

Systematischer Vergleich von Verfahren zur
überwachten Klassifikation von multispektralen
Luftbildern mit Bodenauflösungen im Meterbereich

von

Daniel Kulbach

Juli 1997

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

Gutachter: Prof. J. Bienlein und Prof. H. Spitzer

Kurzfassung

In dieser Arbeit werden zwei bekannte überwachte spektrale Klassifikationsverfahren miteinander verglichen, und zwar das „Minimum Distance“- und das „Maximum Likelihood“-Verfahren. Der Vergleich erfolgt auf multispektralen Luftbildern. Die Luftbilder wurden mit einem Multispektralscanner vom Typ Daedalus AADS 1268 mit insgesamt 10 Spektralkanälen aufgenommen. Die Bilddaten wurden über der Stadt Nürnberg aufgenommen und besaßen eine Bodenauflösung von teilweise besser als einem Meter.

Der Vergleich beginnt mit einer Suche nach geeigneten Klassen. Anschließend werden für die verschiedenen Klassen Pixel (Kontrollpixel) ausgewählt, deren Klassenzugehörigkeit genau bekannt ist. Die Kontrollpixel werden mit beiden Verfahren klassifiziert und danach die erreichten Klassifikationsgenauigkeiten mit Hilfe der „kappa coefficient“ miteinander verglichen. Da die Klassifikationsergebnisse eine starke Abhängigkeit von der Wahl der Trainingsgebiete zeigten, wurde auch untersucht, welchen Einfluß die Wahl der Trainingsgebiete auf die Klassifikationsergebnisse hat. Da randomisierte Trainingsätze genutzt wurden, konnten Fehlergrenzen für die Klassifikationsergebnisse abgeschätzt werden. Zusätzlich wurden noch Methoden zur Effizienzsteigerung untersucht (z.B. Reduzierung der Anzahl der Spektralkanäle und der Trainingsklassen). Abschließend wurde untersucht, in wieweit der Einsatz von überwachten Klassifikationsverfahren bei der Änderungsdetektion zu brauchbaren Ergebnissen führt.

Der Vergleich der beiden Verfahren zeigte, daß eine sorgfältige Wahl der Trainingsgebiete viel wichtiger ist als die Entscheidung, welches der beiden Verfahren man verwendet. Außerdem führte die Reduzierung der Anzahl der Spektralkanäle zu einer spürbaren Effizienzsteigerung.

Abstract

In this study two spectral classification methods are compared, 'Minimum Distance' and 'Maximum Likelihood'. The comparison was done on multispectral aerial imagery. The images were recorded by the multispectral scanner Daedalus AADS 1268 which provides images in 10 spectral bands. The image data was taken over the city of Nuremberg, the spatial resolution was mostly better than one meter.

The comparison starts with the finding of appropriate classes. Then pixels (control pixels) with their class exactly known were chosen for each class. The control pixels were classified with both methods. Afterwards the resulting classification accuracies ('kappa coefficient') were compared using the 'kappa coefficient'. The classification results showed a strong dependence on the choice of the training areas. Therefore the effect of the choice of the training areas on the classification results was investigated. Randomized sets of training areas were used for the classifications in order to estimate the reliability and error margins of the classification results. In addition, efficiency increasing methods were studied, e.g. reducing the number of spectral bands and training classes. Finally it was examined whether the use of supervised classification methods yields useful results for change detection.

The comparison of both methods shows that the deliberate choice of the training areas is of much more importance than the choice of the classification method. Reducing the number of spectral bands to 6 and 3 respectively leads to a significant increase in classification efficiency.

Inhaltsverzeichnis

1 Einleitung	6
2 Theoretische Grundlagen	8
2.1 Fernerkundung.....	8
2.1.1 Radiometrische Größen.....	8
2.1.2 Definition und Aufgaben der Fernerkundung.....	9
2.1.3 Ausbreitung elektromagnetischer Strahlung in der Atmosphäre.....	9
2.1.4 Reflexion elektromagnetischer Strahlung an Oberflächen.....	11
2.2 Klassifikation von Multispektralbildern.....	13
2.2.1 Klassifikation als Instrument zur Abstraktion.....	13
2.2.2 Computergestützte Klassifikationsverfahren.....	13
2.2.3 Probleme und Grenzen.....	17
2.3 Bestimmung der Klassifikationsgenauigkeit.....	18
2.3.1 Statistische Grundlagen.....	18
2.3.2 Die Konfusionsmatrix.....	19
2.3.3 Der Kappa-Wert.....	20
2.4 Entzerrung von Luftbildern.....	22
2.4.1 Ursachen von Bildverzerrungen.....	22
2.4.2 Methoden der Bildentzerrung.....	23
2.4.3 Probleme und Grenzen.....	24
3 Datenmaterial und Datennahme	25
3.1 Der Daedalus-Scanner.....	25
3.2 Die Luftphotos.....	29
4 Überwachte Klassifikation von Multispektralbildern	30
4.1 Der Weg vom Multispektralbild zur Klassifikationskarte.....	30
4.2 Beschreibung des verwendeten Datenmaterials.....	31
4.3 Festlegung des Klassifikationszieles.....	33
4.4 Beschreibung des Stichprobenmaterials.....	36
4.5 Prüfung der Erreichbarkeit des Klassifikationszieles.....	38
4.5.1 Durchführung der Untersuchung.....	38
4.5.2 Auswertung und Interpretation der Ergebnisse.....	45
4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit.....	47
4.6.1 Durchführung der Untersuchung.....	47
4.6.2 Auswertung und Interpretation der Ergebnisse.....	59

4.7 Untersuchung von Methoden zur Erhöhung der Klassifikationsgenauigkeit	62
4.7.1 Durchführung der Untersuchung.....	62
4.7.2 Auswertung und Interpretation der Ergebnisse.....	66
4.8 Untersuchung von Methoden zur Reduzierung des Rechenaufwandes.....	71
4.8.1 Durchführung der Untersuchung.....	72
4.8.2 Auswertung und Interpretation der Ergebnisse.....	83
4.8.3 Vergleich der untersuchten Methoden.....	84
4.9 Demonstration der Klassifikationsverfahren an einem Bildausschnitt.....	85
4.9.1 Durchführung.....	86
4.9.2 Diskussion der Ergebnisse.....	86
5 Änderungsdetektion mit Hilfe der überwachten Klassifikation.....	91
5.1 Entzerrung des Bildmaterials.....	91
5.2 Auswahl der Trainingsklassen und Durchführung der Klassifikation.....	94
5.3 Auswertung und Diskussion der Ergebnisse	96
6 Zusammenfassung und Ausblick	102
7 Literaturverzeichnis	106
8 Anhang.....	109

Abbildungsverzeichnis

Abb. 1: Darstellung zur Veranschaulichung des Raumwinkels	8
Abb. 2: Darstellung zur Veranschaulichung des Strahlungsflusses	8
Abb. 3: Darstellung zur Veranschaulichung der Bestrahlungsstärke E , spezifischen Ausstrahlung M , Strahlstärke I und Strahldichte L	9
Abb. 4: Darstellung der Veränderung des Spektrums der Sonne unter dem Einfluß der Atmosphäre	10
Abb. 5: Darstellung der verschiedenen Wege, auf denen die elektromagnetische Strahlung ein Fernerkundungsflugzeug erreichen kann	11
Abb. 6: Darstellung zur Veranschaulichung von diffuser und gerichteter Reflexion	12
Abb. 7: Darstellung zur Definition und Messung der Reflexionsfunktion (BRDF).....	12
Abb. 8: Darstellung zur Veranschaulichung des Merkmalsraums.....	14
Abb. 9: Darstellung zur Veranschaulichung des Mittelpunktsvektors \vec{m}	15
Abb. 10: Darstellung zur Veranschaulichung der Zuweisungsvorschrift für das „Maximum Likelihood“- Verfahren.....	16
Abb. 11: Darstellung zur Veranschaulichung der Auswirkungen von perspektivischen Verzerrungen.....	22
Abb. 12: Darstellungen zur Veranschaulichung der Ursachen, die zur Panorama-Verzerrung führen.....	23
Abb. 13: Darstellung zur Veranschaulichung der Datenstruktur und der Aufnahmegeometrie des Daedalus- Scanners	26
Abb. 14: Darstellung des schematischen Aufbaus des Daedalus-Scanners.....	27
Abb. 15: Darstellung des schematischen Aufbaus einer Reihenmeßkammer.....	29
Abb. 16: Diagramm der spektralen Empfindlichkeit des Farbinfrarotfilms KODAK 2443.....	29
Abb. 17: Bildausschnitt aus dem Flugstreifen T4	34
Abb. 18: Darstellung der gemittelten Spektren, die aus den Pixeln der Stichproben berechnet wurden, die als Trainingsklassen ausgewählt wurden.....	39
Abb. 19: Darstellung zur Veranschaulichung der Ergebnisse in Tabelle 23.....	40
Abb. 20: Übersicht 1 über die Ergebnisse, die mit dem „Minimum Distance“- und dem „Maximum Likelihood“- Verfahren (bei Verwendung von 10 Spektralkanälen) erreicht wurden	57
Abb. 21: Übersicht 2 über die Ergebnisse, die mit dem „Minimum Distance“- und dem „Maximum Likelihood“- Verfahren (bei Verwendung von 10 Spektralkanälen) erreicht wurden	58
Abb. 22: Darstellung aller Kontrollpixel der Klasse „Flachdach“	61
Abb. 23: Darstellung zur Veranschaulichung des unüberwachten Klassifikationsprogramms.....	64
Abb. 24: Demonstration des unüberwachten Klassifikationsprogramms an einem realen Beispiel.....	65
Abb. 25: Übersicht über die Ergebnisse, die bei den Klassifikationen mit „Methode A“ erreicht wurden.....	69
Abb. 26: Übersicht über die Ergebnisse, die bei den Klassifikationen mit „Methode B“ erreicht wurden.....	70
Abb. 27: Übersicht 1 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren, bei Verwendung von „Methode 1“ erreicht wurden	75
Abb. 28: Übersicht 2 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren, bei Verwendung von „Methode 1“ erreicht wurden (Methode 1).....	76
Abb. 29: Übersicht 1 über die Ergebnisse, die mit dem „Maximum Likelihood“-Verfahren, bei Verwendung von „Methode 1“ erreicht wurden	77
Abb. 30: Übersicht 2 über die Ergebnisse, die mit dem „Maximum Likelihood“-Verfahren, bei Verwendung von „Methode 1“ erreicht wurden	78
Abb. 31: Übersicht 1 über den Vergleich zwischen den Ergebnissen aus Kap. 4.6 und den Ergebnissen, die mit Methode 2 („Minimum Distance“-Verfahren) erreicht wurden	79
Abb. 32: Übersicht 2 über den Vergleich zwischen den Ergebnissen aus Kap. 4.6 und den Ergebnissen, die mit Methode 2 („Minimum Distance“-Verfahren) erreicht wurden	80
Abb. 33: Übersicht 1 über den Vergleich zwischen den Ergebnissen aus Kap. 4.6 und den Ergebnissen, die mit Methode 2 („Maximum Likelihood“-Verfahren) erreicht wurden	81
Abb. 34: Übersicht 2 über den Vergleich zwischen den Ergebnissen aus Kap. 4.6 und den Ergebnissen, die mit Methode 2 („Maximum Likelihood“-Verfahren) erreicht wurden	82
Abb. 35: Diagramm der Kappa-Werte, die mit den verschiedenen Methoden in diesem Kapitel erreicht wurden. .	85
Abb. 36: Kontrastverstärkte Darstellung der Szene aus dem Flugstreifen T3	87
Abb. 37: Darstellung der Klassifikationsergebnisse, die bei der Klassifikation des gewählten Bildausschnittes mit dem „Minimum Distance“-Verfahren erreicht wurden.....	88
Abb. 38: Darstellung der Klassifikationsergebnisse, die bei der Klassifikation des gewählten Bildausschnittes mit dem „Maximum Likelihood“-Verfahren erreicht wurden	89

Verzeichnisse

Abb. 39: Bildausschnitte aus den Jahren 1991 und 1995 mit jeweils 36 markierten Paßpunkten.	91
Abb. 40: Bildausschnitt aus dem invers transformierten Quellbild	93
Abb. 41: Bildausschnitt aus dem Zielbild.....	93
Abb. 42: Bildausschnitt mit 26 Paßpunkten, die zur Kontrolle der Entzerrung gesetzt wurden.	94
Abb. 43: Bildausschnitt aus dem Jahr 1995 (noch nicht Panorama-entzerrt)	95
Abb. 44: Farbige Klassifikationskarten mit den Klassen: Asphalt (schwarz), Beton (rot), Erde (gelb), Vegetation (grün).....	97
Abb. 45: Änderungskarte, die sich aus der Verknüpfung der beiden Klassifikationskarten ergaben, die mit dem „Minimum Distance“-Verfahren erzeugt wurden	99
Abb. 46: Änderungskarte, die sich aus der Verknüpfung der beiden Klassifikationskarten ergaben, die mit dem „Maximum Likelihood“-Verfahren erzeugt wurden.	99
Abb. 47: Änderungskarte, die sich aus der Median-Filterung und der logischen Verknüpfung aller vier Klassifikationskarten ergab	100
Abb. 48: Bildausschnitt aus dem Zielbild (1995) mit 15 Polygonen, die jeweils eine Änderung markieren, die bei einer manuellen Auswertung gefunden wurden.	100
Abb. A - 1: Flugstreifen T1 (links), T2 (mitte) und T3 (rechts) bis Scanzeile 4000	112
Abb. A - 2: Flugstreifen T1 (links), T2 (mitte) und T3 (rechts) ab Scanzeile 4000.	113
Abb. A - 3: Flugstreifen T4 (links), T5 (mitte) und T6 (rechts) bis Scanzeile 4000	114
Abb. A - 4: Flugstreifen T4 (links), T5 (mitte) und T6 (rechts) ab Scanzeile 4000	115
Abb. A - 5: Flugstreifen T7 (links), T8 (mitte) und T10 (rechts) bis Scanzeile 4000	116
Abb. A - 6: Flugstreifen T7 (links), T8 (mitte) und T10 (rechts) ab Scanzeile 4000	117
Abb. A - 7: Flugstreifen T9	118
Abb. A - 8 bis Abb. A-27: Darstellung ausgewählter Stichproben mit den jeweiligen gemittelten Spektren	120

Tabellenverzeichnis

Tabelle 1: Beispiel einer Konfusionsmatrix mit den Klassen A, B und C.....	20
Tabelle 2: Einfache Konfusionsmatrizen mit ihren Kappa-Werten und Gesamtgenauigkeiten.....	21
Tabelle 3: Tabelle zur Bewertung von Kappa-Werten	22
Tabelle 4: Die Spektralbereiche der Detektoren des Daedalus-Scanners.....	25
Tabelle 5: Übersicht über die im folgenden verwendeten Klassen.....	35
Tabelle 6: Übersicht über die Anzahl der Pixel, die für die Klassen ausgewählt wurden	36
Tabelle 7: Ergebnisse der Klassifikation der Klasse „Flachdach“	41
Tabelle 8: Ergebnisse der Klassifikation der Klasse „Spitzdach(bel)“	41
Tabelle 9: Ergebnisse der Klassifikation der Klasse „Spitzdach(sch)“	41
Tabelle 10: Ergebnisse der Klassifikation der Klasse „Fassade“	41
Tabelle 11: Ergebnisse der Klassifikation der Klasse „Strasse(bel)“	42
Tabelle 12: Ergebnisse der Klassifikation der Klasse „Strasse(sch)“	42
Tabelle 13: Ergebnisse der Klassifikation der Klasse „Bürgersteig“	42
Tabelle 14: Ergebnisse der Klassifikation der Klasse „Parkplatz“	42
Tabelle 15: Ergebnisse der Klassifikation der Klasse „Fahrzeuge“	43
Tabelle 16: Ergebnisse der Klassifikation der Klasse „Bäume“	43
Tabelle 17: Ergebnisse der Klassifikation der Klasse „Wiese(bel)“	43
Tabelle 18: Ergebnisse der Klassifikation der Klasse „Wiese(sch)“	43
Tabelle 19: Ergebnisse der Klassifikation der Klasse „Felder(bew)“	44
Tabelle 20: Ergebnisse der Klassifikation der Klasse „Erdreich“	44
Tabelle 21: Ergebnisse der Klassifikation der Klasse „Eisenbahn“	44
Tabelle 22: Ergebnisse der Klassifikation der Klasse „Gewässer“.....	44
Tabelle 23: Ergebnisse der Klassifikation Klasse „Markierung(Flughafen)“	45
Tabelle 24: Ergebnisse der Klassifikation der Klasse „Vorfeld(Flughafen)“	45
Tabelle 25: Übersicht über die Neuordnung der Informationsklassen und der Anzahl ihrer Kontrollpixel.....	48
Tabelle 26: Übersicht über die Zusammensetzung der Trainingsgruppen.....	48
Tabelle 27: Übersicht über die sechs Permutationssätze	50
Tabelle 28: Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 1).....	51
Tabelle 29: Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 1)	51
Tabelle 30: Differenzmatrix (Permutationssatz 1)	51

Tabelle 31: <i>Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 2)</i>	52
Tabelle 32: <i>Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 2)</i>	52
Tabelle 33: <i>Differenzmatrix (Permutationssatz 2)</i>	52
Tabelle 34: <i>Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 3)</i>	53
Tabelle 35: <i>Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 3)</i>	53
Tabelle 36: <i>Differenzmatrix (Permutationssatz 3)</i>	53
Tabelle 37: <i>Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 4)</i>	54
Tabelle 38: <i>Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 4)</i>	54
Tabelle 39: <i>Differenzmatrix (Permutationssatz 4)</i>	54
Tabelle 40: <i>Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 5)</i>	55
Tabelle 41: <i>Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 5)</i>	55
Tabelle 42: <i>Differenzmatrix (Permutationssatz 5)</i>	55
Tabelle 43: <i>Gemittelte Konfusionsmatrix („Minimum Distance“-Verfahren, Permutationssatz 6)</i>	56
Tabelle 44: <i>Gemittelte Konfusionsmatrix („Maximum Likelihood“-Verfahren, Permutationssatz 6)</i>	56
Tabelle 45: <i>Differenzmatrix (Permutationssatz 6)</i>	56
Tabelle 46: <i>Gemittelte Konfusionsmatrix („Methode A“, 10 Klassen)</i>	67
Tabelle 47: <i>Gemittelte Konfusionsmatrix („Methode A“, 12 Klassen)</i>	67
Tabelle 48: <i>Gemittelte Konfusionsmatrix („Methode A“, 16 Klassen)</i>	67
Tabelle 49: <i>Gemittelte Konfusionsmatrix („Methode A“, 20 Klassen)</i>	68
Tabelle 50: <i>Gemittelte Konfusionsmatrix („Methode A“, 29 Klassen)</i>	68
Tabelle 51: <i>Gemittelte Konfusionsmatrix („Methode A“, 38 Klassen)</i>	68
Tabelle 52: <i>Übersicht über die zum Training in diesem Abschnitt gewählten Stichproben aus dem Anhang</i>	86
Tabelle 53: <i>Vergleich von Klassifikationsergebnissen aus dieser Arbeit mit den Ergebnissen aus anderen Arbeiten</i>	104
Tabelle 54: <i>Auflistung der Katalognummern, unter denen die in Kap. 4.5 zum Training verwendeten Stichproben im Stichprobenkatalog zu finden sind (beachte Seite 108)</i>	118
Tabelle 55: <i>Daten über die Stichproben im Anhang</i>	119

1 Einleitung

Die Erdbeobachtung mit Hilfe von Luft- und Satellitenbildern gewinnt in Forschung und Anwendungspraxis stetig an Bedeutung. Dabei werden verstärkt Sensoren eingesetzt, die in verschiedenen Spektralbereichen abbilden (sichtbares Licht, verschiedene Infrarotkanäle, Radar). Im Rahmen der „Arbeitsgruppe für Naturwissenschaft und Internationale Sicherheit in der Universität Hamburg (CENSIS)“ beschäftigt sich ein Projekt des II. Instituts für Experimentalphysik unter der Leitung von Prof. Dr. Hartwig Spitzer und Prof. Dr. Johann Bienlein (DESY) mit den physikalischen Grundlagen der Fernerkundung und der Methodenentwicklung für die rechnergestützte Bildauswertung.

Die Projektgruppe „Physikalische Grundlagen der Fernerkundung“ verfolgt hierbei im wesentlichen zwei Ziele. Das eine Ziel besteht in der Entwicklung von Methoden, um Fernerkundungsdaten auf Einflüsse der äußeren Aufnahmebedingungen (wie z.B. der Tageszeit oder atmosphärischen Parametern) zu korrigieren. Hierfür ist vor allem ein besseres Verständnis der physikalischen Prozesse notwendig, die sich abspielen, wenn die elektromagnetische Strahlung die Atmosphäre durchquert und an den Objekten am Erdboden reflektiert wird. Die zweite Zielrichtung besteht in der Weiterentwicklung von Methoden zur computergestützten Bildauswertung. Der Schwerpunkt liegt hierbei auf Methoden für das Aufspüren von Veränderungen beim Vergleich zweier Bilder (Änderungsdetektion) und auf Methoden, mit denen es möglich ist die Objekte, die auf Luftaufnahmen entdeckt wurden, in Gruppen mit ähnlichen Eigenschaften einzuteilen (Klassifikationsverfahren).

Bei dem Einsatz von Klassifikationsverfahren ist es wichtig zu wissen, mit welcher quantitativen Genauigkeit die Einteilung der Objekte in die verschiedenen Klassen erfolgte. Die Methoden zur Bestimmung der Genauigkeit, mit der die Klassifikation eines einzelnen Luftbildes ausgeführt wurde, wird z.B. in [Congalton 1991] und [Richards 1993] beschrieben. Aufbauend auf dieser Methodik wird in der vorliegenden Arbeit ein systematischer Vergleich zwischen zwei verschiedenen Klassifikationsverfahren durchgeführt. Hierbei handelt es sich um Klassifikationsverfahren, die in der entsprechenden Literatur (siehe z.B. [Richards 1993] oder [Duda & Hart 1993]) häufig erwähnt werden. Diese beiden Verfahren werden im allgemeinen als „Minimum Distance“- und „Maximum Likelihood“-Verfahren bezeichnet.

In früheren Arbeiten wurde ebenfalls ein Vergleich zwischen den beiden erwähnten Verfahren durchgeführt. In [Wilson 1992] wurden die Verfahren auf der Grundlage von simulierten Fernerkundungsdaten verglichen. In [Booth & Oldfield 1989] wurden Satellitendaten (Landsat TM) für den Vergleich verwendet, wobei die Ergebnisse allerdings ohne Angabe der verwendeten Klassen veröffentlicht wurden. Die vorliegende Arbeit unterscheidet sich von den erwähnten Veröffentlichungen in zwei wichtigen Punkten:

1. Es werden Luftbilder mit einer hohen räumlichen Auflösung (im Bereich von einem Meter) verwendet.
2. Es wird systematisch untersucht, welchen Einfluß die Variation der „Eingabeparameter“¹ auf die Klassifikationsergebnisse hat.

¹ Beide Verfahren benötigen vor der Durchführung einer Klassifikation Informationen („Trainingsdaten“) über die typischen Eigenschaften der verwendeten Gruppen (oder *Klassen*).

In Kapitel 2 werden die notwendigen theoretischen Grundlagen über die Fernerkundung vermittelt und die verwendeten Klassifikationsverfahren eingehend beschrieben. In Kapitel 3 wird die Funktionsweise der Geräte, die bei der Aufnahme der Luftbilder verwendet wurden, näher erklärt. In Kapitel 4 wird der eigentliche Vergleich zwischen den beiden Klassifikationsverfahren durchgeführt. Zusätzlich werden in diesem Kapitel noch einige Möglichkeiten untersucht, um die Effizienz der eingesetzten Verfahren zu steigern. In Kapitel 5 wird an einem Beispiel untersucht, in wieweit eine Änderungsdetektion, die sich auf den Einsatz der beiden untersuchten Klassifikationsverfahren stützt, zu brauchbaren Ergebnissen führt. Das Kapitel 6 enthält noch eine abschließende Zusammenfassung und einen Ausblick auf weitergehende Fragestellungen.

Im Rahmen der Diplomarbeit sind verschiedene Aufgaben angefallen, die selbständig durchzuführen waren, u.a.:

- Sichtung des gesamten Bildmaterials und Herausschneiden von geeigneten Objekten (Stichproben).
- Zusammenstellung der Stichproben zu einem umfangreichen Katalog mit den entsprechenden Spektren. (Ein Auszug aus dem Katalog befindet sich im Anhang.)
- Entwicklung von Programmen,² um die Stichproben zu erheben, zu verwalten und zu katalogisieren.
- Erweiterung und Anpassung von Programmen³ zur Klassifikation von Multispektralbildern.
- Entzerrung von Luftbildern und Überprüfung der Entzerrungsgenauigkeit.

² Die in dieser Arbeit verwendeten Programme wurden mit dem Programm-Paket PV-WAVE erstellt. Dieses Paket enthält Programm-Module, die in eigene Programme eingebunden werden können. Die Programmentwicklung erfolgte in einer UNIX-Umgebung (Solaris auf Sun-Workstations).

³ Es standen zu Beginn der Arbeit Klassifikationsprogramme zur Verfügung, die von R. Wiemker entwickelt worden waren.

2 Theoretische Grundlagen

2.1 Fernerkundung

2.1.1 Radiometrische Größen

Die Radiometrie befaßt sich mit der quantitativen Beschreibung von elektromagnetischen Strahlungsflüssen. Einige in der Radiometrie definierte Größen sind im Rahmen dieser Arbeit von Bedeutung.

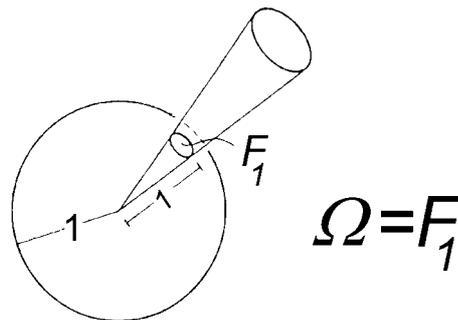


Abb. 1: Darstellung zur Veranschaulichung des Raumwinkels (Quelle: [Kraus & Schneider 1988])

Die elektromagnetische Strahlung kann man sich als eine Strömung aus Energie vorstellen, die (z.B. von einer Punktquelle ausgehend) in alle Richtungen des Raumes ausströmt. Wenn die Strahlung nicht in alle Richtungen ausströmen kann, so beschreibt man dies, am zweckmäßigsten, durch den Begriff des *Raumwinkels* Ω . Der Raumwinkel Ω wird über die Fläche F_1 definiert, die ein Kegel aus der Einheitskugel herauschneidet (siehe Abb. 1). Der Raumwinkel Ω hat die Größe von einem Steradian [sr], wenn er aus der Einheitskugel eine Fläche $F_1 = 1$ herauschneidet.

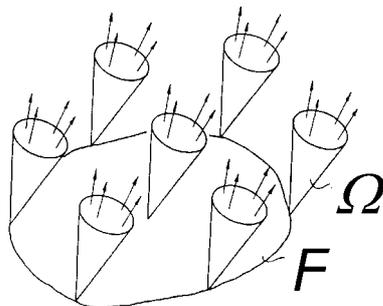


Abb. 2: Darstellung zur Veranschaulichung des Strahlungsflusses (Quelle: [Kraus & Schneider 1988])

Der *Strahlungsfluß* Φ ist eine grundlegende Größe für die Radiometrie. Er ist definiert als die Strahlungsleistung, die durch die Fläche F in den Raumwinkel Ω strömt (siehe Abb. 2). Durch die Einführung differentieller Flächen- und Raumwinkelemente dF und $d\Omega$ können aus dem Strahlungsfluß weitere wichtige Größen abgeleitet werden. Zu diesen Größen gehören die *Bestrahlungsstärke* E [$W \cdot m^{-2}$], die *spezifische Ausstrahlung* M [$W \cdot m^{-2}$], die *Strahlstärke* I [$W \cdot sr^{-1}$] und die *Strahldichte* L [$W \cdot m^{-2} \cdot sr^{-1}$] (siehe Abb. 3). Man beachte, daß bei der Bestrahlungsstärke E der Strahlungsfluß $d\Phi$ aus dem gesamten Halbraum ($\Omega = 2\pi$) auf das Flächenelement dF fällt. Bei der spezifischen Ausstrahlung M hingegen wird der Strahlungsfluß $d\Phi$ in den Halbraum abgestrahlt.

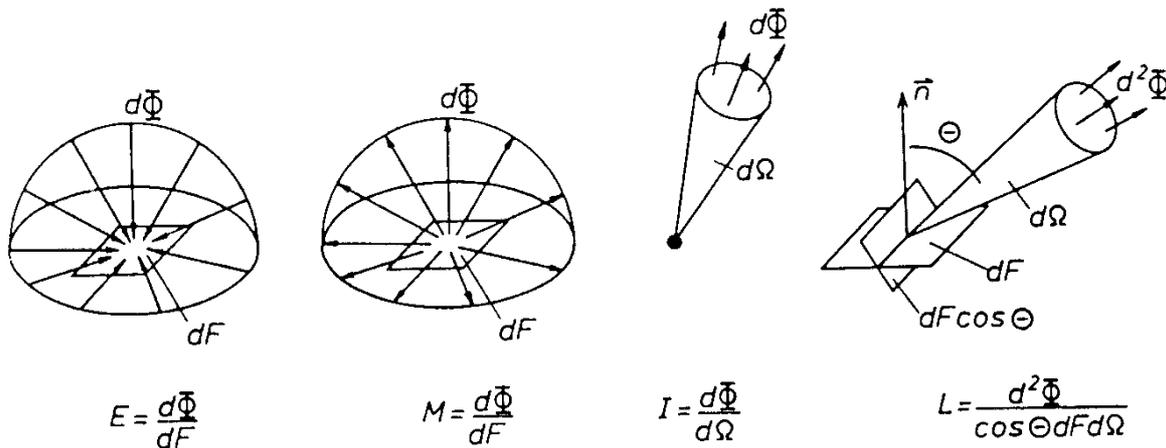


Abb. 3: Darstellung zur Veranschaulichung der Bestrahlungsstärke E , spezifischen Ausstrahlung M , Strahlstärke I und Strahldichte L (Quelle: [Kraus & Schneider 1988])

2.1.2 Definition und Aufgaben der Fernerkundung

Unter dem Begriff „Fernerkundung“ versteht man die Vorgänge, welche die Erfassung von Objekten und ihrer Eigenschaften aus großer Entfernung zum Ziel haben [Kraus & Schneider 1988].

Die Fernerkundung befaßt sich im wesentlichen mit der Erkundung der Erdoberfläche mit Hilfe von Fernerkundungsgeräten (Satelliten und Flugzeugen). Zu den wichtigsten Aufgaben der Fernerkundung gehört die Vermessung der geometrischen Gestalt der Erdoberfläche (Kartografie), die Lokalisierung und Identifizierung von militärischen Objekten und die Überwachung der Umweltbedingungen von ökologisch gefährdeten Regionen auf der Erde.

Ein für die Fernerkundung idealer Informationsträger sollte mit der Erdoberfläche und mit dem Detektor des Fernerkundungsgerätes möglichst gut wechselwirken. Er sollte gleichzeitig von der Luft zwischen der Erdoberfläche und dem Detektor möglichst wenig beeinflusst werden. Der einzige Informationsträger, der diese Eigenschaften in ausreichendem Maße besitzt, ist die elektromagnetische Strahlung. Als Quelle für die elektromagnetischen Strahlung wird meistens das natürliche Sonnenlicht eingesetzt (passive Fernerkundung). In einigen Fällen werden auch Radargeräte, die sich an Bord des Fernerkundungsgerätes befinden, verwendet (aktive Fernerkundung).

2.1.3 Ausbreitung elektromagnetischer Strahlung in der Atmosphäre

Die elektromagnetische Strahlung ist, wie bereits erwähnt wurde, kein idealer Informationsträger, denn sie wechselwirkt auch mit der Atmosphäre. Jede Wechselwirkung mit den Molekülen in der Luft bewirkt aber eine Veränderung der vom Erdboden reflektierten elektromagnetischen Signale. Da man diese Einflüsse weder vermeiden noch vernachlässigen kann, sollte man die Wechselwirkungsmechanismen möglichst gut verstehen, um wenigstens ihre Auswirkungen abschätzen zu können.

Bevor man sich mit diesen Mechanismen eingehender befaßt, sollte man sich zuerst mit der Zusammensetzung der Atmosphäre beschäftigen. Die Atmosphäre ist ein Gasgemisch aus Stickstoff, Sauerstoff, Edelgasen, Wasserdampf, Kohlendioxid, Ozon und Aerosolen. Aerosole sind Teilchen mit Durchmessern von 0.01 bis 100 μm , wie Staub, Dunst oder Nebel. Wasserdampf und Aerosole kommen in zeitlich schwankender Konzentration vor. Die Dichte der Atmosphäre

2 Theoretische Grundlagen

ist nicht konstant, sie läßt sich aber näherungsweise durch eine exponentielle Höhenabhängigkeit beschreiben:

$$n(z) = n(0) \cdot e^{-\frac{z}{h}}, \quad (\text{Gl. 1})$$

wobei z der Höhe über dem Meeresspiegel und $n(0)$ der Teilchendichte auf der Höhe des Meeresspiegels entspricht ($h \approx 8\text{km}$).

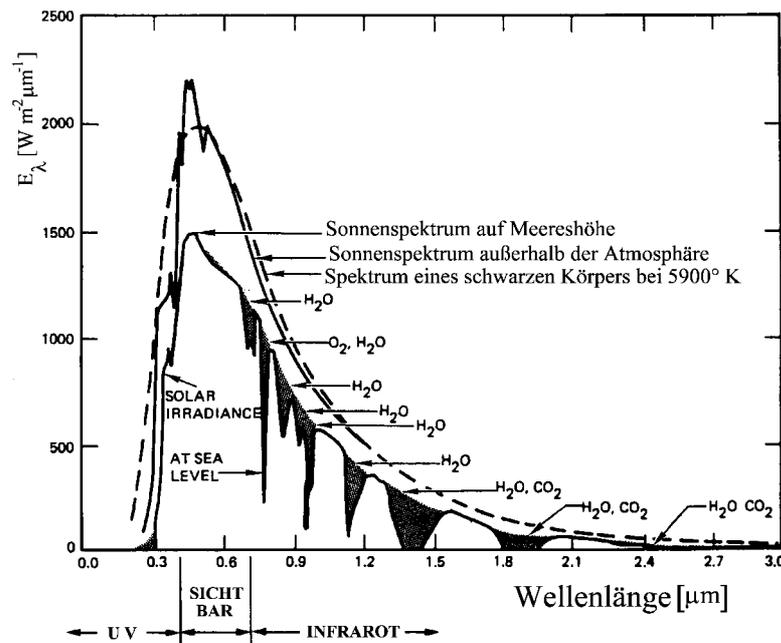


Abb. 4: Darstellung der Veränderung des Spektrums der Sonne unter dem Einfluß der Atmosphäre (Quelle: [Elachi 1987])

Die Wechselwirkungen zwischen elektromagnetischer Strahlung und den Gasmolekülen der Atmosphäre lassen sich in zwei Gruppen unterteilen, und zwar in Absorption und in Streuung. Von Absorption spricht man, wenn die elektromagnetische Strahlung, beim Durchgang durch Materie, in Wärme umgewandelt wird. Bei diesem Prozeß werden die Elektronen der Atome und Moleküle in der Atmosphäre, durch die hindurch tretende Strahlung, in höhere Energieniveaus angehoben. Bei Molekülen können zusätzlich noch Rotations- und Vibrationsübergänge auftreten. Da die Gasmoleküle die elektromagnetische Energie nur im Rahmen ihrer Eigenfrequenzen aufnehmen können, kommt es zur linienhaften Absorption der Strahlung. Diese Absorptionslinien sind aufgrund verschiedener Effekte (z.B. Dopplereffekt) in der Praxis verbreitert, man spricht deshalb von Absorptionsbanden. In Abb. 4 sind einige dieser Absorptionsbanden (O_2 , H_2O , CO_2) als schwarz schattierte Bereiche sichtbar.

Unter dem Begriff Streuung werden alle diejenigen Wechselwirkungen zusammengefaßt, die hauptsächlich zu einer Richtungsänderung der Strahlung führen. Man unterscheidet zwischen zwei Arten von Streuung, und zwar zwischen Rayleigh- und Mie-Streuung.

Die *Rayleigh-Streuung* ist dadurch gekennzeichnet, daß die Wellenlänge der Strahlung viel größer ist als die Größe der Teilchen, an denen sie gestreut wird. Dadurch schwingen alle Ladungen eines Teilchens, die von der Strahlung zu Schwingungen angeregt wurden, in Phase. Die Rayleigh-Streuung ist stark wellenlängenabhängig ($\sigma \propto \lambda^{-4}$, σ : Streuquerschnitt). Da das

blaue Licht die kürzeste Wellenlänge im sichtbaren Spektrum der Sonne besitzt, wird es von der Rayleigh-Streuung am stärksten gestreut. Dieser Effekt ist an der Blaufärbung des Himmels direkt sichtbar [Kraus & Schneider 1988].

Als *Mie-Streuung* bezeichnet man die Streuung an Teilchen, deren Größe ungefähr der Wellenlänge der gestreuten Strahlung entspricht. Das Richtungsverhalten der Mie-Streuung ist stark anisotrop (größte Streuamplitude in Ausbreitungsrichtung). Sie ist ebenfalls wellenlängenabhängig ($\sigma \propto \lambda^{-1}$) [Kraus & Schneider 1988].

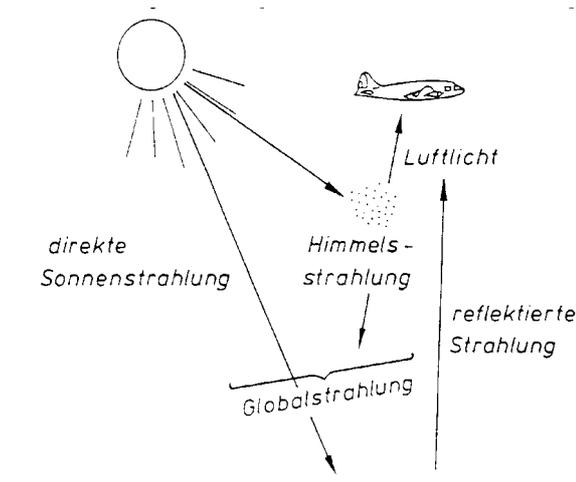


Abb. 5: Darstellung der verschiedenen Wege, auf denen die elektromagnetische Strahlung ein Fernerkundungsflugzeug erreichen kann (Quelle: [Kraus & Schneider 1988])

Aufgrund der beschriebenen Streu- und Absorptionseffekte, kann die von der Sonne ausgesandte Strahlung den Detektor eines Fernerkundungsflugzeuges auf verschiedenen Wegen erreichen. So kann z.B. das von der Sonne kommende Licht in der Atmosphäre derart gestreut werden, daß es den Detektor ohne Wechselwirkung mit dem Erdboden erreicht (*Luftlicht*). Das gestreute Licht (*Himmelsstrahlung*) kann aber auch den Erdboden erreichen und die Beleuchtung eines Objekt durch die direkte Sonnenstrahlung verstärken (*Globalstrahlung*). Der Weg, den die Strahlung auf dem Weg zum Detektor genommen hat, ist also nicht mehr genau rekonstruierbar (siehe Abb. 5).

2.1.4 Reflexion elektromagnetischer Strahlung an Oberflächen

Sobald der elektromagnetische Strahlungsfluß Φ_0 auf die Oberfläche eines Objektes trifft, wird ein Teil des Strahlungsflusses absorbiert Φ_a , transmittiert Φ_t und ein Teil reflektiert Φ_r .

Da diese Anteile stark von den Eigenschaften des betrachteten Objektes abhängen, führt man zweckmäßigerweise die Begriffe Absorptionsgrad α , Reflexionsgrad ρ und Transmissionsgrad τ ein:

$$\alpha, \rho, \tau, = \frac{\Phi_{a,r,t}}{\Phi_0} \quad (\text{Gl. 2})$$

α, ρ und τ hängen aber nicht nur von den Objekteigenschaften ab, sondern auch von der Wellenlänge λ der einfallenden Strahlung. Da die Summe aus Φ_A , Φ_R und Φ_T gleich Φ_0 ist (Energieerhaltung), folgt:

$$\alpha(\lambda) + \rho(\lambda) + \tau(\lambda) = 1 \quad (\text{Gl. 3})$$

2 Theoretische Grundlagen

Für die Fernerkundung ist die reflektierte Strahlung von besonderem Interesse, weil nur sie vom Fernerkundungsgerät aus direkt meßbar ist. Das Reflexionsverhalten eines Objektes wird stark von seiner Oberfläche beeinflusst. So ist die Reflexion an *glatten* Oberflächen gerichtet und an *rauen* Oberflächen⁴ diffus (siehe Abb. 6). In der Praxis treten häufig Mischformen aus beiden Reflexionsarten auf (*gemischte Reflexion*).

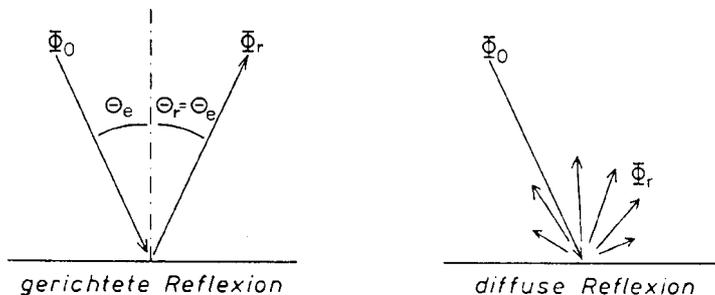


Abb. 6: Darstellung zur Veranschaulichung von diffuser und gerichteter Reflexion (Quelle: [Kraus & Schneider 1988])

Um das Reflexionsverhalten einer Oberfläche erschöpfend zu beschreiben, benötigt man eine Funktion, die als *BRDF* (*bidirectional reflectance distribution function*) bezeichnet wird. Sie ist folgendermaßen definiert:

$$f(\lambda, \theta_e, \phi_e, \theta_r, \phi_r) = \frac{dL_r(\lambda, \theta_e, \phi_e, \theta_r, \phi_r)}{dE_e(\lambda, \theta_e, \phi_e)} \quad (\text{Gl. 4})$$

Hierbei symbolisiert L_r die *Strahldichte der reflektierten Strahlung* und E_e die *Bestrahlungsstärke der einfallenden Strahlung*. Die Bedeutung der übrigen Größen ist aus Abb. 7 ersichtlich.

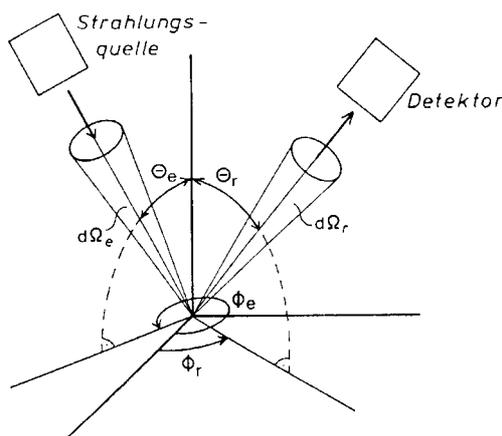


Abb. 7: Darstellung zur Definition und Messung der Reflexionsfunktion (BRDF) (Quelle: [Kraus & Schneider 1988])

⁴ Das „Rayleigh-Kriterium“ ermöglicht es, die Rauigkeit einer Oberfläche quantitativ zu charakterisieren [Kraus & Schneider 1988]: „Eine Oberfläche ist für Strahlung der Wellenlänge λ glatt, die unter dem Winkel θ zwischen Flächennormaler und Strahlrichtung einfällt, wenn $h < \frac{\lambda}{8 \cos \theta}$ wobei h die Standardabweichung der Oberflächenunebenheiten ist.“

2.2 Klassifikation von Multispektralbildern

Den Begriff Klassifikation kann man definieren als einen Prozeß, bei dem Objekte in Gruppen mit gleichen oder zumindest ähnlichen Eigenschaften (Merkmale) eingeteilt werden.

2.2.1 Klassifikation als Instrument zur Abstraktion

Da im Rahmen dieser Arbeit der Begriff Klassifikation eine zentrale Rolle spielt, erscheint es sinnvoll, die Bedeutung der Klassifikation für das menschliche Denkverhalten ein wenig zu erörtern.

Ein Problem, mit dem jeder Mensch täglich zu kämpfen hat, ist die Bewältigung der enormen Informationsflut, die er ständig über seine Sinnesorgane aufnimmt. Der wichtigste Schlüssel zur Lösung dieses Problems besteht darin, die wahrgenommenen Informationen zu filtern und zu abstrahieren. Diese Abstraktion ist aber grundsätzlich nichts anders als eine Form von Klassifikation. Allerdings klassifiziert ein Mensch nicht nur reale Objekte wie beispielsweise Fahrzeuge in Klassen wie z.B. PKW und LKW, sondern er klassifiziert selbst die Merkmale von Objekten nach ihrer momentanen Wichtigkeit. So wird ein Autofahrer im Straßenverkehr in der Regel nicht auf die Farben der übrigen Autos achten. Wenn er sich auf einer Automobilausstellung befindet und die neuesten Automodelle betrachtet, dann wird er wahrscheinlich auch auf die Farbe achten. Ob er es wirklich tut, läßt sich aber nicht mit absoluter Sicherheit sagen, weil jeder Mensch die Regeln, nach denen er klassifiziert, zumindest teilweise selbst bestimmt. Es gibt allerdings einen Grundkonsens über grundlegende Begriffe (oder Klassen), sonst wäre die menschliche Kommunikation, wie wir sie kennen, vermutlich gar nicht möglich.

2.2.2 Computergestützte Klassifikationsverfahren

Bei den Objekten, die im Rahmen dieser Arbeit vom Computer in Klassen eingeteilt werden sollen, handelt es sich um die Bildpunkte von Multispektralbildern. Ein Multispektralbild ist mit einem Farbbild vergleichbar. Man kann ein Farbbild als eine Einheit aus drei Einzelbildern (Farbauszüge: rot, grün und blau) auffassen. Jedes dieser Bilder enthält Informationen über das Reflexionsverhalten der abgebildeten Objekte in jeweils einem anderen Bereich des elektromagnetischen Spektrums. Ein Multispektralbild besteht meistens aus mehr als drei Einzelbildern ($n > 3$). Im Computer werden die Informationen, die in jedem Einzelbild enthalten sind, in einer Matrix (*Bildmatrix*) gespeichert. Jeder Bildpunkt besitzt eine Adresse (Bildkoordinatenpaar), die seine Position in der Bildmatrix eindeutig festlegt. Die Werte der Matrix werden als *Grauwerte* bezeichnet, weil sich jedes der Einzelbilder in Form eines Graustufen-Bildes auf dem Monitor darstellen läßt. Jeder Bildpunkt (Pixel) im Multispektralbild besitzt also eine Menge von n Grauwerten. Die n Grauwerte bilden einen n -dimensionalen Vektor. Die Pixel eines Multispektralbildes lassen sich also als Punkte in einem n -dimensionalen Vektorraum darstellen. Im allgemeinen bezeichnet man diesen Vektorraum als *Merkmalsraum*. Im Zusammenhang mit Multispektralbildern kann man ihn aber auch als Multispektralraum bezeichnen.

Im Merkmalsraum liegen zwei Pixel dicht bei einander, wenn sie ähnliche (spektrale) Merkmale besitzen. Im Ortsraum liegen zwei Pixel dicht bei einander, wenn sie ähnliche Bildkoordinaten besitzen (siehe Abb. 8).

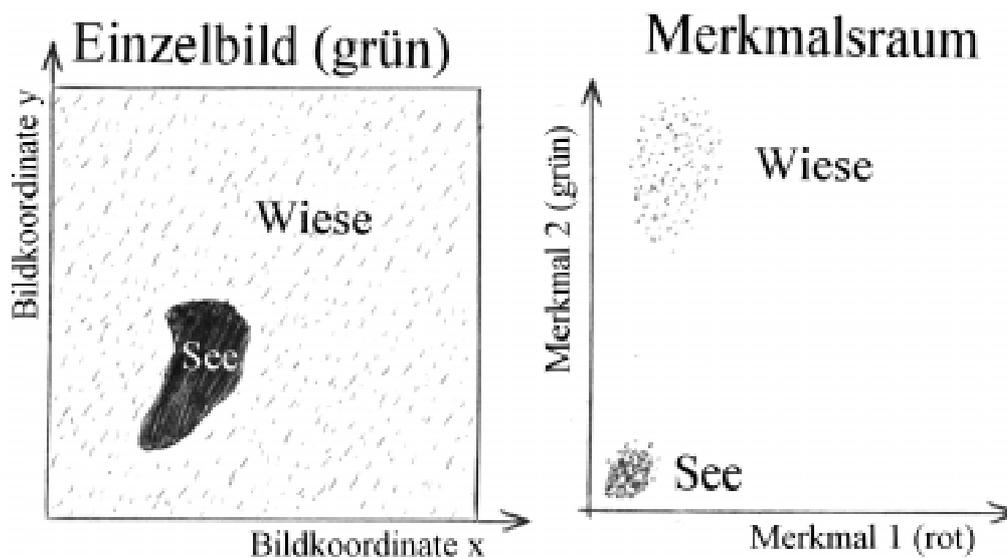


Abb. 8: Darstellung zur Veranschaulichung des Merkmalsraums. (Links: Bild im Ortsraum (grüner Farbkanal, rechts: Bild im Merkmalsraum (roter und grüner Farbkanal)).

Um das Ziel der Klassifikation, nämlich die Einteilung der Bildpunkte nach ihrer Ähnlichkeit in eine Reihe von Klassen, erreichen zu können, muß der Begriff Ähnlichkeit erst einmal definiert werden. In der sog. parametrischen Klassifikation wird zu diesem Zweck im Merkmalsraum eine Metrik (Abstandsmaß) definiert, und ein Bildpunkt wird der Klasse zugeordnet, zu deren Mittelpunkt er den geringsten Abstand besitzt. Die Bestimmung der Lage der Klassenmittelpunkte ist das Hauptproblem der Klassifikation. Es gibt zwei unterschiedliche Vorgehensweisen, um sie zu bestimmen, und zwar die überwachte und die unüberwachte Klassifikation.

Bei der *unüberwachten Klassifikation* werden die Mittelpunkte der Klassen anfangs willkürlich vorgegeben, und dann in einem iterativen Prozeß solange angepaßt, bis alle Pixel einen möglichst geringen Abstand zu den Mittelpunkten der Klasse haben, denen sie zugeordnet wurden. Ein bekanntes unüberwachtes Klassifikationsverfahren ist der sog. „iterative Optimization Clustering“-Algorithmus [Richards 1993]. Er wird in einigen Quellen ([Duda & Hart 1973], [Bezdek 1981]) auch als „k-means“ oder „Migrating Means“-Algorithmus bezeichnet.

Bei der *überwachten Klassifikation* werden die Mittelpunkte der Klassen aus einer Menge von Pixeln (Trainingspixel) bestimmt, die von einem Trainer (Menschen) als besonders typisch für die jeweiligen Klassen ausgewählt wurden (siehe [Richards 1993], [Duda & Hart 1973]).

Es gibt zwei überwachte Klassifikationsverfahren, die besonders verbreitet sind, und zwar das „Minimum Distance“-Verfahren und das „Maximum Likelihood“-Verfahren.

Das „Minimum Distance“-Verfahren

Dieses Verfahren basiert auf der Annahme, daß alle Pixel, die zu einer Klasse gehören, im Merkmalsraum isotrop um den entsprechenden Klassenmittelpunkt herum verteilt sind. Aus diesem Grund verwendet es als Abstandsmaß den euklidischen Abstand:

$$d(\vec{x}, \vec{m}) = \sqrt{(x_1 - m_1)^2 + \dots + (x_n - m_n)^2} \quad (\text{Gl. 5})$$

Dabei ist \vec{x} der *Merkmalsvektor* eines Pixels und \vec{m} der *Mittelpunktvektor* einer Klasse. Der Mittelpunktvektor wird durch kanalweise Mittelung der Grauwerte aus den Pixeln, die der Trainer für diese Klasse ausgewählt hat, berechnet (siehe Abb. 9). Die Berechnung der Wurzel kann für die Klassifikation weggelassen werden, weil hierbei nicht die absoluten Abstände interessieren, sondern nur welcher Klassenmittelpunkt den geringsten Abstand zum gerade betrachteten Pixel besitzt.

Die eigentliche Klassifikation besteht nun darin, für jedes Pixel, das klassifiziert werden soll, die Abstände zu den Mittelpunktvektoren aller verfügbaren Klassen zu berechnen und die Klasse mit dem geringsten Abstand auszuwählen. Dieser Klasse wird dann das jeweilige Pixel zugewiesen.

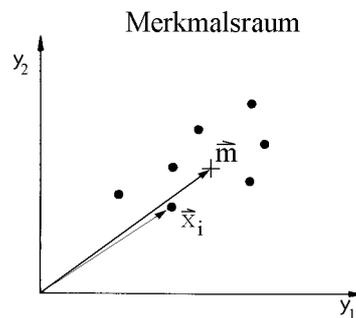


Abb. 9: Darstellung zur Veranschaulichung des Mittelpunktvektors \vec{m} . Zur Berechnung von \vec{m} müssen die Komponenten (hier y_1 und y_2) der Merkmalsvektoren \vec{x}_i der Trainingspixel getrennt von einander gemittelt werden. (Quelle [Richards 1993])

Das „Maximum Likelihood“-Verfahren

Die Annahme, daß die Pixel einer Klasse im Merkmalsraum isotrop verteilt sind, ist nur sehr eingeschränkt gültig. Ursache hierfür sind beispielsweise Beleuchtungseffekte. Sie bewirken eine strahlenförmig vom Ursprung weg gerichtete Streuung der Pixel im Merkmalsraum. Um derartigen Effekten zu begegnen, setzt man im allgemeinen das „Maximum Likelihood“-Verfahren ein.

Dieses Verfahren beruht auf der Annahme, daß die Verteilung der Pixel einer Klasse im Merkmalsraum einer (mehrdimensionalen) Normalverteilung entspricht. Aufbauend auf dieser Annahme wird für jedes Pixel des Bildes die Wahrscheinlichkeit $p(\omega_i | \vec{x})$ dafür berechnet, daß es der Klasse ω_i angehört. Hierbei ist \vec{x} der Ort des entsprechenden Pixels im Merkmalsraum. Ein Pixel am Ort \vec{x} wird nun der Klasse ω_i zugewiesen, wenn es die folgende Zuweisungsbedingung erfüllt:

$$\vec{x} \in \omega_i, \text{ falls } p(\omega_i | \vec{x}) > p(\omega_j | \vec{x}) \forall j \neq i \quad (\text{Gl. 6})$$

Das Pixel am Ort \vec{x} wird also der Klasse mit der größten Wahrscheinlichkeit („Likelihood“) zugewiesen (siehe Abb. 10). Allerdings sind die Wahrscheinlichkeiten $p(\omega_i | \vec{x})$ unbekannt. Man löst dieses Problem dadurch, daß man die folgende Beziehung verwendet:

$$p(\omega_i | \vec{x}) = \frac{p(\vec{x} | \omega_i) p(\omega_i)}{p(\vec{x})} \quad (\text{Gl. 7})$$

2 Theoretische Grundlagen

$$\text{mit } p(\vec{x}) = \sum_j p(\vec{x}|\omega_j)p(\omega_j) \quad (\text{Gl. 8})$$

Dabei ist $p(\omega_i)$ die a priori Wahrscheinlichkeit, daß das Bild Pixel der Klasse ω_i enthält. $p(\vec{x})$ ist die Wahrscheinlichkeit am Ort \vec{x} ein Pixel von irgendeiner Klasse zu finden und $p(\vec{x}|\omega_i)$ gibt die Wahrscheinlichkeit an, die Klasse ω_i am Ort \vec{x} zu finden:

$$p(\vec{x}|\omega_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\left\{-\frac{1}{2}(\vec{x} - \vec{m}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{m}_i)\right\}, \quad (\text{Gl. 9})$$

wobei \vec{m}_i der Mittelpunktvektor und Σ_i die Kovarianzmatrix der Klasse ω_i ist. Σ_i läßt sich aus den Merkmalsvektoren \vec{x}_j der k Pixel, die der Trainer für die Klasse ω_i ausgewählt hat, durch folgende Formel berechnen:

$$\Sigma_i = \frac{1}{k-1} \sum_{j=1}^k (\vec{x}_j - \vec{m}_i)(\vec{x}_j - \vec{m}_i)^T. \quad (\text{Gl. 10})$$

Der Mittelpunktvektor \vec{m}_i wird aus den gleichen Merkmalsvektoren \vec{x}_j berechnet (vergleiche Abb. 9).

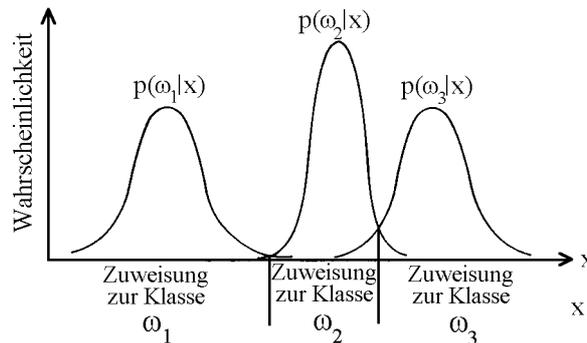


Abb. 10: Darstellung zur Veranschaulichung der Zuweisungsvorschrift für das „Maximum Likelihood“-Verfahren. (Quelle: [Richards 1993]) Die senkrechten Striche unterhalb der x -Achse definieren die Zuweisungsgrenzen.

Für die Zuweisungsbedingung folgt hieraus:

$$\vec{x} \in \omega_i, \text{ falls } p(\vec{x}|\omega_i)p(\omega_i) > p(\vec{x}|\omega_j)p(\omega_j) \forall j \neq i \quad (\text{Gl. 11})$$

Die Entscheidung, ob ein Pixel einer bestimmten Klasse angehört oder nicht, wird in der Praxis jedoch nicht durch die eben beschriebenen Wahrscheinlichkeiten getroffen, sondern anhand der mathematisch einfacher zu handhabenden Funktionen $g_i(\vec{x})$:

$$g_i(\vec{x}) = \ln\{p(\vec{x}|\omega_i)p(\omega_i)\} = \ln\{p(\vec{x}|\omega_i)\} + \ln\{p(\omega_i)\} \quad (\text{Gl. 12})$$

Außerdem tritt in der Praxis häufig das Problem auf, daß die a priori Wahrscheinlichkeiten $p(\omega_i)$ nicht bekannt sind. In dieser Situation werden die Wahrscheinlichkeiten $p(\omega_i)$ für alle Klassen im allgemeinen gleich gesetzt:

$$p(\omega_i) = p(\omega_j) \quad \forall i, j \quad (\text{Gl. 13})$$

Somit wird ein Pixel am Ort \vec{x} im Merkmalsraum der Klasse ω_i zugewiesen, wenn gilt:

$$\vec{x} \in \omega_i, \text{ falls } g_i(\vec{x}) > g_j(\vec{x}) \quad \forall j \neq i, \quad (\text{Gl. 14})$$

$$\text{wobei } g_i(\vec{x}) = -\ln |\Sigma_i| - (\vec{x} - \vec{m}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{m}_i) \quad (\text{Gl. 15})$$

2.2.3 Probleme und Grenzen

In Kapitel 2.2.1 wurde erörtert, wie wichtig die Klassifikation für das menschliche Denken ist. Denn hinter vielen menschlichen Begriffen (wie z.B. Straße, Wald oder Wiese) verbergen sich Klassenbezeichnungen. Ein Mensch verwendet für seine Klassifikation aber in der Regel nicht die gleichen Merkmale wie der Computer. Er achtet nämlich überwiegend auf die äußere Gestalt von Objekten und nutzt Zusatzinformationen (*Kontextwissen*) für die Klassifikation. Dieser Sachverhalt ist für die computergestützte Klassifikation sehr problematisch. Denn häufig reichen die (spektralen) Merkmale, die dem Computer zur Verfügung stehen, nicht aus, um die Pixel eines Bildes zuverlässig in die vom Menschen vorgegebenen Klassen einzuteilen.

Außerdem können Probleme auftreten, wenn die Pixel, die zu einer Klasse gehören, im Merkmalsraum weit verstreut sind. Diese starke Streuung kann verschiedene Ursachen haben:

- Fehler bei der Bestimmung der Merkmale (*Meßfehler*)
- Vermischung von Merkmalen verschiedener Objekte (z.B. Straße und Wald) an Übergangszonen (Entstehung von *Mischpixeln*)
- Die Objekte in der Klasse sind sehr unterschiedlich (Beispiel: Ein Wald kann aus vielen verschiedenen Baumarten bestehen)

Die starke Streuung der Pixel einer Klasse wird erst dann zu einem Problem, wenn einige Pixel dieser Klasse über die Zuweisungsgrenzen der Klasse (beachte Abb. 10) hinaus gestreut werden (Überschreitung der *Trennbarkeit*). Der genaue Verlauf der Trennbarkeitsgrenze einer Klasse hängt von den verwendeten Trainingspixeln (aller Klassen) und von dem verwendeten Klassifikationsverfahren ab. So ist es z.B. für das „Minimum Distance“-Verfahren recht problematisch, wenn die Pixel einer Klasse im Merkmalsraum nicht isotrop (kugelförmig) verteilt sind. Für das „Maximum Likelihood“-Verfahren ist dies kein Problem, denn die Funktionen $g_i(\vec{x})$ (siehe Gl. 15) können der Situation im Merkmalsraum viel besser angepaßt werden. Hierzu ist aber ein wesentlich höherer Trainingsaufwand notwendig, da nicht nur die Mittelpunktsvektoren \vec{m}_i , sondern auch die Kovarianzmatrizen Σ_i aus den Trainingsdaten abgeschätzt werden müssen.⁵

⁵ Es wird empfohlen mindestens $10 \cdot N$ Trainingspixel für jede Klasse auszuwählen, um die Kovarianzmatrix der Klasse abzuschätzen. Hierbei entspricht N der Anzahl der Merkmale (siehe [Richards 1993]).

2 Theoretische Grundlagen

Andererseits ist es für das „Maximum Likelihood“-Verfahren problematisch, wenn die Pixel innerhalb der Trainingsklassen nicht normalverteilt sind. Häufig bestehen die vom Menschen vorgegebenen Klassen (*Informationsklassen*) aus mehreren *Unterklassen*, die sich in ihren (spektralen) Merkmalen deutlich voneinander unterscheiden (*Spektralklassen*) [Richards 1993]. Wenn die Trainingspixel aus mehreren Spektralklassen stammen, wird die Streuung der Pixel der entsprechenden Informationsklasse überschätzt.

2.3 Bestimmung der Klassifikationsgenauigkeit

Die meisten Klassifikationsverfahren liefern als Ergebnis ein zweidimensionales Datenfeld von der Größe des klassifizierten Bildes. Wenn ein Pixel an der Position (x,y) im klassifizierten Bild der Klasse K zugewiesen wurde, so wird in dieses Datenfeld an der Position (x,y) die Klassennummer K eingetragen. Dieses Datenfeld wird häufig als Klassifikationskarte bezeichnet. Die Klassifikationskarte erhält der Anwender, also die Person, die letztendlich den Nutzen aus der Klassifikation zieht.

Für den Anwender ist es wichtig zu wissen, wie genau die Klassifikationskarte die Realität widerspiegelt. In diesem Zusammenhang ist die Angabe von Gesamtgenauigkeiten besonders problematisch, denn ein Klassifikationsfehler kann für verschiedene Anwender unterschiedliches Gewicht haben. Außerdem können die Genauigkeiten der einzelnen Klassen in einer Klassifikation erheblich voneinander abweichen. Es ist also für einen Anwender nicht empfehlenswert, auf eine Klassifikationskarte zu vertrauen, von der er nur die Gesamtgenauigkeit kennt. Dies gilt besonders dann, wenn er nur an einzelnen Klassen in der Karte interessiert ist.

2.3.1 Statistische Grundlagen

Bei der Prüfung der Genauigkeit einer Klassifikationskarte ist es im allgemeinen zu aufwendig, die gesamte Karte zu überprüfen. Um dieses Problem zu lösen, benötigt man Methoden der *Statistik*.

Man könnte die Statistik folgendermaßen charakterisieren [Sachs 1992]:

„Statistik ist die Kunst, Daten zu gewinnen, darzustellen, zu analysieren und zu interpretieren, um zu neuem Wissen zu gelangen.“

In der Statistik steht immer die Grundgesamtheit im Mittelpunkt des Interesses. Sie ist die Menge aller möglichen Erfahrung oder Beobachtungen. Im konkreten Fall bildet die Klassifikationskarte als Ganzes die Grundgesamtheit.

Man kann die Statistik in zwei Richtungen unterteilen, und zwar in die „Beschreibende Statistik“ und in die „Beurteilende Statistik“ [Sachs 1992].

Die „Beschreibende Statistik“ ist eine Weiterentwicklung der „Lehre von der Zustandsbeschreibung der Staaten“ aus dem 18. Jahrhundert. Ihre Aufgabe ist die Beschreibung von Zuständen und Vorgängen in einer Grundgesamtheit. Hierfür benutzt sie beispielsweise graphische Darstellungen, Tabellen und typische Kenngrößen, wie Lagemaße (z.B. arithmetische Mittelwerte) und Streumaße (z.B. Standardabweichungen).

$$\text{Arithmetisches Mittel: } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (\text{Gl. 16})$$

$$\text{Standardabweichung: } \sigma = \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{n-1}} \quad (\text{Gl. 17})$$

Die „Beurteilende Statistik“ versucht, aus geeigneten Daten auf allgemeine Gesetzmäßigkeiten zu schließen, die auf die Grundgesamtheit übertragbar sind. Sie stützt sich auf die Wahrscheinlichkeitsrechnung, welche die notwendigen Methoden liefert, um zu überprüfen, ob eine vermutete allgemeine Gesetzmäßigkeit tatsächlich auf die Grundgesamtheit übertragbar ist. Diesen Vorgang bezeichnet man als Prüfung einer Hypothese (siehe z.B. [Sachs 1992]).

Die Erhebung von Stichproben ist ein Thema, das für die Statistik von großer Bedeutung ist. Hierbei sind grundsätzlich Zufallsstichproben vorzuziehen. Sie haben den Vorteil, daß die aus ihnen ermittelten Kenngrößen gegenüber den Kenngrößen der Grundgesamtheit meistens nur Zufallsfehler aufweisen. Andernfalls können noch methodische oder systematische Fehler auftreten. Wenn eine Grundgesamtheit aus unterschiedlichen Teilgesamtheiten besteht, ist die Verwendung von geschichteten Zufallsstichproben empfehlenswert [Sachs 1992].

2.3.2 Die Konfusionsmatrix

Die Grundvoraussetzung für jede Form von quantitativer Genauigkeitsanalyse in der Klassifikation ist die Verfügbarkeit von Gebieten, deren Klassenzugehörigkeit hundertprozentig bekannt ist. Diese Gebiete werden im folgenden *Kontrollgebiete* genannt. Die Kontrollgebiete müssen in gleich große Einheiten unterteilt werden. In der computergestützten Klassifikation bietet sich als Einheit das Pixel an, da die Klassifikationskarte bereits in diese Einheit unterteilt ist. Ein Kontrollgebiet besteht also aus einer Menge von Kontrollpixeln.

