteilung im Testgebiet Rennweg. In der Spalte “Pixelanzahl”, ist die Anzahl der Pixel angegeben, die pro Klasse markiert wurden, um für das Training bzw. die Berechnung der Gütemaße zu fungieren. In der Spalte dahinter steht der jeweilige prozentuale Anteil am Bild. In der letzten Zeile ist die Gesamtanzahl der Pixel, die für die Validierung ausgesucht wurden, angegeben.

Die zugehörige Validierungskarte ist in Abbildung 4.6 dargestellt. Die Beschreibung der Klassen ist in Tabelle 4.5 zu finden. Die Auswahl von Testflächen ist in diesem Gebiet schwierig, da

- die Auflösung mit fast drei Metern zu klein ist, um die kleinskaligen Strukturen aufzulösen
- durch die hohe Bauweise viele Straßen im Schatten liegen.

In diesem Testgebiet finden sich neben den schon erwähnten Klassen noch die Klasse “Flachdach, braun”, die Namensgebung beruht auf dem optischen Eindruck, sowie zwei unterschiedliche Giebeldachklassen und die Klasse “Parkplatz, hell”. Diese beiden Klassen, “Giebeldach, beleuchtet” und “Giebeldach, schattig” finden sich jeweils am gleichen Haus, nur daß aufgrund der Sonneneinstrahlung eine Hälfte direkt beleuchtet ist. Die Giebeldächer bestehen aus roten Ziegeln. Die Klasse “Parkplatz, hell” läßt sich aufgrund des CIR-Fotos und des Spektrums weder der Klasse “Betonplatten” noch der Klasse “Straße” zuordnen.

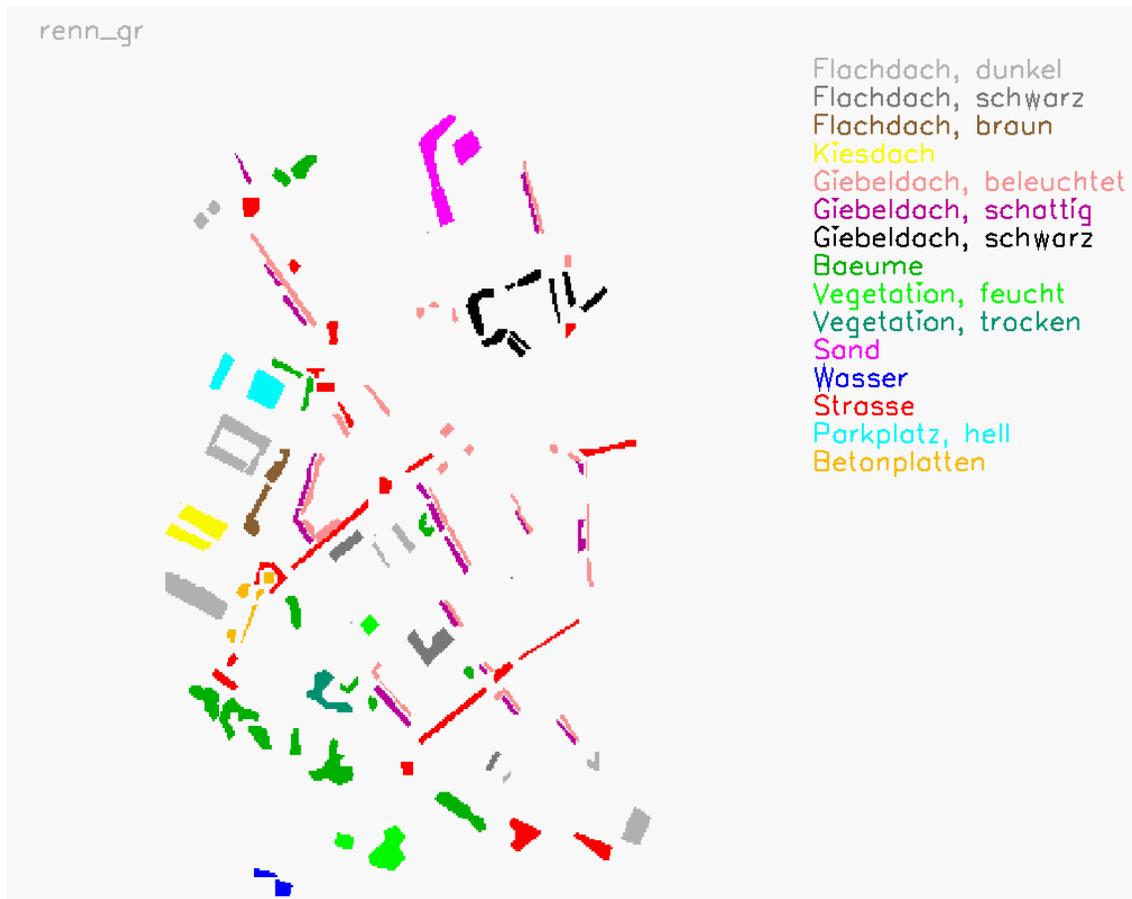


Abbildung 4.6: Validierungskarte Rennweg: Nürnberg Stadtteil Rennweg, die Einteilung erfolgte nach der Klassenauswahl aus Tabelle 4.5.



Abbildung 4.7: Nürnberg Stadtteil Rennweg im Kanal 6 der Multispektralbilder. Der Kanal wurde mittels der IDL Funktion *hist_equal* aufgehellt.

4.3.4 Gebiet: Innenstadt

Dieses Testgebiet stammt aus der Altstadt Nürnbergs. Es ist ähnlich aufgebaut wie das Innenstadtgebiet Rennweg. Durch die Altstadt fließt die Pegnitz, die hier zwei Inseln hat, wobei die untere bebaut ist. Die Ausrichtung des Bildes (s. Abb. 4.9) und der Validierungskarte (s. Abb. 4.8) ist nicht Nord-Süd, sondern eher West-Ost, da der Überflug in dieser Richtung stattfand und sich die Karte an der Geometrie der CIR-Fotos orientiert.

Klassen-Nr.	Bezeichnung	Pixelanzahl	Prozentanteil
1	Giebeldach, beleuchtet	5621	3.5
2	Flachdach, dunkel	471	0.2
3	Metалldach	570	0.3
4	Metалldach, blau	466	0.2
5	Flachdach, braun	343	0.2
6	Straße	5051	3.1
7	Parkplatz, hell	459	0.2
8	Bäume	2070	1.2
9	Vegetation, feucht	312	0.1
10	Wasser	2385	1.4
	Gesamt	17748	11.0

Tabelle 4.6: Klasseneinteilung im Testgebiet Innenstadt. In der Spalte “Pixelanzahl”, ist die Anzahl der Pixel angegeben, die pro Klasse markiert wurden, um für das Training bzw. die Berechnung der Gütemaße zu fungieren. In der Spalte dahinter steht der jeweilige prozentuale Anteil am Bild. In der letzten Zeile ist die Gesamtanzahl der Pixel, die für die Validierung ausgesucht wurden, angegeben.

Die Altstadt ist zwar auch in Blockbebauung bebaut, aber da die Häuser älter sind, sind die Dachflächen größer. Auch die Straßen sind hier breiter. In der Mitte des Ausschnitts ist der Hauptmarkt bei der Frauenkirche zu sehen. Die Straßen, die von dort nach Süden weggehen, sind Fußgängerzonen.

Die Klasse “Parkplatz, hell” entspricht wieder der Signatur aus dem Gebiet Rennweg, wobei hier die Zuordnung Parkplatz irreführend ist, da es sich um keinen Parkplatz handelt. Dabei sieht man, daß die Beschreibung der Klassen durch Bezeichnung wie “Parkplatz” für spektrale Merkmale keinen Sinn macht, da spektrale Signaturen Materialeigenschaften sind, während “Parkplatz” eine Informationsklasse ist. Die Klasse “Vegetation, trocken” läßt sich in diesem Ausschnitt nicht finden, da die Vegetation durch die Pegnitz bewässert wird.

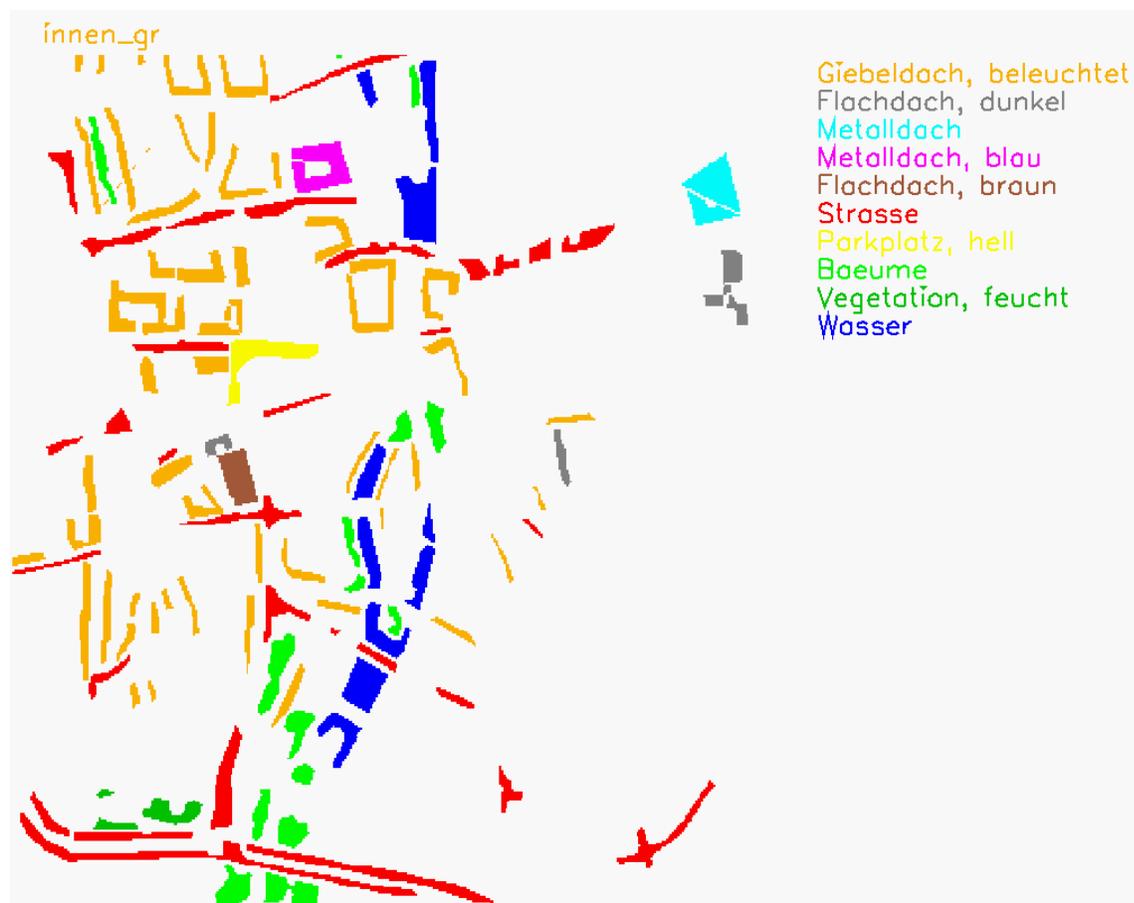


Abbildung 4.8: Validierungskarte Innenstadt: Dieses Innenstadtgebiet liegt in der Nürnberger Altstadt. Die Einteilung erfolgte nach der Klassenauswahl aus Tabelle 4.6.

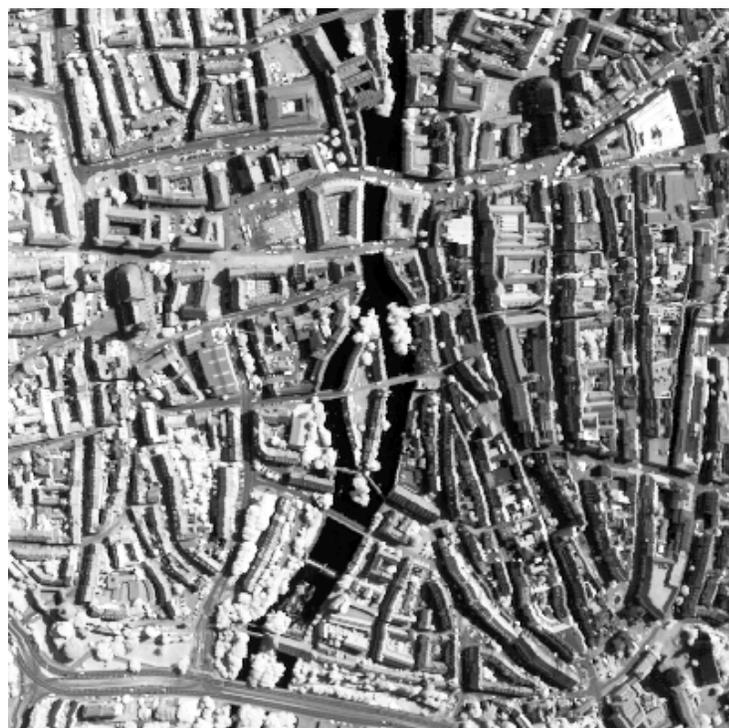


Abbildung 4.9: Nürnberger Altstadt im Kanal 6 der Multispektralbilder. Der Kanal wurde mittels der IDL Funktion *hist_equal* aufgehellt.

4.3.5 Gebiet: Gesamtszene

Zum Test der Klassifikation auf großräumigen Gebieten wurden die vorher vorgestellten Testgebiete zu einer Gesamtszene zusammengefügt. Die Validierungskarte hat 22 Klassen, die sich aus den teilweise unterschiedlichen Klassen der kleineren Testszenen zusammensetzen. Die Klassifikationsergebnisse werden sich sehr wahrscheinlich von denen der Einzelszenen unterscheiden, da der 10-dimensionale Merkmalsraum nun in 22 Klassen eingeteilt werden muß. Diese feinere Einteilung, sowie die größere Anzahl an Pixeln pro Klasse beeinflussen die Klassifikation. Die Auswahl der Trainingspixel wird in den jeweiligen Kapiteln der Klassifikation beschrieben.

In der Tabelle 4.7 sind drei Klassen vertreten, die mit einem prozentualen Bildanteil an den Testpixeln von weniger als 0.1% angegeben werden. Diese Klassen wurden ausgewählt, da sie sich zu stark von den anderen Klassen unterscheiden. Die geringe Pixelanzahl macht eine gute Bestimmung der Klassifikatoren schwierig. Auf dieses Problem wird im Kapitel 5 *Klassifikation & Fusion* näher eingegangen. Es spiegelt allerdings auch die Problematik bei realen Bildern wieder, bei denen nicht für jede Klasse eine ausreichende Anzahl an Trainingspixeln zur Verfügung stehen kann.

4.3.5.1 Spektren der Klassen

Die Plots (s. Abb. 4.11) auf den nächsten beiden Seiten stellen die 10-kanaligen Spektren der einzelnen Klassen dar. Dabei wurde der Mittelwert aller Testpixel jeder Klasse gebildet. Als Fehlerbalken sind die Standardabweichungen der Pulshöhenverteilungen in den Testpixeln angegeben. Die Reflektanzen sind nicht in Prozent angegeben sondern in Pulshöhen.

Die ersten drei Flachdachklassen unterscheiden sich hauptsächlich in der Höhe der Reflektanzen. Die Form der Spektren ist sehr ähnlich. Die Klasse “Flachdach, braun” unterscheidet sich besonders im infraroten Bereich. Das Spektrum der Klasse “Metalldach” ist sehr hell. Ein ähnliches Spektrum hat die Klasse “Sand/Schotter”. Es ist allerdings etwas intensitätsschwächer. Die Klasse “Metalldach, blau” weist dagegen ein gänzlich anderes Spektrum auf. Auffällig ist der Peak in Kanal 3.

Die Form des Spektrums der Klasse “Kiesdach” ähnelt wieder dem der Flachdächer, es hat aber einen steileren Anstieg im blauen und grünen Bereich als das Spektrum der Klasse “Flachdach, hell”.

Die beiden Klassen “Giebeldach, beleuchtet” und “Giebeldach, schattig” zeigen ganz deutlich den Unterschied auf zwischen indirekter Beleuchtung durch die Umgebung und direkter Sonneneinstrahlung. Die Reflektanzwerte liegen im Beleuchteten um einen Faktor 2 bis 3 höher als im Schatten. Der verminderte Anteil im Infraroten oberhalb von 1 μm ist auch auf die fehlende direkte Sonneneinstrahlung zurückzuführen. Die schwarzen Ziegel der Klasse “Giebeldach, schwarz” zeigen wieder ein ähnliches Verhalten wie die Flachdachspektren, allerdings ohne das Maximum im Kanal 9. Die hellen Ziegel der Klasse “Giebeldach, hell” haben ein deutlich anderes Spektrum als die Spektren der beiden anderen Giebeldachklassen, was auf ein anderes Material schließen läßt.

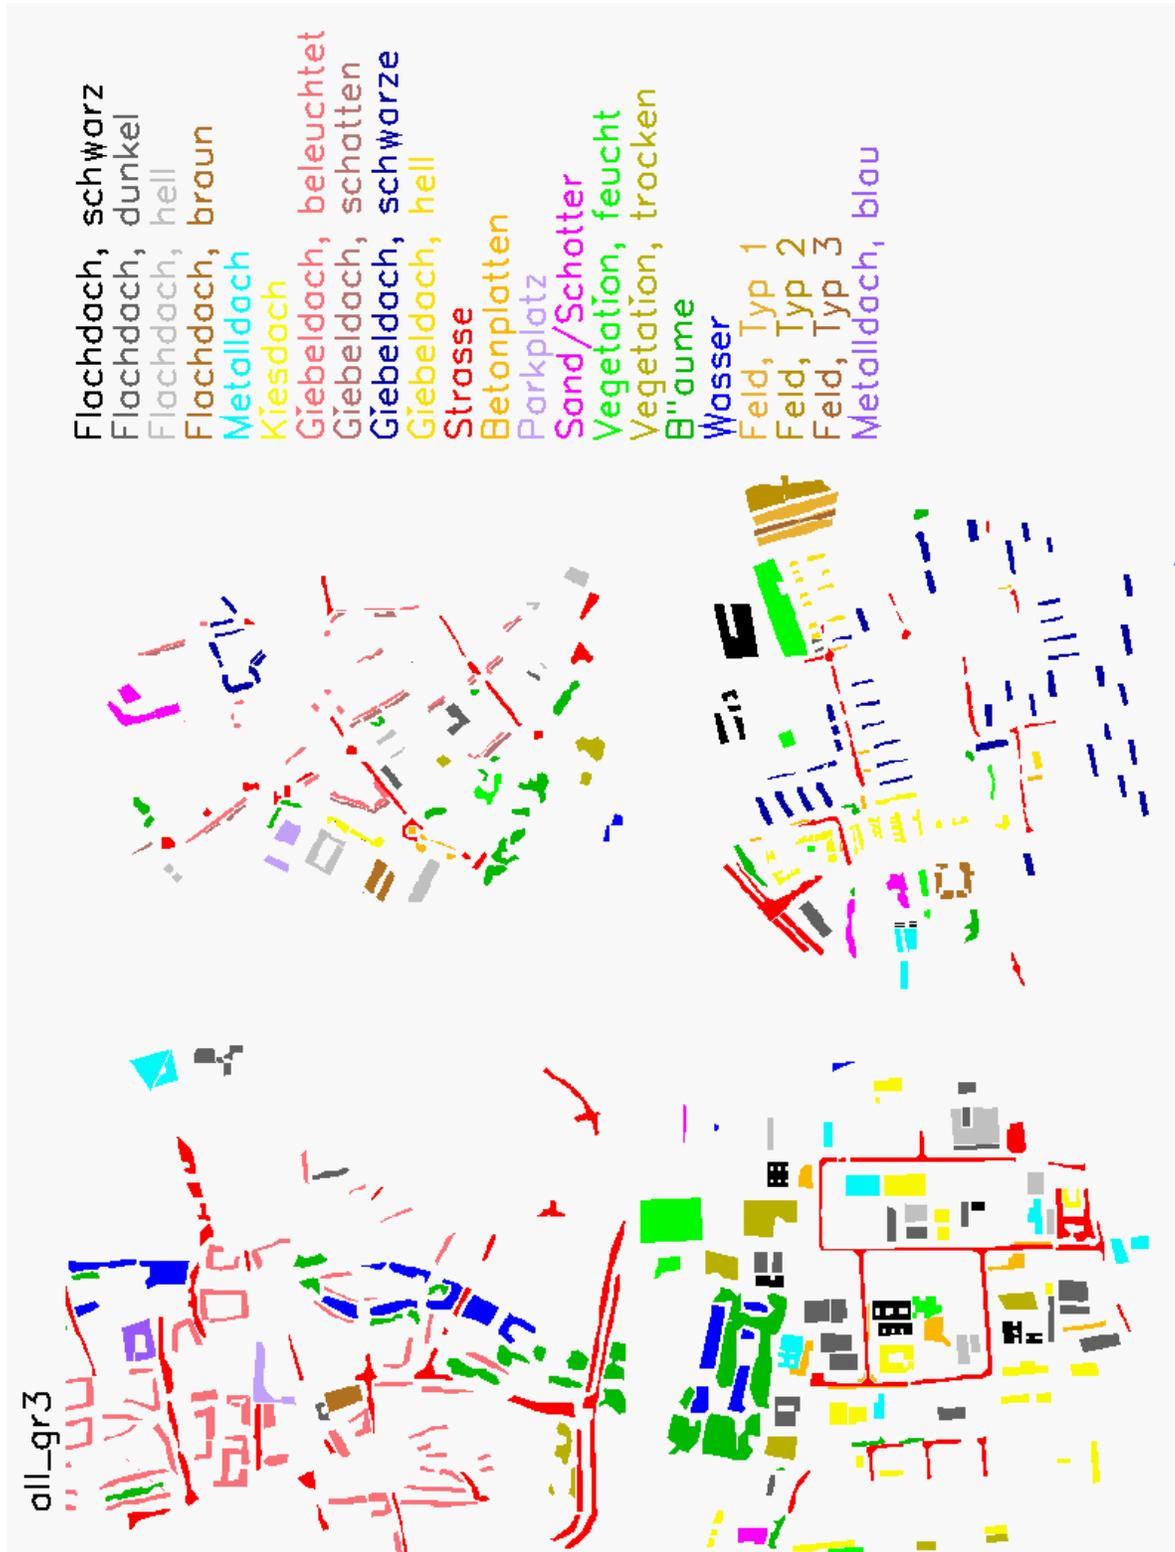


Abbildung 4.10: Validierungskarte Gesamtzone:

Die Klasseneinteilung ergibt sich aus den vorher beschriebenen Klassen. Die Klassen sind in Tabelle 4.7 angegeben.

Klassen-Nr.	Bezeichnung	Pixelanzahl	Prozentanteil
1	Flachdach,schwarz	2494	0.3
2	Flachdach,dunkel	4405	0.6
3	Flachdach,hell	2640	0.4
4	Flachdach,braun	958	0.1
5	Metалldach	2268	0.3
6	Kiesdach	4147	0.6
7	Giebeldach, beleuchtet	6573	1.0
8	Giebeldach, schattig	631	0.0
9	Giebeldach, schwarz	3217	0.5
10	Giebeldach, hell	321	0.0
11	Straße	11534	1.8
12	Betonplatten	1313	0.2
13	Parkplatz	780	0.1
14	Sand/Schotter	1170	0.1
15	Vegetation, feucht	3621	0.5
16	Vegetation, trocken	2660	0.4
17	Bäume	7507	1.1
18	Wasser	3743	0.5
19	Feld, Typ 1	900	0.1
20	Feld, Typ 2	782	0.1
21	Feld, Typ 3	200	0.0
22	Metалldach, blau	466	0.0
	Gesamt	62330	9.7

Tabelle 4.7: Klasseneinteilung für die zusammengesetzte Testszene aus allen vier Ausschnitten. Insgesamt gibt es 22 Klassen. In der Spalte “Pixelanzahl”, ist die Anzahl der Pixel angegeben, die pro Klasse markiert wurden, um für das Training bzw. die Berechnung der Gütemaße zu fungieren. In der Spalte dahinter steht der jeweilige prozentuale Anteil am Bild. In der letzten Zeile ist die Gesamtanzahl der Pixel, die für die Validierung ausgesucht wurden, angegeben.

Die Klassen “Straße” und “Parkplatz” sind sich von der Form des Spektrums her wieder ähnlich. Sie unterscheiden sich in der Intensität, was auch durch den optischen Eindruck, der zur Klassenauswahl führte, bestätigt wird. Die Klasse “Betonplatten” bezieht sich auf die Platten, mit denen Bürgersteige belegt sind. Die Klasse “Sand/Schotter” ist am ehesten mit der Klasse “Feld, Typ 2” zu vergleichen. Letztere ist zwar sehr viel dunkler, hat aber eine ähnliche Form.

Die Formen der Spektren der Vegetationsklasse gleichen sich sehr. Die Unterschiede sind vor allem im infraroten Bereich zu finden, wo die Spektren unterschiedlich stark

abfallen. Das liegt u.a. an unterschiedlichen Anteilen von Beiträgen des Erdbodens (je nach Bewuchsdichte).

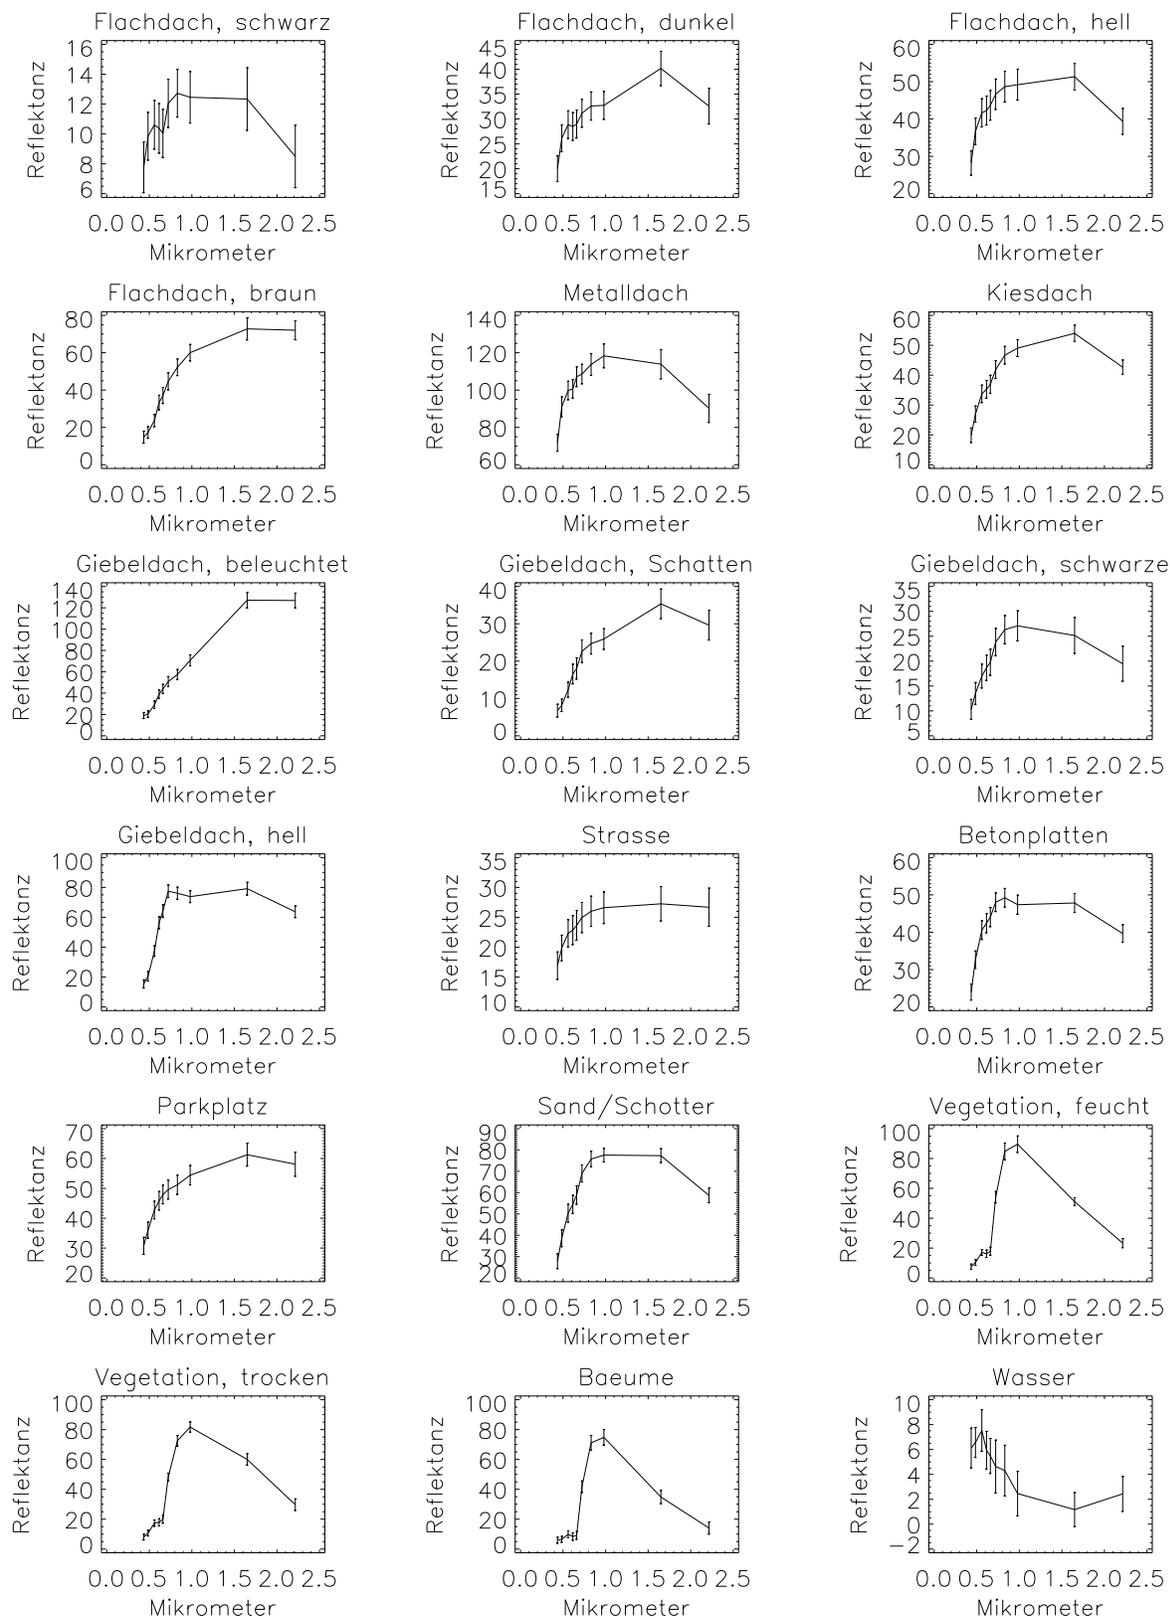


Abbildung 4.11: Spektren der ausgewählten Klassen.

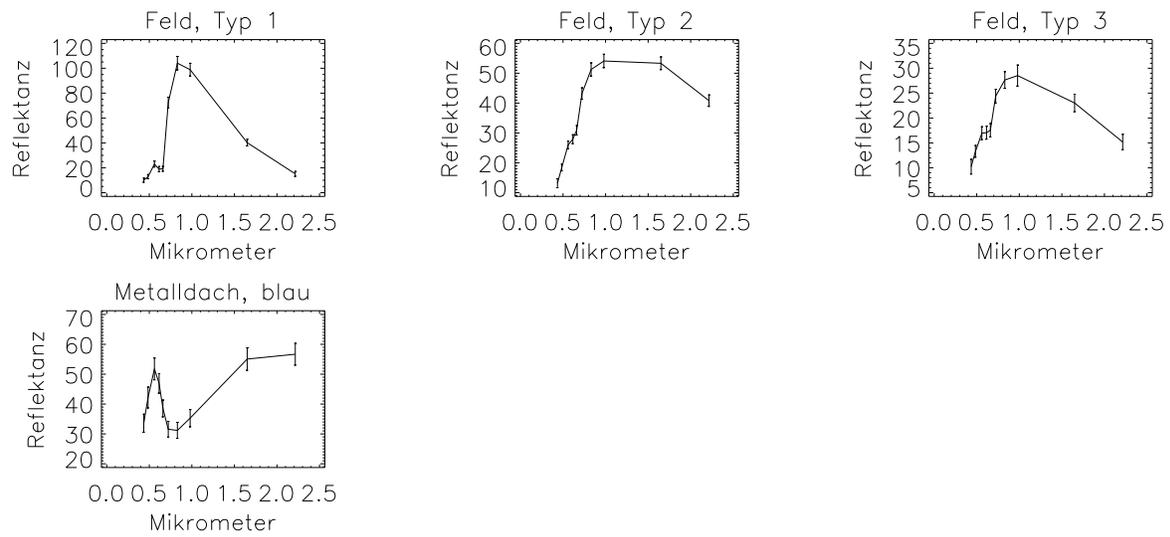


Abbildung 4.12: Spektren der ausgewählten Klassen.

5 Klassifikation & Fusion

In diesem Kapitel werden die Klassifikationsergebnisse der getesteten Verfahren vorgestellt. Zuerst wird eine kurze Betrachtung der beiden unüberwachten Fuzzy-Algorithmen, *Fuzzy-c-Means* (im weiteren FCM) und *Fuzzy-c-Means* mit Kontext (im weiteren SFCM), vorgenommen. Bei den überwachten Verfahren werden zunächst die Ergebnisse des klassischen Maximum Likelihood Verfahrens (im weiteren ML) vorgestellt, das als Vergleich zu den Fuzzy-Methoden dient. Die Fuzzy-Methoden, die getestet wurden sind

- FKNN: Fuzzy k-nearest neighbor (im weiteren FKNN),
- Fusion mittels einer konvexen Linearkombination (im weiteren FLK),
- Fusion mittels eines neuronalen Netzes (im weiteren FNN).

Für die Verfahren wurden als Datensätze verschiedene Kanalkombinationen benutzt:

- alle 10 Kanäle des DAEDALUS Detektors,
- 4 Kanäle des DAEDALUS Detektors, die den IKONOS Kanälen entsprechen,
- 9 aus 10 Kanälen des DAEDALUS Detektors (nur für FNN und ML Klassifikation).

Die Klassifikation mit den IKONOS Kanälen wurde in Hinblick auf die Daten, die mit dem IKONOS Satelliten aufgenommen wurden und der Arbeitsgruppe vorliegen, gemacht. Dieser verfügt über vier multispektrale Kanäle mit einer Bodenauflösung von 4 m. Die Wellenlängenbereiche und die entsprechenden DAEDALUS Kanäle sind in Tabelle 5.1 aufgeführt.

IKONOS		DAEDALUS
Kanal	Wellenlänge [μm]	Kanal
1	0.45 - 0.52	2
2	0.52 - 0.60	3
3	0.63 - 0.69	5
4	0.76 - 0.90	7

Tabelle 5.1: Es sind die Kanalnummern der jeweiligen Detektoren angegeben. Für den IKONOS Detektor sind die detektierten Wellenlängenbereiche angegeben.

Bei der Fusion wurden nicht die Reflektanzwerte verwendet, sondern Fuzzy-Klassifikationen (*possibility maps*) der Einzel-Kanal-Bilder, die mit FKNN klassifiziert wurden.

5.1 Unüberwachte Klassifikation

Die unüberwachte Klassifikation kann einem Anwender helfen, in unüberschaubaren Datenmengen erste Klassenmerkmale zu finden. Der Anwender kann dabei die Anzahl der Klassen, in die ein Datensatz eingeteilt werden soll, vorgeben. Die Zuweisung der Klassen zu Informationsklassen erfolgt nach der Klassifikation durch den Anwender.

Es besteht auch die Möglichkeit mittels eines Maßes für die Kompaktheit einer Klasse, die Anzahl der Klassen automatisch zu ermitteln. Diese Verfahren sind allerdings sehr rechenintensiv. Im folgenden beschränke ich mich nur auf zwei unüberwachte Verfahren FCM und SFCM. Als Beispielszene wird das Testgebiet Andernacherstraße benutzt. Die Einteilung erfolgt in fünf und in zehn Klassen.

