

Studienrichtung Vermessungswesen
Technische Universität Wien

GEOWISSENSCHAFTLICHE
MITTEILUNGEN

Heft 48

**Ergänzung und Fortführung eines digitalen Landschaftsmodelles
mit multispektralen und hochauflösenden
Fernerkundungsaufnahmen**

von

Adele Sindhuber

Veröffentlichung des Institutes für Photogrammetrie und Fernerkundung

Geowiss. Mitt.
48, 1998

Wien, im Mai 1998

Studienrichtung Vermessungswesen
Technische Universität Wien

**GEOWISSENSCHAFTLICHE
MITTEILUNGEN**

Heft 48

**Ergänzung und Fortführung eines digitalen Landschaftsmodelles
mit multispektralen und hochauflösenden
Fernerkundungsaufnahmen**

von

Adele Sindhuber

Veröffentlichung des Institutes für Photogrammetrie und Fernerkundung

Geowiss. Mitt.
48, 1998

Wien, im Mai 1998

Herausgeber und Verleger: o.Prof.Dr.-Ing.K.Kraus

Vorstand des Institutes für Photogrammetrie und Fernerkundung
der Technischen Universität Wien
A-1040 Wien, Gußhausstraße 27-29

Die Kosten für den Druck wurden aus eigenen Einnahmen des Institutes für Photogrammetrie und Fernerkundung der Technischen Universität Wien getragen.

Mein besonderer Dank gilt Herrn Josef Jansa, der mit zahlreichen guten Ideen zum Gelingen dieses Projektes beigetragen hat. Bei Professor Kraus möchte ich mich sehr herzlich für die angeregten Diskussionen über verschiedene Ideen und Visionen zur Fernerkundung bedanken. Bei allen Institutsmitgliedern und meinen Freundinnen und Freunden möchte ich mich bedanken für die angenehme Begleitung durch diese schöne Zeit des Forschens und Suchens.

Druck: Laser-Print-Express

Auflage: 250 Stück

ISBN 3-9500791-0-6

KURZFASSUNG

In dieser Arbeit soll ein Landnutzungslayer aus multispektralen und hochauflösenden panchromatischen Fernerkundungsbildern abgeleitet werden.

Zur Auswertung der multispektralen Satellitenbilder wird ein Klassifizierungsverfahren vorgestellt, bei dem nach dem Prinzip der Maximum Likelihood Klassifizierung nicht nur die Klassen größter Wahrscheinlichkeitsdichte, wie üblich, sondern auch die Klassen zweitgrößter Wahrscheinlichkeitsdichte ausgewiesen werden. Dadurch erhält man eine Aussage über die Eindeutigkeit der multispektral zugewiesenen Klasse. Damit die Geometrie der Daten verfeinert wird, sollen auch Informationen aus panchromatischen Bildern in die Ausarbeitung einfließen.

Die Analyse panchromatischer Daten besteht aus Texturanalysen mittels Förstner-Operator, mit dem homogene Flächen, Kanten und Punkte ausgewiesen werden. Hochtexturierte Gebiete werden so erkannt und können als besiedelte Flächen ausgegeben werden. Mit Schwellwertverfahren kann Wald aus panchromatischen Bildern extrahiert werden.

Alle verfügbaren Informationen aus den Fernerkundungsaufnahmen und aus dem Digitalen Landschaftsmodell des Bundesamtes für Eich- und Vermessungswesen werden mittels hierarchischer Regeln verknüpft, wobei jedem Pixel eine Landnutzungsclass zugewiesen wird. Aus der Vielfalt der Informationen und der daraus resultierenden Überbestimmung kann eine Sicherheit der Klassenzuordnung abgeleitet werden. Das Ergebnis ist ein Landnutzungslayer mit 15 x 15 Meter Bodenauflösung.

Eine detaillierte Genauigkeitsuntersuchung mit visueller Orthophotointerpretation bildet den Abschluß.

ABSTRACT

For a landuse-classification we combined high resolution multispectral data with high ground resolution imagery to get good ground resolution on the one hand, and to improve supervised multispectral classification with texture analyses of panchromatic data.

The program for multispectral classification takes into consideration that class-signatures are statistically very different, and probabilities vary for each pixel for every class. We calculate with the maximum likelihood algorithm the probability for every pixel for every class, to decide, whether a pixel is within a class with high probability, or if it is very uncertain for a pixel to belong to any class.

Texture analyses in form of point and edge detection with the Förstner Operator are used to extract information of the high resolution data. So homogeneous areas, edges and points are detected. This information can be analysed and gives us an idea of highly textured areas, where villages and single buildings are. Forest areas can be detected by image-segmentation. A mean-value and a standard-deviation is specified, within pixels in a focal window belong to the forest in the panchromatic image.

Furthermore all extracted information is linked together. The high spatial resolution of the panchromatic analyses is linked with the multispectral information.

Finally our results are connected with the digital-landscape-model of the Federal Office of Metrology and Surveying and classes of certainty are generated. We get an actual landuse-layer with a ground resolution of about 15 x15 meters.