Außerdem muß geklärt werden, nach welchem Schema die Kontrollgebiete ausgewählt werden sollen. In der Praxis werden häufig Verfahren eingesetzt, die z.B. über die gesamte Karte ein Gitter legen und die Gebiete auswählen, die unter den Gitterpunkten liegen. Auch Auswahlverfahren, die auf dem Zufallsprinzip beruhen, kommen zum Einsatz. Allerdings muß berücksichtigt werden, daß bei diesen Verfahren die Wahl auf Gebiete fallen kann, deren korrekte Klassenzugehörigkeit nur mit sehr großem Aufwand bestimmt werden kann. Dies ist z.B. dann der Fall, wenn zur Bestimmung der Klassenzugehörigkeit eine Vorortbesichtigung in unwegsamen Gelände notwendig ist. Hier müssen in der Praxis Kompromisse geschlossen werden, denn gerade Ortsbesichtigungen sind sehr kostenintensiv. Um sie zu vermeiden, greift man häufig auf Luftaufnahmen mit einer möglichst hohen räumlichen Auflösung zurück. Aus diesem Grund ist die Annahme, die Klassenzugehörigkeit der Kontrollgebiete sei hundertprozentig genau bekannt, nur eingeschränkt gültig. Die Genauigkeit, mit der die Güte einer Klassifikation festgestellt werden kann, wird also maßgeblich durch das verwendete Auswahlverfahren, die Genauigkeit der Kontrollgebiete und die Anzahl der Kontrollpixel bestimmt.

Nachdem die Kontrollgebiete ausgewählt worden sind, müssen die entsprechenden Kontrollgebiete aus der Klassifikationskarte herausgesucht werden. Wenn die Klassifikationskarte n verschiedene Klassen enthält, dann sind für jedes Kontrollpixel n verschiedene Beobachtungen möglich. Eine mögliche Beobachtung ist, daß es sich tatsächlich in der richtigen Klasse befindet. Es kann aber auch in eine der $n - 1$ übrigen Klassen eingeordnet worden sein. Alle derartigen Beobachtungen faßt man in einer $n \times n$ -Matrix zusammen. Sie wird im folgenden als *Konfusionsmatrix*⁶ bezeichnet. Um die Konfusionsmatrix zu erzeugen, müssen zunächst alle

⁶ Dieser Begriff wurde auch in [Burger 1992] verwendet.

2 Theoretische Grundlagen

Elemente in der Matrix auf den Wert Null gesetzt werden. Anschließend muß der im folgenden beschriebene Vorgang mit allen Kontrollpixeln durchgeführt werden. Angenommen die Überprüfung eines Kontrollpixels (z.B. durch Vorortbesichtigung) hat ergeben, daß es der Klasse i zugeteilt werden muß. Wenn dieses Pixel im Rahmen der Klassifikation der Klasse j zugewiesen wurde, dann wird die Zahl in der i -ten Spalte und j -ten Zeile in der Konfusionsmatrix um eins erhöht. Tabelle 1 zeigt ein Beispiel für eine Konfusionsmatrix. Die Tabelle enthält die Ergebnisse einer fiktiven Klassifikation mit drei Klassen A, B und C. Wenn man beispielsweise wissen möchte, wie viele Kontrollpixel, die eigentlich der Klasse A angehören, der Klasse B zugewiesen wurden, dann muß man die Zahl lesen, die in Spalte A und Zeile B steht. Die Summe einer Spalte Σ_s gibt an, wie viele Kontrollpixel einer bestimmten Klasse wirklich angehören. Die Summe einer Zeile Σ_z gibt an, wie viele Kontrollpixel im Rahmen der Klassifikation einer bestimmten Klasse zugewiesen wurden. Die Zahl in der letzten Spalte und letzten Zeile in der Tabelle gibt an, wie viele Kontrollpixel insgesamt ausgewählt wurden. Die i -te Zahl in der Diagonale gibt Auskunft darüber, wie viele Kontrollpixel der Klasse i korrekt klassifiziert wurden.

	A	B	C	Σ_z
A	40	16	22	78
B	5	33	12	50
C	7	5	57	69
Σ_s	52	54	91	197

Tabelle 1: Beispiel einer Konfusionsmatrix mit den Klassen A, B und C

Aus den Werten in einer Konfusionsmatrix können einige Prozentzahlen berechnet werden, die die erreichte Genauigkeit einer Klassifikation charakterisieren. So kann man beispielsweise den Wert eines Elementes der Diagonale (korrekt klassifizierte Pixel) durch die entsprechende Spaltensumme Σ_s teilen und mit 100 multiplizieren und erhält die prozentuale Wahrscheinlichkeit, mit der ein Pixel der entsprechenden Klasse korrekt klassifiziert wurde. Dieser Zahlenwert wird im folgenden als *Wiedererkennungsgenauigkeit* G_W (*producer accuracy*) bezeichnet. Wenn man die eben beschriebene Rechnung mit der Zeilensumme Σ_z durchführt, erhält man die prozentuale Wahrscheinlichkeit dafür, daß ein bestimmtes Pixel, das bei der Klassifikation der entsprechenden Klasse zugewiesen wurde, dieser auch tatsächlich angehört. Eine derart berechnete Prozentzahl wird im folgenden als *Zuweisungsgenauigkeit* G_Z (*user accuracy*) bezeichnet. Eine weitere wichtige Möglichkeit der Genauigkeitscharakterisierung besteht darin, die Summe der Diagonalen zu bilden, sie durch die Gesamtzahl der Kontrollpixel zu teilen und mit 100 zu multiplizieren. Das Ergebnis dieser Rechnung wird im folgenden als *Gesamtgenauigkeit* G_G (*overall accuracy*) bezeichnet [Congalton 1991]. Die sich für Tabelle 1 ergebenden Genauigkeiten werden im folgenden aufgelistet.

$$\begin{aligned} G_W(A) &= 76,9 \% , & G_W(B) &= 61,1 \% , & G_W(C) &= 35,0 \% \\ G_Z(A) &= 51,3 \% , & G_Z(B) &= 66,0 \% , & G_Z(C) &= 82,6 \% \\ G_G &= 66,0 \% \end{aligned}$$

2.3.3 Der Kappa-Wert

In der Vergangenheit wurden verschiedene Versuche unternommen die Informationen, die in der Konfusionsmatrix stecken, durch einen einzigen Zahlenwert wiederzugeben. Eine in diesem Zusammenhang entwickelte Maßzahl ist der *Kappa-Wert* (*Kappa Coefficient*). Er ist ein recht bekanntes Maß für die Gesamtgenauigkeit einer Klassifikationskarte und wurde 1983 in die Fernerkundung eingeführt [Congalton & Mead 1983]. Er berechnet sich aus allen Elementen

der Konfusionsmatrix und nicht nur aus den Elementen der Diagonalen, wie beispielsweise die im letzten Abschnitt eingeführte Gesamtgenauigkeit G_G .

Der Kappa-Wert wird folgendermaßen berechnet:

$$\kappa = \frac{(p_0 - p_Z)}{(1 - p_Z)} \quad (\text{Gl. 18})$$

$$\text{mit } p_0 = \sum_i \frac{X_{i,i}}{N} \text{ und } p_Z = \sum_i \left(\sum_j \frac{X_{i,j}}{N} \right) \cdot \left(\sum_j \frac{X_{j,i}}{N} \right) \quad (\text{Gl. 19})$$

Hierbei steht N für die Gesamtzahl der Kontrollpixel und $X_{i,j}$ für das Element in der Konfusionsmatrix, das sich in der i -Spalte und j -ten Zeile befindet. p_0 ist äquivalent zur Gesamtgenauigkeit G_G . p_Z entspricht dem Anteil an Kontrollpixeln, von denen man erwartet, daß sie zufällig korrekt klassifiziert worden sind. Mit anderen Worten, wenn man die Kontrollpixel nicht klassifizieren würde, sondern sie nur zufällig zuweist, dann würde ein geringer Anteil trotzdem korrekt zugeteilt. Der Anteil p_Z dieser Pixel wird von dem Anteil der korrekt zugewiesenen Pixel subtrahiert (siehe [Rosenfield & Fitzpatrick-Lins 1986]). Damit der Kappa-Wert den Wert Eins erreichen kann, was einer 100-prozentig korrekten Klassifikation entsprechen würde, muß im Nenner der obigen Gleichung (Gl. 18) p_Z von Eins subtrahiert werden⁷. Der Kappa-Wert kann nicht nur Werte zwischen Null und Eins annehmen, sondern auch negative Werte, wenn weniger Pixel als korrekt erkannt wurden, als man bei einer zufälligen Zuweisung erwarten würde. Außerdem sind Kappa-Werte meistens kleiner als die Werte für die Gesamtgenauigkeit G_G der entsprechenden Konfusionsmatrix.

Um mit dem Kappa-Wert besser vertraut zu werden, ist es sinnvoll die Kappa-Werte von einigen einfachen Fehlermatrizen auszurechnen und mit den entsprechenden Gesamtgenauigkeiten G_G zu vergleichen (siehe Tabelle 2).

KM ₁	A	B	C	Σ_z				
A	1	1	1	3				
B	1	1	1	3				
C	1	1	1	3				
Σ_s	3	3	3	9				
	$\kappa = 0,0$		$G_G = 0,33$ (33%)					
KM ₂	A	B	C	Σ_z				
A	3	0	0	3				
B	0	3	0	3				
C	0	0	3	3				
Σ_s	3	3	3	9				
	$\kappa = 1,0$		$G_G = 1,0$ (100%)					
KM ₃	A	B	C	Σ_z				
A	2	1	0	3				
B	1	2	0	3				
C	0	1	2	3				
Σ_s	3	4	2	9				
	$\kappa = 0,5$		$G_G = 0,67$ (67%)					
KM ₄	A	B	C	Σ_z				
A	2	0	0	2				
B	3	2	0	5				
C	0	0	2	2				
Σ_s	5	2	2	9				
	$\kappa = 0,53$		$G_G = 0,67$ (67%)					
KM ₅	A	B	C	Σ_z				
A	0	3	3	6				
B	0	0	3	3				
C	0	0	0	0				
Σ_s	0	3	6	9				
	$\kappa = -0,13$		$G_G = 0,0$ (0%)					
KM ₆	A	B	C	Σ_z				
A	0	0	9	9				
B	0	0	0	0				
C	0	0	0	0				
Σ_s	0	0	9	9				
	$\kappa = 0,0$		$G_G = 0,0$ (0%)					

Tabelle 2: Einfache Konfusionsmatrizen mit ihren Kappa-Werten und Gesamtgenauigkeiten

Man beachte, daß Konfusionsmatrix KM₃ und KM₄ in Tabelle 2 die gleiche Gesamtgenauigkeit G_G besitzen, aber ihre Kappa-Werte unterschiedlich sind.

⁷ Die Berechnung des Kappa-Wertes wird u.a. in [Congalton & Mead 1983], [Congalton 1991], [Hudson & Ramm 1987], [Richards 1993] und [Rosenfield & Fitzpatrick-Lins 1986] beschrieben.

2 Theoretische Grundlagen

In [Ortiz et al 1997] wurde eine Skala für die Bewertung von Kappa-Werten eingeführt (siehe Tabelle 3).

Kappa-Wert [%]	Qualität
< 0,0	Sehr schlecht
0 bis 20	Schlecht
20 bis 40	Akzeptabel
40 bis 60	Gut
60 bis 80	Sehr gut
80 bis 100	Ausgezeichnet

Tabelle 3: Tabelle zur Bewertung von Kappa-Werten

2.4 Entzerrung von Luftbildern

Die im Rahmen der flugzeuggestützten Fernerkundung gewonnenen Daten werden im allgemeinen als Bilder (Luftbilder) dargestellt. Diese Luftbilder sind Abbildungen der vom Fernerkundungsgerät erfaßten Objekte. Bei dem Abbildungsprozeß können *Verzerrungen* auftreten.

Man kann eine Verzerrung folgendermaßen definieren [Brockhaus 1984]:

„Eine Verzerrung ist eine Abbildung, bei der das Verhältnis der Abstände zweier Punkte P und Q und ihrer beiden Bildpunkte von der Lage P und der Richtung der Verbindungsgeraden von P und Q und vom Abstand vom Bildmittelpunkt abhängt.“

2.4.1 Ursachen von Bildverzerrungen

Bei der Abbildung eines dreidimensionalen Objektes auf eine zweidimensionale Bildebene kommt es häufig zu Verzerrungsproblemen. Wo und wie stark die Verzerrungen in einem Bild auftreten, hängt erheblich von der Projektionsart ab, die zur Bilderzeugung eingesetzt wurde. Wenn die Objekte beispielsweise durch eine Zentralprojektion abgebildet wurden, dann werden die Eckpunkte hoher Objekte (z.B. Gebäude) vom Bildmittelpunkt weg versetzt (siehe Abb. 11). Wenn die Objekte hingegen durch eine Parallelprojektion abgebildet wurden, dann werden die Eckpunkte hoher Objekte senkrecht zur Bewegungsrichtung des Fernerkundungsgerätes nach außen versetzt (siehe Abb. 11). Im folgenden werden derartige projektionsbedingte Verzerrungen als *perspektivische Verzerrungen* bezeichnet.

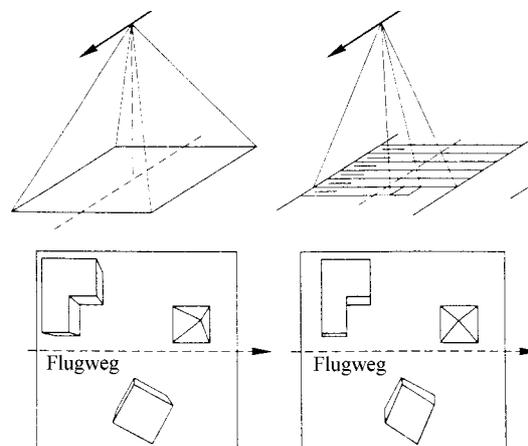


Abb. 11: Darstellung zur Veranschaulichung der Auswirkungen von perspektivischen Verzerrungen (links: Zentralprojektion, rechts: Parallelprojektion) (Quelle: [Albertz 1991])

Neben diesen unvermeidlichen Verzerrungen treten aber auch noch Verzerrungen auf, deren Ursachen eher in der vierten Dimension liegen, nämlich in der für die Bildaufnahme benötigten Zeit. Während sich die Bildaufnahme bei Luftbildkameras im Sekundenbruchteil vollzieht, dauert diese bei Scanner-Systemen sehr viel länger. Denn Scanner-Systeme erfassen ein Objekt nicht als Ganzes, sondern tastet es in kleinen Stücken ab. Geht der Scanner hierbei zeilenweise vor, so bezeichnet man ihn als einen Zeilenscanner. Die Flugbewegung des Fernerkundungsgerätes und die zeilenweise Abtastung senkrecht zur Flugrichtung führen dann zur Erfassung zusammenhängender Gebiete. Allerdings führt nun jede Störung der gleichförmigen Flugbewegungen zu Verzerrungen. Ursachen für derartige Störungen sind (bei Fernerkundungsflugzeugen) Rotationsbewegungen um eine der Flugzeugachsen, Veränderungen in der Flughöhe oder Fluggeschwindigkeit. Aber selbst wenn keine Störungen der Flugbewegung auftreten, tritt bei Zeilenscannern eine Form von Verzerrung auf, die im allgemeinen als *Panorama-Verzerrung* bezeichnet wird. Sie entsteht, weil die Scanner die Erdoberfläche in immer gleichen Winkel-Inkrementen ω abtasten, unabhängig davon, ob sie gerade den Bereich senkrecht unter dem Flugzeug (Nadir-Bereich) oder einen Gebiet am Rande des Scan-Bereichs (Off-Nadir-Bereich) scannen (siehe Abb. 12) [Albertz 1991].

2.4.2 Methoden der Bildentzerrung

Die Entzerrung von Luftbildern wird dann notwendig, wenn man verschiedene Luftbilder miteinander vergleichen möchte. Hierbei besteht das Ziel nicht unbedingt darin, die Bilder wirklich zu entzerren, sondern vielmehr eine Anpassung der zu vergleichenden Bilder durchzuführen.

Die Grundaufgabe bei jeder Art von Bildentzerrung besteht darin, eine geeignete geometrische Transformation zu finden und diese auf das Bild anzuwenden. Eine geometrische Transformation verändert die Grauwerte eines Bildes nicht, sondern nur die Position der Pixel im Bild.

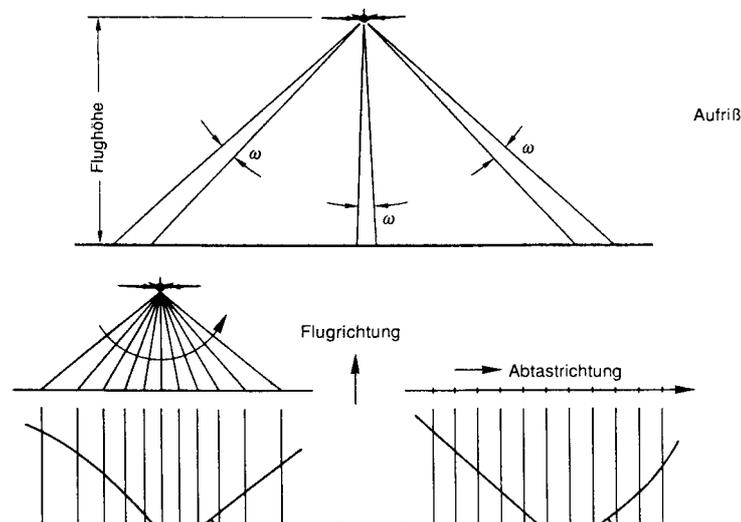


Abb. 12: Darstellungen zur Veranschaulichung der Ursachen, die zur Panoramaverzerrung führen. (Unten links: Abtastung mit konstanten Winkel-Inkrementen, unten rechts: Verzerrung des Bildes bei Wiedergabe in konstanten Strecken-Inkrementen) (Quelle: [Albertz 1991])

Am einfachsten ist die Panorama-Verzerrung zu korrigieren, weil diese Form der Verzerrung nur von den Eigenschaften des Scanners abhängt und sich durch eine recht einfache Transformationsfunktion korrigieren läßt, welche lediglich vom Scan-Winkel des Zeilenscanners abhängt.

2 Theoretische Grundlagen

Für die Korrektur der übrigen Verzerrungen gibt es zwei grundsätzliche Vorgehensweisen. Entweder man versucht mit Hilfe von Paßpunkten eine Interpolationsfunktion zu finden, um das betreffende Bild zu transformieren, oder man versucht die Aufnahmegeometrie und die Flugbewegungen möglichst genau mathematisch zu modellieren.

Die Vorteile der ersten Vorgehensweise liegen vor allem in dem geringen technischen Aufwand. Zur Durchführung benötigt man zunächst eine Reihe paarweise korrespondierender Punkte (Paßpunkte). Aus diesen Paßpunkten werden anschließend die für die Transformation benötigten Koeffizienten bestimmt. Da die Transformationen im allgemeinen mit Hilfe von Computern durchgeführt werden, handelt es sich bei den zu entzerrten Bildern in der Regel um Digitalbilder. Digitalbilder bestehen aus einer Menge von Pixeln, die in einer Matrix M (Bildmatrix) angeordnet sind. Nachdem also die benötigten Koeffizienten ermittelt worden sind, wird eine neue Bildmatrix M_{NEU} für die Pixel des entzerrten Bildes angelegt. Danach wird für jedes Element dieser Bildmatrix M_{NEU} , mit Hilfe einer inversen Bildtransformation, das korrespondierende Element in der Bildmatrix M_{ALT} des verzerrten Bildes gesucht und in M_{NEU} eingesetzt. Bei einem Digitalbild kann es vorkommen, daß an der ermittelten Position kein unmittelbar korrespondierendes Element zu finden ist. In diesem Fall wird häufig auf das nächst benachbarte Element zurückgegriffen (*nearest neighbor*) oder eine Interpolation zwischen mehreren nächst liegenden Pixeln vorgenommen. Der ganze Prozeß wird auch als „Resampling“ bezeichnet ([Albertz 1991], [Ehlers 1994] und [Wiemker 1996]).

Die zweite Vorgehensweise verspricht im Prinzip bessere Ergebnisse, benötigt aber, neben den eigentlichen Bilddaten, eine enorme Menge an Zusatzinformationen über die Fluglage und die Abbildungsgeometrie des Scanners. Außerdem wird ein digitales Geländemodell benötigt (siehe [Albertz 1991], [Zang et al 1994]).

2.4.3 Probleme und Grenzen

In der Regel ist eine absolute Entzerrung des Bildmaterials nicht möglich. Hierfür gibt es verschiedene Gründe. So tritt in der Praxis häufig das Problem auf, daß zwischen zwei Bildern nicht beliebig viele zuverlässig korrespondierende Punktpaare (Paßpunkte) gefunden werden können. Dieses Problem kann bei starken Verzerrungen dazu führen, daß noch Verzerrungen im Bild zurückbleiben. Außerdem ist jeder Paßpunkt mit einem Fehler behaftet. Ein Paßpunkt kann also ein Bild auch verzerren. Wenn für die Entzerrung Informationen über den Flugzustand des Fernerkundungsgerätes verwandt werden, dann führen Ungenauigkeiten innerhalb dieser Informationen ebenfalls zu einer Einschränkung der Qualität der Entzerrung.

Ein weiteres Problem, das bei der Entzerrung von Bildern auftreten kann, wird meistens als *Korrespondenzproblem* bezeichnet. Verursacht wird dieses Problem dadurch, daß dreidimensionale Objekte in eine zweidimensionale Ebene (Bildebene) abgebildet werden, denn hierbei wird nur ein Teil der Informationen des Objektes erfaßt. Wenn ein Objekt für die Entzerrung aus einer anderen Perspektive dargestellt werden muß, dann stehen die hierfür notwendigen Informationen häufig gar nicht zur Verfügung. Für die Entzerrung bedeutet dies, daß nicht alle Bildpunkte einen korrespondierenden Bildpunkt im jeweils anderen Bild besitzen, obwohl beide Bilder dieselben Objekte enthalten [Jähne 1993].

3 Datenmaterial und Datennahme

Das Bildmaterial, das für diese Arbeit zur Verfügung stand, wurde in den Jahren 1991, 1992, 1994 und 1995 im Raum Nürnberg aufgenommen. Die Überfliegungen wurden von der DLR (Deutsche Forschungsanstalt für Luft- und Raumfahrt) im Auftrag der Universität Hamburg durchgeführt. Die DLR verwendete einen Multispektralscanner vom Typ AADS 1268 der Firma Daedalus Enterprises Inc (USA), der in ein Flugzeug vom Typ Dornier DO 228 eingebaut worden war.

Zusätzlich zu den Scannerdaten wurden während der Überfliegungen noch eine Reihe von Luftphotos aufgenommen. Die Luftphotos der Jahre 1991 und 1992 sind schwarz/weiß. Die Luftphotos aus den Jahren 1994 und 1995 sind *CIR-Bilder (color infrared) oder sog. Falschfarben-Infrarot-Bilder*. In den Jahren 1991 und 1992 wurden Scannerdaten und Luftphotos in den Flughöhen 300m, 900m und 1800m aufgenommen. In den beiden übrigen Jahren wurden die Daten und die Photos nur aus Flughöhen von 300m und 1800m aufgenommen. Der Abbildungsmaßstab der Photos betrug 1:2000 (bzw. 1:12000) bei einer Flughöhe von 300m (bzw. 1800m).

3.1 Der Daedalus-Scanner

Der Multispektralscanner AADS 1268 wird im folgenden als *Daedalus-Scanner* bezeichnet. Der Daedalus-Scanner ist in der Lage, die von Objekten auf dem Erdboden ausgestrahlten elektromagnetischen Strahldichten L zu messen und aufzuzeichnen. Er verfügt über elf Detektoren, die jeweils für einen bestimmten Bereich des Spektrums empfindlich sind. Die Strahldichten werden also nicht über das gesamte Spektrum integriert gemessen, sondern die Integration erfolgt separat für die elf verschiedenen Spektralbereiche (Spektralkanäle) der elf Detektoren (siehe Tabelle 4). Deshalb bezeichnet man diesen Scanner als *Multispektralscanner*.

Kanal	Spektralbereich [μm]	Bandbreite [μm]	Detektormaterial
1	0,42 - 0,45	0,03	Silizium (Si)
2	0,45 - 0,52	0,07	Silizium (Si)
3	0,52 - 0,60	0,08	Silizium (Si)
4	0,605 - 0,625	0,02	Silizium (Si)
5	0,63 - 0,69	0,06	Silizium (Si)
6	0,695 - 0,75	0,055	Silizium (Si)
7	0,76 - 0,90	0,14	Silizium (Si)
8	0,91 - 1,05	0,14	Silizium (Si)
9	1,55 - 1,75	0,20	Indium-Antimonit (InSb)
10	2,08 - 2,35	0,27	Indium-Antimonit (InSb)
11	8,5 - 13,0	4,50	Quecksilber-Kadmium-Tellurit (HgCdTe)

Tabelle 4: Die Spektralbereiche der Detektoren des Daedalus-Scanners (Quelle: [Kollewe 1996])

Der Daedalus-Scanner ist ein Zeilenscanner. Er tastet den Erdboden in kleinen Flächenstücken (Bodenelementen) mit konstanten Winkel-Inkrementen ω von $0,12^\circ$ ab. Die Bodenelemente am Rande des Erfassungsbereichs des Scanners liegen in einem Winkel von $42,96^\circ$, gemessen von der Hochachse des Flugzeuges (siehe Abb. 13). Die Breite b eines Bodenelements läßt sich durch die folgende Gleichung beschreiben:

$$b(\varphi) = h \cdot (\tan(\varphi + \omega) - \tan(\varphi)), \quad (\text{Gl. 20})$$

3 Datenmaterial und Datennahme

wobei h der Flughöhe und ϕ dem momentanen Scan-Winkel entspricht. Bei einer Flughöhe von 300m (1800m) haben die Flächenstücke im Nadir-Bereich eine Größe von ca. 0,64 x 0,64 m (3,8 x 3,8 m) und im Off-Nadir-Bereich (bei $42,96^\circ$) eine Größe von ca. 1,2 x 1,2 m (7 x 7 m).

Eine Folge aus direkt nacheinander aufgenommenen Scanzeilen ergibt ein zusammenhängendes Multispektralbild, es wird im folgenden als Flugstreifen bezeichnet.

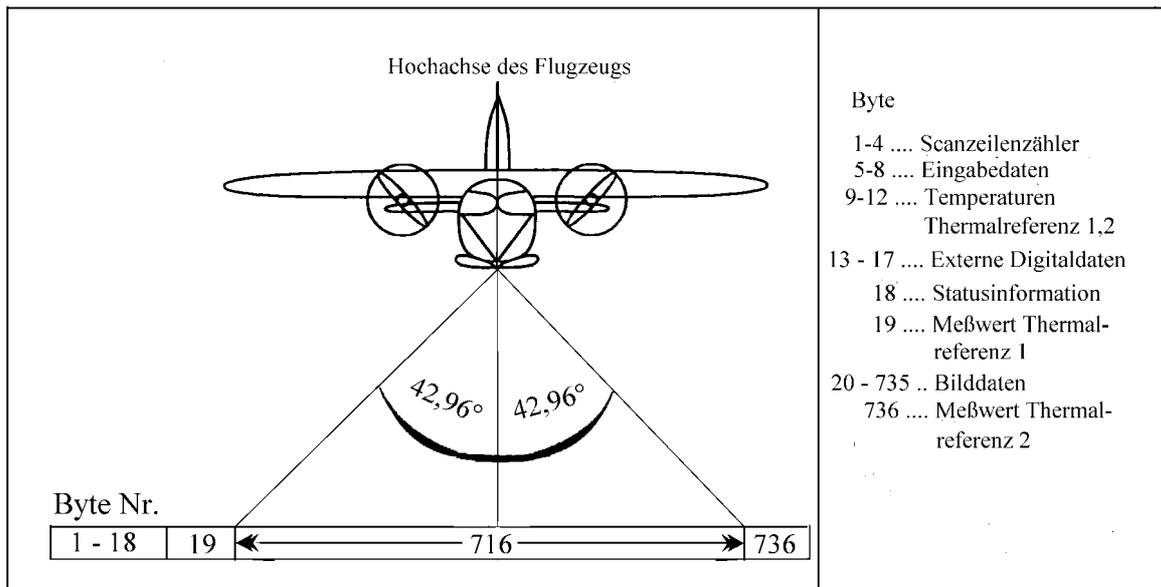


Abb. 13: Darstellung zur Veranschaulichung der Datenstruktur und der Aufnahmegeometrie des Daedalus-Scanners (Quelle: [Kollewe 1996])

Der Daedalus-Scanner AADS 1268 besteht im wesentlichen aus folgenden Baugruppen:

- Scan-Kopf
- Spektrometer
- Analog/Digital-Wandler (A/D-Wandler)
- Bedienungskonsole
- Magnetbandrecorder

Das Kernstück des Scan-Kopfes bildet der rotierende Scan-Spiegel⁸. Er hat die Aufgabe, die durch die geöffnete Bodenlücke einfallende Strahlung auf den primären Teleskopspiegel zu projizieren (siehe Abb. 14). Dieser und ein weiterer Teleskopspiegel dienen dazu, die einfallende Strahlung zu bündeln. Nach der Bündelung wird die Strahlung mit Hilfe eines halbdurchlässigen Spiegels in das Spektrometer projiziert. Im Spektrometer wird die einfallende Strahlung zunächst mit drei dichroitischen Filtern in vier verschiedene Spektralbereiche aufgespalten. Einer dieser Spektralbereiche ist der Bereich des sichtbaren Lichtes und des nahen Infrarot. Die in diesen Bereich fallende Strahlung wird durch ein Prisma weiter aufgespalten und anschließend über eine Linse auf eine Reihe aus acht Si-Detektoren fokussiert. Die Strahlung aus den übrigen drei Spektralbereichen wird mit einer Linse auf jeweils einen Detektor fokussiert, der für Strahlung des betreffenden Spektralbereichs besonders empfindlich ist. Die

⁸ Der Scan-Spiegel besteht aus zwei Spiegelflächen, die sich beim Scan-Vorgang abwechseln (d.h. es befindet sich jeweils nur ein Spiegel im Strahlengang).

Detektoren liefern ein elektronisches Signal, das zu der auf den Detektor auftreffenden Strahlungsleistung proportional ist. Diese Signale werden von den A/D-Wandlern digitalisiert. Die A/D-Wandler besitzen einen diskreten Wertebereich aus 256 verschiedenen Werten. Die von ihnen digitalisierten Daten werden mit dem Magnetbandrecorder aufgezeichnet. Die Struktur mit der die Daten auf das Magnetband geschrieben werden, ist für alle Spektralkanäle gleich (siehe Abb. 13).

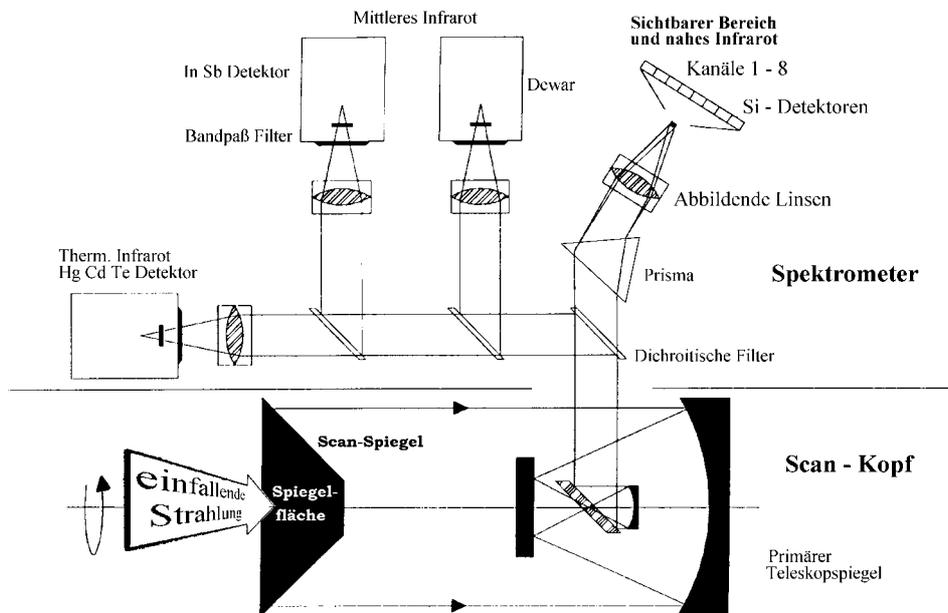


Abb. 14: Darstellung des schematischen Aufbaus des Daedalus-Scanners. (Als Vorlage für die Abbildung diente eine schematische Zeichnung des Herstellers. Die Richtung der einfallenden Strahlung wurde vom Autor dieser Arbeit zur Verdeutlichung ergänzt.)

Zusätzlich zu den oben erwähnten Baugruppen besitzt der Daedalus-Scanner noch zwei Schwarzkörperstrahler und ein Gyrometer. Die Schwarzkörperstrahler werden während des Fluges konstant auf zwei verschiedenen Temperaturen gehalten. Sie werden am Anfang (bzw. am Ende) jeder Scan-Zeile von dem Detektor des Spektralkanals Nr. 11 gemessen. Die Maßnahme dient der Kalibrierung dieses Kanals. Er wird im folgenden als thermischer Kanal bezeichnet. Das Gyrometer wird dazu verwendet, um Bildverzerrungen, die durch Drehbewegungen des Flugzeuges um seine Längsachse entstanden sind, zu korrigieren (Rollkompensation).

Das von der DLR gelieferte Datenmaterial wurde nach einem von Thomas Hepp (siehe [Hepp 1994]) und Thomas Kollewe (siehe [Kollewe 1996]) beschriebenen Verfahren für die weitere Verwendung aufbereitet. Ziel dieser Aufbereitung war es, aus den gemessenen Strahldichten Reflektanzwerte zu berechnen. Die Reflektanz ist zu dem in Kapitel 2.1.4 eingeführten Reflexionsgrad $\rho(\lambda)$ äquivalent. Sie wird definiert als Quotient aus der von einem Objekt reflektierten Strahldichte L_r und der (aus dem gesamten Halbraum von 2π) auf das Objekt einfallenden Bestrahlungsstärke E_e :

$$\rho(\lambda) = \pi \frac{L_r(\lambda)}{E_e(\lambda)}. \quad (\text{Gl. 21})$$

3 Datenmaterial und Datennahme

Die Reflektanz hat den Vorteil, daß sie im Idealfall nur von den Objekteigenschaften abhängt. Die Strahldichte hingegen wird noch zusätzlich durch Einflüsse, wie z.B. Sonnenstand und Atmosphärenzusammensetzung beeinflusst. Das Problem bei der Reflektanzberechnung ist, daß die einfallende Bestrahlungsstärke E_e nicht direkt gemessen werden kann, zumindest nicht vom Fernerkundungsgerät aus. Sie wird mit Hilfe von Computermodellen ermittelt, welche den Strahlungstransport durch die Atmosphäre in Abhängigkeit von den zur Aufnahmezeit herrschenden Wetterbedingungen (Luftdruck, Sichtweite usw.) simulieren. Thomas Hepp verwendete für die Strahlungstransportsimulation das Computermodell⁹ LOWTRAN-7. Anschließend berechnete er (mit dem Computerprogramm SENSAT-4 [Richter 1992]) aus den vom Sensor gemessenen Strahldichten die entsprechenden Reflektanzwerte (näheres siehe [Hepp 1994]).

Während der Überfliegungen in den Jahren 1994 und 1995 wurden die von einigen ausgewählten Oberflächen reflektierten Strahlungsdichten zusätzlich noch mit einem hochauflösenden Radiospektrometer vom Typ IRIS Mark IV der Firma GER (USA) gemessen. Dieses Spektrometer verfügt über 862 Spektralkanäle, welche über den Spektralbereich von 300 bis 3000 nm verteilt sind. Das Gerät war auf einem Stativ montiert. Mit dem Gerät wurde die Reflektanz der ausgewählten Flächen aus einem Abstand von ca. 1 Meter gemessen. Weitere Informationen siehe [Kollewe 1996].

Der Vergleich der Meßdaten vom IRIS-Spektrometer und vom Daedalus-Scanner ergab, daß die Kalibrierung der Daten vom Daedalus-Scanner, durch die Verwendung der Daten vom IRIS-Spektrometer, verbessert werden können. Deshalb sind die Bilddaten der Jahre 1994 und 1995 mit Hilfe der IRIS-Messungen korrigiert worden [Kollewe et al 1996].

Die berechneten Daten standen am Anfang dieser Arbeit als Bilddateien im Dateiformat TIFF (Tagged Image File Format) zur Verfügung. Die Reflektanzwerte wurden hierbei so codiert, daß z.B. ein Wert von 0 im TIFF-Bild einer Reflektanz von 0% und ein Wert von 255 einer Reflektanz von 100% entsprach. Diese Bilder werden im folgenden als Reflektanzbilder bezeichnet. Im Rahmen der Arbeit wurden nur die Bilddaten der ersten zehn Spektralkanäle des Daedalus-Scanners verwendet. Die Daten des thermischen Kanals wurden also nicht verwendet.

Die Größe des Fehlers, mit dem die Reflektanzwerte behaftet sind, hängt maßgeblich von dem Fehler der gemessenen Strahldichten und von der Güte der verwendeten Computersimulationen (SENSAT-4, LOWTRAN-7) ab. Da die genaue Bestimmung der Güte der Simulationen äußerst schwierig ist, kann der Fehler nur abgeschätzt werden. Er liegt bei bis zu 10% (siehe [Kollewe et al 1996]).

⁹ Das Computermodell LOWTRAN-7 berücksichtigt bei der Simulation die folgenden Effekte:

- Aerosol-Absorption und Streuung
- Kontinuums-Absorption
- Molekulare-Absorption und Streuung

Es verfügt über sechs Atmosphärenmodelle (Standardatmosphären). Weitere Informationen sind in [Hepp 1994] oder [Anderson et al 1995] zu finden.

3.2 Die Luftphotos

Die Luftphotos wurden mit einer Reihenmeßkammer vom Typ RMK A 15/23 der Firma Carl Zeiss aufgenommen. Sie besitzt ein Bildformat von $23 \times 23 \text{ cm}^2$ und eine Brennweite von 15cm (entspricht einem maximalen Bildwinkel von 94°). Ihre Belichtungszeiten liegen zwischen $1/100$ bis $1/1000$ Sekunde. Sie hat ein Kassettenvolumen 120m und ein Gewicht von 110kg (inklusive Aufhängung, Kassette und Steuergerät). Abb. 15 zeigt den prinzipiellen Aufbau einer Reihenmeßkammer.

In den Jahren 1994 und 1995 wurde für die Aufnahme der Luftphotos Farbinfrarot-Filme vom Typ „KODAK AEROCHROME Infrared Film 2443“ eingesetzt.

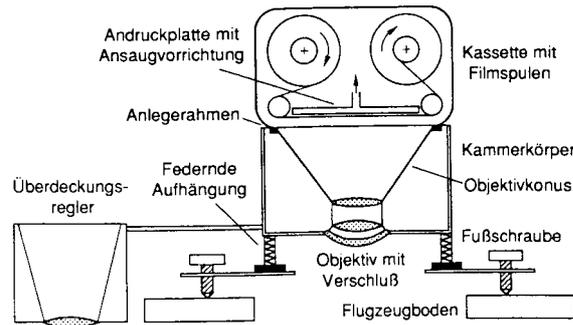


Abb. 15: Darstellung des schematischen Aufbaus einer Reihenmeßkammer (Quelle: [Albertz 1991])

Farbinfrarotfilme unterscheiden sich von den üblichen Farbfilmen dadurch, daß eine ihrer Farbschichten für das Licht des infraroten Spektralbereichs sensibilisiert wurde (siehe Abb. 16). Auf einem Farbinfrarotfilm erscheinen blaue Objekte schwarz, grüne Objekte blau und rote Objekte grün. Objekte, die viel infrarote Strahlung emittieren z.B. Bäume, erscheinen auf dem Infrarotfilm in rötlicher Farbe.

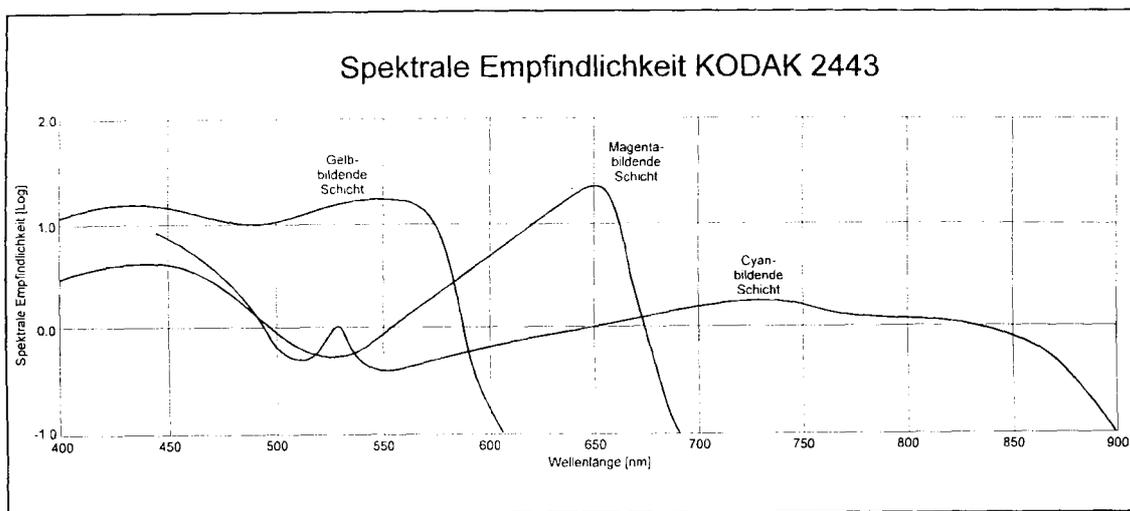


Abb. 16: Diagramm der spektralen Empfindlichkeit des Farbinfrarotfilms KODAK 2443 (Quelle: [Kollewe 1996])

4 Überwachte Klassifikation von Multispektralbildern

4.1 Der Weg vom Multispektralbild zur Klassifikationskarte

Das Ziel dieses Abschnitts ist es (am Beispiel des für diese Arbeit zur Verfügung stehenden Bildmaterials) die Schritte darzulegen, die zur Durchführung einer überwachten Klassifikation notwendig sind. Außerdem werden einige wichtige Probleme angesprochen, die im Rahmen einer Klassifikation auftreten können.

Der erste Schritt besteht darin, daß man das zu klassifizierende Bildmaterial sichtet und versucht, eine Reihe von Klassen zu definieren, in die das Bildmaterial eingeteilt werden soll. Diese Klassen sind in der Regel sehr abstrakt und man weiß anfangs noch gar nicht, ob die spektralen Informationen (Merkmale), die dem Computer während der Klassifikation zur Verfügung stehen, ausreichen, um die Objekte im Bild in diese Klassen zu unterteilen. Da mit Hilfe dieser Klassen der Informationsgehalt des Bildes auf die für einen menschlichen Betrachter wichtigsten Informationen reduziert wird, werden sie im folgenden als *Informationsklassen* bezeichnet. Für die Klassifikation ist es wichtig, daß es möglichst für jedes Objekt im Bild eine Informationsklasse gibt, der es angehört. Andernfalls werden die Pixel dieses Objektes, in der Klassifikationsphase, einer Informationsklasse zugewiesen, der sie keinesfalls angehören.

Nachdem das Klassifikationsziel definiert wurde, beginnt die *Trainingsphase*. In der Trainingsphase besteht das Hauptproblem darin, daß die gesuchten Informationsklassen nicht auf der Grundlage der spektralen Merkmale des Bildes definiert wurden, d. h. die Pixel einer Informationsklasse können sehr unterschiedliche spektrale Merkmale besitzen. Dies läßt sich am besten durch ein Beispiel verdeutlichen. Angenommen, man definiert die Informationsklasse „Gebäude mit flachen Dächern“. Die Dächer dieser Gebäude können mit sehr unterschiedlichen Materialien gebaut worden sein, z.B. aus Wellblech oder Teerpappe. Da diese beiden Materialien sehr unterschiedliche spektrale Eigenschaften haben, müssen für beide Materialtypen getrennte Trainingsklassen eingesetzt werden. Die Frage, nach der optimalen Zahl und Lage der Trainingsklassen im Merkmalsraum, ist nur schwer zu beantworten, weil ein hochdimensionaler Merkmalsraum kaum darstellbar oder vorstellbar ist. Außerdem können die Trainingsklassen verschiedener Informationsklassen miteinander konkurrieren (Beispiel: asphaltierte Straßen und Dächer aus Teerpappe). Das Erkennen derartiger Situationen ist nicht immer einfach und verlangt eine Menge Erfahrung.

Zu Beginn der Trainingsphase, muß das Datenmaterial, aus dem die Trainingsdaten gewonnen werden, geeignet dargestellt werden. Im Rahmen dieser Arbeit wurden hierfür die Bilddaten des Spektralkanals Nr. 7 (0,76 - 0,9 μm) des Daedalus-Scanners auf dem Computermonitor kontrastverstärkt dargestellt. Anschließend wurden in dem dargestellten Bild eine Reihe geschlossener Polygone markiert und auf diese Weise Trainingsgebiete für die verschiedenen Trainingsklassen definiert. Aus den Pixeln, die das jeweilige Polygon umschloß, wurden die Mittelwerte (einen für jeden verwendeten Spektralkanal des Daedalus-Scanners) und die Kovarianzmatrix der entsprechenden Klasse berechnet. Die aus allen Trainingsgebieten berechneten Daten wurden von einem Computerprogramm zu einem Datensatz zusammengefaßt. Dieser Datensatz wird im folgenden als Trainingsatz bezeichnet. Neben diesen Daten müssen noch Informationen darüber gespeichert werden, zu welcher Informationsklasse die einzelnen Trainingsklassen gehören. Dies geschieht am zweckmäßigsten mit Nummern, die die verschiedenen Klassen symbolisieren.

In der *Klassifikationsphase* werden die Klassifikationsprogramme gestartet und ihnen die benötigten Daten übergeben. Das „Minimum Distance“-Klassifikationsprogramm benötigte als Eingabe, neben den zu klassifizierenden Bilddaten, noch die in der Trainingsphase berechneten Mittelwerte. Die Bilddaten wurden in Form eines dreidimensionalen Datenfeldes (Flugstreifenbreite x Flugstreifenlänge x Spektralkanäle) übergeben. Das „Maximum Likelihood“-Klassifikationsprogramm benötigte noch zusätzlich die berechneten Kovarianzmatrizen. Die Klassifikationsprogramme übergaben ihre Ergebnisse jeweils in Form eines zweidimensionalen Datenfeldes (Flugstreifenbreite x Flugstreifenlänge). In diesen Datenfeldern (Klassifikationskarten) war für jedes Pixel die Nummer der Trainingsklasse an der entsprechenden Position des Originalbildes vom Klassifikationsprogramm eingetragen worden. Die Nummern vergaben die Klassifikationsprogramme entsprechend der Reihenfolge der Klassen im Trainingssatz. Da die Klassifikationskarten noch die Nummern der Trainingsklassen enthielten und nicht die Nummern der Informationsklassen, war noch eine Transformation der Klassennummern erforderlich. Nach dieser Transformation konnten die Klassifikationskarten auf dem Bildschirm betrachtet und ausgewertet werden.

Am Ende dieses Kapitels muß noch ein Problem angesprochen werden, das in der Praxis bei der Klassifikation mit dem „Maximum Likelihood“-Verfahren auftreten kann. Bei der Auswahl einer zu geringen Zahl (bzw. zu ähnlicher Pixel) kann es vorkommen, daß die aus ihnen errechnete Kovarianzmatrix nicht vollrangig ist. In diesem Fall ist die Matrix nicht invertierbar. Das im Rahmen dieser Arbeit eingesetzte „Maximum Likelihood“-Klassifikationsprogramm begegnete diesem Problem, indem es den kleinsten Eigenwert E ($E > 0$), der im gesamten Trainingssatz auftrat, in die Diagonalelemente der Kovarianzmatrizen eintrug, die den Wert null besaßen. Weitere Informationen zu diesem Problem sind z.B. bei [Duda & Hart 1973] zu finden. Das Problem der Invertierbarkeit einer Matrix ist im Grunde ein mathematisches Problem (siehe [Fischer 1986]).

4.2 Beschreibung des verwendeten Datenmaterials

Bevor mit der Festlegung des Klassifikationszieles begonnen werden kann, muß das verwendete Datenmaterial zunächst gesichtet werden. Obwohl für die Arbeit das Bildmaterial von vier verschiedenen Jahren zu Verfügung stand, wurden die im Rahmen dieser Arbeit durchgeführten statistischen Untersuchungen auf die Flugstreifen, die im Jahr 1994 aus 300m Höhe aufgenommen wurden, begrenzt.

Der betreffende Flug wurde am 18.Okt.1994 durchgeführt. Die Aufnahmezeit begann um 11:12 Uhr (Universal Time) und endete um 12:17 Uhr (UT). Die Sonne stand zu dieser Zeit in Nürnberg in einem Winkel von ca. 30° über dem Horizont (entspricht einem Zenitwinkel von 70°) und strahlte aus südlicher Richtung (Azimutwinkel von 183° bis 202°) auf das Aufnahmegebiet ein. Das verwendete Datenmaterial ist in 10 Flugstreifen unterteilt. Sie werden im folgenden mit den T1 bis T10 bezeichnet. Im Anhang (Abb. A - 1 bis Abb. A - 7) befinden sich Abbildungen, die einen Überblick über den Inhalt der Flugstreifen T1 bis T10 vermitteln. Es wurden jeweils drei Flugstreifen (mit Ausnahme von Flugstreifen T9) nebeneinander dargestellt. Aufgrund der Länge der Flugstreifen wurden sie geteilt und in zwei Abbildungen aufgeteilt. Im Fall des Flugstreifens T9 wurden die Teile direkt nebeneinander gestellt. In jedem Flugstreifen ist, mit Ausnahme von T9, ein waagerechter schwarzer Streifen zu erkennen. Diese Streifen sind bei der Datenaufbereitung durch die DLR entstanden. Die DLR hat die langen Flugstreifen in zwei Dateien aufgespalten. Die Dateien beginnen und enden jeweils mit zwei Scanzeilen, deren Grauwerte alle den Wert null enthalten. Die Flugstreifen sind noch panoramaverzerrt.

4 Überwachte Klassifikation von Multispektralbildern

Der Flugstreifen T1 umfaßt 7601 Scanzeilen. Er enthält die Scannerdaten aus einem Überflug über die Startbahn des Nürnberger Flughafen. Die Startbahn ist von Grasflächen umgeben. Am Anfang des Flugstreifen (Scanzeile 400 bis 800) befindet sich eine kleine Ortschaft mit dem Namen „Buch“. Sie ist von Feldern (landwirtschaftliche Nutzflächen) umgeben. Am Ende des Flugstreifen (Scanzeile 6000 bis 7600) erkennt man ein größeres Waldgebiet. Es ist Teil des „Sebalder Reichswaldes“.

Der Flugstreifen T2 umfaßt 7831 Scanzeilen. Der Flugweg, bei der Aufnahme von T2, erfolgte parallel und mit leichtem Versatz zu T1 (ca. 60% Überdeckung). Der Inhalt ist dem von T1 deshalb sehr ähnlich. Am rechten Rand des Flugstreifens ist, im Bereich von Scanzeile 800 bis 1000, ein See (als dunkler ovaler Fleck) zu erkennen.

Der Flugstreifen T3 umfaßt 7633 Scanzeilen. Der Flugweg liegt wieder parallel zu dem von T1. Besonders interessant an diesem Flugstreifen ist das Gewerbegebiet im Bereich von Scanzeile 5300 bis 6000.

Der Flugstreifen T4 umfaßt 7191 Scanzeilen. Der Bereich von Scanzeile 0 bis 4000 wird überwiegend von Wohngebieten geprägt. Im Bereich von Scanzeile 2500 bis 3500 kann man ein Wohn- und Gewerbegebiet erkennen, das überwiegend aus Gebäuden mit flachen Dächern besteht. Im restlichen Teil des Flugstreifen überwiegen Felder.

Der Flugstreifen T5 umfaßt 7641 Scanzeilen. Da dieser Flugstreifen leicht versetzt zu T4 aufgenommen wurde, ist sein Inhalt dem Inhalt von T4 wiederum sehr ähnlich.

Der Flugstreifen T6 umfaßt 7212 Scanzeilen. Er verläuft parallel zu T4 und T5. Besonders auffällig ist die Parkanlage („Volkspark Marienburg“) in der Mitte des Flugstreifens (Scanzeile 3700 bis 5300).

Der Flugstreifen T7 umfaßt 6961 Scanzeilen. Im Bereich von Scanzeile 0 bis 2700 befindet sich ein größeres Wohn- und Gewerbegebiet mit einem kleinem Bahnhof („Bahnhof Nürnberg Nord-Ost“). An dieses Gebiet schließt wieder die Parkanlage aus T6 an. Der Rest des Flugstreifens wird überwiegend von Feldern und einem weiteren kleineren Wohn- und Gewerbegebiet geprägt.

Der Flugstreifen T8 umfaßt 6521 Scanzeilen. Er verläuft entlang eines Flusses („Pegnitz“). Die Autobahnauffahrt am Ende des Flugstreifens (Scanzeile 5600 bis 6000) gehört zur „Autobahn A3“, welche quer zur Flugrichtung verläuft.

Der Flugstreifen T9 umfaßt 2981 Scanzeilen. Die erste Hälfte (Scanzeile 0 bis 1000) des Flugstreifen wird von einem großen See geprägt. Am linken Rand des Flugstreifens im Bereich von Scanzeile 1500 befindet sich der „Bahnhof Nürnberg Ost“. In der zweiten Hälfte des Flugstreifens verläuft wieder der Fluß „Pegnitz“ und die Eisenbahnlinie, die zum Bahnhof führt.

Der Flugstreifen T10 umfaßt 6021 Scanzeilen. Im Bereich von Scanzeile 0 bis 1000 befindet sich ein kleines Wohngebiet. Es ist Teil der Ortschaft „Großgründlach“. Der übrige Teil des Flugstreifen enthält überwiegend Felder, einige Baumreihen und ein Waldstück, das zum „Sebalder Reichswald“ gehört.

4.3 Festlegung des Klassifikationszieles

Wenn man die Beschreibung des Datenmaterials im vorherigen Abschnitt genauer betrachtet, wird man feststellen, daß für die Beschreibung bereits Klassenbezeichnungen, wie z.B. „Gewerbegebiet“ verwendet wurden. Dies ist unvermeidlich und verdeutlicht, wie wichtig die Klassifikation für das menschliche Denken ist. Allerdings sind diese Klassen nicht unbedingt für eine computergestützte Klassifikation geeignet. Für die Beurteilung, ob eine Klassenbezeichnung geeignet ist, lassen sich drei Kriterien einführen:

- 1. Kriterium:** Die Merkmale, die dem Klassifikationsprogramm zur Verfügung stehen, genügen für eine ausreichende Abgrenzung der entsprechenden Klasse von den übrigen Klassen.
- 2. Kriterium:** Der Informationsgehalt, den die entsprechende Klasse vermittelt, rechtfertigt die Aufstellung der Klasse.
- 3. Kriterium:** Die Wahrscheinlichkeit für das Auftreten von Objekten (Pixel) der entsprechenden Klasse ist ausreichend hoch.

Ein wichtiger Aspekt, der bei der Festlegung der Klassen von Bedeutung ist, ist die Auflösung mit der das Gebiet aufgenommen wurde. Im dritten Kapitel wurde erwähnt, daß die Größe der Fläche, die einem Pixel entspricht, zwischen $(0,64\text{m})^2$ und $(1,2\text{m})^2$ liegt (bei 300m Flughöhe). Bei der Betrachtung eines Gebietes in dieser Auflösung, drängt sich dem menschlichen Betrachter eine andere Klasseneinteilung auf, als bei der Betrachtung des Bildmaterials im Anhang (Abb. A - 1 bis Abb. A - 7). Abb. 17 zeigt einen Ausschnitt aus dem in Flugstreifen T4 entdeckten Wohn- und Gewerbegebiet. Nach einer längeren Betrachtung von Abb. 17 und den Abb. A - 1 bis Abb. A - 7 könnte man zu der in Tabelle 5 dargestellten Klasseneinteilung kommen. Ob man zu dieser Einteilung kommt, hängt von der Bewertung der obigen Kriterien ab. So sprechen das erste und das dritte Kriterium beispielsweise gegen die Klasse „Fahrzeuge“. Jedoch kann der Informationsgehalt der Klasse (zweites Kriterium) für einen Anwender (z.B. Verkehrsplaner) so wichtig sein, daß es die anderen beiden Kriterien überwiegt. Da die Bewertung der Kriterien so individuell ist, ist die in dieser Arbeit eingeführte Klasseneinteilung sicher kritisierbar. Deshalb werden im folgenden die Gründe dargelegt, die zur Aufstellung einiger Klassen geführt haben.

Die Klassen „Wiese(sch)“ und „Strasse(sch)“ wurden aufgestellt, weil sie nicht nur die Information vermitteln, daß sich an der entsprechenden Stelle ein Stück von einer Wiese oder einer Straße befindet, sondern weil sie zusätzlich die Information beinhalten, daß sich in der Nähe ein höheres Objekt (z.B. Baum oder Gebäude) befindet. Diese Information könnte von einem Klassifikationsprogramm genutzt werden, um die Klassifikation dieser Objekte zu verbessern. Die Klasse „Fassade“ könnte ebenfalls zur Verbesserung der Klassifikation von Gebäuden beitragen. Die Klasse „Flughafenmarkierung“ könnte hilfreich sein, wenn man versucht, in einer Klassifikation über ein größeres Gebiet (z.B. mehrere Flugstreifen) Straßenpixel von Pixeln der Startbahn zu trennen.

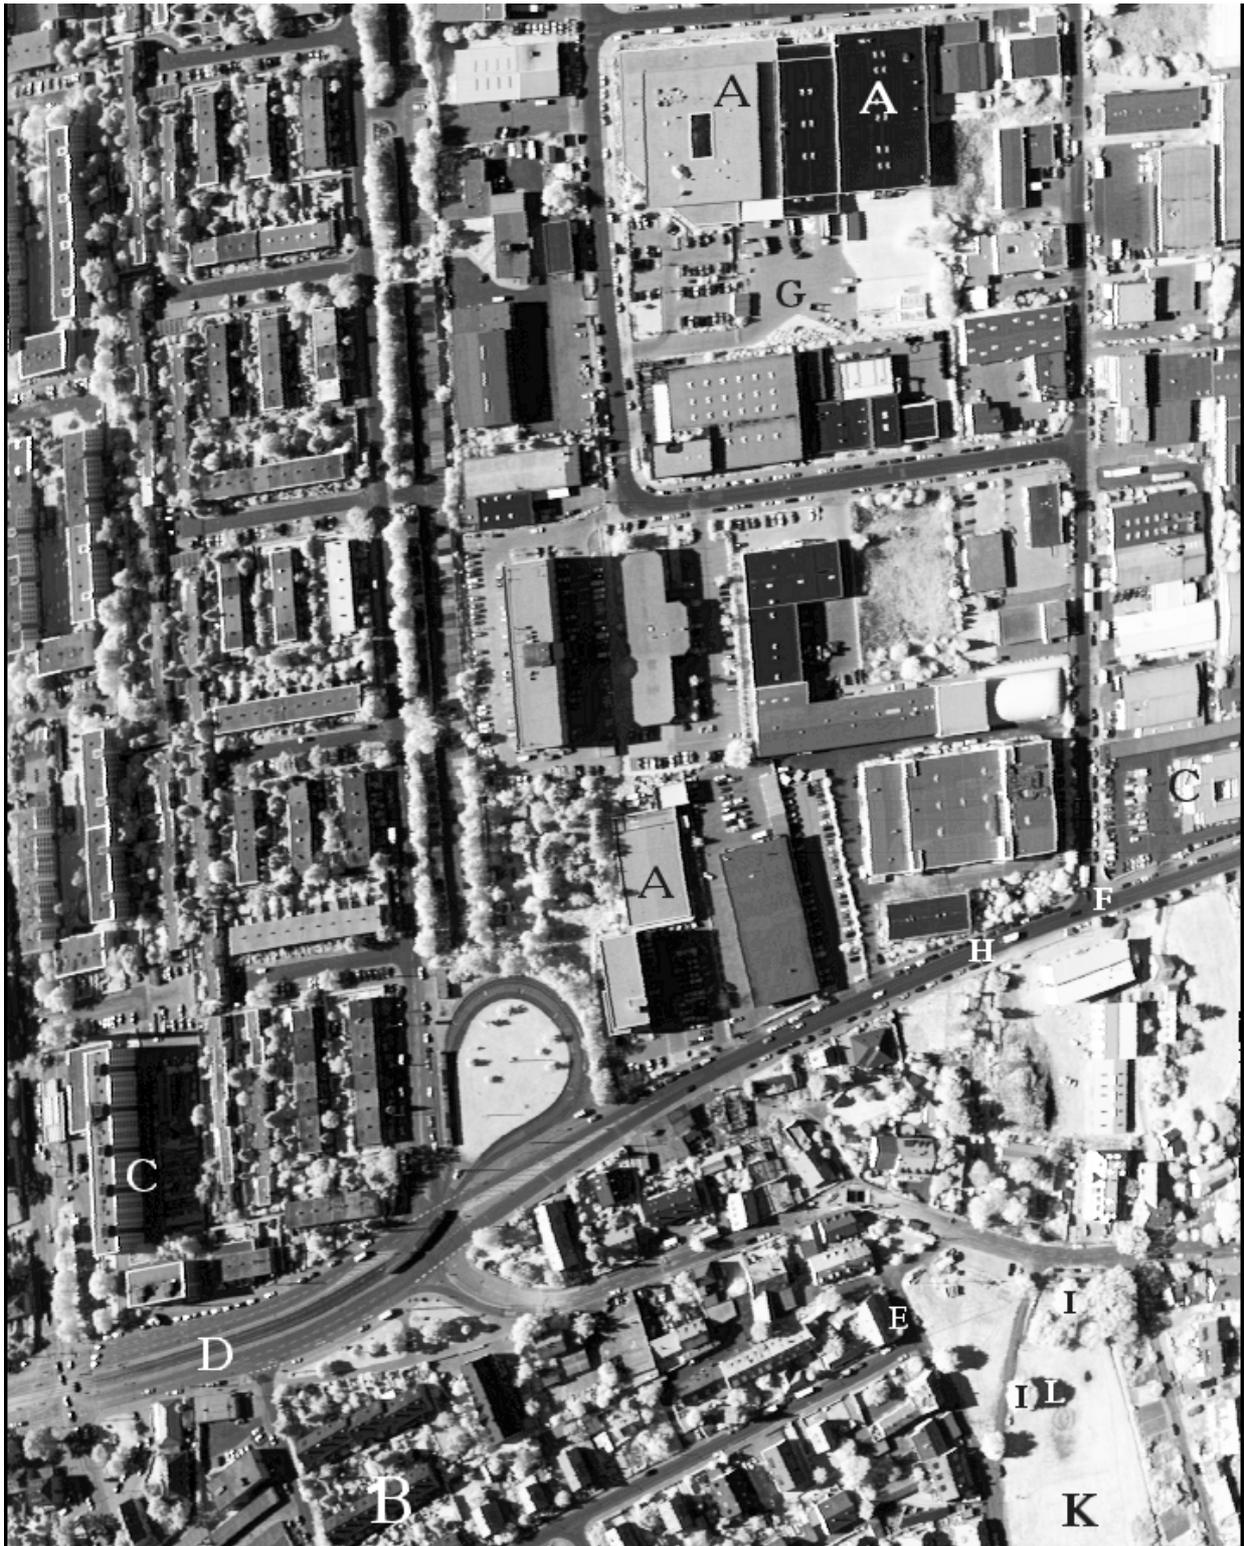


Abb. 17: Bildausschnitt aus dem Flugstreifen T4 (Scanzeile 2200 bis 3100, Spektralkanal Nr. 7 (0,76 - 0,90 μm), kontrastverstärkt). Die Buchstaben markieren Orte, in deren Nähe Objekte zu finden sind, die zu den in **Tabelle 5** definierten Klassen gehören.

Klassenbezeichnung	Beschreibung	Fundort
Flachdach	Dächer ohne geneigte Dachhälften	Abb. 17 Markierung A
Spitzdach(bel)	Dächer mit geneigten Dachhälften und von der Globalstrahlung beleuchtet.	Abb. 17 Markierung B
Spitzdach(sch)	Dächer mit geneigten Dachhälften und von der Himmelsstrahlung beleuchtet. Sie sind also beschattet.	Abb. 17 Markierung B
Fassade	Seitenwände von Gebäuden, die von der Global- oder Himmelsstrahlung beleuchtet werden.	Abb. 17 Markierung C
Strasse(bel)	Straßen, die von der Globalstrahlung beleuchtet werden.	Abb. 17 Markierung D
Strasse(sch)	Straßen, die von der Himmelsstrahlung beleuchtet werden.	Abb. 17 Markierung E
Bürgersteig	Gebiete, die an die Straßen angrenzen und sich von diesen, aufgrund ihrer spektralen Eigenschaften, abgrenzen.	Abb. 17 Markierung F
Parkplatz	Gebiete abseits von Straßen, auf denen parkende Fahrzeuge zu erkennen sind.	Abb. 17 Markierung G
Fahrzeuge	Objekte aus ca. 6 bis 12 Pixeln, die sich auf Straßen, Bürgersteigen oder Parkplätzen befinden.	Abb. 17 Markierung H
Bäume	Objekte, die Schatten werfen und auf den Luftphotos rötlich erscheinen	Abb. 17 Markierung I
Wiese(bel)	Grasflächen, die von der Globalstrahlung beleuchtet werden.	Abb. 17 Markierung K
Wiese(sch)	Grasflächen, die von der Himmelsstrahlung beleuchtet werden.	Abb. 17 Markierung L
Felder(bew)	Gebiete, auf denen landwirtschaftliche Nutzpflanzen angebaut werden.	Abb. A - 1 (T1) Scanzeile 0 - 400
Erdreich	Gepflügte Felder, so daß der Erdboden die spektralen Eigenschaften des Gebietes bestimmt.	Abb. A - 1 (T1) Scanzeile 0 - 400
Eisenbahn	Gebiete, in denen sich Eisenbahnzüge bewegen können.	Abb. A - 7 (T9) ab Scanzeile 1200
Gewässer	Flüsse, Teiche und größere Seen	Abb. A - 7 (T9) bis Scanzeile 1100
Markierung(Flughafen)	Stark reflektierende Flächen auf der Startbahn des Nürnberger Flughafens	Abb. A - 1 (T1) Scanzeile 2200
Vorfeld(Flughafen)	Das Gebiet zwischen der Rollbahn und den Terminalgebäuden	Abb. A - 1 (T2) Scanzeile 3000 - 4000

Tabelle 5: Übersicht über die im folgenden verwendeten Klassen. Die Rubrik „Fundort“ gibt Auskunft darüber, wo Exemplare der jeweiligen Klasse zu finden sind.

4.4 Beschreibung des Stichprobenmaterials

Für die Durchführung der weiteren Untersuchungen ist es notwendig, daß aus dem verwendeten Datenmaterial Gebiete ausgewählt werden und einer der in Kapitel 4.3 festgelegten Klassen zugeteilt werden. Diese Gebiete werden im folgenden als *Stichproben* bezeichnet.

Vor der Auswahl der Stichproben wurden zunächst die einzelnen Bilddateien in den Speicher des Computers geladen und aus den Bilddateien quadratische Bildausschnitte mit einer Größe von 50 x 50 Pixeln herausgeschnitten. Diese Maßnahme diente der besseren Handhabung der Datenmengen. In den ausgewählten Bildausschnitten wurden die Gebiete für die eigentlichen Stichproben mit Hilfe geschlossener Polygone festgelegt. Die Koordinaten der Eckpunkte der Polygone wurden, zusammen mit den Angaben über die Herkunft des jeweiligen Bildausschnitts, in einer Datei gespeichert. Im Anhang auf Seite 111 befindet sich (als Beispiel) ein Auszug aus einer derartigen Datei.