5.1.1 *Fuzzy-C-Means* (FCM)

Der FCM Algorithmus wird in Kapitel 2.4.2.1 auf Seite 32 erklärt. Er ist eine Erweiterung des ISODATA mittels Fuzzy-Methoden. Jeder Pixel erhält eine Zugehörigkeit zu jeder Klasse. Die Zuweisung eines Pixels zu einer Klasse geschieht auf Grund des höchsten Zugehörigkeitswertes. Die Klassifikationen der Testszene auf Seite 80 sind mit dem IDL Programm `fuzzykmeans.pro` erstellt worden.

<u>Funktion:</u>	FUZZYKMEANS
<u>Aufruf:</u>	CLASSMAP = FUZZYKMEANS(MAP, CLASSES, CENTERS, MEMBERSHIPMAP)

Die Funktion hat vier Eingabewerte (`MAP`, `CLASSES`, `CENTERS`, `MEMBERSHIPMAP`). Die ersten beiden Parameter, das zu klassifizierende Bild (`MAP`) und die Klassenanzahl (`CLASSES`), sind Pflichteingaben. Die beiden anderen Werte sind optional. Die Parameter `CENTERS` und `MEMBERSHIPMAP` dienen dazu, Zwischenergebnisse der Funktion zurückzugeben. Der Parameter `CENTERS` liefert die Klassenzentren zurück. Im Parameter `MEMBERSHIPMAP` werden die Zugehörigkeiten der Pixel zu den Klassen (*possibility maps*) abgelegt. Das Ergebnis des Programms ist eine klassifizierte Karte (`CLASSMAP`).

5.1.1.1 FCM mit 5 Klassen

Die Einteilung in fünf Klassen mit dem FCM ergibt eine gute Einteilung (Abb. 5.1). Es treten aber für eine brauchbare Klassifikation einige Schwierigkeiten auf. Der Klasse "blau" entsprechen nicht nur Wasser, sondern auch Schattengebiete, dunklen Dachoberflächen und teilweise Straßen. Das Merkmal dieser Klasse ist die niedrige Reflektanz der

Oberflächen. Der Klasse “rot“ entsprechen sowohl Flachdächer, die mit Teerpappe belegt sind als auch Straßen. Ein Problem, das bei den untersuchten Klassifikationen immer wieder auftritt, da beides sehr ähnliche Materialien sind. Die Klasse “hellblau“ beschreibt die stark reflektierenden Oberflächen, wie Metaldächer und Sandflächen. Die Klasse “gelb“ steht für Oberflächen wie Kiesdächer und Betonplatten. Die Klasse “grün“ beschreibt die Vegetation, die eine sehr große und auffällige Klasse ist. Die Vegetation läßt sich auch mittels des einfachen Maßes NDVI¹ gut klassifizieren.

5.1.1.2 FCM mit 10 Klassen

Die Erhöhung der Klassenanzahl auf 10 läßt ein etwas differenzierteres Ergebnis entstehen (s. Abb. 5.3). Die Wasser-, Schatten- und dunklen Flachdachflächen werden immer noch nicht in einzelne Klassen getrennt. Dafür gibt es eine Trennung zwischen den mit Teerpappe bedeckten Häusern und den Straßen. Die Vegetation ist insgesamt durch 5 Klassen vertreten, weil sie einen großen Bereich im Merkmalsraum einnimmt. Diese Aufspaltung ließe sich vielleicht durch ein Kompaktheitsmaß, das z.B. die Dichte einer Klasse bewertet, unterbinden.

5.1.2 *Fuzzy-C-Means* mit Kontext (SFCM)

Beim SFCM (*Smooth-Fuzzy-C-Means*) wird der in Kapitel 2.4.2.1 auf Seite 34 beschriebene Algorithmus verwendet. Das IDL Programm `smoothfuzzykmeans.pro` nimmt diese Klassifikation vor.

<u>Funktion:</u>	SMOOTHFUZZYKMEANS
<u>Aufruf:</u>	CLASSMAP = SMOOTHFUZZYKMEANS(MAP, CLASSES, CENTERS, BETA, KSIZE)

Die Funktion `smoothfuzzykmeans` hat fünf Eingabeparameter. Die ersten drei (`MAP, CLASSES, CENTERS`) entsprechen denen der Funktion `fuzzykmeans`. Die Parameter `BETA` und `KSIZE` beziehen sich auf das Umgebungspotential. `BETA` beschreibt die Reichweite des Umgebungspotentials. Für `BETA = 1` werden alle Elemente in der Umgebung gleich stark bewertet. `KSIZE` gibt die Größe der Umgebung (Fenstergröße) an, in der das Potential wirkt. Die Fenstergröße bewirkt auch den etwas verwaschenen Eindruck der klassifizierten Szenen in Abbildung 5.2 und 5.4. Für die Klassifikationen mit SFCM wurde `BETA = 0.8` und `KSIZE = 3` gewählt. Die Werte innerhalb dieses Fenster werden u.a. mit der IDL Funktion `smooth` gemittelt, so daß man einen Verlust der Auflösung erhält, welcher der Fenstergröße entspricht.

¹NDVI - Normalized Difference Vegetation Index

Der Vegetationsindex NDVI wird aus zwei Spektralkanälen, rot (R) und nahinfrarot (NIR) durch $NDVI = \frac{NIR - R}{NIR + R}$ gebildet. Beim DAEDALUS Detektor wird der Kanal 4 für rot und Kanal 7 für nahinfrarot benutzt.

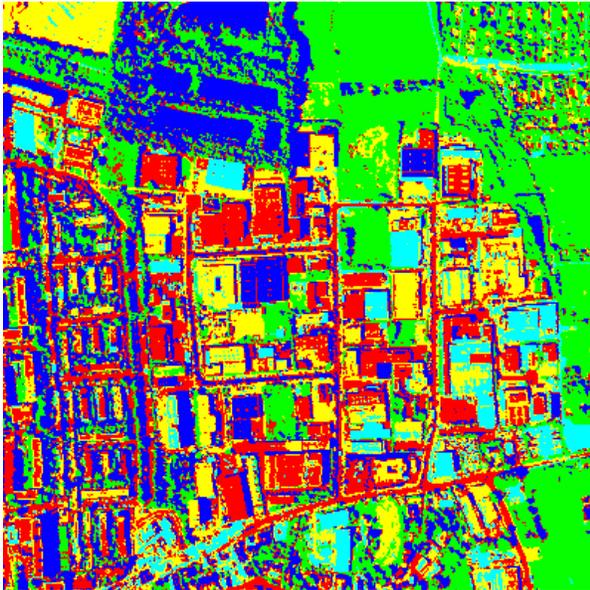


Abbildung 5.1: FCM mit 5 Klassen

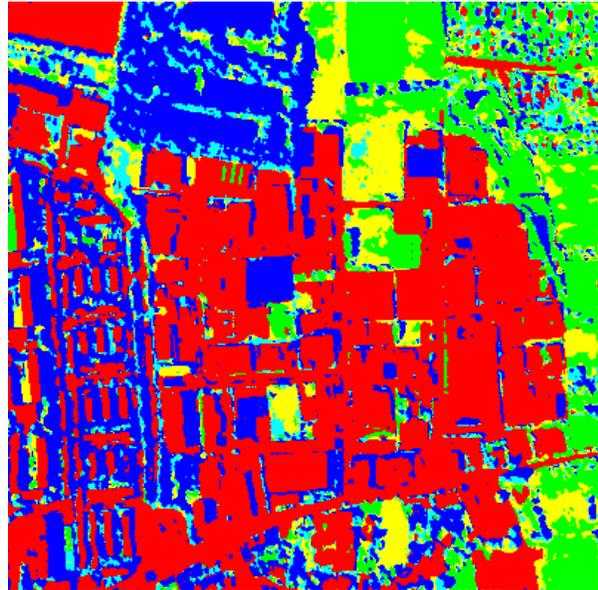
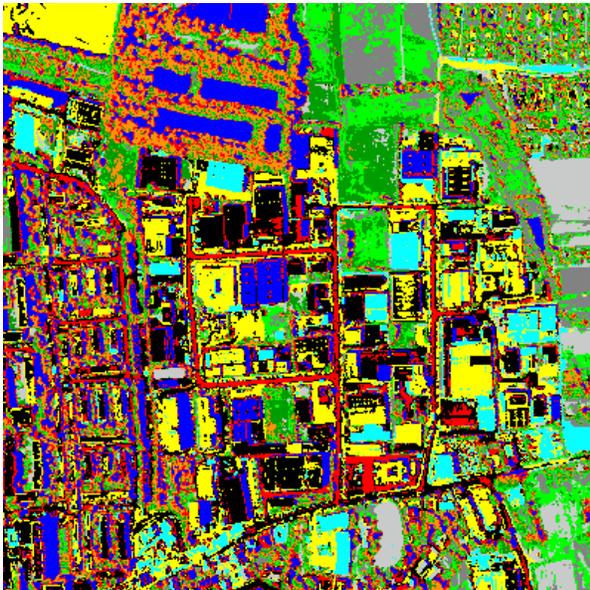
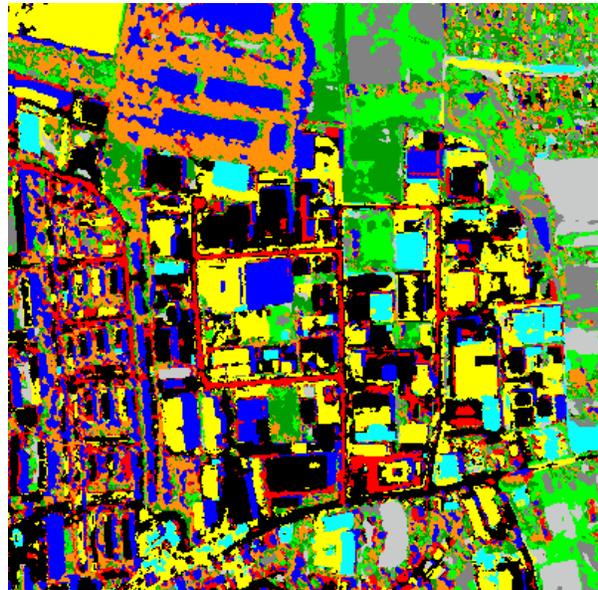
Abbildung 5.2: SFCM mit 5 Klassen,
BETA = 0.8 und KSIZE = 3 .

Abbildung 5.3: FCM mit 10 Klassen

Abbildung 5.4: SFCM mit 10 Klassen,
BETA = 0.8 und KSIZE = 3 .

5.2 Überwachte Klassifikation

Die überwachte Klassifikation mittels Fuzzy-Methoden stellt den Schwerpunkt dieser Arbeit dar. Dabei wurden verschiedene Methoden getestet (s.o). Im folgenden werden die Ergebnisse der Klassifikationen dargestellt und beschrieben. Dabei werden nur die Klassifikationsergebnisse des Testgebiets Andernacherstr. und der Gesamtszene abgebildet. Die Ergebnisse der anderen Testgebiete werden durch das Gütemaß Kappa-Wert bewertet. Für die Bewertung gilt die Tabelle 5.2 aus [OFE97]. Die Darstellung der Ergebnisse erfolgt nach folgendem Muster:

- Erläuterung der Methode mit verwendeten Programmen und Parametern.
- Abbildung und Beschreibung der Klassifikationsergebnisse. Die klassifizierten Karten werden für die Auswahl “alle Kanäle” und “IKONOS Kanäle” und die Testgebiete Andernacherstr. und Gesamtszene abgebildet.
- Bewertung aller Testgebiete (Andernacherstr., Innenstadt, Rennweg, Thon, Gesamtszene) mittels des Kappa-Werts und über die Genauigkeit, mit der die Validierungskarte erstellt wurde, geschehen (s. Kap. 4.1). Der Fehler, der beim Kappa-Wert angegeben ist, wurde mittels Gleichung 2.53 bestimmt. Es zeigt sich, daß der Fehler erst in der dritten Nachkommastelle zu bemerken ist.

Kappa-Wert	Qualität
< 0.0	sehr schlecht
0.0 bis 0.2	schlecht
0.2 bis 0.4	akzeptabel
0.4 bis 0.6	gut
0.6 bis 0.8	sehr gut
0.8 bis 1.0	ausgezeichnet

Tabelle 5.2: Tabelle zur Bewertung von Kappa-Werten.

Die Untersuchung der Klassifikationen anhand der klassenspezifischen Gütemaße PAUA und FPAUA wird im Kapitel 6 *Bewertung der klassenspezifischen Gütemaße* vorgenommen.

5.2.1 Maximum Likelihood (ML)

Die Maximum Likelihood Klassifikation dient als Vergleichsverfahren zu den Fuzzy-Methoden. Die dafür benötigten Programme lagen in Hamburg vor und wurden in das

Programm MFIAS² integriert. Als Auswahlparameter sind die Kanalanzahl, die Klassenanzahl und die Anzahl der Trainingselemente gegeben. Die Klassenanzahl ist durch die Vorgabe einer Validierungskarte festgelegt. Die Trainingselemente werden dabei zufällig aus der Validierungskarte ausgewählt. Es gibt auch die Möglichkeit, die Trainingspixel und Klassenanzahl interaktiv zu bestimmen. Die Koordinaten dieser Pixel werden abgespeichert, um bei der späteren Bewertung der Klassifikation herausgenommen werden zu können.

In [Ric99] wird empfohlen, $10 \cdot N$ (N Anzahl der Klassen) Trainingspixel pro Klasse auszuwählen, um eine statistisch aussagekräftige Kovarianzmatrix zu erhalten. In den folgenden Klassifikationen wurden u.a. auf Grund mangelnder **Trainingspixel 50 Pixel pro Klasse** ausgewählt. Dies erwies sich als ausreichend. Eine Erhöhung der Pixelanzahl brachte keine signifikanten Änderungen in den Gütemaßen, wie man der Tabelle 5.3 entnehmen kann. Die Kappa-Werte des Testgebiets Thon nehmen nur geringfügig zu. Es wurde die Klasse Wasser nicht klassifiziert, da diese nur 68 Trainingspixel enthält und somit keine 200 Pixel ausgewählt werden konnten, dies erklärt auch die besseren Kappa-Werte gegenüber der Klassifikation mit der Klasse Wasser. Der Kappa-Wert stieg von 0.848 ± 0.004 bei 50 Trainingspixeln pro Klasse auf 0.877 ± 0.004 bei 200 Trainingspixeln pro Klasse an. Dabei ist zu bedenken, dass die Anzahl der Testpixel entsprechend abnimmt.

Anzahl der Trainingssample	Kappa-Wert
50	0.848 ± 0.004
100	0.866 ± 0.004
150	0.861 ± 0.004
200	0.877 ± 0.004

Tabelle 5.3: Die ML Klassifikation des Testgebiets Thon erzielt mit zunehmender Trainingspixelanzahl pro Klasse leicht bessere Kappa-Werte. Der statistische Fehler des Kappa-Werts änderte sich nicht signifikant. Es wurden 50, 100, 150 und 200 Trainingspixel zufällig aus der Validierungskarte pro Klasse ausgewählt. Hierbei ist zu bedenken, daß die Anzahl an Testpixeln im selben Maße abnimmt.

²MFIAS - Multichannel Fuzzy Interactive Analysis of SAR-Data, ein Programmpaket, das auf dem FIAS (Fuzzy Interactive Analysis of SAR-Data) basiert. Beide Systeme sind von der Gruppe SAR-Expertensysteme unter der Leitung von Frau Benz am Institut für Hochfrequenztechnik und Radarsysteme beim DLR Oberpfaffenhoffen entwickelt worden.

<u>Programm:</u> MFIAS
<hr/>
<u>Parameter:</u> Klassifikation = ML, Kanalanzahl = 10 (alle) oder 4 (IKONOS), Klassenanzahl = (je nach Testgebiet), Trainingspixel = 50 (für ML)

Als Ergebnisse werden sowohl die Klassenkarte, als auch die Karten mit den A POSTERORI Wahrscheinlichkeiten zurückgeliefert. Die A POSTERORI Wahrscheinlichkeiten können mit den *possibility maps* verglichen werden. Für den Vergleich mit der Fusion über neuronale Netze wurde auch die Berechnung der Gütemaße für die Kanalauswahl 9 aus 10 Kanälen durchgeführt. Diese Analyse wurde gemacht, um einen Eindruck zu bekommen, welche Kanäle für die Klassifikation besonders aussagekräftig sind.

5.2.1.1 Testgebiet Andernacherstr.

Die beiden Abbildungen 5.5 und 5.6 zeigen die ML Klassifikation des Testgebiets Andernacherstr.. Abbildung 5.5 ist mit allen 10 DAEDALUS Kanälen klassifiziert worden, Abbildung 5.6 mit den IKONOS Kanälen.

Die eingekreisten Gebiete 1 bis 12 stellen Bereiche dar, in denen sich die einzelnen Klassifikationen unterscheiden. Die Beschreibung der Gebiete kann der Tabelle 5.4 entnommen werden. Bei der Erstellung der Legende ist ein Fehler unterlaufen, die Klasse "Metalldach" wird hellblau dargestellt, die Klasse "Kiesdach" gelb. Dies gilt auch für die anderen Abbildungen des Testgebiets Andernacherstr..

Bei der ML Klassifikation sind besonders die Gebiete 3, 5, und 12 interessant. Im Gebiet 3 ist in beiden Klassifikationen Sand (bzw. Sand/Schotter) erkannt worden. Das Gebiet 12 hingegen ist als Metalldach klassifiziert worden. Diese Klassifizierung ist falsch. Bei der genauen Begutachtung des CIR-Fotos des Gebietes erkennt man dort ebenfalls Sand/Schotter, nur etwas heller als im Gebiet 3. Gebiet 5 zeigt deutlich, daß eine höhere Anzahl von Spektralkanälen zu besseren Klassifikationsergebnissen führen kann. In Abb. 5.5 ist das Flachdach richtig erkannt worden. In Abb. 5.6 wurde es mit der Klasse "Straße" verwechselt. Dies ist nicht weiter erstaunlich, da es sich bei der Flachdachbedeckung um Teerpappe handelt, was in etwa das gleiche Material ist, aus dem die Straße besteht. Auffällig an den Klassifikationen ist, daß Schattengebiete häufig mit Wasser verwechselt werden.

5.2.1.2 Gesamtszene

Die Klassifikationsergebnisse der Gesamtszene werden nur allgemein betrachtet. Es wird ein Vergleich vorgenommen, der sich zum einen auf den visuellen Unterschied der Bilder begründet, zum anderen aus den später ausführlich beschriebenen Gütemaßen.

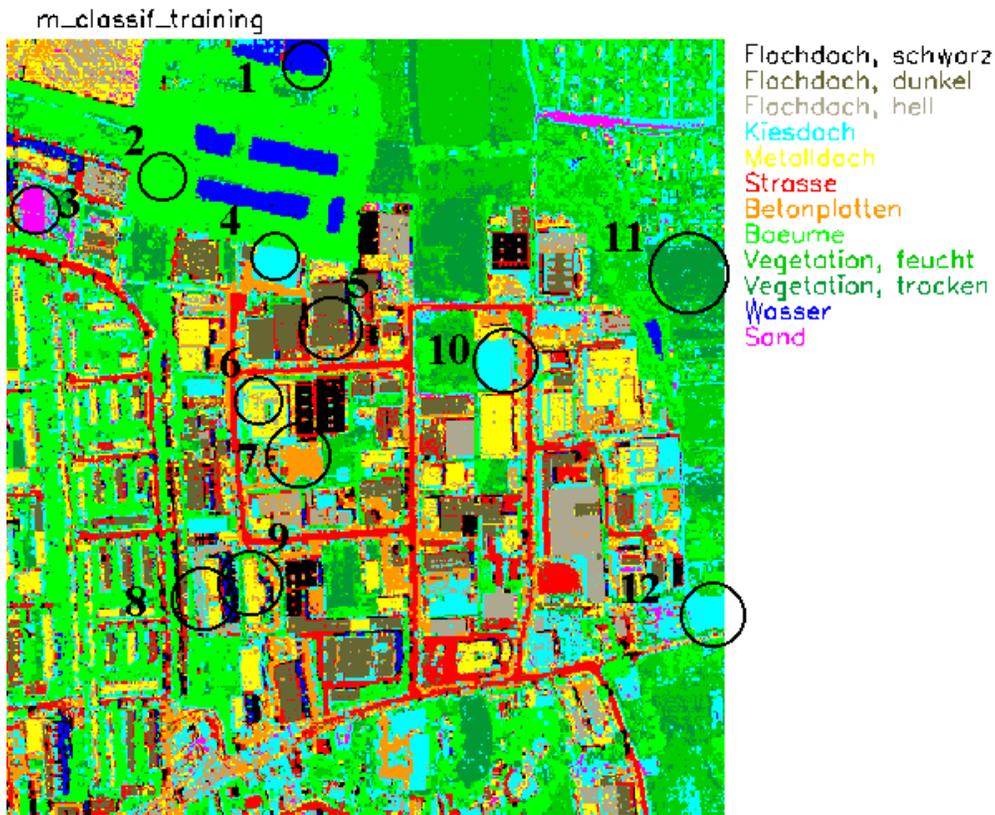


Abbildung 5.5: ML Klassifikation aller Kanäle, Testgebiet: Andernacherstr.

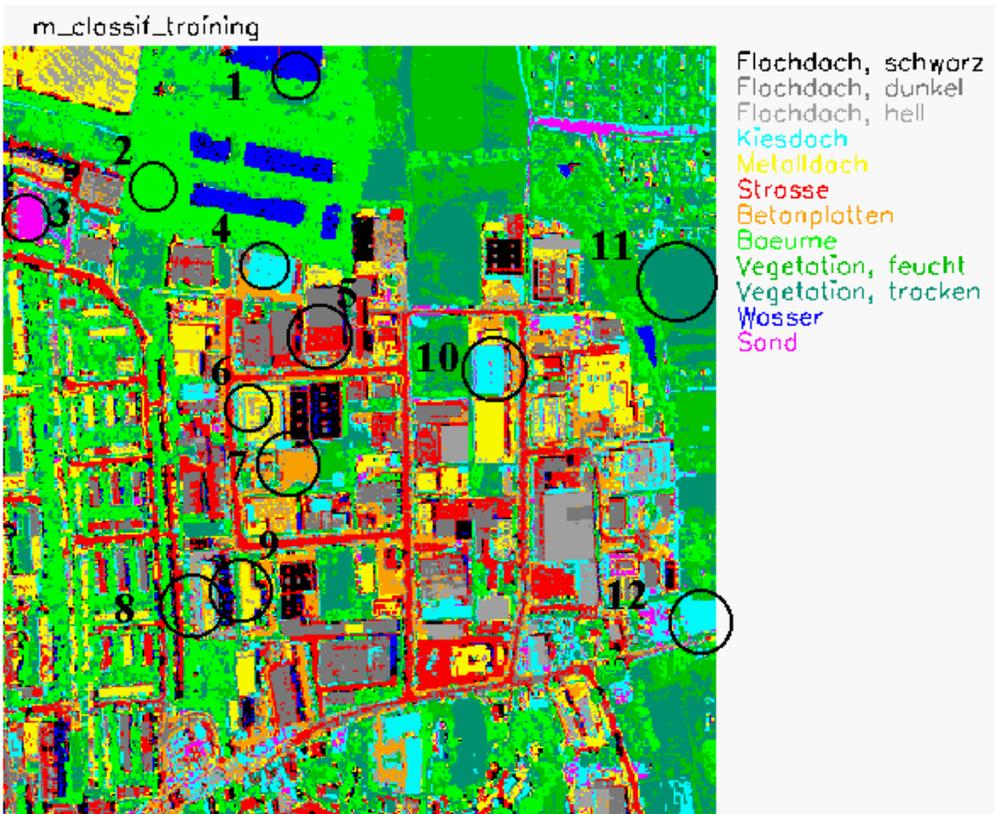


Abbildung 5.6: ML Klassifikation IKONOS Kanäle, Testgebiet: Andernacherstr.
Die eingekreisten Gebiete 1 bis 12 stellen Bereiche dar, in denen sich die einzelnen Klassifikationsverfahren besonders deutlich unterscheiden.

Gebiets-Nr.	Beschreibung
1	Freibad im Wald
2	Waldgebiet
3	Sand/Schotterfläche
4	Metalldach, starkes Relief
5	dunkles Flachdach mit Teerpappe
6	Kiesdach
7	Parkplatz mit Betonplatten
8	Kiesdach
9	Kiesdach
10	Metalldach
11	trockene Vegetationsfläche
12	Sand/Schotterfläche

Tabelle 5.4: 12 Gebiete von besonderem Interesse im Testgebiet Andernacherstr.

Auffällig bei der Gesamtszene ist vor allem der Innenstadtbereich (auf den Abbildungen 5.7 und 5.8 oben links zu sehen). Bei der Klassifikation mit allen Kanälen zeigt die Innenstadt ein überwiegend rotes Erscheinungsbild. Das liegt u.a. an der Auswahl der Farben für die einzelnen Klassen. Die Einfärbung einer Karte mit 22 Farben, die für das menschliche Auge gut unterscheidbar sind, ist schwierig. Besonders dann, wenn in unterschiedlichen Bereichen verschiedene Klassen nebeneinander liegen.

In der Klassifikation mit den IKONOS Kanälen (Abb. 5.8) ist der Innenstadtbereich blau-violett. Dort sind nicht nur die Pegnitz als Wasser erkannt worden, sondern auch viele Schattenbereiche, wie z.B. durch Häuser abgeschattete Straßen. Dies ist auch in der Abb. 5.7 zu sehen. Im Stadtteil Rennweg sind bei der Klassifikation mit allen Kanälen fast keine Straßen erkannt worden. Bei der Klassifikation mit den IKONOS Kanälen sind dort mehr Straßen erkannt worden. Es ist also nicht immer hilfreich, viele Kanäle zu nehmen.

Die allgemein etwas schlechtere Klassifikation hat zwei Ursachen:

1. Die hohe Klassenanzahl. Im Gegensatz zum Testgebiet Andernacherstr. muß der Merkmalsraum in 22 statt in 12 Klassen eingeteilt werden. Das macht eine klare Abgrenzung schwieriger. Die Klassen können sich leichter überlappen.
2. Das größere Testgebiet. Es stehen mehr Pixel zur Verfügung, sowohl für das Training als auch zur Klassifizierung. D.h., daß die Klassengrenzen unschärfer werden, da mehr Pixel zu einer Klasse gehören können und mehr Pixel eine Klasse kennzeichnen. Die Pixel einer Klasse können auch einen größeren Wertebereich umfassen.

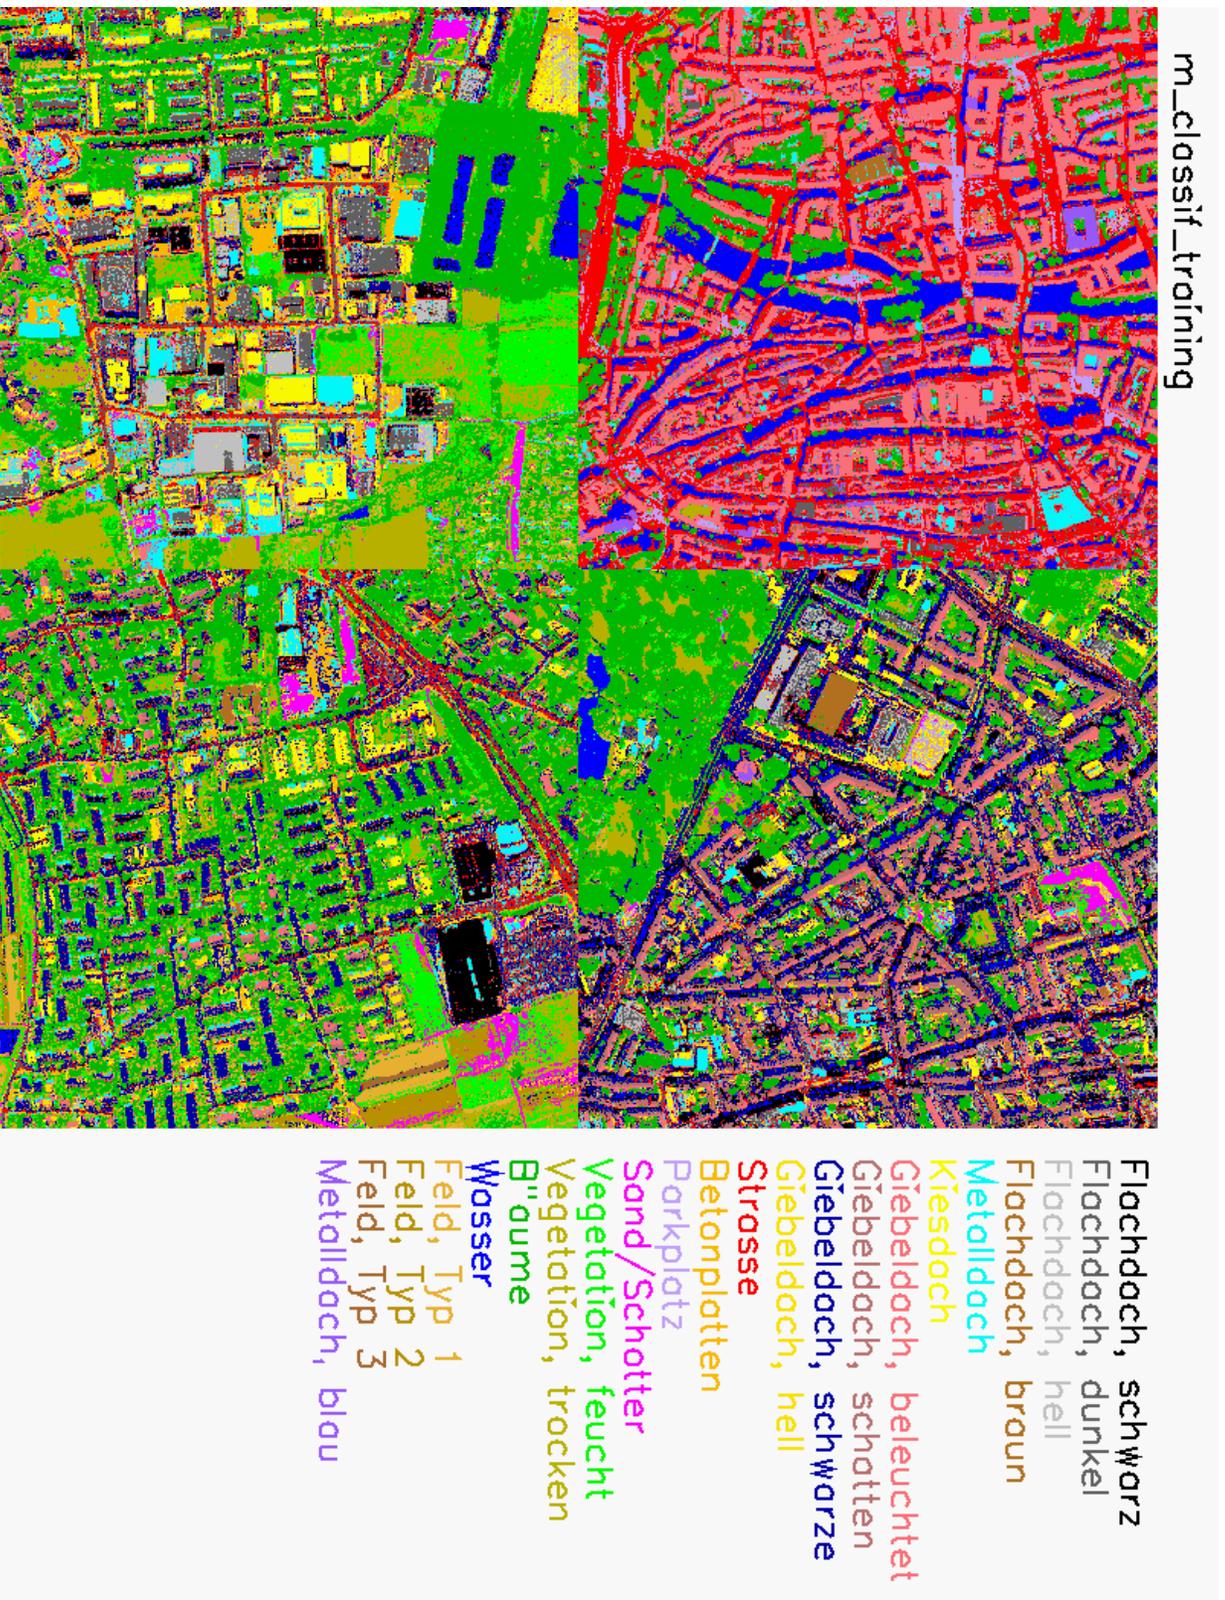


Abbildung 5.7: ML Klassifikation aller Kanäle, Testgebiet: Gesamtzene; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr. ; unten rechts: Thon

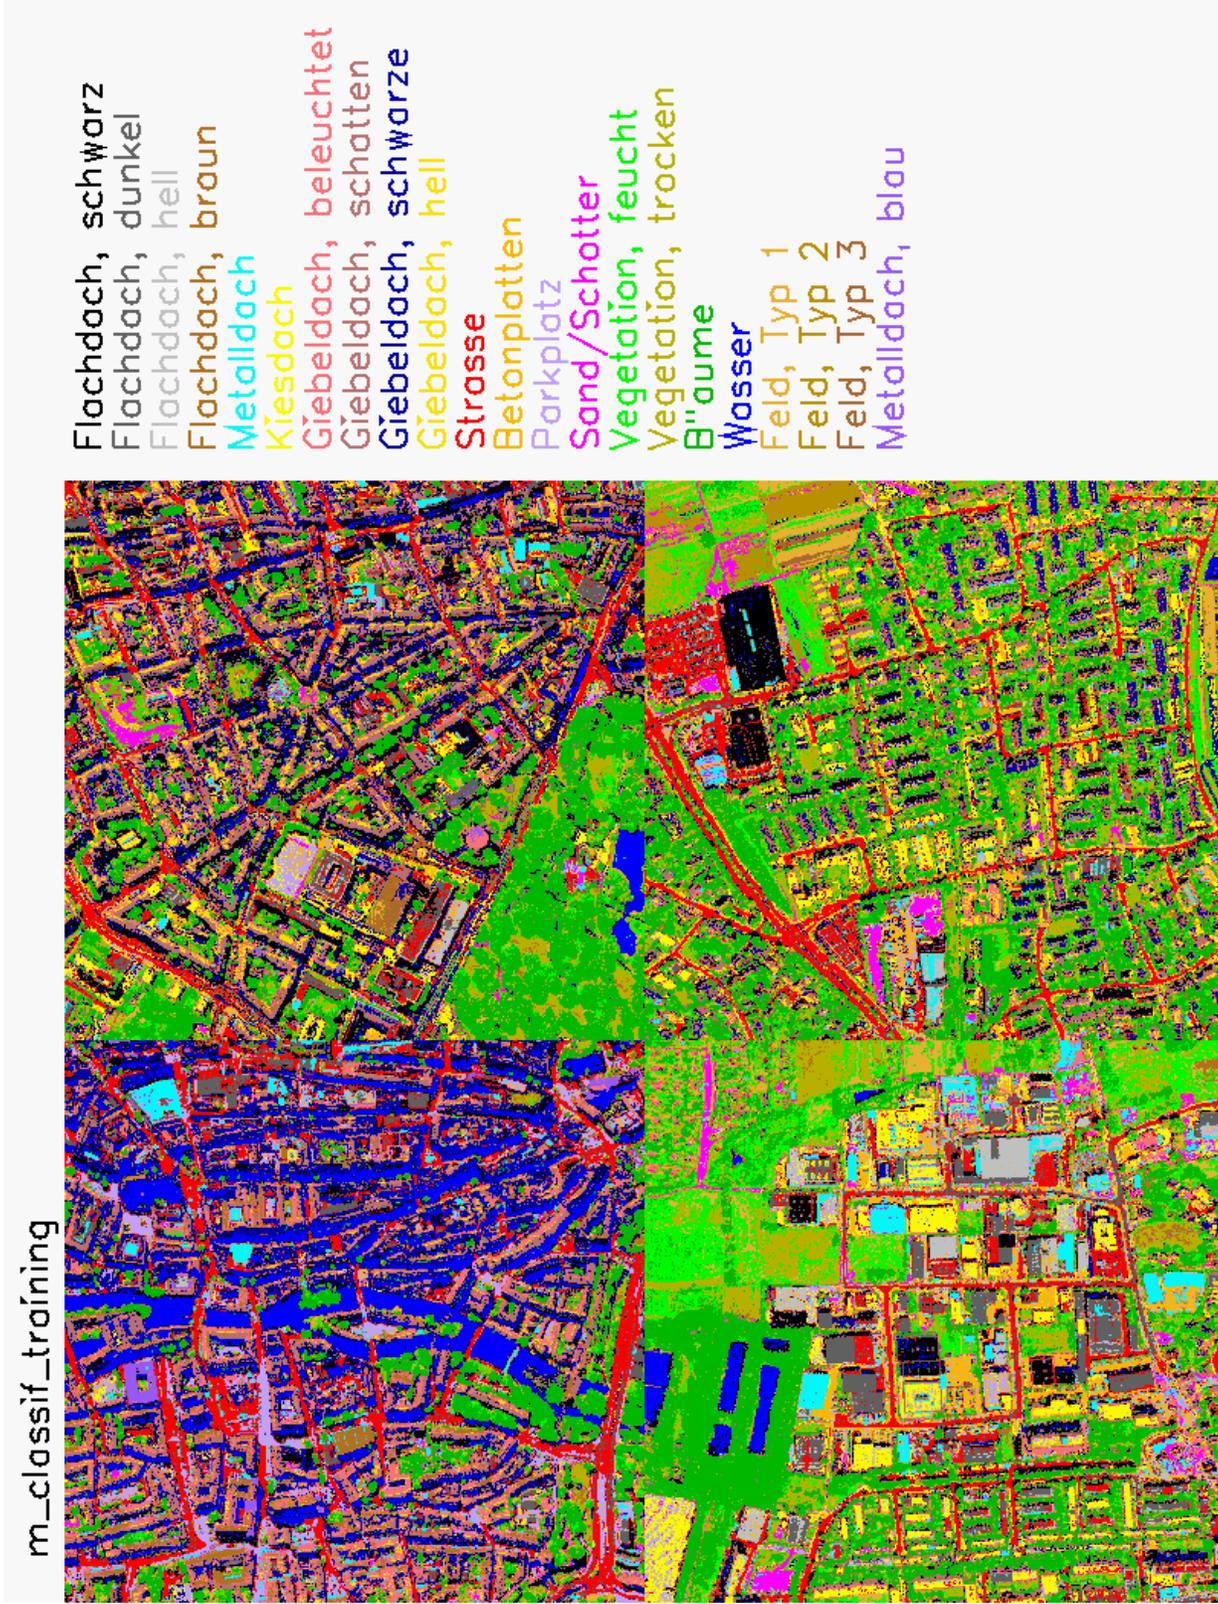


Abbildung 5.8: ML Klassifikation IKONOS Kanäle, Testgebiet: Gesamtzone; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr.; unten rechts: Thon

5.2.1.3 Kappa-Werte

Für die unterschiedlichen Testgebiete ergeben sich bei der ML Klassifikation die in Tabelle 5.5 angegebenen Kappa-Werte. Der Fehler liegt in der dritten Nachkommastelle und schwankt zwischen 0.002 und 0.004.