1	EINLEITUNG UND MOTIVATION	1
2	VERARBEITUNG VON FERNERKUNDUNGSDATEN	4
2.1	AUFBEREITUNG DER SATELLITENDATEN	4
2.1.1	GEOMETRISCHE REKTIFIZIERUNG	4
2.1.2	TOPOGRAPHISCHE KORREKTUR	8
2.1.3	MINNAERT-KORREKTUR	9
2.2	INTERPRETATION VON MULTISPEKTRALEN FERNERKUNDUNGSDATEN	18
2.2.1	MULTISPEKTRALE KLASSIFIZIERUNG MIT VERSCHIEDENEN WAHRSCHEINLICHKEITEN	18
2.2.2	MULTISPEKTRALE KLASSIFIZIERUNG DER TM-DATEN	25
2.3	ANALYSE DER PANCHROMATISCHEN DATEN	29
2.3.1	FILTERUNG	29
2.3.2	SEGMENTIERUNG	34
2.3.3	TEXTURANALYSE	37
3	VERARBEITUNG IM GIS.....	42
3.1	GEOGRAPHISCHE INFORMATIONSSYSTEME.....	42
3.2	DIGITALES LANDSCHAFTSMODELL	43
3.3	VERKNÜPFUNG VERSCHIEDENER FERNERKUNDUNGSDATEN	46
3.4	FERNERKUNDUNG UND GIS.....	50
3.4.1	WISSENSBASIERTER VERKNÜPFUNG VON GIS UND FERNERKUNDUNGSDATEN	50
3.4.2	HANDHABUNG NICHT PERFEKTER DATEN	53
3.4.3	VERKNÜPFUNG VON GIS UND FERNERKUNDUNGSDATEN MIT ANGABEN ZUR SICHERHEIT ...	54
3.5	FERNERKUNDUNGSDATEN VERKNÜPFT MIT VORHANDENEN GIS-DATEN	56
3.5.1	ERSTELLUNG DER REGELBASIS	56
3.5.2	KLASSIFIZIERUNG MIT SICHERHEITEN	57
4	FALLBEISPIEL SPOT UND TM.....	62
4.1.1	AUSWERTUNG DES SPOT-PAN.....	62
4.1.2	KLASSIFIZIERUNG DER TM-DATEN.....	66
4.1.3	VERKNÜPFUNG VON SPOT UND TM	66
5	VERGLEICHENDE ANALYSEN UND GENAUIGKEITEN	68
6	ZUSAMMENFASSUNG, DISKUSSION UND AUSBLICK.....	80
6.1	DISKUSSION	81
6.2	AUSBLICK	82
7	LITERATURVERZEICHNIS.....	83
8	ANHANG.....	87
8.1	OPTISCHE FERNERKUNDUNGSDATEN.....	87