Für das Setzen der Eckpunkte wurden die Bilddaten des Spektralkanals Nr. 7 des jeweiligen Bildausschnitts auf dem Monitor kontrastverstärkt dargestellt. Diese Art der Darstellung hatte zur Folge, daß bei der Festlegung der Gebiete hauptsächlich die Merkmale Form, Größe und Helligkeit eine Rolle spielten. Die Entscheidung, welcher Klasse ein Gebiet zugewiesen werden soll, wurde anhand der Luftphotos getroffen, da diese nicht nur eine bessere räumliche Auflösung besaßen, sondern durch ihre Farbe zusätzliche spektrale Informationen vermittelten.

Die Zahl der Gebiete, die für die einzelnen Klassen ausgewählt wurden, und die Gesamtzahl der Pixel, die sie enthielten, ist der Tabelle 6 zu entnehmen. Einige Stichproben befinden sich, mit den aus ihnen errechneten Spektren, im Anhang (Abb. A - 8 bis Abb. A - 27). Während der Durchführung der Stichprobenerhebung zeigte es sich, daß sich die Stichproben, die für die festgelegten Klassen ausgewählt wurden, in weitere *Unterklassen* einteilen lassen. Diese Unterklassen besitzen zumindest teilweise unterschiedliche spektrale Merkmale. Im folgenden werden einige der Klassen, durch eine Darlegung die gefundenen Unterklassen und der entdeckten Auffälligkeiten, beschrieben.

Klassenbezeichnung	Anzahl der Stichproben	Gesamtzahl der Pixel in den Stichproben	Klassenbezeichnung	Anzahl der Stichproben	Gesamtzahl der Pixel in den Stichproben
Flachdach	120	80217	Bäume	49	11715
Spitzdach(bel)	102	14741	Wiese(bel)	39	34437
Spitzdach(sch)	74	9434	Wiese(sch)	32	7984
Fassade	54	4684	Felder(bew)	36	23501
Strasse(bel)	56	17330	Erdreich	30	37624
Strasse(sch)	35	4076	Eisenbahn	8	1484
Bürgersteig	45	2887	Gewässer	30	30718
Parkplatz	23	10488	Markierung (Flughafen)	7	282
Fahrzeuge	16	2801	Vorfeld (Flughafen)	9	3377

Tabelle 6: Übersicht über die Anzahl der Pixel, die für die Klassen ausgewählt wurden

Die Existenz von Unterklassen war am deutlichsten an der Klasse Flachdach zu erkennen. Die Proben dieser Klasse unterschieden sich vor allem durch das für den Bau des Daches verwendete Baumaterial. Welche Baumaterialien im einzelnen verwendet wurden, konnte anhand der Luftbilder nicht festgestellt werden. Außerdem kann man an einigen Stichproben beobachten

(z.B. Stichprobe „Flachdach 2“ in Abb. A - 8), daß die spektralen Eigenschaften der Baumaterialien zeitlichen Veränderungen unterliegen können. Derartige Effekte verursachen eine Verwischung der Grenzen zwischen den Unterklassen, so daß eine Einteilung der Stichproben in Unterklassen nicht möglich war. Ein Problem bei der Erhebung der Stichproben für die Klasse Flachdach bereiteten die zahlreichen Aufbauten, wie beispielsweise die stark reflektierenden Abdeckungen der Lichtschächte auf einigen Dächern (siehe z.B. „Flachdach 12“ in Abb. A - 8). Die Pixel dieser Aufbauten wurden nicht in die Stichproben aufgenommen, weil aus einigen Stichproben zu einem späteren Zeitpunkt Trainingsklassen generiert werden sollten. Die Hinzunahme der Aufbauten hätte bedeutet, daß die Grauwerte der Pixel in der Stichprobe nicht mehr normalverteilt wären. Dies ist aber die Voraussetzung für Trainingsklassen des „Maximum Likelihood“-Verfahrens.

Die Klasse Spitzdach(bel) läßt sich in zwei spektral recht verschiedene Unterklassen unterteilen. Die eine Klasse bilden Dächer mit roten Dachziegeln (z.B. Stichprobe „Spitzdach(bel) 7“ in Abb. A - 12). Die andere Klasse bilden Dächer mit schwarzen Dachziegeln (z.B. Stichprobe „Spitzdach(bel) 6“ in Abb. A - 12).

In der Klasse „Spitzdach(sch)“ wurden die Unterschiede zwischen den Dächern mit roten und mit schwarzen Dachziegeln ebenfalls beobachtet. Allerdings traten sie nicht so deutlich in Erscheinung. Denn die beschatteten Dachhälften wurden nicht nur mit der Himmelstrahlung, sondern in Wirklichkeit auch noch, in Abhängigkeit ihrer Neigung, mit einem Anteil aus der direkten Sonnenstrahlung beleuchtet.

In der Klasse „Fassade“ gibt es zwei Gruppen, die sich spektral erheblich unterscheiden. Die eine Gruppe bilden alle Seitenwände, die von der Globalstrahlung beleuchtet werden, und die andere Gruppe bilden die Seitenwände die nur von der Himmelsstrahlung beleuchtet werden.

Die Objekte in der Klasse „Fahrzeuge“ unterscheiden sich vor allem in der Farbe, mit der sie lackiert wurden. Fahrzeuge, die mit dunkler Farbe lackiert wurden, unterschieden sich in der für die Stichprobenerhebung gewählten Darstellung kaum von der Straße. Deshalb wurden die Polygone nicht um einzelne Fahrzeuge gelegt, sondern um Ansammlungen dicht parkender Fahrzeuge (siehe „Fahrzeuge 1“ in Abb. A - 26).

Die Klasse „Bäume“ könnte man in zwei wichtige Unterklassen aufteilen, und zwar in die Klassen Laubbäume und Nadelbäume. Die Spektren der Laubbäume liegen im Mittel höher als die Spektren der Nadelbäume.

In der Klasse „Felder(bew)“ war eine große Vielfalt an unterschiedlichen Spektren zu beobachten. Einige der Ursachen für diese Vielfalt sind sicher die unterschiedlichen Reifegrade und die Dichte des Pflanzenwuchses. Inwieweit unterschiedliche Pflanzenarten für die Vielfalt verantwortlich waren, konnte anhand der Luftphotos nicht geklärt werden.

In Kapitel 2.3.1 (Statistische Grundlagen) wurde darauf hingewiesen, daß eine Stichprobenerhebung den Zweck hat, die aus den Stichproben abgeleiteten Aussagen auf die Grundgesamtheit zu übertragen. Da die Stichproben nur aus dem Bildmaterial des Jahres 1994 entnommen wurden, sind auch nur sichere Aussagen über das Bildmaterial dieses Jahres möglich. Die Übertragbarkeit der Ergebnisse auf die Bilddaten eines anderen Jahres werden vor allem durch systematische Veränderungen zwischen den Bilddaten der verschiedenen Jahren, wie z.B. unterschiedlicher Sonnenstand und Jahreszeit, begrenzt.

4.5 Prüfung der Erreichbarkeit des Klassifikationszieles

Eine Klassifikation kann nur dann erfolgreich sein, wenn die Annahme, daß die Objekte (Pixel) der verschiedenen Klassen im Merkmalsraum von einander getrennte Gruppen bilden, möglichst gut erfüllt ist. Die theoretische Grenze der erreichbaren Klassifikationsgenauigkeit wird nur durch die Trennbarkeit dieser Gruppen beeinflusst. In der Praxis kommt noch das Problem hinzu, daß die Position der Gruppen im Merkmalsraum nicht genau bekannt ist. Außerdem können die Pixel einer Klasse im Merkmalsraum in mehreren getrennten Gruppen verteilt sein, so daß man eventuell mehrere Trainingsklassen benötigt, damit die Pixel aller Untergruppen der richtigen Klasse zugewiesen werden.

In der folgenden Untersuchung wird nicht versucht, die theoretische Grenze zu finden, sondern es wird untersucht, wie weit die Pixel, die einer gemeinsamen Klasse angehören, im Merkmalsraum verteilt sind. Gleichzeitig wird untersucht, welche Klassen sich spektral ähnlich sind.

4.5.1 Durchführung der Untersuchung

Der erste Schritt der Untersuchung besteht darin, daß für jede Klasse im Merkmalsraum die optimale Lage des Mittelpunktes ihrer Trainingsklasse gefunden werden muß. Diese Suche erweist sich als schwierig, da die optimale Lage des Mittelpunktes nicht von den Pixeln der jeweiligen Klasse allein abhängt, sondern auch von den Pixeln der übrigen Klassen. Beim „Maximum Likelihood“-Verfahren kommt noch die Bestimmung der optimalen Kovarianzmatrix erschwerend hinzu.

Eine mögliche Lösung für dieses Problem besteht darin, daß man in einem iterativen Prozeß die Mittelpunkte (und die Werte der Kovarianzmatrizen) der Klassen solange variiert, bis die größtmögliche Anzahl an Pixeln, bei der Klassifikation, richtig zugewiesen wird. Dieses Verfahren ist sehr rechenintensiv. Außerdem sind die optimalen Klassenmittelpunkte in der Praxis ohnehin nur sehr selten bekannt, weshalb die Ergebnisse für die Praxis auch nicht repräsentativ wären. Aus diesem Grund wurde für die Untersuchung eine *andere Vorgehensweise* gewählt. Zunächst wurden für jede Stichprobe die Mittelwerte berechnet, die sich aus den Grauwerten ihrer jeweiligen Pixel ergaben. Diese Mittelwerte definieren einen Punkt (*Mittelpunkt*) im Merkmalsraum für die gesamte Stichprobe. Im Anschluß wurde für jede Stichprobe die euklidischen Abstände $d(\vec{m}_i, \vec{m}_k)$ zwischen ihrem Mittelpunkt und den Mittelpunkten der übrigen Stichproben ihrer Klasse berechnet. Die Abstände wurden aufsummiert und durch die Anzahl N der beteiligten Stichproben geteilt:

$$\bar{d}_i = \frac{\sum_{k=1}^N d(\vec{m}_i, \vec{m}_k)}{N} \quad (\text{Gl. 22})$$

Für jede Klasse wurde die Stichprobe gesucht, die zu den übrigen Stichproben ihrer Klasse den geringsten mittleren euklidischen Abstand \bar{d}_i besaß. Diese Stichproben wurden im Rahmen der Untersuchung als *Trainingsklassen* eingesetzt. Sie sind vermutlich nicht die optimalsten Trainingsklassen. Aber sie sollten zumindest repräsentativ sein und zu verhältnismäßig guten Klassifikationsergebnissen führen. Abb. 18 enthält die gemittelten Spektren der als Trainingsklassen ausgewählten Stichproben.

4.5 Prüfung der Erreichbarkeit des Klassifikationszieles

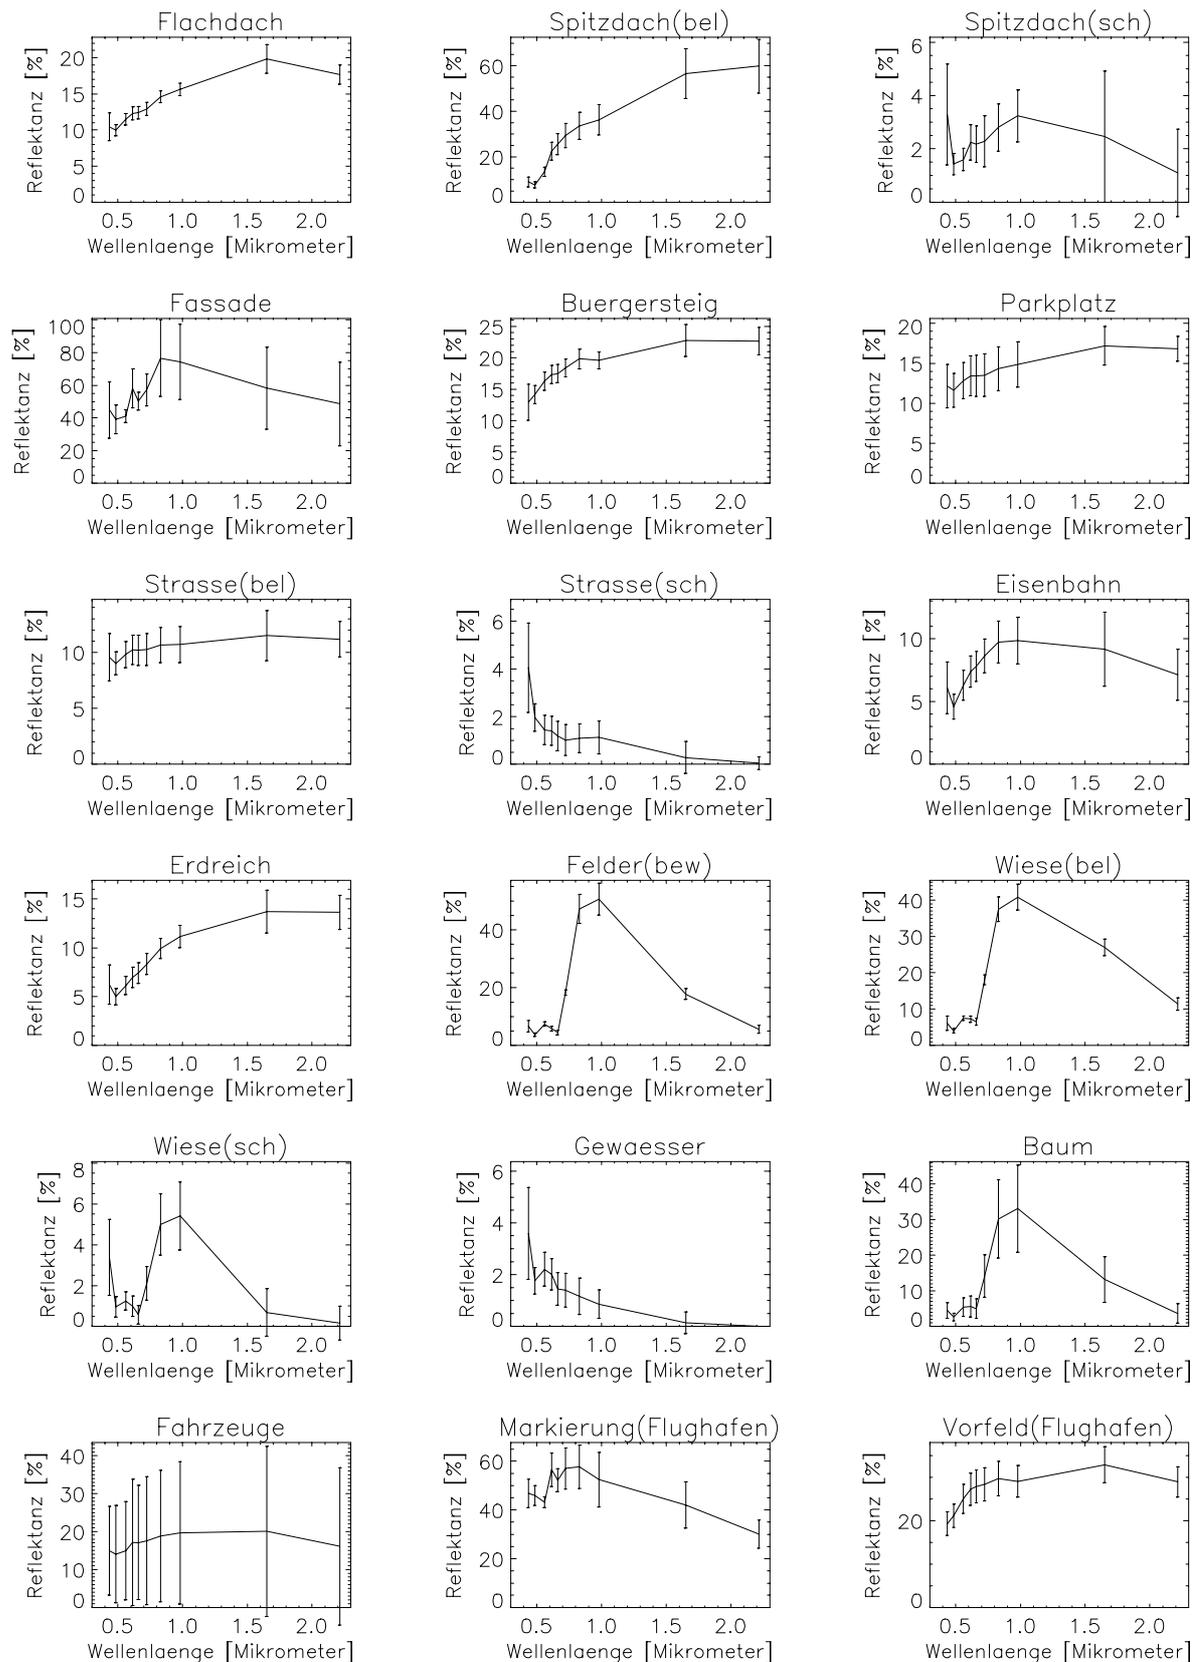


Abb. 18: Darstellung der gemittelten Spektren, die aus den Pixeln der Stichproben berechnet wurden, die als Trainingsklassen ausgewählt wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe. Man beachte, die unterschiedliche Skalierung der y-Achse.

4 Überwachte Klassifikation von Multispektralbildern

Anschließend wurden die Pixel der nicht zum Training verwendeten Stichproben klassifiziert. Hierfür wurden die Pixel aller übriggebliebenen Stichproben klassenweise zu Gruppen zusammengefaßt. Für die Klasse „Flachdach“ (siehe Tabelle 6) bedeutet dies, daß die Pixel der 119 übriggebliebenen Stichproben zu einer Gruppe zusammengestellt wurden. Diese Gruppen aus Kontrollpixeln wurden getrennt voneinander jeweils fünfmal klassifiziert. Dabei wurde die erste Klassifikation mit allen 18 Trainingsklassen durchgeführt (Stufe 1). Unter den 18 Trainingsklasse gab es 17 Klassen, die nicht zu der Klasse gehörten, deren Pixel gerade klassifiziert wurden. Unter diesen 17 Klassen wurde nun diejenige gesucht, der die meisten Pixel zugewiesen wurden. Die entsprechende Klasse („größter Störenfried“) wurde aus den weiteren Klassifikationen ausgeschlossen. Anschließend wurde mit den übrigen 17 Trainingsklassen erneut klassifiziert und wieder der „größte Störenfried“ ausgesondert (Stufe 2). Diese Vorgehensweise wurde iterativ wiederholt. Es wurde sowohl mit dem „Minimum Distance“ als auch mit dem „Maximum Likelihood“-Verfahren klassifiziert.

Tabelle 7 bis Tabelle 24 zeigen die Ergebnisse, die sich aus den fünf Stufen der Iterationen für die verschiedenen Klassen ergaben. Die erste Zeile in jeder Tabelle enthält Angaben darüber, wieviel Prozent der Pixel der richtigen Klasse zugewiesen wurden. Die Zeilen zwei bis fünf geben Auskunft darüber, wieviel Prozent der Pixel den vier größten Störenfrieden zugeteilt wurden. In Zeile sechs und sieben wurden die Trainingsklassen eingesetzt, denen in Stufe 5, neben der richtigen Klasse, die meisten Pixel zugewiesen wurden.

Zur Veranschaulichung der Ergebnisse in den Tabellen dient Abb. 19. Diese Abbildung zeigt eine zwei-dimensionale Projektion aus dem Merkmalsraum. In diesem „reduzierten“ Merkmalsraum wurden alle 230 Kontrollpixel der Klasse „Markierung (Flughafen)“ eingezeichnet. Alle mit dem „Minimum Distance“-Verfahren in Stufe 1 richtig klassifizierten Pixel wurden mit einem „+“-Symbol markiert. Die übrigen Pixel wurden entsprechend dem Klassifikationsergebnis mit einem „x“ oder „*“-Symbol markiert (vergleiche Tabelle 23 („Minimum Distance“, Stufe 1) mit Abb. 19).

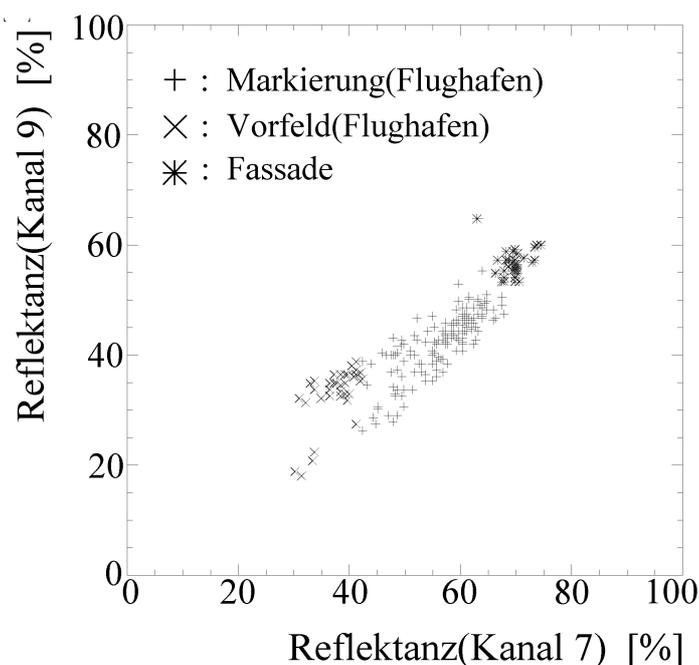


Abb. 19: Darstellung zur Veranschaulichung der Ergebnisse in Tabelle 23 („Minimum Distance“, Stufe 1). Es wurden die Spektralkanäle 5 und 7 verwendet.

4.5 Prüfung der Erreichbarkeit des Klassifikationszieles

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Flachdach	21,0	23,7	34,6	38,6	57,6	Flachdach	9,6	11,2	11,8	13,6	25,6
Bürgersteig	23,0	---	---	---	---	Fahrzeuge	39,4	---	---	---	---
Fahrzeuge	2,2	20,3	---	---	---	Parkplatz	18,0	20,8	---	---	---
Vorfeld(Flughafen)	10,8	13,0	16,3	---	---	Vorfeld(Flughafen)	8,9	20,4	30,8	---	---
Parkplatz	9,6	9,6	15,6	20,8	---	Strasse(bel)	11,6	15,1	23,4	30,1	---
Strasse(bel)	10,7	10,7	10,7	10,7	12,4	Bürgersteig	4,2	6,9	7,3	22,1	30,6
Eisenbahn	5,3	5,3	5,3	5,3	5,3	Fassade	0,4	7,4	7,4	13,2	13,3

Tabelle 7: Ergebnisse der Klassifikation der (80035) Pixel der Klasse „**Flachdach**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Spitzdach(bel)	48,6	48,6	49,1	49,1	49,2	Spitzdach(bel)	13,0	53,8	66,1	71,3	74,5
Flachdach	11,3	---	---	---	---	Fahrzeuge	70,5	---	---	---	---
Bürgersteig	9,1	10,4	---	---	---	Fassade	2,8	23,1	---	---	---
Parkplatz	0,9	10,1	11,8	---	---	Vorfeld(Flughafen)	1,3	4,4	9,6	---	---
Fahrzeuge	2,1	2,2	9,9	18,7	---	Eisenbahn	5,0	7,9	8,9	9,0	---
Strasse(bel)	2,5	2,7	2,7	3,9	14,4	Erdreich	2,7	4,1	4,1	4,3	7,3
Eisenbahn	6,2	6,2	6,2	6,2	6,2	Markierung(Flughafen)	0,0	0,2	3,7	3,8	4,1

Tabelle 8: Ergebnisse der Klassifikation der (14627) Pixel der Klasse „**Spitzdach(bel)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Spitzdach(sch)	51,7	53,4	77,1	82,3	86,0	Spitzdach(sch)	52,4	53,0	54,2	64,8	71,0
Strasse(sch)	21,1	---	---	---	---	Fahrzeuge	8,8	---	---	---	---
Gewässer	4,4	23,7	---	---	---	Strasse(sch)	8,8	8,9	---	---	---
Eisenbahn	11,0	11,0	11,0	---	---	Gewässer	6,7	6,8	14,3	---	---
Erdreich	2,3	2,3	2,3	7,2	---	Wiese(sch)	5,7	5,8	5,8	9,1	---
Strasse(bel)	0,1	0,1	0,1	0,3	3,8	Erdreich	6,7	7,9	7,9	7,9	7,9
Fahrzeuge	2,6	2,6	2,6	2,6	2,6	Eisenbahn	4,6	5,8	5,8	6,0	6,0

Tabelle 9: Ergebnisse der Klassifikation der (9331) Pixel der Klasse „**Spitzdach(sch)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Fassade	55,8	78,0	81,1	81,1	81,1	Fassade	38,3	78,6	80,3	88,3	88,4
Markierung(Flughafen)	25,4	---	---	---	---	Fahrzeuge	59,9	---	---	---	---
Vorfeld(Flughafen)	3,6	6,8	---	---	---	Spitzdach(bel)	0,0	9,7	---	---	---
Eisenbahn	5,3	5,3	5,3	---	---	Markierung(Flughafen)	0,0	8,0	8,0	---	---
Strasse(bel)	3,7	3,7	3,7	7,2	---	Strasse(bel)	0,0	0,9	5,2	5,2	---
Erdreich	0,0	0,0	0,0	0,0	5,8	Vorfeld(Flughafen)	0,0	0,5	2,2	2,2	5,4
Felder(bew)	1,9	1,9	2,0	2,0	2,0	Eisenbahn	0,0	0,3	1,2	1,2	1,8

Tabelle 10: Ergebnisse der Klassifikation der (4550) Pixel der Klasse „**Fassade**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Strasse(bel)	31,4	53,9	55,5	63,4	66,8
Eisenbahn	36,1	---	---	---	---
Parkplatz	16,1	16,1	---	---	---
Flachdach	3,9	3,9	16,2	---	---
Fahrzeuge	4,2	4,2	6,3	13,5	---
Bürgersteig	6,0	6,0	6,0	6,9	17,0
Erdreich	1,2	10,9	10,9	11,2	11,2

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Strasse(bel)	70,1	77,9	78,5	80,8	85,9
Parkplatz	15,4	---	---	---	---
Bürgersteig	3,7	6,2	---	---	---
Vorfeld(Flughafen)	0,6	3,9	8,2	---	---
Fahrzeuge	3,5	4,1	4,8	9,5	---
Flachdach	4,2	5,5	6,2	7,4	9,8
Spitzdach(bel)	1,4	1,4	1,4	1,4	2,8

Tabelle 11: Ergebnisse der Klassifikation der (16556) Pixel der Klasse „**Strasse(bel)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Strasse(sch)	77,8	93,4	98,7	99,8	100,0
Gewässer	16,5	---	---	---	---
Spitzdach(sch)	5,6	6,4	---	---	---
Wiese(sch)	0,2	0,2	1,1	---	---
Eisenbahn	0,0	0,0	0,2	0,2	---

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Strasse(sch)	68,6	94,7	96,6	97,6	98,2
Gewässer	27,2	---	---	---	---
Spitzdach(sch)	2,2	2,7	---	---	---
Fahrzeuge	1,5	1,8	2,0	---	---
Wiese(sch)	0,4	0,6	1,0	1,1	---
Strasse(bel)	0,2	0,2	0,2	0,7	0,7
Spitzdach(bel)	0,0	0,0	0,0	0,2	0,2

Tabelle 12: Ergebnisse der Klassifikation der (3937) Pixel der Klasse „**Strasse(sch)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Bürgersteig	45,9	47,2	49,7	75,0	86,7
Flachdach	14,9	---	---	---	---
Parkplatz	7,4	19,8	---	---	---
Fahrzeuge	14,5	14,9	27,5	---	---
Vorfeld(Flughafen)	12,2	12,2	12,2	12,2	---
Strasse(bel)	1,5	1,6	5,7	7,7	7,7
Wiese(bel)	1,7	1,8	1,8	1,8	1,8

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Bürgersteig	34,7	44,1	55,1	67,8	74,8
Vorfeld(Flughafen)	24,7	---	---	---	---
Fahrzeuge	15,4	27,3	---	---	---
Parkplatz	10,1	13,3	16,5	---	---
Flachdach	7,6	7,8	8,4	8,9	---
Fassade	0,0	0,0	7,8	8,2	8,2
Strasse(bel)	2,4	2,4	2,8	5,7	6,6

Tabelle 13: Ergebnisse der Klassifikation der (2850) Pixel der Klasse „**Bürgersteig**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Parkplatz	11,5	16,5	16,5	16,5	42,5
Strasse(bel)	26,8	---	---	---	---
Vorfeld(Flughafen)	25,6	25,6	---	---	---
Bürgersteig	21,8	21,8	29,2	---	---
Fahrzeuge	4,3	4,3	4,3	31,7	---
Spitzdach(bel)	0,0	0,0	18,2	19,5	20,8
Erdreich	0,8	15,3	15,3	15,3	15,3

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Parkplatz	16,1	16,4	34,6	40,3	59,4
Fahrzeuge	25,9	---	---	---	---
Strasse(bel)	25,3	26,2	---	---	---
Vorfeld(Flughafen)	13,0	21,1	25,3	---	---
Bürgersteig	12,9	14,6	15,1	24,0	---
Fassade	0,0	12,9	12,9	21,5	22,8
Eisenbahn	0,0	1,9	2,3	2,3	2,8

Tabelle 14: Ergebnisse der Klassifikation der (9915) Pixel der Klasse „**Parkplatz**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

4.5 Prüfung der Erreichbarkeit des Klassifikationszieles

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Fahrzeuge	9,7	9,7	9,7	9,7	9,7	Fahrzeuge	76,7	77,7	80,2	84,9	88,1
Eisenbahn	17,3	---	---	---	---	Strasse(sch)	4,9	---	---	---	---
Spitzdach(sch)	17,2	21,7	---	---	---	Gewässer	2,6	6,0	---	---	---
Strasse(bel)	8,7	16,8	17,1	---	---	Spitzdach(sch)	4,3	4,8	8,0	---	---
Erdreich	3,5	7,6	8,2	20,5	---	Strasse(bel)	4,1	4,1	4,1	4,1	---
Wiese(sch)	1,0	1,5	15,0	15,8	25,1	Wiese(sch)	0,4	0,4	0,7	2,6	2,6
Flachdach	3,7	3,7	3,7	4,1	8,4	Parkplatz	1,3	1,3	1,3	1,3	2,0

Tabelle 15: Ergebnisse der Klassifikation der (2714) Pixel der Klasse „**Fahrzeuge**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Bäume	48,9	49,9	82,5	84,7	85,3	Bäume	91,7	97,4	98,6	99,3	99,7
Felder(bew)	23,6	---	---	---	---	Wiese(bel)	6,0	---	---	---	---
Wiese(bel)	11,5	34,1	---	---	---	Fahrzeuge	1,8	2,0	---	---	---
Eisenbahn	9,1	9,1	9,1	---	---	Fassade	0,0	0,0	0,7	---	---
Wiese(sch)	6,6	6,6	6,6	10,7	---	Wiese(sch)	0,4	0,4	0,4	0,4	---
Spitzdach(sch)	0,0	0,0	0,0	0,0	8,5	Felder(bew)	0,1	0,2	0,3	0,3	0,3
Erdreich	0,1	0,1	0,1	2,9	4,6						

Tabelle 16: Ergebnisse der Klassifikation der (11502) Pixel der Klasse „**Bäume**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Wiese(bel)	67,6	86,0	96,4	96,4	97,5	Wiese(bel)	78,0	97,5	98,8	99,6	99,7
Felder(bew)	18,4	---	---	---	---	Bäume	20,3	---	---	---	---
Bäume	12,4	12,4	---	---	---	Felder(bew)	1,2	1,3	---	---	---
Erdreich	0,3	0,3	1,7	---	---	Fahrzeuge	0,2	1,0	1,0	---	---
Flachdach	0,9	0,9	1,6	2,3	---	Fassade	0,2	0,2	0,2	0,4	---
Eisenbahn	0,0	0,0	0,0	1,0	1,5	Eisenbahn	0,0	0,0	0,0	0,0	0,1
Parkplatz	0,0	0,0	0,0	0,0	0,7	Spitzdach(bel)	0,0	0,0	0,0	0,0	0,1

Tabelle 17: Ergebnisse der Klassifikation der (33703) Pixel der Klasse „**Wiese(bel)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Wiese(sch)	87,8	89,3	90,9	96,5	98,1	Wiese(sch)	92,1	97,0	98,9	99,0	99,4
Strasse(sch)	6,6	---	---	---	---	Bäume	7,0	---	---	---	---
Gewässer	0,2	4,8	---	---	---	Fahrzeuge	0,4	2,3	---	---	---
Spitzdach(sch)	1,9	2,4	5,6	---	---	Wiese(bel)	0,1	0,2	0,6	---	---
Eisenbahn	2,9	2,9	2,9	2,9	---	Felder(bew)	0,0	0,0	0,1	0,5	---
Erdreich	0,1	0,1	0,1	0,1	1,3	Gewässer	0,2	0,2	0,2	0,2	0,2
Bäume	0,5	0,5	0,5	0,5	0,6	Eisenbahn	0,0	0,0	0,0	0,1	0,1

Tabelle 18: Ergebnisse der Klassifikation der (7448) Pixel der Klasse „**Wiese(sch)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Felder(bew)	65,5	81,6	95,9	96,1	96,1
Wiese(bel)	25,8	---	---	---	---
Bäume	7,2	16,4	---	---	---
Flachdach	1,3	1,3	2,7	---	---
Parkplatz	0,0	0,0	0,0	1,3	---
Fahrzeuge	0,0	0,0	0,3	1,0	1,4
Erdreich	0,1	0,1	0,2	0,4	0,8

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Felder(bew)	49,0	53,3	91,3	94,0	99,3
Wiese(bel)	25,2	---	---	---	---
Bäume	22,6	42,7	---	---	---
Fahrzeuge	2,3	3,2	7,4	---	---
Fassade	0,8	0,8	1,3	5,3	---
Bürgersteig	0,0	0,0	0,0	0,7	0,7

Tabelle 19: Ergebnisse der Klassifikation der (22452) Pixel der Klasse „Felder(bew)“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Erdreich	51,6	57,9	78,8	90,5	91,0
Flachdach	25,8	---	---	---	---
Eisenbahn	22,2	22,2	---	---	---
Parkplatz	0,0	19,2	19,2	---	---
Bürgersteig	0,1	0,5	0,5	4,9	---
Fahrzeuge	0,0	0,0	0,0	1,6	6,0
Strasse(bel)	0,1	0,2	0,2	1,7	1,7

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Erdreich	71,1	77,5	86,1	89,7	94,1
Fahrzeuge	19,0	---	---	---	---
Spitzdach(bel)	4,7	11,1	---	---	---
Bürgersteig	1,0	2,8	4,9	---	---
Eisenbahn	3,5	4,4	4,4	4,9	---
Bäume	0,1	3,2	3,2	3,2	3,3
Flachdach	0,4	0,7	0,7	1,1	1,1

Tabelle 20: Ergebnisse der Klassifikation der (36494) Pixel der Klasse „Erdreich“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Eisenbahn	26,0	28,6	31,1	31,7	64,6
Spitzdach(sch)	38,6	---	---	---	---
Wiese(sch)	0,0	33,1	---	---	---
Gewässer	0,0	2,8	32,4	---	---
Strasse(sch)	0,0	0,1	1,1	32,9	---
Strasse(bel)	18,3	18,3	18,3	18,3	18,3
Parkplatz	5,1	5,1	5,1	5,1	5,1

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Eisenbahn	51,7	65,1	79,7	87,4	88,9
Fahrzeuge	22,7	---	---	---	---
Spitzdach(sch)	18,2	20,5	---	---	---
Strasse(bel)	6,3	10,8	11,6	---	---
Spitzdach(bel)	0,0	0,7	1,7	3,3	---
Bäume	0,0	0,0	2,8	2,8	3,3
Strasse(sch)	0,7	1,2	2,3	2,8	3,2

Tabelle 21: Ergebnisse der Klassifikation der (1320) Pixel der Klasse „Eisenbahn“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Gewässer	76,9	98,2	99,8	100,0	100,0
Strasse(sch)	21,3	---	---	---	---
Spitzdach(sch)	1,7	1,7	---	---	---
Wiese(sch)	0,1	0,1	0,2	---	---

Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Gewässer	81,8	91,4	99,0	99,4	99,7
Fahrzeuge	9,8	---	---	---	---
Strasse(sch)	7,8	7,8	---	---	---
Wiese(sch)	0,4	0,4	0,4	---	---
Spitzdach(sch)	0,2	0,3	0,4	0,4	---
Bäume	0,0	0,1	0,2	0,2	0,3

Tabelle 22: Ergebnisse der Klassifikation der (29544) Pixel der Klasse „Gewässer“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

4.5 Prüfung der Erreichbarkeit des Klassifikationszieles

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Markierung(Flughafen)	68,3	84,3	93,9	93,9	95,2	Markierung(Flughafen)	35,7	69,1	89,6	95,2	97,8
Fassade	16,1	---	---	---	---	Fahrzeuge	62,2	---	---	---	---
Vorfeld(Flughafen)	15,7	15,7	---	---	---	Fassade	0,0	22,2	---	---	---
Bürgersteig	0,0	0,0	5,2	---	---	Vorfeld(Flughafen)	2,2	8,7	10,4	---	---
Fahrzeuge	0,0	0,0	0,9	6,1	---	Parkplatz	0,0	0,0	0,0	4,8	---
Parkplatz	0,0	0,0	0,0	0,0	2,6	Bürgersteig	0,0	0,0	0,0	0,0	2,2
Spitzdach(bel)	0,0	0,0	0,0	0,0	2,2						

Tabelle 23: Ergebnisse der Klassifikation der (230) Pixel der Klasse „**Markierung(Flughafen)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

Minimum Distance						Maximum Likelihood					
Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5	Klassenbezeichnung	Stufe 1	Stufe 2	Stufe 3	Stufe 4	Stufe 5
Vorfeld(Flughafen)	78,4	81,6	87,9	88,3	94,6	Vorfeld(Flughafen)	81,5	89,7	92,9	94,7	97,7
Bürgersteig	17,3	---	---	---	---	Fahrzeuge	12,9	---	---	---	---
Fahrzeuge	3,0	17,1	---	---	---	Fassade	0,0	4,2	---	---	---
Parkplatz	1,2	1,2	12,0	---	---	Parkplatz	3,5	3,6	3,6	---	---
Flachdach	0,0	0,0	0,0	11,6	---	Bürgersteig	2,0	2,0	2,0	3,3	---
Strasse(bel)	0,0	0,0	0,0	0,0	5,3	Markierung(Flughafen)	0,0	0,5	1,5	1,5	1,5
Markierung(Flughafen)	0,1	0,1	0,1	0,1	0,1	Strasse(bel)	0,1	0,1	0,1	0,5	0,8

Tabelle 24: Ergebnisse der Klassifikation der (2948) Pixel der Klasse „**Vorfeld(Flughafen)**“ mit dem „Minimum Distance“-Verfahren und dem „Maximum Likelihood“-Verfahren. (Alle Angaben in Prozent)

4.5.2 Auswertung und Interpretation der Ergebnisse

Bevor mit der Analyse der Tabellen begonnen werden kann, müssen noch zwei Anmerkungen gemacht werden:

1. Bei der Bewertung der Ergebnisse in Tabelle 7 bis Tabelle 24 muß berücksichtigt werden, daß es sich um Wiedererkennungsgenauigkeiten handelt, d.h. man muß alle Tabellen betrachten, um zu beurteilen, in wieweit eine Klasse die Klassifikation der übrigen Klassen stört.
2. Die Stichprobenerhebung erfolgte mit großer Sorgfalt. Einige Stichproben enthalten jedoch Pixel von verschiedenen Klassen (z.B. die Stichprobe „Felder(bew) 5“ in Abb. A - 20). Da hiervon aber nur wenige Stichproben betroffen waren, wird auch weiterhin von einer weitgehend korrekten Zuteilung der Kontrollpixel zu den insgesamt 18 Klassen ausgegangen.

Bei einer ersten oberflächlichen Betrachtung der Tabelle 7 bis Tabelle 24 fallen zunächst die insgesamt recht niedrigen Prozentzahlen auf. Diese Beobachtung deutet darauf hin, daß die (spektralen) Merkmale, die für die computergestützte Klassifikation zur Verfügung stehen, nur bedingt ausreichen, um die Pixel in die vom Menschen (in diesem Fall dem Autor der Arbeit) vorgegeben Informationsklassen einzuteilen (beachte Kap. 2.2.3). Außerdem kann man beobachten, daß die „spektrale Inhomogenität“ innerhalb der einzelnen Informationsklassen sehr unterschiedlich ist. Denn die Ergebnisse schwanken insgesamt sehr stark. In Stufe 1 beispielsweise schwanken die Ergebnisse, die mit dem „Maximum Likelihood“-Verfahren erreicht wurden, zwischen 9,6% („Flachdach“ in Tabelle 7) und 92,1% („Wiese(sch)“ in Tabelle 18).

4 Überwachte Klassifikation von Multispektralbildern

Bei einer genaueren Betrachtung der in Tabelle 7 bis Tabelle 24 dargestellten Ergebnisse, wurden eine Reihe von Auffälligkeiten festgestellt. Einige dieser Auffälligkeiten werden im folgenden näher beschrieben und mögliche Ursachen diskutiert.

So fällt bei der Betrachtung der Ergebnisse in Tabelle 7 („Flachdach“) auf, daß der Prozentsatz der korrekt klassifizierten Pixel (erste Zeile) von Stufe 1 bis Stufe 5 nur langsam steigt. Dies deutet darauf hin, daß die Pixel dieser Klasse stark im Merkmalsraum verstreut sind. Weiterhin fällt auf, daß die Ergebnisse des „Maximum Likelihood“-Verfahrens schlechter sind als die des „Minimum Distance“-Verfahrens. Eine mögliche Erklärung hierfür ist, daß sich die Pixel innerhalb der Trainingsklasse spektral sehr ähnlich sind. Denn sie stammen alle von demselben Flachdach, und Flachdächer bestehen häufig aus recht homogenen Materialien. Das „Maximum Likelihood“-Verfahren unterschätzt deshalb die Wahrscheinlichkeit, daß Pixel weiter vom Klassenmittelpunkt entfernt liegen.

In Tabelle 8 („Spitzdach(bel)“) ist auffällig, daß beim „Minimum Distance“-Verfahren die Anteile der korrekt klassifizierten Pixel bei allen Stufen im Bereich von 49% liegen. Als Erklärung für diese Stagnation, könnte die bereits in Kap. 4.4 entdeckte Unterteilung der Spitzdächer in Dächer mit roten und mit schwarzen Dachziegeln dienen. Man kann an diesem Beispiel gut erkennen, daß eine Reduzierung der Klassenzahl die Wiedererkennungsgenauigkeit nicht unbedingt erhöhen muß. Sie wirkt sich nur dann positiv aus, wenn das Problem in einer zu großen spektralen Ähnlichkeit der beteiligten Klassen liegt. Wenn das Problem aber in einer zu großen spektralen Inhomogenität der betreffenden Klasse liegt, bleibt die Reduzierung der Anzahl der Informationsklassen meistens erfolglos.

Interessant ist auch Tabelle 15 („Fahrzeuge“). Denn aus dieser Tabelle ist ersichtlich, daß die Klasse „Fahrzeuge“ spektral sehr inhomogen ist. Dies erkennt man daran, daß in allen fünf Stufen mit dem „Minimum Distance“-Verfahren nur jeweils knapp 10% der Pixel korrekt klassifiziert wurden. Mit dem „Maximum Likelihood“-Verfahren wird ein erheblich höherer Prozentsatz der Pixel korrekt klassifiziert. Diese Beobachtung läßt sich mit der starken Inhomogenität innerhalb der Trainingspixel, die für diese Klasse gewählt wurden, erklären (siehe Abb. 18). Da diese Pixel so stark streuen, verläuft die aus ihnen berechnete Normalverteilungskurve im Merkmalsraum sehr flach, so daß die Zuweisungsgrenzen weit vom Klassenmittelpunkt entfernt liegen. Deshalb wurden auch in Tabelle 8 („Spitzdach (bel)“) so viele Pixel der Klasse „Fahrzeuge“ zugewiesen.

In Tabelle 16 („Bäume“) sind besonders die hohen Genauigkeiten auffällig, mit denen das „Maximum Likelihood“-Verfahren die Pixel der Klasse „Bäume“ klassifiziert hat. Diese Beobachtung kann damit erklärt werden, daß ,infolge der inhomogenen Oberflächenstruktur der Bäume, die Spektren der Pixel dieser Klasse starken Schwankungen unterworfen sind. Diese Schwankungen treten bereits innerhalb der einzelnen Stichproben auf. Deshalb schätzt das „Maximum Likelihood“-Verfahren die Wahrscheinlichkeit, daß die Pixel weit vom Klassenmittelpunkt der Klasse entfernt liegen können auch entsprechend hoch ein.

Fazit:

Das Ziel dieser Untersuchung war es, zu überprüfen, in wieweit das gesteckte Klassifikationsziel erreichbar ist. Da in den weiteren Untersuchungen nicht die Erreichung von möglichst guten Klassifikationsergebnissen angestrebt wird, sondern ein Vergleich der Verfahren, müssen die verwendeten Klassen nicht unbedingt sehr hohe Wiedererkennungsgenauigkeiten besitzen.

Allerdings zeigte es sich, daß bei einigen Klassen (z.B. „Flachdach“) das „Minimum Distance“-Verfahren die besseren Ergebnisse lieferte, während bei anderen Klassen (z.B. „Bäume“) das „Maximum Likelihood“-Verfahren die besseren Resultate brachte. Die Wahl der Informationsklassen hat also einen Einfluß auf den Vergleich der beiden Verfahren. Deshalb werden in den folgenden Untersuchungen nicht nur die Kappa-Werte verglichen, sondern auch noch die Wiedererkennungsgenauigkeiten der einzelnen Klassen berücksichtigt. Außerdem sollte unbedingt auf die Klasse „Fahrzeuge“ verzichtet werden, denn sie könnte die Klassifikationen in den weiteren Untersuchungen derart stören, daß die Ergebnisse von dieser Klasse sehr stark abhängig werden könnten. Bei Verzicht auf diese Klasse kann man bei den meisten der übrigen Klassen eine Wiedererkennungsgenauigkeit von ca. 50% bis 80% erwarten. Bei den Klassen „Flachdach“ und „Spitzdach(bel)“ sollte die Zahl der Trainingsklassen erhöht werden. Diese Empfehlung könnte man auch für die Klassen „Parkplatz“ und „Strasse(bel)“ aussprechen. Man könnte diese Klassen aber auch zu einer Informationsklasse zusammenfassen, da sie sich spektral ähnlich sind und auch einen ähnlichen Informationsgehalt vermitteln. Ein direkter Vergleich der beiden Klassifikationsverfahren ist an dieser Stelle noch nicht sinnvoll, da bei der Auswahl der Trainingsklassen die Kovarianzmatrizen nicht berücksichtigt wurden, was zu einer Übervorteilung des „Minimum Distance“-Verfahrens führen würde.

4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit

In diesem Abschnitt wird untersucht, in wieweit eine Erhöhung der Anzahl an Trainingsklassen zu einer Erhöhung der Klassifikationsgenauigkeit führen kann. Dieser Ansatz ist deshalb erfolgversprechend, weil die bisherigen Untersuchungen gezeigt haben, daß die gewählten Informationsklassen teilweise aus sich spektral unterscheidenden Unterklassen bestehen. Die Pixel innerhalb der Informationsklassen sind also nicht grundsätzlich normalverteilt.

4.6.1 Durchführung der Untersuchung

Die Durchführung der Untersuchung mit der Vielzahl der in Kap. 4.3 eingeführten Klassen ist nicht zweckmäßig, da die Ergebnisse zu unübersichtlich würden. Deshalb wurden einige Klassen zu neuen Informationsklassen zusammengefaßt. Die Klassen „Bürgersteig“, „Parkplatz“, „Strasse(bel)“ und „Strasse(sch)“ wurden zur Klasse „Verkehr“ zusammengefaßt. Die Klassen „Spitzdach(bel)“ und „Spitzdach(sch)“ wurden zur Klasse „Sp_dach“ und die Klassen „Wiese(bel)“ und „Wiese(sch)“ zur Klasse „Wiese“ vereinigt. Neben der Klasse „Fahrzeuge“ werden zusätzlich noch die Klassen „Markierung(Flughafen)“ und „Vorfeld(Flughafen)“ in der Untersuchung nicht berücksichtigt, weil sie nur am Flughafen vorkommen und man in der Praxis wahrscheinlich auf eine getrennte Klassifikation dieses Gebietes zurückgreifen würde.

Im nächsten Schritt der Untersuchung mußte aus den vorhandenen Stichproben eine Reihe von Proben ausgewählt werden, um sie im weiteren Verlauf der Untersuchung als Trainingsklassen einzusetzen. Die Auswahl erfolgte zufällig mit Hilfe des Computers. Der Computer wählte insgesamt 117 Stichproben aus. Es handelt sich um die ersten 117 der 120 Stichproben im Anhang (Abb. A - 8 bis Abb. A - 27). Der Vorteil in der zufälligen Auswahl besteht darin, daß sich die ausgewählten Stichproben prinzipiell für beide Klassifikationsverfahren gleichermaßen eignen, wodurch ein direkter Vergleich des „Minimum Distance“- und des „Maximum Likelihood“-Verfahrens erst möglich wird.

4 Überwachte Klassifikation von Multispektralbildern

Neue Klassenbezeichnung	Alte Klassenbezeichnungen	Anzahl der Pixel
Fl_dach	Flachdach	65951
Sp_dach	Spitzdach(bel), Spitzdach(sch)	20910
Fassade	Fassade	4141
Verkehr	Bürgersteig, Parkplatz, Strasse(bel), Strasse(sch)	29511
Bahn	Eisenbahn	499
Erde	Erdreich	29045
Wiese	Wiese(bel), Wiese(sch)	35490
Felder	Felder(bew)	17086
Bäume	Bäume	8807
Wasser	Gewässer	22735

Tabelle 25: Übersicht über die Neuordnung der Informationsklassen und der Anzahl ihrer Kontrollpixel

Die Pixel der übrigen Stichproben wurden als *Kontrollpixel* verwendet. Tabelle 25 zeigt eine Übersicht über die Anzahl der Kontrollpixel und aus welchen Klassen sie stammen. Tabelle 26 zeigt eine Übersicht über die Anzahl der Stichproben, die für die verschiedenen Klassen als Trainingsklassen gewählt wurden. Sie wurden jeweils zu Gruppen zusammengefaßt. Diese Gruppen werden im folgenden als *Trainingsgruppen* bezeichnet. Die Stichproben, die von Spitzdächern und Wiesen stammten, wurden zweifach zugeteilt, um auf die unterschiedlich beleuchteten Stichproben der jeweiligen Klasse getrennt zugreifen zu können.

Bezeichnung des Trainingsgruppe	Stichproben, aus denen sich die Trainingsgruppe zusammensetzt	Gesamtzahl der Stichproben
Flachdach	Flachdach 1-20	20
Spitzdach	Spitzdach(bel) 1-12, Spitzdach(sch) 1-8	20
Spitzdach(bel)	Spitzdach(bel) 1-12	12
Spitzdach(sch)	Spitzdach(sch) 1-8	8
Fassade	Fassade 1-6	6
Verkehr	Buergersteig 1-6, Parkplatz 1-6, Strasse(bel) 1-5, Strasse(sch) 1-5	22
Eisenbahn	Eisenbahn 1-4	4
Erdreich	Erdreich 1-5	5
Wiese	Wiese(bel) 1-5, Wiese(sch) 1-5	10
Wiese(bel)	Wiese(bel) 1-5	5
Wiese(sch)	Wiese(sch) 1-5	5
Felder	Felder(bew) 1-10	10
Bäume	Baum 1-12	12
Gewässer	Gewaesser 1-8	8

Tabelle 26: Übersicht über die Zusammensetzung der Trainingsgruppen

Aus diesen Trainingsgruppen wurden im weiteren Verlauf der Untersuchung Stichproben ausgewählt und zu *Trainingsätzen* zusammengestellt. Die Auswahl der Stichproben erfolgte mit Hilfe eines Computerprogramms. Dieses Programm benötigte zunächst die Eingabe einer *Erzeugungsvorschrift*, die dem Programm mitteilte, wie viele Stichproben es zufällig aus den verschiedenen Trainingsgruppen auswählen sollte. In der „Erprobungsphase“ wurden verschiedenen Erzeugungsvorschriften getestet. Es zeigte sich hierbei, daß sich die Klassifikations-

ergebnisse selbst dann stark unterschieden, wenn die eingesetzten Trainingssätze mit der gleichen Erzeugungsvorschrift erzeugt worden waren. Um diesem Problem zu begegnen, wurden mit jeder Erzeugungsvorschrift nicht nur ein Trainingssatz erzeugt, sondern es wurden insgesamt 100 Trainingssätze generiert. Diese 100 Trainingssätze bilden jeweils eine Gruppe, die im folgenden als *Permutationssatz* bezeichnet wird. Die Zahl 100 stellt ein Kompromiß dar zwischen der Forderung nach möglichst stabilen Ergebnissen und der Notwendigkeit den Rechenaufwand zu begrenzen. Es wurden insgesamt sechs verschiedene Permutationssätze erzeugt (siehe Tabelle 27). Jeder Permutationssatz besitzt dabei eine andere Erzeugungsvorschrift.

Im nächsten Schritt der Untersuchung wurden die Kontrollpixel sowohl mit dem „Minimum Distance“-Verfahren als auch mit dem „Maximum Likelihood“-Verfahren klassifiziert. Die Trainingsgrundlage bildeten die insgesamt 600 Trainingssätze aus den 6 Permutationssätzen. Hieraus ergaben sich also 1200 Klassifikationen, die wiederum insgesamt 1200 Konfusionsmatrizen als Ergebnis lieferten. Jeweils 100 Konfusionsmatrizen besaßen die Gemeinsamkeit, daß zu ihrer Erzeugung das gleiche Verfahren verwendet wurde, und daß der zum Training verwendete Trainingssatz von demselben Permutationssatz stammte. Die Zellen dieser Konfusionsmatrizen wurden elementweise gemittelt, d.h. es wurden die 100 Werte, die sich an der jeweils gleichen Position in den 100 verschiedenen Matrizen befanden, gemittelt und die errechneten Mittelwerte zu einer neuen (gemittelten) Konfusionsmatrix zusammengefaßt. Auf diese Weise entstanden insgesamt 12 gemittelte Konfusionsmatrizen. Sie sind in Tabelle 28 bis Tabelle 44 zu finden. Diese Matrizen unterscheiden sich von der in Kap 2.3.2 eingeführten Matrix. Denn sie enthalten nicht die absoluten Zahlen, wie die Matrix in Tabelle 1, sondern Prozentzahlen, die sich auf die Gesamtzahl der Kontrollpixel in der betreffenden Klasse (siehe Tabelle 25) beziehen. Die Prozentzahlen in der Diagonalen (schwarz unterlegt) entsprechen also der Wiedererkennungsgenauigkeit. Die Rubrik „Klassenzahl“ gibt noch einmal einen Überblick über die Anzahl der Trainingsklassen, die für die einzelnen Informationsklassen eingesetzt wurden. Einige Tabellen enthalten in dieser Rubrik zwei durch einen Schrägstrich getrennte Zahlen. Die erste Zahl gibt an, wie viele Trainingsklassen aus der Trainingsgruppe mit der Endung „(bel)“ der entsprechenden Klasse stammen (vergleiche Tabelle 26). Die zweite Zahl gibt an, wie viele Trainingsklassen aus der Trainingsgruppe mit der Endung „(sch)“ der entsprechenden Klasse stammen. Die letzte Zeile in den Tabellen enthält Angaben über den mittleren Kappa-Wert κ und die gemittelte Gesamtgenauigkeit G_G mit Angabe des jeweiligen Standardfehlers. Der Standardfehler σ_x ist definiert durch

$$\sigma_x = \frac{\sigma}{\sqrt{n}}, \quad (\text{Gl. 23})$$

wobei σ der Standardabweichung der Meßgröße x entspricht und n der Anzahl der Beobachtungen, d.h. hier speziell $n = 100$.

Nach jeweils zwei gemittelten Konfusionsmatrizen folgt in dem Tabellenblock aus Tabelle 28 bis Tabelle 45 eine Differenzmatrix. Diese Matrizen haben die Aufgabe, den Vergleich der Ergebnisse der beiden Klassifikationsverfahren zu erleichtern. Sie sind durch elementweise Subtraktion der Konfusionsmatrizen der beiden Verfahren entstanden. Es wurden hierbei die Ergebnisse der „Maximum Likelihood“-Klassifikationen von denen Ergebnissen der „Minimum Distance“-Klassifikationen abgezogen. Die Fehler in der letzten Zeile der Differenzmatrizen wurden, gemäß dem Fehlerfortpflanzungsgesetz, aus den entsprechenden Standardfehlern der ursprünglichen Größen berechnet.

4 Überwachte Klassifikation von Multispektralbildern

$$\text{Fehlerfortpflanzungsgesetz: } \sigma_y = \sqrt{\sum_{i=1}^m \left(\frac{\partial y}{\partial x_i} (\bar{x}_i) \right)^2 \cdot \sigma_{x_i}^2} \quad (\text{Gl. 24})$$

$$\text{Hieraus folgt für den speziellen Fall: } \Delta_{\kappa, G_G} = \sqrt{\sigma_{\kappa, G_G}^2 (\text{Tabelle i}) + \sigma_{\kappa, G_G}^2 (\text{Tabelle j})} \quad (\text{Gl. 25})$$

Bezeichnung der Trainingsgruppe	Per mutatio ns satz num mer					
	1	2	3	4	5	6
Flachdach	1	1	5	2	3	4
Spitzdach	1	0	0	0	0	0
Spitzdach(bel)	0	1	1	1	2	3
Spitzdach(sch)	0	1	1	1	1	2
Fassade	1	1	1	2	3	3
Verkehr	1	1	1	2	3	4
Eisenbahn	1	1	1	2	2	2
Erdreich	1	1	1	2	3	3
Wiese	1	0	0	0	0	0
Wiese(bel)	0	1	1	1	2	3
Wiese(sch)	0	1	1	1	1	2
Felder	1	1	1	2	3	4
Bäume	1	1	1	2	3	4
Gewässer	1	1	1	2	3	4
Gesamtzahl der Trainingsklassen	10	12	16	20	29	38

Tabelle 27: Übersicht über die sechs Permutationssätze. Die 14 Zahlen, die jeweils in der Spalte unter einer Permutationssatznummer stehen, definieren die Erzeugungsvorschrift für den entsprechenden Permutationssatz.