Testgebiet:	Andernacherstr.	Innenstadt	Rennweg	Thon Gesamtscene
ML(alle):	0.902 ± 0.002	0.884 ± 0.003	0.859 ± 0.004	0.841 ± 0.004 0.770 ± 0.002
ML(ikonos):	0.870 ± 0.002	0.887 ± 0.003	0.764 ± 0.005	0.771 ± 0.004 0.674 ± 0.002

Tabelle 5.5: Kappa-Werte der ML Klassifikation für die verschiedenen Testgebiete.

Man kann deutlich erkennen, daß die Gesamtgenauigkeit mit zunehmender Klassenanzahl abnimmt. Die beiden Testgebiete Andernacherstr. und Innenstadt haben ausgezeichnete Kappa-Werte (0.902 ± 0.002 bzw. 0.884 ± 0.003) bei der Klassifikation mit allen Kanälen. Die Gesamtscene mit 22 Klassen hat immerhin noch einen Kappa-Wert von 0.770 ± 0.002 . Die Testgebiete Rennweg und Thon erreichen eine Gesamtgenauigkeit von 0.859 ± 0.004 bzw. 0.841 ± 0.004 . Insgesamt sind die Kappa-Werte der Klassifikationen als ausgezeichnet zu bewerten.

Auch die Reduktion der Kanalanzahl macht sich bei den Testgebieten mit vielen Klassen deutlicher bemerkbar. Der Kappa-Wert nimmt bei den Gebieten Rennweg, Thon und Gesamtscene um bis zu 0.096 ab. Die Gebiete Andernacherstr. und Innenstadt zeigen keine große Veränderung (-0.032 bzw. $+0.003$). Aber auch hier kann man noch von sehr guten bis ausgezeichneten Klassifikationsergebnissen sprechen.

5.2.2 Fuzzy *k*-nearest-neighbor (FKNN)

Die Fuzzy *k*-nearest-neighbor Klassifikation ist ebenfalls Bestandteil des Programms MFI-AS. Zu den Auswahlparametern gehören wie bei der ML Klassifikation die Kanalanzahl, die Klassenanzahl und die Anzahl der Trainingselemente pro Klasse. Hinzu kommt die Anzahl der nächsten Nachbarn, die zur Klassifikation betrachtet werden. Als gute Parameterwahl hat sich die Auswahl von **30 Pixeln pro Klasse** und **fünf nächste Nachbarn** bewährt.

Zusätzlich zu der Auswahl aller Kanäle und der IKONOS Kanäle wurden die zehn Spektralkanäle einzeln klassifiziert. Die Ergebnisse dieser Klassifikationen und ihre Güte- maße dienen als Grundlage für die Klassifikation mittels der Fusionsalgorithmen.

Die Klassifikation mit FKNN erwies sich als recht langsam, weil die Bilder pixelweise bearbeitet werden. Der Algorithmus ist für einen "real-time" Einsatz entwickelt worden, was dazu führt, daß wenig Speicher gebraucht wird, aber viel Rechenleistung. IDL ist für

Rechnungen mit kompletten Arrays (Datenfelder) entwickelt worden, das Zugreifen auf einzelne Elemente ist hingegen sehr langsam. Hier liegt noch ein Optimierungspotential vor. Die Idee hinter der *“real-time“* Klassifizierung besteht darin, daß man während der Aufnahme eines Bildes dieses Bild an Hand von Standardspektren klassifiziert. Die klassifizierten Daten verbrauchen sehr viel weniger Speicherplatz.

<u>Programm:</u> MFIAS
<hr/>
<u>Parameter:</u> Klassifikation = FKNN, Kanalanzahl = 10 (alle) oder 4 (IKONOS), Klassenanzahl = (je nach Testgebiet), Trainingspixel = 30 (für FKNN), nearest-neighbor = 5

5.2.2.1 Testgebiet Andernacherstr.

Die Klassifikationsergebnisse für das Testgebiet Andernacherstr. sind in den Abbildungen 5.9 (alle DAEDALUS Kanäle) und 5.10 (IKONOS Kanäle) zu sehen. Die interessanten Bereiche hier sind 1, 3, 6, 7, 8, 9 und 12. Das Gebiet 1 ist bei der Klassifikation mit allen Kanälen richtig als Wasser erkannt worden. Es handelt sich um ein Freibad, das relativ hell ist, da das Wasser nicht sehr tief und das Becken gefliert ist. Dieser Unterschied macht sich bei der Klassifikation mit den 4 IKONOS Kanälen bemerkbar. Das Gebiet wird nun auch als dunkles Flachdach bzw. Straße erkannt. Bei dieser Klassifikation wird das Gebiet 12 der gleichen Klasse zugewiesen, wie das Gebiet 3. Hier ist ein Vorteil dieser Methode gegenüber der ML Klassifikation zu erkennen. Die Gebiete 6 und 7 sollten, wie in Abb. 5.9, den Klassen Kiesdach (6) und Betonplatten (7) zugewiesen werden. In Abb. 5.10 wird Gebiet 6 fast komplett als Betonplatten erkannt. Ein Nachteil der Klassifikation mit nur 4 Kanälen. Die Bereiche 8 und 9 haben ein ähnliches Verhalten. Bei der Klassifikation mit allen Kanälen werden beide Hausdächer als Flachdächer erkannt. Mit den IKONOS Kanälen wird Bereich 8 als helles Flachdach klassifiziert. Der Schatten des Hauses in Bereich 8 wird in beiden Fällen als Wasser erkannt.

5.2.2.2 Gesamtszene

Die auffällige Rotfärbung des Innenstadtbereiches in Abbildung 5.11 bei der ML Klassifikation ist bei der Klassifikation mit FKNN nicht so deutlich zu sehen. In Abbildung 5.11 wird häufiger die Klasse *“Giebeldach, schattig“* zugewiesen als *“Giebeldach, beleuchtet“*. Auffällig sind wieder die vielen Flächen, die als Wasser klassifiziert wurden, von denen nur die Pegnitz in der Mitte wirklich Wasser darstellt. Alle anderen Flächen sind wieder Schatten. Eine Klasse, die in diesem Bereich häufig vertreten ist, ist die Klasse *“Parkplatz“*. Ob diese Klassifikation richtig ist, läßt sich nicht beurteilen. Es findet zumindest

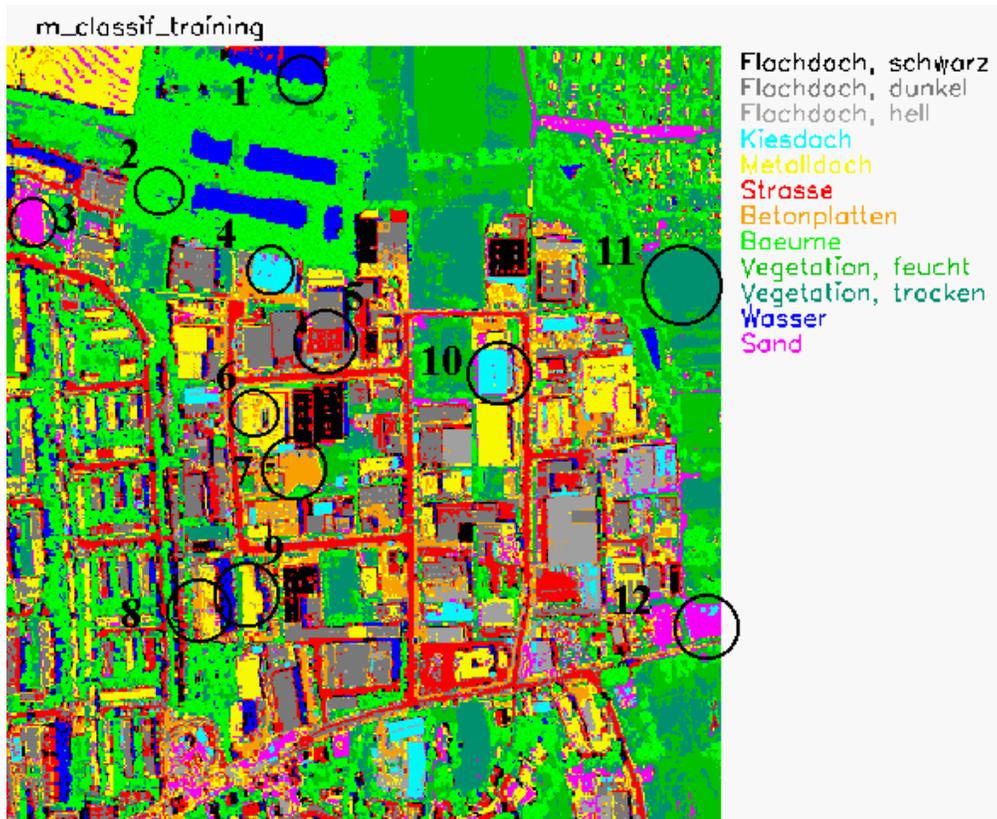


Abbildung 5.9: FKNN Klassifikation aller Kanäle, Testgebiet: Andernacherstr.

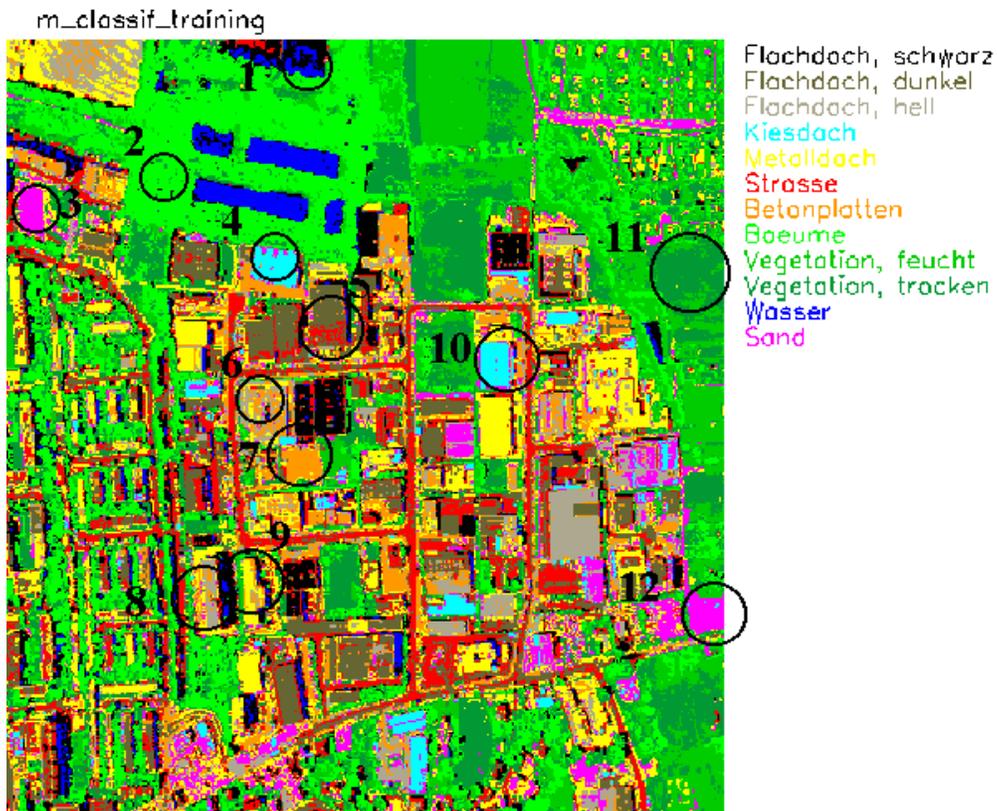


Abbildung 5.10: FKNN Klassifikation IKONOS Kanäle, Testgebiet: Andernacherstr.
 Die eingekreisten Gebiete 1 bis 12 stellen Bereiche dar, in denen sich die einzelnen Klassifikationsverfahren besonders deutlich unterscheiden.

eine Vermengung mit der Klasse “Betonplatten“ statt. Die Schattenbereiche im Stadtteil Rennweg (oben rechts in den Abbildungen), werden auch meist als Wasser erkannt.

Die Reduktion der Kanalanzahl auf 4 in Abbildung 5.12 führt zu einer vermehrten Zuweisung der Pixel zur Klasse “Wasser“. Im Innenstadtbereich werden die Hausdächer auch vermehrt fehlklassifiziert. Dies zeigt sich auch in den Gütemaßen sehr deutlich. Eine weitere Fehlklassifikation ist die Teichanlage am unteren Rand des Gebiets Rennweg. Die Auswahl “alle Kanäle“ erkennt dort die Klasse “Giebeldach, schwarz“, während die Auswahl “IKONOS Kanäle“ diesen Bereich mit der Klasse “Feld, Typ 3“ verwechselt.

5.2.2.3 Kappa-Werte

Für die unterschiedlichen Testgebiete ergeben sich bei der FKNN Klassifikation die in Tabelle 5.6 angegebenen Kappa-Werte. Auch hier liegt der Fehler des Kappa-Wertes in der dritten Nachkommastelle und schwankt zwischen 0.002 und 0.005.

Testgebiet:	Andernacherstr.	Innenstadt	Rennweg	Thon Gesamtzene
FKNN(alle):	0.820 ± 0.003	0.708 ± 0.004	0.706 ± 0.006	0.701 ± 0.005 0.636 ± 0.002
FKNN(ikonos):	0.729 ± 0.003	0.692 ± 0.004	0.645 ± 0.006	0.635 ± 0.005 0.552 ± 0.002

Tabelle 5.6: Kappa-Werte der FKNN Klassifikation für die verschiedenen Testgebiete.

Die Kappa-Werte der einzelnen Testgebiete liegen zwischen 0.820 ± 0.003 (Andernacherstr.) und 0.636 ± 0.002 (Gesamtzene) bei der Klassifikation mit allen zehn DAEDALUS Kanälen. Die Abnahme der Genauigkeit ist nicht direkt an die Klassenanzahl gekoppelt, auch wenn der schlechteste Kappa-Wert bei der Gesamtzene zustande kommt. Die Gebiete Innenstadt, Rennweg und Thon haben alle einen Kappa-Wert um 0.70. Insgesamt handelt es sich jedoch um gute bis sehr gute Klassifikationsergebnisse.

Die Reduktion der Kanalanzahl führt beim Testgebiet Andernacherstr. zur größten Abnahme der Genauigkeit, von 0.82 auf 0.729 ± 0.003 . Das Innenstadtgebiet erweist sich wieder als robust gegenüber der Reduktion, der Kappa-Wert bleibt mit 0.692 ± 0.004 nur um 0.016 unter dem Wert, der mit allen Kanälen erreicht wird. Die Abnahme der Kappa-Werte in den Gebieten Rennweg, Thon und der Gesamtzene bewegen sich um 0.07 bis 0.08.

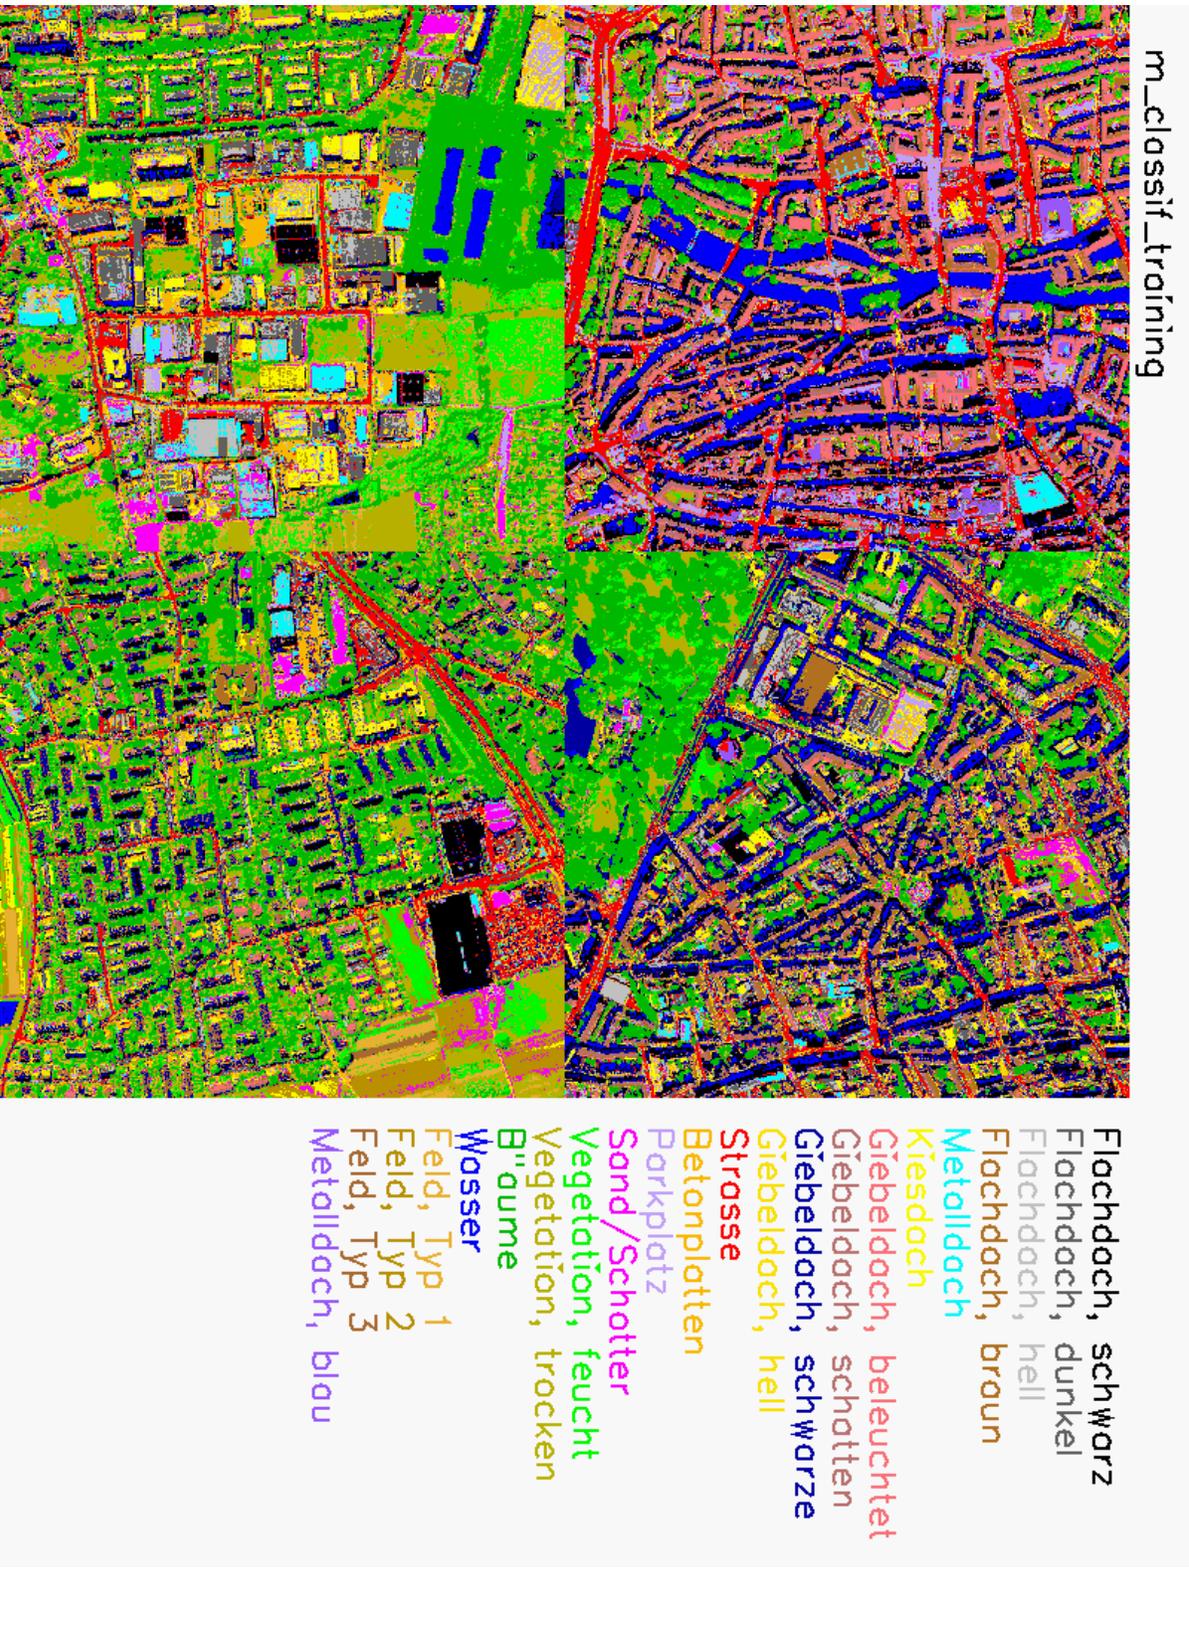


Abbildung 5.11: FKNN Klassifikation aller Kanäle, Testgebiet: Gesamtzone; oben links: Innenstadt; oben rechts: Renntweg; unten links: Andernacherstr.; unten rechts: Thon

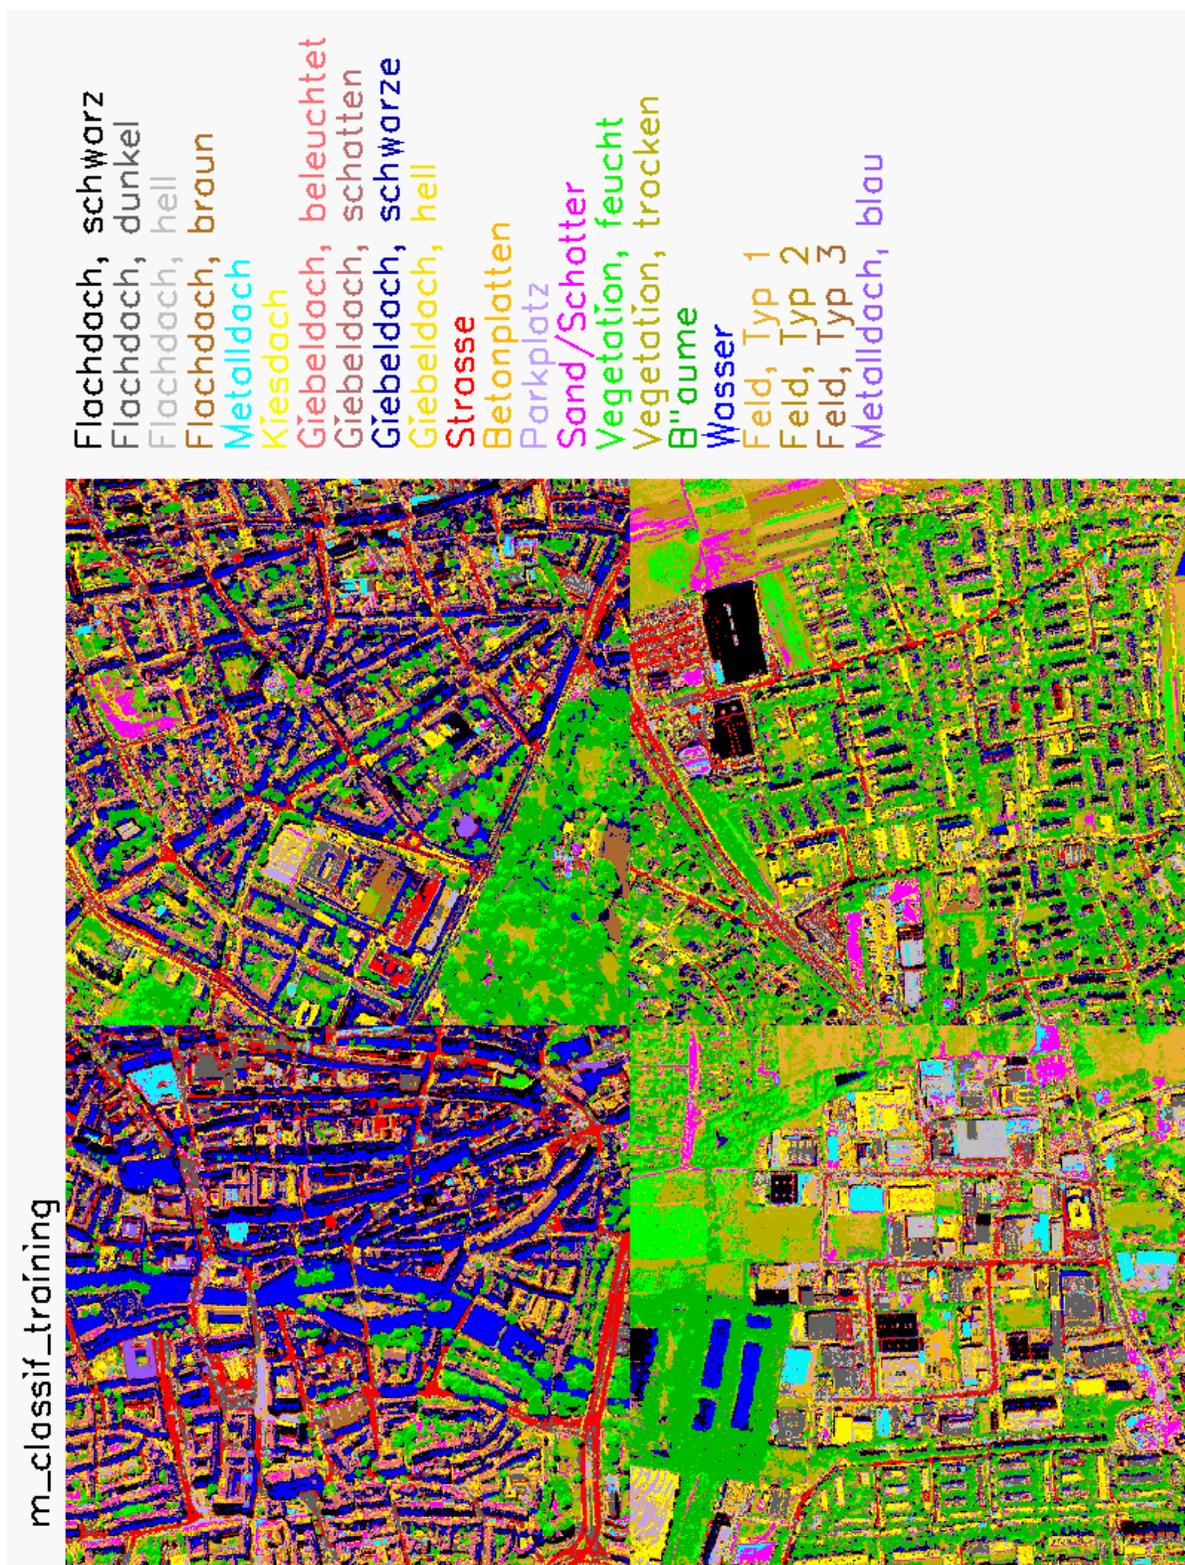


Abbildung 5.12: FKNN Klassifikation IKONOS Kanäle, Testgebiet: Gesamtzone; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr.; unten rechts: Thon

5.3 Fusion klassifizierter Daten

Bei der Fusion klassifizierter Daten wurden zwei Verfahren getestet. Die Verfahren wurden beim DLR in Oberpfaffenhofen entwickelt und an die optischen DAEDALUS Daten angepaßt. Das Programmpaket *Fuzzy Fusion Tool* ist in IDL entwickelt worden. Es bietet zwei verschiedene Fusionsalgorithmen an. Zum einem die Fusion mittels der gewichteten konvexen Linearkombination (FLK), zum anderen die Fusion mittels eines neuronalen Netzes (FNN). In beiden Fällen werden vorher klassifizierte Karten zu einer neuen (besseren) Klassifikation fusioniert. Als Grundlage zur Fusion dienen die mit FKNN erzeugten Einzel-Kanal-Klassifikationen, wobei die *possibility maps* fusioniert werden.

5.3.1 Gewichtete konvexe Linearkombination (FLK)

Die konvexe Linearkombination von Fuzzy-Klassifikationen ist in Kapitel 2.5.1 auf Seite 44 beschrieben. Die Gewichte, mit denen die Klassen und Klassifikationen gewichtet werden, ergeben sich aus dem Fuzzy-Gütemaß FPAUA. Diese Gütemaße sind mit dem IDL Programm `errormatrix.pro` berechnet worden.

Programm: Fuzzy Fusion Tool

Parameter:

Fusionsmethode = FLK,
 Kanalanzahl = 10 (alle) oder 4 (IKONOS),
 Gütemaß = FPAUA

5.3.1.1 Testgebiet Andernacherstr.

Die Kombination aller mit FKNN klassifizierten Kanäle zeigt die Karte in Abbildung 5.13. Die markierten Gebiete entsprechen denen der vorherigen Klassifikationen. In Abbildung 5.14 ist das gleiche Testgebiet mit den vier IKONOS Kanälen fusioniert worden. Die interessanten Gebiete sind 1, 2, 4, 5, 6, 8, 9, 11 und 12. In Abb. 5.13 ist das Wasser im Freibad noch weitgehend richtig klassifiziert worden, bei der Reduktion auf vier Kanäle treten wieder die bekannten Probleme auf. Das Waldgebiet 2 wird bei geringerer Kanalanzahl weniger gut erkannt. Im Bereich 4 tritt teilweise eine Verwechslung zwischen der Klasse "Metalldach" und der Klasse "Sand" auf. Dieses Dach zeichnet sich durch ein starkes Relief aus, die einzelnen Dachflächen sind stark gegeneinander geneigt, so daß sehr stark reflektierenden Flächen sich mit weniger stark reflektierende Flächen abwechseln. Die Klassen "Metalldach" und "Sand" liegen dicht beieinander. Das Dach im Gebiet 6 wird hauptsächlich als "Betonplatten" erkannt, obwohl es ein Kiesdach ist. Dasselbe tritt im Gebiet 9 auf. Im Gebiet 8 wird das Dach als "Flachdach, hell" klassifiziert, was

nicht richtig ist, wie man anhand der Validierungskarte sehen kann. Zu einer drastischen Fehlklassifikation kommt es im Gebiet 11. Bei der Verwendung aller Kanäle wird diese trockene Wiesenfläche hauptsächlich als Sand erkannt, der teilweise unter der trockenen Vegetation auf dem CIR-Foto zu sehen ist. Mit nur vier Kanälen erscheint das Gebiet als Straßenbereich. Das Gebiet 12 hingegen wird in beiden Klassifikationen richtig als Sandfläche erkannt.

5.3.1.2 Gesamtszene

Die Fusion der Einzel-Kanal-Klassifikationen der Gesamtszene erwies sich als sehr schlecht. Die Hauptursache dürfte darin liegen, daß die Klassifikation eines Kanals in 22 Klassen nicht funktioniert. Wie man an dem klassenspezifischen Gütemaß FPAUA in den Tabellen im Anhang erkennt, gibt es Klassen, die sehr niedrige Gütemaße haben. Bei der Klassifikation der einzelnen Kanäle kam es vor, daß eine oder mehrere Klassen in einem Kanal gar nicht erkannt wurden. Die Aufteilung von maximal 255 Werten in 22 Klassen bedingt eine kleine Klassengröße oder sich überlappenden Klassen.

In der Klassifikation mit allen zehn Kanälen (Abb. 5.15) sind drei Auffälligkeiten zu sehen. Die Klasse "Flachdach, hell" kommt fast gar nicht vor. Es gibt Verwechslungen zwischen den Klassen "Betonplatten" und "Parkplatz". Die Vegetation wird häufig als Wasser klassifiziert, insbesondere die Bäume. Die Klasse "Wasser" tritt sehr oft auf, wobei wieder die Schattengebiete eine große Rolle spielen.

Bei der Verwendung der IKONOS Kanäle sieht das Ergebnis noch schlechter aus (s. Abb. 5.15). Die Hausdächer im Testgebiet Innenstadt sind alle gelblich gefärbt, d.h. sie gehören entweder der Klasse "Giebedach, hell", oder der Klasse "Kiesdach" an. Die Vegetation wird auch größtenteils als Wasser erkannt.

5.3.1.3 Kappa-Werte

Die Kappa-Werte für die FLK der verschiedenen Testgebiete sind in Tabelle 5.7 aufgeführt.

Testgebiet:	Andernacherstr.	Innenstadt	Rennweg	Thon Gesamtszene
FLK(alle):	0.687 ± 0.003	0.561 ± 0.004	0.496 ± 0.006	0.386 ± 0.005 0.342 ± 0.002
FLK(ikonos):	0.598 ± 0.003	0.457 ± 0.004	0.357 ± 0.006	0.324 ± 0.004 0.246 ± 0.002

Tabelle 5.7: Kappa-Werte der Klassifikation durch FLK für die verschiedenen Testgebiete.

Die Kappa-Werte der FLK liegen deutlich niedriger als bei den vorherigen Methoden. Die Fehler Werte sind auch etwas höher, als bei den anderen Verfahren, bewegen sich aber

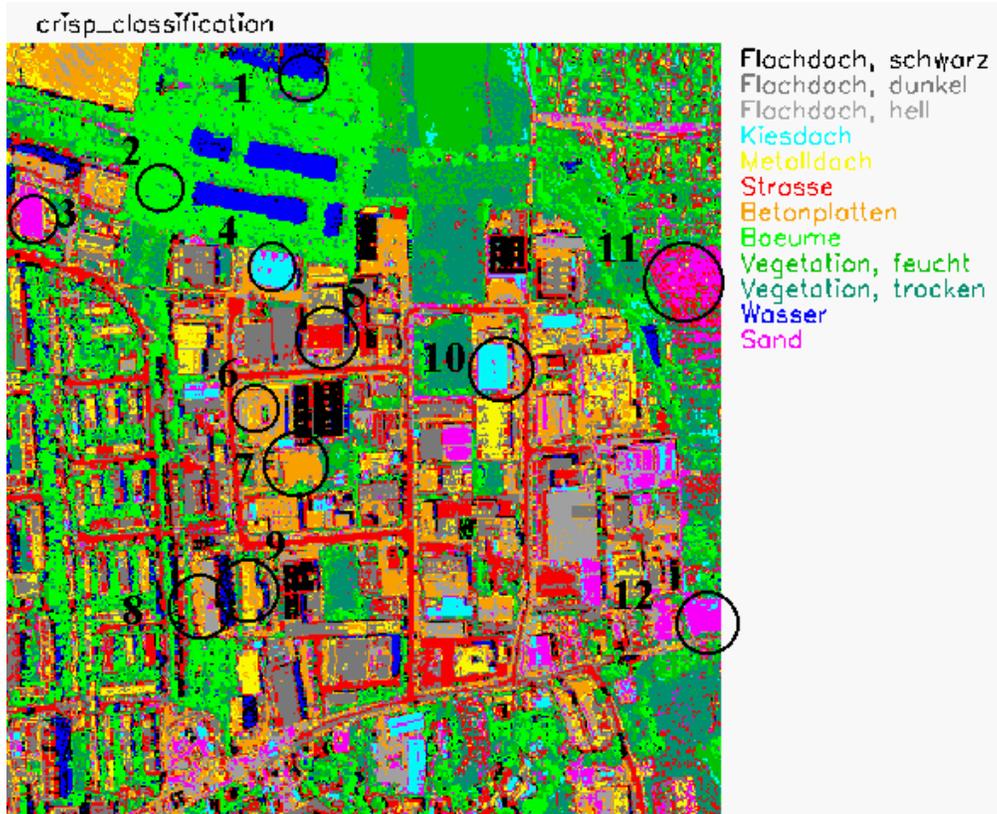


Abbildung 5.13: FLK Klassifikation aller Kanäle, Testgebiet: Andernacherstr.