Abbildungsverzeichnis

Abbildung 1 Verschiedene Aufnahmesysteme in der Fernerkundung [Ries Ch., 1997].....	5
Abbildung 2 Paßelemente in Vektorform.....	7
Abbildung 3 Strahlungsfluß verschiedener Objekte [aus Albertz, 1991] li: spiegelnde Reflexion, Mitte: diffuse Reflexion (Lambertscher Strahler), re: gemischte Reflexion,.....	8
Abbildung 4 Reflexionsverteilungskurve von Kieferbeständen nach Hildebrandt 1976	9
Abbildung 5 Geometrische Beziehungen der Aufnahme [Smith et al., 1980]	11
Abbildung 6 $\cos^k(i)$ in Abhängigkeit vom Einfallswinkel der Sonne und der Minnaert-Konstanten k	13
Abbildung 7 Relativer mittlerer Fehler des multiplikativen Korrekturfaktors K in Abhängigkeit von der Minnaert- Konstante k und dem Einstrahlungswinkel i	14
Abbildung 8 Vergleich der Waldmaske des Originalen-TM Bildes mit dem topographisch korrigierten Bild	15
Abbildung 9 Mittelwerte der beiden „Wald“-Klassen in den Kanälen des Originalbildes und des korrigierten Bildes	16
Abbildung 10 Spektrale Reflexionsgrade verschiedener Oberflächen (Nach E.L.Krinow, aus Schwidofsky 1976)....	18
Abbildung 11 Merkmalsraum zur multispektralen Klassifizierung [Albertz, 1991].....	19
Abbildung 12 Seed Tool von Imagine.....	22
Abbildung 13 Feature-Space der Kanäle 4 und 5 und Feature-Space der Kanäle 2 und 3	22
Abbildung 14 Beispiele von Distanzhistogrammen aus [Erda, 1994].....	23
Abbildung 15 Klassifizierung eines TM-Ausschnittes mit Klassen erster Wahrscheinlichkeitsdichte oben, Klassen zweiter Wahrscheinlichkeitsdichte unten.....	28
Abbildung 16 Gegenüberstellung des Ausgangsbildes IRS-1C-Pan zum gefilterten Bild	33
Abbildung 17 Schwellwertabgrenzung von Wald	35
Abbildung 18 Waldlayer aus Schwellwertbildung in der IRS-1C-Pan Aufnahme.....	36
Abbildung 19 Gegenüberstellung von Förstner-Operator und IDM-Texturanalyse	40
Abbildung 20 Visuelle Interpretation und Texturanalyse mittels Förstner Operator.....	41
Abbildung 21 Übersicht über die Objektbereiche und Gruppen	45
Abbildung 22 Ablaufdiagramm der Verknüpfung von multispektralen und hochauflösenden Informationen	47
Abbildung 23 TM-Klassifizierung überlagert mit Vektoren aus der hochauflösenden Aufnahme	48
Abbildung 24 Extraktion der Waldgrenze aus dem IRS-1C-PAN mittels Snakes	49
Abbildung 25 Beispiel eines Klassifikationsmodelles [Bolstad P. et al., 1992]	52
Abbildung 26 Entscheidungsfindung für eine Klassifizierung [Bolstad P. et al., 1992].....	52
Abbildung 27 Ablaufschema des wissensbasierten Systems [Kontoes C. et al., 1993]	55
Abbildung 28 Ablaufdiagramm von der Fernerkundungsaufnahme zur Bodenbedeckung	60
Abbildung 29 Landnutzung nach der Verknüpfung sämtlicher Daten mit Klassen verschiedener Sicherheiten.....	61
Abbildung 30 Texturanalyse des SPOT-Bildes mit Förstner-Operator.....	63
Abbildung 31 Besiedlungslayer abgeleitet von der SPOT-Texturanalyse.....	64
Abbildung 32 Waldlayer abgeleitet mit Schwellwertanalysen aus dem SPOT-Bild	65
Abbildung 33 Landnutzungsinterpretation aus SPOT-Pan- und TM-Aufnahme im Raum Gmunden	67
Abbildung 34 Gegenüberstellung der visuellen Luftbildinterpretation und der Fernerkundungsanalyse	70
Abbildung 35 Gegenüberstellung der verschiedenen Waldinterpretationen.....	74
Abbildung 36 Vergleich der Waldabgrenzungen.....	75
Abbildung 37 Ausschnitt vom Traunsee	76
Abbildung 38 Industrieflächen und besiedelte Gebiete	76
Abbildung 39 Vergleich der Waldlichtungen	77
Abbildung 40 Abgrenzung hochtexturierter Gebiete.....	77
Abbildung 41 Vergleich der Abgrenzung eines Dorfes	78
Abbildung 42 Österreichische Überflugsgebiete von IRS-1C	88
Abbildung 43 Lage der TM-Szenen und der Paßelemente mit dem Blattschnitt der ÖK-50	89

1 Einleitung und Motivation

Das Institut für Photogrammetrie und Fernerkundung (I.P.F.) der Technischen Universität Wien hat ein starkes wissenschaftliches Engagement sowohl in der Photogrammetrie als auch auf dem Gebiet der Fernerkundung. Die Schwerpunkte in der Fernerkundung liegen einerseits in der Behandlung geometrischer Probleme, wie der geometrischen Rektifizierung von Aufnahmen, andererseits im interpretatorischen Bereich, wo in den vergangenen Jahren ein Landnutzungsdatensatz mit einer Auflösung von 50x50 Metern flächendeckend für Österreich für den Mobilfunk aus Thematic Mapper Daten abgeleitet wurde. Aufgrund der regen Nachfrage, die diesem Datensatz entgegengebracht wurde, konnte ein prinzipielles großes Interesse der Anwender von und an Landnutzungsdaten festgestellt werden.

Die folgende Arbeit entstand im Rahmen des Forschungsprojektes MISSION 79.064/2 – II/5/95 des Bundesministeriums für Wissenschaft und Verkehr. Neue Möglichkeiten von Fernerkundungsanwendungen in Österreich sollen gefunden und Lösungen entwickelt werden. Das I.P.F. versucht dabei gemeinsam mit dem Bundesamt für Eich- und Vermessungswesen (BEV) für deren Digitales Landschaftsmodell (DLM) einen Bodenbedeckungslayer abzuleiten. Dieser Layer soll eine Bodenauflösung von genauer als 20x20 Meter haben. Die gewünschten Klassen sind „Wasser“, „Wald“, „Acker“, „Grünland“, „Besiedelt“, „Fels“ und „Gletscher“.