4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
1	Fl_dach	28,1	11,8	5,4	21,6	8,2	15,8	0,6	0,1	0,3	0,0
1	Sp_dach	5,4	20,0	8,7	3,5	6,1	0,9	3,4	0,2	0,7	5,8
1	Fassade	3,3	10,2	62,9	0,8	0,0	0,0	0,0	0,0	0,4	0,0
1	Verkehr	21,6	14,0	4,4	20,8	11,8	7,6	2,0	0,1	0,5	14,0
1	Bahn	11,1	12,7	6,2	20,4	35,0	17,1	3,1	0,0	6,6	3,7
1	Erde	22,7	8,3	0,4	20,8	29,4	56,9	1,8	0,0	7,7	0,0
1	Wiese	2,2	8,5	2,4	1,6	5,3	0,8	27,1	21,3	12,6	2,2
1	Felder	3,0	4,9	6,7	1,9	0,6	0,8	34,5	44,9	24,8	0,0
1	Bäume	0,1	0,2	2,4	0,2	0,0	0,0	24,2	33,5	46,3	0,0
1	Wasser	2,3	9,3	0,4	8,4	3,7	0,0	3,2	0,0	0,1	74,2
K =		28,70	+/- 0,70	G_G =		36,90	+/- 0,60				

Tabelle 28: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz I. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
1	Fl_dach	27,9	4,7	4,2	26,6	5,9	8,1	0,0	0,0	0,0	0,7
1	Sp_dach	7,8	20,2	4,1	6,3	6,7	4,6	0,6	0,0	0,0	6,5
1	Fassade	15,6	25,7	76,7	7,3	2,3	0,9	3,9	19,7	7,7	3,8
1	Verkehr	25,6	8,0	4,8	31,8	9,2	6,8	0,2	0,0	0,0	8,5
1	Bahn	6,5	12,0	2,6	13,9	35,0	1,0	0,1	0,0	0,0	0,7
1	Erde	9,1	9,9	0,2	2,7	21,7	65,0	0,4	0,1	0,2	0,4
1	Wiese	0,7	4,0	2,3	2,0	0,2	0,8	30,5	14,6	4,5	2,2
1	Felder	4,4	6,2	3,2	1,8	11,7	11,3	24,9	35,3	16,7	2,5
1	Bäume	2,2	7,1	1,9	1,9	7,3	1,6	39,4	30,3	70,8	14,3
1	Wasser	0,1	2,2	0,0	5,7	0,0	0,0	0,1	0,0	0,0	60,4
K =		31,70	+/- 0,60	G_G =		38,90	+/- 0,70				

Tabelle 29: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz I. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
1	Fl_dach	-0,2	-7,1	-1,2	5,0	-2,3	-7,7	-0,6	-0,1	-0,3	0,7
1	Sp_dach	2,4	0,2	-4,6	2,8	0,6	3,7	-2,8	-0,2	-0,7	0,7
1	Fassade	12,3	15,5	13,8	6,5	2,3	0,9	3,9	19,7	7,3	3,8
1	Verkehr	4,0	-6,0	0,4	11,0	-2,6	-0,8	-1,8	-0,1	-0,5	-5,5
1	Bahn	-4,6	-0,7	-3,6	-6,5	0,0	-16,1	-3,0	0,0	-6,6	-3,0
1	Erde	-13,6	1,6	-0,2	-18,1	-7,7	8,1	-1,4	0,1	-7,5	0,4
1	Wiese	-1,5	-4,5	-0,1	0,4	-5,1	0,0	3,4	-6,7	-8,1	0,0
1	Felder	1,4	1,3	-3,5	-0,1	11,1	10,5	-9,6	-9,6	-8,1	2,5
1	Bäume	2,1	6,9	-0,5	1,7	7,3	1,6	15,2	-3,2	24,5	14,3
1	Wasser	-2,2	-7,1	-0,4	-2,7	-3,7	0,0	-3,1	0,0	-0,1	-13,8
Δ(K) =		3,00	+/- 0,92	Δ(G_G) =		2,00	+/- 0,92				

Tabelle 30: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 29 von denen aus Tabelle 28). (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

		R e f e r e n z										
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser	
1	Fl_dach	28,6	9,4	3,5	21,0	6,4	13,3	0,6	0,1	0,3	0,0	
1 / 1	Sp_dach	10,0	39,0	17,5	5,9	13,1	2,0	1,6	0,0	0,6	13,1	
1	Fassade	3,3	7,2	63,0	1,1	0,2	0,0	0,0	0,0	0,6	0,0	
1	Verkehr	23,6	10,1	4,9	19,4	7,1	5,8	0,5	0,1	0,3	9,1	
1	Bahn	9,8	10,4	5,8	20,1	32,9	15,6	1,1	0,0	5,6	3,4	
1	Erde	19,8	6,9	0,4	21,7	33,7	61,8	1,6	0,0	6,0	0,0	
1 / 1	Wiese	2,8	10,8	2,1	2,6	4,0	0,7	47,7	39,8	22,9	4,5	
1	Felder	1,2	1,2	1,5	0,8	0,4	0,7	28,0	41,2	23,5	0,0	
1	Bäume	0,0	0,1	0,7	0,1	0,0	0,0	18,5	18,8	40,3	0,0	
1	Wasser	1,1	4,9	0,6	7,3	2,3	0,0	0,4	0,0	0,0	69,9	
K =		33,40	+/- 0,70	G_G =		41,40	+/- 0,70					

Tabelle 31: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz 2. (Alle Angaben in Prozent)

		R e f e r e n z										
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser	
1	Fl_dach	30,1	5,1	3,3	28,0	4,9	6,3	0,0	0,0	0,0	0,2	
1 / 1	Sp_dach	10,9	38,7	5,0	9,1	14,8	8,3	0,5	0,0	0,1	16,6	
1	Fassade	13,6	19,5	75,8	6,3	3,1	1,1	3,2	16,7	8,2	3,8	
1	Verkehr	25,4	6,3	4,6	30,9	7,0	4,8	0,1	0,0	0,1	8,5	
1	Bahn	5,3	8,8	2,4	13,5	33,2	0,9	0,0	0,0	0,0	0,4	
1	Erde	9,7	9,3	0,7	3,7	24,0	70,8	0,1	0,0	0,2	0,1	
1 / 1	Wiese	1,4	4,9	5,6	2,0	1,0	1,7	60,7	30,7	13,9	2,9	
1	Felder	2,4	2,1	1,0	0,9	5,3	5,3	14,1	34,6	12,7	0,9	
1	Bäume	1,3	3,5	1,8	0,6	6,7	0,8	21,4	17,9	64,8	13,0	
1	Wasser	0,0	1,8	0,0	4,7	0,0	0,0	0,1	0,0	0,0	53,6	
K =		38,30	+/- 0,80	G_G =		45,40	+/- 0,80					

Tabelle 32: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz 2. (Alle Angaben in Prozent)

		R e f e r e n z										
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser	
1	Fl_dach	1,5	-4,3	-0,2	7,0	-1,5	-7,0	-0,6	-0,1	-0,3	0,2	
1 / 1	Sp_dach	0,9	-0,3	-12,5	3,2	1,7	6,3	-1,1	0,0	-0,5	3,5	
1	Fassade	10,3	12,3	12,8	5,2	2,9	1,1	3,2	16,7	7,6	3,8	
1	Verkehr	1,8	-3,8	-0,3	11,5	-0,1	-1,0	-0,4	-0,1	-0,2	-0,6	
1	Bahn	-4,5	-1,6	-3,4	-6,6	0,3	-14,7	-1,1	0,0	-5,6	-3,0	
1	Erde	-10,1	2,4	0,3	-18,0	-9,7	9,0	-1,5	0,0	-5,8	0,1	
1 / 1	Wiese	-1,4	-5,9	3,5	-0,6	-3,0	1,0	13,0	-9,1	-9,0	-1,6	
1	Felder	1,2	0,9	-0,5	0,1	4,9	4,6	-13,9	-6,6	-10,8	0,9	
1	Bäume	1,3	3,4	1,1	0,5	6,7	0,8	2,9	-0,9	24,5	13,0	
1	Wasser	-1,1	-3,1	-0,6	-2,6	-2,3	0,0	-0,3	0,0	0,0	-16,3	
Δ(K) =		4,90	+/- 1,06	Δ(G_G) =		4,00	+/- 1,06					

Tabelle 33: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 32 von denen aus Tabelle 31). (Alle Angaben in Prozent)

4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
5	Fl_dach	65,3	25,5	18,2	53,0	29,9	44,4	1,8	0,3	1,8	0,0
1 / 1	Sp_dach	5,7	35,0	11,0	3,8	11,5	0,8	1,6	0,0	0,7	12,7
1	Fassade	2,8	6,2	58,7	0,6	0,0	0,0	0,0	0,0	0,7	0,0
1	Verkehr	11,5	6,3	2,6	11,3	6,1	3,8	0,4	0,1	0,3	5,6
1	Bahn	5,4	7,8	5,1	14,4	28,5	9,1	0,8	0,0	5,7	3,8
1	Erde	6,4	3,4	0,2	6,8	18,0	41,7	1,4	0,0	7,1	0,0
1 / 1	Wiese	1,7	10,1	2,2	1,5	4,8	0,1	49,3	38,8	23,6	4,9
1	Felder	0,1	0,2	0,8	0,2	0,2	0,1	26,7	37,1	21,5	0,0
1	Bäume	0,0	0,1	0,9	0,1	0,0	0,0	17,6	23,7	38,6	0,0
1	Wasser	1,1	5,4	0,4	8,4	0,9	0,0	0,4	0,0	0,0	73,0
K =		38,20	+/- 0,60	G_G =		47,90	+/- 0,50				

Tabelle 34: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz 3. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
5	Fl_dach	68,8	14,1	10,6	59,9	19,2	24,4	0,0	0,0	0,0	2,0
1 / 1	Sp_dach	6,7	37,2	4,8	6,6	10,9	8,5	0,7	0,0	0,0	12,5
1	Fassade	7,6	17,2	71,9	3,1	2,4	0,4	3,1	20,6	8,5	3,3
1	Verkehr	10,2	4,5	2,6	16,6	6,2	3,3	0,2	0,0	0,0	5,1
1	Bahn	1,3	7,4	0,9	4,8	27,1	0,6	0,0	0,0	0,0	0,3
1	Erde	2,4	6,8	0,0	0,4	19,7	55,2	0,1	0,0	0,1	0,1
1 / 1	Wiese	0,7	5,0	6,9	2,5	0,3	0,8	55,0	26,8	9,6	3,3
1	Felder	1,1	2,3	0,7	0,5	5,6	5,5	15,9	30,3	9,8	1,1
1	Bäume	1,0	3,8	1,4	0,5	8,6	1,3	24,9	22,2	71,9	17,9
1	Wasser	0,0	1,8	0,0	5,1	0,0	0,0	0,1	0,0	0,0	54,4
K =		43,00	+/- 0,70	G_G =		51,50	+/- 0,70				

Tabelle 35: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz 3. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
5	Fl_dach	3,5	-11,4	-7,6	6,9	-10,7	-20,0	-1,8	-0,3	-1,8	2,0
1 / 1	Sp_dach	1,0	2,2	-6,2	2,8	-0,6	7,7	-0,9	0,0	-0,7	-0,2
1	Fassade	4,8	11,0	13,2	2,5	2,4	0,4	3,1	20,6	7,8	3,3
1	Verkehr	-1,3	-1,8	0,0	5,3	0,1	-0,5	-0,2	-0,1	-0,3	-0,5
1	Bahn	-4,1	-0,4	-4,2	-9,6	-1,4	-8,5	-0,8	0,0	-5,7	-3,5
1	Erde	-4,0	3,4	-0,2	-6,4	1,7	13,5	-1,3	0,0	-7,0	0,1
1 / 1	Wiese	-1,0	-5,1	4,7	1,0	-4,5	0,7	5,7	-12,0	-14,0	-1,6
1	Felder	1,0	2,1	-0,1	0,3	5,4	5,4	-10,8	-6,8	-11,7	1,1
1	Bäume	1,0	3,7	0,5	0,4	8,6	1,3	7,3	-1,5	33,3	17,9
1	Wasser	-1,1	-3,6	-0,4	-3,3	-0,9	0,0	-0,3	0,0	0,0	-18,6
Δ(K) =		4,80	+/- 0,92	Δ(G_G) =		3,60	+/- 0,86				

Tabelle 36: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 35 von denen aus Tabelle 34). (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
2	Fl_dach	31,4	11,2	5,3	20,9	6,6	14,9	0,3	0,0	0,1	0,0
1 / 1	Sp_dach	6,4	35,5	4,9	3,5	7,4	0,6	1,3	0,0	0,3	5,8
2	Fassade	3,7	9,4	76,7	0,6	0,0	0,0	0,0	0,0	0,4	0,0
2	Verkehr	27,8	11,9	2,4	28,2	10,4	5,0	0,4	0,0	0,1	18,0
2	Bahn	12,1	13,0	7,3	25,2	51,1	12,8	1,3	0,0	3,9	2,8
2	Erde	16,5	6,3	0,1	12,4	22,3	66,1	1,3	0,0	5,1	0,0
1 / 1	Wiese	0,4	6,1	0,7	0,6	1,4	0,0	34,8	24,7	11,5	0,7
2	Felder	0,7	0,9	1,4	0,7	0,3	0,6	39,4	52,6	26,2	0,0
2	Bäume	0,0	0,1	0,8	0,1	0,0	0,0	20,5	22,7	52,4	0,0
2	Wasser	1,0	5,5	0,2	7,9	0,5	0,0	0,5	0,0	0,0	72,8
K =		35,90	+/- 0,60	G_G =		43,40	+/- 0,50				

Tabelle 37: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz 4. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
2	Fl_dach	33,7	4,2	2,1	27,7	5,6	4,9	0,0	0,0	0,0	0,2
1 / 1	Sp_dach	9,9	33,7	1,4	5,5	9,7	4,9	0,3	0,0	0,0	5,6
2	Fassade	15,5	25,9	89,6	6,2	0,9	0,2	2,8	24,3	7,3	3,3
2	Verkehr	27,4	5,9	2,8	40,3	7,2	2,5	0,1	0,0	0,0	10,8
2	Bahn	2,9	10,7	1,6	10,7	46,2	0,4	0,0	0,0	0,0	0,3
2	Erde	7,6	9,8	0,0	1,2	20,2	82,4	0,1	0,0	0,1	0,0
1 / 1	Wiese	0,3	2,6	1,3	1,0	0,1	0,2	41,4	14,1	4,0	0,4
2	Felder	1,8	1,7	0,4	0,7	5,3	4,2	24,1	42,0	10,7	1,3
2	Bäume	0,8	2,7	0,7	0,3	4,9	0,3	31,0	19,6	77,9	7,9
2	Wasser	0,0	2,9	0,0	6,5	0,0	0,0	0,2	0,0	0,0	70,3
K =		42,00	+/- 0,60	G_G =		48,60	+/- 0,60				

Tabelle 38: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz 4. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
2	Fl_dach	2,3	-7,0	-3,2	6,8	-1,0	-10,0	-0,3	0,0	-0,1	0,2
1 / 1	Sp_dach	3,5	-1,8	-3,5	2,0	2,3	4,3	-1,0	0,0	-0,3	-0,2
2	Fassade	11,8	16,5	12,9	5,6	0,9	0,2	2,8	24,3	6,9	3,3
2	Verkehr	-0,4	-6,0	0,4	12,1	-3,2	-2,5	-0,3	0,0	-0,1	-7,2
2	Bahn	-9,2	-2,3	-5,7	-14,5	-4,9	-12,4	-1,3	0,0	-3,9	-2,5
2	Erde	-8,9	3,5	-0,1	-11,2	-2,1	16,3	-1,2	0,0	-5,0	0,0
1 / 1	Wiese	-0,1	-3,5	0,6	0,4	-1,3	0,2	6,6	-10,6	-7,5	-0,3
2	Felder	1,1	0,8	-1,0	0,0	5,0	3,6	-15,3	-10,6	-15,5	1,3
2	Bäume	0,8	2,6	-0,1	0,2	4,9	0,3	10,5	-3,1	25,5	7,9
2	Wasser	-1,0	-2,6	-0,2	-1,4	-0,5	0,0	-0,3	0,0	0,0	-2,5
Δ(K) =		6,10	+/- 0,85	Δ(G_G) =		5,20	+/- 0,78				

Tabelle 39: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 38 von denen aus Tabelle 37). (Alle Angaben in Prozent)

4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
3	Fl_dach	36,5	12,0	3,8	24,0	7,3	15,4	0,1	0,0	0,1	0,0
2 / 1	Sp_dach	6,9	37,8	1,6	4,9	7,6	0,5	1,3	0,0	0,3	1,7
3	Fassade	3,8	7,4	83,4	0,5	0,0	0,0	0,0	0,0	0,2	0,0
3	Verkehr	27,8	12,6	1,8	32,0	11,4	2,9	0,3	0,0	0,0	12,1
2	Bahn	8,8	11,9	7,0	20,0	48,5	8,1	1,2	0,0	1,7	1,1
3	Erde	14,1	5,9	0,0	9,9	23,6	72,6	0,8	0,0	4,4	0,0
2 / 1	Wiese	0,4	6,0	0,6	0,4	0,5	0,0	44,5	33,4	13,8	0,3
3	Felder	0,7	0,9	0,9	0,5	0,6	0,4	31,7	47,7	19,9	0,0
3	Bäume	0,0	0,0	0,5	0,1	0,0	0,0	19,4	18,8	59,6	0,0
3	Wasser	1,0	5,5	0,3	7,8	0,5	0,0	0,5	0,0	0,0	84,8
K =		41,70	+ / - 0,50	G_G =		49,00	+ / - 0,40				

Tabelle 40: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz 5. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
3	Fl_dach	38,1	4,9	1,7	28,6	7,8	2,9	0,0	0,0	0,0	0,2
2 / 1	Sp_dach	13,2	38,5	2,8	8,1	10,7	4,6	0,5	0,0	0,0	3,0
3	Fassade	12,8	21,6	89,5	4,7	0,6	0,0	1,2	22,1	7,0	1,8
3	Verkehr	25,0	6,5	3,3	41,9	7,4	1,9	0,0	0,0	0,0	8,8
2	Bahn	1,6	9,7	1,1	7,2	40,7	0,1	0,0	0,0	0,0	0,3
3	Erde	6,3	9,3	0,0	0,7	19,8	83,8	0,0	0,0	0,1	0,0
2 / 1	Wiese	0,1	2,5	0,6	1,3	0,1	0,2	52,2	17,8	3,8	0,3
3	Felder	2,2	2,0	0,3	0,6	7,7	6,3	17,5	44,0	7,5	0,1
3	Bäume	0,6	2,2	0,6	0,2	5,2	0,1	28,5	16,2	81,6	6,4
3	Wasser	0,0	2,9	0,0	6,7	0,0	0,0	0,2	0,0	0,0	79,2
K =		47,10	+ / - 0,50	G_G =		53,40	+ / - 0,40				

Tabelle 41: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz 5. (Alle Angaben in Prozent)

Kl a s s i f i k a t i o n	R e f e r e n z										
	Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume
3	Fl_dach	1,6	-7,1	-2,1	4,6	0,5	-12,5	-0,1	0,0	-0,1	0,2
2 / 1	Sp_dach	6,3	0,7	1,2	3,2	3,1	4,1	-0,8	0,0	-0,3	1,3
3	Fassade	9,0	14,2	6,1	4,2	0,6	0,0	1,2	22,1	6,8	1,8
3	Verkehr	-2,8	-6,1	1,5	9,9	-4,0	-1,0	-0,3	0,0	0,0	-3,3
2	Bahn	-7,2	-2,2	-5,9	-12,8	-7,8	-8,0	-1,2	0,0	-1,7	-0,8
3	Erde	-7,8	3,4	0,0	-9,2	-3,8	11,2	-0,8	0,0	-4,3	0,0
2 / 1	Wiese	-0,3	-3,5	0,0	0,9	-0,4	0,2	7,7	-15,6	-10,0	0,0
3	Felder	1,5	1,1	-0,6	0,1	7,1	5,9	-14,2	-3,7	-12,4	0,1
3	Bäume	0,6	2,2	0,1	0,1	5,2	0,1	9,1	-2,6	22,0	6,4
3	Wasser	-1,0	-2,6	-0,3	-1,1	-0,5	0,0	-0,3	0,0	0,0	-5,6
Δ(K) =		5,40	+ / - 0,71	Δ(G_G) =		4,40	+ / - 0,57				

Tabelle 42: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 41 von denen aus Tabelle 40). (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

Kl a s s e n	Klassenzahl	Klassenname	R e f e r e n z									
			Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
	4	Fl_dach	39,2	11,7	4,3	23,0	6,4	17,4	0,0	0,0	0,1	0,0
	3 / 2	Sp_dach	8,1	45,7	2,6	5,2	11,9	0,7	0,7	0,0	0,1	1,7
	3	Fassade	3,6	5,8	80,4	0,6	0,0	0,0	0,0	0,0	0,1	0,0
	4	Verkehr	28,5	12,5	3,4	35,4	14,5	2,6	0,1	0,0	0,0	12,5
	2	Bahn	6,8	10,2	6,9	19,8	42,2	7,9	0,7	0,0	0,9	1,0
	4	Erde	13,0	5,0	0,0	8,6	23,7	70,9	0,6	0,0	2,3	0,0
	3 / 2	Wiese	0,1	4,3	0,6	0,5	0,3	0,0	52,9	33,1	14,5	0,2
	3	Felder	0,1	0,5	0,8	0,2	0,8	0,5	27,5	50,1	19,0	0,0
	4	Bäume	0,0	0,0	0,5	0,0	0,0	0,0	17,1	16,8	62,9	0,0
	4	Wasser	0,6	4,2	0,4	6,8	0,2	0,0	0,4	0,0	0,0	84,6
K =			45,10	+/- 0,50	G_G =			52,10	+/- 0,50			

Tabelle 43: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Minimum Distance“-Verfahren auf der Grundlage von Permutationssatz 6. (Alle Angaben in Prozent)

Kl a s s e n	Klassenzahl	Klassenname	R e f e r e n z									
			Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
	4	Fl_dach	43,0	5,0	1,7	27,4	9,4	4,2	0,0	0,0	0,0	0,2
	3 / 2	Sp_dach	12,3	49,9	2,5	7,5	13,9	6,6	0,2	0,0	0,0	3,2
	3	Fassade	10,2	15,0	89,4	2,7	0,1	0,0	0,3	14,5	4,8	0,8
	4	Verkehr	26,5	6,2	3,3	47,3	7,5	2,2	0,0	0,0	0,0	5,2
	2	Bahn	1,0	7,2	0,9	5,7	34,5	0,1	0,0	0,0	0,0	0,2
	4	Erde	4,3	7,9	0,0	0,5	20,6	79,6	0,0	0,0	0,1	0,0
	3 / 2	Wiese	0,1	2,2	1,0	1,4	0,1	0,1	58,1	18,6	2,6	0,1
	3	Felder	2,1	2,1	0,3	0,6	9,1	6,8	15,5	49,7	7,1	0,2
	4	Bäume	0,4	1,5	0,9	0,1	4,8	0,2	25,7	17,2	85,5	8,7
	4	Wasser	0,0	3,0	0,0	6,8	0,0	0,0	0,2	0,0	0,0	81,4
K =			51,60	+/- 0,50	G_G =			57,60	+/- 0,40			

Tabelle 44: Gemittelte Konfusionsmatrix der 100 Klassifikationen der Stichprobenpixel mit dem „Maximum Likelihood“-Verfahren auf der Grundlage von Permutationssatz 6. (Alle Angaben in Prozent)

Kl a s s e n	Klassenzahl	Klassenname	R e f e r e n z									
			Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
	4	Fl_dach	3,8	-6,7	-2,6	4,4	3,0	-13,2	0,0	0,0	-0,1	0,2
	3 / 2	Sp_dach	4,2	4,2	-0,1	2,3	2,0	5,9	-0,5	0,0	-0,1	1,5
	3	Fassade	6,6	9,2	9,0	2,1	0,1	0,0	0,3	14,5	4,7	0,8
	4	Verkehr	-2,0	-6,3	-0,1	11,9	-7,0	-0,4	-0,1	0,0	0,0	-7,3
	2	Bahn	-5,8	-3,0	-6,0	-14,1	-7,7	-7,8	-0,7	0,0	-0,9	-0,8
	4	Erde	-8,7	2,9	0,0	-8,1	-3,1	8,7	-0,6	0,0	-2,2	0,0
	3 / 2	Wiese	0,0	-2,1	0,4	0,9	-0,2	0,1	5,2	-14,5	-11,9	-0,1
	3	Felder	2,0	1,6	-0,5	0,4	8,3	6,3	-12,0	-0,4	-11,9	0,2
	4	Bäume	0,4	1,5	0,4	0,1	4,8	0,2	8,6	0,4	22,6	8,7
	4	Wasser	-0,6	-1,2	-0,4	0,0	-0,2	0,0	-0,2	0,0	0,0	-3,2
Δ(K) =			6,50	+/- 0,71	Δ(G_G) =			5,50	+/- 0,64			

Tabelle 45: Differenzmatrix (elementweise Subtraktion der Prozentzahlen aus Tabelle 44 von denen aus Tabelle 43). (Alle Angaben in Prozent)

4.6 Untersuchung des Zusammenhangs zwischen Klassenzahl und Klassifikationsgenauigkeit

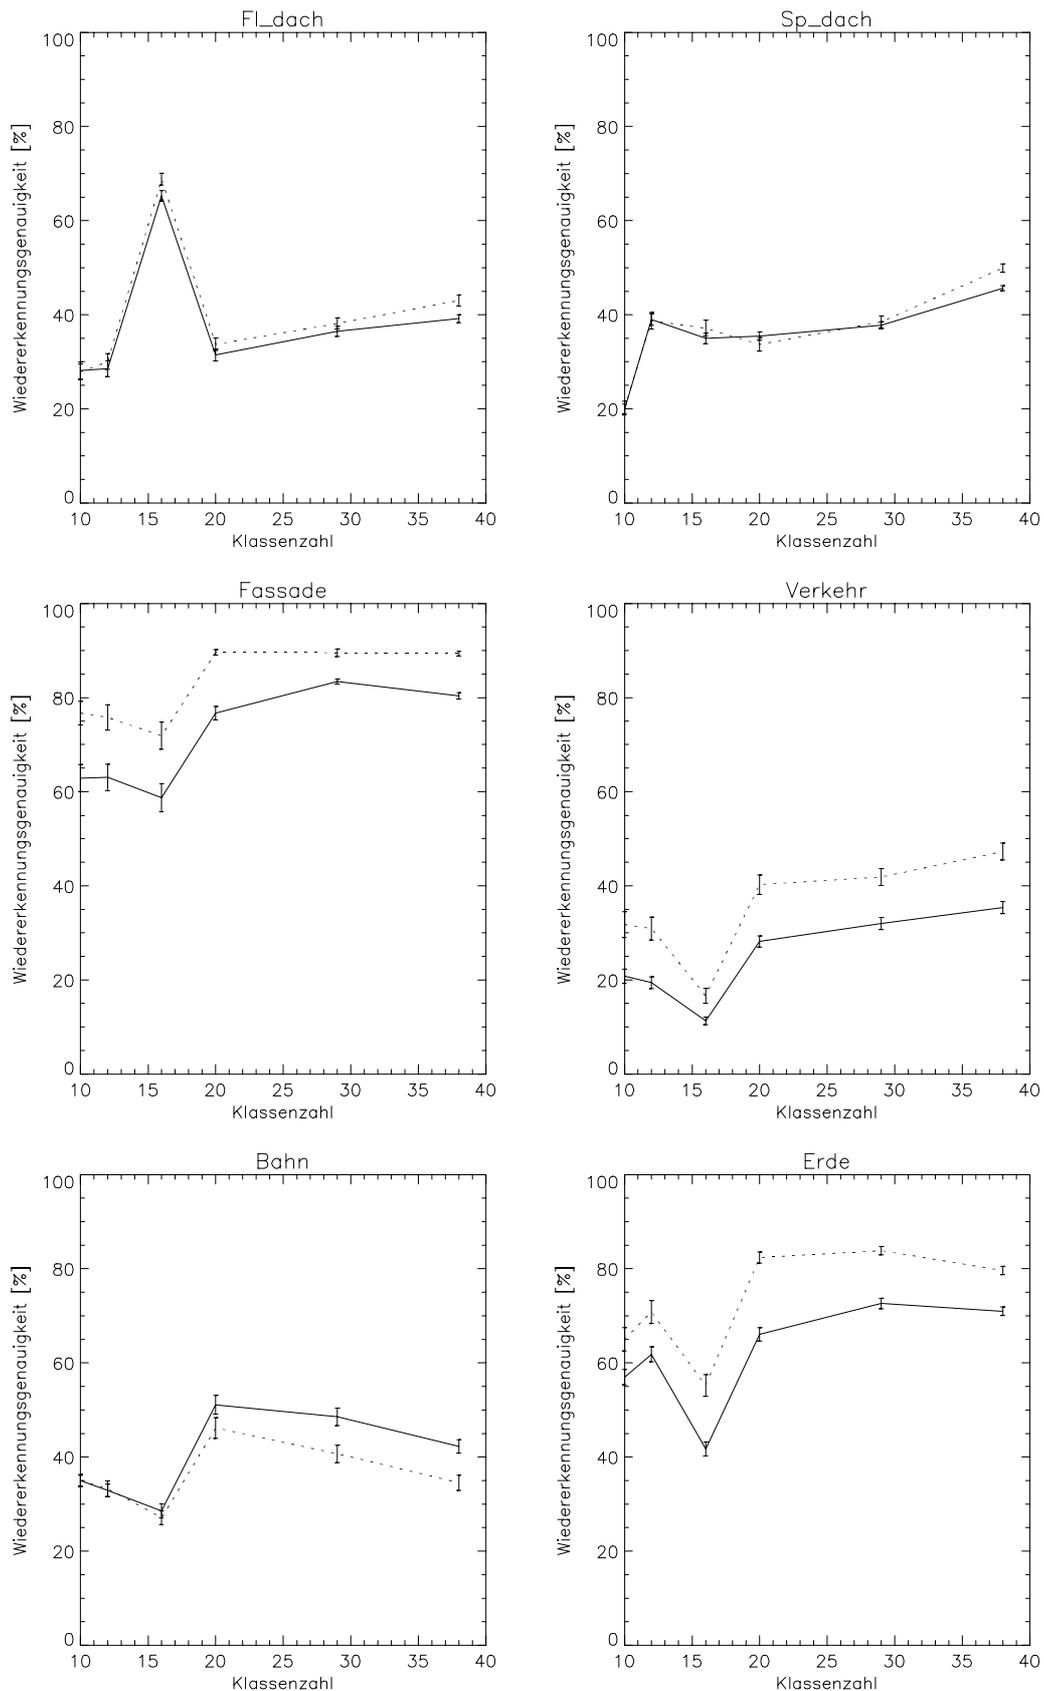


Abb. 20: Übersicht 1 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren (durchgezogene Linie) und dem „Maximum Likelihood“-Verfahren (gestrichelte Linie), bei Verwendung aller 10 Spektralkanäle, erreicht wurden.

4 Überwachte Klassifikation von Multispektralbildern

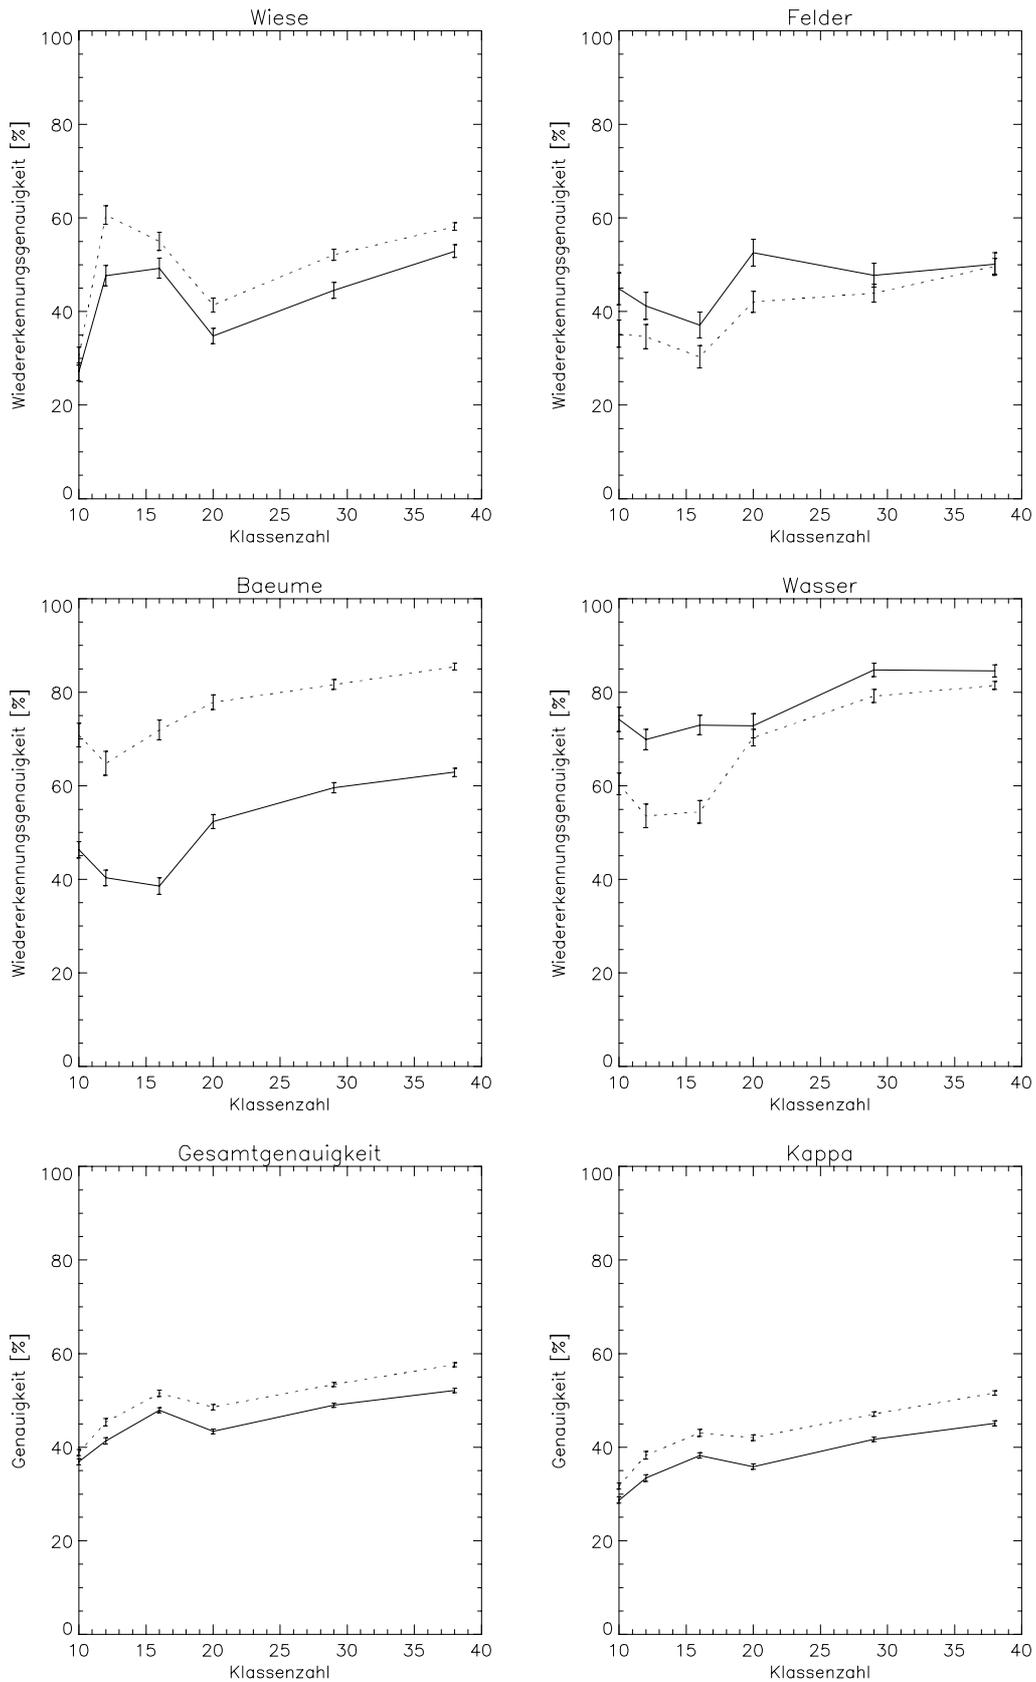


Abb. 21: Übersicht 2 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren (durchgezogene Linie) und dem „Maximum Likelihood“-Verfahren (gestrichelte Linie), bei Verwendung aller 10 Spektralkanäle, erreicht wurden.

Da sich die verschiedenen Permutationssätze jeweils in der Anzahl der insgesamt eingesetzten Trainingsklassen unterscheiden, ist es möglich, die Wiedererkennungsgenauigkeiten der einzelnen Informationsklassen in Abhängigkeit von der Gesamtzahl der Klassen graphisch darzustellen (siehe Abb. 20 und Abb. 21). Es ist hierbei zu beachten, daß die Zahl der Trainingsklassen, die für die einzelnen Informationsklassen eingesetzt wurden, unterschiedlich sind (vergleiche Tabelle 27).

4.6.2 Auswertung und Interpretation der Ergebnisse

Die Ergebnisse der Untersuchung werden im folgenden unter zwei Gesichtspunkten analysiert:

- Welchen Einfluß hat die Klassenzahl auf das Klassifikationsergebnis.
- Worin unterscheiden sich die Klassifikationsergebnisse beider Verfahren.

Einfluß der Klassenzahl:

Die Erhöhung der Klassenzahl von 10 auf 12 Trainingsklassen hat die Wiedererkennungsgenauigkeit der Informationsklassen „Sp_dach“ und „Wiese“ deutlich erhöht (jeweils um mindestens 18%). Allerdings ist die Wiedererkennungsgenauigkeit einiger Klassen, wie z.B. „Bäume“ und „Wasser“, um bis zu 6% gesunken. Trotzdem stieg der Kappa-Wert um durchschnittlich 5,7% an, so daß sich die Hinzunahme der beiden Trainingsklassen als sinnvoll erwiesen hat.

Die Erhöhung der Klassenzahl auf 16 Trainingsklassen, durch Hinzunahme 4 weiterer Klassen für die Informationsklasse „Fl_dach“, hat zwar die Wiedererkennungsgenauigkeit dieser Klasse erheblich erhöht (auf 65,3 bis 68,8%), jedoch ist auch die Wiedererkennungsgenauigkeit von einigen anderen Klassen deutlich gesunken. So ist z.B. die Genauigkeit der Klasse „Erde“ um mehr als 15% gesunken. Der Kappa-Wert ist gegenüber der Klassifikation mit 12 Klassen um 4,8% gestiegen. Für diesen Erfolg waren allerdings doppelt so viele zusätzliche Klassen notwendig als bei der ersten Klassenerhöhung.

In Permutationssatz 4 wurden 20 Trainingsklassen eingesetzt. Für jede Informationsklasse wurde die gleiche Anzahl an Trainingsklassen eingesetzt. Obwohl hierbei mehr Trainingsklassen eingesetzt wurden als bei Permutationssatz 3 sind die Klassifikationsergebnisse insgesamt schlechter. Mit Permutationssatz 5 (29 Klassen) und 6 (38 Klassen) werden die Klassifikationsergebnisse von Permutationssatz 3 wieder übertroffen.

Man kann aus den Ergebnissen schlußfolgern, daß man, wenn man nur wenige zusätzliche Trainingsklassen einsetzen möchte, diese auf spektral inhomogene Klassen konzentrieren sollte. Beim Einsatz vieler Trainingsklassen lohnt es sich, möglichst für jede Informationsklasse die gleiche Anzahl an Trainingsklassen zu wählen, weil sonst die Wiedererkennungsgenauigkeiten einzelner Klassen zu stark absinken können.

Vergleich der Wiedererkennungsgenauigkeiten beider Verfahren:

Die beiden Klassifikationsverfahren erreichten in den Klassen „Fl_dach“ und „Sp_dach“ jeweils sehr ähnliche Wiedererkennungsgenauigkeiten. Die Nutzung der Informationen, die in

4 Überwachte Klassifikation von Multispektralbildern

den Kovarianzmatrizen dieser beiden Klassen stecken, erhöht ihre Wiedererkennungsgenauigkeiten also nur unwesentlich. Anders ist es bei den Klassen „Fassade“, „Verkehr“, „Erde“, „Wiese“ und „Bäume“. Bei diesen Klassen liegen die Wiedererkennungsgenauigkeiten beim „Maximum Likelihood“-Verfahren höher als beim „Minimum Distance“-Verfahren. Bei den drei Klassen „Bahn“, „Felder“ und „Wasser“ führt die Einbeziehung der Informationen in den Kovarianzmatrizen sogar zur Verschlechterung der Wiedererkennungsgenauigkeiten dieser Klassen. Außerdem zeigen die Kurven (in Abb. 20 und Abb. 21) dieser drei Klassen einen auffälligen Verlauf. Denn während die Kurven beider Verfahren in den Diagrammen der übrigen Klassen für die selbe Klasse jeweils recht ähnlich verlaufen, verändert sich der Abstand zwischen den beiden Kurven in den Diagrammen der erwähnten drei Klassen in Abhängigkeit von der Klassenzahl. So nimmt der Abstand zwischen den beiden Kurven bei der Klasse „Bahn“ mit steigender Klassenzahl zu. Bei der Klasse „Felder“ nimmt dieser Abstand mit steigender Klassenzahl ab, und bei der Klasse „Wasser“ ist der Abstand zunächst groß und nimmt dann (bei einer Klassenzahl von 20 Klassen) sprunghaft ab.

Insgesamt betrachtet, liegen die Kappa-Werte, die mit dem „Maximum Likelihood“-Verfahren erreicht wurden, um **durchschnittlich 5% höher** als die Kappa-Werte, die mit dem „Minimum Distance“-Verfahren erreicht wurden.

Es stellt sich nun die Frage, warum die Unterschiede in den Kappa-Werten so gering sind. Um diese Frage beantworten zu können, muß man sich noch einmal vor Augen führen, worin der wesentliche Unterschied zwischen den beiden Verfahren besteht. Das „Minimum Distance“-Verfahren basiert auf Annahme, daß die Pixel der verschiedenen Klassen im Merkmalsraum isotrop (kugelförmig) um den entsprechenden Klassenmittelpunkt herum verteilt sind. Das „Maximum Likelihood“-Verfahren basiert auf der Annahme, daß die Pixel der verschiedenen Klassen im Merkmalsraum um den jeweiligen Klassenmittelpunkt herum normalverteilt¹⁰ sind.

Hieraus ergibt sich als erster möglicher Erklärungsansatz, daß die Pixel der verschiedenen Klassen im Merkmalsraum weitgehend isotrop um ihre Klassenmittelpunkte verteilt sind. Dieser Erklärung widersprechen allerdings die Beobachtungen, die an realen Beispielen (siehe Abb. 19 und Abb. 22) im Merkmalsraum gemacht wurden. So sind die Pixel in den beiden Abbildungen weder kugelförmig noch normalverteilt. Sie legen vielmehr die Vermutung nahe, daß die Pixel im Merkmalsraum häufig sehr komplex verteilt sind, so daß die Klassifikation der Pixel für beide Verfahren ähnlich schwierig ist.

Außerdem zeigt eine Betrachtung von Tabelle 55 im Anhang, daß die Anzahl der Pixel innerhalb einiger zum Training verwendeten Stichproben sehr gering sind. Hiervon sind vor allem die Stichproben betroffen, die für das Training der Klassen „Fassade“ und „Verkehr“ verwendet wurden. Die geringe Anzahl an Trainingspixel ist vor allem für das „Maximum Likelihood“-Verfahren problematisch, denn für die Schätzung der Kovarianzmatrix werden bei zehn Merkmalen (bzw. Spektralkanälen) die Verwendung von mindestens 100 Trainingspixel empfohlen (vergleiche Kap. 2.2.3). Allerdings zeigen die beiden Klassen „Fassade“ und „Verkehr“, die von diesem Problem am stärksten betroffen sind, keine Auffälligkeiten (siehe Abb. 20 und Abb. 21), die eindeutig auf dieses Problem zurückzuführen wären. Viel problematischer als die Zahl der Trainingspixel ist vermutlich die Tatsache, daß alle Trainingspixel einer Trainingsklasse aus einem räumlich eng begrenzten Gebiet stammen. Für die Klasse „Flachdach“ bedeutet dies beispielsweise, daß die

¹⁰Wenn die Pixel einer Klasse normalverteilt sind, dann nimmt die Konzentration der Pixel mit zunehmenden Abstand vom Mittelpunkt der entsprechenden Klasse ab. Die Stärke der Abnahme ist richtungsabhängig.

Trainingspixel, die von einem Dach aus Teerpappe stammen, nur unzureichende Informationen darüber enthalten, wie stark die Pixel, infolge von Materialschwankungen (Verwitterung, Herstellungstoleranzen), im Merkmalsraum verstreut liegen. Außerdem wurden alle Pixel, die zur gleichen Stichprobe gehören, jeweils unter einem ähnlichen Scan-Winkel gemessen¹¹. Dies kann ebenfalls zu einer Unterschätzung der Wahrscheinlichkeit führen, daß Pixel der betreffenden Klasse weit im Merkmalsraum verstreut liegen. Der einzige Ausweg scheint darin zu liegen, daß die Trainingspixel aus mehreren räumlich getrennten Gebieten ausgewählt werden. Hierdurch erhöht sich jedoch die Gefahr, daß die Pixel innerhalb der Trainingsklasse nicht mehr normalverteilt sind, erheblich. In diesem Fall wird die Wahrscheinlichkeit, daß Pixel der betreffenden Klasse im Merkmalsraum weit verstreut liegen, überschätzt. Eine Untersuchung über die Auswirkung dieses Problems wird in Kapitel 4.8 (Untersuchung von Methoden zur Reduzierung des Rechenaufwandes) durchgeführt.

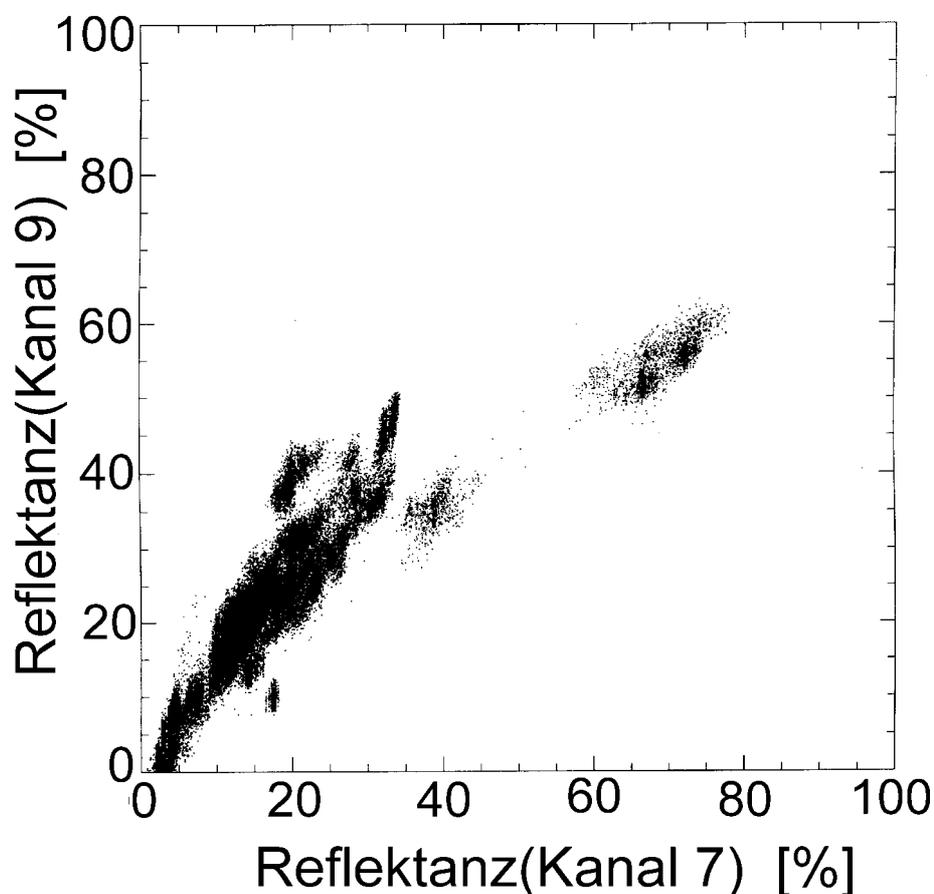


Abb. 22: Darstellung aller Kontrollpixel der Klasse „Flachdach“ (siehe **Tabelle 25**) im Merkmalsraum. (Projektion der Spektralkanäle 7 und 9 des Daedalus-Scanners.)

Neben den gemittelten Kappa-Werten ist auch die Größe des Fehlers, mit dem die gemittelten Kappa-Werte behaftet sind, von Bedeutung (siehe Tabelle 28 bis Tabelle 44). Man bedenke, daß

¹¹ In Kap. 2.1.4 wurde erwähnt, daß das Reflexionsverhalten eines Objektes nur mit der Hilfe der Reflexionsfunktion (BRDF) erschöpfend beschrieben werden kann. Diese Funktion hängt unter anderem von dem Winkel ab, unter dem ein Objekt beobachtet wird. Beim Daedalus-Scanner kann der Beobachtungswinkel (bzw. Scan-Winkel), unter dem eine horizontale Fläche (z.B. Flachdach) gescannt wird, in einem Bereich von $\pm 42,86^\circ$ (vergleiche Abb. 13) liegen. Je nach Scan-Winkel (und den Eigenschaften des reflektierendem Materials) können sich die vom Sensor gemessenen Strahldichten stark unterscheiden. Da dieser Effekt bei der Berechnung der Reflektanzwerte nicht berücksichtigt wurde, erhöht er zusätzlich die Streuung der Pixel im Merkmalsraum. In der Projektgruppe „Fernerkundung“ (CENSIS) wurde bislang in zwei Diplomarbeiten das winkelabhängige Reflexionsverhalten von Objekten gemessen (siehe [Meister 1996], [Rothkirch 1997]).

4 Überwachte Klassifikation von Multispektralbildern

der Fehler um so kleiner wird, je größer die Zahl der Kappa-Werte ist, über die gemittelt wird. Hierdurch werden die beträchtlichen Schwankungen in den Ergebnissen etwas verdeckt, die bei der Klassifikation mit den verschiedenen Trainingsätzen (aus jeweils dem gleichen Permutationssatz) auftraten. So schwankten beispielsweise die 100 Kappa-Werte, über die in Tabelle 43 („Permutationssatz 6“, „Minimum Distance“-Verfahren) gemittelt wurde, zwischen **31,7% und 57,0%**. Die 100 Kappa-Werte, über die in Tabelle 44 („Permutationssatz 6“, „Maximum Likelihood“-Verfahren) gemittelt wurde, reichten von **40,3% bis 62,0%**.

Fazit:

Die bisherige *Trainingsmethode*, d.h. die Auswahl von kleinen und räumlich begrenzten Trainingsgebieten führte zu einer Benachteiligung des „Maximum Likelihood“-Verfahrens. Allerdings wurden die beiden Verfahren bisher auch nur im Hinblick auf die Anzahl der eingesetzten Trainingsklassen verglichen. Da der Rechenaufwand in Abhängigkeit der Trainingsklassenzahl für beide Verfahren sehr unterschiedlich ist, ist auch noch ein Vergleich auf der Grundlage des benötigten Rechenaufwandes notwendig.¹²

Man kann jedoch aus dem Vergleich der beiden Verfahren in diesem Kapitel schlußfolgern, daß das „Maximum Likelihood“-Verfahren durch die Nutzung der zusätzlichen Informationen, die in der Kovarianzmatrix enthalten sind, die Klassifikationsgenauigkeit (Kappa-Werte) um durchschnittlich 5% steigern konnte.

Aus der starken Schwankung der einzelnen Klassifikationsergebnisse kann man schlußfolgern, daß eine sorgfältige Auswahl der Trainingsgebiete wichtiger ist als die Entscheidung, welches der beiden Verfahren verwendet wird.

4.7 Untersuchung von Methoden zur Erhöhung der Klassifikationsgenauigkeit

In diesem Kapitel werden Methoden untersucht, um die bisher erreichten Klassifikationsgenauigkeiten zu erhöhen. Es gibt im wesentlichen drei Ansatzpunkte, um die Genauigkeit einer Klassifikation zu erhöhen:

- 1) Man kann das zu klassifizierende Bildmaterial vor der Klassifikation filtern, um die spektrale Vielfalt im Bildmaterial zu reduzieren.
- 2) Man kann versuchen, die Mittelwerte und die Kovarianzmatrizen der Trainingsklassen zu optimieren
- 3) Man kann den Merkmalsraum durch geeignete Merkmale erweitern. Hierbei muß es sich nicht um spektrale Merkmale handeln.

4.7.1 Durchführung der Untersuchung

Im folgenden werden zwei Methoden untersucht (Methode A und B), die sich beide auf den zweiten Ansatzpunkt beziehen.

¹² Dieser Vergleich wird in Kap. 4.8 durchgeführt.

Methode A:

In Kap 4.5 wurde die „optimale“ Lage für die verschiedenen Trainingsklassen im Merkmalsraum dadurch gefunden, daß für jede Klasse jeweils die Stichprobe ermittelt wurde, die den geringsten euklidischen Abstand zu den übrigen Stichproben der entsprechenden Klasse besaß. Wenn man mehr als eine Trainingsklasse pro Informationsklasse einsetzen möchte, dann ist diese Vorgehensweise nicht empfehlenswert. In einer solchen Situation ist es sinnvoller, ein *unüberwachtes Klassifikationsverfahren* einzusetzen. Hierbei werden von dem unüberwachten Klassifikationsprogramm die Punkte (Häufungspunkte) gesucht, an denen sich die Pixel der jeweiligen Informationsklasse im Merkmalsraum konzentrieren. Von diesen Häufungspunkten wird angenommen, daß sie in etwa der optimalen Lage für Trainingsklassen der verschiedenen Informationsklassen entsprechen. Die Schritte, die zur Umsetzung einer derartigen Vorgehensweise notwendig sind, werden im folgenden beschrieben.

Ein unüberwachtes Klassifikationsprogramm benötigt zu Beginn seiner Arbeit zwei verschiedene Eingaben, nämlich die Anzahl der Häufungspunkte und die Grauwerte (Merkmale) der Pixel, aus denen es die Häufungspunkte ermitteln soll. Deshalb wurden im ersten Schritt der Untersuchung die Pixel aller Stichproben, die jeweils der gleichen Trainingsgruppe angehörten, zusammengefaßt. Am Beispiel der Trainingsgruppe „Flachdach“ bedeutete dies, daß die Grauwerte, der Stichproben „Flachdach 1“ bis „Flachdach 20“ in ein gemeinsames Datenfeld übertragen werden mußten. Als nächstes benötigt das Programm noch Angaben über die Anzahl der Häufungspunkte, die es in dem Merkmalsraum finden soll, der aus den Pixeln gebildet wird, die dem Programm übergeben wurden. Es ist sehr schwierig, die optimale Anzahl an Häufungspunkten für die verschiedenen Klassen zu ermitteln, weil in der Praxis die Anhäufungen der Pixel im Merkmalsraum meistens nicht scharf voneinander abgetrennt sind. Außerdem sollten die Ergebnisse aus dieser Untersuchung mit den Ergebnissen aus den Untersuchungen in Kap. 4.6 vergleichbar sein. Deshalb wurde die Zahl der Häufungspunkte analog zur Anzahl der Stichproben gewählt, die der Computer in Kap. 4.6 zufällig aus den verschiedenen Trainingsgruppen auswählen mußte (beachte Tabelle 27). In dieser Untersuchung legen die Erzeugungsvorschriften also fest, wie viele Häufungspunkte in den verschiedenen Trainingsgruppen vom unüberwachten Klassifikationsprogramm gesucht werden sollen. Am konkreten Beispiel von Permutationssatz 3 bedeutet dies, daß das unüberwachte Klassifikationsprogramm fünf Häufungspunkte in der Trainingsgruppe „Flachdach“ zu suchen hatte und jeweils einen Häufungspunkt in den Trainingsgruppen „Spitzdach(bel)“, „Spitzdach(sch)“, „Fassade“, „Verkehr“, „Eisenbahn“, „Erdreich“, „Wiese(bel)“, „Wiese(sch)“, „Felder“, „Bäume“ und „Gewässer“.

Im folgenden wird die Arbeitsweise des eingesetzten unüberwachten Klassifikationsprogramms stichwortartig beschrieben:

- 1. Schritt:** Übergabe der Grauwerte der Pixel P und der Anzahl Z der zu suchenden Häufungspunkte an das Programm
- 2. Schritt:** Zufällige Auswahl von Z Pixeln aus den übergebenen Pixeln P und Verwendung dieser Pixel als *Startpunkte* S_i
- 3. Schritt:** Berechnung der euklidischen Abstände zwischen jedem Pixel P und den Z Startpunkten S_i
- 4. Schritt:** Bestimmung des jeweils kürzesten Abstandes für jedes Pixel P und Zuordnung des jeweiligen Pixels zu dem entsprechenden Startpunkt (d.h. Bildung von Klassen)

4 Überwachte Klassifikation von Multispektralbildern

5. Schritt: Berechnung der Klassenmittelpunkte \bar{m}_i (mit $i = 1, \dots, Z$) für die in Schritt 4) gebildeten Klassen
6. Schritt: Berechnung der Abstände zwischen den Klassenmittelpunkten \bar{m}_i und jedem Pixel P
7. Schritt: Bestimmung des jeweils kürzesten Abstandes für jedes Pixel P und Zuordnung zu der entsprechenden Klasse (d.h. Bildung neuer Klassen)
8. Schritt: Berechnung der neuen Klassenmittelpunkte \bar{n}_i (mit $i = 1, \dots, Z$)
9. Schritt: Wiederholung von Schritt 6) bis 8) solange bis der größte euklidische Abstand, der zwischen einem alten Klassenmittelpunkt \bar{m}_i (mit $i = 1, \dots, Z$) und dem entsprechenden neuen Klassenmittelpunkt \bar{n}_i liegt, kleiner ist als ein Prozent des Abstandes zwischen dem jeweiligen alten Klassenmittelpunkt \bar{m}_i und dem Ursprung des Merkmalsraumes, d.h.

$$\max \left(\frac{d(\bar{m}_i, \bar{n}_i)}{d(\bar{m}_i, \text{Ursprung})} \text{ mit } i = 1, \dots, Z \right) < 0,01$$
10. Schritt: Rückgabe der zuletzt berechneten Klassenmittelpunkte \bar{n}_i als Ergebnis¹³

Abb. 23 zeigt zur Verdeutlichung des Verfahrens eine grafische Darstellung von einigen Programmschritten, die zur unüberwachten Klassifikation eines einfachen fiktiven Beispiels notwendig sind.

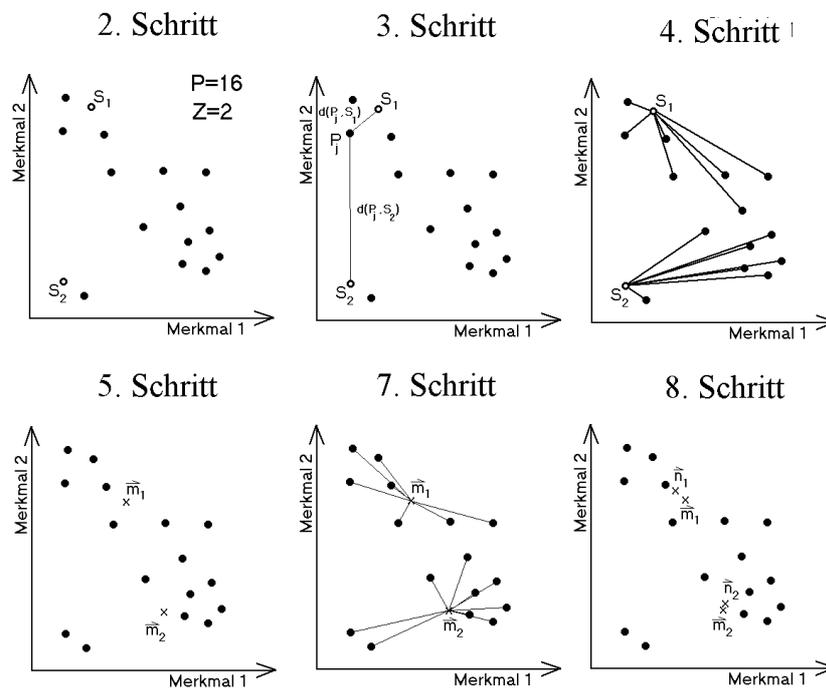


Abb. 23: Darstellung zur Veranschaulichung des unüberwachten Klassifikationsprogramms (an einem einfachen Beispiel)

In Abb. 24 wird das Verfahren an einen realen Beispiel demonstriert. Das unüberwachte Klassifikationsprogramm wurde hierbei vor die Aufgabe gestellt, in den Pixeln der Stichproben

¹³ Die vom Programm übergebenen Klassenmittelpunkte entsprechen den gesuchten Häufungspunkten. Das Programm führt, bei Anforderung nur eines einzigen Häufungspunktes, lediglich eine kanalweise Mittelung der übergebenen Pixel durch.

„Flachdach 1“ bis „Flachdach 20“ fünf Häufungspunkte zu suchen. Die vom Programm gefundenen Häufungspunkte sind jeweils mit einem „+“-Symbol markiert worden. Das Programm benötigt 17 Iterationen, um diese Häufungspunkte zu finden. Die in den verschiedenen Iterationen berechneten Klassenmittelpunkte wurden durch Linien verbunden. Einer der in Abb. 24 dargestellten Häufungspunkte liegt zwischen mehreren Anhäufungen aus Pixeln. Es kann also vorkommen, daß sich an den Häufungspunkten, die von einem unüberwachten Klassifikationsprogramm gefunden wurden, gar keine Pixel befinden. Dies ist ein wichtiges Problem bei unüberwachten Klassifikationsverfahren.

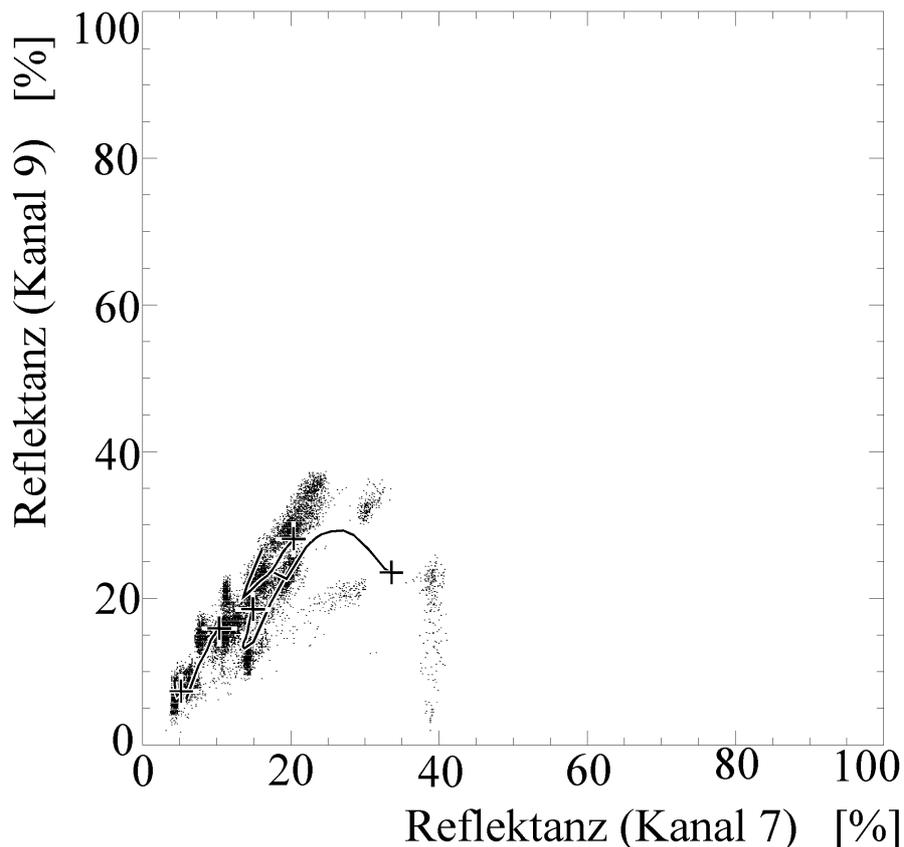


Abb. 24: Demonstration des unüberwachten Klassifikationsprogramms an einem realen Beispiel. (Klassifikation der Pixel der Stichproben „Flachdach 1“ bis „Flachdach 20“ in 5 Klassen).

Im weiteren Verlauf der Versuchsdurchführung wurden die Kontrollpixel (siehe Tabelle 25) mit dem „Minimum Distance“-Verfahren klassifiziert, wobei als Training die Häufungspunkte dienten, die vom unüberwachten Klassifikationsprogramm geliefert wurden. Die Zahl der Häufungspunkte (bzw. Zahl der Trainingsklassen) wurde, wie schon erwähnt, entsprechend den Erzeugungsvorschriften der sechs Permutationssätze gewählt (siehe Tabelle 27). Die Suche nach den Häufungspunkten und die anschließende Klassifikation der Kontrollpixel wurde für jede Erzeugungsvorschrift 100 mal durchgeführt, weil das unüberwachte Klassifikationsprogramm nicht bei jedem Programmdurchlauf die exakt gleichen Häufungspunkte lieferte. Die jeweils 100 Konfusionsmatrizen wurden wieder (wie in Kap. 4.6 beschrieben) gemittelt. Die Kontrollpixel wurden also insgesamt 600 mal klassifiziert und 6 gemittelte Konfusionsmatrizen erzeugt (siehe Tabelle 46 bis Tabelle 51). Einen Überblick über die erreichten Wiedererkennungsgenauigkeiten in Abhängigkeit von der Anzahl der eingesetzten Trainingsklassen (bzw. Häufungspunkte) liefert Abb. 25.

Methode B:

In Kap. 4.5.2 wurde beobachtet, daß die Wiedererkennungsgenauigkeit der Pixel der Klasse „Flachdach“ recht gering war. Es wurde vermutet, daß dies daran lag, daß die Pixel eines einzelnen Flachdaches sich spektral ähnlicher sind als dies bei den Pixeln von Flachdächern allgemein der Fall ist. In Methode B wird deshalb versucht, durch Multiplikation aller Elemente der Kovarianzmatrix der entsprechenden Trainingsklasse mit einem konstanten Faktor F ($F > 1$), diesen Effekt zu kompensieren. Denn die Werte einer Kovarianzmatrix sind um so größer, je stärker die Pixel, aus denen sie berechnet wurde, im Merkmalsraum verstreut sind.

Zu diesem Zweck wurden die Kontrollpixel aus Kap. 4.6 erneut klassifiziert. Das Training erfolgte mit Permutationssatz 2. Die Kovarianzmatrix der Trainingsklasse für die Klasse „Flachdach“ wurde in jedem Trainingssatz des Permutationssatzes 2 mit dem jeweils gleichen Faktor multipliziert. Anschließend wurden die Kontrollpixel klassifiziert. Aus den 100 Klassifikationen wurden wieder die gemittelten Konfusionsmatrizen berechnet. Die Vorgehensweise wurde für die Faktoren 2, 4, 6, 8, 10 und 12 durchgeführt. Die gemittelten Konfusionsmatrizen wurden, um Platz zu sparen, nicht abgedruckt. Dafür zeigt Abb. 26 die Wiedererkennungsgenauigkeiten für die einzelnen Klassen in Abhängigkeit der eingesetzten Faktoren.

4.7.2 Auswertung und Interpretation der Ergebnisse

Auswertung Methode A:

Ein Vergleich der Kurven in Abb. 20 mit den Kurven in Abb. 25 für die Klassen „Fl_dach“ und „Sp_dach“ zeigen, daß sich die Kurven der jeweiligen Klasse zumindest in ihrem qualitativen Verlauf sehr ähnlich sind. Ansonsten bestehen wenig Übereinstimmungen zwischen den Kurven in Abb. 25 und den Kurven in Abb. 20 und Abb. 21. So sind in vielen Kurven starke Sprünge zu beobachten. Beim Übergang von 10 zu 12 Klassen tritt z.B. ein starker Sprung in der Wiedererkennungsgenauigkeit der Klasse „Felder“ auf. Dieser Sprung wird durch die Bildung jeweils einer getrennten Trainingsklasse aus den Pixeln der Trainingsgruppe „Wiese(bel)“ und „Wiese(sch)“ verursacht. Ein weiterer starker Sprung tritt in der Klasse „Bahn“ beim Übergang von 12 zu 16 Klassen auf. Das Auftreten dieses Sprungs legt die Vermutung nahe, daß diese Klasse im Merkmalsraum zwei spektral unterschiedliche Unterklassen besitzt. Diese Unterklasse müssen allerdings auch räumlich getrennt sein, denn sonst hätten die vom „Maximum Likelihood“-Verfahren erreichten Wiedererkennungsgenauigkeiten in dieser Klasse nicht niedriger sein dürfen, als die des „Minimum Distance“-Verfahrens (siehe Abb. 20).

Für zwei Klassen hat die Erhöhung der Anzahl der Trainingsklassen keine Vorteile gebracht, nämlich für die Klassen „Fassade“ und „Wasser“. Bei diesen beiden Klassen sinkt die Wiedererkennungsgenauigkeit mit steigender Klassenzahl, vor allem beim Übergang von 29 zu 38 Trainingsklassen.

Die Kappa-Werte steigen nur beim Übergang von 12 zu 16 Klassen stärker an. Die weitere Erhöhung der Klassenzahl bewirkt nur noch geringfügige Steigerungen des Kappa-Wertes. Allerdings führt die Erhöhung der Klassenzahl dazu, daß sich die Wiedererkennungsgenauigkeiten der einzelnen Klassen einander angleichen. So liegen bei der Klassifikation mit 38 Klassen die Wiedererkennungsgenauigkeiten von allen Klassen bei mindestens 40%.