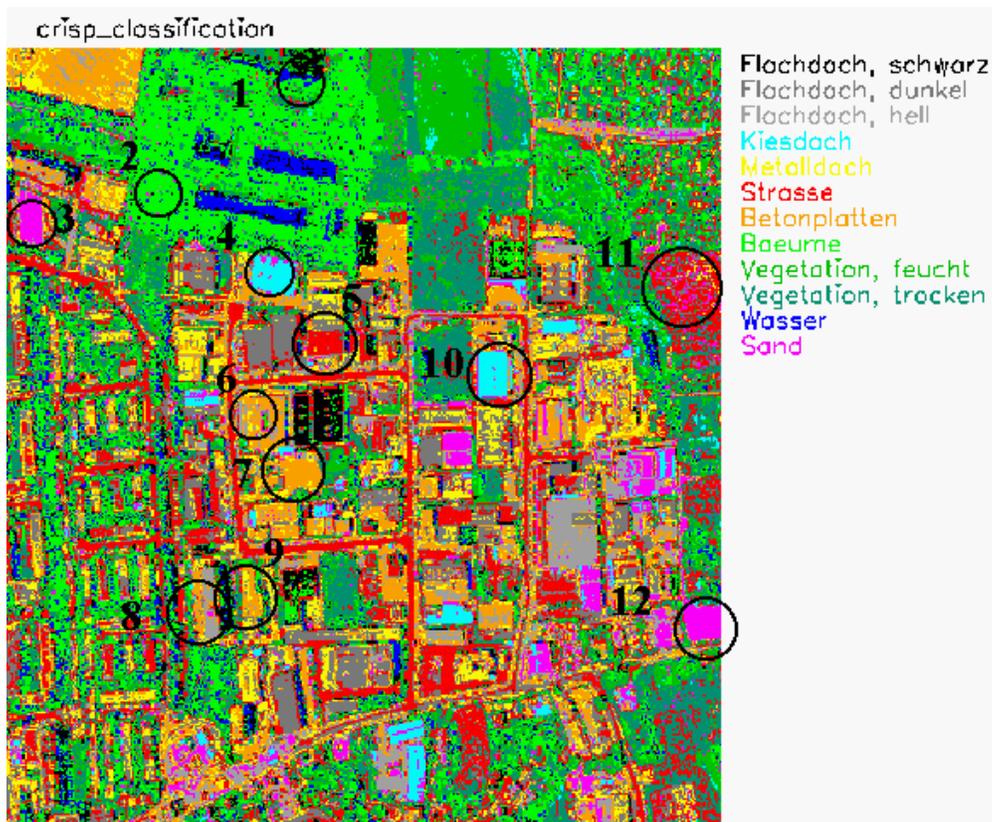


Abbildung 5.14: FLK Klassifikation IKONOS Kanäle, Testgebiet: Andernacherstr. Die eingekreisten Gebiete 1 bis 12 stellen Bereiche dar, in denen sich die einzelnen Klassifikationsverfahren besonders deutlich unterscheiden.

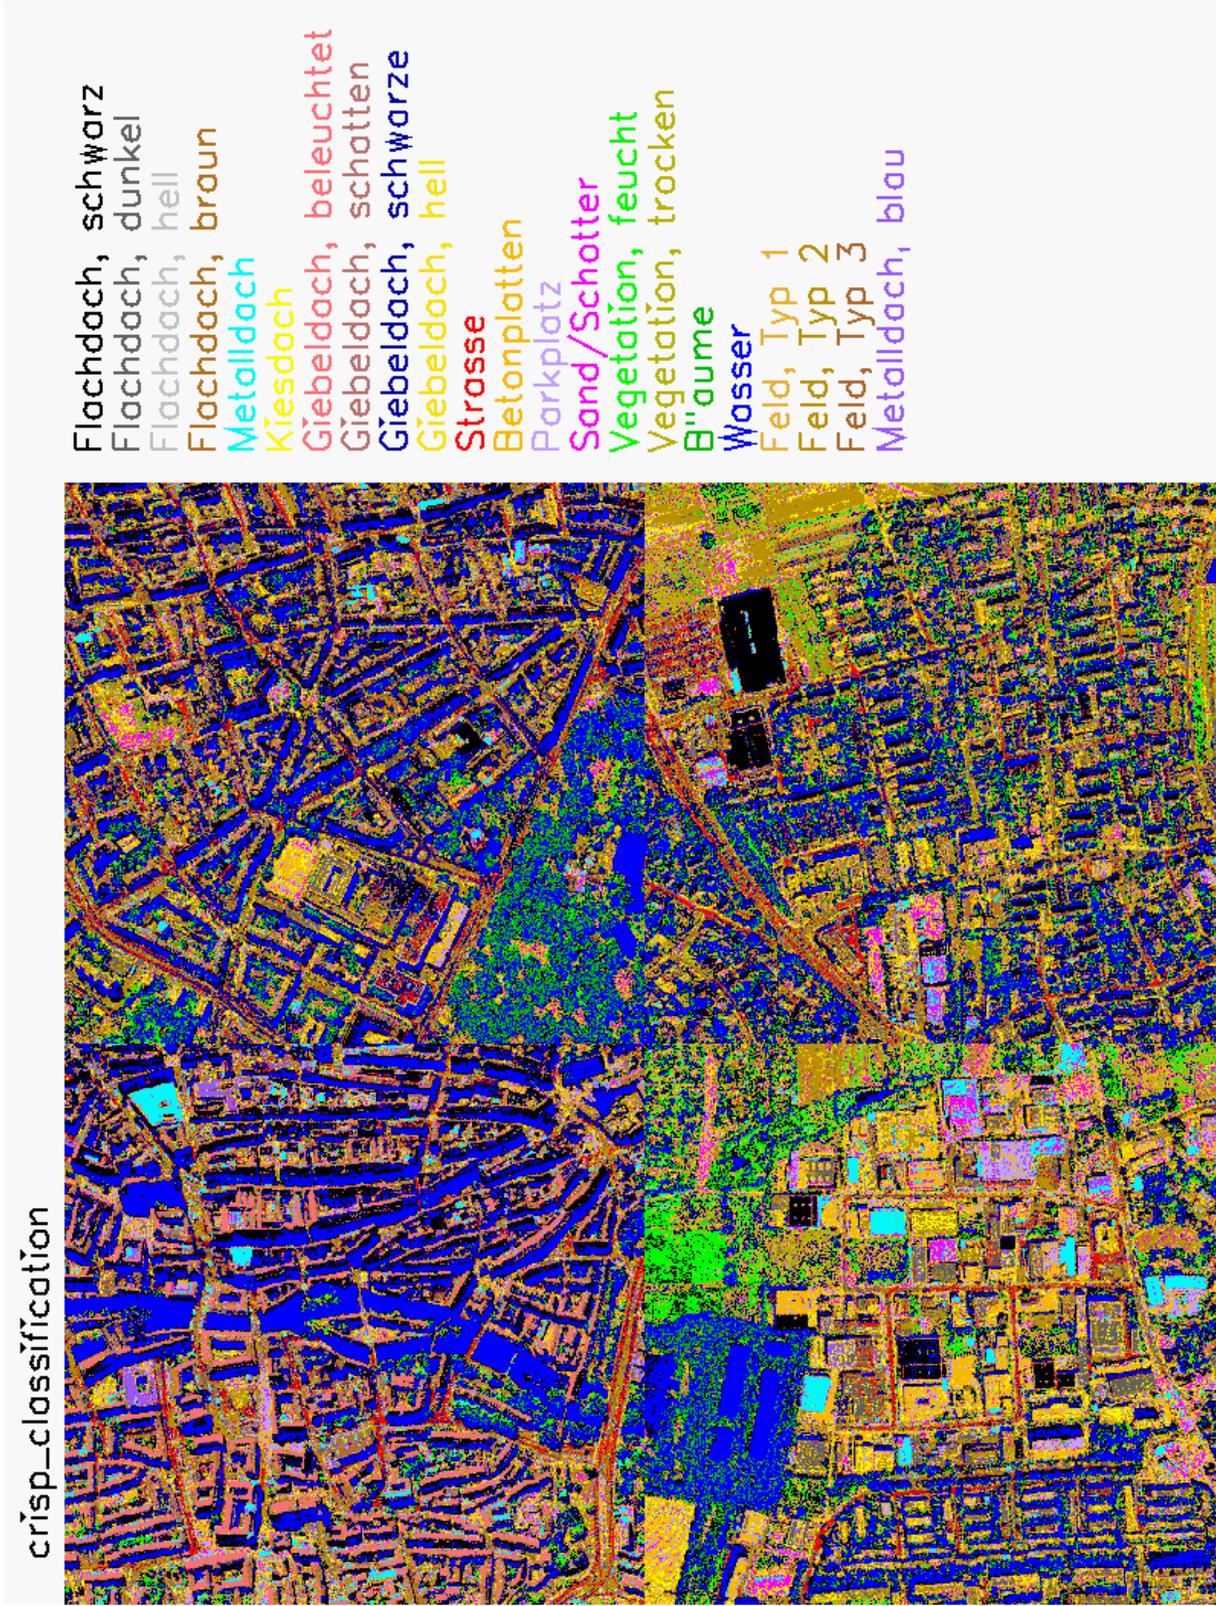


Abbildung 5.15: FLK Klassifikation aller Kanäle, Testgebiet: Gesamtzene; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr. ; unten rechts: Thon

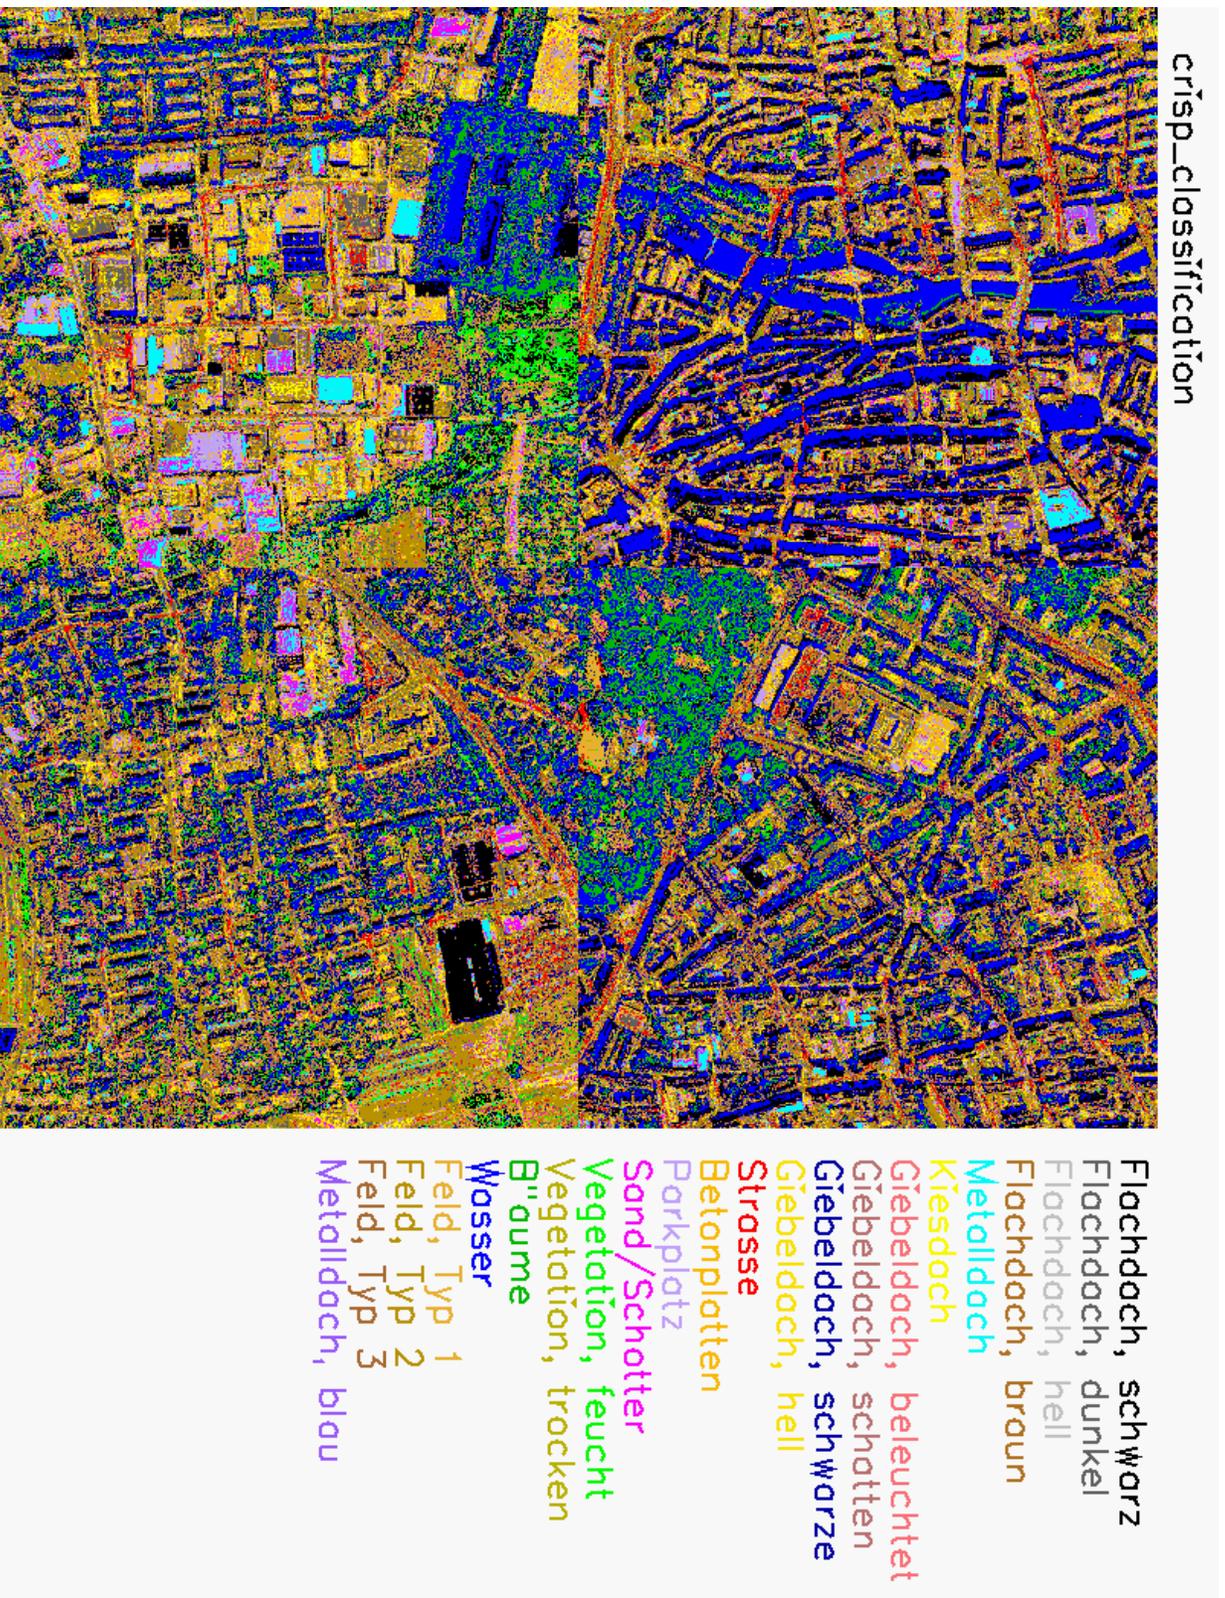


Abbildung 5.16: FLK Klassifikation IKONOS Kanäle, Testgebiet: Gesamtzone; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr.; unten rechts: Thonweg

immer noch im Bereich der dritten Nachkommastelle. Bei der Fusion aller Einzel-Kanal-Klassifikationen ergibt sich das beste Ergebnis für die Andernacherstr. (0.687 ± 0.003). Mit zunehmender Klassenanzahl nimmt der Kappa-Wert stark ab. Rennweg (15 Klassen) hat einen Kappa-Wert von 0.496 ± 0.006 , Thon (16 Klassen) von 0.386 ± 0.005 und das Gesamtgebiet (22 Klassen) von nur noch 0.342 ± 0.002 . Diese Abnahme läßt sich dadurch erklären, daß die einzelnen Kanäle nicht mehr gut in die entsprechenden Klassen eingeteilt werden können (s.o.).

Dieser Effekt wird bei der Verwendung von nur vier Einzel-Kanal-Klassifikationen zur Fusion noch stärker. Die Kappa-Werte liegen jetzt zwischen 0.598 ± 0.003 (Andernacherstr.) und 0.246 ± 0.002 (Gesamtscene).

5.3.2 Neuronales Netz (FNN)

Für die Fusion mit dem neuronalen Netz werden die Fuzzy-Klassifikationen (FNN) und die Validierungskarten benötigt. Das neuronale Netz lernt mittels des *back-propagation* Algorithmus'. Da die erzielten Ergebnisse ähnlich gut sind, wie die der ML Klassifikation, wurde auch untersucht, wie sich die Ergebnisse ändern, wenn man die Kanalanzahl reduziert. Die Ergebnisse der Auswahl 9 aus 10 Kanäle sind ebenfalls angegeben (s. Tab. 5.10 auf Seite 106). Eine weitere Reduktion der Kanalanzahl ist [Reg00] untersucht worden.

Programm: Fuzzy Fusion Tool

Parameter: Fusionsmethode = FNN,
 Kanalanzahl = 10 (alle) oder 4 (IKONOS),
 Anzahl der verdeckten Neuronen = (je nach
 Klassenanzahl),
 Anzahl der Trainingsiterationen = 1

5.3.2.1 Testgebiet Andernacherstr.

Die Fusion FNN zeigt deutlich bessere Ergebnisse als die FLK. Trotz der gleichen Datenbasis, die aus den Fuzzy-Ergebnissen der FKNN Klassifikationen (*possibility maps*) der einzelnen Spektralkanäle besteht. Die Gütemaße der FNN sind annähernd so gut wie bei der ML Klassifikation, optisch machen sie sogar einen besseren Eindruck. Die in Abbildung 5.17 und 5.18 gezeigten Klassifikationen haben gut von einander abgrenzte Gebiete. Im Freibad im Gebiet 1 ist eine rote Linie zu erkennen, diese Markierung ist auf den Luftfotos auch zu sehen, wenngleich es sich nicht um eine Straße handelt. Die beiden Sand/Schotter Flächen in den Gebieten 3 und 12 werden richtig erkannt. Im Wald um die Wasserflächen bei Gebiet 2 sind kleine blaue Flächen zu sehen, die nicht Wasser sind. Es handelt sich um Schatten, der auf Bäume fällt. Dies tritt bei der ML Klassifikation nicht auf.

Die Auswahl der IKONOS Kanäle verschlechtert die Klassifikation in einigen Bereichen (s. Abb. 5.18). Im Freibadbereich (Gebiet 1) wird jetzt auch die Klasse “Flachdach, schwarz“ erkannt. Das dunkle Flachdach in Gebiet 5 wird wieder der Klasse “Straße“ zugeordnet. Die Fehlklassifikation des Gebietes 11, wie bei der FLK, tritt nicht mehr auf. Die Metalldächer in Gebiet 4 und 10 werden in allen Klassifikationen richtig erkannt. Die Fuzzy-Verfahren neigen allerdings zu einer Verwechslung mit der Klasse “Sand“. Dies ist bei der ML Klassifikation andersherum. Die Klasse “Sand“ wird häufig als “Metalldach“ klassifiziert.

5.3.2.2 Gesamtszene

Der bei der Fusion mit FLK benannte Nachteil tritt beim neuronalen Netz nicht auf. Die FLK benötigt zur Fusion die FPAUA Werte, die, wie erwähnt, für einzelne Klassen der Einzel-Kanal-Klassifikationen sehr klein sein können. Die FNN benutzt die *possibility maps* als Eingangsdaten. Mit Hilfe dieser Zugehörigkeiten findet das Netz genügend Strukturen in den Daten, um eine gute Klassifikation zu erreichen.

In Abbildung 5.19 ist das Ergebnis der Klassifikation mit allen DAEDALUS Kanälen gezeigt. Die Abbildung 5.20 wurde nur mit den vier IKONOS Kanälen erzeugt. Es zeigt sich wieder der hohe Schattenanteil in den Testgebieten Innenstadt und Rennweg. Der Schatten wird hauptsächlich als Wasser klassifiziert. Die Hausdächer kommen dafür gut heraus. Im Gebiet Andernacherstr. sind die meisten Klassen wieder richtig zugewiesen worden. Im Gebiet Thon sehen die dunkelblauen Hausdächer der Klasse Wasser recht ähnlich, sind aber richtig als “Giebedach, schwarz“ erkannt worden.

5.3.2.3 Kappa-Werte

Die Kappa-Werte für FNN der verschiedenen Testgebiete sind in Tabelle 5.8 aufgeführt, ebenso der statistische Fehler.

Testgebiet:	Andernacherstr.	Innenstadt	Rennweg	Thon Gesamtszene
FNN(alle):	0.834 ± 0.003	0.760 ± 0.004	0.710 ± 0.006	0.754 ± 0.004 0.757 ± 0.002
FNN(ikonos):	0.752 ± 0.003	0.689 ± 0.004	0.624 ± 0.006	0.629 ± 0.005 0.620 ± 0.002

Tabelle 5.8: Kappa-Werte der Klassifikation durch FNN für die verschiedenen Testgebiete.

Die Kappa-Werte der unterschiedlichen Testgebiete können mit gut bis sehr gut bewertet werden. Das Testgebiet Andernacherstr. zeichnet sich durch den höchsten Kappa-Wert (0.834 ± 0.003) aus. Die Kappa-Werte der anderen Testgebiete liegen bei 0.75. Nur das

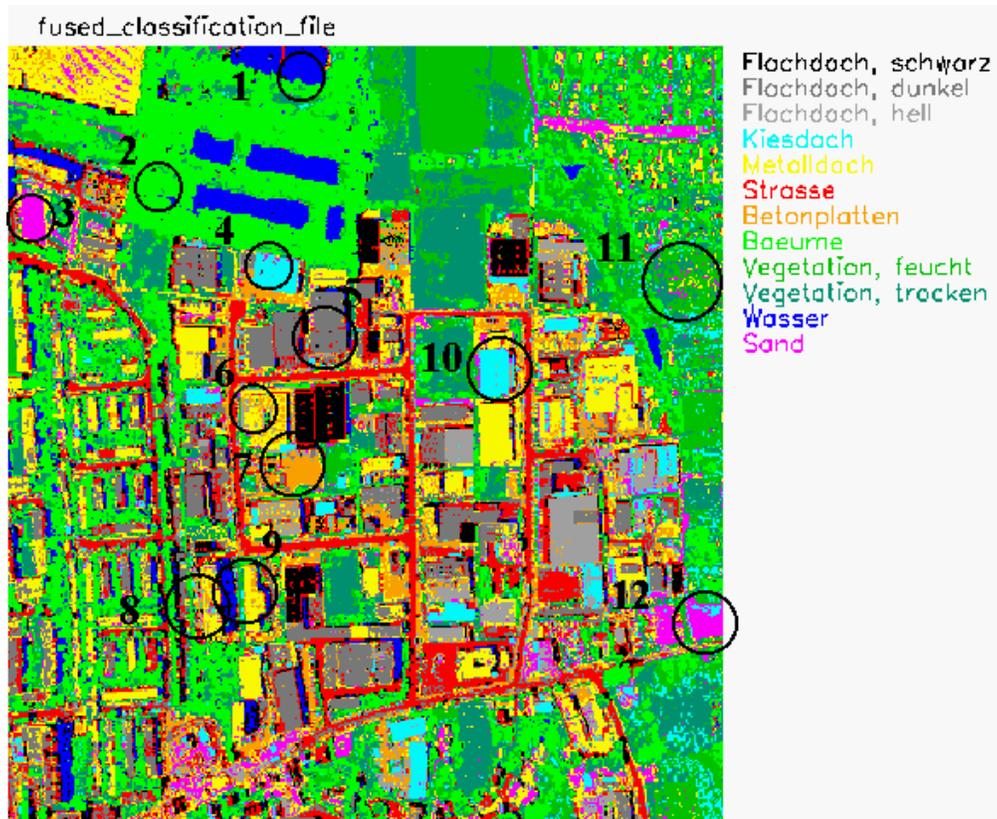


Abbildung 5.17: FNN Klassifikation aller Kanäle, Testgebiet: Andernacherstr.

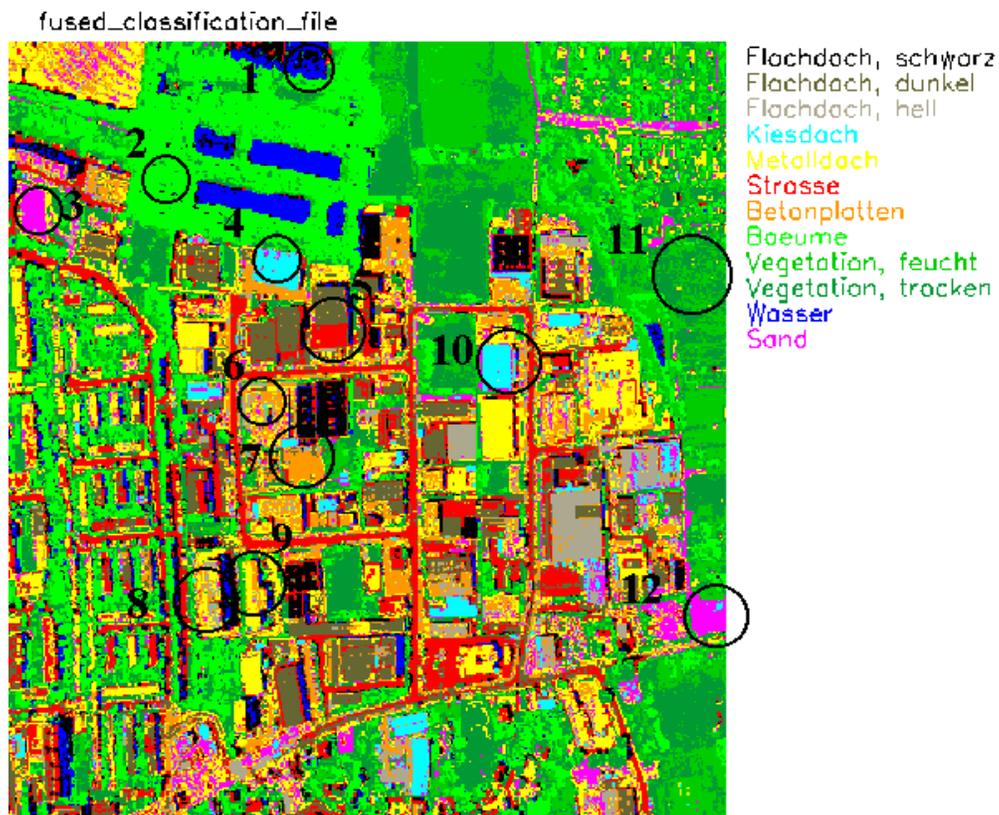


Abbildung 5.18: FNN Klassifikation IKONOS Kanäle, Testgebiet: Andernacherstr. Die eingekreisten Gebiete 1 bis 12 stellen Bereiche dar, in denen sich die einzelnen Klassifikationsverfahren besonders deutlich unterscheiden.

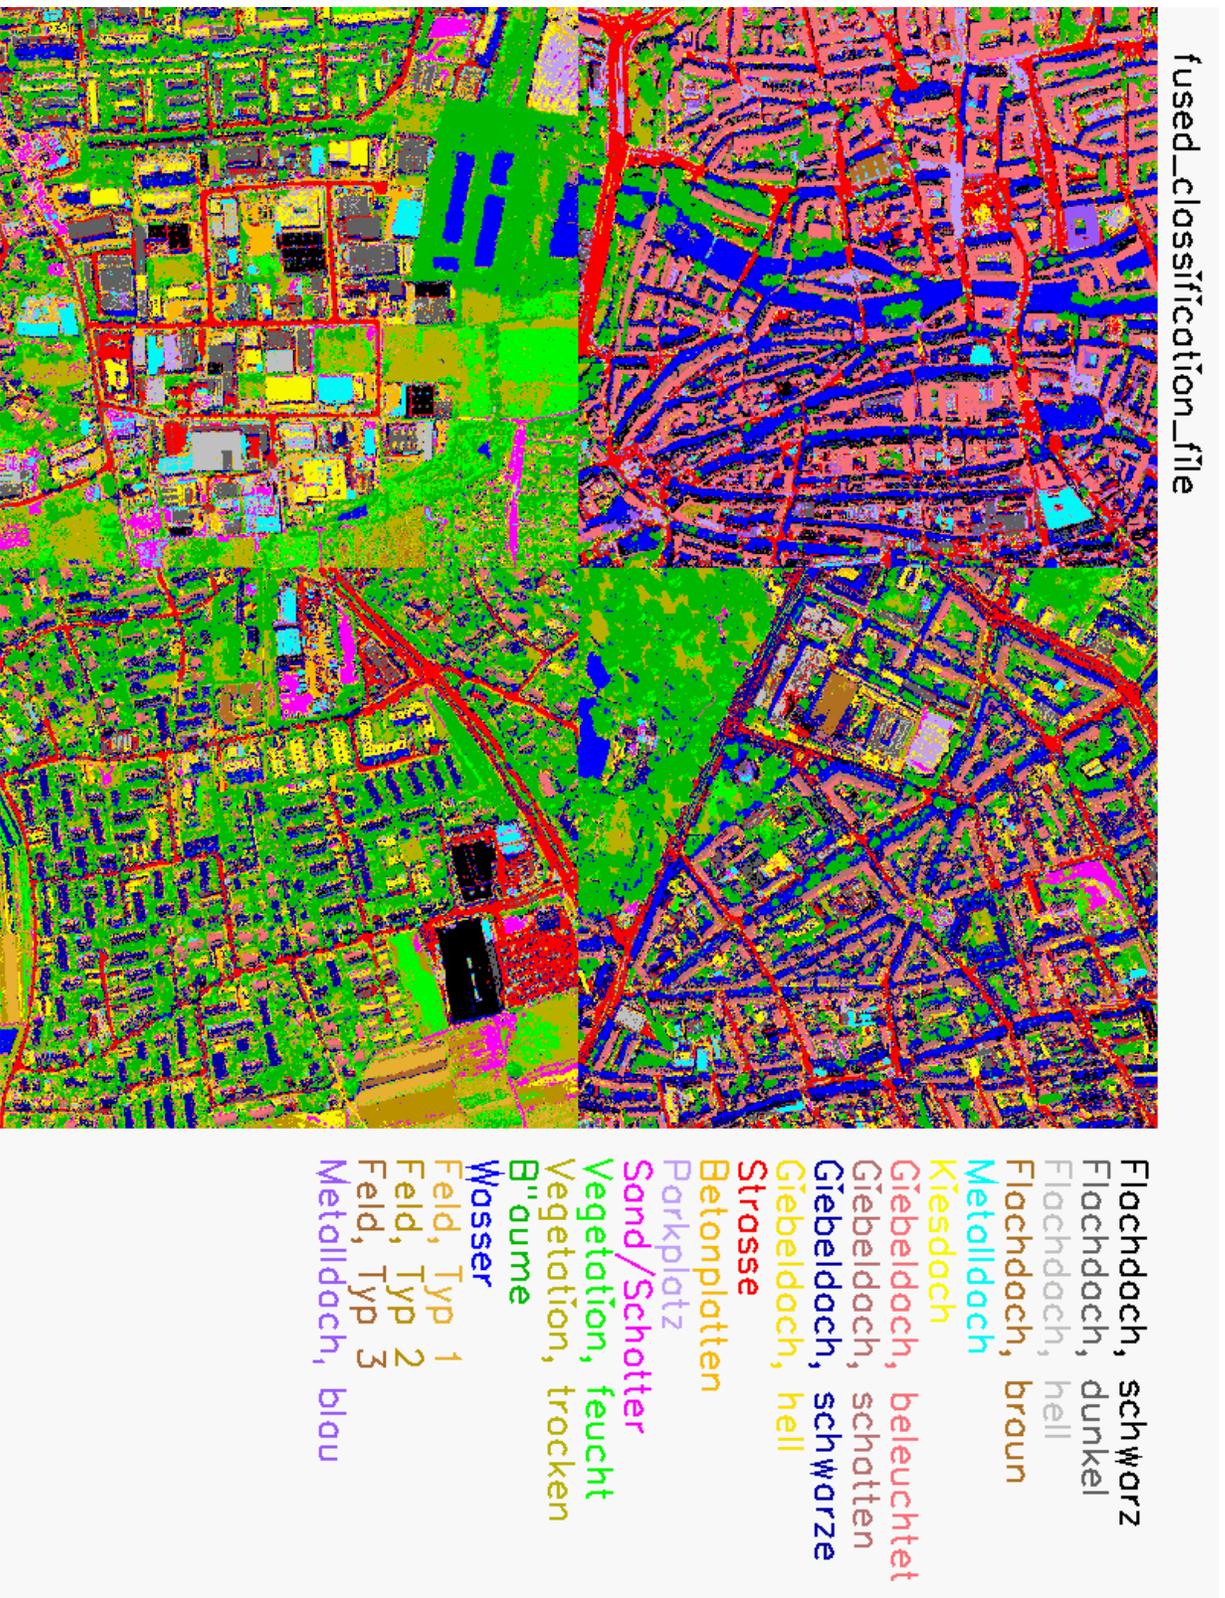


Abbildung 5.19: FNN Klassifikation aller Kanäle, Testgebiet: Gesamtzene; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr. ; unten rechts: Thon

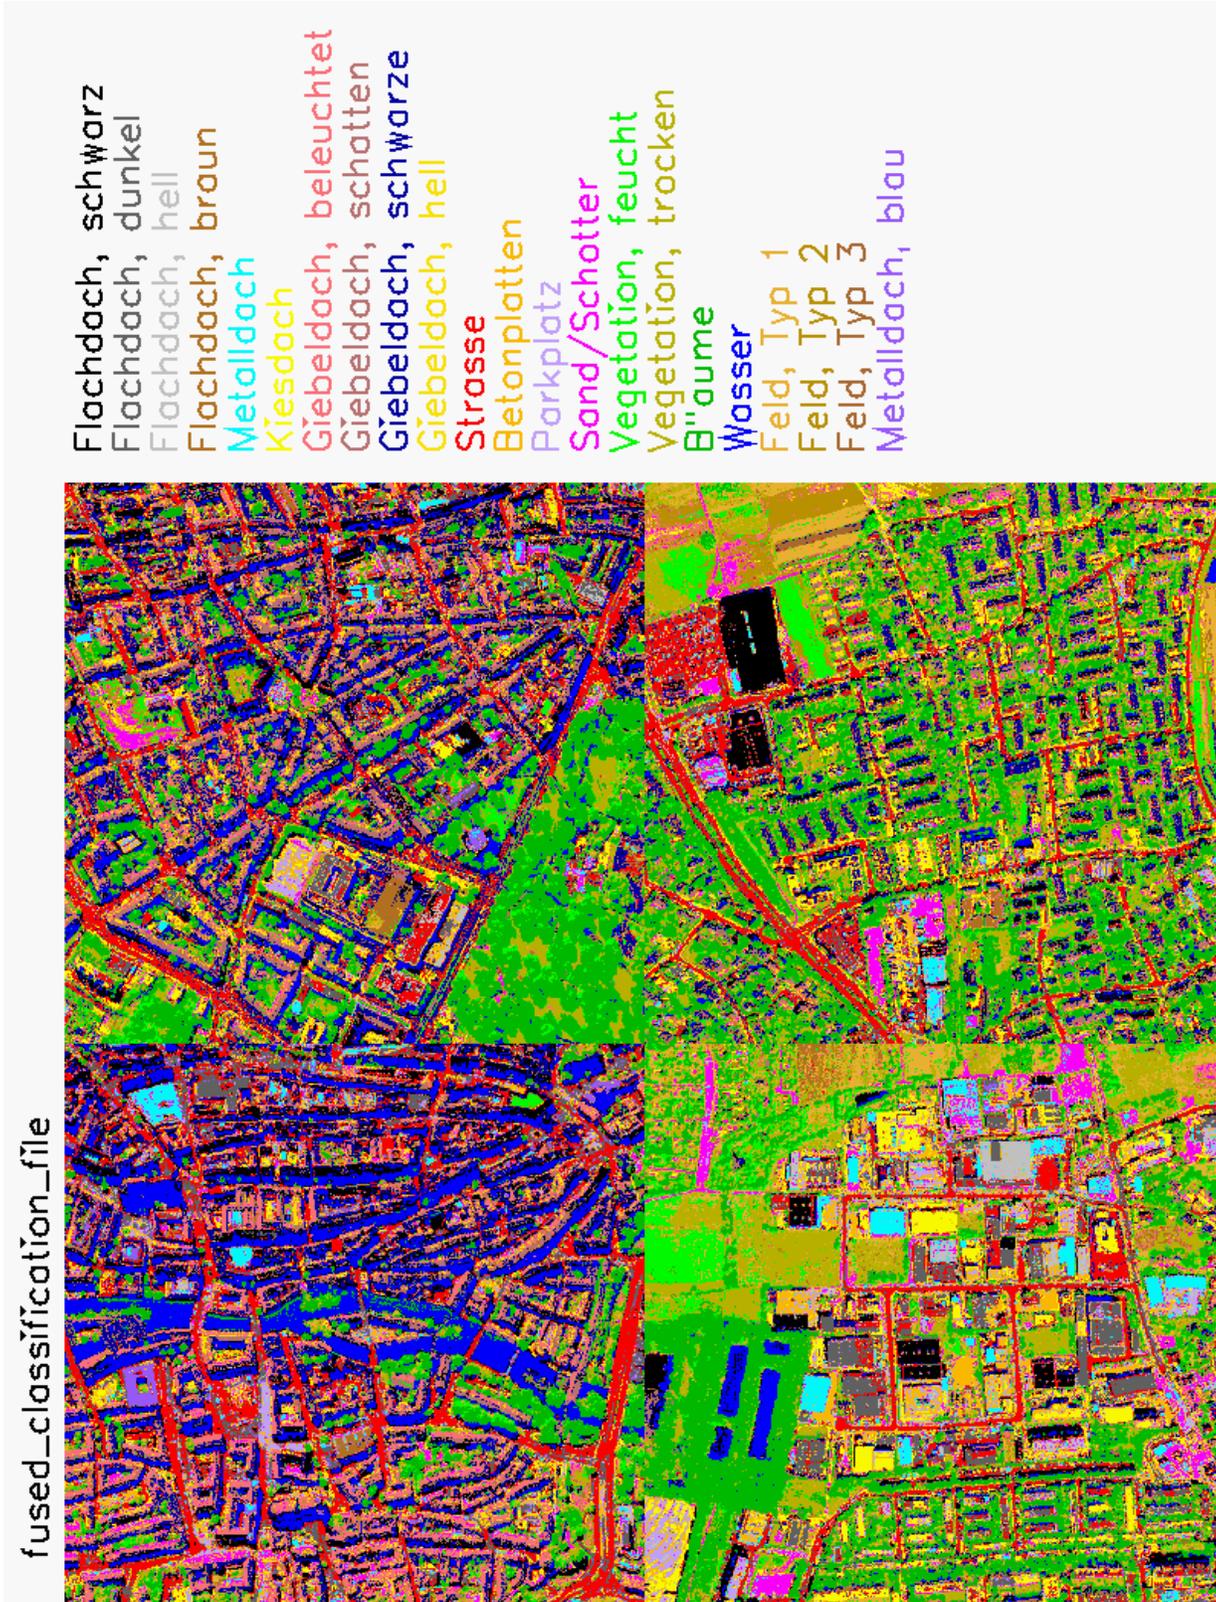


Abbildung 5.20: FNN Klassifikation IKONOS Kanäle, Testgebiet: Gesamtzone; oben links: Innenstadt; oben rechts: Rennweg; unten links: Andernacherstr.; unten rechts: Thon

Gebiet Rennweg liegt etwas niedriger mit einem Kappa-Wert von 0.71. Die FNN zeigt sich erstaunlich robust gegenüber der Erhöhung der Klassenanzahl. Trotz der gleichen Datenbasis von FLK und FNN werden viel höhere Kappa-Werte erreicht.