Die Motivation für diese Aufgabe liegt in der Vervollständigung des DLM des BEV, da es bisher in den Österreichischen Karten 1:50000 (Ök50) nur die Information „Wald“ als Bodenbedeckung gab. Zudem sollen auch andere bestehende Landnutzungsdaten mit dem Potential der neuen hochauflösenden Fernerkundungsdaten aktualisiert und verfeinert werden. Nicht nur die rasanten Entwicklungen im Bereich der Fernerkundung und der Bildauflösung sind hier wichtig, auch die Bildverarbeitung öffnet neue Wege für die Bearbeitung panchromatischer Daten, da dort große Fortschritte im Bereich der Muster- und Objekterkennung gemacht werden. Diese Entwicklungen sollen nun auf hochauflösende Fernerkundungsbilder angewandt werden. Zusätzlich bieten die vielfältigen Systeme von Geographischen Informationssystemen (GIS) Methoden an, eine Fülle von hybriden Informationen zu verbinden. Diese Verknüpfung von Daten ermöglicht einerseits die aus den Fernerkundungsdaten gewonnenen Informationen miteinander zu verbinden, andererseits die bestehenden Daten aus dem DLM in die Landnutzungsanalyse miteinzubeziehen. Das wiederum schafft die Möglichkeit, aus einer großen Überbestimmung heraus die Landnutzung für ein Pixel zu bestimmen und aus der Konsistenz der Daten auf eine Sicherheit der Klassenzuordnung zu schließen. Diese Einbeziehung der Sicherheit der Zuordnung ermöglicht eine effiziente Nachbearbeitung, da nur noch die unsicheren Klassen visuell kontrolliert werden müssen.

Der erste Teil dieser Arbeit erläutert die Bildvorverarbeitung und beschreibt zuerst die Rektifizierung der Fernerkundungsaufnahmen mit dem Schwerpunkt auf der Art und Erfassung von Paßpunkten. Anschließend wird ein Verfahren der Topographischen Korrektur vorgestellt.

Der darauf folgende Abschnitt behandelt die Auswertung multispektraler Satellitenbilder. Es wird ein Klassifizierungsverfahren vorgestellt, bei dem nach dem Prinzip der Maximum Likelihood Klassifizierung nicht nur die Klassen größter Wahrscheinlichkeitsdichte, wie üblich, sondern auch die Klassen zweitgrößter Wahrscheinlichkeitsdichte ausgewiesen werden. Dadurch erhält man eine Aussage über die Eindeutigkeit der multispektral zugewiesenen Klasse. Aufgrund der überaus guten spektralen Auflösung von 7 Spektralkanälen enthalten diese Landsat- Thematic Mapper-Daten (TM-) die wichtigsten spektralen Informationen für die Landnutzungsklassifizierung. Die geforderte geometrische Genauigkeit ist aus den TM-Daten alleine nicht zu erreichen, da diese Daten nur eine Auflösung von 30x30 Meter haben. Deshalb müssen zusätzlich auch hochauflösende Bilddaten in die Analyse integriert werden. Damit wird die Geometrie der Daten verfeinert, Informationen, die aus panchromatischen Bildern gewonnen werden, können in die Ausarbeitung einfließen.

Das Kapitel 2.3 beschäftigt sich mit der Analyse panchromatischer Daten. Mit Texturanalysen mittels Förstner-Operator können besiedelte Gebiete erkannt werden und mit Hilfe von Schwellwertverfahren kann „Wald“ aus diesen Bildern gut extrahiert werden. Die Ausgangsdaten für die Entwicklung der hier vorgestellten Methode sind panchromatische Indian Remote Sensing Bilddaten (IRS-1C-Pan) mit einer Bodenauflösung von 5,8x5,8 Meter.

In dieser Arbeit wird ein Bodenbedeckungslayer für ein GIS abgeleitet. Dazu werden GIS-Werkzeuge verwendet und zugleich topographische Daten aus einem GIS miteinbezogen. Daher soll eine allgemeine Abklärung über Aufgaben und Möglichkeiten eines GIS erfolgen. Anschließend wird in einer Literaturstudie die Verknüpfung von Fernerkundungsdaten mit topographischen Daten mit Angaben zur Sicherheit und Vollständigkeit der Daten erläutert. Ausgehend davon werden alle verfügbaren Informationen aus den Fernerkundungsaufnahmen und aus dem DLM mittels hierarchischer Regeln verknüpft und jedem Pixel wird eine Landnutzungsklasse zugewiesen. Aus der Vielfalt der Informationen und der daraus resultierenden Überbestimmung kann auch ein Maß für die Sicherheit der Klassenzuordnung abgeleitet werden.

Zum Abschluß erfolgt eine detaillierte Genauigkeitsuntersuchung mit visueller Orthophoto-interpretation und eine Fallstudie, um die erarbeiteten Methoden auf neue TM- bzw. auch auf ein panchromatisches SPOT-Bild anzuwenden.

Im Anhang befindet sich eine Auflistung derzeit verfügbarer und geplanter Fernerkundungsdaten.

Als Software wurden hauptsächlich die beiden Programmpakete ERDAS-IMAGINE und ARC/Info verwendet.

IMAGINE ist ein Bildverarbeitungssystem, das speziell für Fernerkundungsdaten konzipiert ist. Es stehen Module für den Datenimport und -export, für die ebene Rektifizierung (ohne digitales Höhenmodell), für die multispektrale Klassifizierung, für die Erstellung von Plots zur graphischen Ausgabe, etc. zur Verfügung. Ein wichtiges Tool ist der IMAGINE Model-Maker, mit dem der Anwender über graphische Unterstützung und visueller Programmierung Makros

entwickeln kann. Sämtliche Entwicklungen, die in der folgenden Arbeit vorgestellt werden, sind im Model-Maker realisiert.