4.7 Untersuchung von Methoden zur Erhöhung der Klassifikationsgenauigkeit

		R e f e r e n z									
Klassenzahl	Klassenname	FL_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
1	FL_dach	25,4	1,9	0,1	18,2	12,8	4,8	0,0	0,0	0,0	0,0
1	Sp_dach	7,6	12,7	0,0	0,4	0,4	17,0	1,8	0,0	0,1	0,0
1	Fassade	9,4	32,0	88,8	5,0	0,0	0,0	0,0	0,0	0,6	0,0
1	Verkehr	32,5	8,3	0,6	20,9	0,4	0,5	0,0	0,0	0,1	0,0
1	Bahn	8,2	13,5	7,8	28,5	22,8	32,0	2,0	0,0	18,8	0,0
1	Erde	8,6	2,7	0,0	13,8	41,3	45,7	1,6	0,0	3,6	0,0
1	Wiese	0,0	0,0	0,0	0,2	0,0	0,0	42,9	12,1	5,4	0,0
1	Felder	0,0	0,1	1,2	0,0	0,0	0,0	26,5	75,8	21,9	0,0
1	Bäume	0,0	0,0	0,0	0,1	0,0	0,0	7,8	12,0	48,8	0,0
1	Wasser	8,3	28,7	1,6	12,8	22,2	0,0	17,4	0,0	0,9	100,0
K = 35,10		G_G = 41,79									

Tabelle 46: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 10 Klassen. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	FL_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
1	FL_dach	29,0	5,4	0,1	18,4	13,0	15,4	0,6	0,0	0,0	0,0
1 / 1	Sp_dach	2,7	34,1	7,4	2,4	25,9	0,0	0,0	0,0	0,0	0,2
1	Fassade	9,4	5,3	87,7	5,0	0,0	0,0	0,0	0,0	0,4	0,0
1	Verkehr	35,9	11,7	0,6	21,0	0,4	1,0	0,1	0,0	0,1	0,0
1	Bahn	6,0	11,0	2,7	26,3	6,0	32,0	0,8	0,0	14,7	0,0
1	Erde	9,2	2,9	0,0	13,9	41,5	51,7	1,9	0,0	3,6	0,0
1 / 1	Wiese	3,3	17,9	0,9	0,3	12,0	0,0	49,8	63,9	19,7	0,5
1	Felder	0,0	0,0	0,5	0,1	0,0	0,0	22,3	17,1	9,5	0,0
1	Bäume	0,0	0,0	0,0	0,2	0,0	0,0	24,1	18,9	51,9	0,0
1	Wasser	4,5	11,6	0,2	12,4	1,2	0,0	0,4	0,0	0,0	99,2
K = 34,60		G_G = 42,22									

Tabelle 47: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 12 Klassen. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	FL_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
5	FL_dach	73,8	23,8	4,8	41,2	24,0	43,9	1,0	0,1	0,1	0,0
1 / 1	Sp_dach	1,2	31,4	7,4	2,2	21,0	0,0	0,0	0,0	0,0	0,2
1	Fassade	4,0	4,7	83,6	3,8	0,0	0,0	0,0	0,0	0,4	0,0
1	Verkehr	9,0	3,4	0,1	13,8	0,5	1,0	0,0	0,0	0,0	0,0
1	Bahn	1,6	6,5	2,5	22,4	5,0	4,8	0,8	0,0	14,7	0,0
1	Erde	4,0	2,2	0,0	3,6	36,7	50,3	2,0	0,0	3,6	0,0
1 / 1	Wiese	2,0	16,4	0,9	0,3	11,6	0,0	49,8	63,9	19,7	0,5
1	Felder	0,0	0,0	0,4	0,1	0,0	0,0	22,1	17,0	9,5	0,0
1	Bäume	0,0	0,0	0,0	0,2	0,0	0,0	23,9	18,9	51,9	0,0
1	Wasser	4,4	11,6	0,2	12,4	1,2	0,0	0,4	0,0	0,0	99,2
K = 44,70		G_G = 53,82									

Tabelle 48: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 16 Klassen. (Alle Angaben in Prozent)

4 Überwachte Klassifikation von Multispektralbildern

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
2	Fl_dach	29,6	7,1	0,1	29,9	0,1	3,1	0,0	0,0	0,0	0,0
1 / 1	Sp_dach	1,0	29,9	9,6	8,5	1,2	0,0	0,0	0,0	0,0	0,0
2	Fassade	3,5	7,3	79,2	0,2	0,0	0,0	0,0	0,0	0,0	0,0
2	Verkehr	23,0	7,8	8,3	26,3	4,2	0,2	0,0	0,0	0,0	0,0
2	Bahn	14,6	11,8	0,6	17,6	71,5	8,6	1,0	0,0	2,7	0,0
2	Erde	22,7	9,4	0,0	4,5	17,3	88,0	0,4	0,0	0,6	0,0
1 / 1	Wiese	1,0	14,7	0,1	0,3	2,2	0,0	65,7	11,3	14,2	0,5
2	Felder	0,0	0,0	0,6	0,4	0,0	0,0	28,1	40,5	30,9	0,0
2	Bäume	0,0	0,1	1,3	0,0	0,0	0,0	4,0	48,1	51,6	0,0
2	Wasser	4,6	11,8	0,4	12,4	3,5	0,0	0,8	0,0	0,0	99,4
K = 44,70		G_G = 52,56									

Tabelle 49: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 20 Klassen. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
3	Fl_dach	36,2	6,4	2,2	23,3	3,9	22,8	0,0	0,0	0,0	0,0
2 / 1	Sp_dach	6,1	34,0	6,7	4,1	1,2	0,0	0,0	0,1	0,4	0,0
3	Fassade	2,9	5,4	72,4	0,2	0,0	0,0	0,0	0,0	0,3	0,0
3	Verkehr	24,5	10,1	7,6	46,4	5,1	1,5	0,0	0,0	0,0	0,0
2	Bahn	9,4	8,6	0,5	10,2	68,8	1,4	0,8	0,0	0,9	0,0
3	Erde	14,6	8,1	0,0	2,6	15,0	74,4	0,4	0,0	0,5	0,0
2 / 1	Wiese	1,4	14,8	8,7	0,4	2,2	0,0	53,5	14,8	9,1	0,5
3	Felder	0,0	0,0	0,8	0,3	0,3	0,0	18,4	54,5	20,9	0,0
3	Bäume	0,0	0,1	0,7	0,0	0,0	0,0	26,1	30,6	68,0	0,0
3	Wasser	4,8	12,5	0,5	12,5	3,5	0,0	0,9	0,0	0,0	99,4
K = 47,30		G_G = 55,00									

Tabelle 50: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 29 Klassen. (Alle Angaben in Prozent)

		R e f e r e n z									
Klassenzahl	Klassenname	Fl_dach	Sp_dach	Fassade	Verkehr	Bahn	Erde	Wiese	Felder	Bäume	Wasser
4	Fl_dach	47,0	11,6	5,0	32,1	4,6	25,8	0,0	0,0	0,0	0,0
3 / 2	Sp_dach	3,8	41,7	0,2	0,7	10,2	0,0	0,2	0,1	0,1	0,2
3	Fassade	0,5	3,9	41,8	0,4	0,0	0,0	0,0	0,0	0,2	0,0
4	Verkehr	27,9	14,1	0,9	49,8	3,0	0,3	0,2	0,0	0,0	5,6
2	Bahn	3,9	7,7	6,2	5,8	64,5	0,3	0,2	0,0	0,2	0,0
4	Erde	13,2	8,1	0,0	3,0	17,2	73,6	0,4	0,0	0,3	0,0
3 / 2	Wiese	3,1	7,6	43,8	0,3	0,0	0,0	55,0	23,3	9,1	0,3
3	Felder	0,0	0,1	0,7	0,2	0,2	0,0	17,4	53,6	15,7	0,0
4	Bäume	0,0	0,1	0,8	0,0	0,0	0,0	26,1	23,0	74,3	0,0
4	Wasser	0,5	5,3	0,6	7,8	0,4	0,0	0,5	0,0	0,0	93,8
K = 50,40		G_G = 54,32									

Tabelle 51: Gemittelte Konfusionsmatrix aus 100 Klassifikationen mit „Methode A“ und 38 Klassen. (Alle Angaben in Prozent)

4.7 Untersuchung von Methoden zur Erhöhung der Klassifikationsgenauigkeit

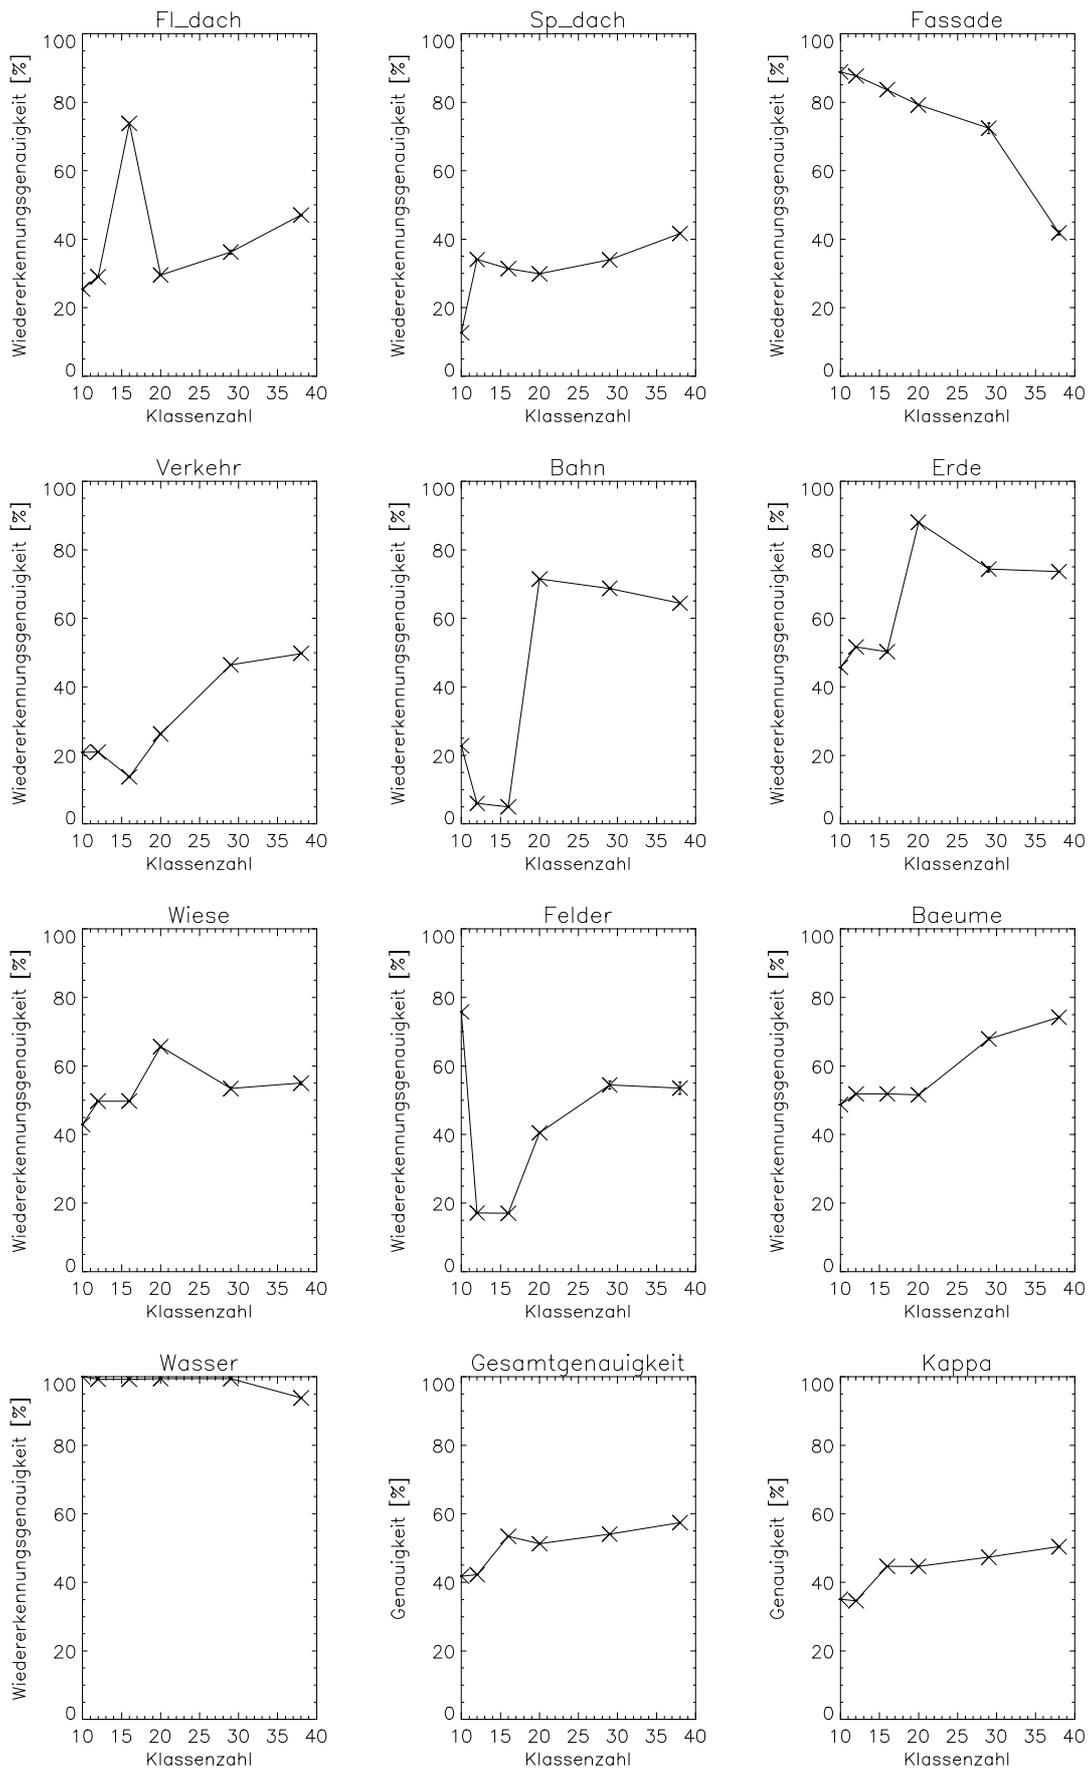


Abb. 25: Übersicht über die Ergebnisse, die bei den Klassifikationen mit „Methode A“ erreicht wurden.

4 Überwachte Klassifikation von Multispektralbildern

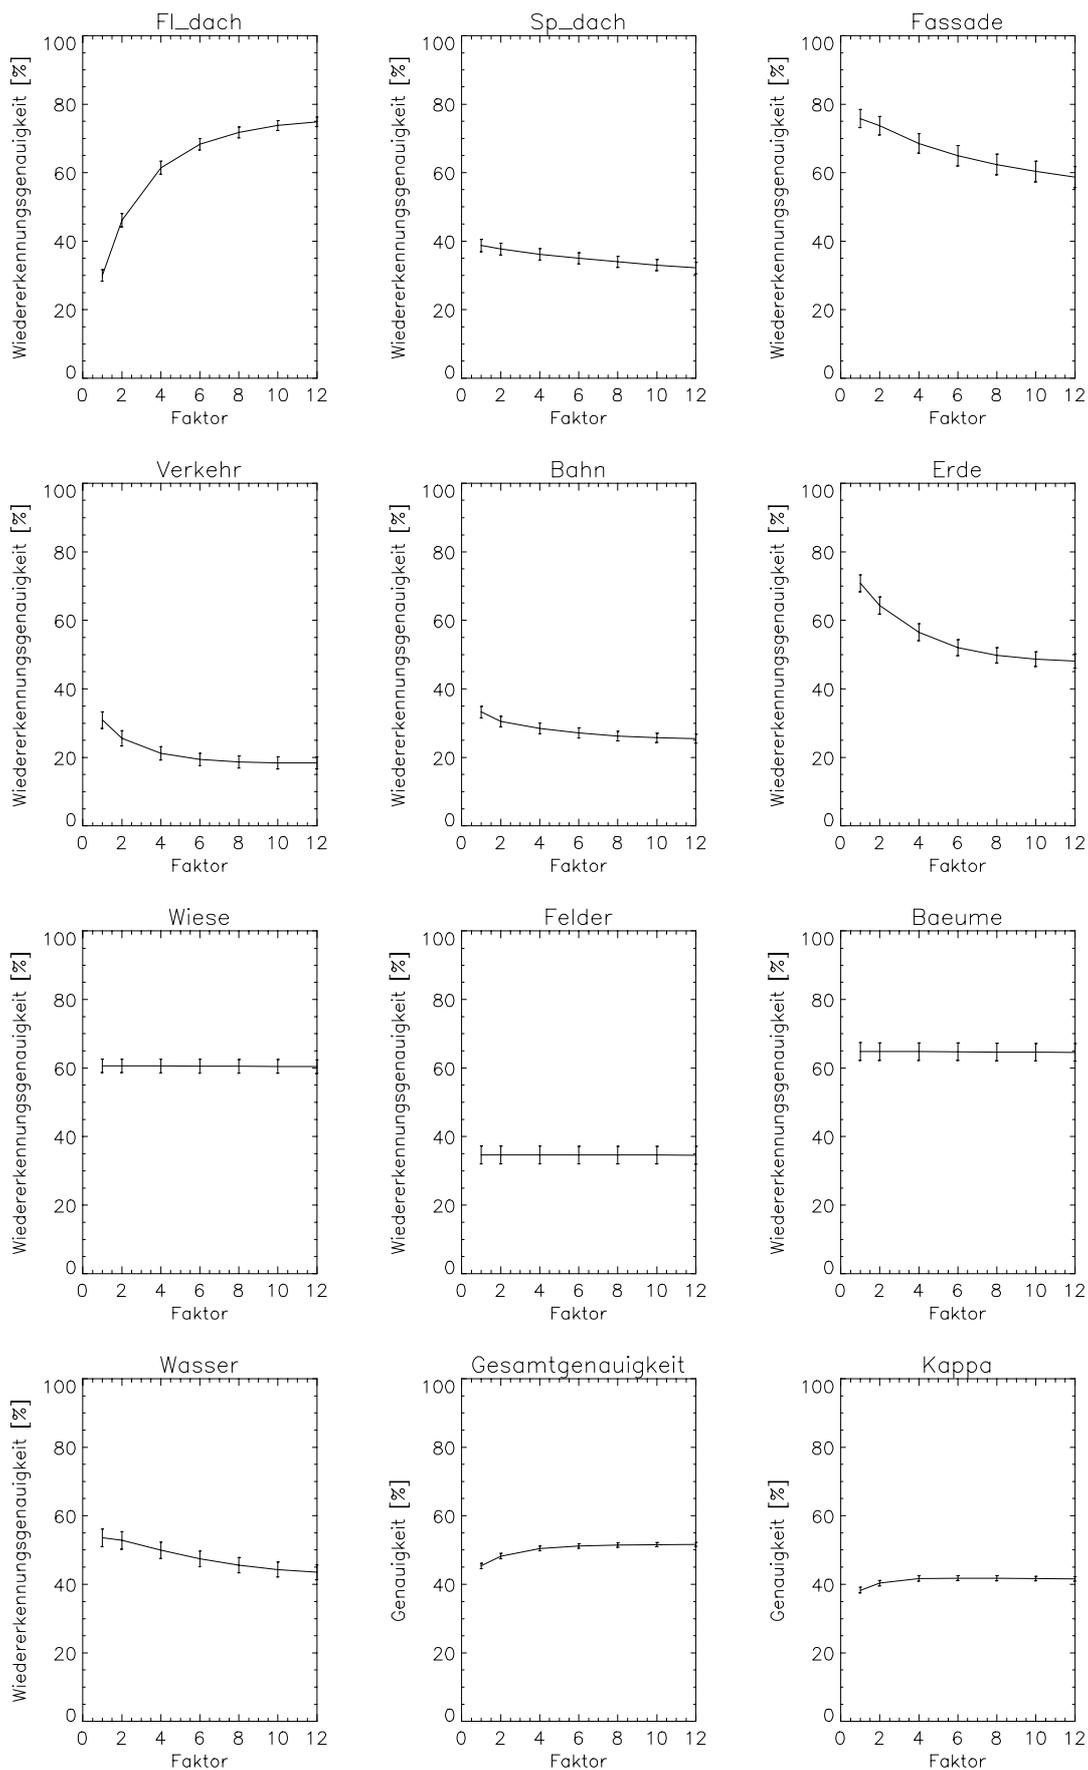


Abb. 26: Übersicht über die Ergebnisse, die bei den Klassifikationen mit „Methode B“ erreicht wurden.

Insgesamt gesehen hat diese Methode die Klassifikation mit dem „Minimum Distance“-Verfahren um ca. 5% verbessern können. Die nur geringfügige Verbesserung der Klassifikationsgenauigkeit hat vermutlich zwei Ursachen. Zum einen werden nicht immer reale Häufungspunkte von dem unüberwachten Klassifikationsprogramm gefunden. So kann es vorkommen, daß sich an einem von dem Programm gefundenen Häufungspunkt gar kein Pixel befindet (vergleiche Abb. 24). Zum anderen war vermutlich die Zahl der Pixel, die dem unüberwachten Klassifikationsprogramm übergeben wurden, nicht immer ausreichend, um auf die wahre Verteilung der Pixel der betreffenden Klasse im Merkmalsraum zu schließen. Dieses Problem ist an der Klasse „Flachdach“ gut sichtbar. Denn die Pixel der Stichproben „Flachdach 1“ bis „Flachdach 20“ häufen sich in Abb. 24 an teilweise ganz anderen Stellen als die Kontrollpixel in Abb. 22. Die eigentliche Problem liegt also eher wieder in der großen spektralen Inhomogenität innerhalb einiger Informationsklassen.

Auswertung Methode B:

In Abb. 26 ist zu erkennen, daß die Erhöhung des Faktors zu einem anfänglich sehr starken Anstieg der Wiedererkennungsgenauigkeit der Klasse „Fl_dach“ führt. Die Stärke des Anstieges nimmt mit der Zunahme des Faktors ab, und bei Faktor 12 erreicht die Wiedererkennungsgenauigkeit dieser Klasse annähernd seinen „Sättigungspunkt“, der bei ca. 75% liegt.

Die Erhöhung des Faktors verbesserte nicht nur die Klassifikation der Pixel der Klasse „Fl_dach“, sondern verschlechterte gleichzeitig die Wiedererkennungsgenauigkeiten einiger anderer Klassen. Zu diesen Klassen zählen vor allem die Klassen „Fassade“, „Verkehr“ und „Erde“. Es gibt aber auch drei Klassen, deren Wiedererkennungsgenauigkeiten unverändert blieben. Hierzu gehören die Klassen „Wiese“, „Felder“ und „Bäume“.

Interessant ist aber auch der Verlauf der Kurven. Denn die Kurven der verschiedenen Klassen zeigen unterschiedlich starke Krümmungen. So ist z.B. die Kurve der Klasse „Erde“ viel stärker gekrümmt als die Kurve der Klasse „Bahn“.

Mit dieser Methode konnte also die Wiedererkennungsgenauigkeit der Klasse „Fl_dach“ deutlich erhöht werden, wobei der Kappa-Wert zwischen den Faktoren von 1 bis 4 um 3,1% anstieg und anschließend stagnierte. Zwar ist dieser Anstieg nicht sehr hoch, jedoch konnte die Erhöhung erreicht werden, ohne daß die Zahl der Trainingsklassen erhöht wurde, was zusätzlichen Trainings- und Rechenaufwand bedeutet hätte. Außerdem bedeutet die Stagnation des Kappa-Wertes bei den größeren Faktoren, daß das Finden eines geeigneten Faktors relativ unproblematisch ist.

4.8 Untersuchung von Methoden zur Reduzierung des Rechenaufwandes

Bevor mit der Untersuchung von Methoden zur Reduzierung des Rechenaufwandes bei der Durchführung einer Klassifikation begonnen werden kann, muß zunächst geklärt werden, wodurch die Größe des Rechenaufwandes beeinflusst wird. Der Rechenaufwand ist für beide Verfahren sehr unterschiedlich. Beim „Minimum Distance“-Verfahren liegt der größte Aufwand in der Berechnung der euklidischen Abstände zwischen den einzelnen Pixeln, die klassifiziert werden sollen, und den Mittelpunkten der Trainingsklassen (siehe Gl. 5). Da die Berechnung der Wurzel, wie bereits in Kap. 2.2.2 erwähnt, weggelassen werden kann, ergibt sich als Rechenaufwand R_{MD} pro Pixel für das „Minimum Distance“-Verfahren:

4 Überwachte Klassifikation von Multispektralbildern

$$R_{MD} = M_{MD} + S_{MD} + A_{MD} \quad (\text{Gl. 26})$$

$$M_{MD} = N_T \cdot N_K \cdot m, \quad S_{MD} = N_T \cdot N_K \cdot s, \quad A_{MD} = N_T \cdot N_K \cdot a \quad (\text{Gl. 27})$$

wobei M der Anzahl der Multiplikationen, S der Anzahl der Subtraktionen und A der Anzahl der Additionen entspricht, die für die Klassifikation eines einzigen Pixels benötigt wird. N_T entspricht der Anzahl der Trainingsklassen und N_K der Anzahl der Kanäle des Daedalus-Scanners (bzw. den Merkmalen). m , s und a entsprechen der Rechenzeit, die der Computer für die Ausführung der verschiedenen Rechenoperationen benötigt. In der Praxis ist die Rechenzeit, die für die Ausführung einer Multiplikation benötigt wird, deutlich größer als die Zeit, die für eine der beiden anderen Operationen benötigt wird. Deshalb wird im folgenden nur der Rechenaufwand für die benötigten Multiplikationen berücksichtigt:

$$R_{MD} \approx N_T \cdot N_K \cdot m \quad \text{Ordnung } O(N_T N_K) \quad (\text{Gl. 28})$$

Beim Maximum Likelihood-Verfahren liegt der größte Aufwand in der Berechnung der Funktionen g_i (siehe Gl. 15). Wenn man wieder nur den Rechenaufwand für die benötigten Multiplikationen berücksichtigt, erhält man:

$$R_{ML} \approx (N_K^2 + N_K) \cdot N_T \cdot m \quad \text{Ordnung } O(N_K^2 N_T) \quad (\text{Gl. 29})$$

Es gibt also zwei wichtige Ansatzpunkte, um den Rechenaufwand zu reduzieren:

- 1) Reduktion der Merkmale (bzw. Spektralkanäle) N_K
- 2) Reduktion der Trainingsklassen N_T

4.8.1 Durchführung der Untersuchung

Im folgenden werden Methoden untersucht, die entweder die Zahl der Merkmale (Methode 1) oder die Zahl der Trainingsklassen reduzieren (Methode 2).

Methode 1:

Das Hauptproblem bei der Reduzierung der Merkmale besteht darin, die Merkmale herauszufinden, die für die Klassifikation am unwichtigsten sind¹⁴. Unwichtig sind Merkmale vor allem dann, wenn sie untereinander stark korreliert (abhängig) sind. Deshalb wird in der Literatur (siehe [Duda & Hart 1973] oder [Richards 1993]) als Lösung meistens die Durchführung einer Hauptachsentransformation empfohlen. Hierbei werden die Achsen des Merkmalsraumes so gedreht, daß alle Merkmale nach der Transformation unkorreliert sind. Man erhält also praktisch einen Satz neuer Merkmale. Eine Kovarianzmatrix, die aus Pixeln des transformierten Merkmalsraums berechnet wird, besitzt nur noch in der Diagonalen von null verschiedene Werte. Je größer ein Diagonalwert ist, desto wichtiger ist das entsprechende neue Merkmal für die Klassifikation. Diese Lösung hat allerdings auch zwei Nachteile. Zum einen ist der Rechenaufwand für die Transformation recht hoch. Zum anderen hängt das Ergebnis der Transfor-

¹⁴ Die Aussonderung von unwichtigen Merkmalen hat einen weiteren Vorteil. Je weniger Merkmale für die Klassifikation verwendet werden, desto weniger Trainingspixel werden für eine sichere Schätzung der Kovarianzmatrizen der Trainingsklassen benötigt (siehe [Duda & Hart 1973] oder [Richards 1993]).

mation von dem Bildmaterial ab, das für die Transformation verwendet wurde. Denn für die Durchführung einer Hauptachsentransformation muß zunächst die Kovarianzmatrix Σ_B aus allen Pixeln des Bildes berechnet werden (Rechenaufwand der Ordnung $O(N_K^2)$ pro Pixel). Anschließend muß die Transformationsmatrix bestimmt werden. Jedes Pixel des Bildes muß mit dieser Matrix transformiert werden. Hier für ist ein Rechenaufwand von der Größenordnung $O(N_K N_{TK})$ notwendig. Hierbei bezeichnet N_{TK} die Anzahl der Kanäle die nach der Transformation noch verwendet werden. In der Praxis werden meistens drei Kanäle verwendet. Insgesamt ergibt sich also ein Rechenaufwand der mit dem Aufwand vergleichbar ist, der für eine „Maximum Likelihood“-Klassifikation notwendig ist.

Aufgrund dieser Nachteile wurde, im Rahmen dieser Untersuchung, von der üblichen Vorgehensweise abgewichen und ein anderes Auswahlverfahren gewählt. So wurde nicht nach den wichtigsten Kanälen gesucht, sondern statt dessen nach Bildsensoren gesucht, die in der Fernerkundung verbreitet sind und weniger Spektralkanäle besitzen als der Daedalus-Scanner. Auf diese Weise konnte gleichzeitig untersucht werden, in wieweit die Verwendung der zusätzlichen Kanäle des Daedalus-Scanners die Klassifikationsgenauigkeit gegenüber den anderen Sensoren erhöhen kann. In der Fernerkundung sind Multispektralbilder, die vom „Landsat Thematic Mapper“ (nähere Informationen zu diesem Gerät siehe [Richards 1993] oder [Sabins 1978]) aufgenommen wurden, recht verbreitet. Dieses Gerät verfügt über sechs Spektralkanäle und einen Thermalkanal. Der Daedalus-Scanner besitzt ebenfalls diese Kanäle, und zwar sind dies die Spektralkanäle¹⁵ Nr. 2 (0,45 - 0,52 μm), 3 (0,52 - 0,60 μm), 5 (0,63 - 0,69 μm), 7 (0,76 - 0,90 μm), 9 (1,55 - 1,75 μm) und 10 (2,08 - 2,35 μm).

Zusätzlich zu den Multispektralbildern sind für die Fernerkundung aber auch noch die Falschfarben-Infrarot-Bilder (CIR-Bilder) interessant. Kapitel 3.2 enthält ein Diagramm, in dem die spektrale Empfindlichkeit des Farbinfrarotfilms KODAK 2443 in Abhängigkeit von der Wellenlänge dargestellt ist (siehe Abb. 16). Wenn man die spektralen Empfindlichkeiten der verschiedenen Farbschichten mit den Wellenlängen vergleicht, an denen die verschiedenen Detektoren des Daedalus-Scanners lichtempfindlich sind, so kann man jeder Farbschicht einen Spektralkanal zuordnen. Hierzu bestimmt man für jede Farbschicht zunächst den Wellenlängenbereich, in dem ihre spektrale Empfindlichkeit im Vergleich zu den Empfindlichkeiten der anderen Schichten möglichst groß ist. Danach sucht man ein Spektralkanal aus, dessen Wellenlängenbereich möglichst gut mit diesem Bereich überein stimmt. Diese Vorgehensweise führte zur Auswahl der Spektralkanäle Nr. 3 (0,52 - 0,60 μm), 5 (0,63 - 0,69 μm) und 7 (0,76 - 0,90 μm).

Im folgenden wird deshalb sowohl mit der Kanalkombination 3, 5 und 7 („entsprechend“ den **drei** Farbschichten des KODAK 2443) klassifiziert als auch mit der Kanalkombination 2, 3, 5, 7, 9 und 10 (entsprechend der **sechs** Spektralkanäle des Landsat Thematic Mapper).

Die eigentliche Versuchsdurchführung unterschied sich von der in Kap. 4.6.1 beschriebenen Durchführung im wesentlichen darin, daß die zu klassifizierenden Bilddaten, also die Kontrollpixel, und die Trainingsdaten auf die Informationen der ausgewählten Kanäle reduziert werden mußten. Es wurden mit den reduzierten Bilddaten insgesamt 2400 Klassifikationen durchgeführt. Jeweils 1200 Klassifikationen wurden mit dem gleichen Klassifikationsverfahren durchgeführt. Jeweils 600 Klassifikationen wurden mit dem gleichen Verfahren und der gleichen Kanalzahl (3 oder 6) durchgeführt, und bei 100 Klassifikationen stammte zusätzlich noch der

¹⁵ Der Thermalkanal wird auch weiterhin nicht berücksichtigt.

4 Überwachte Klassifikation von Multispektralbildern

Trainingssatz aus dem gleichen Permutationssatz. Die Ergebnisse aus diesen 100 Klassifikationen wurden wieder jeweils zu einer gemittelten Konfusionsmatrix zusammengefaßt. Die Konfusionsmatrizen konnten allerdings, um den Umfang der Arbeit zu begrenzen, nicht abgedruckt werden. Es wurden wiederum nur die Wiedererkennungsgenauigkeiten der einzelnen Klassen in Abhängigkeit der Gesamtzahl der Trainingsklassen dargestellt (siehe Abb. 27 bis Abb. 30).

Methode 2:

Es gibt zwei Möglichkeiten, um die Anzahl der Trainingsklassen zu reduzieren. Man kann unwichtige Trainingsklassen vor der Klassifikation aussondern oder die Pixel *mehrerer Trainingsklassen zu einer Klasse zusammenführen*. In der folgenden Versuchsdurchführung wurde die zuletzt genannte Möglichkeit genutzt.

Zum Vergleich der Ergebnisse dieser Untersuchung mit den Ergebnissen aus Kap. 4.6 wurden wieder die Permutationssätze verwendet. Jeder Permutationssatz besteht aus 100 Trainingssätzen. Jeder Trainingssatz enthält eine Vorschrift darüber, welche Stichproben als Trainingsklassen eingesetzt werden sollen und mit welchen Informationsklassen die verschiedenen Trainingsklassen verknüpft sind. Diese Vorschrift wurde genutzt, um die Pixel aller Stichproben zusammenzufassen, die in dem jeweiligen Trainingssatz aufgeführt wurden und der gleichen Informationsklasse angehörten. Aus den zusammengefaßten Pixeln wurden für jede Informationsklasse die Kovarianzmatrix und der Mittelpunkt ihrer Trainingsklasse im Merkmalsraum berechnet. Es wurde also die Zahl der Trainingsklassen für alle Trainingssätze auf insgesamt zehn Klassen reduziert. Die Kontrollpixel wurden nun erneut mit beiden Klassifikationsverfahren klassifiziert und die Ergebnisse wieder, wie in Kap. 4.6 beschrieben, zu gemittelten Konfusionsmatrizen zusammengefaßt.

4.8 Untersuchung von Methoden zur Reduzierung des Rechenaufwandes

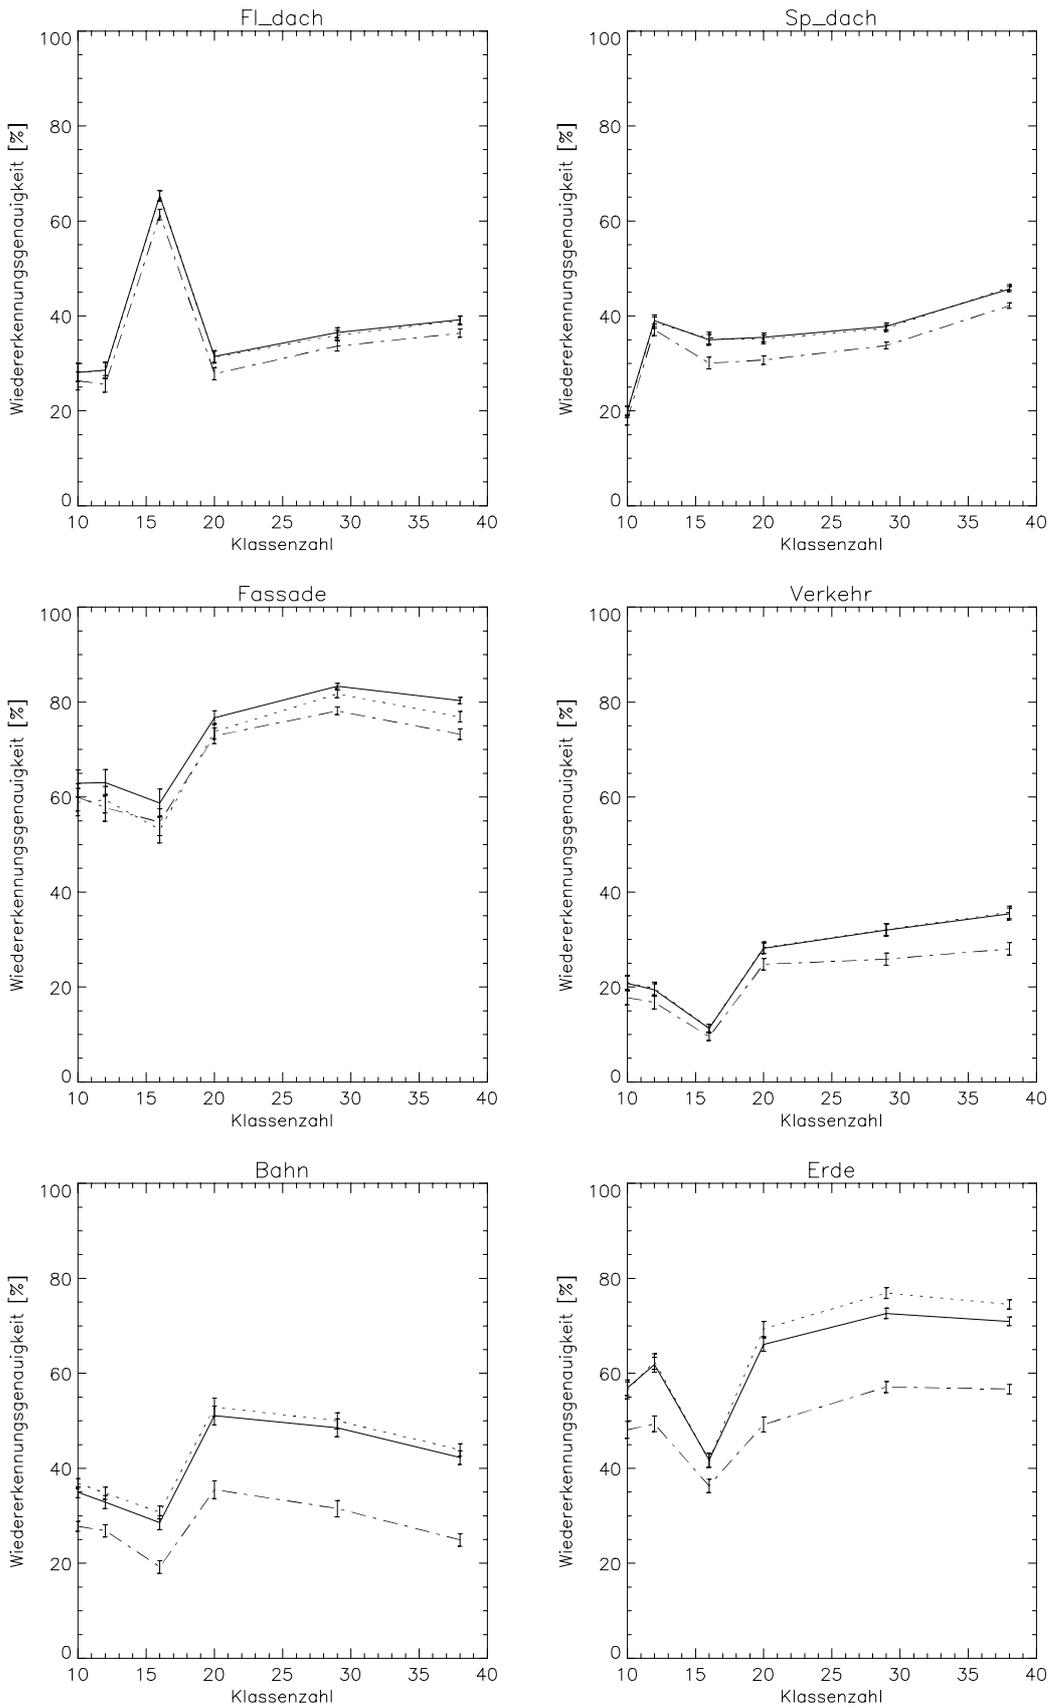


Abb. 27: Übersicht 1 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren, bei Verwendung von 10 Kanälen (durchgezogene Linie), 6 Kanälen (gepunktete Linie) und 3 Kanälen (gestrichelte Linie), erreicht wurden (Methode 1)

4 Überwachte Klassifikation von Multispektralbildern

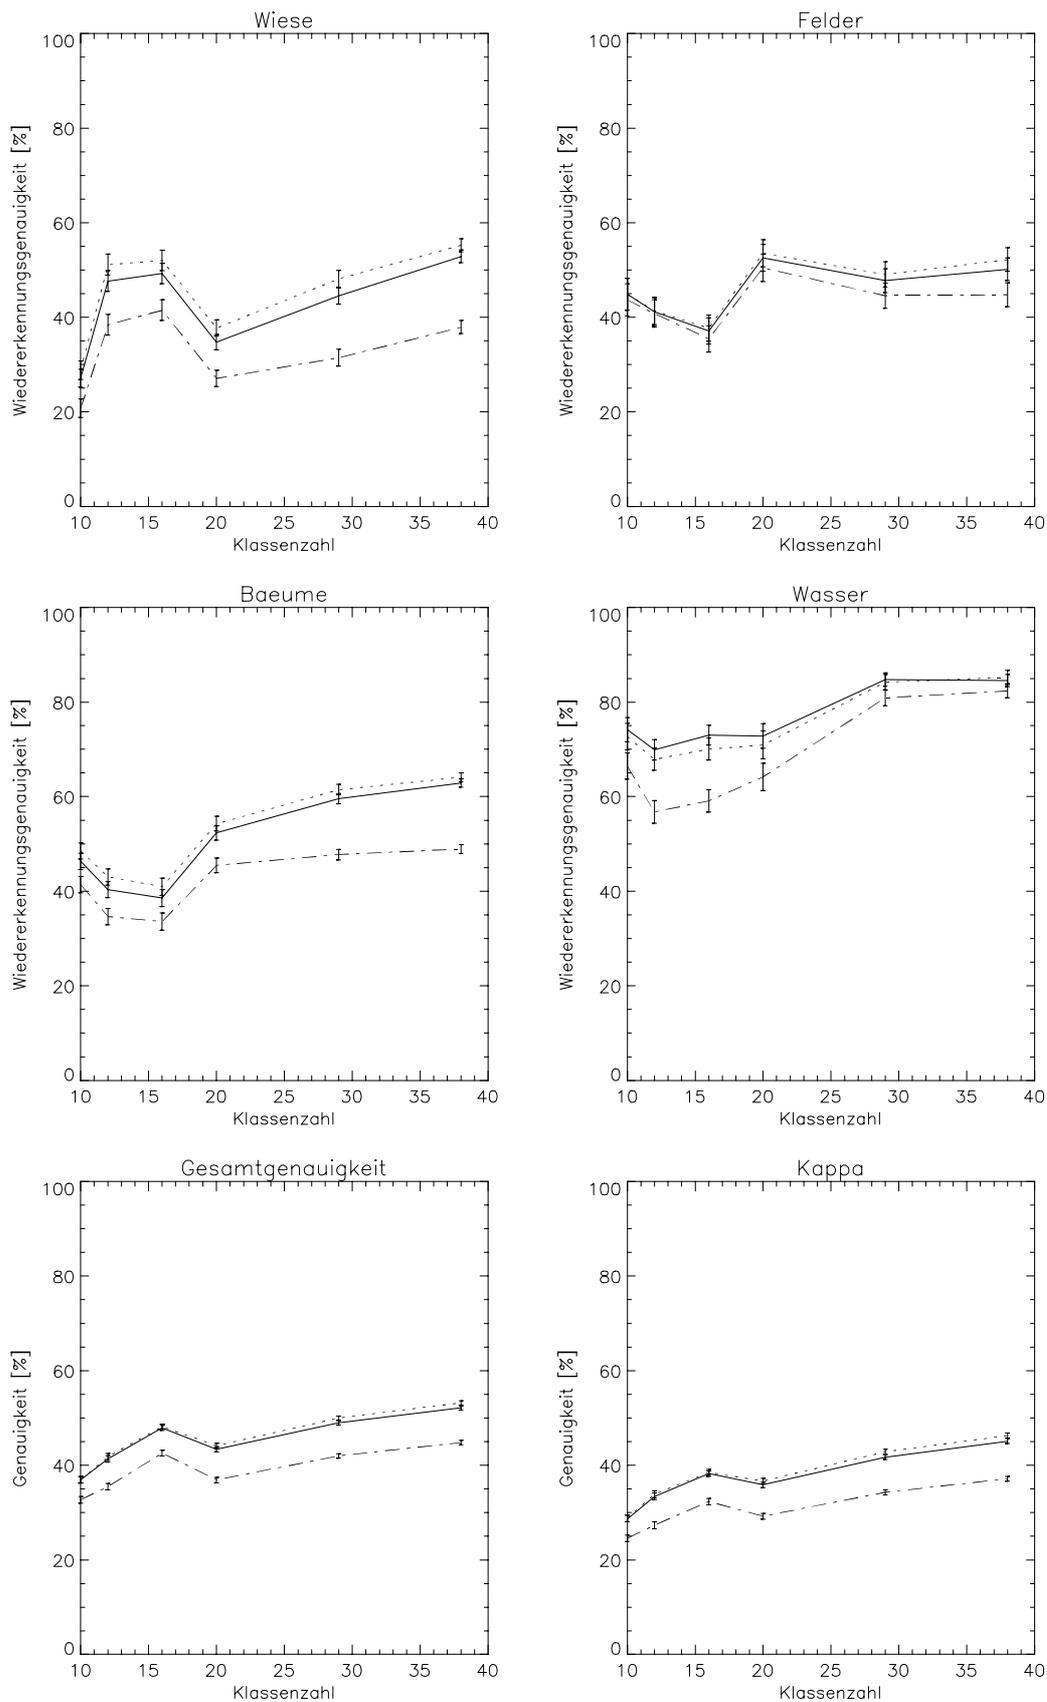


Abb. 28: Übersicht 2 über die Ergebnisse, die mit dem „Minimum Distance“-Verfahren, bei Verwendung von 10 Kanälen (durchgezogene Linie), 6 Kanälen (gepunktete Linie) und 3 Kanälen (gestrichelte Linie), erreicht wurden (Methode 1)

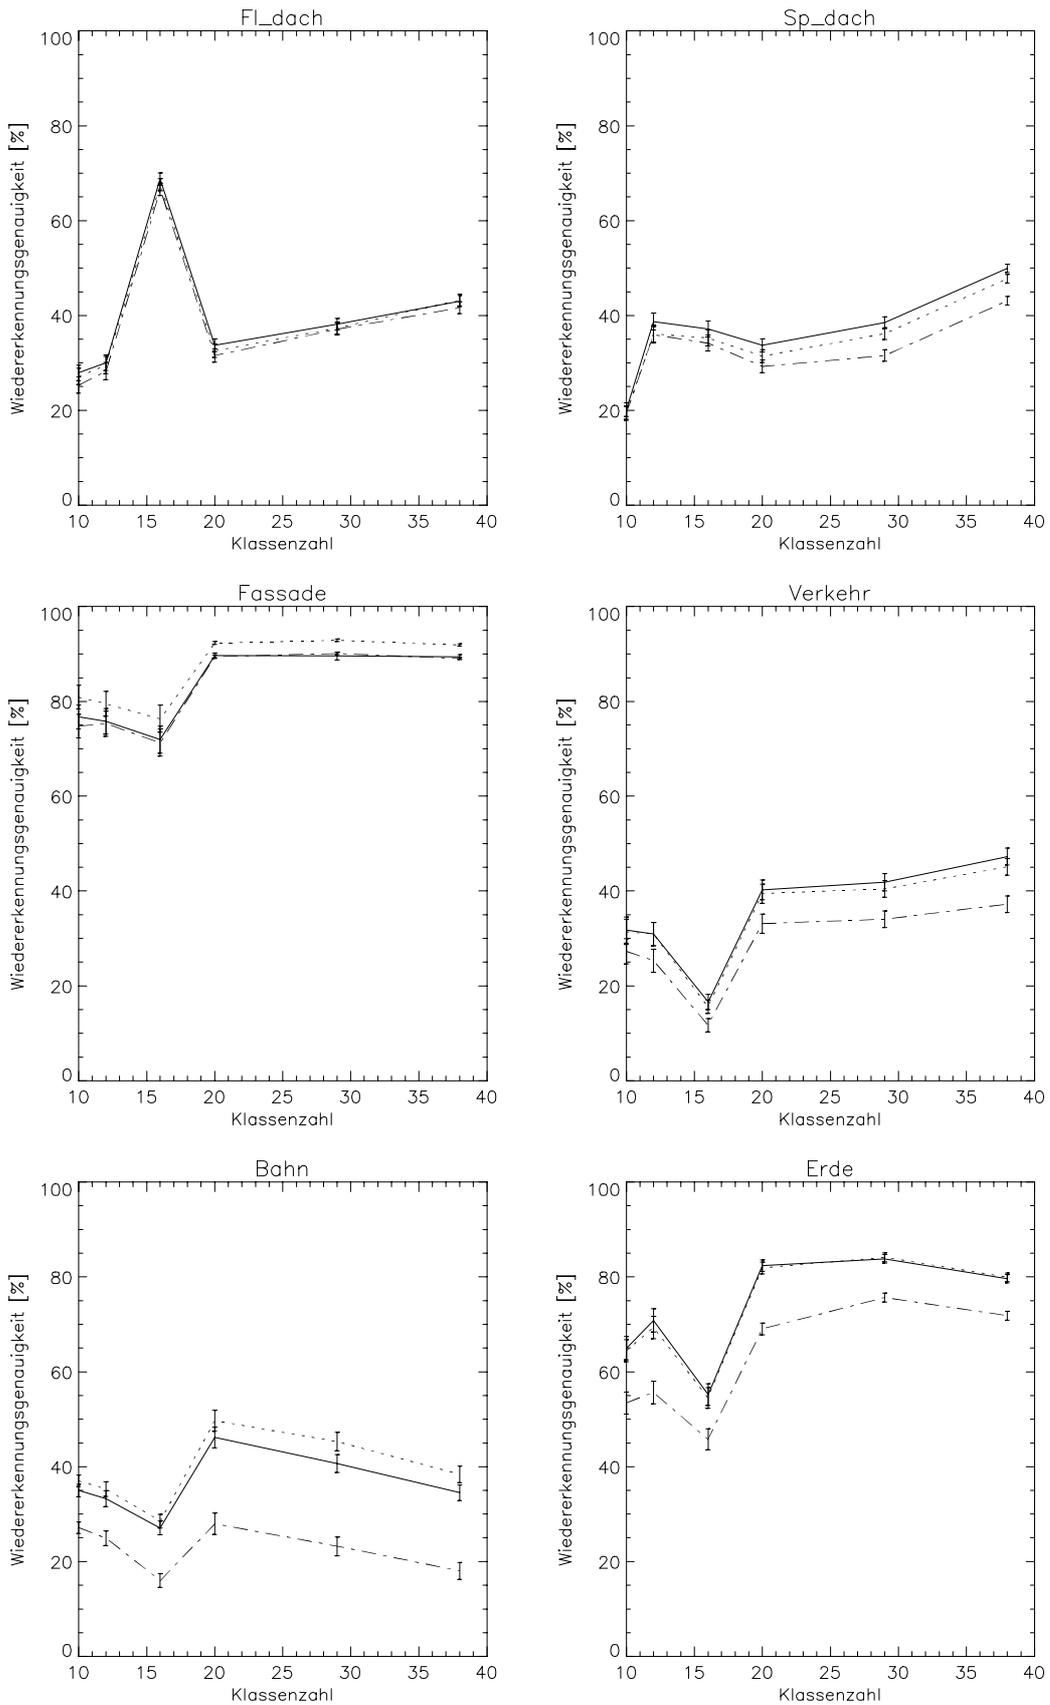


Abb. 29: Übersicht 1 über die Ergebnisse, die mit dem „Maximum Likelihood“-Verfahren, bei Verwendung von 10 Kanälen (durchgezogene Linie), 6 Kanälen (gepunktete Linie) und 3 Kanälen (gestrichelte Linie), erreicht wurden. (Methode 1)

4 Überwachte Klassifikation von Multispektralbildern

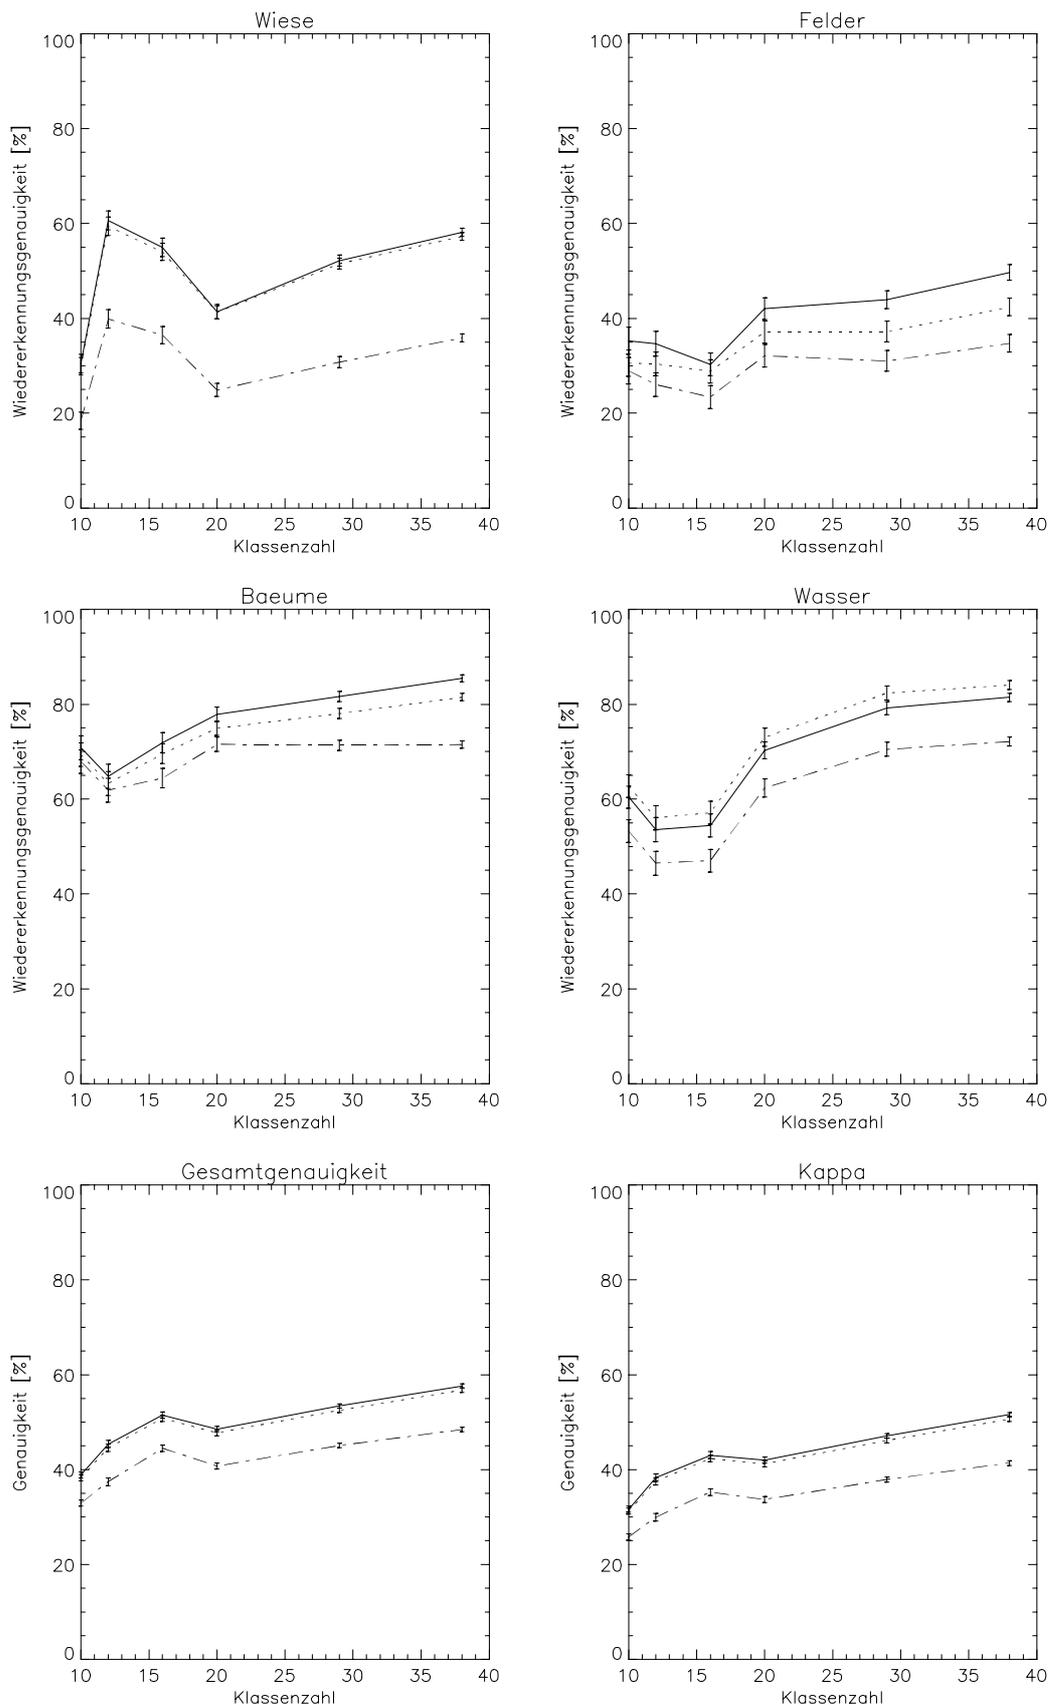


Abb. 30: Übersicht 2 über die Ergebnisse, die mit dem „Maximum Likelihood“-Verfahren, bei Verwendung von 10 Kanälen (durchgezogene Linie), 6 Kanälen (gepunktete Linie) und 3 Kanälen (gestrichelte Linie), erreicht wurden. (Methode 1)

4.8 Untersuchung von Methoden zur Reduzierung des Rechenaufwandes

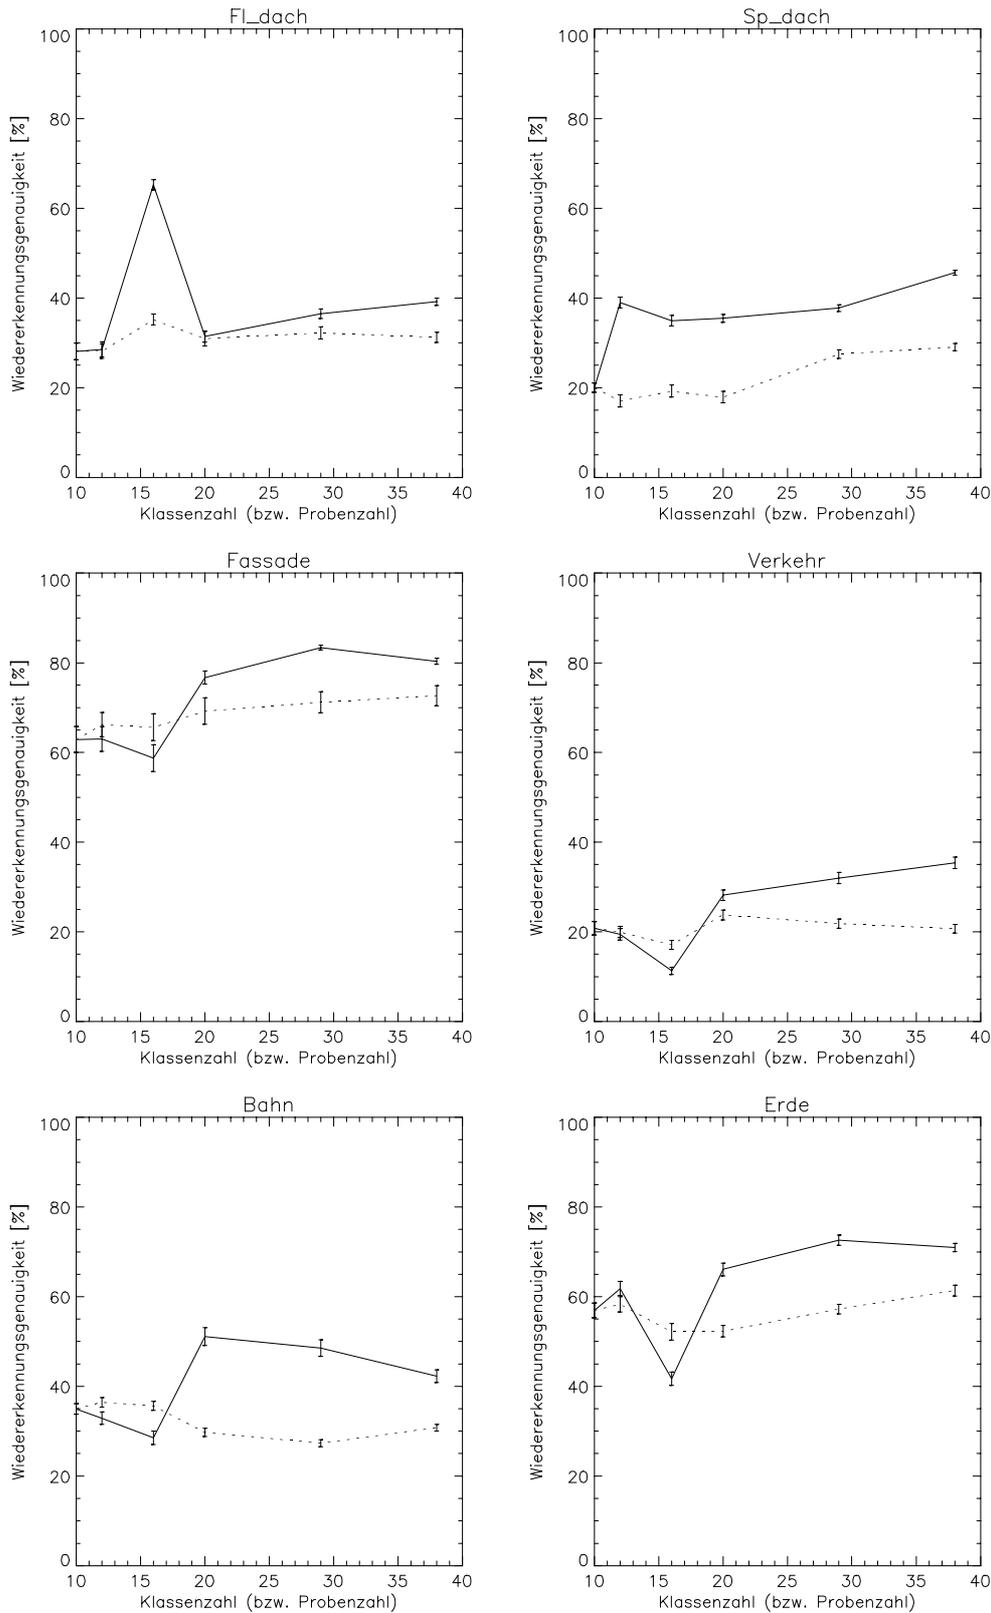


Abb. 31: Übersicht 1 über den Vergleich zwischen den Ergebnisse, die sich aus den Klassifikationen mit dem „Minimum Distance“-Verfahren in Kap. 4.6 ergaben (durchgezogene Linie), und den Ergebnissen, die sich mit dem „Minimum Distance“-Verfahren bei Anwendung von Methode 2 ergaben (gestrichelte Linie). Bei Methode 2 entspricht die Skalierung an der x-Achse der Stichprobenzahl, weil bei dieser Methode die Zahl der Trainingsklassen immer bei 10 Klassen liegt.

4 Überwachte Klassifikation von Multispektralbildern

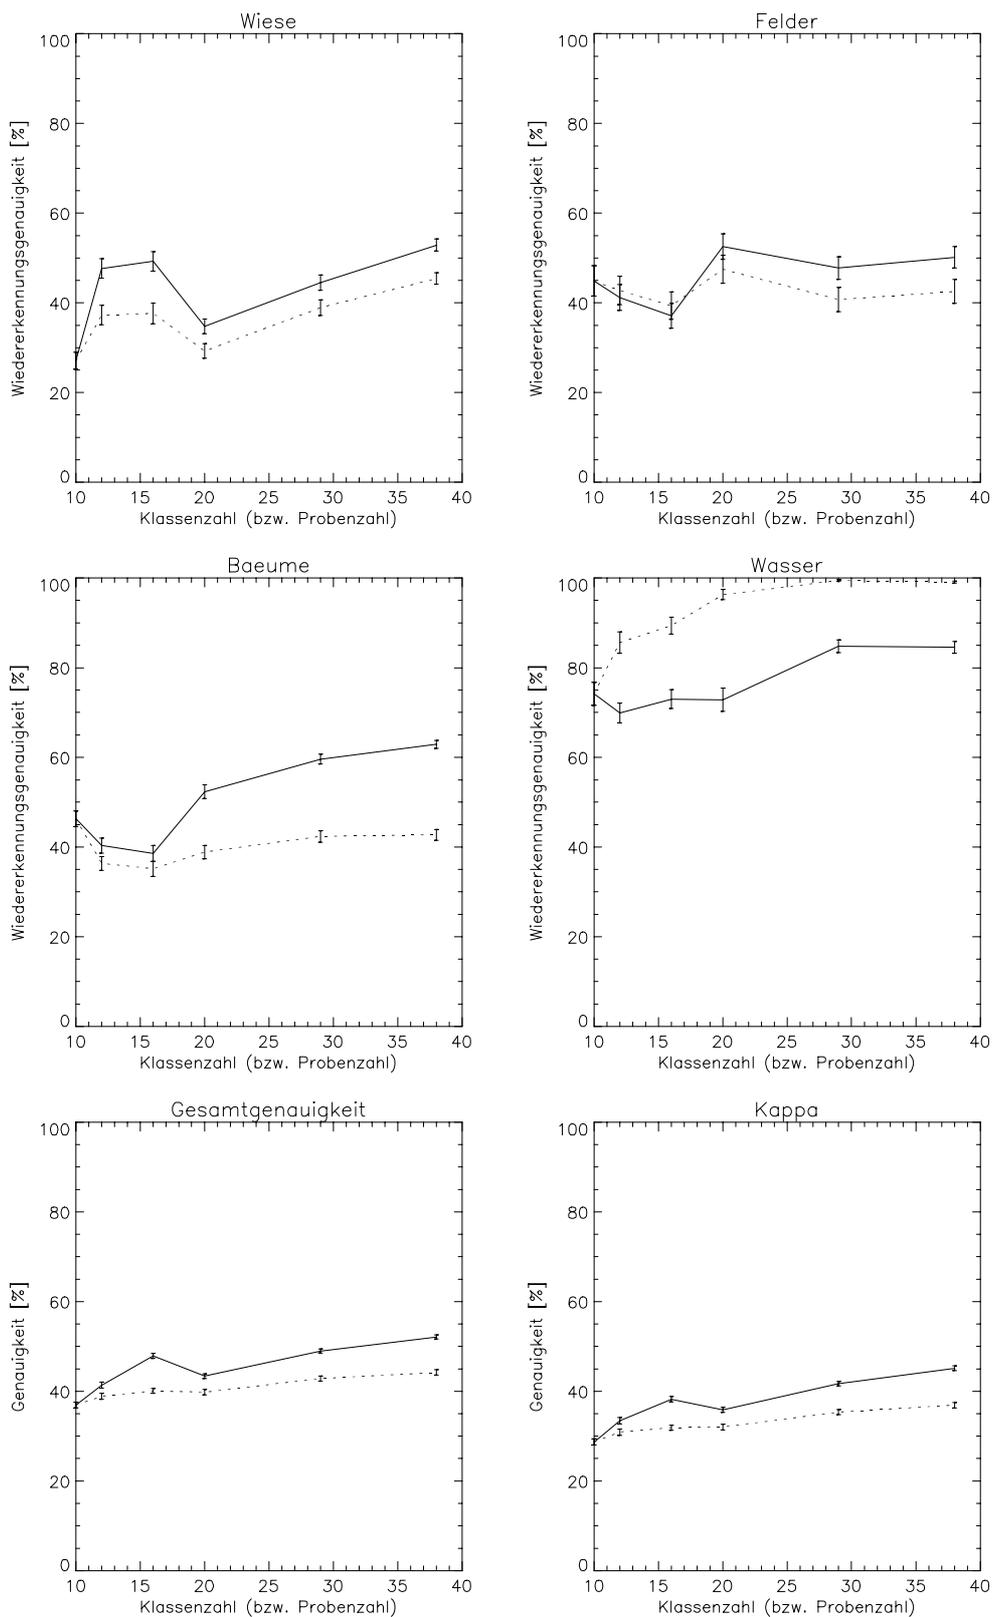


Abb. 32: Übersicht 2 über den Vergleich zwischen den Ergebnisse, die sich aus den Klassifikationen mit dem „Minimum Distance“-Verfahren in Kap. 4.6 ergaben (durchgezogene Linie), und den Ergebnissen, die sich mit dem „Minimum Distance“-Verfahren bei Anwendung von Methode 2 ergaben (gestrichelte Linie). Bei Methode 2 entspricht die Skalierung an der x-Achse der Stichprobenzahl, weil bei dieser Methode die Zahl der Trainingsklassen immer bei 10 Klassen liegt.

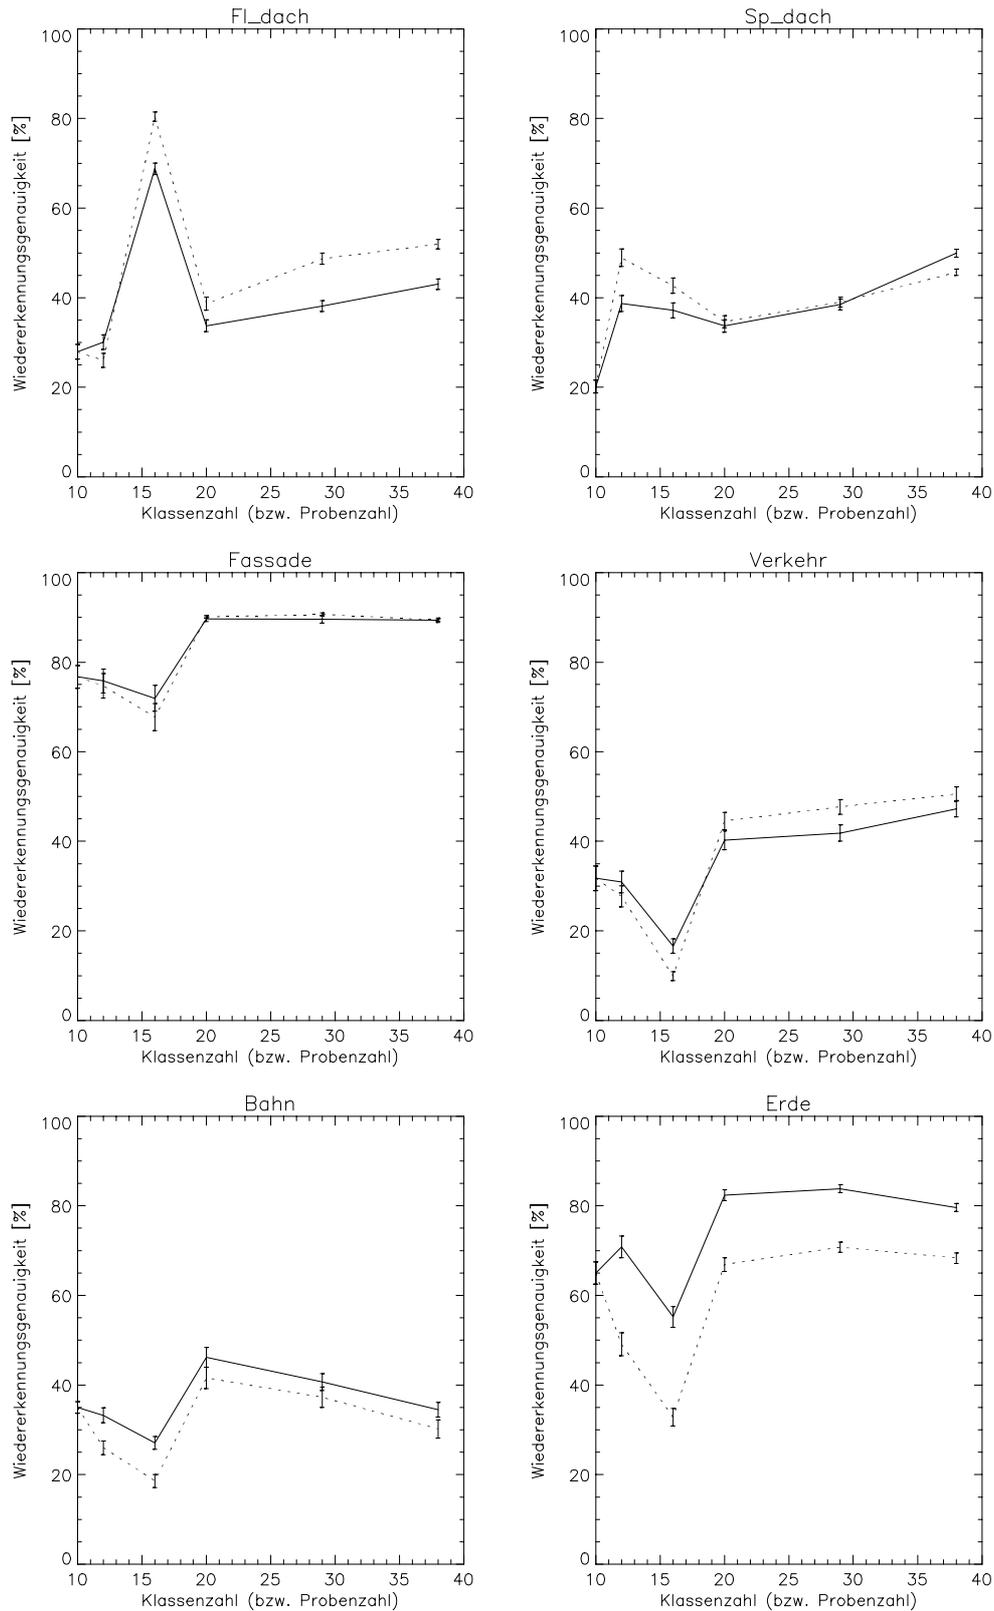


Abb. 33: Übersicht 1 über den Vergleich zwischen den Ergebnisse, die sich aus den Klassifikationen mit dem „Maximum Likelihood“-Verfahren in Kap. 4.6 ergaben (durchgezogene Linie), und den Ergebnissen, die sich mit dem „Maximum Likelihood“-Verfahren bei Anwendung von Methode 2 ergaben (gestrichelte Linie). Bei Methode 2 entspricht die Skalierung an der x-Achse der Stichprobenzahl, weil bei dieser Methode die Zahl der Trainingsklassen immer bei 10 Klassen liegt.