Deutlicher bemerkbar macht sich hingegen die Reduktion der Anzahl der fusionierten Klassifikationen. Die Kappa-Werte nehmen zwischen 0.071 (Innenstadt) und 0.132 (Gesamtszene) ab. Aber auch hier liegt die Genauigkeit immer noch deutlich über jener der FLK. Die Ergebnisse sind in allen Gebiet als gut zu bewerten.

5.4 Zusammenfassung

Es werden die Kappa-Werte der einzelnen Verfahren miteinander verglichen und bewertet. Die Fehler der Kappa-Werte lagen dabei in der dritten Nachkommastelle und wurden hauptsächlich durch die Anzahl der Testpixel bestimmt. Zunächst wird die Kanalauswahl "alle Kanäle" und "IKONOS Kanäle" betrachtet. Als weitere Untersuchung der Effekte der Kanalreduktion werden noch die Kappa-Werte der ML Klassifikationen und der FNN für die Auswahl von 9 aus 10 Kanälen dargestellt.

5.4.1 Kanalauswahl: Alle Kanäle und IKONOS Kanäle

In Tabelle 5.9 werden die Kappa-Werte der verschiedenen Verfahren mit einander verglichen. Die statistische Schwankung der Kappa-Werte ist der Tabelle zu entnehmen. Zum einen wurden alle Kanäle (alle) des DAEDALUS Detektors benutzt, zum anderen eine Auswahl von vier Kanälen, die denen des IKONOS Satelliten (ikonos) entsprechen.

ML Klassifikation Die höchsten Kappa-Werte erreicht die ML Klassifikation mit einem Kappa-Wert von bis zu 0.902 bei der Klassifikation der Testszene Andernacherstr. mit allen Kanälen. Am schlechtesten bei der ML Klassifikation wird die Gesamtszene bei vier Kanälen bewertet mit einem Kappa-Wert von 0.674. Bei der Gesamtszene ist der Unterschied zwischen der Auswahl aller Kanäle und vier Kanäle am größten mit einer Differenz von 0.096. Ähnlich groß ist der Unterschied im Testgebiet Rennweg, 0.859 (alle Kanäle) zu 0.764 (IKONOS Kanäle). Die Kappa-Werte der einzelnen Testszene liegen zwischen 0.841 (Thon) und 0.902 (Andernacherstr.). D.h., daß die Klassifikationen sehr gut bewertet werden. Die Reduzierung der Kanalanzahl auf 4 Kanäle hat bei der ML Klassifikation je nach Testgebiet unterschiedliche Effekte.

FKNN Klassifikation Gute Kappa-Werte hat die FKNN Klassifikation ergeben. Mit Werten zwischen 0.636 (Gesamtszene) und 0.820 (Andernacherstr.) für alle Kanäle und 0.552 (Gesamtszene) und 0.729 (Andernacherstr.) für vier Kanäle. Die Differenz zwischen den beiden Kanalauswahlen bewegt sich wieder um 0.07. Auffällig ist hier der nur geringe Unterschied (0.016) im Testgebiet Innenstadt.

Testgebiet:	Andernacherstr.	Innenstadt	Rennweg	Thon Gesamtszene
	Kappa :	Kappa :	Kappa :	Kappa :
ML(alle):	0.902 ± 0.002	0.884 ± 0.003	0.859 ± 0.004	0.841 ± 0.004 0.770 ± 0.002
ML(ikonos):	0.870 ± 0.002	0.887 ± 0.003	0.764 ± 0.005	0.771 ± 0.004 0.674 ± 0.002
FKNN(alle):	0.820 ± 0.003	0.708 ± 0.004	0.706 ± 0.006	0.701 ± 0.005 0.636 ± 0.002
FKNN(ikonos):	0.729 ± 0.003	0.692 ± 0.004	0.645 ± 0.006	0.635 ± 0.005 0.552 ± 0.002
FLK(alle):	0.687 ± 0.003	0.561 ± 0.004	0.496 ± 0.006	0.386 ± 0.005 0.342 ± 0.002
FLK(ikonos):	0.598 ± 0.003	0.457 ± 0.004	0.357 ± 0.006	0.324 ± 0.004 0.246 ± 0.002
FNN(alle):	0.834 ± 0.003	0.760 ± 0.004	0.710 ± 0.006	0.754 ± 0.004 0.757 ± 0.002
FNN(ikonos):	0.752 ± 0.003	0.689 ± 0.004	0.624 ± 0.006	0.629 ± 0.005 0.620 ± 0.002

Tabelle 5.9: Kappa-Werte der verschiedenen Klassifikationsverfahren auf unterschiedlichen Testgebieten.
“alle“ - alle Kanäle; “ikonos“ - IKONOS Kanäle
FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK - Fusion über gewichtete Linearkombination; FNN - Fusion mittels neuronalen Netz; ML - Maximum Likelihood Klassifikation

Klassifikation durch FNN Für die Klassifikation durch FNN werden sehr gute Kappa-Werte erreicht. Der optische qualitative Eindruck vermittelt teilweise sogar ein besseres Klassifikationsergebnis als die ML Klassifikation. Die Kappa-Werte reichen von 0.71 (Rennweg) bis 0.834 (Andernacherstr.). Die Gesamtszene wird ähnlich gut bewertet wie die Einzelszenen. Die Reduktion der Kanalanzahl macht sich bei dieser Methode sehr viel deutlicher bemerkbar als bei der ML Klassifikation. Die Kappa-Werte fallen um bis zu 0.125 (Thon) ab. Besonders groß ist der Unterschied bei der Gesamtszene (0.137), was auf die hohe Klassenanzahl und die dadurch bedingte schlechte Klassifikation der Einzel-Kanal-Bilder zurückzuführen ist. Dies hat auch den drastischen Abfall im Testgebiet Thon bedingt.

Klassifikation durch FLK Am schlechtesten schneidet das Verfahren der gewichteten konvexen Linearkombination ab. Die Kappa-Werte liegen bei der Auswahl aller Einzel-Kanal-Klassifikationen zwischen 0.687 (Andernacherstr.) und 0.342 (Gesamtszene). Es

zeigt sich deutlich, wie mit der höheren Klassenanzahl die Genauigkeit der Klassifikation abnimmt. Der Unterschied bei der Klassifikation mit vier Kanälen bewegt sich zwischen 0.089 (Andernacherstr.) und 0.139 (Rennweg).

Zusammenfassend läßt sich sagen, daß die ML Klassifikation in den Trainingsgebieten die höchsten Genauigkeiten erzielt. Das nächstbeste Verfahren ist FNN, das bei den Kappa-Werten zwischen 0.013 (Gesamtszene) und 0.149 (Rennweg) schlechter liegt als die ML Klassifikation.

Die Reduktion der Kanalanzahl auf nur vier Kanäle führt bei der ML Klassifikation zu geringeren Abnahmen der Genauigkeit als bei den anderen Verfahren. Hierbei zeigen sich die FKNN Klassifikation und die FNN ähnlich robust.

Bei hohen Klassenanzahlen ist die FNN Klassifikation ähnlich gut wie die ML Klassifikation. Ob dies nun an der erwähnten niedrigen Trainingselementanzahl bei der ML Klassifikation liegt, wurde nicht untersucht.

5.4.2 Kanalauswahl: 9 aus 10 Kanälen

Um eine systematische Untersuchung des Einflusses der Kanalanzahl auf die Klassifikation zu machen, wurde eine Auswahl von 9 aus 10 Kanälen getroffen. Bei den zehn Klassifikationen wurde jeweils einer von zehn Kanälen nicht berücksichtigt. Die Analyse wurde mit den Verfahren ML und FNN gemacht, da diese die genauesten Klassifikationen geliefert haben. Die Fehler im Kappa-Wert werden nicht mehr mit angegeben, da diese weiterhin nur die dritte Nachkommastelle betreffen.

	Andernacherstr.		Innenstadt		Rennweg		Thon		Gesamtszene	
ohne	ML	FNN	ML	FNN	ML	FNN	ML	FNN	ML	FNN
ch1	0.914	0.839	0.889	0.747	0.877	0.727	0.836	0.779	0.792	0.753
ch2	0.906	0.827	0.887	0.747	0.861	0.689	0.823	0.756	0.777	0.738
ch3	0.916	0.829	0.894	0.756	0.873	0.724	0.812	0.764	0.777	0.755
ch4	0.912	0.836	0.887	0.758	0.877	0.724	0.834	0.751	0.789	0.751
ch5	0.912	0.838	0.891	0.761	0.864	0.706	0.833	0.770	0.787	0.748
ch6	0.909	0.838	0.882	0.747	0.874	0.712	0.830	0.768	0.780	0.752
ch7	0.902	0.827	0.880	0.749	0.870	0.716	0.832	0.760	0.780	0.750
ch8	0.903	0.828	0.873	0.743	0.875	0.712	0.831	0.769	0.782	0.751
ch9	0.909	0.827	0.892	0.754	0.876	0.717	0.825	0.765	0.761	0.740
ch10	0.903	0.816	0.891	0.754	0.868	0.712	0.820	0.736	0.773	0.733

Tabelle 5.10: Kappa-Werte der Kanalauswahl 9 aus 10 für alle Testgebiete. Es sind die Kappa-Werte für die ML Klassifikation und Fusion mittels neuronalem Netz (FNN) angegeben.

Die Tabelle 5.10 zeigt die Ergebnisse der Kappa-Werte für die Kanalauswahl 9 aus 10 Kanälen für alle Testgebiete und die Verfahren FNN und ML. Man sieht, daß das Weglassen eines Kanals keinen großen Einfluß auf die Klassifikationsgenauigkeit hat. Dies gilt für beide Verfahren. Der Unterschied zwischen ML und FNN liegt im gleichen Bereich, wie bei der Klassifikation mit allen Kanälen.

6 Bewertung der klassenspezifischen Gütemaße

In diesem Kapitel wird die Bewertung der Klassifikationen weitergeführt. Es werden die klassenspezifischen Gütemaße Produkt aus *producers* und *users accuracy* (PAUA) und Fuzzy-Produkt aus *producers* und *users accuracy* verwendet. Die Definition dieser Gütemaße wurde in Kapitel 2.4.3 auf Seite 39 angegeben. Die beiden Gütemaße bewerten die jeweiligen Klassen einer Klassifikation. Außerdem ist die Konfusionsmatrix der ML Klassifikation aller Kanäle mitzugeben. Aus der Konfusionsmatrix berechnet sich der Kappa-Wert und der PAUA-Wert. Sie gibt zudem einen Aufschluß darüber, welche Klassen wie verwechselt wurden.

Zur besseren Vergleichbarkeit werden die verschiedenen Verfahren auf jeweils einer Testszene verglichen. Angegeben werden die Werte sowohl für die Klassifikationen mit allen DAEDALUS Kanälen (alle) als auch mit den vier IKONOS Kanälen (ikonos).

6.1 Testgebiet: Andernacherstr.

In der Grafik 6.1 sind die PAUA (links) und FPAUA (rechts) Werte der FNN im Testgebiet Andernacherstr. dargestellt. Zur besseren Orientierung sind in der Tabelle 6.1 nochmal die Klassen mit Nummern und Bezeichnung aufgeführt.

In der Grafik erkennt man, daß nicht jede Klasse gleich gut erkannt wird. Auffällig sind die Klassen 5, 6 und 7, die sehr viel niedrige Werte aufweisen als die übrigen Klassen. Klasse 7 fällt unter 0.6 im FPAUA Wert ab. Bei der Reduktion auf nur vier Kanäle wird die Güte der Klasse 3 deutlich schlechter. Besonders gut werden die Vegetationsklassen (8, 9, 10) und die Klasse "Wasser" erkannt mit FPAUA Werten über 0.9.

In Grafik 6.4 sind nur die PAUA Werte angegeben, da eine Anwendung der Berechnung des FPAUA Wertes nicht sinnvoll ist, weil es sich um kein Fuzzy Verfahren handelt. Die Konfusionsmatrix der ML Klassifikation aller Kanäle, aus der sich auch der PAUA-Wert berechnet, ist in Tabelle 6.2 dargestellt.

Die PAUA Werte liegen deutlich höher als bei der FNN Klassifikation. Die ML Klassifikation hat hauptsächlich Schwierigkeiten bei der Klasse 7 (Betonplatten). Diese Klasse wird, wie man in der Konfusionsmatrix erkennen kann, mit der Klasse Kiesdach (5) verwechselt. Das liegt u.a. an den ähnlichen Materialeigenschaften, die Betonplatten und Kiesdächer haben. Die Klassen 5 und 6 werden besser erkannt als bei der FNN. Auffällig ist in der Konfusionsmatrix u.a. die Verwechslung der Klasse 2 (dunkle Flachdächer) mit den Klassen 3 und 6 (helle Flachdächer und Straßen). Die Reduktion auf vier Kanäle

Klassen-Nr.	Bezeichnung	Klassen-Nr.	Bezeichnung
1	Flachdach, schwarz	7	Betonplatten
2	Flachdach, dunkel	8	Bäume
3	Flachdach, hell	9	Vegetation, trocken
4	Metalldach	10	Vegetation, feucht
5	Kiesdach	11	Wasser
6	Straße	12	Sand

Tabelle 6.1: Klassen Testgebiet:Andernacherstr.

verringert auch die Güte der Klasse 3.

Die FKNN Klassifikation, deren Ergebnisse in 6.2 abgebildet sind, zeigt ein ähnliches Verhalten wie die ML Klassifikation. Gegenüber der FNN ist FKNN nur in der Klasse 5 besser. Bei der Verwendung der IKONOS Kanäle verschlechtern sich die Genauigkeiten der Klassen 3, 5, 6 und 11 deutlich.

Die FLK zeigt ein anderes Verhalten in den Genauigkeiten der einzelnen Klassen (s. Abb. 6.3). Der Durchschnitt der Gütemaße ist sehr viel niedriger als bei den anderen Verfahren. Die Genauigkeiten der einzelnen Klassen schwanken zudem stark. Besonders auffällig sind die Klassen 4 und 12 (sehr hohe Werte) und 5 (sehr niedrig). Erstaunlich ist auch, daß die FPAUA Werte der Klassifikation mit den IKONOS Kanälen teilweise höher liegen als die, welche mit allen DAEDALUS Kanälen gemacht wurden.

	1	2	3	4	5	6	7	8	9	10	11	12
1	1208	1	0	0	0	71	0	0	0	0	5	0
2	1	2709	0	0	9	110	0	0	0	0	0	0
3	1	260	1453	3	234	8	49	0	0	0	0	1
4	0	8	7	1309	68	12	12	30	9	20	9	6
5	2	56	16	1	2563	26	71	1	0	0	0	1
6	26	233	0	0	2	3113	4	4	0	0	0	0
7	1	24	83	0	111	61	837	1	0	0	0	0
8	3	0	0	1	0	11	0	3551	32	59	18	0
9	0	0	0	6	1	0	1	32	1824	188	0	0
10	0	0	0	0	3	0	1	39	8	1674	0	0
11	0	0	0	0	0	12	0	1	0	0	1126	0
12	0	0	0	1	7	0	0	0	0	0	0	236

Tabelle 6.2: Konfusionsmatrix für ML Klassifikation, Testgebiet: Andernacherstr.

In den Zeilen ist die Pixelanzahl für die Klassen der Validierungskarte angegeben, in den Spalten die Pixelanzahl für die Klassen des Klassifikationsergebnisses.

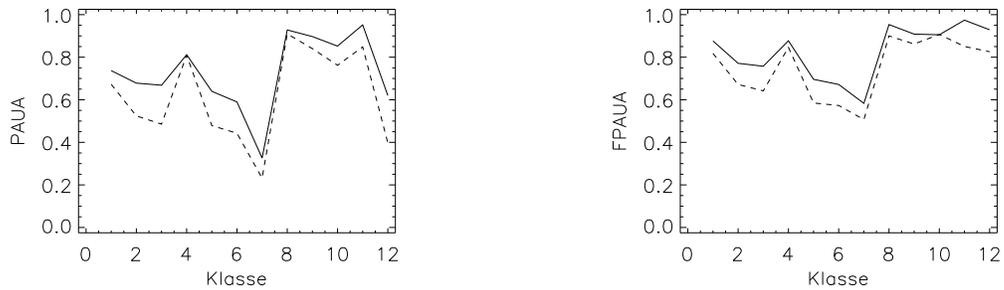


Abbildung 6.1: Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FNN).

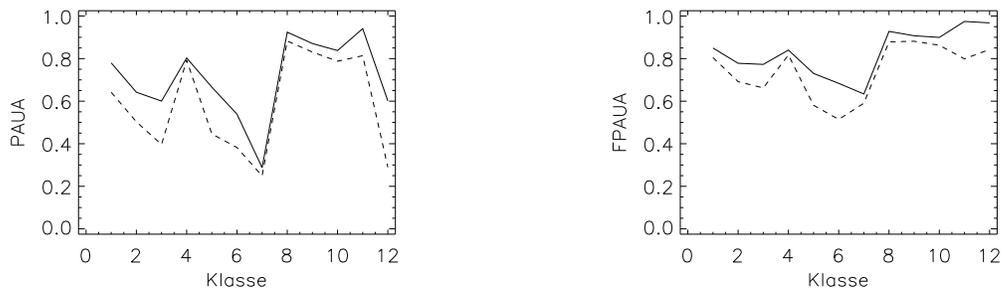


Abbildung 6.2: Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FKNN)

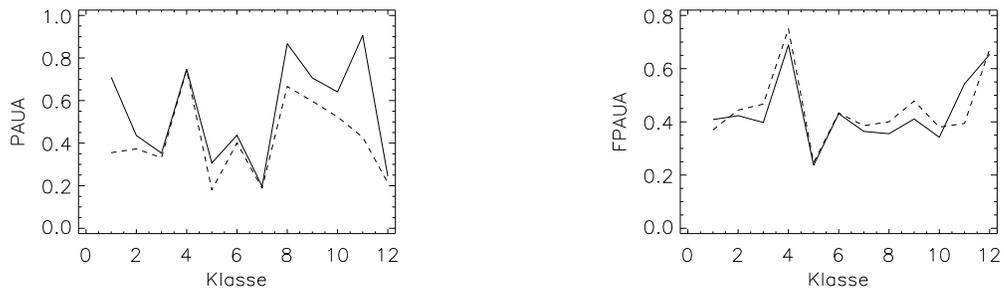


Abbildung 6.3: Testgebiet Andernacherstr.: Gütemaße PAUA und FPAUA (FLK).

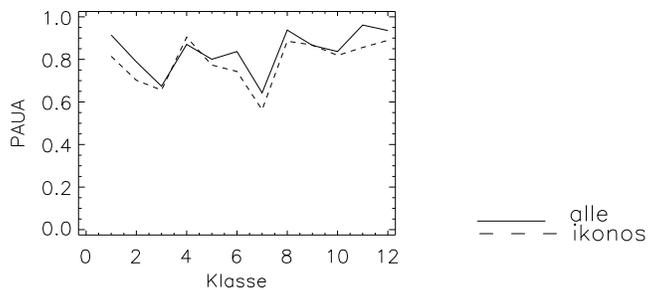


Abbildung 6.4: Testgebiet Andernacherstr.: Gütemaße PAUA (ML).

In alle Abbildungen sind die Gütemaße PAUA (links) und FPAUA (rechts) dargestellt. Die Kanalkombinationen "alle Kanäle" sind durchgezogen und "IKONOS Kanäle" gestrichelt dargestellt.

6.2 Testgebiet: Innenstadt

Die Gütemaße für das Testgebiet Innenstadt sind in den Abbildungen 6.5 (FNN), 6.8 (ML), 6.6 (FKNN) und 6.7 (FLK) dargestellt. Man erkennt leicht die sehr breite Streuung der Werte, insbesondere bei den PAUA Werten (linke Grafiken in den Abbildungen). Die Konfusionsmatrix für die ML Klassifikation aller Kanäle ist in Tabelle 6.4 wiedergegeben.

Klassen-Nr.	Bezeichnung	Klassen-Nr.	Bezeichnung
1	Giebeldach, beleuchtet	6	Straße
2	Flachdach, dunkel	7	Parkplatz, hell
3	Metalldach	8	Bäume
4	Metalldach, blau	9	Vegetation, feucht
5	Flachdach, braun	10	Wasser

Tabelle 6.3: Klassen Testgebiet:Innenstadt

Die Klassen 2, 5, 7 und 9 weisen bei der FNN eine schlechte Genauigkeit bei den PAUA Werten auf. Die FPAUA Werte zeigen zwar ein ähnliches Verhalten, liegen aber im Durchschnitt höher und schwanken nicht so stark. Am besten werden die Klassen 3 und 10 erkannt. Die Reduktion auf vier Kanäle macht sich am deutlichsten in den Klassen 1, 5, 6 und 9 bemerkbar.

Die ML Klassifikation hat den höchsten PAUA Wert in der Klasse 5. Die Klasse 4 wird hingegen schlechter bewertet, als in den übrigen Verfahren. Die Reduktion auf vier Kanäle führt bei der ML Klassifikation zu einem niedrigen PAUA Wert in der Klasse 9 (Vegetation feucht). Die Konfusionsmatrix (s. Tab. 6.4) erklärt einige der schlechten Gütemaße. Besonders auffällig sind die Klassen 6 (Straße) und 7 (Parkplatz, hell). Die Einteilung der Klasse 7 erfolgte aufgrund einer optischen Einschätzung des CIR-Fotos. Wie man sieht, wird ist diese Klasse der Klasse "Straße" sehr ähnlich. Desweiteren fällt auf, daß in den Referenzgebieten der Klassen 1 und 5 viele andere Klassen gefunden wurden.

Bei der FKNN Klassifikation ist bei den FPAUA Werten keine starke Schwankung zu erkennen, im Gegensatz zu den PAUA Werten. Auffällig hier ist die hohe Genauigkeit der Klassen 3 und 10 (Metalldach und Wasser). Das Verwenden von nur vier Kanälen führt zu einer Abnahme der Genauigkeit in den Klassen 4 bis 7.

Bei der FLK liegt der Durchschnitt der Werte niedriger als bei den anderen Verfahren. Auffällig sind die Klassen 3 und 10, die eine deutlich höherer Genauigkeit aufweisen als der Rest. In diesen Werten wird nicht berücksichtigt, wie häufig Wasser an anderen Stellen fehlklassifiziert wurde. Zur Erinnerung sei angemerkt, daß im Innenstadtgebiet viele Straßen im Schatten liegen und deshalb als Wasser erkannt wurden. Straßen, die im Schatten liegen, wurden allerdings nicht als Validierungs- bzw. Trainingsgebiet ausgewählt.

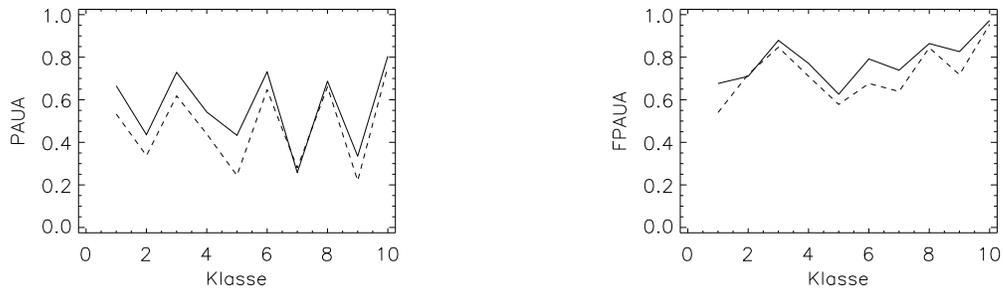


Abbildung 6.5: Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FNN)

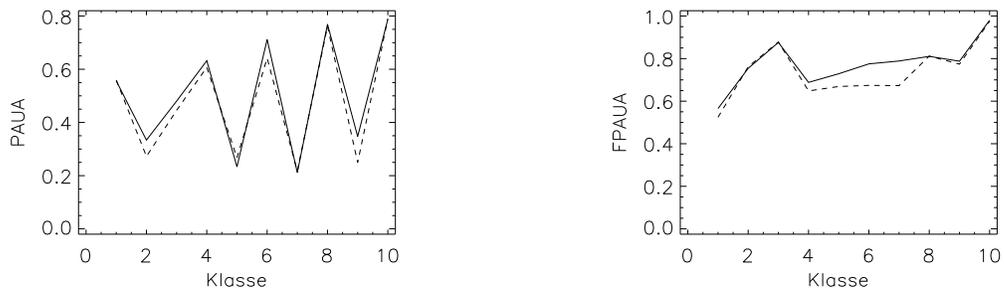


Abbildung 6.6: Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FKNN)

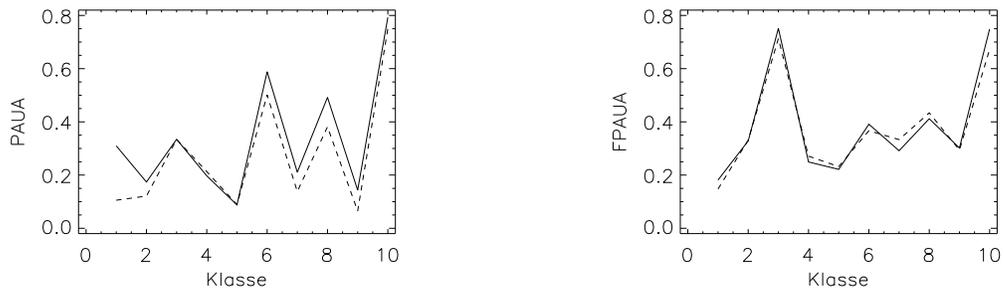


Abbildung 6.7: Testgebiet Innenstadt: Gütemaße PAUA und FPAUA (FLK).

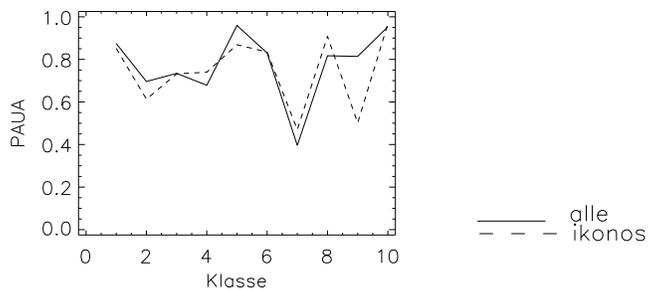


Abbildung 6.8: Testgebiet Innenstadt: Gütemaße PAUA (ML).

In alle Abbildungen sind die Gütemaße PAUA (links) und FPAUA (rechts) dargestellt. Die Kanalkombinationen "alle Kanäle" sind durchgezogen und "IKONOS Kanäle" gestrichelt dargestellt.

	1	2	3	4	5	6	7	8	9	10
1	5140	8	7	9	12	112	28	92	12	5
2	11	399	0	7	0	124	1	0	0	0
3	99	2	503	1	0	47	2	6	0	0
4	62	0	0	378	0	63	0	0	0	2
5	0	0	0	0	283	0	0	0	0	0
6	32	7	7	5	0	4213	11	0	1	1
7	87	6	1	15	0	335	362	1	0	0
8	115	0	4	2	0	88	6	1910	5	8
9	22	0	0	0	0	5	0	8	248	1
10	3	0	0	0	0	14	0	3	0	245

Tabelle 6.4: Konfusionsmatrix für ML Klassifikation, Testgebiet: Innenstadt
In den Zeilen ist die Pixelanzahl für die Klassen der Validierungskarte angegeben, in den Spalten die Pixelanzahl für die Klassen des Klassifikationsergebnisses.

6.3 Testgebiet: Rennweg

Die Ergebnisse der Analyse der Gütemaße PAUA (links) und FPAUA (rechts) für das Test Gebiet Rennweg sind in den Grafiken 6.9, 6.10, 6.11 und 6.12 dargestellt.

Klassen-Nr.	Bezeichnung	Klassen-Nr.	Bezeichnung
1	Flachdach, dunkel	9	Vegetation, trocken
2	Flachdach, schwarz	10	Vegetation, feucht
3	Flachdach, braun	11	Sand
4	Kiesdach	12	Wasser
5	Giebeldach, beleuchtet	13	Straße
6	Giebeldach, schattig	14	Betonplatten
7	Giebeldach, schwarz	15	Parkplatz, hell
8	Bäume		

Tabelle 6.5: Klassen Testgebiet: Rennweg

Die Klassifikation durch FNN hat sehr stark schwankende Gütemaße. Sie reichen bei den PAUA Werten von etwa 0.25 in Klasse 15 bis etwa 0.9 für Klasse 12. Dieses Verhalten spiegelt sich in den FPAUA Werten wieder, wenn auch nicht so deutlich. Die Verwendung der vier IKONOS Kanäle verringert besonders die Genauigkeit der Kanäle 3, 5, 7, 10, 11 und 13.

Die FKNN Klassifikation zeigt ein entsprechendes Verhalten in den Gütemaßen. Der

starke Unterschied in der Genauigkeit der Klasse 4 zwischen der Verwendung von zehn bzw. vier Kanälen tritt hier nicht auf.

Das Verfahren FLK erzeugt sehr viel schlechtere Genauigkeiten für die einzelnen Klassen. Die PAUA Werte liegen für eine Reihe von Klassen unter 0.3. Der Unterschied in der Kanalanzahl macht sich dafür nur bei den PAUA Werten bemerkbar. Dies bedingt, daß die Kappa-Werte der FLK Klassifikation im Testgebiet Rennweg so niedrig sind.

Die ML Klassifikation ergibt wieder ein zur FNN und FKNN Klassifikation ähnliches Bild. Sie liegt im Ganzen in ihren Werten etwas besser. Die Reduktion auf vier Kanäle macht sich aber stark bemerkbar, insbesondere in den Kanälen 3, 7, 13 und 15. Der PAUA Wert fällt bei der Klasse 7 von 0.6 auf 0.1 Die Konfusionsmatrix in Tabelle 6.6 läßt einige Schlüsse auf die Ursachen der teilweise schlechten Ergebnisse zu. Die Klasse "Parkplatz, hell" (15) wird wieder mit der Klasse "Straße" (13) verwechselt. Starke Ähnlichkeiten, die zu Fehlklassifikationen führten, lassen sich auch zwischen den Klassen 2 und 7 und den Klassen 1 und 13 finden.

Zusammenfassend läßt sich sagen, daß die Gütemaße für die einzelnen Klassen sehr unterschiedlich sind. Dies gilt für jede Klassifikationsmethode. Niedrige Werte haben die Klassen 3, 6, 13 und 15, hohe Werte die Klassen 2, 4, 9, 10, 11, 12 und 14. Auffällig ist der starke Abfall der Gütemaße in der Klasse 7 (Giebedach, schwarz) bei der Reduktion auf vier Kanäle.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	905	2	5	0	0	3	2	0	0	0	0	0	116	0	0
2	9	213	0	0	0	7	69	0	0	0	0	0	43	0	1
3	2	2	113	0	4	11	1	0	0	0	0	0	19	6	1
4	0	0	0	259	0	2	0	0	0	0	0	0	0	0	0
5	8	1	1	2	860	25	1	15	0	0	1	0	21	1	2
6	2	7	10	0	28	490	27	0	0	0	0	0	19	0	1
7	1	23	0	0	1	34	300	0	0	0	0	1	9	0	0
8	0	0	0	0	2	6	2	1039	26	1	1	0	0	0	1
9	0	0	0	0	1	0	0	115	283	0	0	0	0	0	0
10	0	0	0	0	0	0	0	19	120	1	0	0	0	0	0
11	0	0	0	0	2	0	0	5	0	4	429	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	51	0	0	0
13	53	19	3	0	3	3	10	0	0	0	0	0	885	0	1
14	2	0	0	0	1	0	0	15	0	0	0	0	2	266	0
15	1	1	14	0	0	0	1	0	0	0	0	0	35	4	66

Tabelle 6.6: Konfusionsmatrix für ML Klassifikation, Testgebiet: Rennweg
 In den Zeilen ist die Pixelanzahl für die Klassen der Validierungskarte angegeben, in den Spalten die Pixelanzahl für die Klassen des Klassifikationsergebnisses.