ARC/Info ist ein GIS-Programm, mit dem Vektor- und Rasteroperationen und deren Verknüpfungen möglich sind. Für die Bearbeitung aller Vektordaten und deren Konvertierung ins Rasterformat, sowie für die Attributierung von Daten wurde dieses Programm verwendet.

Für die Geocodierung der Daten wurden die am I.P.F. entwickelten Programme ORIENT und SCOP verwendet, während die Texturanalysen, Filterungen und Snakes- Berechnungen auf C++ - Programmen des Institutes durchgeführt wurden.

2 Verarbeitung von Fernerkundungsdaten

2.1 Aufbereitung der Satellitendaten

2.1.1 Geometrische Rektifizierung

Fernerkundungsdaten stellen eine wichtige Grundlage für die großräumige Erfassung von Umweltparametern dar. Die Fernerkundung liefert aktuelle, flächendeckende Daten, meist in digitaler Form, die zum Großteil einer automatischen Verarbeitung zugeführt werden können. Allerdings sind diese Aufnahmen in Bezug auf das Landeskoordinatensystem verzerrt. Voraussetzung für die gemeinsame Auswertung von Fernerkundungsaufnahmen und anderen topographischen Daten ist daher die geometrische Rektifizierung der Scanneraufnahmen. Darunter versteht man die Entzerrung der Bildmatrix in Bezug auf das Landeskoordinatensystem. Das bedeutet, daß alle gemeinsam zu verarbeitenden Daten in das gleiche Koordinatensystem transformiert werden.

Bei der Entzerrung von Scanneraufnahmen kann man grundsätzlich zwei Methoden unterscheiden:

- Nichtparametrische Rektifizierung
- Parametrische Rektifizierung

Die einfachste Methode ist die nichtparametrische Rektifizierung. Sie beruht auf der Zerlegung des gescannten Gebietes in mehrere Teilbereiche und der anschließenden unabhängigen Entzerrung jedes einzelnen Bereiches durch einfache Transformationen. Voraussetzung für die Verwendung dieser einfachen Entzerrungsmethode sind nicht zu stark verzerrte Scanneraufnahmen und keine zu groben Inhomogenitäten.

Bei niedrigen Flughöhen, großen Geländehöhenunterschieden und hoher Bodenauflösung muß man auf die parametrische Rektifizierung übergehen, die die Einbeziehung eines digitalen Geländemodellles erlaubt. Bei der parametrischen Lösung werden Informationen über die Flugbahn, einschließlich Drehungen und Neigungen der Plattform in die Entzerrung miteinbezogen. Dazu ist es notwendig die geometrische Aufnahmesituation zu rekonstruieren, was eine genaue Kenntnis des Abbildungsprozesses voraussetzt, und für die äußere Orientierung eine Anzahl an Paßpunkten erfordert [Kraus K., 1990], [Ries Ch., 1997].

Die Fernerkundungssysteme arbeiten mit verschiedenen Aufnahmeverfahren. Satellitengestützte Abtaster sind beispielsweise in der Lage mehrere spektrale Kanäle gleichzeitig aufzunehmen. Bei einem Rotationsscanner wird mit Hilfe eines rotierenden Prismas die von der Erdoberfläche ausgehende Strahlung von einem Detektor aufgenommen. Die während einer Umdrehung des Prismas gescannten Strahlungsintensitätswerte, die sogenannten Grauwerte, bilden eine Zeile der

Bildmatrix. Da sich bei diesem Abbildungsvorgang keine Optik im Strahlungsbereich befindet, kann mit Rotationsscannern neben den Spektralbereichen des sichtbaren Lichtes und des nahen Infrarots auch Thermalstrahlung erfaßt werden. Mit diesem Aufnahmesystem werden die Landsat Thematic Mapper Daten aufgenommen.

Ein weiterer gebräuchlicher Scannertyp ist die digitale Zeilenkamera. Bei diesem Aufnahmesystem ist in der Brennebene der Empfangsoptik eine ganze Zeile von Detektoren angeordnet. Ein Scan einer Zeilenkamera stellt eine exakte Zentralperspektive dar. Mit diesem Aufnahmesystem sind sowohl die französischen Fernerkundungsaufnahmen SPOT-Pan als auch die IRS-1C-Bilder aufgenommen. Die Abbildung 1 zeigt die verschiedenen Aufnahmesysteme im Vergleich zu einer Luftbildaufnahme.