4 Überwachte Klassifikation von Multispektralbildern

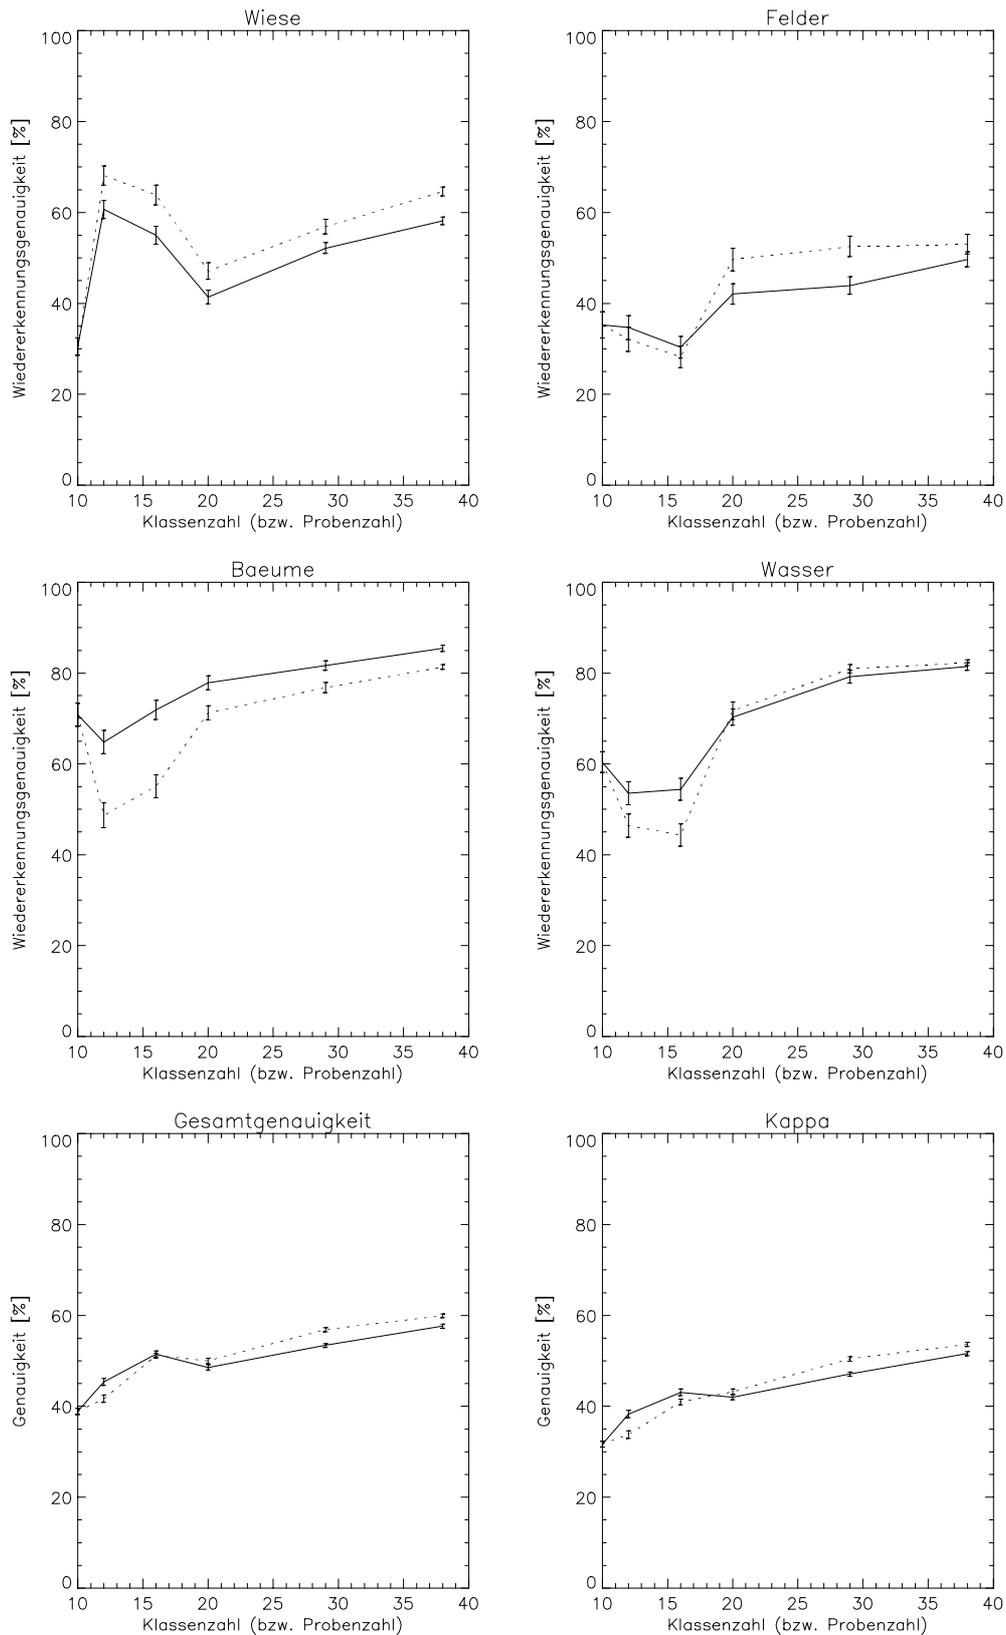


Abb. 34: Übersicht 2 über den Vergleich zwischen den Ergebnisse, die sich aus den Klassifikationen mit dem „Maximum Likelihood“-Verfahren in Kap. 4.6 ergaben (durchgezogene Linie), und den Ergebnissen, die sich mit dem „Maximum Likelihood“-Verfahren bei Anwendung von Methode 2 ergaben (gestrichelte Linie). Bei Methode 2 entspricht die Skalierung an der x-Achse der Stichprobenzahl, weil bei dieser Methode die Zahl der Trainingsklassen immer bei 10 Klassen liegt.

4.8.2 Auswertung und Interpretation der Ergebnisse

Auswertung Methode 1:

Bei der Betrachtung der in Abb. 27 bis Abb. 30 dargestellten Ergebnisse fällt als erstes auf, daß die Klassifikationsergebnisse, selbst bei Verwendung von nur noch drei Kanälen, sehr hoch sind. Die Kappa-Werte der Klassifikationen mit zehn Kanälen sind **nur um ca. 6 bis 7% besser** als die Ergebnisse mit drei Kanälen. Die Kappa-Werte der Klassifikationen mit sechs Kanälen zeigen gar **keinen signifikanten Unterschied** mehr zu den Klassifikationen mit zehn Kanälen.

Trotzdem zeigen einzelne Klassen interessante Auffälligkeiten. Hierzu zählen beispielsweise die Klassen „Fassade“ und „Wasser“. Denn bei diesen Klassen werden mit dem Maximum Likelihood-Verfahren die höchsten Wiedererkennungsgenauigkeiten nicht mit zehn Kanälen erreicht, sondern bei der Verwendung von nur sechs Kanälen. Außerdem ist an diesen Klassen auffällig, daß dieses Verhalten beim Minimum Distance-Verfahren überhaupt nicht auftritt. Die Auswirkungen der Merkmalsreduktionen hängen allerdings nicht nur vom Verfahren ab, sondern bei einigen Klassen auch von der Anzahl der eingesetzten Trainingsklassen. Hierzu zählen z.B. die Klassen „Bahn“ und „Bäume“.

Insgesamt kann man aus den Ergebnissen schlußfolgern, daß in den Spektralkanälen 3, 5 und 7 des Daedalus-Scanners bereits ein erheblicher Teil der spektralen Informationen enthalten ist¹⁶. Die Kanäle 1, 4, 6, und 8 des Daedalus-Scanners enthalten anscheinend (in Bezug auf die übrigen sechs Kanäle) überwiegend redundante Informationen.

Auswertung Methode 2:

In der folgenden Auswertung werden die Ergebnisse für beide Klassifikationsverfahren jeweils getrennt voneinander mit den Klassifikationsergebnissen aus Kap. 4.6 verglichen.

Abb. 31 und Abb. 32 enthalten die Ergebnisse der Klassifikationen mit dem „**Minimum Distance**“-Verfahren. Ein Blick auf die Kurve mit den Kappa-Werten zeigt, daß die Bildung von Trainingsklassen aus den Pixeln mehrerer Stichproben die Kappa-Werte, bei diesem Verfahren, kaum verändert haben. Die Werte steigen mit zunehmender Stichprobenzahl nur sehr langsam an und der Maximalwert liegt nur bei ca. 37%. In Kap. 4.6 lag der größte gemittelte Kappa-Wert bei 45%. **Der Kappa-Wert verschlechterte sich um bis zu 8%.**

Im Vergleich zu den Ergebnissen aus Kap. 4.6 haben sich die Wiedererkennungsgenauigkeiten der meisten Klassen deutlich verschlechtert. Eine Ausnahme bildet hierbei die Klasse „Wasser“. Bei dieser Klasse steigt die Wiedererkennungsgenauigkeit mit der Anzahl der Stichproben, die für das Training verwendet wurden (siehe Abb. 32).

Eine weitere interessante Auffälligkeit zeigen die Ergebnisse, die mit Permutationssatz 3 (siehe die Ergebnisse in Abb. 31 und Abb. 32 bei einer „Klassenzahl (bzw. Probenzahl)“ von 16) erreicht wurden. Denn bei diesem Permutationssatz wurde die Trainingsklasse für die Klasse

¹⁶ Diese Beobachtung bestätigt die Leistungsfähigkeit von Nachweisverfahren mit drei Spektralkanälen, wie z.B. Farbinfrarot-Filme

4 Überwachte Klassifikation von Multispektralbildern

„Fl_dach“ aus jeweils fünf Stichproben gebildet. Dies führte allerdings zu einer nur geringen Erhöhung der Wiedererkennungsgenauigkeit in dieser Klasse.

Insgesamt gesehen hat sich die „Verschmelzung“ von mehreren Stichproben zu einer Trainingsklasse für das „Minimum Distance“-Verfahren als nachteilig erwiesen. Die Ursache hierfür ist wohl wieder in der zu großen spektralen Vielfalt innerhalb der verschiedenen Informationsklassen zu suchen. Denn beim „Minimum Distance“-Verfahren kann mit einer Trainingsklasse pro Informationsklasse auch nur maximal ein Häufungspunkt in jeder Informationsklasse abgedeckt werden.

In Abb. 33 und Abb. 34 sind die entsprechenden Klassifikationsergebnisse für das „**Maximum Likelihood**“-Verfahren dargestellt. Bei diesem Verfahren zeigt ein Blick auf die Kurve „Kappa“, daß sich die Kappa-Werte, durch die Vereinigung mehrerer Stichproben zu einer Trainingsklasse, im Vergleich zu den Kappa-Werten aus Kap. 4.6 insgesamt nicht verschlechtert haben. Sie haben sich bei den Permutationssätzen 4 bis 6 sogar verbessert, und zwar **um 3 bis 4%**. Die Bildung von Trainingsklassen aus Pixeln, die von verschiedenen Stichproben stammten, hat also zu einer Verbesserung des Informationsgehaltes in den Kovarianzmatrizen geführt. Denn mit Hilfe der Kovarianzmatrix läßt sich für jede Klasse ableiten, wie groß die Wahrscheinlichkeit ist, daß ein Pixel dieser Klasse in einer bestimmten Richtung und Entfernung vom Klassenmittelpunkt anzutreffen ist. Die Verbesserung der Klassifikationsergebnisse ist aber keinesfalls selbstverständlich, weil die Pixel innerhalb der einzelnen Informationsklassen im Merkmalsraum nicht grundsätzlich normalverteilt sind. Ein gutes Beispiel hierfür ist die Klasse „Wiese“. Sie besteht aus mindestens zwei spektralen Unterklassen. Die eine Klasse bilden die Pixel, die von der Globalstrahlung beleuchtet werden. Die andere Klasse bilden die Pixel, die von der Himmelsstrahlung beleuchtet werden. Der Mittelwert, der ja aus allen Pixeln errechnet wird, liegt von den Pixeln beider Klassen weit entfernt. Die aus ihnen errechnete Kovarianzmatrix muß also sehr große Werte enthalten, wodurch ein Pixel dieser Klasse auch dann noch zugewiesen wird, wenn es vom Mittelpunkt der entsprechenden Trainingsklasse weit entfernt ist. Dieser Effekt ist in Abb. 34 an dem Verlauf der Kurve „Baeume“ zu erkennen. Die Wiedererkennungsgenauigkeit von dieser Klasse fällt bei Verwendung von Permutationssatz 2 ab. In den Permutationssätzen 4 bis 6 wird die Trainingsklasse für die Klasse „Bäume“ auch aus mindestens zwei Stichproben gebildet, und die Wiedererkennungsgenauigkeiten liegen nur noch 5% unter den entsprechenden Ergebnissen aus Kap. 4.6. Insgesamt sind die Probleme, die durch diesen Effekt verursacht werden, aber sehr gering, so daß diese Methode für das „Maximum Likelihood“-Verfahren sehr empfehlenswert ist. Allerdings sollte jede Trainingsklasse aus mindestens drei Stichproben (bzw. Trainingsgebiete) gebildet werden.

4.8.3 Vergleich der untersuchten Methoden

Die Untersuchung begann mit einer Analyse des Rechenaufwandes, der mit der Klassifikation eines einzigen Pixels verbunden ist. Hierbei wurden Formeln entwickelt, mit denen die Anzahl der notwendigen Multiplikationen pro Pixel berechnet werden können (siehe Gl. 28 und Gl. 29). Die errechneten Zahlen wurden zur Erzeugung des Diagramms in Abb. 35 genutzt. In dem Diagramm wurden die Kappa-Werte, die bei den Klassifikationen in Kap. 4.6 und 4.8 erreicht wurden, in Abhängigkeit der Multiplikationen pro Pixel aufgetragen. Man beachte, daß die x-Achse logarithmisch skaliert ist. Dies war notwendig, weil beim Maximum Likelihood-Verfahren die Anzahl der Multiplikationen quadratisch mit der Kanalzahl ansteigt. Deshalb wäre auch eine Kombination der Methoden 1 und 2 sicher sinnvoll. Zur Untermauerung dieser These wurde Methode 2 noch einmal mit den sechs Kanälen aus Methode 1 durchgeführt. Die Kappa-Werte, die sich hieraus ergaben, sind im Diagramm mit Dreieck-Symbolen markiert (siehe „2_ML_6K“ in der Legende.)

Bei der Betrachtung des Diagramms, fällt zunächst auf, daß alle Kurven, die zur Methode 2 gehören, auf einer senkrechten Gerade liegen. Dies liegt daran, daß, bei dieser Methode, jede Klassifikation mit 10 Trainingsklassen durchgeführt wurde. Deshalb ist der Rechenaufwand für alle Permutationsätze gleich. Der Kappa-Wert, der zum „Permutationsatz 1“ gehört, liegt am dichtesten am Koordinatenursprung. Der Kappa-Wert, der zum „Permutationsatz 6“ gehört, befindet sich jeweils am Ende der Kurve. Dies gilt für alle Kurven.

Die effizienteste Methode ist die kombinierte Methode („2_ML_6K“) mit den Permutationsätzen 5 und 6. Das „Minimum Distance“-Verfahren ist ebenfalls recht effizient. Das Diagramm zeigt aber auch, daß man mindestens 100 Multiplikationen pro Pixel ausführen muß, um einen Kappa-Wert von 40% zu erreichen.

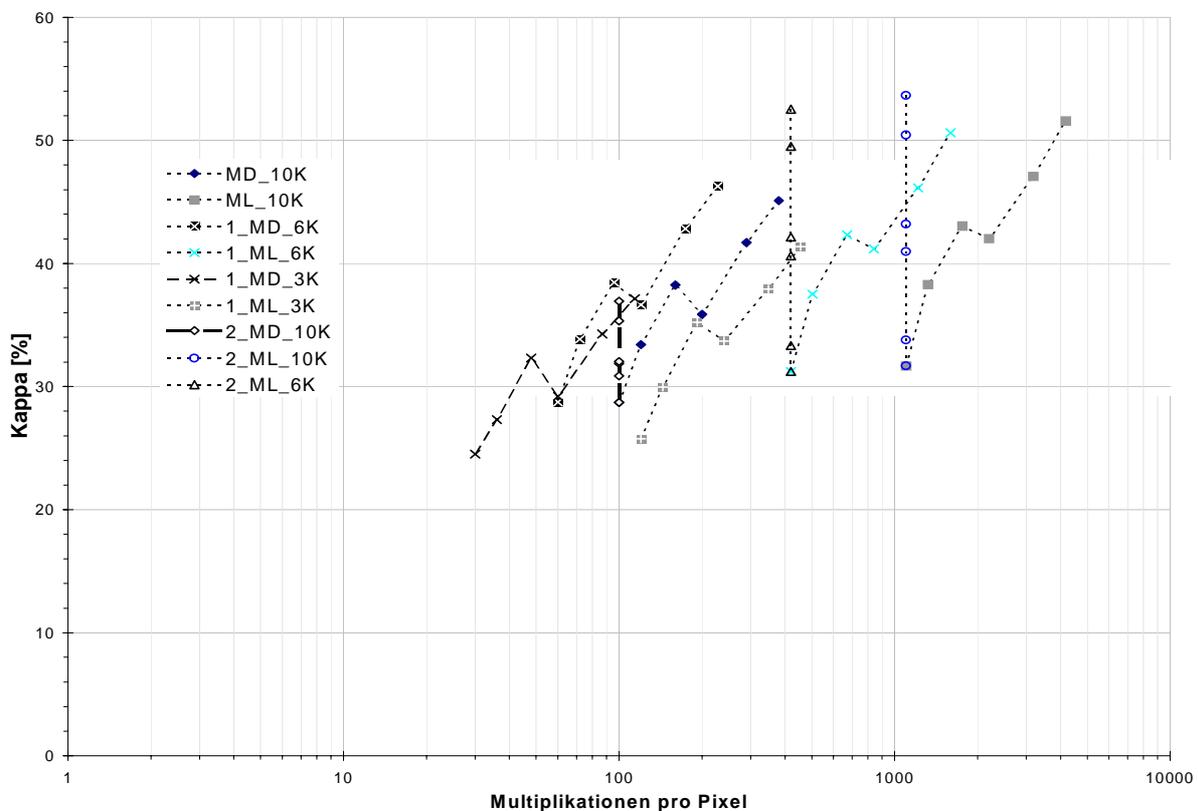


Abb. 35: Diagramm der Kappa-Werte, die mit den verschiedenen Methoden in diesem Kapitel erreicht wurden. (Hierbei bedeutet: MD: „Minimum Distance“-Verfahren, ML: „Maximum Likelihood“-Verfahren, 1: Methode 1, 2: Methode 2 und K: Kanalzahl)

4.9 Demonstration der Klassifikationsverfahren an einem Bildausschnitt

In den bisherigen Untersuchungen in dieser Arbeit wurden die beiden Klassifikationsverfahren stets mit Hilfe von Maßzahlen (wie z.B. dem Kappa-Wert) verglichen. Diese Vergleiche waren sehr abstrakt. Deshalb wird im folgenden eine *Szene* (d.h. ein rechteckiger Bildausschnitt mit Pixeln von verschiedenen Klassen) aus einem Flugstreifen ausgeschnitten und mit beiden Verfahren klassifiziert. Hierfür werden alle zehn Spektralkanäle verwendet. Anschließend werden die von beiden Verfahren erzeugten Klassifikationskarten miteinander verglichen.

4 Überwachte Klassifikation von Multispektralbildern

4.9.1 Durchführung der Demonstration

Der erste Schritt bestand darin, eine Szene und einen Trainingssatz auszuwählen. Als Szene wurde ein Teil des Gewerbegebietes, das in Flugstreifen T3 abgebildet ist, ausgewählt (siehe Abb. 36). Für das Training wurde ein Trainingssatz aus „Permutationssatz 6“ gewählt. Die Wahl fiel dabei auf den Trainingssatz, der (bei der Klassifikation der Kontrollpixel aus Kap. 4.5) den höchsten (aus beiden Verfahren) gemittelten Kappa-Wert aufwies. Die Namen der Stichproben, die hierdurch als Trainingsgebiete gewählt wurden, sind der Tabelle 52 zu entnehmen. Abschließend wurde der Bildausschnitt mit beiden Verfahren klassifiziert und die Ergebnisse wurden graphisch dargestellt (siehe Abb. 37 und Abb. 38).

Die beiden Abbildungen enthalten jeweils in der linken oberen Ecke eine kontrastverstärkte Darstellung des gewählten Bildausschnittes. Rechts neben dieser Darstellung befindet sich jeweils eine Klassifikationskarte. In dieser Karte sind die Pixel, die der gleichen Informationsklasse zugewiesen wurden, nicht mit einer einheitlichen Farbe markiert, sondern mit einer einheitlichen Graustufe. Die Karte enthält also zehn Graustufen. Mit der dunkelsten Graustufe (schwarz) sind die Pixel der Klasse „Fl_dach“ markiert. Die Reihenfolge der übrigen Graustufen entspricht der Reihenfolge der Informationsklasse in Tabelle 52. In den übrigen Darstellungen sind die Pixel weiß markiert worden, die der Klasse zugewiesen wurden, deren Name in der jeweiligen Bildüberschrift auftaucht.

Name der Stichproben	Name der Informationsklasse
Flachdach 3, Flachdach 4, Flachdach 7, Flachdach 8	Fl_dach
Spitzdach(bel) 5, Spitzdach(bel) 10, Spitzdach(bel) 11, Spitzdach(sch) 2, Spitzdach(sch) 8	Sp_dach
Fassade 2, Fassade 4, Fassade 5	Fassade
Buergersteig 1, Buergersteig 6, Parkplatz 5, Strasse(bel)	Verkehr
Eisenbahn 1, Eisenbahn 2	Bahn
Erdreich 1, Erdreich 2, Erdreich 5	Erde
Wiese(bel) 2, Wiese(bel) 3, Wiese(bel) 4, Wiese(sch) 3, Wiese(sch) 4,	Wiese
Felder(bew) 2, Felder(bew) 6, Felder(bew) 9, Felder(bew) 10	Felder
Baum 3, Baum 6, Baum 7, Baum 9	Baeume
Gewaesser 2, Gewaesser 4, Gewaesser 6, Gewaesser 8	Wasser

Tabelle 52: Übersicht über die zum Training in diesem Abschnitt gewählten Stichproben aus dem Anhang.

4.9.2 Diskussion der Ergebnisse

Mit dem in Tabelle 52 aufgeführten Trainingssatz wurden bei der Klassifikation der Kontrollpixel Kappa-Werte von 53,8% („Minimum Distance“-Verfahren) und 60,2% („Maximum Likelihood“-Verfahren) erreicht. Allerdings sind diese Angaben nur sehr eingeschränkt auf den gewählten Bildausschnitt übertragbar, weil die Klassifikationsergebnisse lokal sehr unterschiedlich ausfallen können. Deshalb lohnt es sich auch nicht, die Ergebnisse, die die Klassifikation des Bildausschnittes erbracht hat, quantitativ zu analysieren, statt dessen werden im

folgenden die Auffälligkeiten beschrieben, die bei der Betrachtung von Abb. 37 und Abb. 38 entdeckt wurden.

Eine Auffälligkeit, die in beiden Abbildungen zu beobachten ist, betrifft die Flachdächer. Die einzelnen Flachdächer wurden unterschiedlich gut klassifiziert. So wurden einige Flachdächer fast vollständig erfaßt, während andere Dächer überhaupt nicht erfaßt wurden. Auffällig sind auch die Ergebnisse der Klasse „Fassade“. Denn beide Verfahren haben keine der Gebäudefassaden, die in dem gewählten Bildausschnitt allerdings auch überwiegend stark beschattet sind, entsprechend zugewiesen. Dafür wurde ein Dach (siehe Abb. 36 im Bereich von Scanzeile 5500 bei einem Scan-Winkel von ca. 23°) praktisch komplett der Klasse „Fassade“ zugeordnet. Eine Überprüfung anhand der Luftphotos ergab, daß es sich bei diesem Dach vermutlich um ein Metaldach handelt. Eine Auffälligkeit, die nur in Abb. 37 (also beim „Minimum Distance“-Verfahren) zu beobachten ist, betrifft die Klasse „Verkehr“, und zwar wurde hier eine Vielzahl der Straßenpixel irrtümlich den Klassen „Bahn“ und „Erde“ zugewiesen.

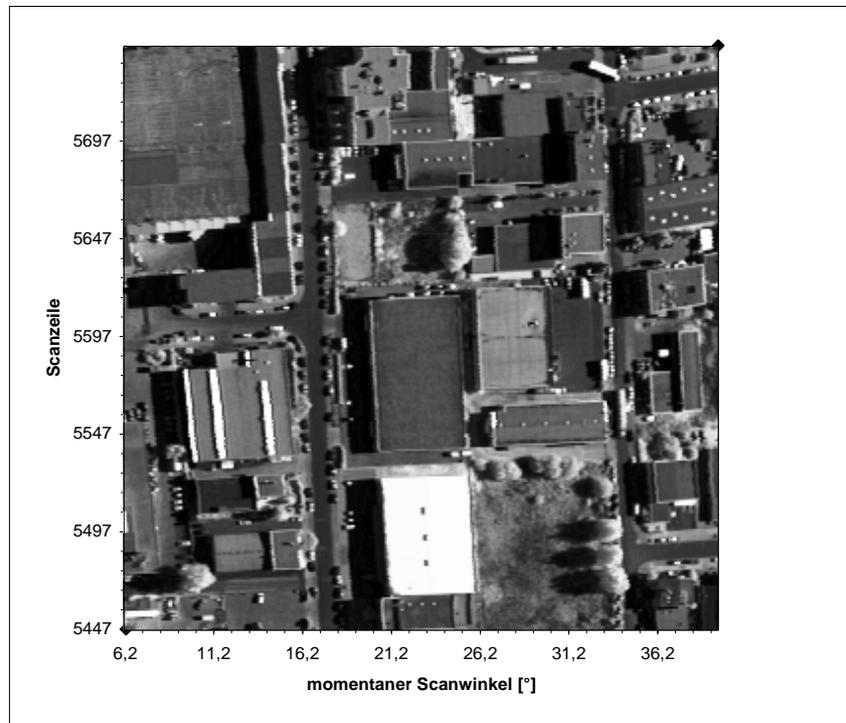


Abb. 36: Kontrastverstärkte Darstellung der Szene aus dem Flugstreifen T3, die in diesem Abschnitt klassifiziert wird. Sie stammt aus dem Jahr 1994 (vergleiche **Abb. A - 2**)

In dem Bildausschnitt gibt es eine Wiese (siehe Abb. 36 im Bereich von Scanzeile 5500 bei einem Scan-Winkel von ca. 30°), auf der drei Bäume dicht zusammenstehen. Auf den Luftphotos war zu erkennen, daß die Pflanzen auf dieser Wiese, zur Zeit der Aufnahme, stark vertrocknet waren. Die Pixel der Wiese wurden vom „Minimum Distance“-Verfahren überwiegend der Klasse „Erde“ zugeteilt. Das „Maximum Likelihood“-Verfahren hat die meisten Pixel der Wiese auch tatsächlich der Klasse „Wiese“ zugewiesen.

Interessant sind aber auch die Bäume, die auf der Wiese stehen, denn wenn man genau hinsieht, kann man (vor allem in Abb. 37) erkennen, daß jeweils die von der Sonne beschienen (rechten) Hälften der Bäume beim „Minimum Distance“-Verfahren der Klasse „Felder“ zugeordnet worden sind.

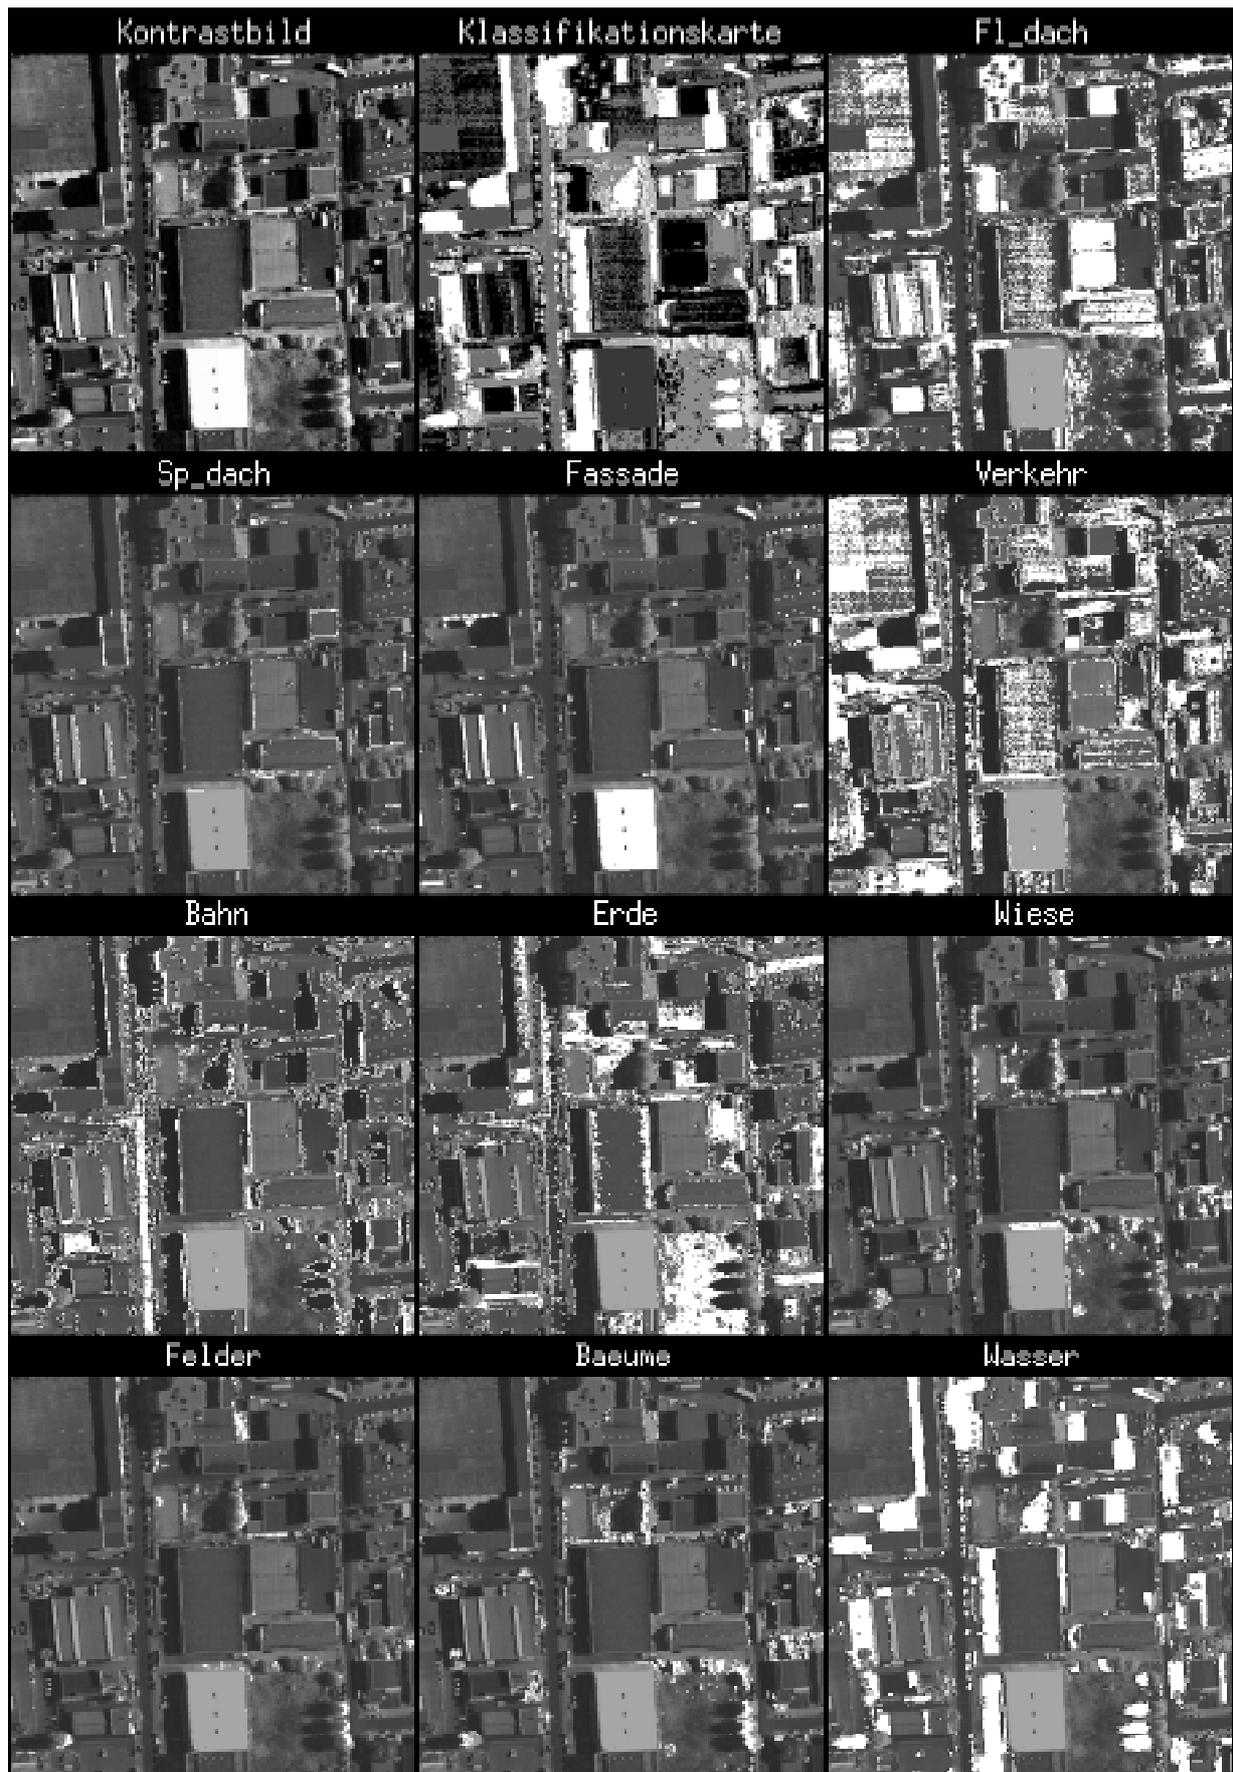


Abb. 37: Darstellung der Klassifikationsergebnisse, die bei der Klassifikation des gewählten Bildausschnittes mit dem „Minimum Distance“-Verfahren erreicht wurden.

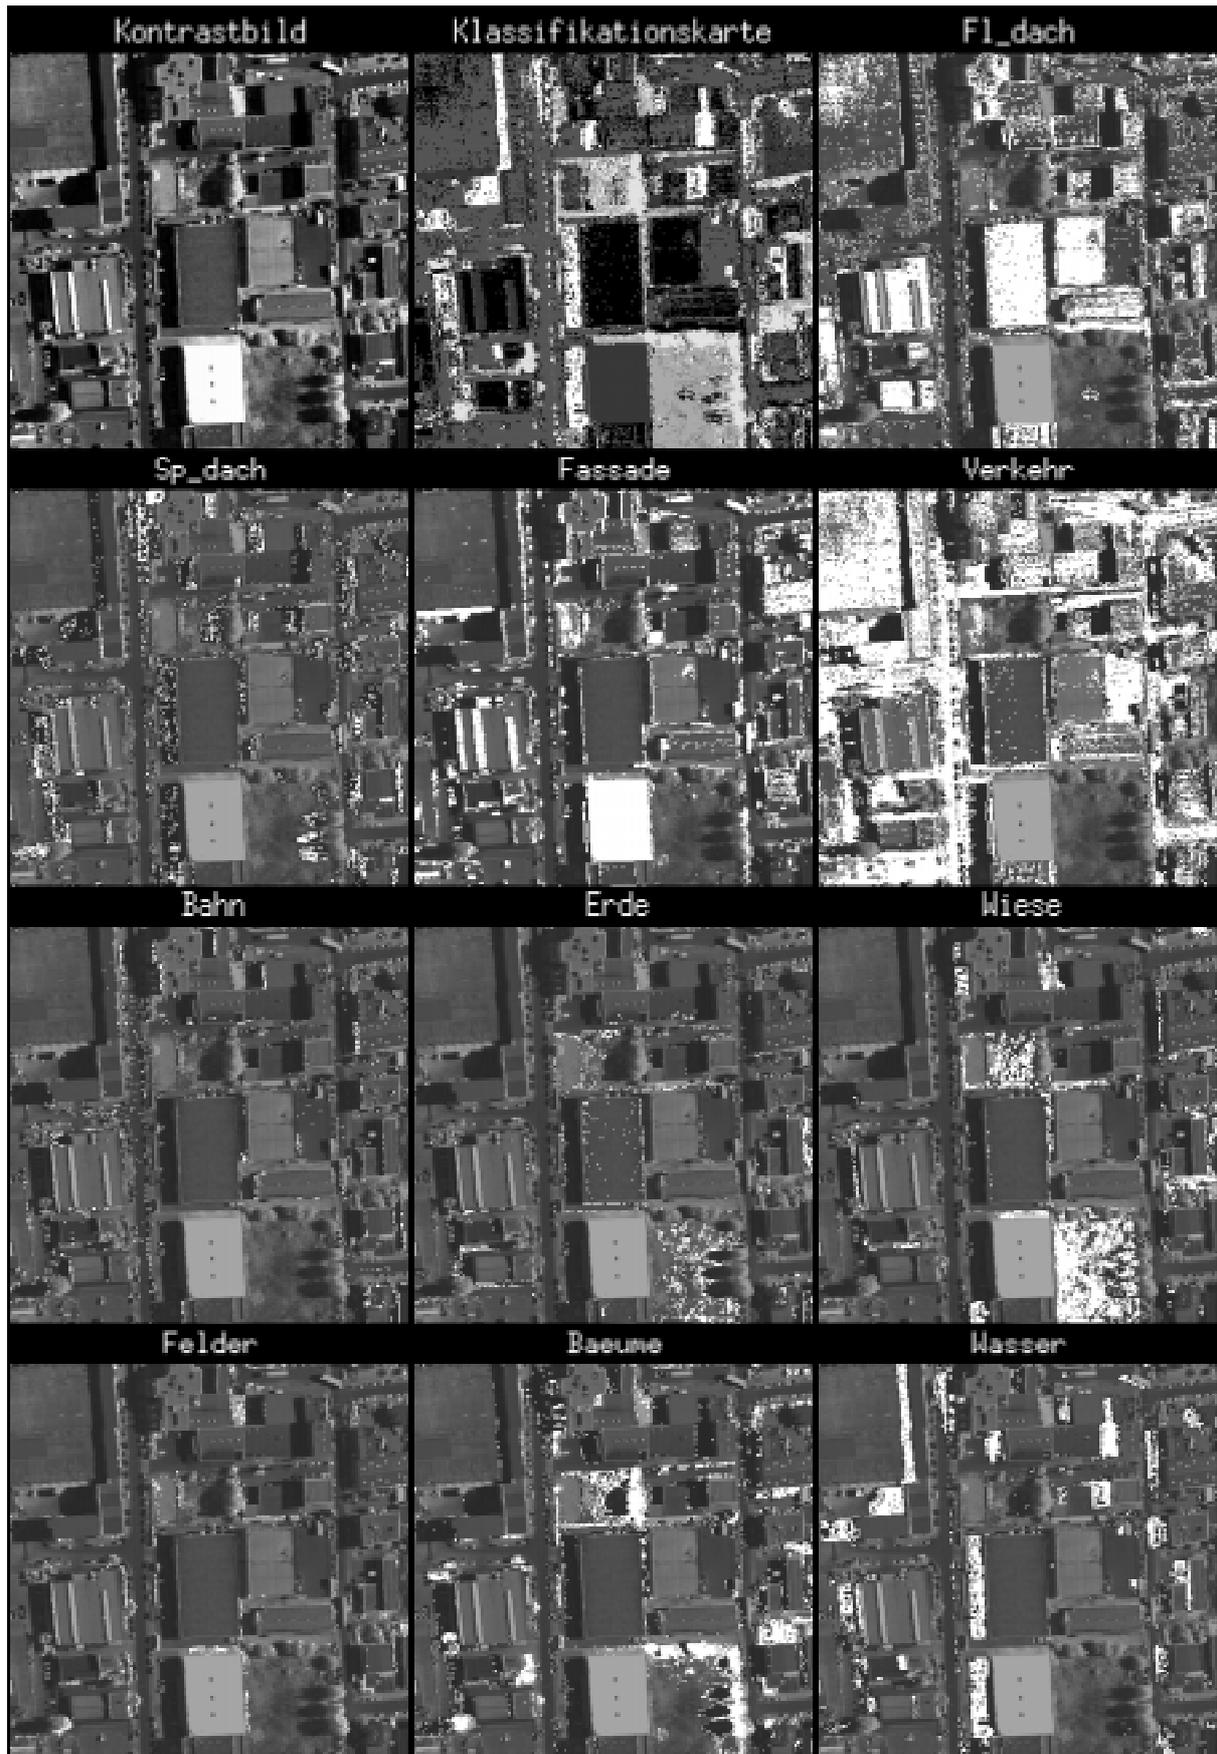


Abb. 38: Darstellung der Klassifikationsergebnisse, die bei der Klassifikation des gewählten Bildausschnittes mit dem „Maximum Likelihood“-Verfahren erreicht wurden

4 Überwachte Klassifikation von Multispektralbildern

Eine wichtige Auffälligkeit, die in beiden Abbildungen zu beobachten ist, tritt an den stark beschatteten Gebäudefassaden auf. Diese Fassaden und andere Schattenflächen wurden beim „Minimum Distance“-Verfahren überwiegend mit Wasserflächen verwechselt. Dieses Phänomen wurde häufig beobachtet. In der Praxis erweist sich also die Trennung von Schattenflächen und Wasserflächen als schwierig.

Insgesamt betrachtet erscheinen die Ergebnisse, die mit dem Maximum Likelihood-Verfahren erreicht wurden, spürbar besser zu sein. Allerdings muß noch einmal betont werden, daß hierbei nur ein kleiner Bildausschnitt verwendet wurde und die Ergebnisse deshalb auch nicht repräsentativ sind.

5 Änderungsdetektion mit Hilfe der überwachten Klassifikation

In der Praxis ist es nicht nur wichtig, daß man ein Luftbild mit hoher Genauigkeit klassifizieren kann, sondern es ist auch wichtig, daß man zeitliche Veränderungen aufdecken kann, um beispielsweise Entwicklungstendenzen abschätzen zu können. Hierfür müssen zwei Voraussetzungen gegeben sein. Erstens, es müssen mindestens zwei Luftbilder vorliegen, die zu verschiedenen Zeitpunkten aufgenommen wurden und das gleiche Gebiet abbilden. Zweitens, man muß über geeignete Methoden verfügen, um die Luftbilder zu entzerren und die aufgetretenen Veränderungen aufzuspüren¹⁷.

5.1 Entzerrung des Bildmaterials

Der erste Schritt der Durchführung bestand in der Sichtung des gesamten Bildmaterials, um zwei geeignete Bildausschnitte zu finden. Die Wahl fiel auf zwei Bildausschnitte, die aus den Jahren 1991 und 1995 stammten. Beide Ausschnitte wurden aus 1800m Höhe aufgenommen, und sie enthielten beide die Region um den „Nürnberger Flughafen“.

Im nächsten Schritt der Durchführung wurden beide Bildausschnitte Panorama-entzerrt (siehe Kap. 2.4.2). Anschließend wurden in beiden Bildausschnitten insgesamt 36 Paare korrespondierender Punkte (Paßpunkte) markiert (siehe Abb. 39). Mit Hilfe des Akima-Verfahrens (siehe unten) wurden die beiden Ausschnitte entzerrt. Der Begriff Entzerrung ist in diesem Zusammenhang eigentlich unpassend, denn keines der beiden Bilder ist verzerrungsfrei. Die Verzerrung des einen Bildes wird genau genommen nur der Verzerrung des anderen Bildes angepaßt. Für eine echte Entzerrung registriert man beide Luftbilder auf eine topographische Karte.



Abb. 39: Bildausschnitte aus den Jahren 1991 (links) und 1995 (rechts) mit jeweils 36 markierten Paßpunkten (weiße Flecken). Die Aufnahme erfolgte jeweils aus 1800m Höhe. Beide Bilder sind Panorama-entzerrt und kontrastverstärkt.

¹⁷ Für das Aufspüren von Veränderungen ist eine Klassifikation der Luftbilder nicht unbedingt notwendig. In [Speck 1997] wurden Detektionsverfahren untersucht, die nicht auf die vorherige Klassifikation der Luftbilder aufbauen.

5 Änderungsdetektion mit Hilfe der überwachten Klassifikation

Eine Entzerrung ist im Prinzip eine Transformation, bei der die Koordinaten (u,v) eines Quellbildes auf die Koordinaten (x,y) eines Zielbildes abgebildet werden. Im konkreten Fall ist das Bild aus dem Jahre 1991 das Quellbild und das Bild aus dem Jahre 1995 das Zielbild. Außerdem wurde hierbei eine inverse Transformation $(x, y) \mapsto (u, v)$ durchgeführt (beachte Kap. 2.4.2). Es müssen also die Transformationsfunktionen $u(x,y)$ und $v(x,y)$ bestimmt werden. Wir betrachten die beiden Funktionen u und v zunächst als eine bivariate Oberflächenfunktion $z(x,y)$ ersetzen.

Das bivariate Akima-Verfahren (siehe [Wiemker 1996], [Akima 1978]), das für die Entzerrungen in diesem Kapitel eingesetzt wurde, ist ein lokales Interpolationsverfahren. Deshalb wird bei diesem Verfahren nicht nur eine Oberflächenfunktion berechnet, sondern es werden eine Reihe von Funktionen $z_i(x, y)$ berechnet, die für jeweils eine bestimmte Region des Bildes zuständig sind (lokale Interpolation). Für die praktische Durchführung bedeutet dies, daß zunächst jeweils drei im Zielbild benachbarte Paßpunkte zu einer Gruppe zusammengefaßt werden (sog. „Delauney Dreiecksvermaschung“). Jeder Paßpunkt ist dabei in mehreren Gruppen enthalten. Für jede Gruppe wird eine Funktion $z_i(x, y)$ berechnet. Die Höhe der Oberflächenfunktionen $z_i(x, y)$ wird an jeweils drei Punkten festgelegt. Die Lage und die Höhe dieser Punkte werden durch die Koordinaten der drei Paßpunkte und ihrer korrespondierenden Punkte fixiert. Die Höhen aller übrigen Punkte (x,y) werden durch Interpolation und Extrapolation angepaßt (gefittet). Hierfür wird ein Polynom fünften Grades verwendet:

$$z_i(x, y) = \sum_{j=0}^5 \sum_{k=0}^{5-j} q_{ijk} x^j y^k \quad (\text{Gl. 30})$$

Bei der Bestimmung der Koeffizienten q_{ijk} müssen die folgenden Randbedingungen erfüllt werden:

- Es sei an der Stelle (x_0, y_0) ein Paßpunkt, der für alle Dreiecke D_i mit $i \in I$ einen Eckpunkt bildet. Die Werte der Funktionen $z_i(x, y)$ mit $i \in I$ und ihrer ersten und zweiten partiellen Ableitungen (nach x und y) müssen dann an dieser Stelle übereinstimmen.
- Die drei Richtungsableitungen $r_s(\delta)$ mit $s = 1, 2$ oder 3 der Funktionen $z_i(x, y)$ in jeweils eine der drei Richtungen senkrecht zu den drei Seiten des entsprechenden Dreiecks sind Polynome maximal dritten Grades in δ . Hierbei ist δ eine Variable, die den Weg entlang der jeweiligen Seite beschreibt.

Jede Funktion $z_i(x, y)$ ist für die Punkte (x,y) gültig, die innerhalb der Dreiecksfläche liegen, die von den drei Paßpunkten der Gruppe aufgespannt wird. Für Punkte (x,y) , die außerhalb der Dreiecksvermaschung liegen, erfolgt eine Extrapolation über das Maschennetz hinaus mit Polynomen lediglich zweiten Grades.

In Abb. 39 sind die verwendeten Paßpunkte markiert. Bei der Festlegung von Paßpunkten hat sich die Beachtung der folgenden drei empirischen Regeln bewährt:

- 1) Eckige Kanten von flachen, künstlichen Objekten (z.B. Straßen oder Parkplätze) sind als Paßpunkte gut geeignet. Die Ecken von hohen Objekten (z.B. Gebäude) sind, aufgrund möglicher perspektivischer Verzerrungen (beachte Kap. 2.4.1), nicht immer geeignete Paßpunkte.

- 2) Das Setzen von Paßpunkten in der Nähe des Bildrandes ist besonders wichtig. Denn sie sorgen dafür, daß auch viele der Pixel, die sich in den Randbereichen des Bildes befinden, innerhalb der von den Paßpunkten aufgespannten Dreiecksflächen liegen.
- 3) Die Anzahl der Paßpunkte ist nicht wichtig. Man kann unter Umständen auch mit sehr wenigen Paßpunkten eine gute Entzerrung erreichen.

Die letzte Regel legt die Strategie nahe, die Entzerrung mit anfangs nur wenigen Paßpunkten durchzuführen und das Ergebnis in einem iterativen Prozeß schrittweise zu verfeinern.

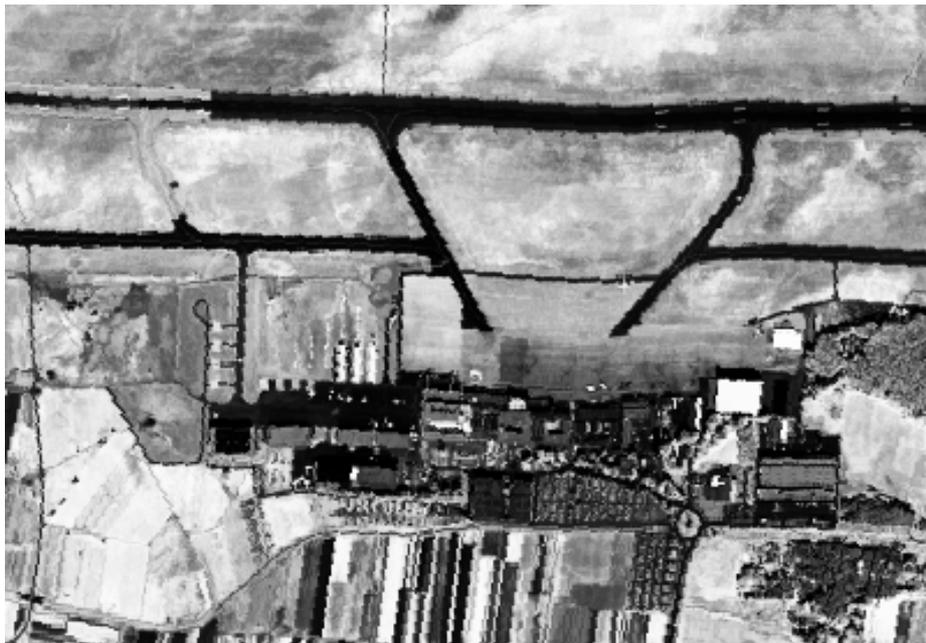


Abb. 40: Bildausschnitt aus dem invers transformierten Quellbild (also aus dem Jahr 1991)



Abb. 41: Bildausschnitt aus dem Zielbild (also aus dem Jahre 1995)

5 Änderungsdetektion mit Hilfe der überwachten Klassifikation

Nach der Entzerrung wurde die Region um den Flughafen aus dem invers transformierten Quellbild und aus dem Zielbild herausgeschnitten (siehe Abb. 40 und Abb. 41). Abschließend erfolgte noch eine Überprüfung der Entzerrungsgenauigkeit. Hierfür wurde in den eben erwähnten Bildausschnitten erneut Paßpunkte festgelegt. Die euklidischen Abstände zwischen den jeweils korrespondierenden Paßpunkten wurden berechnet und die gerundeten Werte jeweils rechts neben den entsprechenden Paßpunkt geschrieben (siehe Abb. 42). Man erkennt, daß die Stärke der „Restverzerrungen“ lokal recht unterschiedlich ist. Deshalb wurde auch auf die Angabe eines mittleren euklidischen Abstandes verzichtet.

Bei einer genauen Betrachtung der beiden Abbildungen kann man erkennen, daß die räumliche Auflösung in der Abb. 40 geringer ist als die Auflösung in der Abb. 41. Dieser Effekt tritt generell immer beim „Resampling“¹⁸ von Digitalbildern auf.



Abb. 42: Bildausschnitt (aus dem Zielbild) mit 26 Paßpunkten, die zur Kontrolle der Entzerrung gesetzt wurden. Die Zahlen entsprechen den gerundeten euklidischen Abständen zwischen den korrespondierenden Punkten in Abb. 40 und Abb. 41.

5.2 Auswahl der Trainingsklassen und Durchführung der Klassifikation

Nachdem nun die beiden aufeinander angepaßten (entzerrten) Bilder (Abb. 40 und Abb. 41) vorliegen, kann mit der Klassifikation dieser Bilder begonnen werden. Zunächst benötigt man wieder Trainingspixel, um die notwendigen Trainingsklassen zu generieren. Als Erstes muß entschieden werden, aus welchem Bildmaterial die Trainingspixel entnommen werden sollen. Am naheliegendsten ist wohl die Entnahme der Pixel aus dem jeweiligen zu klassifizierenden Bild. Dieser Weg wurde allerdings nicht beschritten, sondern es wurden für beide Bilder die Trainingspixel aus einem weiteren Bildausschnitt entnommen, der aus dem Bildmaterial von 1995 stammte und aus einer Flughöhe von 300m aufgenommen worden war (siehe Abb. 43). Diese Wahl hat zur Folge, daß bei der Klassifikation des Bildausschnittes von 1991 Effekte auftreten können, die mit der unterschiedlichen Kalibrierung der Bilddaten zusammenhängen. (Zur Erinnerung: Nur die Daten von 1994 und 1995 sind mit IRIS-Messungen kalibriert worden.) Die Wahl der Trainingsgebiete aus einem anderen als dem zu klassifizierenden Ausschnitt die Möglichkeit, Effekte zu beobachten, die durch unterschiedliche Flughöhen entstehen. Man bedenke, daß sich die spektralen Merkmale kleiner, dicht zusammenstehender Objekte, bei einer Abnahme der räumlichen Auflösung, mit einander vermischen.

¹⁸ In der vorliegenden Arbeit wurde das Resampling nach der „nearest neighbor“-Methode durchgeführt (vergleiche Kapitel 2.4.2).

Der nächste Schritt besteht in der Festlegung geeigneter Informationsklassen. Die in Kapitel 4 verwendeten Klassen sind hier nicht geeignet, weil die mit ihnen erreichten Genauigkeiten nur sehr gering waren. Für die Durchführung einer Änderungsdetektion benötigt man jedoch Klassen, die eine möglichst gute Trennbarkeit besitzen. Denn jede Diskrepanz zwischen der Klassenzugehörigkeit eines Pixel in dem einen Bild und der Klassenzugehörigkeit seines korrespondierenden Pixels in dem anderen Bild wird als Änderung interpretiert. Da für die Klassifikation nur spektrale Merkmale eingesetzt wurden, erschienen die vier Informationsklassen „Asphalt“, „Beton“, „Erde“ und „Vegetation“ als geeignet. Für diese Klassen wurden insgesamt 9 Trainingsgebiete festgelegt. Anschließend wurden die für die Klassifikation notwendigen Mittelwerte und Kovarianzmatrizen berechnet. Für die Klassifikationen mit dem „Minimum Distance“-Verfahren wurde aus jedem Trainingsgebiet jeweils eine Trainingsklasse gebildet. Für die Klassifikation mit dem „Maximum Likelihood“-Verfahren wurden wieder die Pixel mehrerer Trainingsgebiete (wie bei Methode 2 in Kap. 4.8 beschrieben) zusammengeführt.

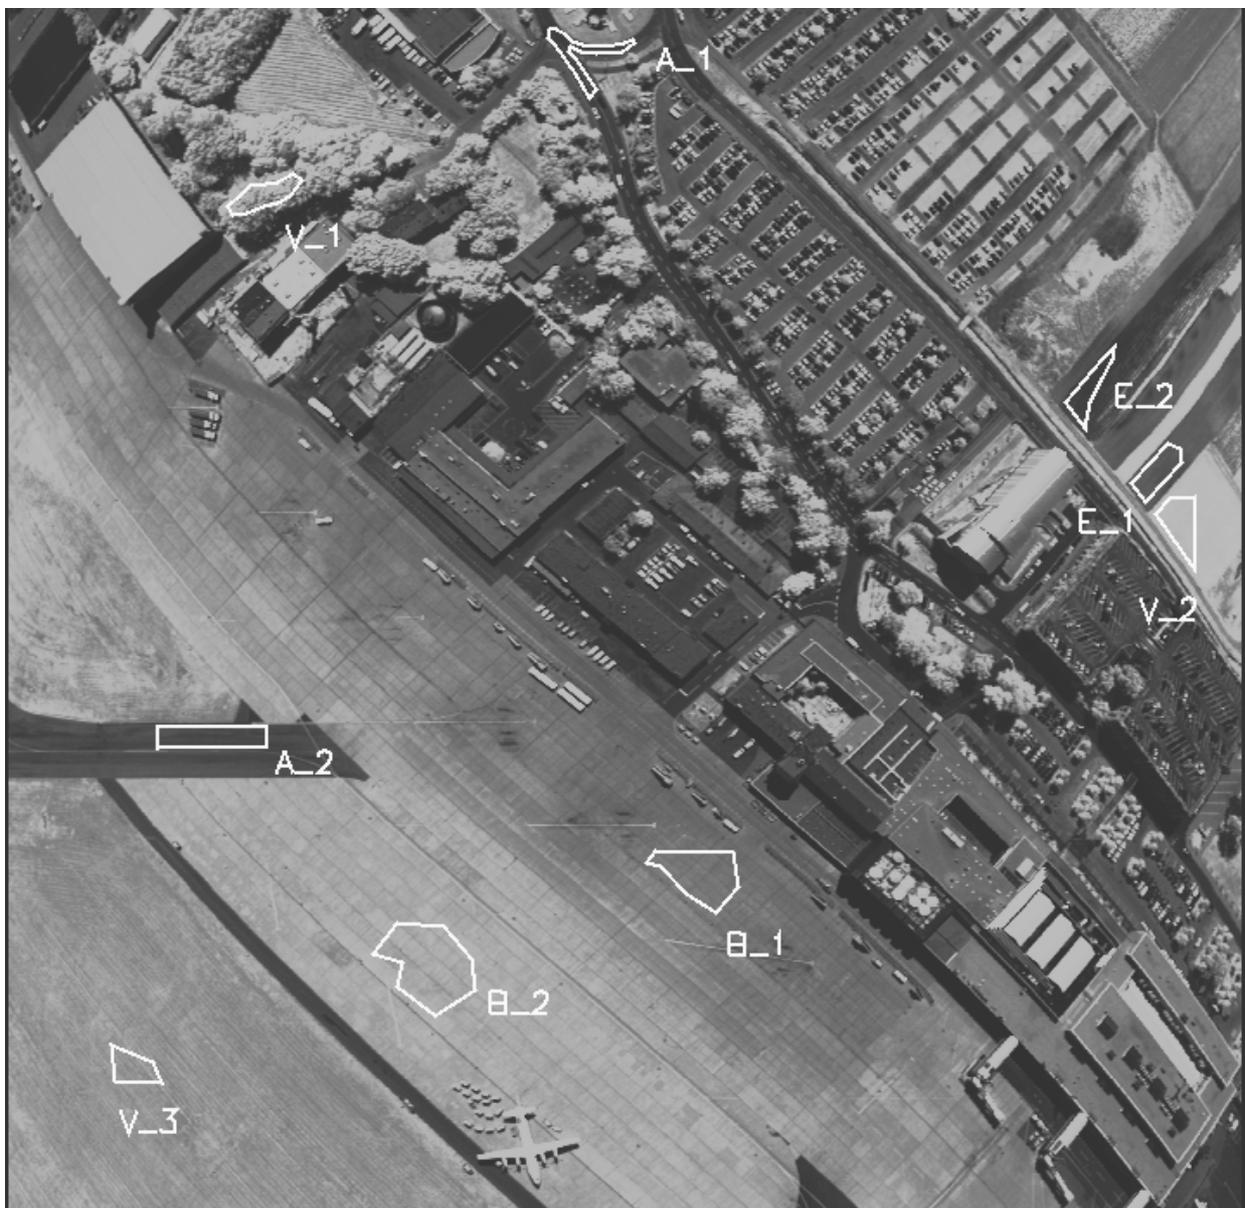


Abb. 43: Bildausschnitt aus dem Jahr 1995 (noch nicht Panorama-entzerrt). Er wurde aus 300m Höhe aufgenommen, und aus ihm wurden die Daten für die Trainingsklassen „Asphalt“ (A), „Beton“ (B), „Erde“ (E) und „Vegetation“ (V) gewonnen.

5 Änderungsdetektion mit Hilfe der überwachten Klassifikation

Die Ergebnisse der insgesamt vier Klassifikationen sind als farbige Klassifikationskarten in Abb. 44 zu sehen. Eine Genauigkeitsanalyse, wie sie in Kapitel 4 durchgeführt wurde, war nicht möglich, weil eine sichere Identifikation der verschiedenen Materialien, anhand der Luftaufnahmen, nicht möglich war. Die Klassifikationskarten zeigen eine Reihe von Auffälligkeiten. So hat z.B. das „Minimum Distance“-Verfahren (im Vergleich zum „Maximum Likelihood“-Verfahren) deutlich mehr Pixel der Klasse „Erde“ zugewiesen. Das „Maximum Likelihood“-Verfahren hat die meisten dieser Pixel der Klasse „Vegetation“ zugeteilt. Die Ursache für diesen Effekt liegt vermutlich wieder in der fehlenden Normalverteilung in den Grauwerten der Trainingspixel (beachte Kap. 4.8).

In Abb. 40 ist in der unteren rechten Bildecke ein kleines Waldgebiet zu erkennen. Dieses Waldgebiet wurde vom „Minimum Distance“-Verfahren in beiden Jahren überwiegend als „Erde“ eingestuft und nicht als „Vegetation“. Andererseits hat das Maximum Likelihood-Verfahren einige der gepflügten Felder als „Vegetation“ eingestuft. Eine Auffälligkeit, die alle Klassifikationskarten in Abb. 44 zeigen, ist die Klassifikation von einigen gepflügten Feldern als „Asphalt“. Da eine zufriedenstellende Beurteilung der Klassifikationskarten ohne quantitative Genauigkeitsanalyse nicht möglich ist, werden alle vier Karten im folgenden verwendet.

5.3 Auswertung und Diskussion der Ergebnisse

Bevor mit der Durchführung der eigentlichen Änderungsdetektion begonnen werden kann, muß der Begriff „Änderung“ zunächst präzisiert werden. Im folgenden wird unter einer „Änderung am Ort x“ jeder Vorgang verstanden, bei dem ein Objekt am Ort x durch ein zweites Objekt ersetzt wird, dessen Eigenschaften sich vom ersten Objekt signifikant unterscheiden. Die Frage, ob sich die Eigenschaften von zwei Objekten signifikant unterscheiden, kann nicht immer eindeutig geklärt werden. Da im Rahmen dieser Arbeit nur spektrale Merkmale für die Klassifikation eingesetzt werden, kann auch nur der Austausch von Objekten erfaßt werden, die sich in ihren spektralen Eigenschaften unterscheiden.

Die eigentliche Durchführung der Änderungsdetektion beruht auf der logischen Verknüpfung von zwei Klassifikationskarten, die zu Bildern gehören, die zu unterschiedlichen Zeitpunkten aufgenommen wurden. Die Klassenzugehörigkeit von jedem Pixel wird mit der Klassenzugehörigkeit seines korrespondierenden Pixels verglichen. Wenn beide verschiedenen Klassen angehören, liegt eine Änderung vor. Die Ergebnisse der Vergleiche werden in eine neue Karte eingetragen. Sie wird im folgenden als Änderungskarte bezeichnet. Sie ist im Prinzip ebenfalls eine Klassifikationskarte mit den beiden Klassen „Änderung“ und „keine Änderung“.

In Abb. 45 sind die Änderungspixel weiß markiert, die sich aus der Verknüpfung der beiden Klassifikationskarten, die mit dem „Minimum Distance“-Verfahren erzeugt wurden, ergaben. Abb. 46 zeigt die entsprechenden Ergebnisse für das „Maximum Likelihood“-Verfahren.

Die beiden Abbildungen zeigen eine Vielzahl von Änderungen. Die Ursachen dieser Änderungen lassen sich in vier Kategorien einteilen:

- 1) Änderungen durch die Bewegung von Flugzeugen und Fahrzeugen
- 2) Änderungen durch bauliche Maßnahmen
- 3) Änderungen durch landwirtschaftliche Aktivitäten
- 4) Änderungen, die durch „Restverzerrungen“ verursacht werden. (Sie sind z.B. an den Rändern der Startbahn zu beobachten.)