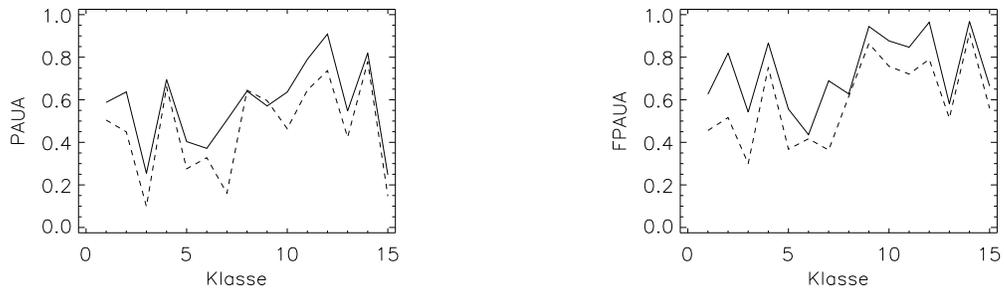


Abbildung 6.9: Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FNN).

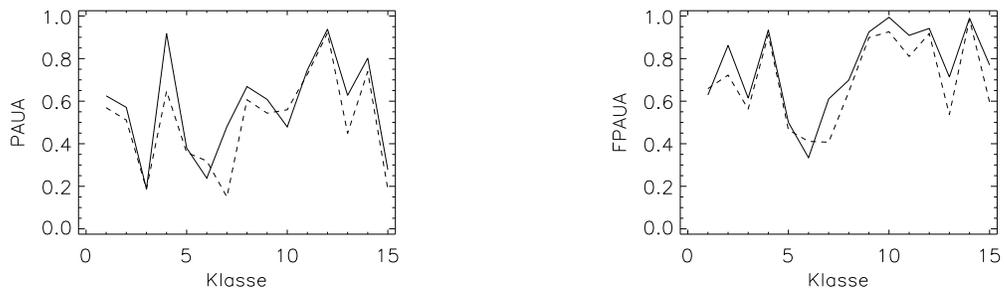


Abbildung 6.10: Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FKNN) .

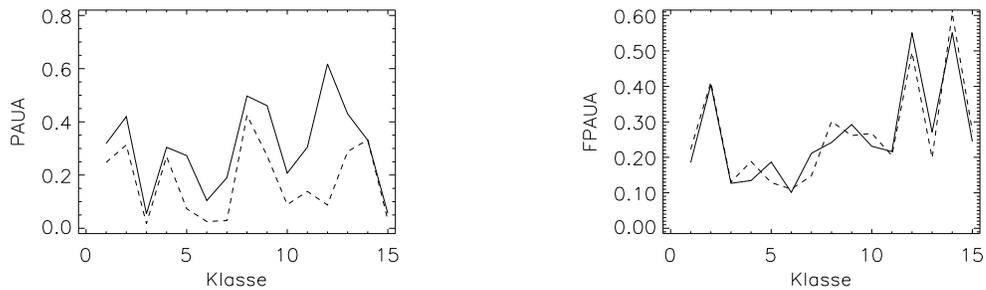


Abbildung 6.11: Testgebiet Rennweg: Gütemaße PAUA und FPAUA (FLK) .

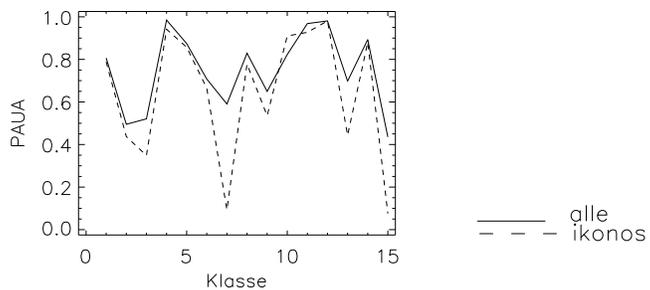


Abbildung 6.12: Testgebiet Rennweg: Gütemaße PAUA (ML) . In alle Abbildungen sind die Gütemaße PAUA (links) und FPAUA (rechts) dargestellt. Die Kanalkombinationen "alle Kanäle" sind durchgezogen und "IKONOS Kanäle" gestrichelt dargestellt.

6.4 Testgebiet: Thon

Die PAUA und FPAUA Werte des Testgebiets Thon sind in den Grafiken 6.16, 6.17, 6.18 und 6.19 abgebildet. Eine Auffälligkeit in diesen Bewertungen zeigt sich bei der Klasse 11 (Sand). Die Klasse 11 wird in den Gütemaßen PAUA und FPAUA außer bei der ML Klassifikation (6.19) und der FLK (6.18) unterschiedlich bewertet. Während der PAUA Wert auf den halben Wert des Werts der Klasse 10 abfällt, steigt der FPAUA Wert gegenüber der Klasse 10 nochmals an. Dies zeigt den Unterschied in der Art der Bewertung. Während bei PAUA nur das Maximum der Fuzzy-Klassifikation zählt, werden bei FPAUA auch die anderen Zugehörigkeiten berücksichtigt.

Klassen-Nr.	Bezeichnung	Klassen-Nr.	Bezeichnung
1	Flachdach, schwarz	9	Betonplatten
2	Flachdach, dunkel	10	Sand
3	Metalldach	11	Wasser
4	Flachdach, braun	12	Bäume
5	Kiesdach	13	Vegetation, trocken
6	Giebeldach, schwarz	14	Feld, Typ 1
7	Giebeldach, beleuchtet	15	Feld, Typ 2
8	Straße	16	Feld, Typ 3

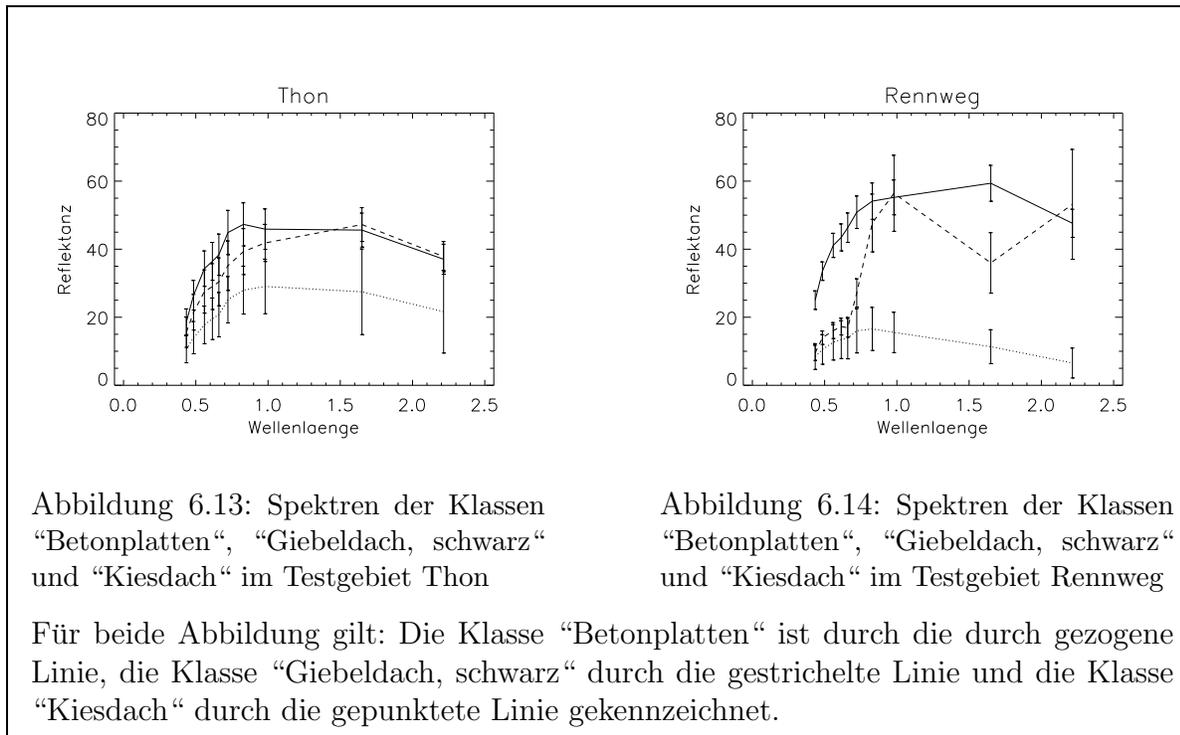
Tabelle 6.7: Klassen Testgebiet: Thon

Die Ergebnisse der FNN sind wieder sehr unterschiedlich. Die PAUA Werte schwanken zwischen 0.1 bei der Klasse 9 und 0.9 bei der Klasse 10. Die FPAUA Werte variieren nicht so extrem. Aber die Klassen 2 und 5 bis 9 werden deutlich schlechter bewertet als die übrigen Klassen. Die Reduktion der Kanalanzahl macht sich ebenfalls bei diesen Klassen am stärksten bemerkbar.

Bei der Klassifikation mit FKNN verhalten sich die Gütemaße entsprechend. Die Reduktion der Kanalanzahl fällt allerdings nicht so stark aus.

Bei der ML Klassifikation fällt auf, daß die PAUA Werte für die Klasse 12 bei allen Kanälen niedriger sind als bei den vier IKONOS Kanälen. Ansonsten sind die Werte etwas höher als bei der Klassifikation durch FNN. Der Abfall des PAUA Werts bei der Klasse 5 zwischen der Klassifikation mit zehn und mit vier Kanälen ist nicht so stark, wie bei der FNN. Die Konfusionsmatrix für die ML Klassifikation, die in Tabelle 6.8 dargestellt ist, gibt Ausschluß darüber, weshalb die Klassen 2, 8, 9 und 16 so schlecht bewertet werden. Bei der Klasse "Flachdach, dunkel" (2) kommt es zu einer häufigen Verwechslung mit der Klasse "Straße" (8). Die Klasse "Betonplatten" (9) wird mit den Klasse "Kiesdach" (5) und "Giebeldach, schwarz" (6) verwechselt im Gegensatz zum Testgebiet Rennweg. Die Plots in den Abbildungen 6.13 und 6.14 zeigen deutlich, daß es die Spektren im Gebiet Rennweg deutlich getrennt voneinander vorliegen. Im Gebiet Thon ist die Streuung der

einzelnen Spektren wesentlich größer, so daß die Spektren nicht mehr voneinander getrennt werden können. Ursachen für diese starke Streuung sind in der schlechten Auswahl der Trainingsgebiete und unterschiedlichen Materialien zu suchen.



Die Klasse "Feld, Typ 3" (16) ist sehr ähnlich zu der Klasse "Feld, Typ 1" (14). Diese Verwechslungen lassen sich auf sehr ähnliche Materialeigenschaften zurückführen, die sehr ähnlichen Spektren bedingen. Die Abhängigkeit der PAUA Werte von der Anzahl der Trainingspixel ist in Abbildung 6.15 wiedergegeben. Die besseren Werte sind auf Fehlen der Klasse "Wasser" (11) zurückzuführen. Die Genauigkeit nimmt hauptsächlich bei der Klasse "Giebeldach, beleuchtet" zu.

Die Gütemaße der Klassifikation durch FLK sind sehr schlecht (unter 0.2) bis auf einige Ausnahmen (Klasse 1, 3 und 11). Dies läßt sich durch die hohe Klassenanzahl und die damit verbundene schlechte Klassifikation der Einzel-Kanal-Bilder erklären.

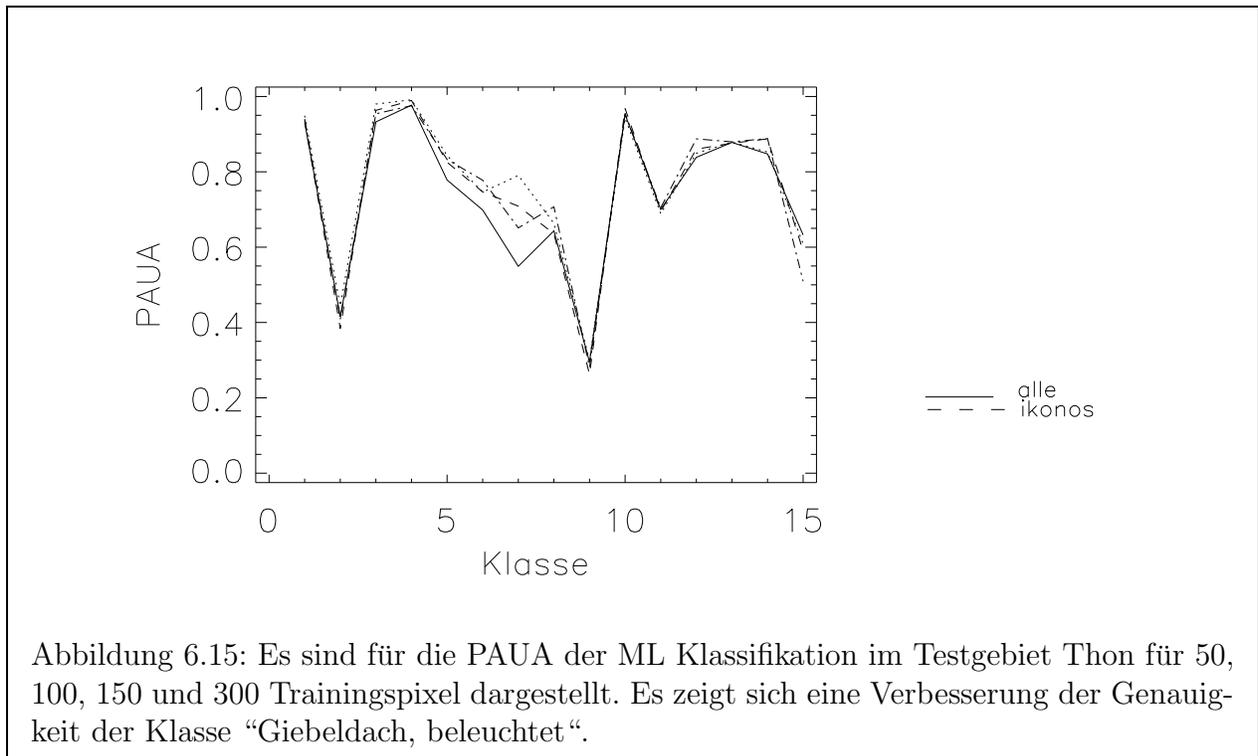


Abbildung 6.15: Es sind für die PAUA der ML Klassifikation im Testgebiet Thon für 50, 100, 150 und 300 Trainingspixel dargestellt. Es zeigt sich eine Verbesserung der Genauigkeit der Klasse “Giebeldach, beleuchtet“.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1096	1	0	0	0	12	0	9	0	0	0	0	0	0	0	0
2	0	219	0	0	9	50	0	190	0	0	0	0	0	0	0	0
3	0	1	281	0	2	10	0	5	0	2	0	0	0	0	0	0
4	0	0	0	261	0	0	0	0	0	0	0	0	0	0	0	0
5	0	1	0	0	761	37	1	13	30	0	0	0	0	0	0	0
6	19	3	0	0	30	2140	4	120	1	0	0	2	6	5	16	4
7	0	0	0	4	4	14	266	13	0	7	0	8	26	0	1	0
8	39	7	0	0	2	347	0	1368	2	0	0	0	0	1	0	2
9	0	0	0	0	46	61	0	32	91	2	0	3	0	4	16	0
10	0	0	0	0	1	0	0	0	0	344	0	0	18	0	1	0
11	0	0	0	0	0	0	0	1	0	0	28	0	0	0	0	0
12	0	0	0	0	1	4	2	1	0	0	0	392	165	29	0	0
13	0	0	0	0	1	5	0	0	0	1	0	2	1244	0	69	0
14	0	1	0	0	1	4	0	5	1	0	0	16	5	777	0	3
15	0	0	0	0	1	0	0	0	0	0	0	0	19	0	629	0
16	0	0	0	0	3	20	0	5	0	0	0	0	0	35	0	147

Tabelle 6.8: Konfusionsmatrix für ML Klassifikation, Testgebiet: Thon

In den Zeilen ist die Pixelanzahl für die Klassen der Validierungskarte angegeben, in den Spalten die Pixelanzahl für die Klassen des Klassifikationsergebnisses.

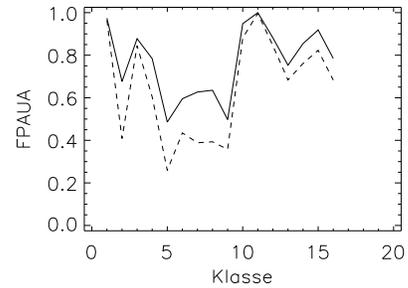
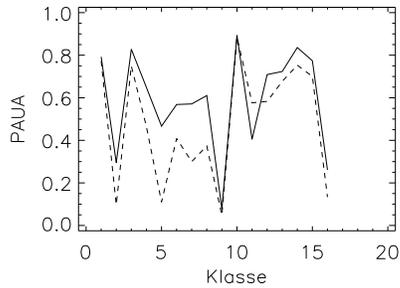


Abbildung 6.16: Testgebiet Thon: Gütemaße PAUA und FPAUA (FNN) .

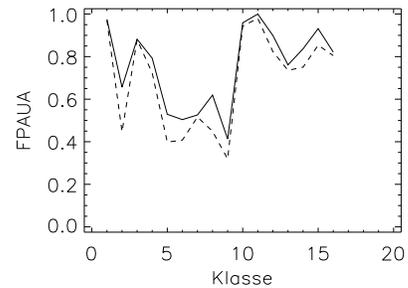
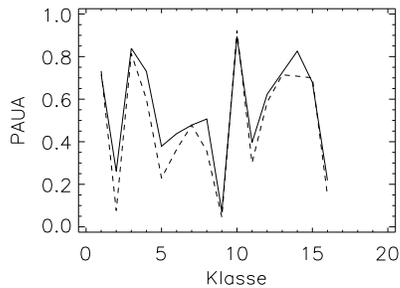


Abbildung 6.17: Testgebiet Thon: Gütemaße PAUA und FPAUA (FKNN) .

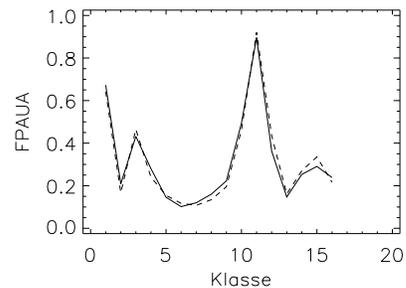
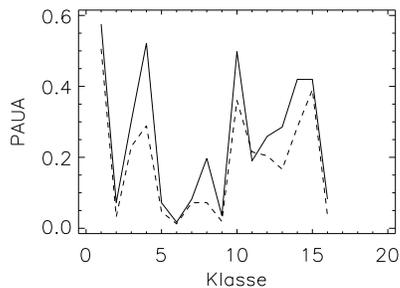
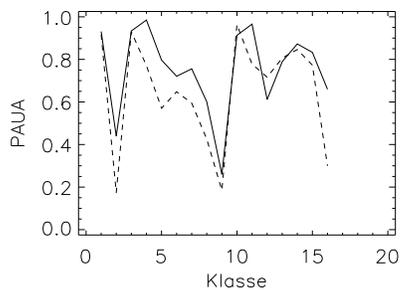


Abbildung 6.18: Testgebiet Thon : Gütemaße PAUA und FPAUA (FLK).



— alle
- - - ikonos

Abbildung 6.19: Testgebiet Thon: Gütemaße PAUA (ML).

In alle Abbildungen sind die Gütemaße PAUA (links) und FPAUA (rechts) dargestellt. Die Kanalkombinationen "alle Kanäle" sind durchgezogen und "IKONOS Kanäle" gestrichelt dargestellt.

6.5 Testgebiet: Gesamtszene

Die Gütemaße der Klassen in der Gesamtszene sind gleichmäßiger verteilt, als bei den Testgebieten Rennweg und Thon. Etwas schlechtere Werte als der Durchschnitt haben die Klassen 5 bis 12. Bei diesen Kanälen macht sich die Reduzierung auf 4 Kanäle am deutlichsten bemerkbar.

Klassen-Nr.	Bezeichnung	Klassen-Nr.	Bezeichnung
1	Flachdach,schwarz	12	Betonplatten
2	Flachdach,dunkel	13	Parkplatz
3	Flachdach,hell	14	Sand/Schotter
4	Flachdach,braun	15	Vegetation, feucht
5	Metалldach	16	Vegetation, trocken
6	Kiesdach	17	Bäume
7	Giebeldach, beleuchtet	18	Wasser
8	Giebeldach, schattig	19	Feld, Typ 1
9	Giebeldach, schwarz	20	Feld, Typ 2
10	Giebeldach, hell	21	Feld, Typ 3
11	Straße	22	Metалldach, blau

Tabelle 6.9: Klassen Gesamtszene

Die PAUA Werte der ML Klassifikation (Abb. 6.23) liegen in einem Bereich von 0.35 (Klasse 12) und 0.9 (Klasse 18). Die schlechtesten Werte haben die Klassen 2, 3 und 19 mit einem PAUA Wert unter 0.4. Die Klassen 8 bis 14 sind auch relativ schlecht bewertet mit PAUA Werten unter 0.6. Bei der ML Klassifikation ist der Abfall der Genauigkeit mit der Reduktion der Kanalanzahl am stärksten. Besonders auffällig sind dabei die Klassen 4 und 21. Weitere Informationen über die Klassen lassen sich aus der Konfusionsmatrix der ML Klassifikation mit allen Kanälen ableiten (s. Tab. 6.10). Interessant sind dabei die Werte der Klasse 11 (Straße) im Validierungsgebiet. Hier zeigen sich starke Ähnlichkeiten mit den Klassen 2 und 9 (Flachdach, dunkel und Giebeldach, schwarz). Diese Klassen zeichnen sich alle durch sehr niedrige Reflektanz aus. Außerdem ist wieder eine Verwechslungen der Klassen "Betonplatten" und "Kiesdach" zu beobachten. Auch die Vegetationsklassen sind stark miteinander korreliert.

Die Werte der FKNN Klassifikation (Abb. 6.21) sind um 0.1 bis 0.2 niedriger als die der ML Klassifikation, zeigen aber einen ähnlichen Verlauf. Die Reduktion der Kanalanzahl ist so groß wie bei der ML Klassifikation und der FNN.

Die PAUA Werte der FNN (Abb. 6.20) sind im Durchschnitt niedriger als die der ML Klassifikation. Die FPAUA Werte liegen höher als die der FKNN Klassifikation. Der Abfall der Genauigkeit bei der Reduktion der Kanalanzahl ist deutlich erkennbar, aber nicht so

stark, wie bei der ML Klassifikation. Bei höherer Klassenanzahl scheint das neuronale Netz gewisse Vorteile gegenüber der ML Klassifikation zu haben.

Die FLK Methode (Abb. 6.22) hat viele Klassen mit einem FPAUA bzw. PAUA Wert von unter 0.2, was die schlechten Kappa-Werte bedingt. Die Erklärung liegt u.a. in der hohen Klassenanzahl und den dadurch bedingten sehr schlechten Einzel-Klassifikationen. Die PAUA Werte der FLK schwanken sehr viel stärker als die FPAUA Werte. Auffällig sind die relative hohen Genauigkeiten der Klassen 1, 5 und 18.

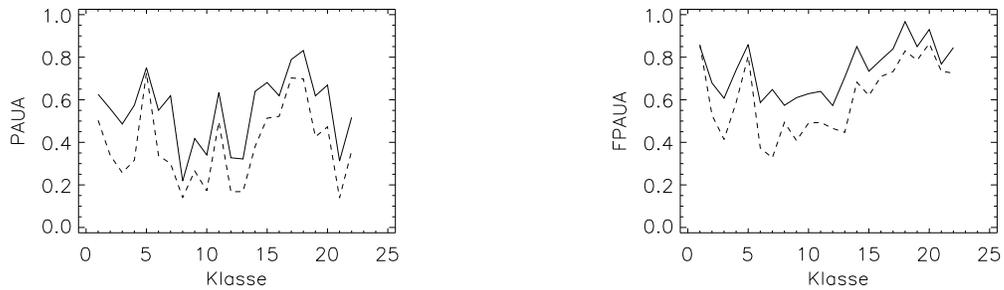


Abbildung 6.20: Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FNN).

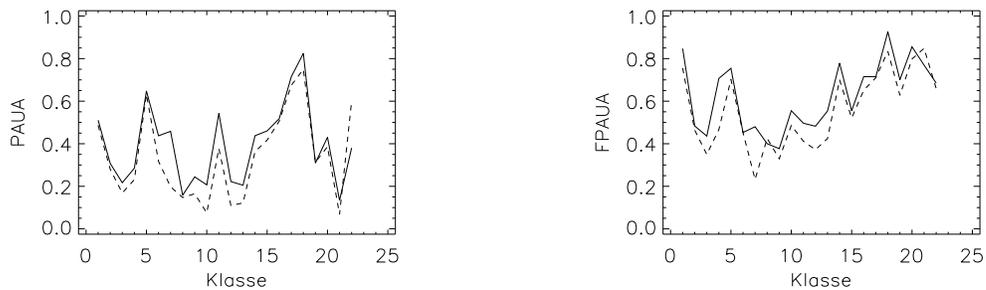


Abbildung 6.21: Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FKNN).

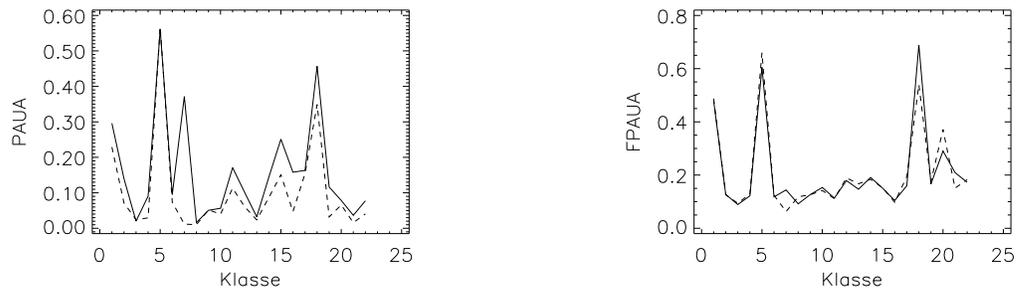


Abbildung 6.22: Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (FLK).

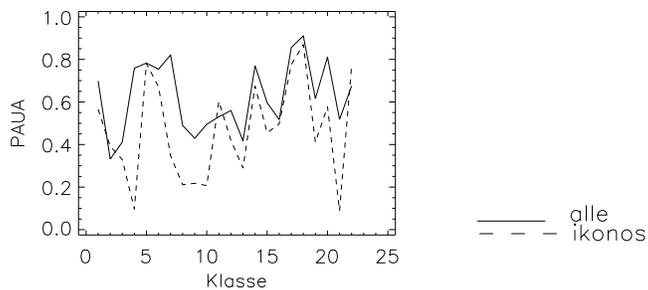


Abbildung 6.23: Testgebiet Gesamtszene: Gütemaße PAUA und FPAUA (ML).
 In alle Abbildungen sind die Gütemaße PAUA (links) und FPAUA (rechts) dargestellt. Die Kanalkombinationen "alle Kanäle" sind durchgezogen und "IKONOS Kanäle" gestrichelt dargestellt.

	1	2	3	4	5	6	7	8	9	10	11
	12	13	14	15	16	17	18	19	20	21	22
1	2232	254	33	0	0	0	0	3	111	0	194
	0	0	0	0	0	0	148	0	0	0	0
2	24	2870	537	0	5	12	21	1	97	0	2185
	1	0	0	0	0	0	5	1	0	0	0
3	1	625	1670	0	23	83	0	1	12	0	236
	17	1	0	0	0	0	0	0	0	0	0
4	1	1	0	786	4	3	98	1	3	3	23
	2	0	0	0	1	19	0	0	0	0	0
5	1	7	80	22	2024	68	102	0	4	4	56
	6	4	11	1	4	18	0	0	0	0	0
6	0	19	59	0	71	3406	3	0	14	0	27
	92	102	5	0	0	1	0	0	2	0	0
7	2	30	7	51	17	18	5747	5	51	3	141
	2	29	0	0	21	81	1	1	0	0	10
8	70	11	0	1	0	15	72	457	103	7	39
	0	0	0	0	0	4	11	0	0	0	0
9	33	144	19	0	0	155	19	58	2384	0	1339
	29	0	0	1	3	16	32	4	6	2	0
10	0	0	0	0	1	2	140	1	20	213	8
	3	0	1	1	0	2	0	0	1	0	0
11	34	304	39	0	7	13	98	9	170	0	6751
	8	38	0	0	2	9	29	1	0	1	0
12	0	7	75	0	0	237	0	0	48	0	107
	1023	36	2	0	0	0	0	0	0	0	0
13	0	5	21	0	2	16	29	0	5	0	191
	17	466	0	0	0	5	0	0	0	0	0
14	0	0	0	0	1	8	1	0	0	0	0
	2	6	1015	150	6	21	0	0	32	0	0
15	0	0	0	0	0	1	1	0	2	0	1
	2	0	27	2760	534	235	0	61	1	1	0
16	0	0	0	2	11	3	22	0	4	2	4
	0	1	13	404	1868	288	0	14	0	0	0
17	0	1	0	0	2	3	42	2	22	1	23
	3	0	0	40	93	6582	12	5	0	1	0
18	0	1	0	0	0	0	11	2	27	0	43
	0	0	0	0	0	6	3404	0	0	0	0
19	0	0	0	0	0	3	0	0	1	0	15
	6	0	0	81	27	119	0	682	0	0	0
20	0	0	0	0	0	2	1	0	0	0	2
	5	0	3	85	1	2	0	1	646	0	0
21	0	0	0	0	0	0	0	0	41	0	15
	0	0	0	0	0	0	0	39	0	112	0
22	0	27	0	0	1	0	66	0	0	0	35
	0	1	0	0	0	0	1	0	0	0	347

Tabelle 6.10: Konfusionsmatrix für ML Klassifikation, Gesamtszene

In den Zeilen ist die Pixelanzahl für die Klassen der Validierungskarte angegeben, in den Spalten die Pixelanzahl für die Klassen des Klassifikationsergebnisses.

6.6 Zusammenfassung

Die Ergebnisse der klassenspezifischen Gütemaße bestätigen die Ergebnisse der Kappa-Werte. Am besten werden die Klassen des Testgebietes Andernacherstr. bewertet.

Es wird deutlich, daß bei den hochaufgelösten Multispektraldaten die Klassifikation mit der Maximum Likelihood Methode die besten Ergebnisse bringt mit PAUA Werten zwischen 0.6 und 0.95 im Testgebiet Andernacherstr.. Von den verwendeten Fuzzy-Verfahren hat sich die Fusion mittels des neuronalen Netzes als erfolgsversprechend erwiesen. Die FPAUA Werte lagen zwischen 0.3 und 0.9, die PAUA Werte zwischen 0.6 und 0.95. Eine interessante Anwendung zeigt sich, wenn man bedenkt, daß sich hiermit Klassifikationsergebnisse aus unterschiedliche Quellen (z.B. Multispektral- und Thermaldaten) mit unterschiedlichen Klassenanzahlen fusionieren lassen.

Die Unterschiede in den Gütemaßen PAUA und FPAUA sind dadurch bedingt, daß die FPAUA Werte alle Zugehörigkeiten berücksichtigen. Die Gütemaße, sowie die Konfusionsmatrix können dazu dienen, Klassen zu identifizieren, die sich schlecht erkennen lassen. Diese können gegebenenfalls mit anderen Klassen vereint oder ganz weggelassen werden. Hierbei erweisen sich auch die *possibility maps* als nützlich, da sie eine Aussage über die Ähnlichkeit der Klassen zueinander machen.

Die Reduktion der Kanalanzahl auf die vier IKONOS Kanäle wirkt sich je nach Verfahren und Klasse unterschiedlich auf die Gütemaße aus. Allgemein wurden die Klassifikationen etwas schlechter bewertet. Es jedoch anzunehmen, daß die Klassifikation mit den IKONOS-Daten ebenfalls zu guten Ergebnissen führen wird.

Es zeigt sich eine starke Abhängigkeit der Gütemaße von den gewählten Testgebieten. Insbesondere die Innenstadtgebiete erzeugen viele Fehlklassifikationen, die zum Teil auf die vielen Schattenbereiche zurückzuführen sind. Des weiteren sind die unterschiedlichen Dachtypen schwierig zu erfassen. Hier könnte eine objektorientierte Klassifikation weiterhelfen.

Die sehr unterschiedlichen Bewertungen der einzelnen Klassen in den verschiedenen Testszenen zeigt, daß es sehr schwierig ist eine unabhängige Klassendatenbank für die Klassifikation zu finden. Die verwendeten Merkmale reichen hierzu nicht aus. Es ist zu beachten, daß die Güte einer Klasse von u.a. zwei Faktoren abhängt. 1. Der Separation der Klassen im Merkmalsraum von einander und 2. der Auswahl der Trainings- und Testgebiete. Um eine bessere Klassifikation zu erreichen, könnte man die Anzahl der Klassen noch weiter erhöhen, um z.B. die unterschiedlichen Arten von Betonplatten besser trennen zu können.

7 Zusammenfassung

In dieser Arbeit wurde ein Vergleich zwischen verschiedenen Fuzzy-Methoden zur Klassifizierung multispektraler Luftbildaufnahmen durchgeführt. Die Multispektraldaten, die zur Verfügung standen, stammten aus dem August 1997 von einer Überfliegung des Stadtgebietes Nürnberg. Aufgenommen wurden diese Daten mit dem 11-Kanal Detektor DAEDALUS AADS 1268 durch das DLR Oberpfaffenhofen. Für die Klassifikation wurden die Reflektanzwerte der ersten 10 Kanäle benutzt, da der 11. Kanal im thermischen Infrarot liegt und somit keine Reflektanz berechnet werden kann.

Die Klassenauswahl wurde in Hinblick auf potentielle Nutzer getroffen. Für eine nutzerrelevante Klassenauswahl zeigte sich, daß man eine überwachte Klassifikation der multispektralen Luftbildaufnahmen vornehmen muß, um die gewünschten Klassen zu erhalten. Eine unüberwachte Klassifikation versucht, den Merkmalsraum nach statistischen Gesichtspunkten optimal aufzuteilen. Dies entspricht nicht immer der gewünschten Klassenauswahl. Die Klassenauswahl, die bei der überwachten Klassifikation getroffen wird, kann aber dazu führen, daß Klassen im Merkmalsraum zu dicht beieinander liegen oder sich überlappen. In beiden Fällen kann es zu Fehlklassifikationen kommen. Um eine bessere Trennung zu erreichen, könnten höher aufgelöste Reflektanzwerte (16 bit statt 8 bit) helfen oder man nimmt weitere Merkmale zur Klassifikation hinzu.

Die Ergebnisse der Berechnung der Gütemaße Kappa-Wert, sowie dem Produkt von *Producers Accuracy* und *Users Accuracy* (PAUA) und dem Fuzzy-Produkt aus *Producers Accuracy* und *Users Accuracy* (FPAUA) zeigten, daß bei den vorliegenden Daten die Verwendung von Fuzzy-Algorithmen erst bei großen Klassenanzahlen Vorteile bringt, wie man z.B. den Grafiken auf Seite 123 entnehmen kann. Dadurch, daß bei einer Fuzzy-Klassifikation jedes Pixel eine Zugehörigkeit zu jeder Klasse erhält, können auch sich überlagernde Klassen besser getrennt werden.

Die Verwendung von 10-kanaligen Multispektraldaten zeigt nur bei bestimmten Klassen Vorteile (z.B. Testgebiet Thon: Klasse 5 - Kiesdach). Die Reduktion der Kanalanzahl auf die vier, den IKONOS Kanälen entsprechenden Kanälen, erwies sich als erstaunlich gut (s. Tabelle 5.9).

7.1 Klassenauswahl & Validierungskarten

Bei der Erstellung der Validierungskarten mußte zuerst eine Entscheidung über die zu erkennenden Klassen getroffen werden. Hierbei habe ich mich von zwei Entscheidungskriterien leiten lassen. Zum einen wollte ich Klassen, die potentielle Nutzer gebrauchen können,

zum anderen Klassen, die sich visuell (CIR-Fotos) und spektral (Multispektralaufnahmen) unterscheiden. Die visuelle bzw. spektrale Unterscheidung ist ein gutes Kriterium dafür, daß diese Klassen auch im Merkmalsraum getrennt vorliegen.