Abbildung 1

Verschiedene Aufnahmesysteme in der Fernerkundung

[Ries Ch., 1997]

Neben der Kenntnis der Aufnahmegeometrie ist es notwendig mit Hilfe von Paßpunkten die äußere Orientierung, das ist die Position des Projektionszentrums und die drei Drehungen des Bildes im Raum, zu bestimmen. Die Messung der Paßpunkte für ein bestimmtes Gebiet stellt immer wieder ein Problem dar. Deshalb haben [Kalliany R., 1991] und [Kohlhofer G., 1991] schon früh begonnen, eine Paßpunktdatenbank zu erstellen. In dieser Datenbank werden sogenannte Paßpunktfeatures verwaltet. Da es in kleinmaßstäbigen Satellitenbildern schwer ist, Punkte zu identifizieren, wurden sogenannte Paßelemente digitalisiert, die dauerhafte Lineamente, wie Waldgrenzen, Verkehrswege und Gewässerufer enthalten. Jedem Paßelement ist ein eindeutiger Bezugspunkt mit dreidimensionalen Koordinaten zugeordnet. Diese Elemente sind zum Großteil aus der topographischen Karte 1:50000 entnommen. Dabei handelt es sich um ca. 2 x 2 km große, vektorielle Kartenausschnitte. Diese vorhandenen Paßpunktfeatures eignen sich sehr gut für die TM-Aufnahmen und Aufnahmen ähnlicher Bodenauflösung. Für die hochauflösenden panchromatischen Aufnahmen, also Aufnahmen mit einer Pixelgröße kleiner als 15 x 15m, sind diese Paßpunktfeatures allerdings viel zu ungenau. Daher wurden für die hochauflösenden Bilder aus den Daten des DLM neue Paßpunktfeatures erstellt. Der

Im Zuge des Projektes MISSION wurde am Institut für Computergestützte Geometrie und Graphik der TU-Graz ein neues Einpaß-System auf JAVA entwickelt, das allen Projektpartnern zur Verfügung stehen soll.


Im WorldWideWeb findet man die vorhandenen Paßpunktfeatures und ein Einpassungsprogramm für die Fernerkundungsaufnahmen.

Bei der Paßfeature-Messung werden die Vektorelemente über das Satellitenbild gelegt und für die anschließende Transformation (des Bildausschnittes auf die Paßelemente im Landeskoordinatensystem) manuell Verschiebungsvektoren gemessen. Dabei erfolgt zuerst eine Grobeinpassung, anschließend werden für die Feineinpassung neue Verschiebungsvektoren gemessen. Diese zweite Einpassung soll in Zukunft durch Matching-Algorithmen automatisch erfolgen.

Die Vorteile der Verwendung von Paßelementen gegenüber Paßpunkten liegen neben der Möglichkeit zur Automatisierung in der höheren Genauigkeit und der großen Zuverlässigkeit der Messungen. Verwechslungen von Paßelementen sind aufgrund der großen Ausschnitte und der Redundanz der Messungen praktisch ausgeschlossen.

Nach der Paßpunktmessung liegen diese Punkte im Bildkoordinatensystem und im Landeskoordinatensystem vor. Daraus kann man mit dem Programmpaket ORIENT die Orientierungsparameter der äußeren Orientierung für jeden Scan berechnen. Die Elemente der inneren Orientierung legen die Lage des Projektionszentrums relativ zur Bildebene fest. Sie werden durch Kalibrierung bestimmt und meist vom Hersteller bekanntgegeben. Mit diesen Orientierungsparametern und mit Hilfe des Geländemodells wird anschließend mit dem Orthophotomodul SCOP.DOP von SCOP die Entzerrung und Geocodierung des Bildes durchgeführt. Das so rektifizierte Satellitenbild ist ein Orthophoto mit den geometrischen Eigenschaften einer Karte.

Paßpunktfeature auf IRS-1C-Pan



Paßpunktfeature auf SPOT-Pan




Abbildung 2

Paßelemente in Vektorform

Wie im Verlauf dieser Arbeit noch gezeigt wird, muß die Rektifizierung der Daten mit größter Genauigkeit erfolgen. Rektifizierungsfehler können später nicht mehr behoben werden; das Ergebnis aller Verknüpfungen wird dadurch schwer beeinträchtigt. Ziel ist, die Georeferenzierung auf ein halbes Pixel genau durchzuführen.

2.1.2 Topographische Korrektur

Für die Aufnahme von Fernerkundungsdaten ist entscheidend, daß sich die Geländeoberfläche und die auf ihr befindlichen Objekte gegenüber der auftreffenden Strahlung sehr unterschiedlich verhalten. Die Reflexionseigenschaften der Geländeobjekte hängen vor allem vom jeweiligen Material, seinem physikalischen Zustand (z.B. der Feuchtigkeit, der Oberflächenrauigkeit) und den geometrischen Verhältnissen ab. Nur aufgrund der Vielfalt dieser Faktoren ist es überhaupt möglich, Gegenstände unmittelbar oder in Bildwiedergaben zu sehen. Von den Objekten wird immer nur ein Teil der auftreffenden Strahlung reflektiert. Über die Art der Reflexion entscheidet die Rauigkeit der Grenzfläche. An Oberflächen, deren Rauigkeit im Vergleich zur Wellenlänge klein ist, findet spiegelnde Reflexion statt. Sie tritt häufig an Wasserflächen auf. An Oberflächen, deren Rauigkeit in der Größenordnung der Wellenlänge der auftreffenden Strahlung liegt, findet diffuse Reflexion statt, d.h. die Strahlung wird nach allen Richtungen zurückgeworfen. Der Idealfall der diffus reflektierenden Oberfläche ist die Lambertsche Fläche, die richtungsunabhängig reflektiert und darum aus allen Richtungen gleich hell erscheint. Die Strahldichte, also der Strahlungsfluß pro Flächeneinheit, ist beim Lambertschen Strahler in alle Richtungen gleich groß. Bei den meisten in der Natur vorkommenden Oberflächen liegt jedoch weder spiegelnde noch diffuse Reflexion vor, sondern eine Mischung von beiden. Bei der gemischten Reflexion wird die auftreffende Strahlung zwar nach allen Richtungen zurückgeworfen, jedoch ungleich stark. [Kraus, 1988], [Albertz, 1991]