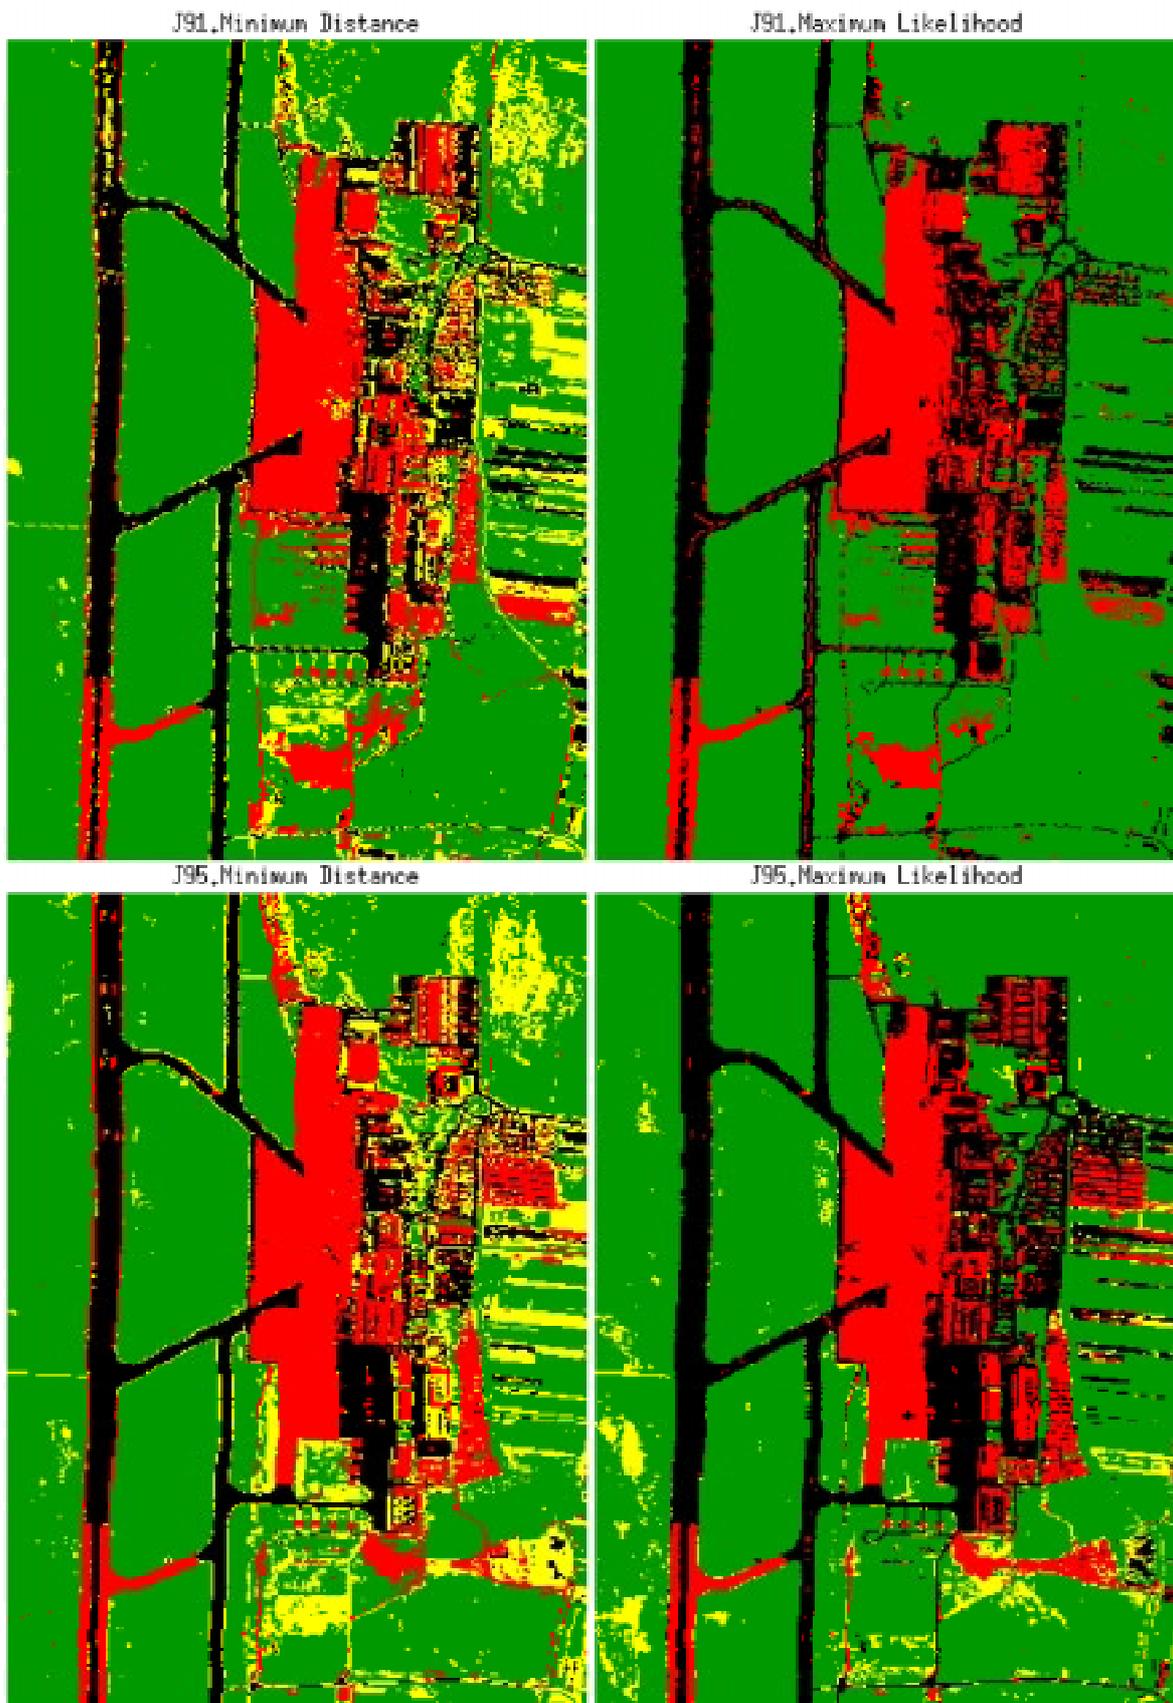


Abb. 44: *Farbige Klassifikationskarten.*
Klassifikation mit den Klassen: Asphalt (schwarz), Beton (rot), Erde (gelb), Vegetation (grün)

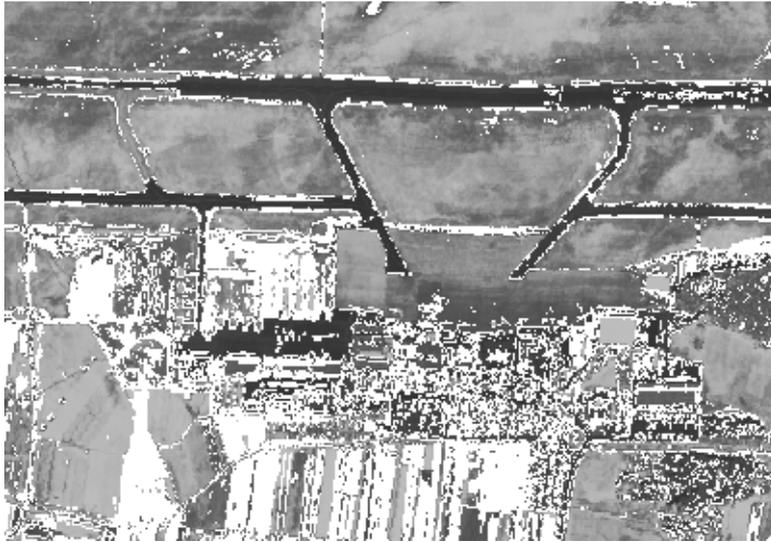


Abb. 45: Änderungskarte, die sich aus der Verknüpfung der beiden Klassifikationskarten ergaben, die mit dem „Minimum Distance“-Verfahren erzeugt wurden. Die Änderungspixel sind weiß markiert.



Abb. 46: Änderungskarte, die sich aus der Verknüpfung der beiden Klassifikationskarten ergaben, die mit dem „Maximum Likelihood“-Verfahren erzeugt wurden. Die Änderungspixel sind weiß markiert.

Um die Anzahl der Änderungspixel zu reduzieren, wurde noch eine weitere Verknüpfung durchgeführt. Hierbei wurden jeweils die Klassifikationskarten des gleichen Jahres verknüpft. Alle Pixel, die von beiden Klassifikationsverfahren der gleichen Klasse zugewiesen wurden, wurden hierbei als „zuverlässig“ eingestuft. Alle übrigen Pixel wurden als „unzuverlässig“ eingestuft. Danach wurden aus der Änderungskarte in Abb. 45 alle Änderungspixel herausgefiltert, die nicht in beiden Jahren als „zuverlässig“ eingestuft worden waren. Abschließend wurde die bereinigte Änderungskarte noch einer Filterung mit einem Medianfilter unterzogen, um vor allem vereinzelte Änderungspixel herauszufiltern, die vermutlich durch „Restverzerrungen“ verursacht wurden. Die Änderungskarte, die sich hieraus ergab, bildete die Grundlage von Abb. 47.

Ein Medianfilter ist ein Rangordnungsfiler. Die Werte aller Pixel, die in einer definierten Umgebung um das gerade betrachtete Pixel herum liegen, werden der Größe nach sortiert. Der Wert des betrachteten Pixels wird anschließend durch den Wert in der Mitte der Liste, die aus

5 Änderungsdetektion mit Hilfe der überwachten Klassifikation

der Sortierung der Werte entstanden ist, ersetzt. Im speziellen Fall wurde die Liste jeweils aus den acht Pixeln gebildet, die das betrachtete Pixel direkt umgaben, und aus dem betrachteten Pixel selbst. Bei nur zwei möglichen Klassen („Änderung“ oder „keine Änderung“) behält ein Pixel nach der Median-Filterung genau dann seine ursprüngliche Klasse bei, wenn die Mehrheit der Pixel im betrachteten Filterfenster (3 x 3) auch dieser Klasse angehört.

Die Filterung und die zusätzlichen Verknüpfungen haben die Zahl der Änderungspixel erheblich reduziert (siehe Abb. 47). Um zu überprüfen, ob trotzdem noch alle wichtigen Veränderungen erfaßt wurden, wurde noch einmal manuell nach auffälligen Veränderungen gesucht. Die auffälligen Gebiete wurden mit weißen Linien umrandet und mit einer Zahl beschriftet (siehe Abb. 48). Zur Kontrolle wurden die Luftphotos eingesetzt.



Abb. 47: Änderungskarte, die sich aus der Median-Filterung und der logischen Verknüpfung aller vier Klassifikationskarten ergab. Die Änderungspixel sind weiß markiert.

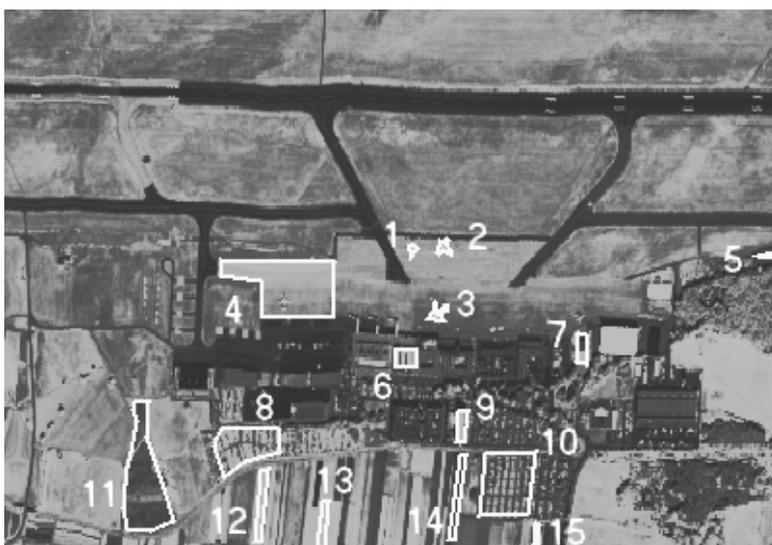


Abb. 48: Bildausschnitt aus dem Zielbild (1995) mit 15 Polygonen, die jeweils eine Änderung markieren, die bei einer manuellen Auswertung gefunden wurden.

Die Zahlen 1 bis 3 markieren Änderungen, die der 1. Kategorie zu zuordnen sind. Sie wurden vom Verfahren alle nicht gefunden. Die Zahlen 4 bis 10 markieren bauliche Veränderungen (2. Kategorie). Der Bau eines Glasdaches an einem der Terminalgebäude (siehe Markierung Nr. 6

in Abb. 48) ist vom Verfahren nicht erkannt worden. Außerdem wurde der Bau eines gesamten Gebäudes nicht entdeckt (siehe Markierung Nr. 9). Die Zahlen 11 bis 15 markieren Änderungen, die durch landwirtschaftliche Aktivitäten verursacht wurden (3. Kategorie). Es wurden vom Computer in allen markierten Gebieten entsprechende Änderungen entdeckt. Allerdings wurde kein einziges Gebiet flächendeckend markiert.

Insgesamt sind die Ergebnisse recht zufriedenstellend. Die Probleme, bei der Erfassung der Änderungen der ersten beiden Kategorien, sind teilweise darauf zurückzuführen, daß keine Materialklasse „Metall“ eingesetzt wurde. Die metallischen Objekte (z.B. die Flugzeuge) wären dann nämlich nicht mehr überwiegend als „Beton“ eingestuft worden. Sie wären also von dem Vorfeld unterscheidbar gewesen. Allerdings besitzt die Klasse „Metall“ keine hohe Klassifikationsgenauigkeit, so daß ihr Einsatz zu neuen Problemen geführt hätte. Es muß in der Praxis also stets ein Kompromiß geschlossen werden zwischen der Wahl geeigneter Klassen und der Forderung nach hoher Klassifikationsgenauigkeit.

6 Zusammenfassung und Ausblick

In dieser Arbeit wurden Verfahren zur Klassifikation multispektraler Luftbilder städtischer Gebiete eingesetzt und bewertet. Das Bildmaterial stammte vom Multispektralscanner Daedalus AADS 1268 mit 10 spektralen Bildkanälen. Die Zielsetzung bestand darin, einen Vergleich zwischen den beiden Klassifikationsverfahren „Minimum Distance“ und „Maximum Likelihood“ durchzuführen. Die vorliegende Untersuchung hebt sich in zwei wesentlichen Punkten von früheren Arbeiten zu diesem Thema ab:

- a) Verwendung von Bildern mit wesentlich höherer räumlicher Auflösung ($\approx 1m$) als üblich.
- b) Berücksichtigung der Abhängigkeit der Klassifikationsgenauigkeiten von der Auswahl der Trainingsgebiete, sowie der Anzahl der verwendeten Spektralkanäle.

Während der Durchführung der Untersuchung mußten eine Reihe von Entscheidungen getroffen werden. Als Erstes mußte geeignetes Bildmaterial ausgewählt werden. Die Wahl fiel auf das Bildmaterial aus dem Oktober 1994, weil bei der Aufnahme von diesem Bildmaterial die Sonne sehr tief stand. Die sich hieraus ergebenden Schatteneffekte sind ein typisches Problem in der Verarbeitung von Bildern mit hoher räumlicher Auflösung. Deshalb war es besonders interessant zu untersuchen, wie die verschiedenen Klassifikationsverfahren auf dieses Problem reagieren.

Im nächsten Schritt folgte eine Einteilung des Bildmaterials in geeignete Informationsklassen. Die Auswahl der Klassen wurde von einer Voruntersuchung über die Erreichbarkeit des angestrebten Klassifikationsziels begleitet. In diesem Zusammenhang wurden kleine Bildausschnitte (Stichproben) aus dem Bildmaterial ausgeschnitten und nach einem Vergleich mit den Luftphotos (Falschfarben-Infrarot-Bilder mit hoher räumlicher Auflösung) den entsprechenden Klassen zugeteilt. Die Stichproben wurden entweder als Kontrollgebiete oder als Trainingsgebiete eingesetzt.

Ein wichtiges Problem, das beim Vergleich der beiden Verfahren gelöst werden mußte, trat bei der Auswahl der Trainingsklassen in Erscheinung, und zwar waren die einzelnen Trainingsklassen für die beiden Verfahren unterschiedlich gut geeignet. Zur Lösung dieses Problems wurden die Trainingsklassen mit Hilfe von Zufallsalgorithmen des verwendeten Computers zu Trainingssätzen zusammengefaßt und diese wiederum zu sechs Permutationssätzen zusammengestellt. Die Ergebnisse aus allen Klassifikationen mit den Trainingssätzen aus jeweils einem Permutationssatz wurden gemittelt. Diese gemittelten Ergebnisse waren weitgehend unabhängig von dem Einfluß der einzelnen Trainingsklassen und sind mit geschätzten Fehler-Margen versehen.

Die anfängliche Zielsetzung wurde noch um die Untersuchung von Maßnahmen zur Erhöhung der Klassifikationsgenauigkeit und zur Reduzierung des Rechenaufwandes bei der Klassifikation erweitert. Abschließend wurde noch untersucht, inwieweit die überwachte Klassifikation zur Detektion von Veränderungen in Bildern geeignet ist, die zu verschiedenen Zeitpunkten aufgenommen wurden.

Die Untersuchungen führten zu folgenden Ergebnissen:

- Die erreichten Genauigkeiten waren nicht sehr hoch. So lagen die gemittelten Kappa-Werte (bei Verwendung von „Permutationssatz 6“) bei ca. 45% („Minimum Distance“-Verfahren) und 52% („Maximum Likelihood“-Verfahren). Für die niedrigen Prozentzahlen gibt es ver-

mutlich zwei Gründe. Zum einen unterscheiden sich die verwendeten Informationsklassen nicht in ausreichendem Maße in ihren spektralen Eigenschaften. Zum anderen sind zumindest einige der Informationsklassen (z.B. die Klasse „Flachdach“) in sich spektral sehr inhomogen. Hierfür sind vor allem unterschiedliche Baumaterialien und Beleuchtungseffekte verantwortlich.

- Das „Maximum Likelihood“-Verfahren erreichte nur durchschnittlich 5% bessere Kappa-Werte als das „Minimum Distance“-Verfahren. Bei der Bewertung dieses Ergebnisses muß berücksichtigt werden, daß der Rechenaufwand für die Klassifikation mit dem „Maximum Likelihood“-Verfahren N_K mal höher ist, wobei N_K der Anzahl der Spektralkanäle entspricht. Die Ursache für den geringen Unterschied ist vermutlich hauptsächlich darin zu suchen, daß die Pixel von zumindest einigen Informationsklassen im Merkmalsraum sehr komplex verteilt sind.
- Die Kappa-Werte, aus denen die gemittelten Kappa-Werte berechnet wurden, waren sehr unterschiedlich. So ergaben sich bei Verwendung von „Permutationssatz 6“, je nach Trainingsatz, Kappa-Werte von 31,7% bis 57,0% („Minimum Distance“-Verfahren) und 40,3% bis 62,0% („Maximum Likelihood“-Verfahren). Ursache hierfür ist vermutlich wieder die komplexe Verteilung der Pixel im Merkmalsraum. Es läßt sich hieraus die Konsequenz ziehen, daß eine sorgfältige Auswahl der Trainingsgebiete wichtiger ist als die Entscheidung, welches der beiden Verfahren man für die Klassifikation verwendet.
- Die Wiedererkennungsgenauigkeiten der einzelnen Informationsklassen waren ebenfalls sehr unterschiedlich. Sie lagen beispielsweise bei der Klassifikation mit „Permutationssatz 6“ in Verbindung mit dem „Maximum Likelihood“-Verfahren (siehe Tabelle 44) im Bereich von 35% bis 85%.
- Sowohl die gemittelten Kappa-Werte als auch die Wiedererkennungsgenauigkeiten der einzelnen Informationsklassen zeigten eine deutliche Abhängigkeit von der Anzahl der eingesetzten Trainingsklassen. Hierbei zeigte es sich, daß wenn man nur wenige zusätzliche Trainingsklassen einsetzen möchte, diese auf spektral besonders inhomogene Klassen konzentrieren sollte. Beim Einsatz vieler Trainingsklassen lohnt es sich, möglichst für jede Informationsklasse die gleiche Anzahl an Trainingsklassen zu wählen, weil sonst die Wiedererkennungsgenauigkeiten einzelner Klassen zu stark absinken können.
- Die Reduzierung der Anzahl der Spektralkanäle erwies sich als sehr erfolgreich. So konnte gezeigt werden, daß sich die Klassifikationsergebnisse nicht signifikant verschlechtern, wenn man die Klassifikation mit nur sechs Spektralkanälen (Kanal Nr. 2, 3, 5, 7, 9 und 10 des Daedalus-Scanners) durchführt. Auch die Klassifikationen mit den drei Spektralkanälen 3, 5 und 7 lieferten vergleichsweise gute Ergebnisse. So waren die Kappa-Werte der Klassifikationen mit allen zehn Spektralkanälen nur um ca. 6 bis 7% höher als die Ergebnisse, die bei der Klassifikation mit nur diesen drei Kanälen erreicht wurden.
- Die „Verschmelzung“ von mehreren Stichproben (Trainingsgebieten) einer Informationsklasse zu einer einzigen Trainingsklasse führte beim „Maximum Likelihood“-Verfahren zu einer Erhöhung (um 3 bis 4%) der Klassifikationsgenauigkeit (gemittelter Kappa-Wert). Die Bildung von Trainingsklassen aus mehreren räumlich getrennten Trainingsgebieten ist also bei der Klassifikation mit dem „Maximum Likelihood“-Verfahren empfehlenswert. Beim „Minimum Distance“-Verfahren führte die Verschmelzung der Stichproben zu einer deutlichen Verschlechterung (um bis zu 8%) der gemittelter Kappa-Werte. Für dieses Verfahren ist es besser mehrere Trainingsklassen pro Informationsklasse einzusetzen.

6 Zusammenfassung und Ausblick

- Die Ergebnisse, die sich aus der Untersuchung von *Änderungsdetektionen* mit Hilfe der überwachten Klassifikation ergeben haben, waren insgesamt recht zufriedenstellend. Es zeigte sich aber auch, daß die Klassifikationsgenauigkeiten, die für eine zuverlässige Änderungsdetektion benötigt werden, sehr hoch sein müssen. Mit den Klassifikationsgenauigkeiten, wie sie in Kapitel 4 erreicht wurden, ist eine erfolgreiche Änderungsdetektion kaum möglich.

Die Untersuchungen in dieser Arbeit wurden auf der Grundlage von multispektralen Luftbildern mit einer hohen räumlichen Auflösung durchgeführt. Aufgrund der hohen Auflösung traten einige Probleme auf (z.B. Schattenbildung), die bei der Verwendung von Bildmaterial mit geringerer räumlicher Auflösungen nicht so stark ins Gewicht fallen. Es ist deshalb sinnvoll, die in dieser Arbeit erreichten Klassifikationsgenauigkeiten mit den Genauigkeiten aus anderen Arbeiten zu vergleichen:

Kappa-Wert [%]	Bewertung gemäß Tabelle 3	Eingesetztes Klassifikationsverfahren	verwendete Klassen	Bildsensor	räumliche Auflösung	Ergebnisse aus:
40,3 bis 62,0	gut bis sehr gut	Maximum Likelihood	Flachdach, Spitzdach, Fassade, Bahn, Verkehr, Erde, Wiese, Felder, Bäume, Wasser	Daedalus AADS 1268	ca. 1 Meter	Kapitel 4.6 in dieser Arbeit
32,5 bis 51,7	akzeptabel bis gut	Maximum Likelihood	Winterweizen, Raps, Hafer, Wintergerste, Sommergerste, Mais	SPOT HRV	ca. 20 Meter	[Palubinskas 1996]
42,2 bis 56,0	gut	Maximum Likelihood	Erde, Bohnen, Mais, Tomaten, Sorghum(Hirse), Sojabohnen, Kürbis	Landsat TM	ca. 30 Meter	[Ortiz et al 1997]

Tabelle 53: Vergleich von Klassifikationsergebnissen aus dieser Arbeit mit den Ergebnissen aus anderen Arbeiten. (Die Angaben über die räumlichen Auflösungen von SPOT HRV und Landsat TM stammen aus [Sabins 1978]).

Aufgrund der Unterschiede in der Wahl der Klassen ist ein direkter Vergleich der Ergebnisse in der obigen Tabelle eigentlich nicht möglich. Die Gegenüberstellung zeigt aber, daß auch die Klassifikationsergebnisse, die sich aus der Klassifikation von Bildern mit geringerer räumlicher Auflösung ergeben, starken Schwankungen unterworfen sind. Außerdem sind die Genauigkeiten, die bei diesen Klassifikationen erreicht wurden, mit den Ergebnissen in dieser Arbeit vergleichbar.

Allerdings sind die erreichten Klassifikationsgenauigkeiten keinesfalls zufriedenstellend. Aus diesem Grund werden abschließend noch einige Ansatzpunkte diskutiert, die zu einer spürbaren Steigerung der Klassifikationsgenauigkeit führen könnten.

Einen ersten wichtigen Ansatzpunkt bilden beim „Maximum Likelihood“-Verfahren die a priori Wahrscheinlichkeiten $p(\omega_i)$ (beachte Gl. 13). Denn vor allem in Bildern mit hoher räumlicher Auflösung ist die Wahrscheinlichkeit hoch, daß zwei benachbarte Pixel der gleichen Klasse angehören. Außerdem lassen sich diese Bilder in Gebiete (z.B. Stadtgebiete) unterteilen, in

denen bestimmte Klassen vorherrschen. Es wäre deshalb sinnvoll, die a priori Wahrscheinlichkeiten $p(\omega_i)$ nicht weiterhin als für alle Klassen gleich anzunehmen, sondern sie lokal abzuschätzen.

Einen weiteren wichtige Möglichkeit zur Erhöhung der Klassifikationsgenauigkeit liegt in der Hinzunahme neuer Merkmale. Dieser Weg ist schon deshalb interessant, weil die Untersuchungen in Kap. 4.8 gezeigt haben, daß nicht alle Spektralkanäle für die Erreichung der bestmöglichen Klassifikationsgenauigkeit benötigt werden. Ein in diesem Zusammenhang interessantes Merkmal ist die lokale spektrale Varianz. Die Varianz entspricht dem Quadrat der Standardabweichung (siehe Gl. 17). Die Varianz eines Pixels ist um so größer, je stärker sich die Grauwerte der Pixel unterscheiden, die sich in einem bestimmten Gebiet um das gerade betrachtete Pixel herum befinden. Wie groß dieses Gebiet sein muß, ist nicht fest vorge-schrieben. In der Praxis wird aber häufig die Varianz aus einem Gebiet mit jeweils neun Pixeln berechnet. Die Varianz ist also ein Streumaß und somit das einfachste der sog. Texturmerkmale. Die Varianz ist beispielsweise in Waldgebieten sehr hoch. Bei Grasflächen oder bewachsenen Feldern ist die Varianz deutlich niedriger (siehe [Neumann 1996]). In wieweit dies zur Verbesserung der Klassifikationsergebnisse führt, sollte überprüft werden. Ein weiteres Merkmal, dessen Einbeziehung gerade bei Bildern mit hoher räumlicher Auflösung erfolgversprechend ist, ist die äußere Gestalt (bzw. Form) von Objekten. In diesem Zusammenhang muß aber darauf hingewiesen werden, daß man, um dieses Merkmal einsetzen zu können, von der Klassifikation einzelner Pixel abweichen muß. Die Klassifikation mit diesem Merkmal erfordert, daß die einzelnen Pixel vor der Klassifikation zu zusammenhängenden Objekten zusammengefügt werden müssen. Die Lösung dieses Problems ist allerdings nicht kurzfristig zu erwarten.

7 Literaturverzeichnis

[Akima 1978]

Akima, H., A Method of Bivariate Interpolation and Smooth Surface Fitting for Irregularly Distributed Data Points. *ACM Transactions on Mathematical Software* **4** (2), 148-159, (1978).

[Albertz 1991]

Albertz, J., Grundlagen der Interpretation von Luft- und Satellitenbildern. Eine Einführung in die Fernerkundung, Wiss. Buchges., Darmstadt (1991).

[Anderson et al 1995]

Anderson, G. P., F. X. Kneizys, J. H. Chetwynd, J. Wang, M. L. Hoke, L. S. Rothman, L. M. Kimball, R. A. Mc Clatchey, E. P. Shettle, S. A. Clough, W. O. Gallery, L. W. Abreu, and J. E. A. Selby (1995). FASSCODE / MODTRAN / LOWTRAN : Present / Past / Future. In *Proceedings of the 18th Annual Review Conference on Atmospheric Transmission Models*, June 6-8, (1995).

[Bezdek 1981]

Bezdek, J.C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York (1981).

[Booth & Oldfield 1989]

Booth, D. J., R. B. Oldfield, A comparison of classification algorithms in terms of speed and accuracy after the application of a post-classification modal filter, *International Journal of REMOTE SENSING*, 1989, VOL. 10, NO. 7, pp. 1271-1276.

[Brockhaus 1984]

Der neue Brockhaus, Lexikon und Wörterbuch in 5 Bänden, Brockhaus, Wiesbaden, (1984).

[Burger 1992]

Burger, R., „Einbeziehung von Geoinformation und Geowissen in die Klassifikation von Satellitenbildern mit Hilfe eines evidenztheoretischen Ansatzes“ in Günther/Riekert (Hrsg.), „Wissensbasierte Methoden zur Fernerkundung der Umwelt“, Wichmann Verlag (1992).

[Congalton & Mead 1983]

Congalton, R. C., und R. A. Mead, A Quantitative Method to Test for Consistency and Correctness in Photointerpretation, *Photogrammetric Engineering and Remote Sensing*, Vol. 49, No. 1, January 1983, pp. 69-74.

[Congalton 1991]

Congalton, R. G., A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data, *Remote Sensing of the Environment*, Vol. 37, pp. 35-46, (1991).

[Duda & Hart 1973]

Duda, R. O., Hart, P. E., *Pattern Classification and Scene Analysis*, John Wiley & Sons, New York, (1973).

[Ehlers 1994]

Ehlers, M., Geometric Registration of Airborne Scanner Data Using Multiquadric Interpolation Techniques. In *Proceedings of the First International Airborne Remote Sensing Conference and Exhibition, Strasbourg*, volume II, pages 492-502, ERIM, Ann Arbor, (1994).

[Elachi 1987]

Elachi, C., Introduction to the Physics and Techniques of Remote Sensing, Wiley & Sons, Inc., New York (1987).

[Fischer 1986]

Fischer, G., Lineare Algebra, Friedrich Vieweg & Sohn Verlagsgesellschaft mbH, Braunschweig/Wiesbaden, 1986

[Hepp 1994]

Hepp, T., Erzeugung multispektraler Reflektanzbilder zur automatisierten Bildauswertung, Diplomarbeit, Universität Hamburg, CENSIS-Report -10-94, (1994).

[Hudson & Ramm 1987]

Hudson, W. D., C. W. Ramm, Correct Formulation of the Kappa Coefficient of Agreement, Photogrammetric Engineering and Remote Sensing, Vol. 53, No. 4, April 1987, pp. 421-422.

[Jähne 1993]

Jähne, B., Digitale Bildverarbeitung, Springer-Verlag Berlin Heidelberg (1993).

[Kollewe 1996]

Kollewe, T., Vergleich multispektraler Flugzeugscanneraufnahmen mit Reflektanzmessungen am Boden, Diplomarbeit, Universität Hamburg, CENSIS-Report -17-96, (1996).

[Kollewe et al 1996]

Kollewe, M., Bienlein, J., Kollewe, T., Spitzer, H., Comparison of multispectral airborne scanner reflectance images with ground surface reflectance measurements, Second International Airborne Remote Sensing Conference and Exhibition, San Francisco, California, 24-27 June 1996.

[Kraus & Schneider 1988]

Kraus, K. und Schneider, W., Fernerkundung, Band 1: Physikalische Grundlagen und Aufnahmetechniken, Ferd. Dummlers Verlag, Bonn (1988).

[Meister 1996]

Meister, G., Messung der spektralen Reflexionsfunktion (BRDF) ausgewählter Oberflächen bei natürlicher Beleuchtung, Diplomarbeit, Universität Hamburg, CENSIS-Report-18-96, (1996)

[Neumann 1996]

Neumann, B., Untersuchung von Strukturmaßen ausgewählter Landschaftselemente auf multispektralen Luftbildern, Diplomarbeit, Universität Hamburg, CENSIS-Report -22-96, (1996).

[Ortiz et al 1997]

Ortiz, M. J., A. R. Formaggio and J. C. N. Epiphanyo, „Classification of croplands through integration of remote sensing, GIS and historical database“, International Journal of REMOTE SENSING, 1997, VOL. 18, NO. 1, p. 95-105

[Palubinskas 1996]

Palubinskas, G., Classification of Agricultural Crop Types Using SPOT HRV and ERS-1 SAR Data in the Test Site Ostalb (South Germany), Zeitschrift für Photogrammetrie und Fernerkundung, S. 155-162, Mai, 1996

[Richards 1993]

Richards, J. A., Remote Sensing Digital Image Analysis, Springer-Verlag, Berlin, New York (1993).

7 Literaturverzeichnis

[Richter 1992]

Richter, R., Model SENSAT-4: Sensor - Atmosphere - Target, DLR -IB 552-01/92, Deutsche Forschungsanstalt für Luft- und Raumfahrt e. V., 82234 Weßling, (1992).

[Rosenfield & Fitzpatrick-Lins 1986]

Rosenfield, G. H., K. Fitzpatrick-Lins, A Coefficient of Agreement as a Measure of Thematic Classification Accuracy, *Photogrammetric Engineering and Remote Sensing*, Vol. 52, No. 2, February 1986, pp. 223-227

[Rothkirch 1997]

Rothkirch, A., Feldmessung der spektralen Reflexionsfunktion (BRDF) eines Hausdaches, Diplomarbeit, II. Institut für Experimentalphysik, Universität Hamburg, (1997).

[Sabins 1978]

Sabins, F. F., *Remote Sensing*, Freeman and Company (1978).

[Sachs 1992]

Sachs, L., *Angewandte Statistik*, Springer-Verlag, Berlin, Heidelberg, (1992).

[Speck 1997]

Speck, A., Änderungsdetektion auf multispektralen Luftbildern durch Hauptachsentransformationen im bitemporalen Merkmalsraum, Diplomarbeit, Universität Hamburg, CENSIS-Report-27-97

[Wiemker 1996]

Wiemker, R., Registration of Airborne Scanner Imagery Using Akima Local Quintic Polynomial Interpolation, Second International Airborne Remote Sensing Conference and Exhibition, San Francisco, California, 24-27 June 1996.

[Wilson 1992]

Wilson, J. D., A comparison of procedures for classifying remotely-sensed data using simulated data sets, *International Journal of REMOTE SENSING*, 1992, VOL. 13, NO. 2, 365-386

[Zang et al 1994]

Zhang, W., J. Albertz and Z. Li, Rectification of Airborne Line-Scanner Imagery Utilizing Flight Parameters. In *Proceedings of the First International Airborne Remote Sensing Conference and Exhibition, Strasbourg*, volume II, pages 492-502, ERIM, Ann Arbor, 1994

Danksagung

Bei Prof. Hartwig Spitzer und Prof. Johann Bienlein bedanke ich mich für das interessante Thema meiner Diplomarbeit. Ihre konstruktive Kritik und intensive Betreuung waren mir eine große Hilfe bei der Fertigstellung dieser Arbeit.

Besonders bedanken möchte ich mich auch bei Rafael Wiemker, der mit zahlreichen Anregungen und Hilfestellungen zum Gelingen meiner Arbeit beigetragen hat.

Bei den Mitgliedern meiner Arbeitsgruppe bedanke ich mich für die gute Zusammenarbeit und die anregenden Diskussionen.

Mein Dank gilt auch den Mitarbeitern der Gruppe KOGS der Universität Hamburg für die Betreuung der verwendeten Computersysteme.

Außerdem danke ich den Mitarbeitern der DLR und den früheren Diplomanden Thomas Hepp und Thomas Kollwe für die Aufbereitung und Bereitstellung des verwendeten Bildmaterials.

Und schließlich möchte ich auch noch den Mitgliedern meiner Familie für die finanzielle und mentale Unterstützung danken.

8 Anhang

In Kapitel 4.4 wurde erwähnt, daß für jede Stichprobe die Koordinaten des Polygons, das sie umschließt, in einer Computerdatei (Dateiformat: ASCII) gespeichert wurden. In dem Kasten (siehe unten) ist als Beispiel ein Auszug (die ersten beiden Stichproben) aus der Datei „J94.markierung_flughafen.serie.asc“ enthalten. Diese Datei enthält alle Daten, die für das Auffinden der Stichproben der Klasse „Markierung(Flughafen)“ notwendig sind.

Hinter der Bezeichnung „Flugstreifen“ steht der Name der TIFF-Datei¹⁹, aus der das Polygon ausgeschnitten wurde. Mit diesem Namen und den aufgelisteten „Polygonkoordinaten“ konnte man die Pixel der betreffenden Stichprobe vom Computer aus dem Bildmaterial heraussuchen lassen. Allerdings war das Laden einer kompletten Bilddatei sehr zeitaufwendig. Aus diesem Grund wurde, wie bereits in Kap. 4.4 erwähnt, aus den Bilddateien quadratische Bildausschnitte mit einer Größe von 50 x 50 Pixel ausgewählt. Für das Auffinden der Stichprobenpixel aus diesen Ausschnitten werden die übrigen Angaben benötigt („Tiffdateistamm“, „Rahmenoffsets“ und „Rahmennummer“).

Während der Ausarbeitung der Diplomarbeit wurde ein „Stichprobenkatalog“ angefertigt. Die Ausdrücke in diesem Katalog sind mit den Ausdrücken im Anhang dieser Arbeit vergleichbar (siehe Abb. A - 8 bis Abb. A - 27). Die Tabelle 55 gibt Auskunft darüber, unter welcher Katalognummer die Stichproben (des Anhangs) im „Stichprobenkatalog“ zu finden sind. Der Tabelle 54 ist zu entnehmen, wo die Stichproben, die in Kap. 4.5 zum Training verwendet wurden, im „Stichprobenkatalog“ zu finden sind. Zusätzlich wurden alle wichtigen Dateien auf einem Computer-Tape archiviert.

```

Flugstreifen : nuernberg_1994/300m/reflektanz/nuer07.tif-adj
Tiffdateistamm : J94_b.nuer07.0-999
  Rahmenoffsets :   68   189
  Rahmennummer :    1
Polygonkoordinaten :
  0. Punkt :   103.00   224.00
  1. Punkt :   103.00   198.00
  2. Punkt :   105.00   198.00
  3. Punkt :   105.00   224.00
  Letzter Punkt :   103.00   224.00
Beschreibung :
Flugstreifen : nuernberg_1994/300m/reflektanz/nuer07.tif-adj
Tiffdateistamm : J94_b.nuer07.0-999
  Rahmenoffsets :   70    3
  Rahmennummer :    0
Polygonkoordinaten :
  0. Punkt :    83.00   39.00
  1. Punkt :    84.00   13.00
  2. Punkt :    86.00   13.00
  3. Punkt :    85.00   39.00
  Letzter Punkt :    83.00   39.00
Beschreibung :

```

Auszug aus der Computerdatei: „J94.markierung_flughafen.serie.asc“

¹⁹ Gemeint sind hier die Bilddateien, die nach dem in Kapitel 3.1 beschriebenen Verfahren (von T. Hepp und T. Kollewe) erzeugt wurden.

Abb. A - 1: *Flugstreifen T1 (links), T2 (mitte) und T3 (rechts) bis Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).*

Abb. A - 2: Flugstreifen T1 (links), T2 (mitte) und T3 (rechts) ab Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).

Abb. A - 3: Flugstreifen T4 (links), T5 (mitte) und T6 (rechts) bis Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).

Abb. A - 4: Flugstreifen T4 (links), T5 (mitte) und T6 (rechts) ab Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).

Abb. A - 5: *Flugstreifen T7 (links), T8 (mitte) und T10 (rechts) bis Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).*

Abb. A - 6: Flugstreifen T7 (links), T8 (mitte) und T10 (rechts) ab Scanzeile 4000. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).

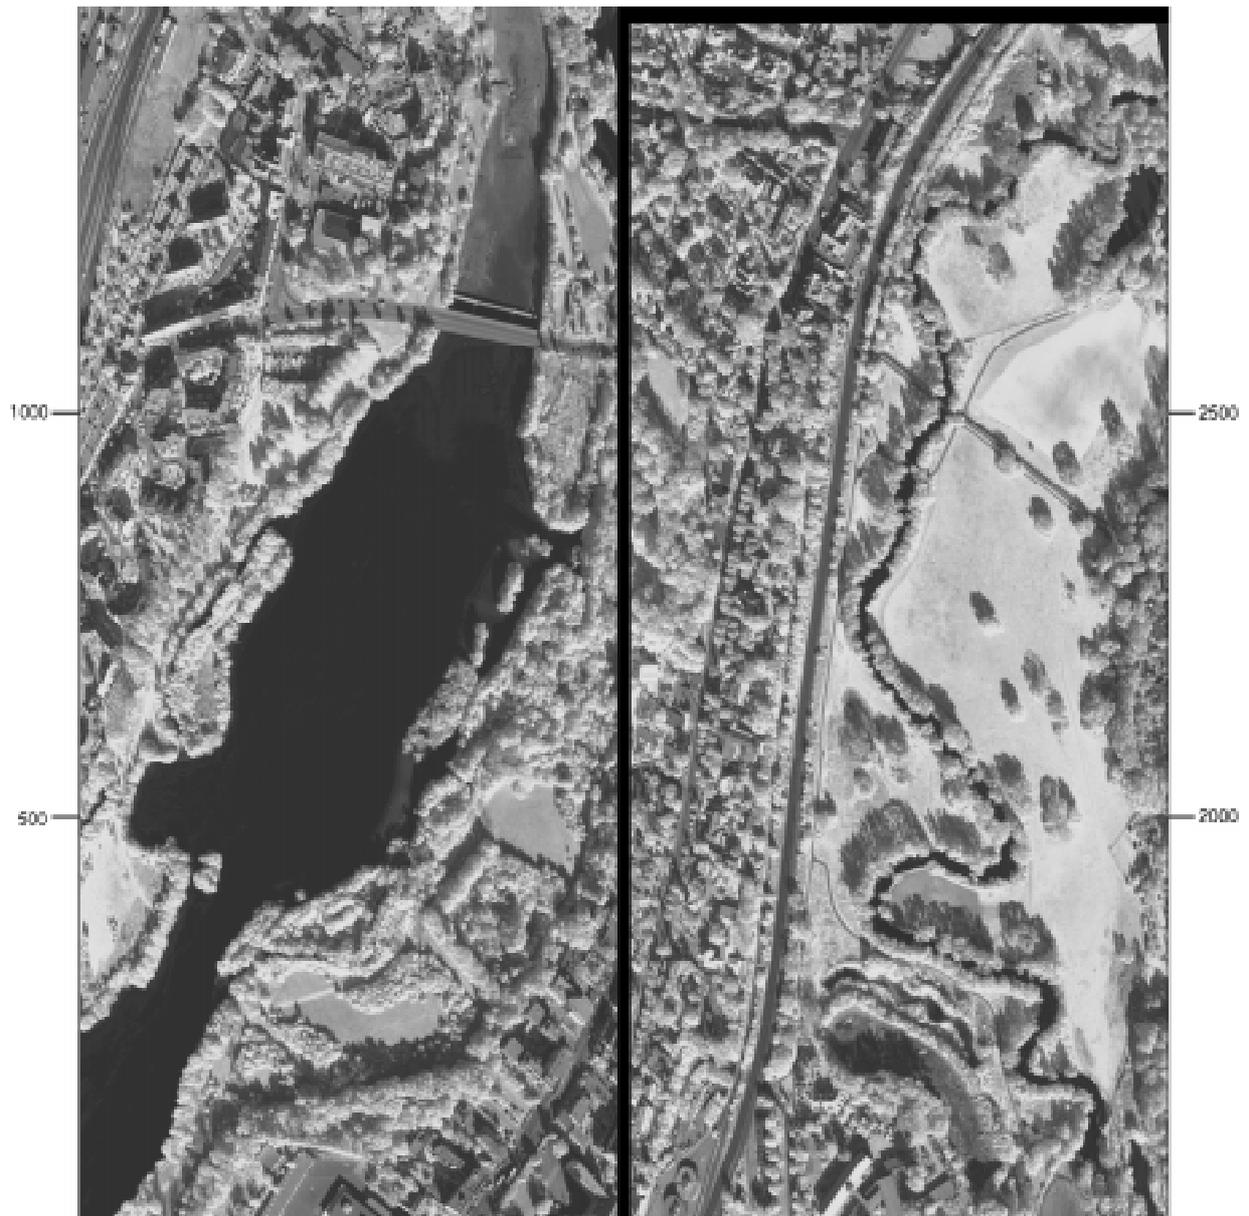


Abb. A - 7: Flugstreifen T9. Die Bildausschnitte sind noch panoramaverzerrt. Sie zeigen eine kontrastverstärkte Darstellung des Spektralkanals Nr.7 (0,76 - 0,90 μm).

Klassenbezeichnung	Nr.	Klassenbezeichnung	Nr.	Klassenbezeichnung	Nr.
Flachdach	99	Strasse(bel)	0	Wiese(sch)	10
Spitzdach(bel)	53	Strasse(sch)	11	Gewaesser	4
Spitzdach(sch)	50	Eisenbahn	6	Baum	28
Fassade	8	Erdreich	0	Fahrzeuge	11
Bürgersteig	1	Felder(bew)	16	Markierung(Flughafen)	3
Parkplatz	7	Wiese(bel)	7	Vorfeld(Flughafen)	0

Tabelle 54: Auflistung der Katalognummern, unter denen die in Kap. 4.5 zum Training verwendeten Stichproben im Stichprobenkatalog zu finden sind (beachte Seite 109)

Bezeichnung der Stichprobe	Kat.-Nr.	Anzahl der Pixel	x-Koordinate des Polygons	Scan-Winkel [°]	Bezeichnung der Stichprobe	Kat.-Nr.	Anzahl der Pixel	x-Koordinate des Polygons	Scan-Winkel [°]
Flachdach 1	3	478	438	9,6	Strasse(bel) 3	42	241	383	3,0
Flachdach 2	8	244	266	-11,0	Strasse(bel) 4	46	108	252	-12,7
Flachdach 3	11	778	55	-36,4	Strasse(bel) 5	55	186	349	-1,1
Flachdach 4	12	1314	629	32,5	Strasse(sch) 1	1	37	70	-34,6
Flachdach 5	18	342	498	16,8	Strasse(sch) 2	6	57	174	-22,1
Flachdach 6	26	546	311	-5,6	Strasse(sch) 3	15	12	265	-11,2
Flachdach 7	35	473	472	13,7	Strasse(sch) 4	18	56	181	-21,2
Flachdach 8	42	461	579	26,5	Strasse(sch) 5	30	170	611	30,4
Flachdach 9	53	1085	452	11,3	Eisenbahn 1	0	170	126	-27,8
Flachdach 10	54	1136	557	23,9	Eisenbahn 2	1	177	230	-15,4
Flachdach 11	55	196	547	22,7	Eisenbahn 3	2	262	500	17,0
Flachdach 12	62	878	201	-18,8	Eisenbahn 4	5	212	630	32,6
Flachdach 13	63	631	308	-6,0	Erdreich 1	1	1892	101	-30,8
Flachdach 14	65	328	559	24,1	Erdreich 2	6	1337	623	31,8
Flachdach 15	66	593	615	30,8	Erdreich 3	11	1579	217	-16,9
Flachdach 16	80	247	596	28,6	Erdreich 4	14	1624	338	-2,4
Flachdach 17	86	907	162	-23,5	Erdreich 5	25	1017	239	-14,3
Flachdach 18	88	876	449	10,9	Felder(bew) 1	3	357	524	19,9
Flachdach 19	114	1251	596	28,6	Felder(bew) 2	4	359	57	-36,1
Flachdach 20	116	1320	292	-7,9	Felder(bew) 3	8	380	211	-17,6
Spitzdach(bel) 1	11	74	143	-25,8	Felder(bew) 4	9	465	380	2,6
Spitzdach(bel) 2	15	144	143	-25,8	Felder(bew) 5	10	576	287	-8,5
Spitzdach(bel) 3	33	70	183	-21,0	Felder(bew) 6	12	870	442	10,1
Spitzdach(bel) 4	35	102	385	3,2	Felder(bew) 7	14	486	491	16,0
Spitzdach(bel) 5	36	62	441	10,0	Felder(bew) 8	21	351	291	-8,0
Spitzdach(bel) 6	39	210	609	30,1	Felder(bew) 9	25	653	243	-13,8
Spitzdach(bel) 7	70	100	320	-4,6	Felder(bew) 10	31	869	181	-21,2
Spitzdach(bel) 8	75	133	357	-0,1	Wiese(bel) 1	6	1199	606	29,8
Spitzdach(bel) 9	84	351	305	-6,4	Wiese(bel) 2	8	453	480	14,6
Spitzdach(bel) 10	89	262	128	-27,6	Wiese(bel) 3	19	1370	205	-18,4
Spitzdach(bel) 11	91	359	553	23,4	Wiese(bel) 4	22	785	297	-7,3
Spitzdach(bel) 12	95	76	226	-15,8	Wiese(bel) 5	29	1409	489	15,7
Spitzdach(sch) 1	5	144	478	14,4	Wiese(sch) 1	6	419	120	-28,6
Spitzdach(sch) 2	8	90	340	-2,2	Wiese(sch) 2	11	230	460	12,2
Spitzdach(sch) 3	9	246	327	-3,7	Wiese(sch) 3	12	60	244	-13,7
Spitzdach(sch) 4	15	99	571	25,6	Wiese(sch) 4	23	84	561	24,4
Spitzdach(sch) 5	29	82	333	-3,0	Wiese(sch) 5	29	250	633	33,0
Spitzdach(sch) 6	43	150	223	-16,2	Baum 1	1	157	408	6,0
Spitzdach(sch) 7	51	146	256	-12,2	Baum 2	2	618	493	16,2
Spitzdach(sch) 8	55	148	321	-4,4	Baum 3	3	190	555	23,6
Fassade 1	12	177	36	-38,6	Baum 4	8	96	159	-23,9
Fassade 2	28	29	581	26,8	Baum 5	19	428	542	22,1
Fassade 3	47	53	577	26,3	Baum 6	23	87	180	-21,4
Fassade 4	49	41	552	23,3	Baum 7	25	83	24	-40,1
Fassade 5	52	48	178	-21,6	Baum 8	26	205	317	-4,9
Fassade 6	53	61	65	-35,2	Baum 9	29	129	580	26,6
Buergersteig 1	22	43	506	17,8	Baum 10	38	204	137	-26,5
Buergersteig 2	23	25	338	-2,4	Baum 11	42	236	340	-2,2
Buergersteig 3	25	22	674	37,9	Baum 12	46	262	93	-31,8
Buergersteig 4	36	41	577	26,3	Gewaesser 1	8	1117	627	32,3
Buergersteig 5	40	50	401	5,2	Gewaesser 2	11	1376	438	9,6
Buergersteig 6	43	122	478	14,4	Gewaesser 3	12	549	405	5,6
Parkplatz 1	1	679	282	-9,1	Gewaesser 4	18	927	363	0,6
Parkplatz 2	5	948	204	-18,5	Gewaesser 5	19	427	357	-0,1
Parkplatz 3	6	552	516	19,0	Gewaesser 6	21	380	250	-13,0
Parkplatz 4	11	175	356	-0,2	Gewaesser 7	22	205	520	19,4
Parkplatz 5	16	332	110	-29,8	Gewaesser 8	23	1828	536	21,4
Parkplatz 6	20	769	458	12,0	Fahrzeuge 1	13	235	661	36,4
Strasse(bel) 1	16	190	558	24,0	Markierung(Flughafen) 1	4	33	89	-32,3
Strasse(bel) 2	31	332	114	-29,3	Vorfeld(Flughafen) 1	4	699	44	-37,7

Tabelle 55: Daten über die Stichproben im Anhang. Die Katalognummer (Kat.-Nr.) gibt an, wo die Stichprobe im „Stichprobenkatalog“ zu finden ist (beachte Seite 109). Der Scan-Winkel läßt sich aus der „x-Koordinate der Fläche“²⁰ mit Hilfe der Formel $(x-716 / 2) / 358 * 42,96^\circ$ berechnen.

²⁰ Ein Polygon besteht aus mehreren Pixeln. Um nur einen Scan-Winkel pro Polygon zu erhalten, wurden die x-Koordinaten der Pixel des entsprechenden Polygons gemittelt. Die „x-Richtung“ entspricht hierbei der Schwenkrichtung des „Scan-Strahls“ (vergleiche Abb. 13).

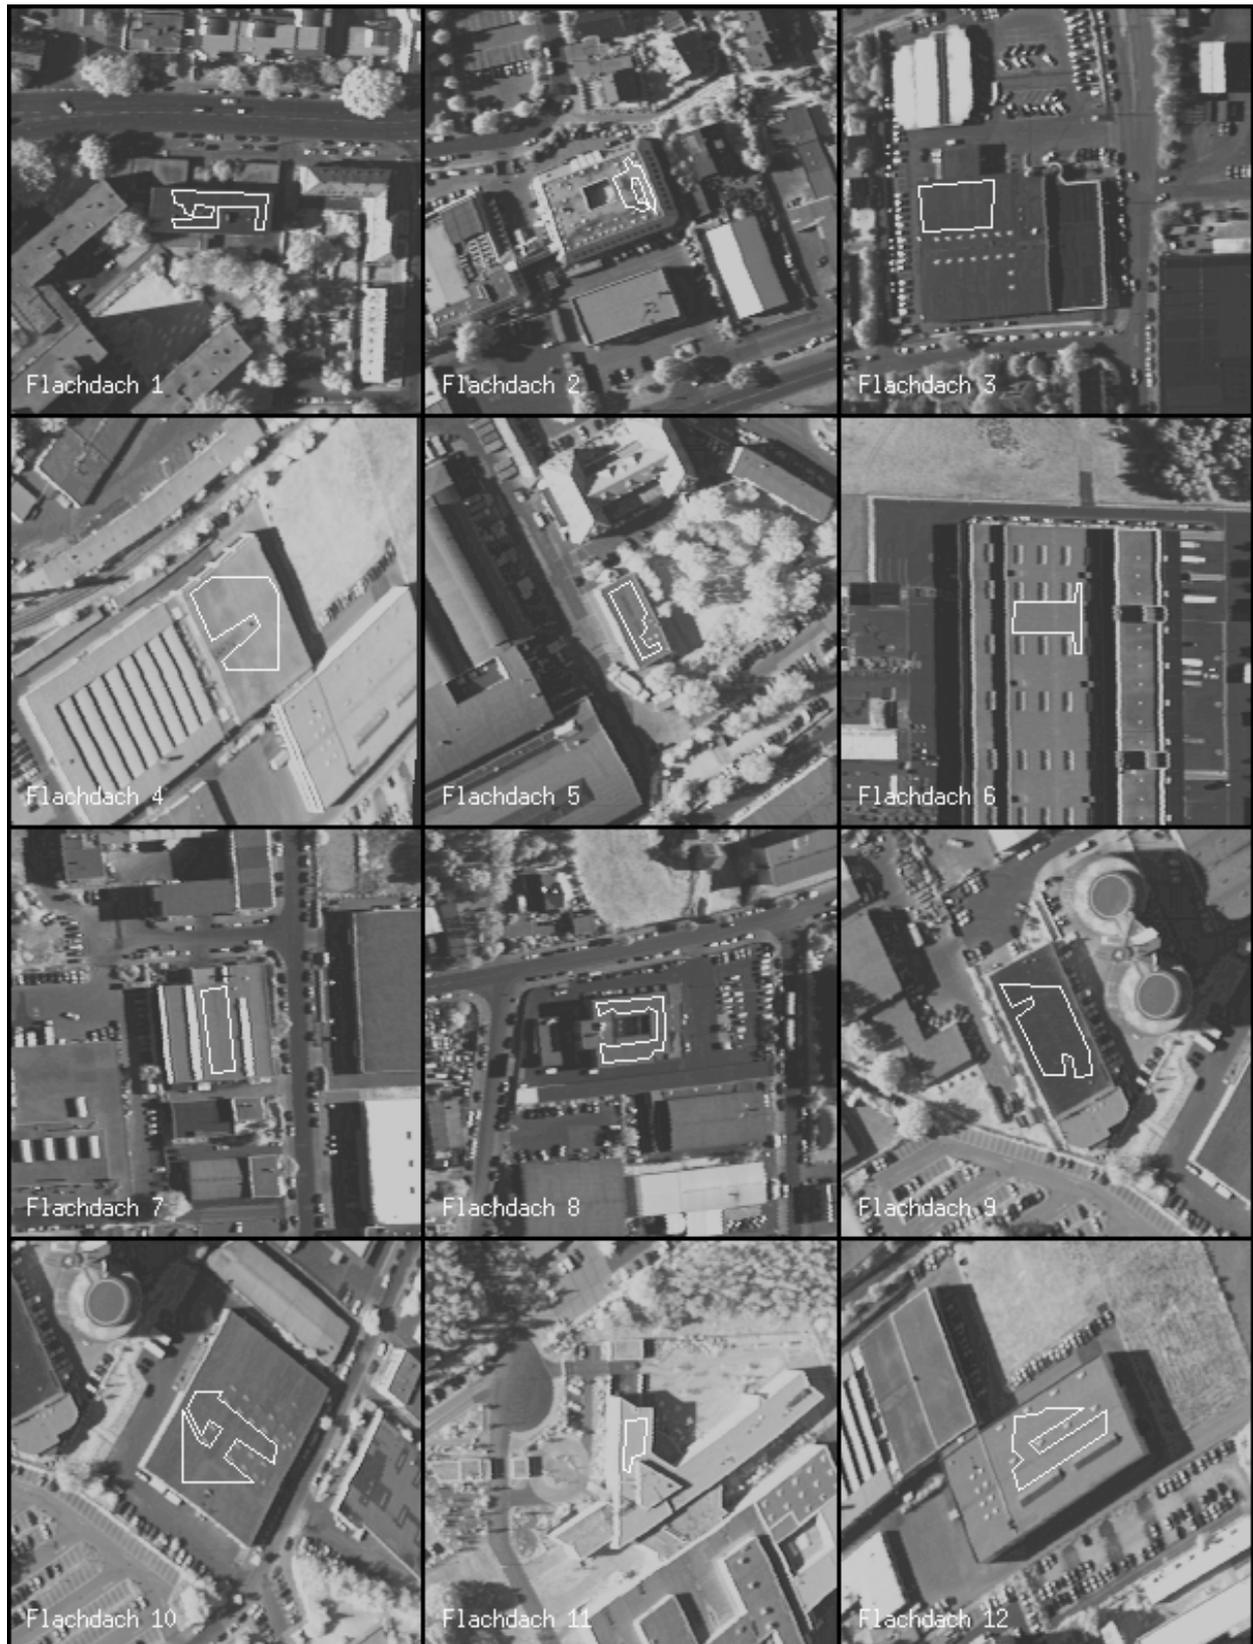


Abb. A - 8: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

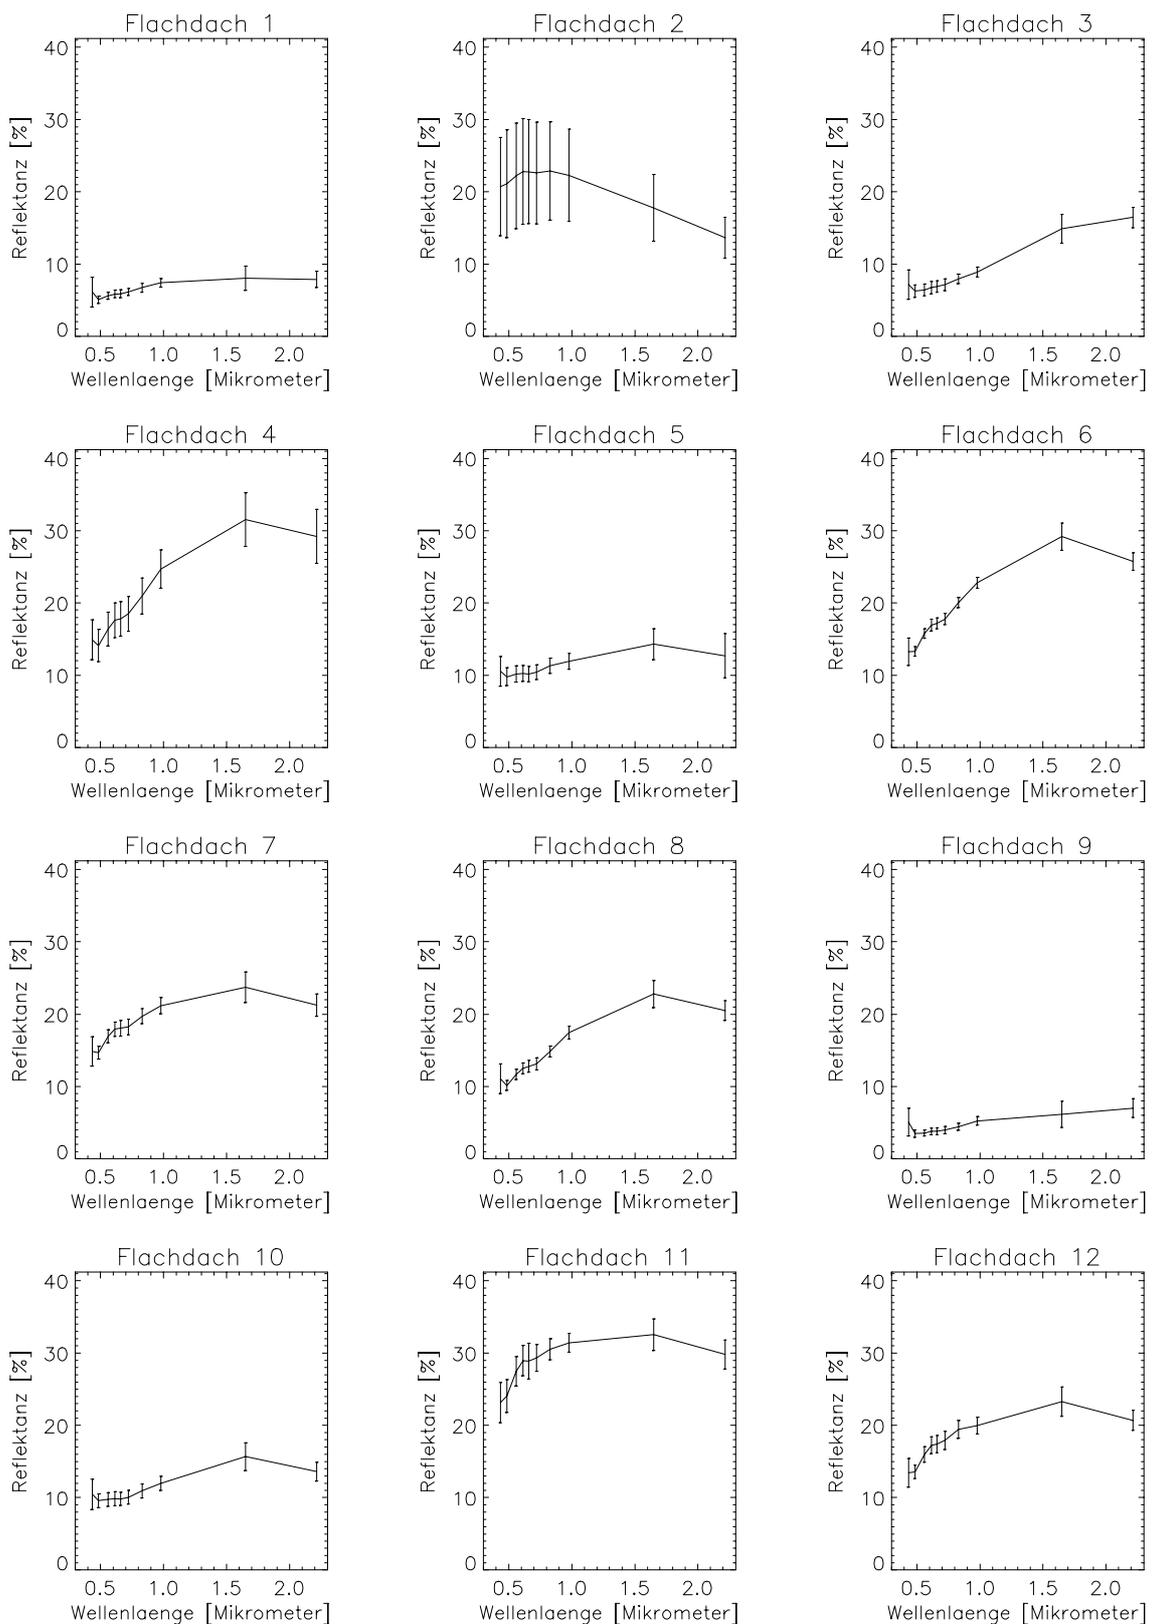


Abb. A - 9: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 10: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

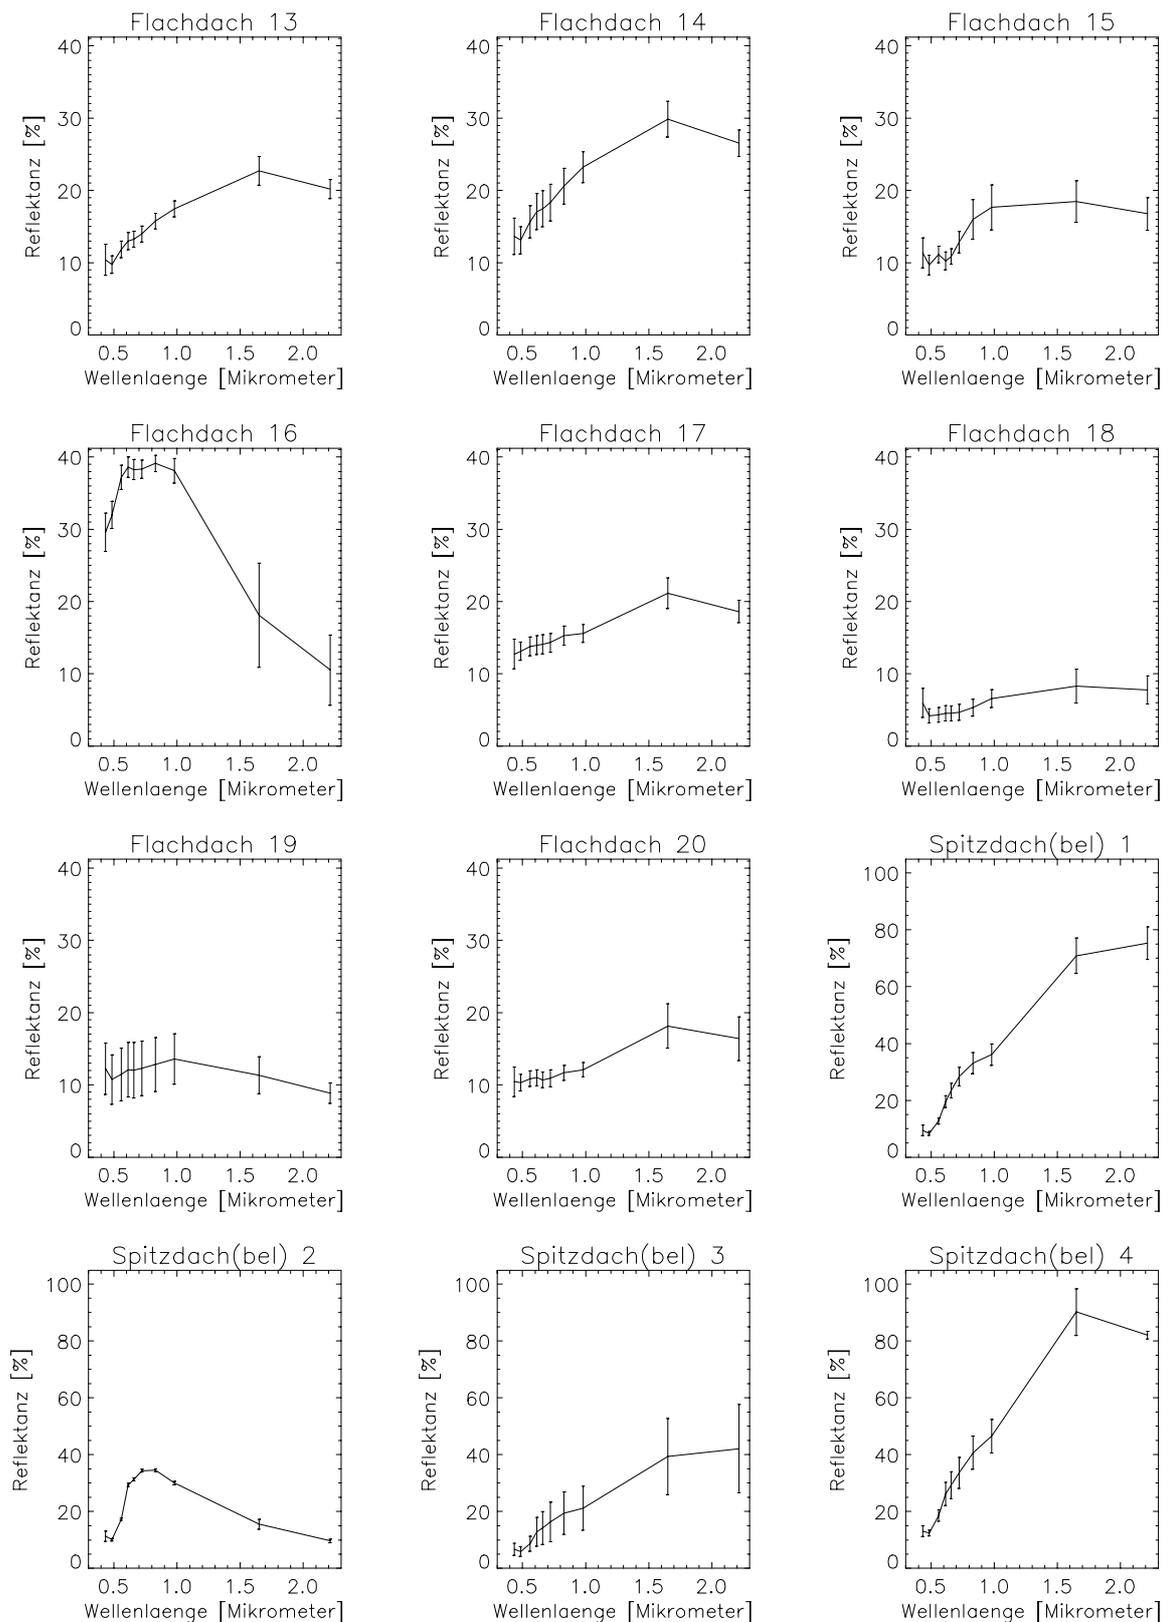


Abb. A - 11: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 12: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