Die Validierungskarten wurden mit Hilfe der CIR-Fotos, die als "Bodenwahrheit" (*groundtruth*) dienten, erstellt. Die CIR-Fotos haben einen Maßstab von 1:6000, das entspricht einer Bodenauflösung von unter 30 cm. Die Validierungskarten wurden sowohl zum Training der überwachten Verfahren als auch zur Bestimmung der Klassifikationsgüte genutzt. Dabei wurde die Anzahl der Pixel, die für das Training genutzt wurden, bei der Berechnung der Gütemaße nicht berücksichtigt. Die doppelte Nutzung wurde vorgenommen, um eine einfachere Handhabung zu haben. Es ergab sich dadurch allerdings ein Problem bei der Bestimmung der Gesamtgenauigkeit einer Klassifikation. Die Referenzgebiete liegen in Bereichen, die sich für das Training einer Klasse gut eignen. Eine aussagekräftigere Berechnung der Genauigkeit wäre gegeben, wenn auch Gebiete referenziert würden, die nicht von typischen Vertretern einer Klasse gebildet werden. Am deutlichsten ist dies bei den Schattenflächen zu bemerken. Bei den durchgeführten Klassifikationen wurden, wie man durch die rein qualitative Begutachtung sieht, viele Bereiche als Wasserflächen erkannt, die durch den Schattenwurf von Häusern oder Bäumen sehr dunkel sind. Eine bessere Trennung der Klassen in beschattete und beleuchtete Klassen, wie es z.B. bei den Häuserdächern gemacht wurde, wäre eine Möglichkeit, dieser Fehlklassifikation zu begegnen. Die korrekte Zuordnung von Klassen bei der Erstellung der Validierungskarten erwies sich in den dunklen Schattenbereichen als schwierig, da auch auf den CIR-Fotos nicht eindeutig zu erkennen ist, um was für eine Bodenbedeckung es sich dort handelt. Eine andere Option ist das generelle Ausblenden von Schattengebieten.

Weitere Schwierigkeiten bei der Erstellung der Validierungskarten waren

- die Bodenauflösung der Multispektralbilder von etwa 3 m. Die niedrige Auflösung bedingte, daß schräge Dachflächen sich schwer markieren ließen, da sie nur ein bis zwei Pixel breit sind.
- die vielen kleinen Besonderheiten (ein bis vier Pixel groß), die in städtischen Gebieten auftreten, wie Dachfenster auf Flachdächern und Autos auf Straßen. Es stellt sich dabei die Frage, ob man diese Elemente bei einer Validierungskarte mit berücksichtigen soll. Es gibt Nutzer, die wissen wollen, ob es sich um eine Straße oder ein Dach handelt, egal ob da diese Straße von Autos befahren wird oder nicht. Bei der Verifikation ist dagegen gefragt, wo sich z.B. ein Panzer auf einer Aufnahme befindet. Diese Aussage läßt sich mit dem vorliegenden Daten nicht so leicht machen, da Autos und LKW (ebenso Panzer) nur wenige Pixel einnehmen und sich in ihren Signaturen aufgrund der unterschiedlichen Lackfarbe stark unterscheiden. Hierzu bedarf es zusätzlicher Verfahren wie sie im Kapitel *Ausblick* erwähnt werden.

Bei der Validierung großer Bilder muß man zudem versuchen, eine möglichst repräsentative Auswahl an Flächen zu finden, um eine aussagekräftige Statistik zu erhalten.

7.2 Klassifikationsergebnisse

Die Bewertung der Klassifikation wurde zum einem qualitativ vorgenommen (s. Kap. 5), zum anderen quantitativ durch die Berechnung der Gütemaße Kappa-Wert, PAUA und FPAUA. Die wichtigsten Ergebnisse der Klassifikation sind:

1. Die ML Klassifikation erreicht bei der Klassifikation von Multispektralbildern die besten Genauigkeiten (Kappa-Werte zwischen 0.77 bei der Gesamtszene und 0.90 im Testgebiet Andernacherstr.).
2. Von den Fuzzy Verfahren hat die Fusion mittels des neuronalen Netzes der mit FKNN klassifizierten Bilder die besten Ergebnisse erbracht (Kappa-Werte zwischen 0.71 Testgebiet Rennweg und 0.83 Testgebiet Andernacherstr.).
3. Die Reduktion der Kanalanzahl auf vier Kanäle verschlechterte die Genauigkeit der Klassifikation um maximal 0.13 im Kappa-Wert. D.h., daß auch mit den IKONOS Daten gute Klassifikationsergebnisse erzielt werden können.

Die getesteten Fuzzy Verfahren, Fuzzy *k-nearest-neighbor* Klassifikation (FKNN), Fusion mittels gewichteter konvexer Linearkombination (FLK), sowie die Fusion mittels eines dreischichtigen neuronalen Netzes (FNN), haben unterschiedliche Ergebnisse ergeben.

FKNN Die FKNN Klassifikation erwies sich als robust gegenüber Änderungen in Testgebieten und der Klassenanzahl. Die Gesamtszene wurde am schlechtesten bewertet mit einem Kappa-Wert von 0.636 für zehn bzw. 0.552 für vier Kanäle.

FNN Etwas besser als die FKNN Klassifikation schnitt die Fusion der Einzel-Kanal-Klassifikation mit der FNN ab (0.62 bzw. 0.757). Der Vergleich der Gütemaße stellt die FNN schlechter als die ML Klassifikation dar. Ein visueller Vergleich zeigt jedoch, daß die FNN bei einigen Klassen, wie z.B. den stark reflektierenden Klassen Sand und Metalldach, besser ist als die ML Klassifikation. Dies liegt u.a. daran, daß keine Normalverteilung der Klassen angenommen werden muß. Auch dieses Verfahren war in allen Testgebieten gleich gut.

FLK Die FLK brachte keine guten Ergebnisse. Die Reduktion der Anzahl der Klassifikationen (entsprechend der Reduktion der Kanäle), die fusioniert wurden, machte sich deutlich stärker bemerkbar. Auch die Erhöhung der Klassenanzahl führte zu schlechteren Ergebnissen. Eine Ursache dafür dürfte in den Gütemaßen liegen, die bei der Einzel-Kanal-Klassifikation mit vielen Klassen, teilweise sehr niedrig ausfallen, da der Merkmalsraum sehr klein ist (255 Werte) und die Klassen sich stark überlagern.

Die klassenspezifischen Gütemaße PAUA und FPAUA können bei der Klassenauswahl helfen. Klassen mit niedrigen Gütemaßen können entweder als nichtklassifizierbar gekennzeichnet werden oder aus der Klassifikation herausgenommen werden. Ein anderer Weg wäre die Suche nach anderen Merkmalen, wie Objektform oder thermale Signatur, um die Klassen auszuzeichnen.

7.3 Vergleich mit aktueller Forschung

Es wurden bisher wenige Untersuchungen zur Genauigkeit von hochauflösenden Multispektraldaten städtischer Gebiete gemacht. Die Fusion von Klassifikationsergebnisse wurde bisher nur von Benediktsson et. al. [BS97] näher untersucht.

Die Untersuchung von Benediktsson et. al. [BS97] aus dem Jahre 1997 vergleicht verschiedene Fusionsverfahren zur Klassifikation von hyperdimensionalen Datensätzen. Sie untersuchten verschiedene Verfahren der *consensus theory*, wie die gewichtete Linearkombination von A POSTERIORI Wahrscheinlichkeiten. Als Datensatz standen Hyperspektralaufnahmen von Island zur Verfügung, die mit dem AVIRIS Sensor (224 Kanäle) aufgenommen wurden. Die Kanäle wurden in drei Datensätze zerlegt. Aus diesen Datensätzen wurden die Kanäle ausgewählt, die 99% der Information enthielten. Diese drei Datensätze wurden jeweils mit ML klassifiziert. Die Klassifikation sollte 15 verschiedene Klassen erkennen. Sie erreichten die besten Ergebnisse mit der Methode des *logarithmic option pool* (LOGP) (93,0 % Overall Accuracy), die damit um 10 % höher liegt als die Ergebnisse ihrer ML Klassifikation. LOGP entspricht einer gewichteten Summe der logarithmierten A Posteriori Wahrscheinlichkeiten der ML Klassifikationen. Die Datensätze wurden dabei gleichmäßig gewichtet.

In einer früheren Untersuchung von Benediktsson et. al. [BSE90] wird ein Vergleich zwischen neuronalen Netzen (NN) und statistischen Verfahren, wie der ML Klassifikation, vorgenommen. Dabei sehen Benediktsson et. al. den Vorteil der NN in der Unabhängigkeit von der Verteilung der Werte einer Klasse, die ja bei der ML Klassifikation als normalverteilt angenommen wird. Der Nachteil, den sie sehen, ist die lange Rechenzeit, die das Training eines NN benötigt.

Andere Untersuchungen zur Klassifikation von Multispektraldaten städtischer Gebiete wurden von Kulbach [Kul97], Roessner et al. [RSMK98], Bayer et al. [BH97] und Netzband et al. [NM97] gemacht.

Kulbach hat sich ebenfalls mit DAEDALUS Aufnahmen beschäftigt und eine statistische Analyse der Klassifikationsgenauigkeiten durchgeführt. Die Bodenauflösung seiner Daten betrug 1 m. Er erzielte dabei für die Maximum Likelihood Klassifikation Kappa-Werte von durchschnittlich 0.52. Auch stellt er fest, daß die Klassifikationsgenauigkeit mit der Erhöhung der Trainingsklassen besser wird. Als Trainingsklassen bezeichnet Kulbach auch unterschiedliche Trainingsgebiete desselben Typs, z.B. Flachdach dunkel. Kulbach vermutete, daß die schlechten Kappa-Werte auf die Auflösung zurückzuführen seien, da in der Literatur bei niedrigen Auflösungen (z.B. Landsat 30 m) bessere Werte angegeben werden.

Bei der Klassifikation der städtischen Oberflächen der Stadt Dresden, die Roessner et al. durchgeführt haben, wurden DAIS 7915¹ Daten verwendet. Es wurde zunächst eine ML Klassifikation vorgenommen. Diese Klassifikation wurde mit 29 am Boden gemessenen Spektren verglichen und nur Pixel, die in den Spektren mit den Standardspektren über-

¹DAIS - Digitale Airborne Imaging Spectrometer. Es wurden 72 Spektralkanäle verwendet mit einer Auflösung von 6 m bei einer Flughöhe von 3500 m

Detektor	Auflösung [m]	Methode	Genauigkeit	Autor
DAEDALUS	3	ML und Fuzzy-Verfahren	Kappa-Werte: 0.6 bis 0.9	Rega, 2000
AVIRIS	20	ML und <i>consensus theory</i>	<i>Overall Accuracy</i> : 0.8 bis 0.9	Benekitsson et al., 1997
DAEDALUS	1	ML	Kappa-Wert: um 0.52	Kulbach, 1997
DAIS	6	ML und <i>spectral-unmixing</i>	keine Angaben	Roessner et al., 1998
DAEDALUS	2	NDVI und ML	<i>Overall Accuracy</i> : 0.85	Bayer et al., 1997
DAEDALUS	2	NDVI, multitemporale Thermalklassifikation und ML	Fehler wird mit 5% bis 15% angegeben	Netzband et al., 1997

Tabelle 7.1: Vergleich verschiedener Arbeiten zur Klassifikation von Multispektralaufnahmen.

einstimmten, wurden als richtig klassifiziert gewertet. Diese machen etwa ein Drittel des untersuchten Gebietes aus. Die übrigen Gebiete wurden mittels eines *spectral-unmixing* Verfahrens klassifiziert. Eine Angabe über die Genauigkeit ihrer Klassifikation machen Roessner et. al. in [RSMK98] nicht.

Die in der Einleitung erwähnten Untersuchungen zur automatischen Detektion von versiegelten Gebieten im städtischen Bereich von Bayer et. al. und Netzband et. al. haben DAEDALUS Daten mit einer Bodenauflösung von 2 m benutzt. Dazu wurden bei Netzband et. al. noch multitemporale Thermalbilder als zusätzliche Informationsquelle benutzt. Beide Untersuchungen verwenden ein hierarchisches Klassifikationsverfahren, das mit der Detektion von Vegetation mittels des NDVI beginnt und für die spätere Trennung von bebauten Flächen von unversiegelten Bodenflächen eine ML Klassifikation benutzt. Netzband et. al. schätzen ihren Fehler auf 5 % bis 10 % Prozent, Bayer et. al. geben eine Gesamtgenauigkeit von 85 % an.

In der Tabelle 7.1 sind die verschiedenen Ergebnisse und Methoden nochmal vergleichend dargestellt.

7.4 Abschließende Betrachtung

Die Untersuchung der Fuzzy-Verfahren wurde in Hinblick auf eine Verbesserung der Ergebnisse, die Daniel Kulbach erzielt hatte, begonnen. Im Laufe der Untersuchung zeichnete sich ab, daß die niedrigen Kappa-Werte von Kulbach nicht bestätigt werden konnten. Die ML Klassifikation erreichte bei der vorgegeben Auswahl an Trainingsklassen und Testgebieten eine teilweise ausgezeichnete Klassifikationsgüte. Die Fuzzy-Verfahren schnitten im Durchschnitt schlechter ab.

Auffällig waren bei den Klassifikationsergebnissen vor allem zwei Erscheinungen:

1. Die Fehlklassifikation von Schattengebieten als Wasser.
2. Die unterschiedliche Genauigkeit der einzelnen Klassen.

Die Extraktion von Schattengebieten wird momentan in der Arbeitsgruppe untersucht. Dabei macht man sich folgende Besonderheiten von Schatten zunutze: Die Schattengebiete werden nur von Himmelslicht beleuchtet, daß nur einen sehr niedrigen Rot- und Infrarotanteil hat und somit eine nur geringe Reflektanz in diesem Bereich des Spektrums aufweist. Diese Eigenschaft bedingt einen Schwellwert bei diesen Kanälen. Wird dieser Schwellwert unterschritten, ist ein Kriterium für Schatten erfüllt. Um Wasserflächen auszuschließen, dürfen die Schattengebiete im blauen Spektralbereich einen gewissen Schwellwert nicht unterschreiten. Weitere Bedingungen lassen sich aus dem NDVI ableiten, um die dunkle Vegetation aus den Schattengebieten herauszuhalten. Um dunkle Gebäude von Schattenflächen zu trennen, wird auch die Objektgröße und -form der gefundenen Schattengebiete ermittelt. Bei großen flächigen Objekten wird davon ausgegangen, daß es sich nicht um Schatten handelt. Die Schattenbereiche können dann entweder nicht weiter berücksichtigt werden oder getrennt klassifiziert werden. Ein Problem ergibt sich dabei aus den niedrigen absoluten Helligkeiten.

Um Schattenbereiche besser in der Helligkeit auflösen zu können, müssen Spektrometer mit größeren Intensitätsbereichen benutzt werden. Die 8 Bit des DAEDALUS Detektors decken den Intensitätsbereich der reflektierten Strahlung nur ungenügend ab. Die Skalierung der Aufnahmen könnte dem menschlichen Auge angepaßt werden, so daß in dunklen Bereichen die Ober- und Untergrenze des Intensitätsbereiches angepaßt wird.

Bei der Klassenauswahl stößt man auf unterschiedliche Anforderungen und teilweise sehr abstrakte Informationsklassen, die sich nicht aus spektralen Eigenschaften ergeben, sondern aus Umgebungsinformationen. Hier müssen neue Wege gesucht werden, wie z.B. objektorientierte Klassifikation und Fusion mit Höhenmodellen.

8 Ausblick

Für eine Verbesserung der Klassifikation von städtischen Gebieten gibt es eine Reihe von neuen Ansätzen. Teilweise sind diese neuen Verfahren schon erwähnt worden, wie z.B. die objektorientierte Klassifikation.

Im Rahmen des Laborpraktikums, das ich zu Beginn meiner Diplomarbeit in der Arbeitsgruppe absolviert habe, wurde die Möglichkeit untersucht, klassifizierte Bilder zu segmentieren, d.h. räumlich getrennte Gebiete in einer Klasse zu suchen und zu Objekten zusammenzufassen. Diese Objekte ließen sich dann auf Umfang und Fläche hin untersuchen. Damit könnten flächige Objekte, wie z.B. Hausdächer, von länglichen Gebieten, wie z.B. Straßen unterschieden werden. Aufgrund langer Rechenzeiten, die der Segmentierungsalgorithmus benötigte, wurde dieses Verfahren nicht weiter untersucht. Ein weiterer Vorteil von Objekten besteht darin, daß man z.B. den Abstand zwischen Objekten unterschiedlicher Klassen bestimmen kann, um neue Aussagen zu gewinnen, wie z.B. die Aussage, daß es sich bei Flachdachgebäuden in der Nähe von Wasser um eine Hafenanlage handeln könnte. Eine Segmentierung vor einer Klassifikation kann dazu genutzt werden, gebietsspezifische Klassen zur Klassifizierung zu benutzen. Ein Gebiet, das hauptsächlich von Vegetation dominiert wird, sollte mit anderen Klassifikatoren untersucht werden, als ein städtisches Gebiet. Eine Software, die diese Segmentierung vornimmt und mit objektorientierter Klassifikation arbeitet, ist *eCognition* von Delphi2¹. Ein Test dieser Software konnte in unserer Arbeitsgruppe bisher nicht vorgenommen werden. Als hilfreich könnte sich auch die Verwendung eines Schattenfilters erweisen.

Ein anderer Ansatz zur Verbesserung von Klassifikationsergebnissen ist die Fusion von Daten unterschiedlicher Informationsquellen. Hier könnte die Fusion von einer Thermalklassifikation mit der Klassifikation von Reflektanzbildern interessante Ergebnisse bringen.

Weitere Informationsquellen sind SAR Daten, digitale Höhenmodelle und GIS Daten. In einem Projekt des DLR, das in diesem Jahr begonnen hat, wird die Zusammenführung von SAR- und Multispektral-Daten untersucht.

Der CENSIS Arbeitsgruppe stehen seit April 2000 vierkanalige Satelliten-Daten des IKONOS Satelliten zur Verfügung. Die Auflösung der Multispektralkanäle beträgt 4 m. Sie läßt sich aber durch die Fusion mit dem panchromatischen Kanal, der 1 m Bodenauflösung hat, erhöhen. Die untersuchte Reduktion der Spektralkanäle ließe sich an diesen Daten testen. Der Vorteil dieser Daten liegt u.a. darin, daß ein Vergleich von Aufnahmen derselben Szene leichter möglich ist (Stichwort: Änderungsdetektion durch Klassifikation), da die Bilder georeferenziert sind. Die Verzerrungen durch Flugzeugbewegungen entfallen

¹Delphi2 Creative Technologies, Rindermarkt 7, D-80331 München
www.delphi2.de

und der Panoramaeffekt ist sehr viel kleiner, da eine Szene als Ganzes durch ein CCD Array² aufgenommen wird, dadurch können einfachere Registrierungsverfahren verwendet werden. Auch die Verzerrung von Gebäuden durch einen schrägen Aufnahmewinkel entfällt, wenn man die Szene aus Nadir aufnimmt.

²Charged Coupled Device - Eine digitale Kamera, die aus vielen in einem Feld (Array) angeordneten Fotodioden besteht.

Literaturverzeichnis

- [AKC⁺95] G. P. Anderson, F. X. Kneizys, J. H. Chetwynd, J. Wang, M. L. Hoke, L. S. Rothman, L. M. Kimball, R. A. McClatchey, E. P. Shattle, S. A. Clough, W. O. Gallery, L. W. Abreu, and J. E. A. Selby. FASCODE / MODTRAN / LOWTRAN : Present / past / future. In *Proceedings of the 18th Annual Review Conference on Atmospheric Transmission Models, June 6–8, 1995*.
- [BB99] Andrea Baraldi and Palma Blonda. A survey of fuzzy clustering algorithms for pattern recognition - part i and ii. *IEEE Transactions on Systems, Man, and Cybernetics Part B: Cybernetics*, 29, 1999.
- [Ben99a] Ursula Benz. *Ein lernfähiger Fuzzy-Verteilungsschätzer zur adaptiven Analyse von Radardaten*. Forschungsbericht DLR-FB Nr. 99-03, Oberpfaffenhofen, 1999.
- [Ben99b] Ursula Benz. Supervised fuzzy analysis of single- and multi-channel SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 37:1023–1037, 1999.
- [BFH75] Yvonne M. M. Bishop, Stephen E. Fienberg, and Paul W. Holland. *Discrete multivariate analysis : theory and practice*. MIT Press, Cambridge, Mass., 1975.
- [BH97] Thomas Bayer and Manuela Hilz. Nutzung von hochauflösenden Fernerkundungsdaten zur Erfassung der kommunalen Flächenversiegelung und Flächennutzung. In *Fernerkundung in Urbanen Räumen*. Heft 28 der *Regensburger Geographische Schriften*, Institut für Geographie an der Universität Regensburg, 1997.
- [Bis95] Christopher M. Bishop. *Neuronal networks for pattern recognition*. Clarendon Press, Oxford, 1995.
- [BJ99] Ursula Benz and Gunther Jäger. Multichannel classification of SAR-images using fuzzy logic. In Ann Arbor Environmental Research Institute (ERIM), editor, *Proc. of the 4th Intern. Airborne Remote Sensing Conference and Exhibition*, volume II, pages 857–866, Ottawa, Ontario, Canada, 1999.
- [Blo96] Isabelle Bloch. Information combination operators for data fusion: A comparative review with classification. *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*, 26:52–67, 1996.

- [Bot98] Hans-Heinrich Bothe. *Neuro-Fuzzy-Methoden*. Springer-Verlag, Berlin, Heidelberg, New York, 1998.
- [BP92] James C. Bezdek and Sankar K. Pal. A convergence theorem for the fuzzy isodata clusterings algorithms. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 130–137, New York, 1992. IEEE Press.
- [BS97] Jon Atli Benediktsson and Johannes R. Sveinsson. Classification of hyperdimensional data using data fusion approaches. In *IGARSS 97*, pages 1669–1671. Singapore International Convention & Exhibition Centre, 1997.
- [BSE90] Jon Atli Benediktsson, Philip H. Swain, and Okan K. Ersoy. Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 28:540–551, 1990.
- [CH67] T.M. Cover and P.E. Hart. Nearest neighbor pattern classification. *IEEE Trans. Inform. Theory*, IT-21:21–27, 1967.
- [DH73] Richard O. Duda and Peter E. Hart. *Pattern classification and scene analysis*. John Wiley & Sons, New York, Chichester, Brisbane, Toronto, Singapore, 1973.
- [Drö94] Christoph Drösser. *Methodische Einführung in krauses Denken*. rororo, Reinbeck bei Hamburg, 1994.
- [Dun73] J.C. Dunn. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. *International Journal of Cybernetics*, 3:32–57, 1973.
- [Ela87] Charles Elachi. *Introduction to the Physics and Techniques of Remote Sensing*. John Wiley & Sons, New York, Chichester, Brisbane, Toronto, Singapore, 1987.
- [FPS99] Ramon Franck, Boris Prinz, and Hartwig Spitzer. Supporting land-use mapping by using multitemporal thermal infrared imagery in conjunction with a simple diurnal temperature model. In Ann Arbor Environmental Research Institute (ERIM), editor, *Proc. of the 4th Intern. Airborne Remote Sensing Conference and Exhibition*, volume I, pages 353–360, Ottawa, Ontario, Canada, 1999.
- [HJKH99] M. Hellmann, G. Jäger, E. Kratzschmar, and M. Habermeyer. Classification of full polarimetric SAR data using artificial neural networks and fuzzy algorithms. In *IGARSS 99, Hamburg*, pages 1995–1997, 1999.
- [HKK97] Frank Höppner, Frank Klawonn, and Rudolph Kruse. *Fuzzy-Clusteranalyse*. Vieweg, Wiesbaden, 1997.

- [JB00] G. Jäger and U. Benz. Measures of classification accuracy based on fuzzy similarity. *IEEE Transactions on Geoscience and Remote Sensing*, 38:1462–1467, 2000.
- [JBS00] G. Jäger, U. Benz, and R. Schreiber. Knowledge-based quality assessment and improvement of digital elevation models from interferometric SAR data. *DLR Oberpfaffenhofen, intern*, 2000.
- [KGG85] J.M. Keller, M.R. Gray, and J.A. Givens. A fuzzy k-nearest neighbor algorithm. *IEEE Trans. Syst., Man., Cybern.*, 15:580–585, 1985.
- [KS88] Karl Kraus and Werner Schneider. *Fernerkundung*, volume 1: Physikalische Grundlagen und Aufnahmetechniken. Ferd. Dümmlers Verlag, Bonn, 1988.
- [Kul97] Daniel Kulbach. *Systematischer Vergleich von Verfahren zur überwachten Klassifikation von multispektralen Luftbildern mit Bodenaufösungen im Meterbereich*. Diplomarbeit, Universität Hamburg, II. Inst. f. Experimentalphysik, CENSIS-Report 29-97, 1997.
- [Mat99] Matthias Möller. Hochoauflösende Fernerkundungsdaten als Quelle für den Aufbau von Stadtinformationssystemen am Beispiel eines digitalen Versiegelungskatasters. In *Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, Band 7*, pages 341–348, 1999.
- [Mei96] Gerhard Meister. *Messung der spektralen Reflektionsfunktion (BRDF) ausgewählter Oberflächen bei natürlicher Beleuchtung*. Diplomarbeit, Universität Hamburg, II. Inst. f. Experimentalphysik, CENSIS-Report 18-96, 1996.
- [Mei00] Gerhard Meister. *Bidirectional Reflectance of Urban Surfaces*. Dissertation eingereicht beim Fachbereich Physik der Universität Hamburg, August 2000, 2000.
- [NM97] Maik Netzband and Gotthard Meinel. Aspekte städtischer Versiegelungserhebung einschließlich GIS-technischer Weiterverarbeitung. In *Fernerkundung in Urbanen Räumen*. Heft 28 der *Regensburger Geographische Schriften*, Institut für Geographie an der Universität Regensburg, 1997.
- [OFE97] M. J. Ortiz, A. R. Formaggio, and J. C. N. Epiphonio. Classification of croplands through integration of remote sensing, GIS and historical database. *International Journal of Remote Sensing*, 18:95–105, 1997.
- [Reg00] Niklas Rega, 2000. Bericht zum dreimonatigen Aufenthalt beim DLR Oberpfaffenhofen.
- [RFL86] G.H. Rosenfield and K. Fitzpatrick-Linz. A coefficient of agreement as a measure of thematic classification accuracy. *Photogramm. Engineering and Remote Sensing*, 52:223–227, 1986.

- [Ric99] John A. Richards. *Remote Sensing Digital Image Analysis: An Introduction*. Springer Verlag, New York, Berlin, Heidelberg, 3rd edition, 1999.
- [RKS98] A. Rothkirch, M. Kollewe, and H. Spitzer. Calibration accuracy of aerial multispectral reflectance images and estimation of error sources. In *Proceedings of the 1'st workshop on imaging spectroscopy, Zurich, CH, ISBN 2-90885-22-0*, pages 155–163, 1998.
- [Rot97] André Rothkirch. *Feldmessung der spektralen Reflexionsfunktion (BRDF) eines Hausdaches*. Diplomarbeit, Universität Hamburg, II. Institut f. Experimentalphysik, CENSIS-Report 30-97, Juli 1997.
- [RSMK98] S. Roessner, K. Segl, K. Munier, and H. Kaufmann. Application of hyperspectral data for differentiation of urban surfaces in the city of dresden, germany. In *Proceedings of the 1'st workshop on imaging spectroscopy, Zurich, CH, ISBN 2-90885-22-0*, pages 463–472, 1998.
- [Wie97] Rafael Wiemker. Unsupervised fuzzy classification of multispectral imagery using spatial-spectral features. In *Classification, Data Analysis and Data Highways*, pages 101–109, Springer-Verlag, 1997.
- [Zad65] Lofti Zadeh. Fuzzy sets. *Inform. & Control*, 8:338–353, 1965.
- [Zel94] André Zell. *Simulation neuronaler Netze*. Addison-Wesley, Bonn, 1994.
- [Zen00] Stephan Zenk. *Vergleich verschiedener Verfahren zur Erkennung von Änderungen in multispektralen Luftbildern städtischer Gebiete*. Diplomarbeit, Universität Hamburg, CENSIS-Report 35-00, Mai 2000.
- [Zim91] H.-J. Zimmermann. *Fuzzy Set Theory - and its Applications*. Kluwer, Dordrecht, 1991.

A Tabellen

A.1 Testgebiet: Andernacherstr.

Klasse:	1	2	3	4	5	6	7	8	9	10	11	12	κ	
ML	PAUA(alle)	0.914	0.788	0.674	0.871	0.801	0.837	0.643	0.938	0.866	0.837	0.961	0.936	0.902
	PAUA(ikonos)	0.815	0.702	0.656	0.904	0.773	0.743	0.563	0.886	0.867	0.819	0.856	0.889	0.870
FKNN	PAUA(alle)	0.780	0.642	0.600	0.803	0.666	0.539	0.288	0.924	0.871	0.838	0.941	0.601	0.820
	PAUA(ikonos)	0.642	0.503	0.396	0.793	0.446	0.382	0.249	0.883	0.831	0.788	0.814	0.290	0.729
	FPAUA(alle)	0.850	0.778	0.773	0.840	0.730	0.684	0.634	0.928	0.907	0.900	0.975	0.968	
	FPAUA(ikonos)	0.805	0.692	0.662	0.817	0.581	0.514	0.591	0.879	0.882	0.863	0.799	0.843	
FLK	PAUA(alle)	0.709	0.436	0.353	0.748	0.306	0.437	0.197	0.868	0.706	0.641	0.906	0.244	0.687
	PAUA(ikonos)	0.355	0.373	0.331	0.745	0.180	0.401	0.188	0.666	0.597	0.523	0.428	0.213	0.598
	FPAUA(alle)	0.409	0.423	0.398	0.690	0.237	0.431	0.364	0.355	0.411	0.342	0.543	0.653	
	FPAUA(ikonos)	0.370	0.444	0.467	0.750	0.247	0.434	0.386	0.400	0.478	0.380	0.394	0.673	
FNN	PAUA(alle)	0.737	0.678	0.668	0.812	0.640	0.590	0.326	0.928	0.897	0.852	0.952	0.620	0.834
	PAUA(ikonos)	0.673	0.524	0.485	0.809	0.479	0.443	0.232	0.910	0.840	0.762	0.848	0.397	0.752
	FPAUA(alle)	0.876	0.771	0.758	0.877	0.696	0.672	0.583	0.953	0.908	0.905	0.974	0.929	
	FPAUA(ikonos)	0.818	0.672	0.642	0.846	0.585	0.573	0.507	0.900	0.862	0.907	0.850	0.826	

Tabelle A.1: Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Andernacherstr.

Kanalauswahl: alle - alle Kanäle; ikonos- IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK

- Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

	Klasse:	1	2	3	4	5	6	7	8	9	10	11	12	κ
ohne ch1	ML	0.904	0.838	0.799	0.947	0.806	0.835	0.562	0.934	0.915	0.886	0.944	0.960	0.914
	FNN	0.753	0.700	0.656	0.825	0.639	0.597	0.349	0.939	0.887	0.842	0.953	0.660	0.839
	FPAUA:	0.873	0.762	0.764	0.882	0.681	0.716	0.581	0.951	0.923	0.894	0.978	0.910	
ohne ch2	ML	0.893	0.809	0.785	0.952	0.778	0.821	0.519	0.935	0.913	0.884	0.941	0.972	0.906
	FNN	0.775	0.664	0.609	0.820	0.621	0.576	0.343	0.926	0.893	0.814	0.939	0.684	0.827
	FPAUA:	0.866	0.776	0.786	0.870	0.651	0.675	0.567	0.932	0.906	0.923	0.981	0.927	
ohne ch3	ML	0.904	0.843	0.804	0.936	0.813	0.841	0.577	0.932	0.901	0.890	0.952	0.933	0.916
	FNN	0.776	0.682	0.634	0.824	0.609	0.594	0.305	0.931	0.890	0.838	0.951	0.736	0.829
	FPAUA:	0.882	0.743	0.775	0.871	0.637	0.705	0.619	0.949	0.901	0.907	0.977	0.912	
ohne ch4	ML	0.914	0.823	0.782	0.945	0.793	0.839	0.560	0.935	0.910	0.879	0.957	0.960	0.912
	FNN	0.745	0.677	0.655	0.827	0.642	0.586	0.340	0.936	0.882	0.853	0.947	0.664	0.836
	FPAUA:	0.863	0.764	0.782	0.883	0.695	0.699	0.541	0.942	0.936	0.893	0.981	0.927	
ohne ch5	ML	0.898	0.839	0.788	0.908	0.790	0.837	0.570	0.934	0.915	0.896	0.941	0.944	0.912
	FNN	0.791	0.679	0.625	0.824	0.649	0.586	0.360	0.936	0.890	0.839	0.953	0.707	0.838
	FPAUA:	0.840	0.747	0.816	0.889	0.671	0.734	0.523	0.960	0.924	0.902	0.980	0.905	
ohne ch6	ML	0.901	0.823	0.787	0.949	0.799	0.841	0.546	0.923	0.900	0.861	0.949	0.964	0.909
	FNN	0.761	0.694	0.645	0.823	0.658	0.575	0.372	0.931	0.881	0.839	0.945	0.653	0.838
	FPAUA:	0.870	0.812	0.796	0.867	0.685	0.688	0.553	0.933	0.926	0.893	0.979	0.912	
ohne ch7	ML	0.904	0.814	0.770	0.943	0.784	0.831	0.542	0.906	0.888	0.845	0.947	0.960	0.902
	FNN	0.778	0.665	0.648	0.826	0.617	0.582	0.305	0.935	0.881	0.825	0.951	0.607	0.827
	FPAUA:	0.861	0.723	0.764	0.870	0.672	0.727	0.568	0.951	0.912	0.910	0.984	0.957	
ohne ch8	ML	0.915	0.799	0.749	0.944	0.792	0.826	0.563	0.909	0.887	0.850	0.965	0.952	0.903
	FNN	0.750	0.696	0.650	0.832	0.600	0.594	0.318	0.933	0.869	0.809	0.935	0.644	0.828
	FPAUA:	0.853	0.749	0.766	0.878	0.617	0.727	0.637	0.933	0.893	0.914	0.981	0.919	
ohne ch9	ML	0.908	0.796	0.792	0.945	0.809	0.823	0.549	0.934	0.906	0.882	0.949	0.960	0.909
	FNN	0.770	0.652	0.644	0.825	0.616	0.566	0.306	0.933	0.883	0.831	0.948	0.671	0.827
	FPAUA:	0.880	0.773	0.736	0.876	0.719	0.622	0.502	0.938	0.931	0.913	0.981	0.936	
ohne ch1	ML0	0.862	0.820	0.708	0.945	0.778	0.842	0.517	0.939	0.909	0.887	0.900	0.949	0.903
	FNN	0.738	0.667	0.591	0.819	0.589	0.573	0.271	0.942	0.892	0.844	0.940	0.584	0.816
	FPAUA:	0.847	0.784	0.662	0.866	0.563	0.679	0.537	0.950	0.914	0.900	0.958	0.907	

Tabelle A.2: Kappa-Wert, PAUA und FPAUA Gütemaße des Testgebiet: Andernacherstr.