Abbildung 3

Strahlungsfluß verschiedener Objekte [aus Albertz, 1991]

li: spiegelnde Reflexion, Mitte: diffuse Reflexion (Lambertscher Strahler), re: gemischte Reflexion,

Durch den Einfluß von Atmosphäre und Beleuchtung können Objekte im hügeligen Gelände trotz identischer spektraler Charakteristika ganz unterschiedliche Intensitätswerte in einem Satellitenbild aufweisen. Eine Waldfläche am Schattenhang erscheint um vieles dunkler als ein Waldstreifen am Sonnenhang, im Tal gelegene Objekte sind stärker vom Dunst betroffen als solche in höheren Lagen.

Radiometrische Korrekturen haben nun zum Ziel, derartige Einflüsse zu eliminieren und die originalen spektralen Eigenschaften der Objektklassen zurückzugewinnen. Objekte mit gleicher Reflexionscharakteristik sollen unter den verschiedenen äußeren Bedingungen identische spektrale Signaturen aufweisen und im Satellitenbild gleiche Intensitätswerte annehmen [Sandmeier, 1997].

Die Umrechnung der tatsächlich vom Sensor empfangenen Strahlung in jene Strahlungsintensität, die der Sensor empfangen hätte, wenn das Gelände eben gewesen wäre, nennt man daher Topographische Korrektur.

Man findet in der Literatur zahlreiche Ansätze für die Verminderung der reliefbedingten Helligkeitsunterschiede. Es gibt sowohl statistisch-empirische und semi-empirische radiometrische Korrekturansätze [Teillet et al., 1982], wie auch physikalisch basierte Modelle [Sandmeier, 1997] für die Verbesserung einer Wald/Nichtwald- und einer Waldbestandesklassifikation, sowie zahlreiche Untersuchungen, die diese Modelle und deren Endergebnisse testen, z.B. [Conese et al., 1993], [Colby, 1991], [Meyer et al., 1993], [Ekstrand, 1996], [Banko, 1997], [Sandmeier, 1997].

2.1.3 Minnaert-Korrektur

Für die Topographische Normalisierung der Thematic Mapper Bilder wurde in dieser Arbeit das Modell der Minnaert-Korrektur verwendet. Dieses Modell baut auf dem Modell der Cosinus-Korrektur auf, berücksichtigt aber die Abweichungen vom Lambertschen Strahler.

Die Minnaert-Funktion wurde 1941 von G. J. Minnaert entwickelt und für photographische Analysen der Randabschattung der Mondoberfläche verwendet [Colby, 1991]. [Smith et al., 1980] haben eine empirische Funktion mit einer Minnaert-Konstanten angesetzt, um die Annahme eines Lambertschen Strahlers für verschiedene Oberflächen zu testen. Sie entdeckten, daß Methoden mit der vereinfachten Annahme eines Lambertschen Strahlers ohne Einführung einer Minnaert-Konstanten nicht sehr effektiv für die Topographische Korrektur sind. Die Minnaert-Konstante k beschreibt die Rückwärtscharakteristik der Reflexionsverteilung einer Oberfläche, also deren Streuungseigenschaften, und steht im Verhältnis zur Oberflächenrauigkeit.

Im Gegensatz zu einem Lambertschen Strahler, der die einfallende Strahlung vollkommen diffus reflektiert, also aus allen Richtungen gleich hell erscheint, überwiegt bei einer Vielzahl von Vegetationsoberflächen und vor allem bei Waldbeständen eine Reflexionsverteilung mit ausgeprägter Rückwärtscharakteristik. Die Abbildung 4 zeigt, daß die größten Anteile der Reflexion der Kieferbestände gegen die Strahlungsquelle, also gegen die Sonne gerichtet sind, wobei θ_s der Zenitwinkel der Sonne ist.