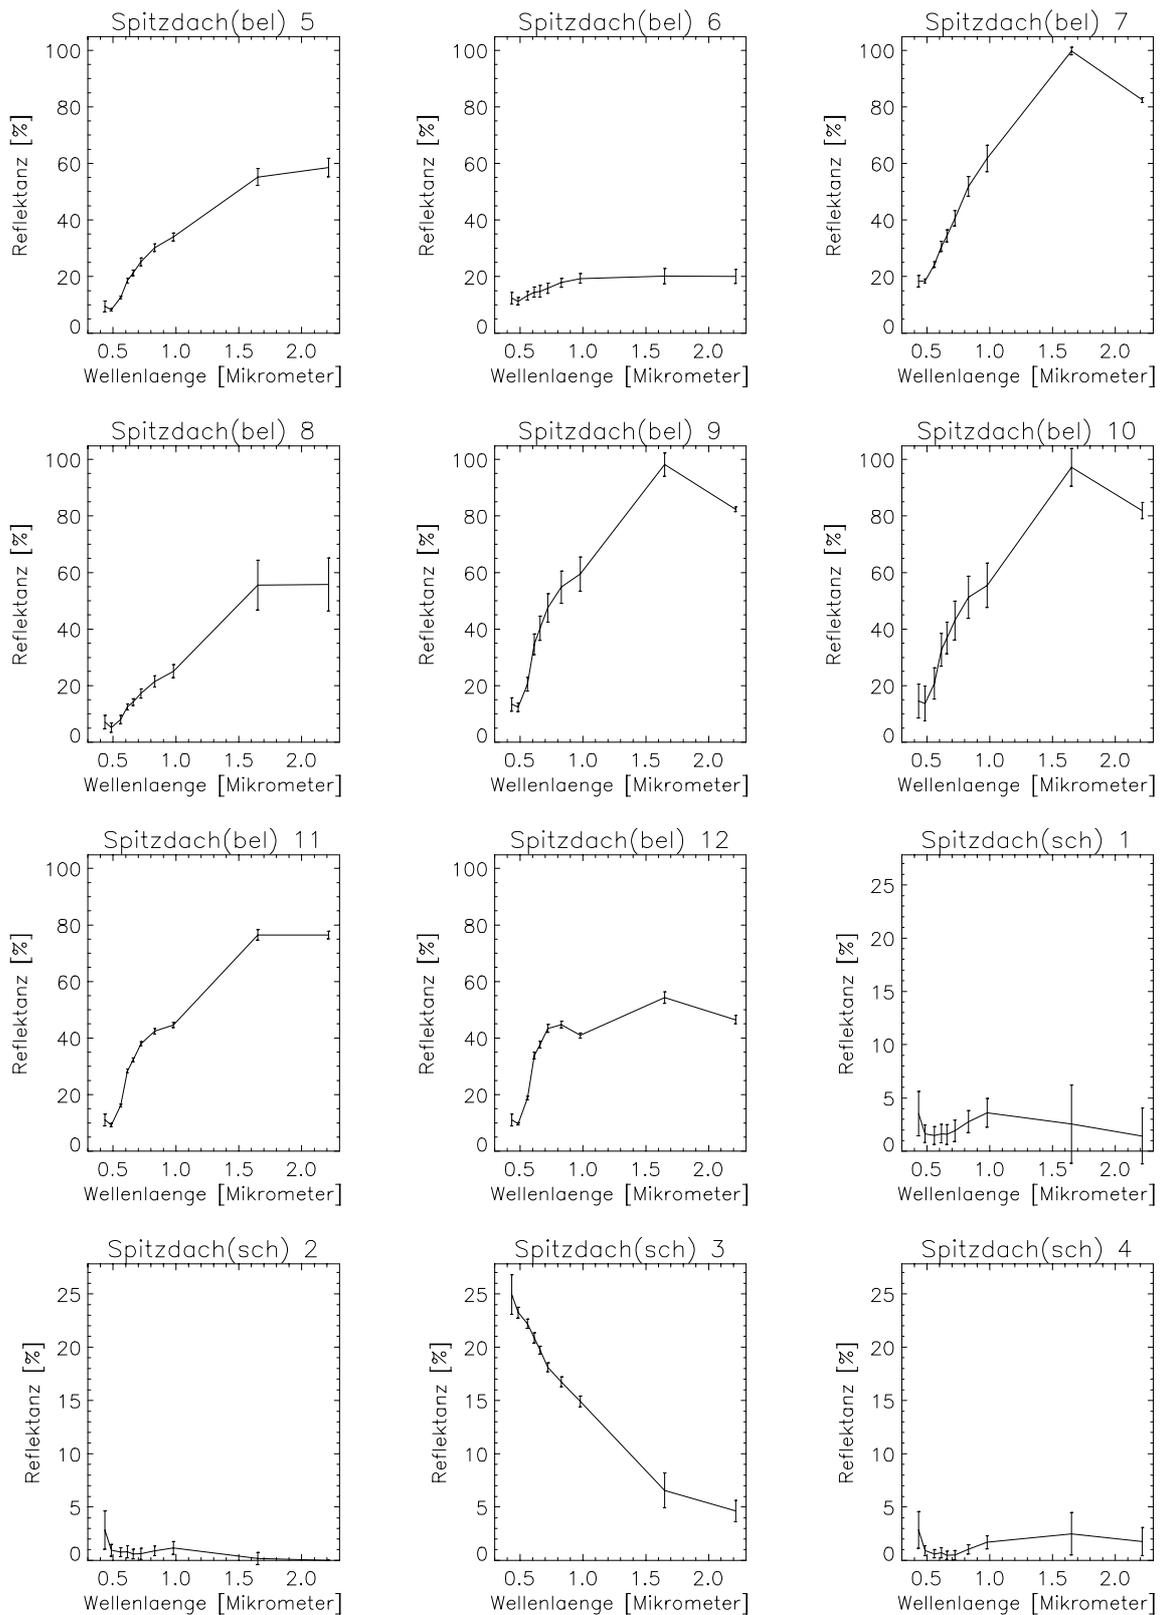


Abb. A - 13: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 14: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

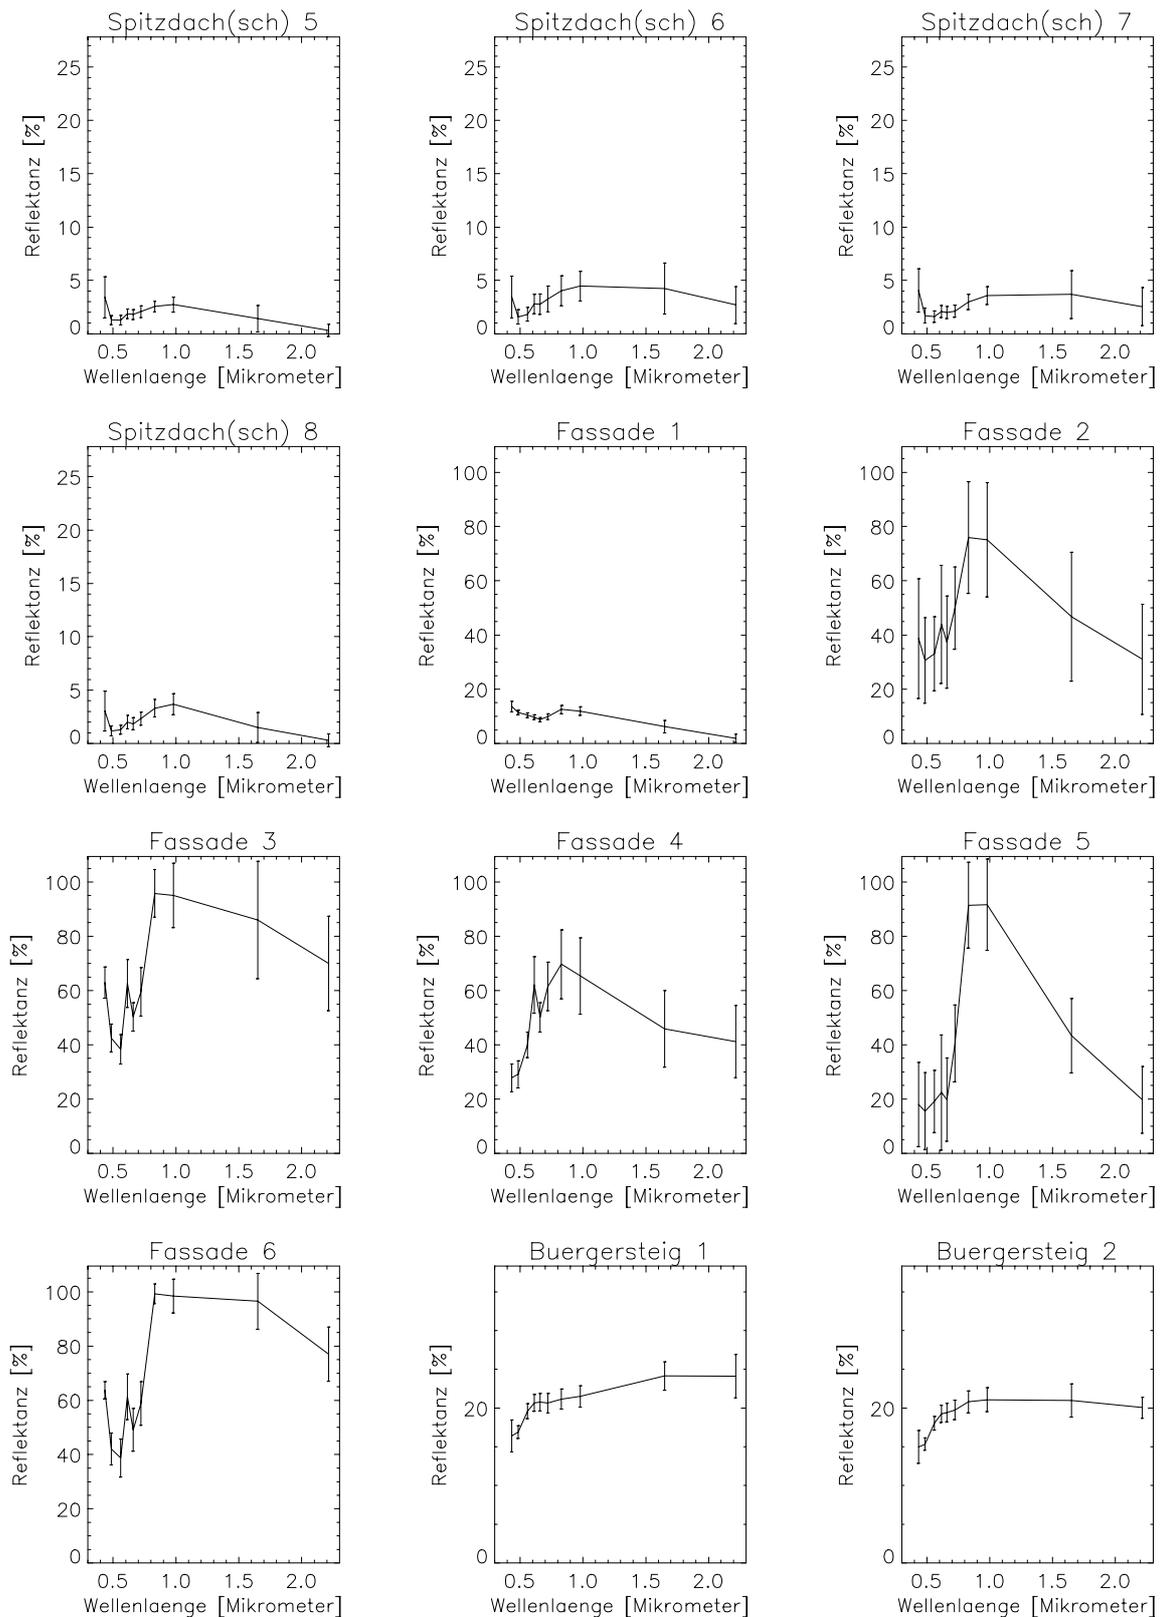


Abb. A - 15: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 16: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

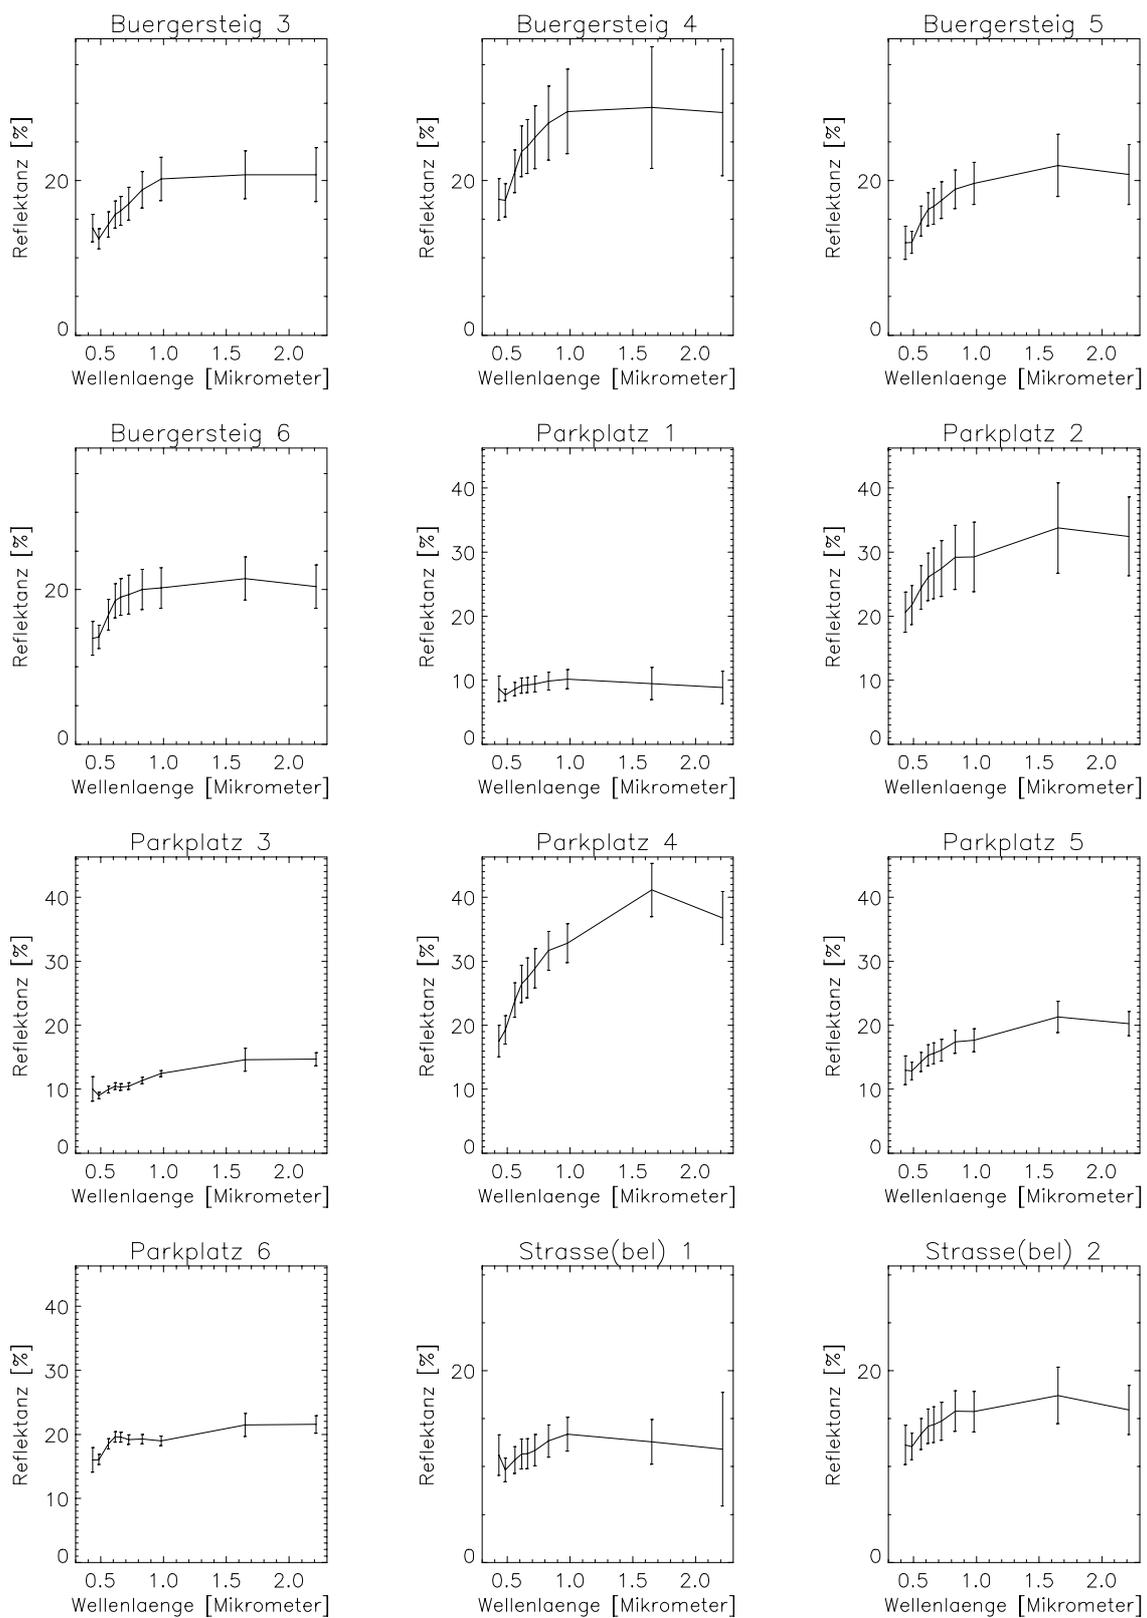


Abb. A - 17: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 18: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

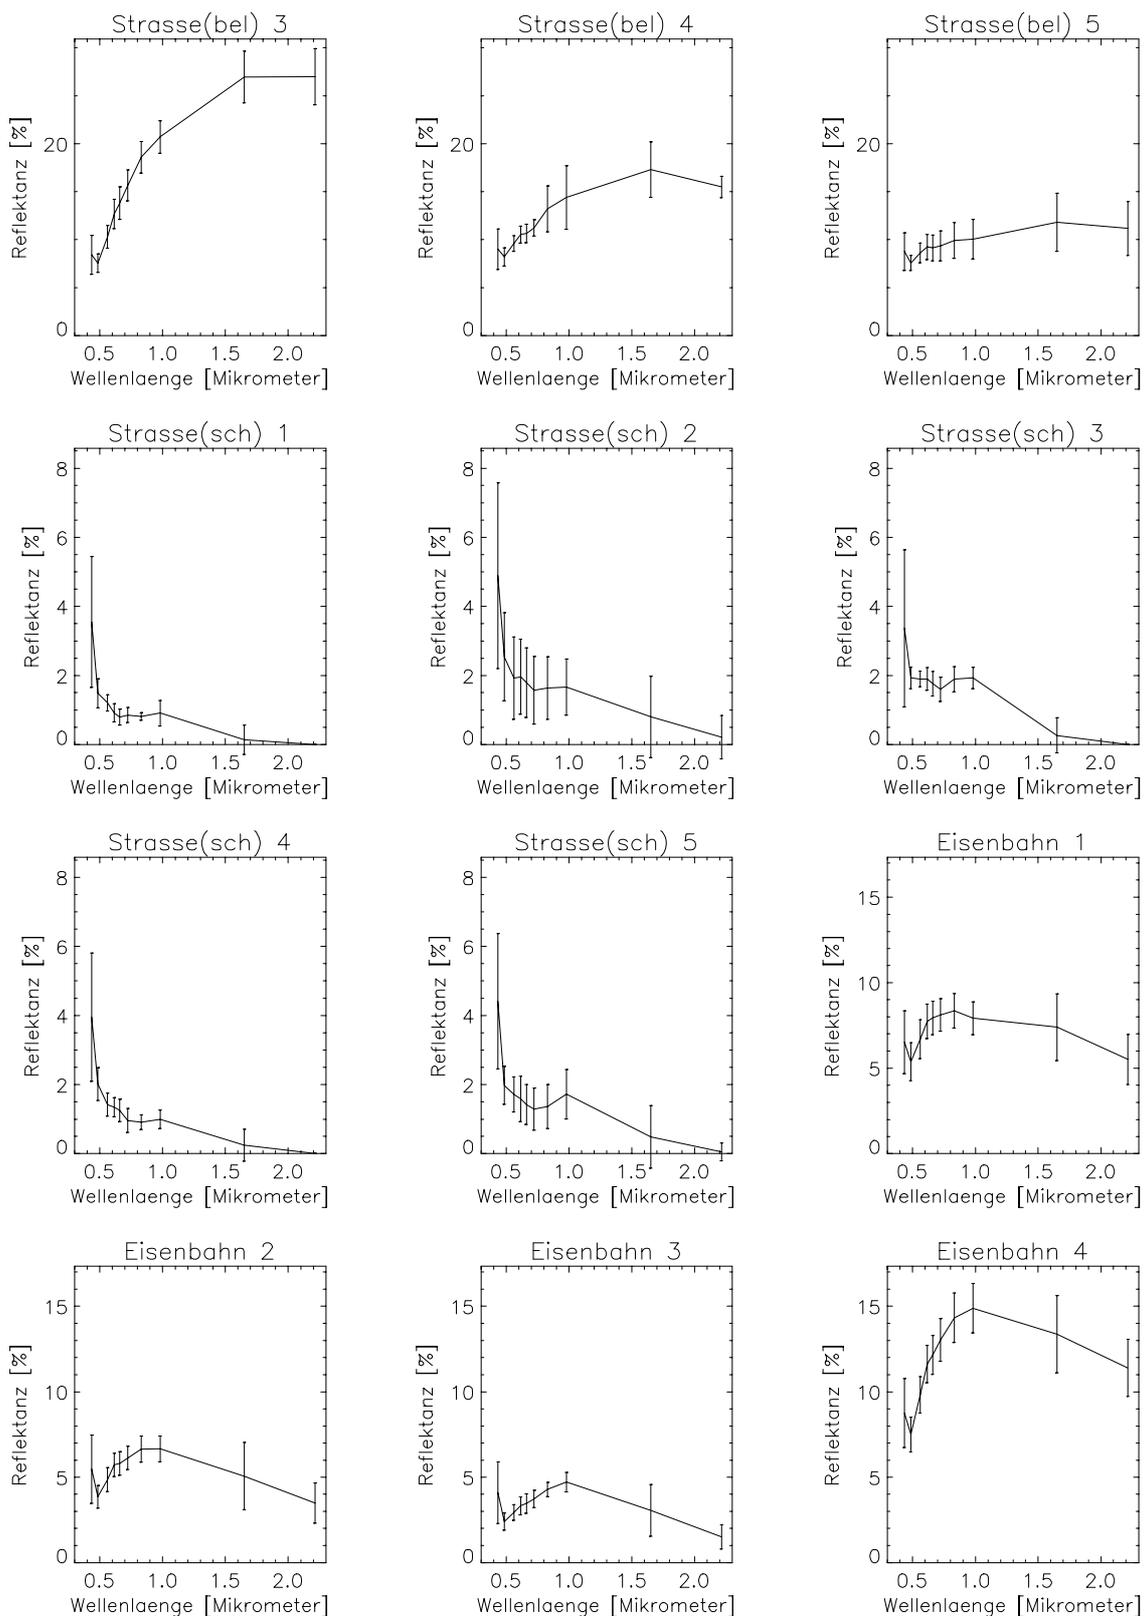


Abb. A - 19: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.

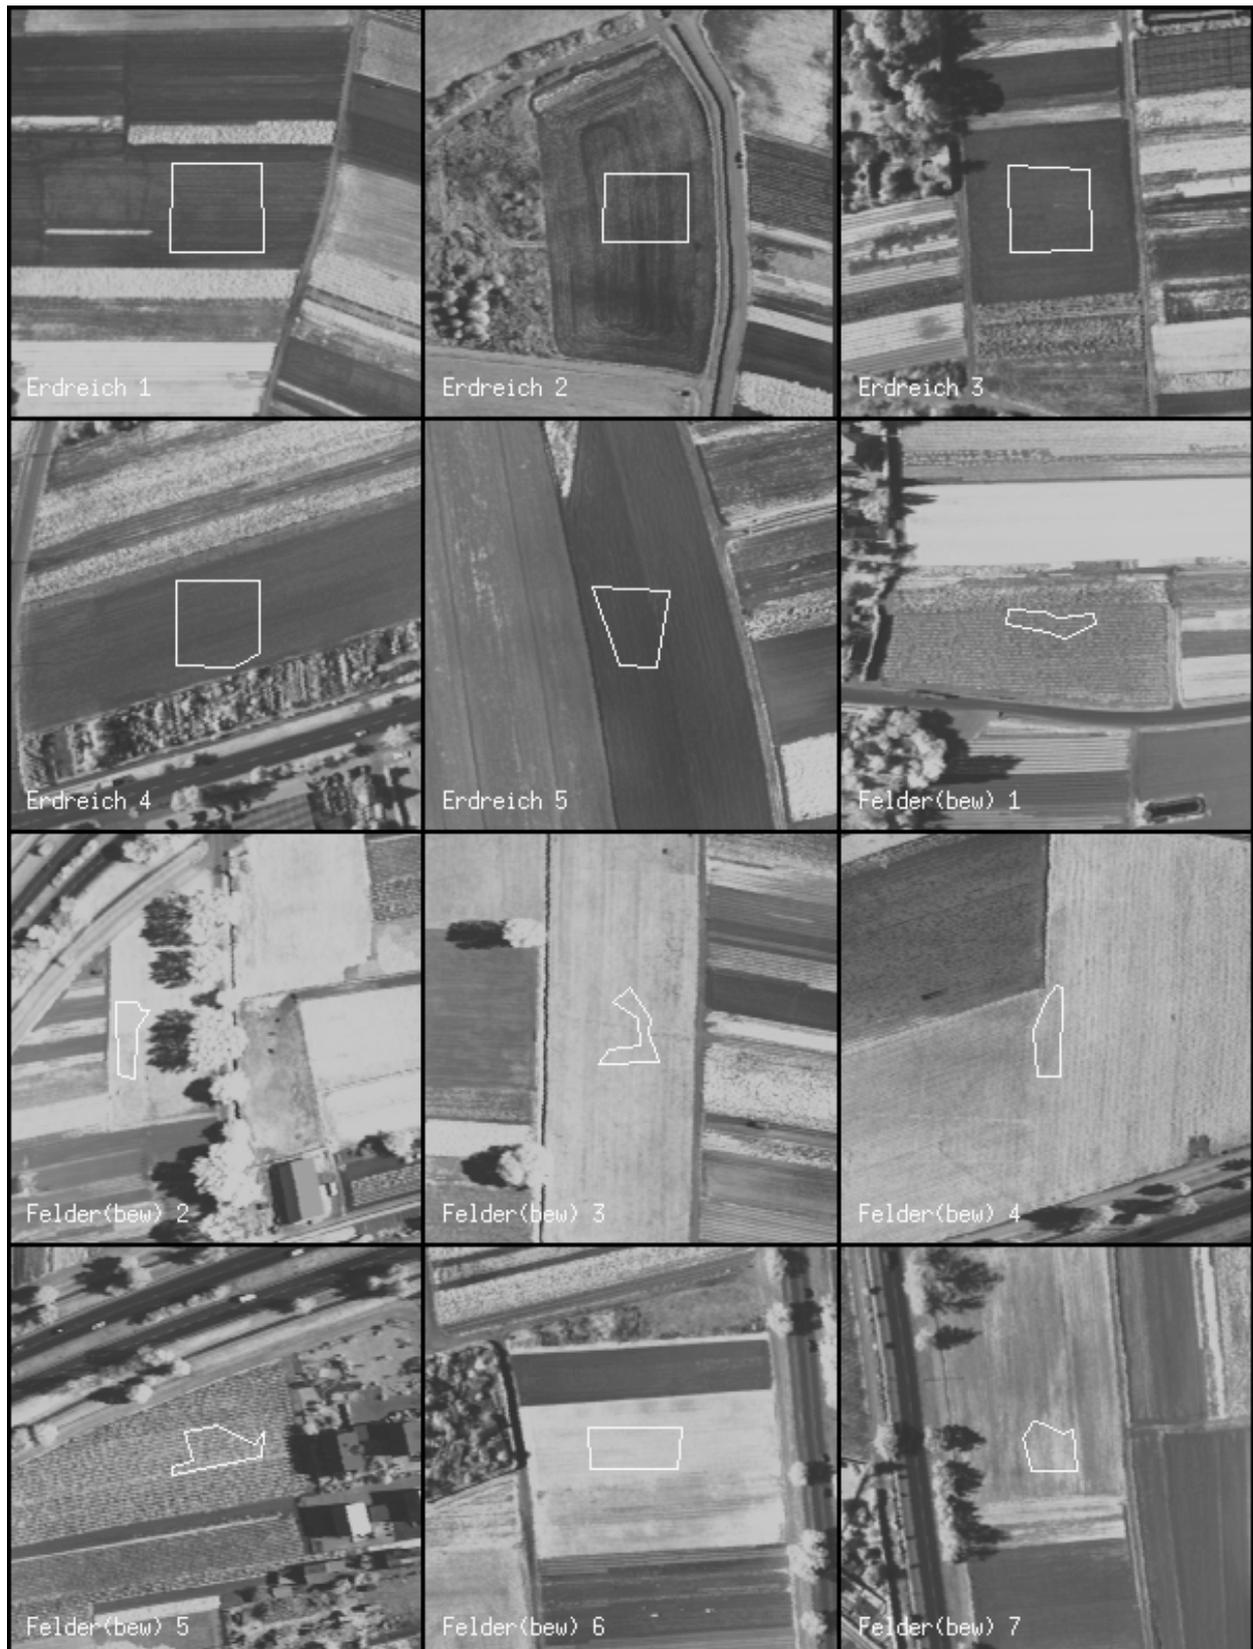


Abb. A - 20: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

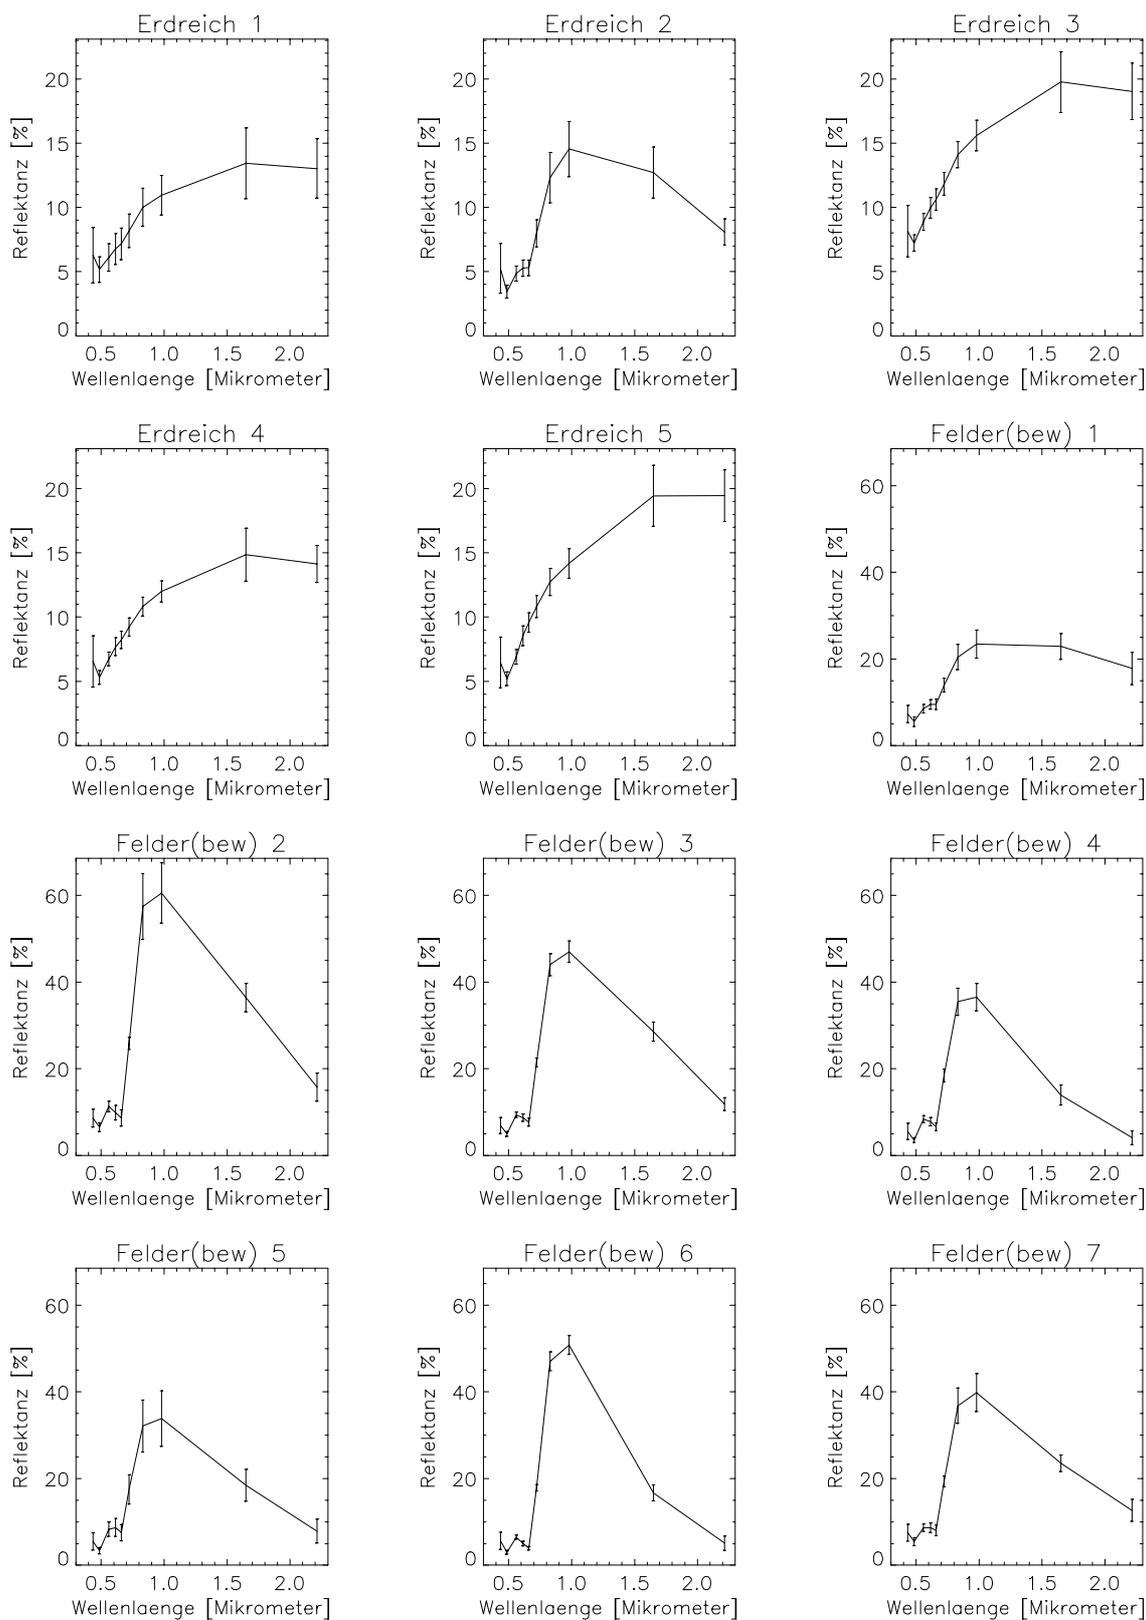


Abb. A - 21: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.



Abb. A - 22: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

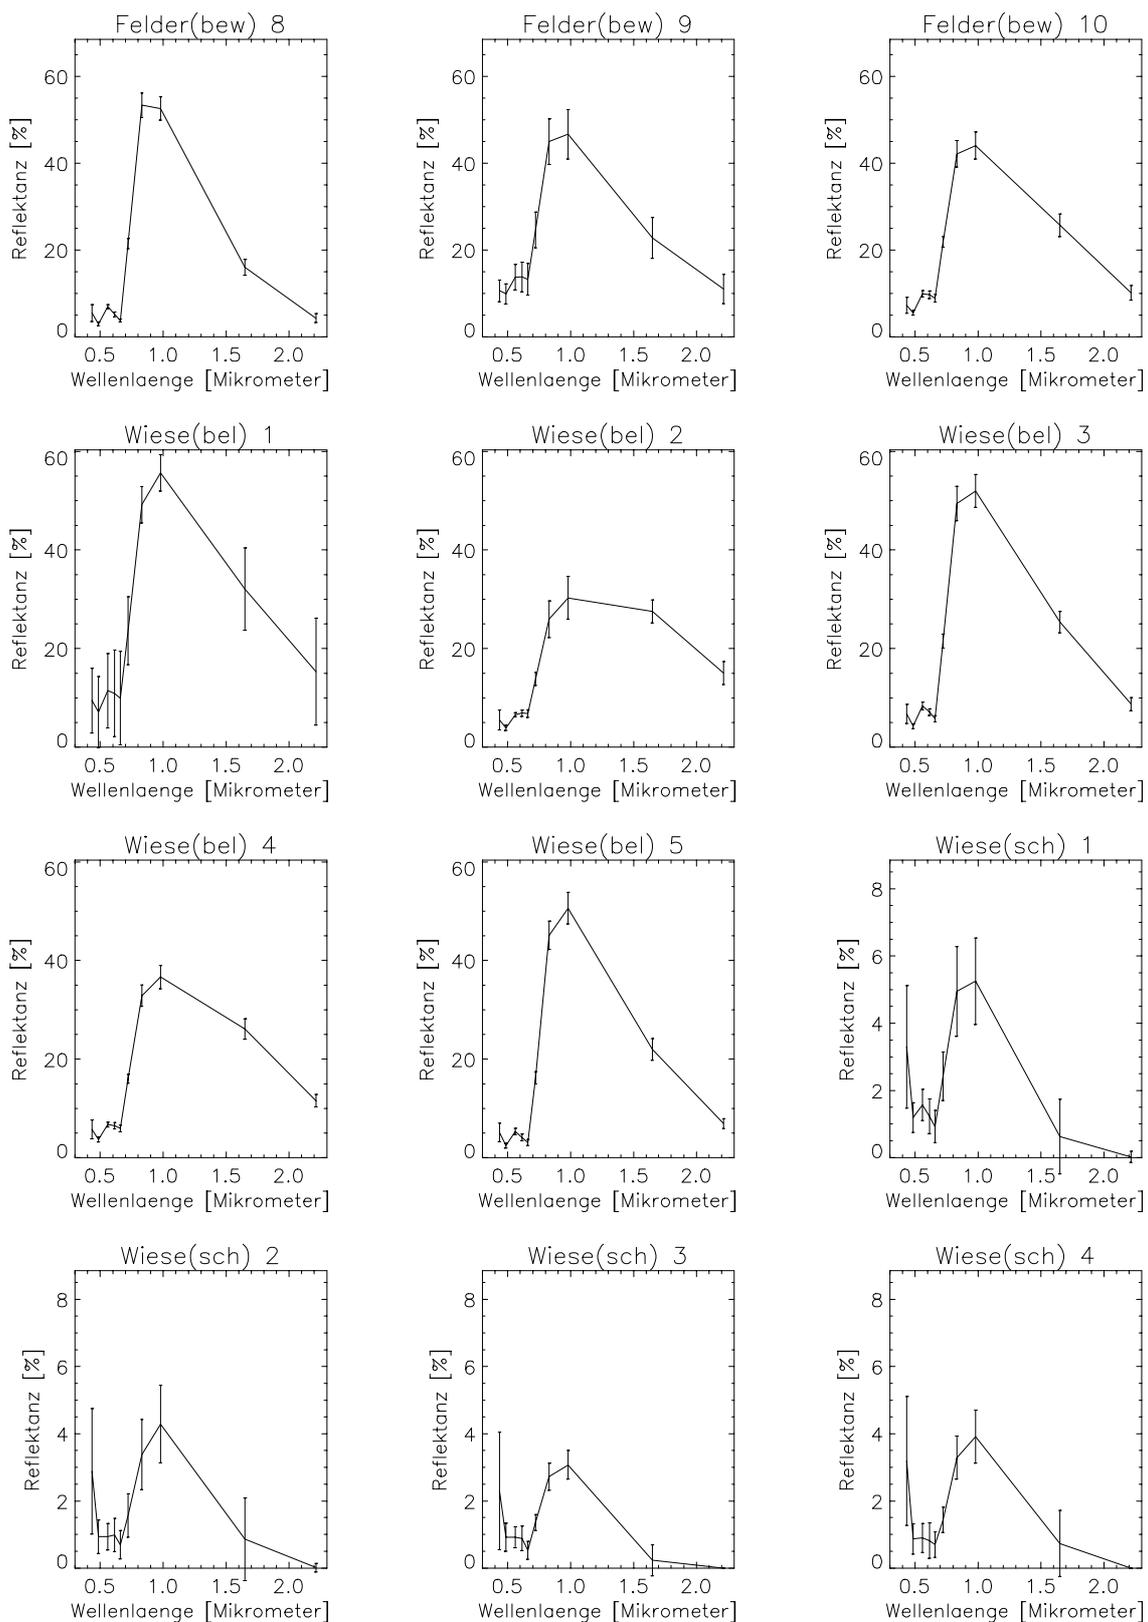


Abb. A - 23: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.

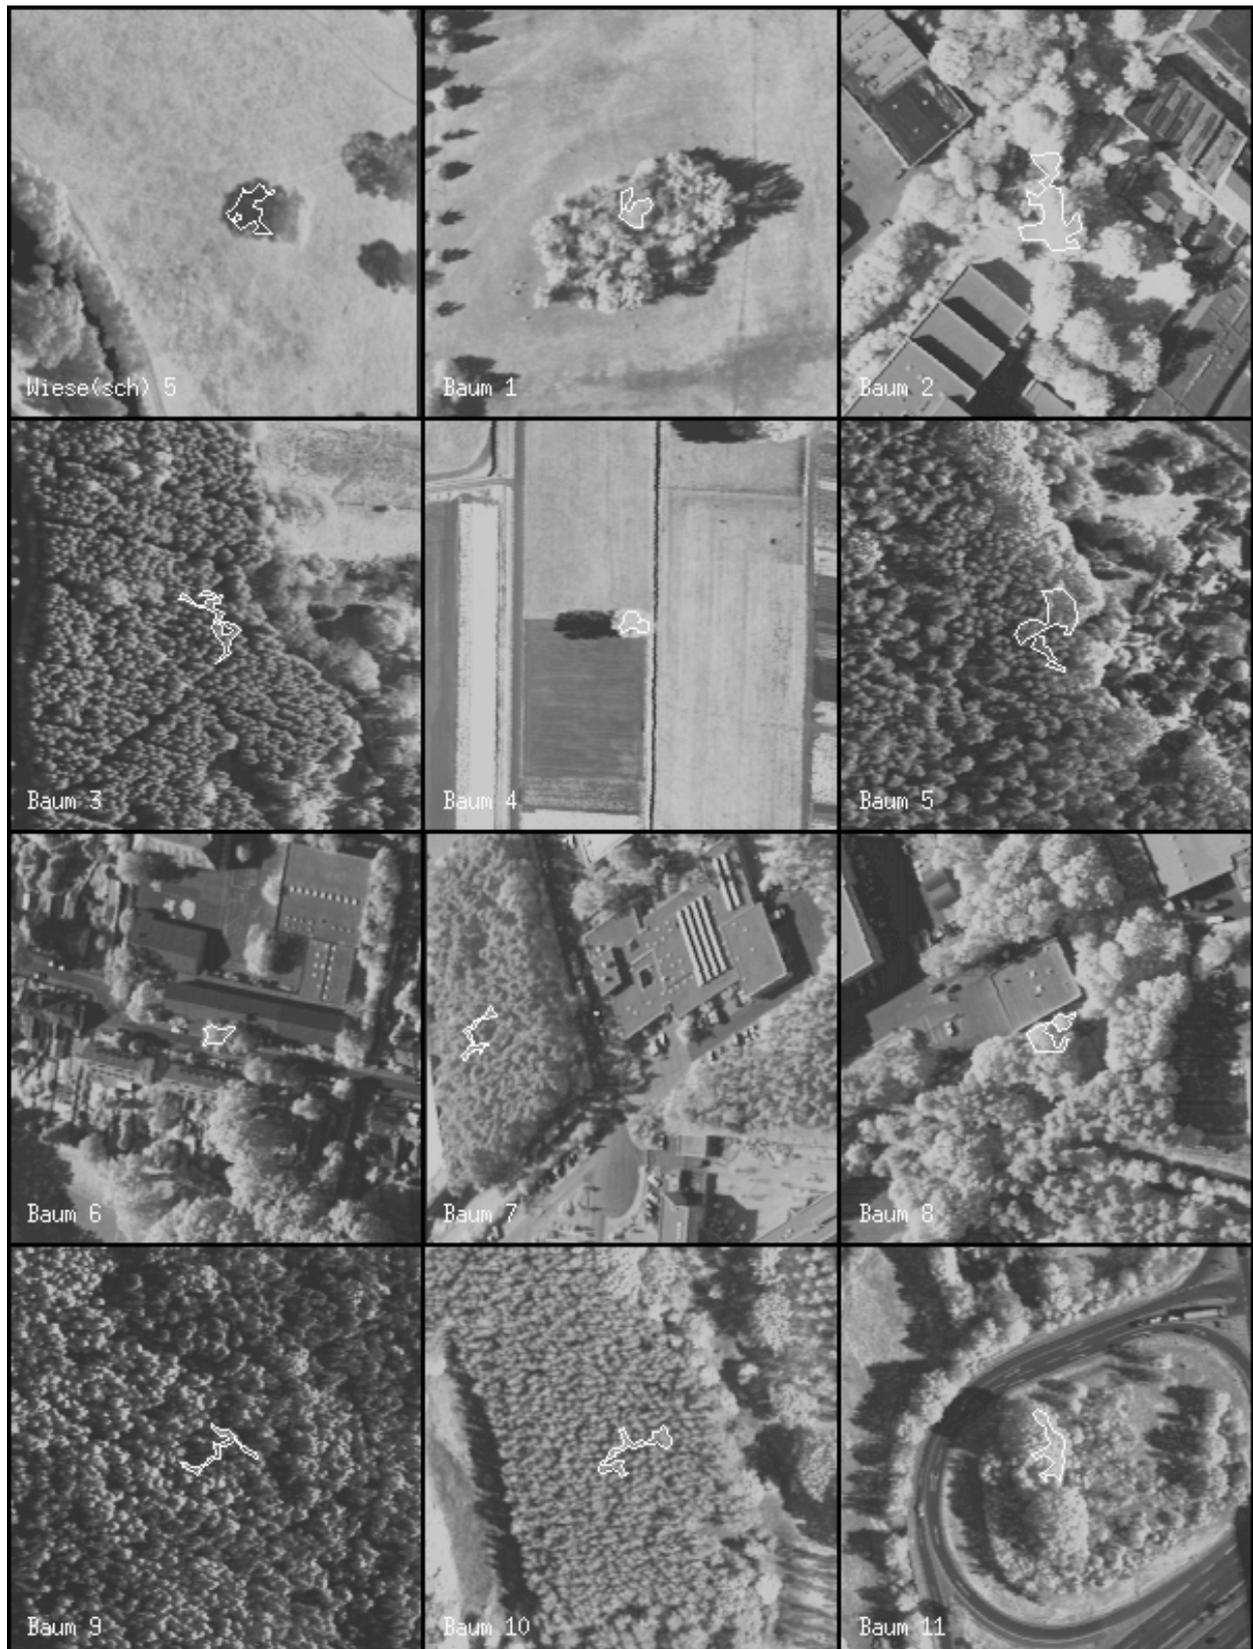


Abb. A - 24: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

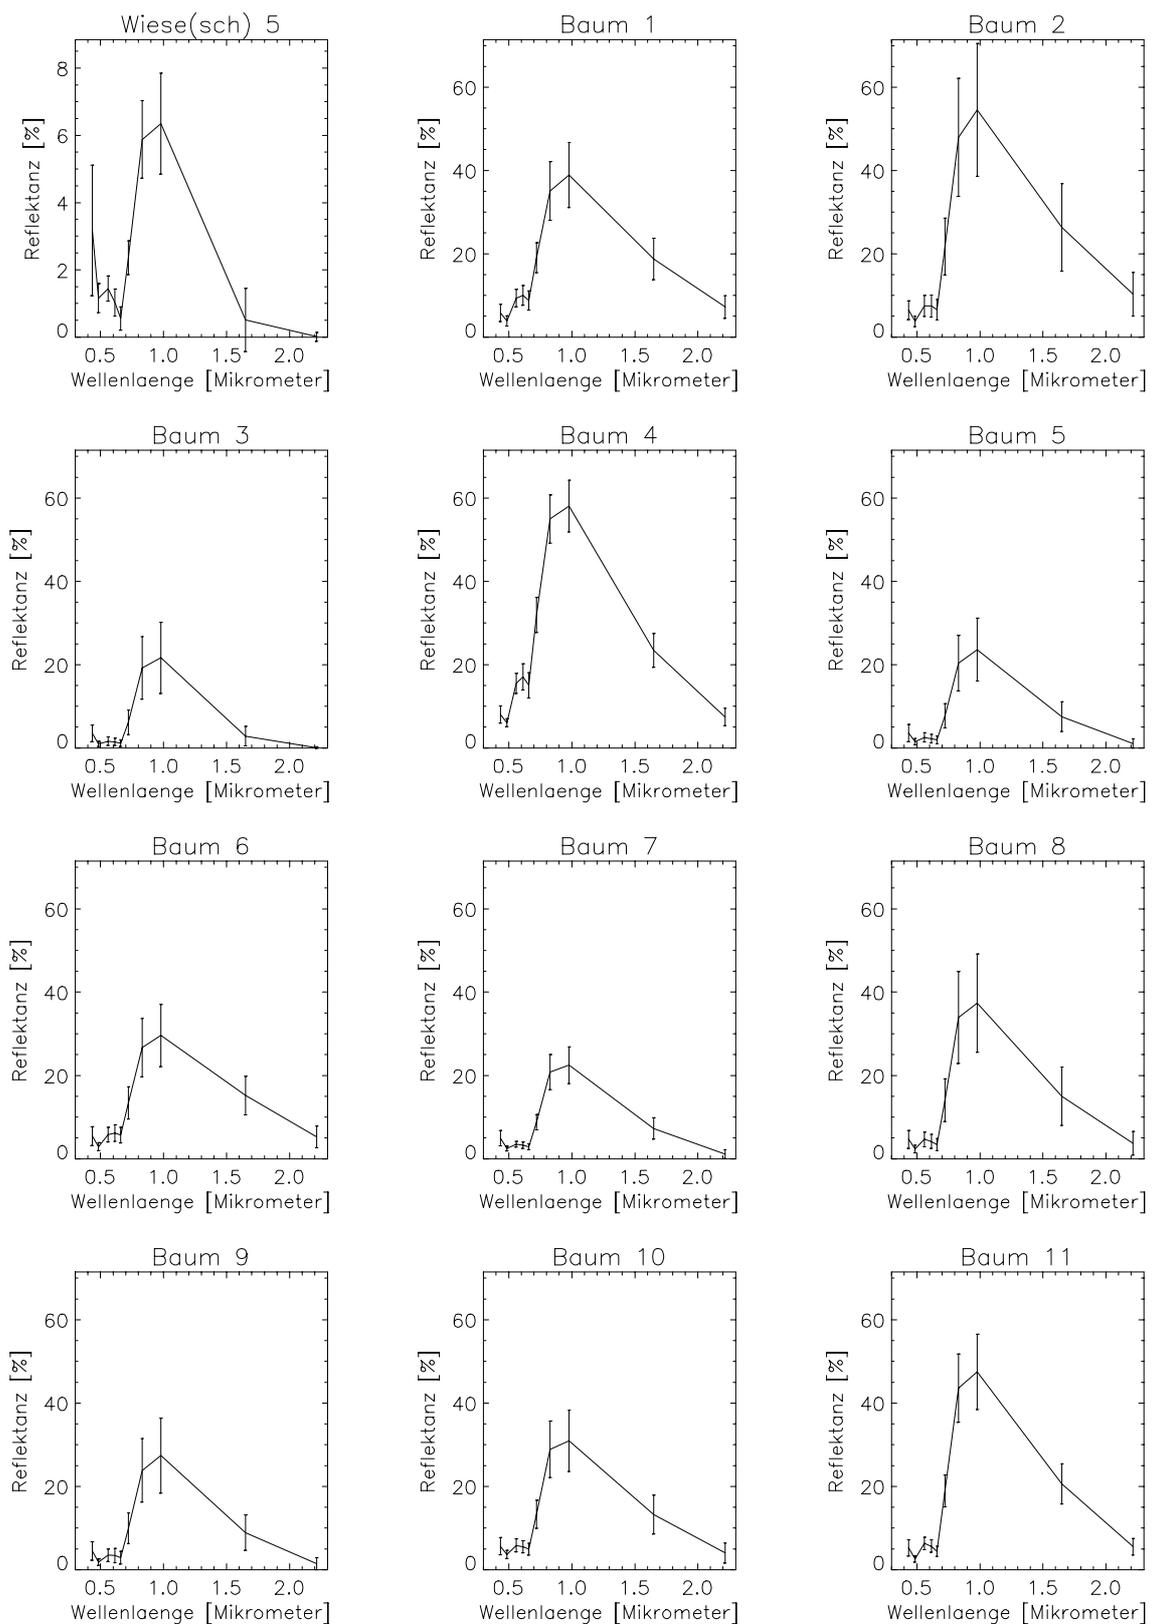


Abb. A - 25: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.

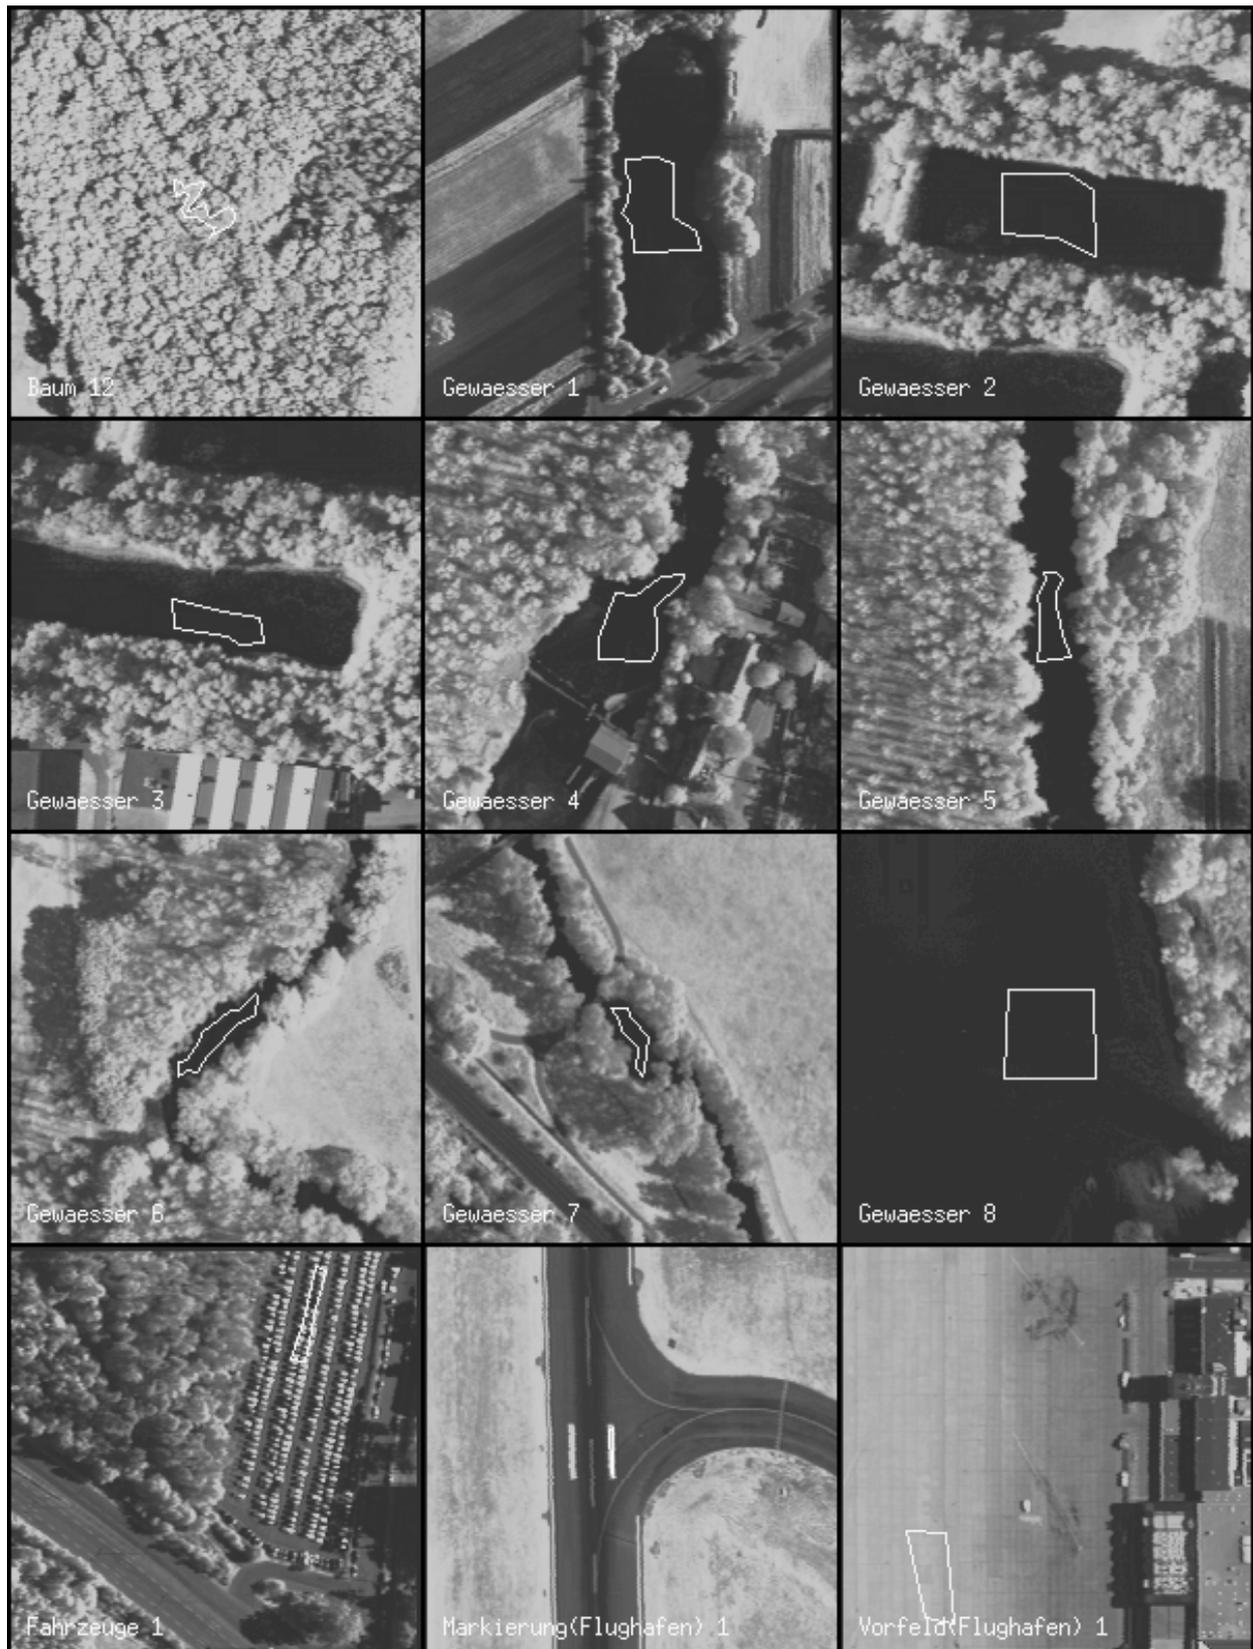


Abb. A - 26: Darstellung ausgewählter Stichproben. Die gemittelten Spektren, welche aus den Pixeln errechnet wurden, die von den Polygonen aus weißen Linien umschlossen sind, befinden sich auf der nächsten Seite. Die Bildausschnitte entstammen den Bilddaten des Spektralkanals Nr. 7. Die Bilddaten wurden kontrastverstärkt.

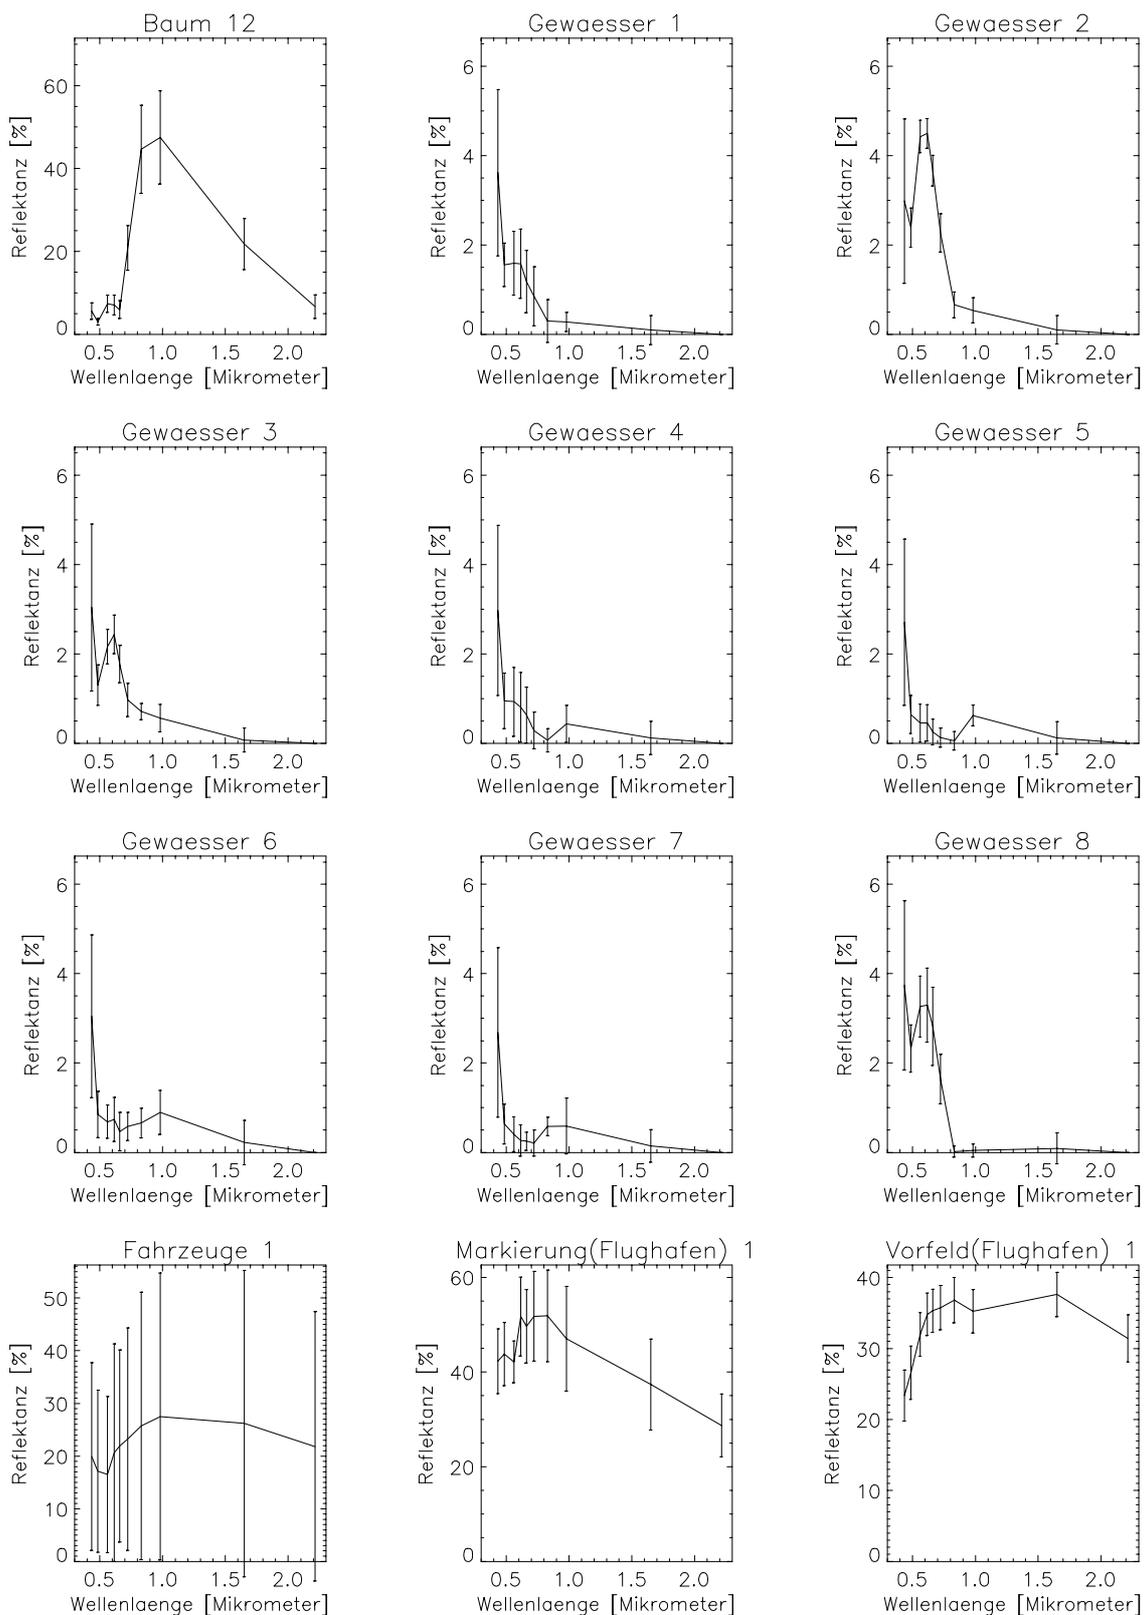


Abb. A - 27: Darstellung der gemittelten Spektren, die aus den Stichproben der vorherigen Seite berechnet wurden. Die Fehlerbalken geben Auskunft über die Standardabweichung der Grauwerte der Pixel innerhalb der jeweiligen Probe.

Erklärung

Ich versichere, daß ich diese Arbeit selbständig und nur unter Zuhilfenahme der angegebenen Quellen angefertigt habe.

(Daniel Kulbach)