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k*-nearest-neighbor Klassifikation; FLK

- Fusion mittels gewichteter Linear kombination; FNN - Fusion mittels neuronalem Netz

A.2 Testgebiet: Innenstadt

Klasse:	1	2	3	4	5	6	7	8	9	10	κ
ML	0.874	0.696	0.734	0.679	0.959	0.830	0.396	0.817	0.814	0.953	0.884
	0.851	0.613	0.732	0.740	0.869	0.835	0.470	0.908	0.501	0.967	0.887
FKNN	0.556	0.334	0.480	0.632	0.233	0.711	0.212	0.769	0.347	0.788	0.708
	0.559	0.272	0.446	0.607	0.267	0.642	0.217	0.761	0.249	0.790	0.692
	0.566	0.754	0.876	0.688	0.729	0.775	0.789	0.810	0.788	0.980	
	0.524	0.761	0.878	0.648	0.669	0.674	0.673	0.812	0.774	0.975	
FLK	0.310	0.174	0.335	0.197	0.088	0.589	0.211	0.492	0.143	0.793	0.561
	0.106	0.121	0.334	0.213	0.089	0.501	0.138	0.381	0.065	0.750	0.536
	0.181	0.328	0.751	0.249	0.221	0.391	0.292	0.412	0.302	0.749	
	0.148	0.331	0.713	0.271	0.232	0.367	0.333	0.434	0.294	0.672	
FNN	0.665	0.436	0.729	0.542	0.433	0.731	0.258	0.688	0.334	0.805	0.760
	0.533	0.337	0.618	0.439	0.244	0.647	0.280	0.661	0.219	0.756	0.689
	0.676	0.710	0.879	0.771	0.626	0.792	0.739	0.864	0.826	0.972	
	0.540	0.719	0.847	0.710	0.578	0.677	0.639	0.844	0.718	0.954	

Tabelle A.3: Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Innenstadt

Kanalauswahl: alle - alle Kanäle; ikonos- IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK

- Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

		Klasse:	1	2	3	4	5	6	7	8	9	10	κ
ohne ch 1	ML	PAUA	0.884	0.820	0.734	0.588	0.986	0.817	0.358	0.889	0.853	0.966	0.889
	FNN	PAUA	0.637	0.419	0.678	0.579	0.274	0.734	0.271	0.678	0.327	0.772	0.747
ohne ch 2	ML	FPAUA	0.656	0.737	0.879	0.761	0.678	0.785	0.689	0.865	0.824	0.976	
	FNN	PAUA	0.879	0.693	0.805	0.595	0.949	0.811	0.371	0.891	0.832	0.965	0.887
ohne ch 3	ML	FPAUA	0.636	0.442	0.714	0.515	0.251	0.736	0.304	0.644	0.321	0.811	0.747
	FNN	PAUA	0.656	0.718	0.883	0.768	0.662	0.787	0.715	0.868	0.826	0.971	
ohne ch 4	ML	PAUA	0.886	0.781	0.781	0.589	0.929	0.826	0.380	0.901	0.875	0.964	0.894
	FNN	PAUA	0.655	0.441	0.674	0.558	0.350	0.726	0.302	0.642	0.350	0.809	0.756
ohne ch 5	ML	FPAUA	0.679	0.733	0.886	0.747	0.614	0.764	0.695	0.867	0.796	0.970	
	FNN	PAUA	0.886	0.802	0.784	0.574	0.966	0.811	0.341	0.889	0.871	0.966	0.887
ohne ch 6	ML	FPAUA	0.668	0.452	0.671	0.503	0.433	0.733	0.309	0.632	0.357	0.772	0.758
	FNN	PAUA	0.672	0.693	0.884	0.768	0.520	0.789	0.670	0.873	0.788	0.974	
ohne ch 7	ML	PAUA	0.879	0.813	0.716	0.536	0.966	0.834	0.394	0.886	0.864	0.966	0.891
	FNN	PAUA	0.664	0.475	0.718	0.601	0.369	0.737	0.293	0.636	0.320	0.813	0.761
ohne ch 8	ML	FPAUA	0.684	0.735	0.877	0.754	0.635	0.795	0.685	0.869	0.830	0.967	
	FNN	PAUA	0.879	0.808	0.754	0.542	0.983	0.808	0.340	0.882	0.842	0.965	0.882
ohne ch 9	ML	FPAUA	0.647	0.479	0.705	0.552	0.291	0.729	0.271	0.642	0.350	0.781	0.747
	FNN	PAUA	0.650	0.738	0.883	0.756	0.644	0.784	0.723	0.862	0.813	0.979	
ohne ch 10	ML	PAUA	0.870	0.807	0.649	0.584	0.963	0.813	0.346	0.882	0.839	0.965	0.880
	FNN	PAUA	0.639	0.444	0.621	0.581	0.266	0.739	0.308	0.689	0.362	0.757	0.749
ohne ch 11	ML	FPAUA	0.640	0.747	0.890	0.743	0.639	0.799	0.735	0.855	0.821	0.979	
	FNN	PAUA	0.871	0.790	0.669	0.567	0.976	0.790	0.313	0.886	0.850	0.965	0.873
ohne ch 12	ML	FPAUA	0.627	0.372	0.614	0.574	0.358	0.726	0.298	0.644	0.295	0.809	0.743
	FNN	PAUA	0.630	0.767	0.896	0.755	0.654	0.799	0.670	0.865	0.839	0.969	
ohne ch 13	ML	PAUA	0.892	0.785	0.774	0.613	0.970	0.818	0.358	0.887	0.836	0.970	0.892
	FNN	PAUA	0.653	0.432	0.726	0.551	0.277	0.731	0.305	0.655	0.356	0.810	0.754
ohne ch 14	ML	FPAUA	0.672	0.730	0.881	0.782	0.709	0.776	0.665	0.872	0.813	0.970	
	FNN	PAUA	0.889	0.779	0.788	0.615	0.973	0.817	0.345	0.887	0.840	0.965	0.891
ohne ch 15	ML	FPAUA	0.663	0.485	0.706	0.542	0.382	0.720	0.258	0.725	0.356	0.758	0.754
	FNN	PAUA	0.668	0.729	0.870	0.765	0.635	0.758	0.799	0.845	0.817	0.977	

Tabelle A.4: Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Innenstadt
 Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k*-nearest-neighbor Klassifikation; FLK
 - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

A.3 Testgebiet: Rennweg

	Klasse:	1	2	3	4	5	6	7	8
		9	10	11	12	13	14	15	κ
ML	PAUA(alle)	0.807	0.495	0.521	0.985	0.874	0.708	0.591	0.829
		0.650	0.823	0.968	0.981	0.698	0.893	0.435	0.859
	PAUA(ikonos)	0.788	0.437	0.349	0.941	0.857	0.665	0.093	0.778
		0.535	0.910	0.927	0.981	0.443	0.881	0.076	0.764
FKNN	PAUA(alle)	0.625	0.571	0.188	0.918	0.380	0.238	0.480	0.669
		0.608	0.479	0.747	0.938	0.627	0.802	0.278	0.706
	PAUA(ikonos)	0.569	0.511	0.187	0.647	0.359	0.319	0.150	0.607
		0.544	0.560	0.726	0.921	0.449	0.739	0.186	0.645
	FPAUA(alle)	0.629	0.862	0.614	0.934	0.500	0.334	0.611	0.699
		0.925	0.994	0.909	0.942	0.713	0.990	0.770	
	FPAUA(ikonos)	0.659	0.723	0.563	0.913	0.465	0.411	0.407	0.644
		0.899	0.926	0.810	0.918	0.536	0.986	0.595	
FLK	PAUA(alle)	0.319	0.420	0.054	0.304	0.273	0.104	0.190	0.497
		0.461	0.207	0.305	0.618	0.430	0.331	0.056	0.496
	PAUA(ikonos)	0.248	0.313	0.017	0.270	0.073	0.025	0.029	0.425
		0.272	0.089	0.138	0.088	0.288	0.333	0.030	0.357
	FPAUA(alle)	0.186	0.405	0.127	0.135	0.187	0.101	0.211	0.242
		0.293	0.231	0.216	0.551	0.271	0.551	0.245	
	FPAUA(ikonos)	0.223	0.412	0.131	0.188	0.129	0.110	0.148	0.301
		0.261	0.268	0.205	0.496	0.198	0.606	0.273	
FNN	PAUA(alle)	0.588	0.637	0.254	0.695	0.404	0.372	0.505	0.641
		0.571	0.636	0.790	0.909	0.547	0.820	0.247	0.710
	PAUA(ikonos)	0.505	0.449	0.098	0.661	0.276	0.328	0.160	0.645
		0.596	0.464	0.645	0.737	0.424	0.779	0.147	0.624
	FPAUA(alle)	0.626	0.820	0.542	0.867	0.556	0.436	0.689	0.627
		0.944	0.877	0.847	0.964	0.581	0.968	0.665	
	FPAUA(ikonos)	0.456	0.516	0.300	0.753	0.367	0.417	0.363	0.616
		0.864	0.757	0.721	0.790	0.513	0.914	0.559	

Tabelle A.5: Kappa-Wert, PAUA und FPAUA Gütemaße Testgebiet: Rennweg

Kanalauswahl: alle - alle Kanäle; ikonos- IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k*-nearest-neighbor Klassifikation; FLK - Fusion mittels gewichteter Linearkombination;

FNN - Fusion mittels neuronalem Netz

ohne		Klasse:	1	2	3	4	5	6	7	8
			9	10	11	12	13	14	15	κ
ch 1	ML	PAUA	0.802	0.645	0.527	0.989	0.855	0.700	0.672	0.869
			0.716	0.905	0.956	1.000	0.741	0.891	0.512	0.877
	FNN	PAUA	0.600	0.621	0.259	0.706	0.406	0.363	0.519	0.699
			0.660	0.669	0.772	0.851	0.563	0.833	0.286	0.727
		FPAUA	0.601	0.826	0.476	0.887	0.540	0.469	0.646	0.688
			0.926	0.834	0.861	0.980	0.629	0.944	0.603	
ch 2	ML	PAUA	0.704	0.682	0.446	0.985	0.872	0.691	0.659	0.861
			0.707	0.881	0.945	1.000	0.708	0.895	0.436	0.861
	FNN	PAUA	0.483	0.595	0.225	0.666	0.390	0.276	0.523	0.676
			0.620	0.621	0.749	0.900	0.532	0.819	0.180	0.689
		FPAUA	0.498	0.822	0.452	0.865	0.507	0.386	0.618	0.680
			0.937	0.846	0.866	0.967	0.596	0.950	0.703	
ch 3	ML	PAUA	0.795	0.629	0.518	0.985	0.852	0.701	0.655	0.864
			0.705	0.937	0.954	0.981	0.744	0.874	0.471	0.873
	FNN	PAUA	0.584	0.690	0.291	0.735	0.394	0.396	0.546	0.689
			0.635	0.679	0.739	0.923	0.578	0.794	0.222	0.724
		FPAUA	0.559	0.769	0.526	0.880	0.508	0.427	0.672	0.688
			0.925	0.889	0.877	0.958	0.706	0.967	0.690	
ch 4	ML	PAUA	0.805	0.646	0.548	0.973	0.868	0.696	0.672	0.863
			0.702	0.920	0.954	0.981	0.739	0.902	0.528	0.877
	FNN	PAUA	0.577	0.640	0.260	0.700	0.404	0.384	0.499	0.714
			0.688	0.672	0.773	0.968	0.576	0.830	0.236	0.724
		FPAUA	0.539	0.647	0.459	0.861	0.511	0.393	0.747	0.718
			0.900	0.860	0.827	0.916	0.667	0.964	0.689	
ch 5	ML	PAUA	0.790	0.618	0.512	0.981	0.853	0.700	0.622	0.829
			0.643	0.907	0.949	1.000	0.725	0.888	0.492	0.864
	FNN	PAUA	0.540	0.636	0.232	0.728	0.405	0.315	0.517	0.717
			0.678	0.652	0.771	0.909	0.565	0.791	0.167	0.706
		FPAUA	0.521	0.613	0.482	0.846	0.514	0.387	0.701	0.713
			0.879	0.877	0.795	0.950	0.654	0.972	0.810	

Tabelle A.6: Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10;

Testgebiet: Rennweg; ohne Kanal 1 bis 5

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy k -nearest-neighbor Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

ohne		Klasse:	1	2	3	4	5	6	7	8
			9	10	11	12	13	14	15	κ
ch 6	ML	PAUA	0.797	0.618	0.548	0.985	0.864	0.696	0.662	0.859
			0.706	0.882	0.952	1.000	0.738	0.890	0.520	0.874
	FNN	PAUA	0.591	0.666	0.344	0.782	0.418	0.380	0.459	0.683
			0.636	0.553	0.807	0.953	0.548	0.791	0.177	0.712
		FPAUA	0.529	0.677	0.393	0.848	0.541	0.461	0.768	0.692
			0.926	0.894	0.829	0.910	0.594	0.981	0.787	
ch 7	ML	PAUA	0.787	0.650	0.555	0.989	0.861	0.697	0.680	0.849
			0.688	0.858	0.952	1.000	0.723	0.905	0.430	0.870
	FNN	PAUA	0.556	0.619	0.287	0.705	0.415	0.390	0.501	0.694
			0.664	0.659	0.774	0.955	0.538	0.840	0.193	0.716
		FPAUA	0.572	0.783	0.511	0.846	0.553	0.455	0.668	0.695
			0.900	0.828	0.819	0.945	0.604	0.962	0.704	
ch 8	ML	PAUA	0.816	0.654	0.570	0.989	0.871	0.699	0.630	0.844
			0.670	0.889	0.942	1.000	0.758	0.911	0.510	0.875
	FNN	PAUA	0.593	0.626	0.208	0.762	0.397	0.280	0.536	0.686
			0.622	0.597	0.766	0.829	0.554	0.841	0.232	0.712
		FPAUA	0.646	0.777	0.305	0.876	0.525	0.465	0.636	0.678
			0.892	0.847	0.833	0.948	0.602	0.941	0.763	
ch 9	ML	PAUA	0.806	0.667	0.527	0.981	0.848	0.700	0.679	0.858
			0.705	0.912	0.952	1.000	0.754	0.905	0.430	0.876
	FNN	PAUA	0.562	0.668	0.281	0.693	0.388	0.391	0.485	0.708
			0.683	0.630	0.792	0.969	0.522	0.803	0.241	0.717
		FPAUA	0.585	0.758	0.461	0.858	0.517	0.410	0.756	0.737
			0.889	0.888	0.828	0.946	0.586	0.961	0.685	
ch 10	ML	PAUA	0.799	0.608	0.527	0.985	0.835	0.710	0.590	0.855
			0.693	0.896	0.945	0.981	0.744	0.882	0.510	0.868
	FNN	PAUA	0.579	0.605	0.236	0.718	0.393	0.410	0.395	0.731
			0.698	0.639	0.784	0.909	0.496	0.802	0.298	0.712
		FPAUA	0.647	0.684	0.549	0.818	0.540	0.392	0.642	0.771
			0.784	0.819	0.835	0.916	0.514	0.978	0.644	

Tabelle A.7: Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10; Testgebietes: Rennweg; ohne Kanal 6 bis 10

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy k -nearest-neighbor Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

A.4 Testgebiet: Thon

	Klasse:	1	2	3	4	5	6	7	8	9
		10	11	12	13	14	15	16	κ	
ML	PAUA(alle)	0.931	0.440	0.934	0.985	0.797	0.721	0.756	0.601	0.260
		0.913	0.966	0.612	0.789	0.873	0.833	0.660	0.841	
	PAUA(ikonos)	0.916	0.175	0.930	0.771	0.571	0.648	0.595	0.425	0.185
		0.964	0.778	0.716	0.806	0.846	0.773	0.300	0.771	
FKNN	PAUA(alle)	0.716	0.261	0.839	0.730	0.379	0.438	0.478	0.507	0.071
		0.894	0.396	0.623	0.725	0.826	0.679	0.219	0.701	
	PAUA(ikonos)	0.732	0.076	0.814	0.600	0.229	0.364	0.478	0.356	0.045
		0.921	0.300	0.586	0.714	0.708	0.700	0.147	0.635	
	FPAUA(alle)	0.975	0.656	0.882	0.792	0.529	0.504	0.526	0.619	0.413
		0.959	1.000	0.899	0.761	0.837	0.931	0.821		
	FPAUA(ikonos)	0.970	0.447	0.880	0.723	0.398	0.408	0.516	0.449	0.320
		0.944	0.979	0.823	0.735	0.750	0.854	0.805		
FLK	PAUA(alle)	0.506	0.032	0.231	0.289	0.046	0.013	0.072	0.072	0.019
		0.360	0.215	0.204	0.166	0.285	0.391	0.036	0.324	
	PAUA(ikonos)	0.576	0.072	0.303	0.522	0.072	0.017	0.082	0.197	0.036
		0.498	0.190	0.259	0.286	0.420	0.420	0.082	0.386	
	FPAUA(alle)	0.673	0.209	0.432	0.280	0.146	0.102	0.120	0.160	0.223
		0.495	0.896	0.363	0.147	0.253	0.291	0.238		
	FPAUA(ikonos)	0.673	0.209	0.432	0.280	0.146	0.102	0.120	0.160	0.223
		0.495	0.896	0.363	0.147	0.253	0.291	0.238		
FNN	PAUA(alle)	0.792	0.295	0.828	0.648	0.467	0.568	0.571	0.610	0.077
		0.893	0.405	0.709	0.723	0.836	0.774	0.261	0.754	
	PAUA(ikonos)	0.772	0.098	0.749	0.464	0.110	0.408	0.300	0.374	0.048
		0.885	0.576	0.583	0.677	0.753	0.700	0.133	0.629	
	FPAUA(alle)	0.974	0.676	0.878	0.784	0.486	0.595	0.627	0.635	0.497
		0.948	1.000	0.881	0.753	0.855	0.919	0.785		
	FPAUA(ikonos)	0.964	0.409	0.844	0.604	0.259	0.435	0.389	0.393	0.358
		0.881	0.997	0.844	0.684	0.761	0.823	0.683		

Tabelle A.8: Kappa-Wert, PAUA und FPAUA Gütemaße; Testgebiet: Thon
 Kanalauswahl: alle - alle DAEDALUS Kanäle; ikonos - IKONOS Kanäle
 Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k*-*nearest-neighbor* Klassifikation; FLK - Fusion mittels gewichteter Linearkombination;
 FNN - Fusion mittels neuronalem Netz

ohne		Klasse:	1	2	3	4	5	6	7	8	9
			10	11	12	13	14	15	16	κ	
ch 1	ML	PAUA:	0.902	0.393	0.937	0.996	0.819	0.664	0.666	0.605	0.230
			0.924	0.964	0.729	0.803	0.869	0.862	0.675	0.836	
	FNN	PAUA:	0.865	0.338	0.819	0.613	0.507	0.623	0.513	0.649	0.086
			0.909	0.391	0.682	0.727	0.854	0.766	0.326	0.779	
	FPAUA:		0.956	0.579	0.873	0.782	0.513	0.665	0.619	0.697	0.489
			0.918	0.998	0.905	0.712	0.842	0.914	0.747		
ch 2	ML	PAUA:	0.884	0.280	0.953	0.992	0.826	0.661	0.742	0.527	0.255
			0.944	0.930	0.741	0.816	0.864	0.867	0.636	0.823	
	FNN	PAUA:	0.813	0.253	0.825	0.653	0.519	0.582	0.506	0.562	0.074
			0.891	0.479	0.692	0.735	0.812	0.752	0.292	0.756	
	FPAUA:		0.966	0.651	0.871	0.775	0.517	0.639	0.587	0.552	0.409
			0.931	1.000	0.882	0.676	0.878	0.846	0.721		
ch 3	ML	PAUA:	0.903	0.380	0.918	0.992	0.824	0.583	0.720	0.547	0.227
			0.919	0.930	0.731	0.787	0.852	0.844	0.645	0.812	
	FNN	PAUA:	0.810	0.314	0.818	0.688	0.521	0.543	0.551	0.628	0.080
			0.880	0.405	0.658	0.778	0.824	0.779	0.251	0.764	
	FPAUA:		0.967	0.614	0.874	0.789	0.564	0.546	0.665	0.715	0.414
			0.949	0.999	0.902	0.772	0.859	0.856	0.765		
ch 4	ML	PAUA:	0.899	0.356	0.924	0.996	0.819	0.666	0.714	0.583	0.256
			0.930	0.964	0.738	0.809	0.867	0.863	0.605	0.834	
	FNN	PAUA:	0.788	0.212	0.833	0.676	0.520	0.574	0.458	0.528	0.086
			0.890	0.567	0.720	0.752	0.845	0.784	0.312	0.751	
	FPAUA:		0.955	0.710	0.871	0.773	0.563	0.601	0.612	0.574	0.415
			0.946	0.989	0.861	0.780	0.872	0.830	0.760		
ch 5	ML	PAUA:	0.917	0.387	0.940	0.996	0.813	0.656	0.705	0.581	0.242
			0.927	0.964	0.751	0.801	0.850	0.861	0.667	0.833	
	FNN	PAUA:	0.844	0.342	0.835	0.673	0.533	0.578	0.536	0.626	0.075
			0.902	0.395	0.718	0.752	0.843	0.788	0.202	0.770	
	FPAUA:		0.959	0.628	0.879	0.781	0.579	0.601	0.570	0.650	0.386
			0.935	1.000	0.886	0.783	0.851	0.860	0.806		

Tabelle A.9: Kappa-Wert, PAUA und FPAUA Gütemaße Kanalauswahl 9 aus 10 ; ohne Kanal 1 bis 5; Testgebiet: Thon

Kanalauswahl: alle - alle DAEDALUS Kanäle; ikonos - IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k*-nearest-neighbor Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

ohne		Klasse:	1	2	3	4	5	6	7	8	9
			10	11	12	13	14	15	16	κ	
ch 6	ML	PAUA:	0.895	0.349	0.946	0.992	0.829	0.658	0.676	0.579	0.274
			0.924	0.966	0.735	0.806	0.862	0.857	0.589	0.830	
	FNN	PAUA:	0.804	0.316	0.840	0.646	0.496	0.578	0.540	0.630	0.082
			0.877	0.507	0.693	0.719	0.840	0.783	0.297	0.768	
	FPAUA:	0.958	0.616	0.864	0.781	0.547	0.592	0.615	0.701	0.433	
			0.948	0.991	0.895	0.746	0.841	0.812	0.753		
ch 7	ML	PAUA:	0.885	0.391	0.940	0.992	0.824	0.649	0.673	0.592	0.260
			0.924	0.933	0.730	0.799	0.861	0.863	0.672	0.832	
	FNN	PAUA:	0.793	0.322	0.825	0.612	0.457	0.596	0.556	0.625	0.077
			0.896	0.436	0.644	0.704	0.815	0.769	0.357	0.760	
	FPAUA:	0.967	0.612	0.881	0.780	0.473	0.633	0.611	0.656	0.491	
			0.920	0.992	0.897	0.672	0.851	0.923	0.659		
ch 8	ML	PAUA:	0.904	0.379	0.956	0.996	0.830	0.650	0.705	0.583	0.281
			0.921	0.966	0.739	0.780	0.855	0.859	0.671	0.831	
	FNN	PAUA:	0.884	0.305	0.838	0.658	0.526	0.596	0.571	0.620	0.072
			0.896	0.382	0.682	0.737	0.828	0.761	0.239	0.769	
	FPAUA:	0.950	0.614	0.878	0.786	0.536	0.619	0.601	0.658	0.421	
			0.949	1.000	0.910	0.720	0.847	0.858	0.770		
ch 9	ML	PAUA:	0.901	0.338	0.924	0.992	0.787	0.653	0.699	0.574	0.244
			0.922	0.964	0.732	0.779	0.852	0.847	0.661	0.825	
	FNN	PAUA:	0.808	0.290	0.832	0.689	0.527	0.574	0.511	0.610	0.040
			0.898	0.436	0.695	0.729	0.841	0.747	0.267	0.765	
	FPAUA:	0.959	0.637	0.888	0.766	0.564	0.585	0.649	0.640	0.247	
			0.921	0.999	0.906	0.686	0.853	0.890	0.758		
ch 10	ML	PAUA:	0.898	0.350	0.921	0.992	0.837	0.619	0.696	0.569	0.250
			0.935	0.840	0.741	0.785	0.863	0.826	0.487	0.820	
	FNN	PAUA:	0.798	0.204	0.824	0.663	0.489	0.572	0.482	0.489	0.070
			0.899	0.472	0.652	0.716	0.821	0.773	0.245	0.736	
	FPAUA:	0.959	0.682	0.886	0.755	0.540	0.611	0.626	0.539	0.427	
			0.949	0.999	0.904	0.737	0.841	0.810	0.649		

Tabelle A.10: Kappa-Wert, PAUA und FPAUA Gütemaße Kanalauswahl 9 aus 10 ; ohne Kanal 6 bis 10; Testgebiet: Thon

Kanalauswahl: alle - alle DAEDALUS Kanäle; ikonos - IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

A.5 Testgebiet: Gesamtszene

	Klasse:	1	2	3	4	5	6	7	8	9	10	11	κ
		12	13	14	15	16	17	18	19	20	21	22	
ML (alle)	PAUA:	0.698	0.332	0.411	0.758	0.783	0.754	0.821	0.490	0.429	0.495	0.530	
		0.560	0.417	0.770	0.596	0.517	0.856	0.910	0.616	0.811	0.518	0.675	0.770
ML (ikonos)	PAUA:	0.566	0.392	0.330	0.096	0.781	0.671	0.347	0.211	0.218	0.207	0.603	
		0.420	0.289	0.675	0.455	0.497	0.775	0.870	0.410	0.578	0.089	0.77	0.674
FKNN(alle)	PAUA:	0.511	0.307	0.217	0.285	0.648	0.437	0.458	0.158	0.244	0.207	0.543	
		0.222	0.205	0.438	0.460	0.518	0.715	0.824	0.310	0.431	0.134	0.380	0.636
	FPAUA:	0.847	0.483	0.436	0.707	0.754	0.453	0.480	0.400	0.377	0.555	0.496	
		0.482	0.554	0.779	0.555	0.715	0.715	0.926	0.701	0.855	0.770	0.685	
FKNN(ikonos)	PAUA:	0.487	0.280	0.169	0.232	0.632	0.318	0.198	0.147	0.165	0.075	0.378	
		0.110	0.122	0.363	0.417	0.506	0.674	0.749	0.313	0.386	0.068	0.601	0.552
	FPAUA:	0.755	0.464	0.350	0.467	0.702	0.452	0.232	0.425	0.329	0.486	0.412	
		0.372	0.424	0.700	0.521	0.651	0.710	0.834	0.628	0.798	0.848	0.660	
FLK(alle)	PAUA:	0.296	0.140	0.020	0.091	0.561	0.095	0.371	0.016	0.051	0.056	0.171	
		0.101	0.032	0.144	0.251	0.158	0.163	0.457	0.116	0.079	0.036	0.077	0.342
	FPAUA:	0.479	0.127	0.089	0.122	0.605	0.118	0.144	0.092	0.127	0.153	0.113	
		0.179	0.147	0.191	0.151	0.104	0.160	0.689	0.166	0.290	0.209	0.173	
FLK(ikonos)	PAUA:	0.229	0.071	0.024	0.029	0.569	0.073	0.012	0.010	0.052	0.040	0.113	
		0.061	0.024	0.087	0.151	0.047	0.154	0.349	0.032	0.066	0.016	0.041	0.246
	FPAUA:	0.487	0.126	0.094	0.129	0.660	0.124	0.063	0.118	0.126	0.142	0.111	
		0.189	0.167	0.184	0.152	0.098	0.195	0.540	0.176	0.371	0.151	0.183	
FNN(alle)	PAUA:	0.626	0.558	0.486	0.575	0.751	0.550	0.619	0.218	0.418	0.341	0.634	
		0.328	0.322	0.639	0.681	0.619	0.789	0.831	0.618	0.669	0.312	0.517	0.757
	FPAUA:	0.852	0.679	0.607	0.740	0.860	0.587	0.648	0.574	0.610	0.629	0.639	
		0.573	0.706	0.850	0.734	0.788	0.839	0.967	0.849	0.930	0.768	0.845	
FNN(ikonos)	PAUA:	0.503	0.339	0.257	0.316	0.726	0.338	0.300	0.140	0.265	0.172	0.497	
		0.168	0.169	0.380	0.513	0.522	0.702	0.699	0.426	0.473	0.139	0.360	0.620
	FPAUA:	0.859	0.528	0.413	0.587	0.806	0.373	0.327	0.494	0.408	0.490	0.494	
		0.465	0.447	0.683	0.620	0.710	0.732	0.829	0.786	0.864	0.734	0.725	

Tabelle A.11: Kappa-Wert, PAUA und FPAUA Gitemaße Testgebiet: Gesamtszene

Kanalauswahl: alle - alle Kanäle; ikonos- IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

ohne	Klasse:	1	2	3	4	5	6	7	8	9	10	11	
		12	13	14	15	16	17	18	19	20	21	22	κ
ch 1													
ML	PAUA:	0.725	0.440	0.393	0.709	0.755	0.741	0.804	0.520	0.502	0.514	0.713	
		0.439	0.365	0.823	0.606	0.552	0.801	0.880	0.395	0.771	0.546	0.712	0.792
FNN	PAUA:	0.612	0.525	0.488	0.548	0.754	0.546	0.613	0.192	0.443	0.348	0.627	
		0.335	0.385	0.610	0.654	0.616	0.786	0.838	0.615	0.649	0.299	0.588	0.753
	FPAUA:	0.844	0.688	0.608	0.736	0.861	0.624	0.646	0.579	0.565	0.617	0.625	
		0.543	0.642	0.867	0.710	0.817	0.833	0.964	0.866	0.935	0.778	0.829	
ch 2													
ML	PAUA:	0.681	0.410	0.385	0.643	0.749	0.700	0.792	0.517	0.476	0.464	0.681	
		0.418	0.344	0.825	0.622	0.559	0.790	0.861	0.369	0.770	0.557	0.673	0.777
FNN	PAUA:	0.540	0.500	0.428	0.525	0.751	0.542	0.602	0.180	0.405	0.374	0.620	
		0.296	0.320	0.560	0.663	0.614	0.779	0.828	0.627	0.671	0.236	0.588	0.738
	FPAUA:	0.870	0.656	0.508	0.770	0.843	0.588	0.624	0.560	0.548	0.597	0.625	
		0.578	0.621	0.875	0.736	0.820	0.810	0.966	0.842	0.923	0.788	0.833	
ch 3													
ML	PAUA:	0.725	0.423	0.387	0.529	0.715	0.696	0.802	0.488	0.469	0.508	0.688	
		0.428	0.324	0.819	0.606	0.571	0.791	0.857	0.379	0.750	0.546	0.693	0.777
FNN	PAUA:	0.608	0.540	0.469	0.519	0.750	0.559	0.621	0.228	0.412	0.358	0.636	
		0.311	0.355	0.673	0.665	0.611	0.783	0.836	0.572	0.737	0.245	0.549	0.755
	FPAUA:	0.877	0.602	0.613	0.739	0.866	0.615	0.651	0.564	0.592	0.649	0.639	
		0.520	0.660	0.827	0.717	0.830	0.834	0.965	0.844	0.911	0.795	0.814	

Tabelle A.12: Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10;

Testgebiet: Gesamtszene; ohne Kanal 1 bis 3

Kanalauswahl: alle - alle Kanäle; ikonos- IKONOS Kanäle

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK

- Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

ohne	Klasse:	1	2	3	4	5	6	7	8	9	10	11	
		12	13	14	15	16	17	18	19	20	21	22	κ
ch 4													
ML	PAUA:	0.724	0.410	0.395	0.619	0.764	0.724	0.803	0.524	0.499	0.476	0.708	
		0.449	0.348	0.821	0.624	0.568	0.807	0.876	0.410	0.759	0.571	0.695	0.789
FNN	PAUA:	0.555	0.542	0.489	0.534	0.756	0.545	0.619	0.230	0.405	0.365	0.637	
		0.280	0.315	0.647	0.665	0.622	0.788	0.833	0.636	0.703	0.329	0.434	0.751
	FPAUA:	0.876	0.619	0.608	0.741	0.850	0.560	0.641	0.548	0.575	0.619	0.638	
		0.568	0.686	0.833	0.750	0.824	0.813	0.963	0.851	0.931	0.757	0.829	
ch 5													
ML	PAUA:	0.719	0.421	0.369	0.710	0.740	0.696	0.811	0.515	0.501	0.478	0.713	
		0.453	0.289	0.812	0.607	0.570	0.813	0.868	0.415	0.744	0.550	0.635	0.787
FNN	PAUA:	0.601	0.557	0.478	0.519	0.757	0.553	0.622	0.193	0.353	0.373	0.611	
		0.336	0.357	0.667	0.661	0.615	0.792	0.830	0.595	0.666	0.253	0.623	0.748
	FPAUA:	0.875	0.597	0.636	0.738	0.849	0.598	0.641	0.587	0.609	0.599	0.587	
		0.526	0.652	0.826	0.705	0.800	0.833	0.967	0.877	0.937	0.765	0.829	
ch 6													
ML	PAUA:	0.717	0.428	0.386	0.691	0.754	0.715	0.812	0.523	0.495	0.489	0.699	
		0.427	0.334	0.832	0.599	0.517	0.760	0.873	0.364	0.774	0.437	0.702	0.780
FNN	PAUA:	0.586	0.524	0.490	0.564	0.758	0.508	0.623	0.235	0.429	0.358	0.639	
		0.304	0.314	0.628	0.653	0.615	0.784	0.830	0.600	0.701	0.261	0.518	0.752
	FPAUA:	0.866	0.661	0.597	0.724	0.861	0.571	0.659	0.545	0.605	0.629	0.654	
		0.572	0.693	0.847	0.672	0.804	0.842	0.969	0.849	0.912	0.755	0.834	

Tabelle A.13: Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10;

Testgebiet: Gesamtszene; ohne Kanal 4 bis 6

Klassifikationsverfahren: ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK

- Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz

ohne	Klasse:	1	2	3	4	5	6	7	8	9	10	11	κ
		12	13	14	15	16	17	18	19	20	21	22	
ch 7													
ML	PAUA:	0.721	0.433	0.378	0.691	0.755	0.717	0.810	0.511	0.512	0.502	0.698	
		0.410	0.335	0.820	0.574	0.497	0.758	0.880	0.395	0.787	0.576	0.696	0.780
FNN	PAUA:	0.610	0.553	0.445	0.453	0.747	0.547	0.606	0.223	0.404	0.346	0.639	
		0.308	0.326	0.588	0.657	0.608	0.787	0.821	0.647	0.707	0.376	0.531	0.750
	FPAUA:	0.857	0.626	0.562	0.766	0.861	0.586	0.624	0.561	0.591	0.633	0.658	
		0.582	0.661	0.860	0.731	0.821	0.813	0.971	0.832	0.934	0.715	0.843	
ch 8													
ML	PAUA:	0.730	0.424	0.385	0.706	0.772	0.746	0.815	0.474	0.506	0.508	0.702	
		0.407	0.360	0.819	0.570	0.521	0.746	0.883	0.384	0.789	0.553	0.708	0.782
FNN	PAUA:	0.588	0.518	0.455	0.512	0.757	0.542	0.623	0.215	0.432	0.370	0.636	
		0.277	0.357	0.607	0.650	0.617	0.788	0.833	0.646	0.654	0.262	0.574	0.751
	FPAUA:	0.858	0.704	0.572	0.738	0.852	0.572	0.661	0.557	0.532	0.626	0.657	
		0.586	0.616	0.823	0.748	0.729	0.829	0.958	0.783	0.934	0.792	0.809	
ch 9													
ML	PAUA:	0.733	0.350	0.324	0.612	0.744	0.744	0.777	0.457	0.471	0.488	0.632	
		0.433	0.354	0.798	0.583	0.513	0.757	0.885	0.330	0.728	0.596	0.749	0.761
FNN	PAUA:	0.595	0.522	0.428	0.521	0.741	0.499	0.610	0.185	0.416	0.333	0.614	
		0.307	0.332	0.630	0.627	0.591	0.786	0.823	0.633	0.659	0.320	0.539	0.740
	FPAUA:	0.864	0.633	0.611	0.733	0.835	0.559	0.635	0.591	0.540	0.610	0.592	
		0.546	0.681	0.834	0.721	0.794	0.814	0.965	0.801	0.930	0.760	0.834	
ch 8													
ML	PAUA:	0.699	0.447	0.318	0.688	0.712	0.731	0.776	0.442	0.465	0.507	0.713	
		0.460	0.371	0.777	0.584	0.482	0.739	0.890	0.355	0.684	0.402	0.748	0.773
FNN	PAUA:	0.570	0.490	0.409	0.537	0.751	0.501	0.596	0.219	0.378	0.359	0.612	
		0.260	0.336	0.569	0.640	0.610	0.781	0.825	0.574	0.673	0.262	0.485	0.733
	FPAUA:	0.854	0.592	0.546	0.703	0.859	0.557	0.602	0.569	0.584	0.601	0.612	
		0.548	0.569	0.845	0.709	0.825	0.808	0.964	0.881	0.924	0.741	0.810	

Tabelle A.14: Kappa-Wert, PAUA und FPAUA Gütemaße für Kanalauswahl 9 aus 10;

Testgebiet: Gesamtszene; ohne Kanal 7 bis 10

alle - alle Kanäle; ikonos - IKONOS Kanäle

ML - Maximum Likelihood Klassifikation; FKNN - Fuzzy *k-nearest-neighbor* Klassifikation; FLK - Fusion mittels gewichteter Linearkombination; FNN - Fusion mittels neuronalem Netz