Abbildung 4

Reflexionsverteilungskurve von Kieferbeständen nach Hildebrandt 1976

Die Cosinus-Korrektur wird in flachem Gelände angewandt, um Beleuchtungsdifferenzen auszugleichen, die auf verschiedene Sonnenstände in multitemporalen Daten zurückzuführen sind. Diese Cosinus-Korrektur modelliert dabei nur die direkte Bestrahlung durch die Sonne, obwohl auch die schwach beleuchteten Gebiete eine Menge an diffuser Beleuchtung trifft. In den „unterbelichteten“ Gebieten bewirkt die Cosinus-Korrektur eine Überkorrektur, da die Korrektur umso größer wird, je kleiner der Wert für $\cos i$. Der Einfallswinkel i ist der Winkel zwischen der Normalen auf die Erdoberfläche und der Richtung zur Sonne. Unter der Annahme eines Lambertschen Strahlers gilt für geneigte Oberflächen, daß die auftreffende Strahlung $L(\lambda, e)$ proportional dem Cosinus des Einfallswinkels i der Sonne ist.

$$L_n(\lambda) = L(\lambda, e) \frac{\cos \theta_s}{\cos i}$$

Glg 2.1.3-1

mit:

 L_n = Bestrahlungsstärke bei $e = 0$ L = Bestrahlungsstärke λ = Wellenlänge e = effektiver Beobachtungswinkel (Neigung des Geländes) i = Einfallswinkel der Sonne θ_s = Zenitwinkel der Sonne

Wie in Abbildung 5 gezeigt wird, kann i mit den Formeln für sphärische Dreiecke abgeleitet werden:

$$\cos i = \cos \theta_s \cdot \cos \theta_n + \sin \theta_s \cdot \sin \theta_n \cdot \cos(\varphi_s - \varphi_n)$$

Glg 2.1.3-2

mit:

 θ_s = Zenitwinkel der Sonne θ_n = Neigungswinkel des Geländes φ_s = Azimut der Sonne φ_n = Azimut des Reliefs (Exposition)

Da aber der Satellit eine nahezu vertikale Beobachtungsrichtung hat, gilt auch, daß der effektive Beobachtungswinkel e , der Winkel zwischen der Oberflächennormalen und der Richtung zum Sensor, gleich dem Zenitwinkel der Oberflächennormalen θ_n ist.




Abbildung 5

Geometrische Beziehungen der Aufnahme

[Smith et al., 1980]

Nun wird diese Cosinus-Korrektur um einen Parameter, die sogenannte Minnaert-Konstante erweitert:

$$L(\lambda, e) = L_n(\lambda) \cdot \cos^{k(\lambda)} i \cdot \cos^{k(\lambda)-1} e$$

Glg 2.1.3-3

wobei:

L_n = Bestrahlungsstärke bei $i = e = 0$

L = Bestrahlungsstärke

λ = Wellenlänge

e = Neigung des Geländes = effektiver Beobachtungswinkel

i = Einfallswinkel der Sonne

k = Minnaert-Konstante

Hier beschreibt der Parameter k die Reflexionscharakteristik oder die Streuungseigenschaften der Oberfläche. Durch Umformung der Gleichung errechnet sich die Steigung k der Regressionsgerade für eine bestimmte Wellenlänge λ aus folgender Gleichung:

$$L \cdot \cos e = L_n \cdot \cos^k i \cdot \cos^k e$$

Glg 2.1.3-4

Nach Logarithmieren erhält man die lineare Form mit den Unbekannten k und $\log(L_n)$:

$$\log(L \cdot \cos e) = \log(L_n) + k \cdot \log(\cos i \cdot \cos e)$$

Glg 2.1.3-5

Die Parameter L , e und i sind bekannt oder können aus bekanntem Sonnenstand und Geländemodell berechnet werden. Als Voraussetzung muß allerdings ein digitales Höhenmodell (DHM) zur Ableitung der Neigung und Exposition vorhanden sein, und der Sonnenstand zum Zeitpunkt der Aufnahme bekannt sein. Dann wird angenommen, daß die korrigierte Bestrahlungsstärke L_n für alle beteiligten Objektpunkte einer Klasse gleich, also konstant ist. Die Minnaert-Konstante k wird dann durch eine Ausgleichung aus Gleichung (Glg 2.1.3-5) errechnet und ist die Steigung der Regressionsgeraden. Daraus kann wiederum für jedes Pixel die „individuelle“ normalisierte Bestrahlungsstärke L_n neu berechnet werden, und das Bild wird topographisch korrigiert. Da die Reflexionseigenschaften eines Objektes sowohl objektspezifisch als auch von der Wellenlänge abhängig sind, muß die Konstante k für jede Objektklasse und jeden Spektralbereich neu ermittelt werden. Das heißt, daß k für jede Klasse pro Kanal der TM-Aufnahme bestimmt werden muß, da sich sonst die unterschiedlichen spektralen Eigenschaften der Objekte auswirken. Ein schwach reflektierendes Objekt reagiert weniger stark auf unterschiedliche Sonneneinstrahlung als eines mit hohem Reflexionsvermögen. Entsprechend unterschiedlich fallen die Regressionsparameter und damit die Minnaert-Konstanten aus.

[Sandmeier 1997] zeigt diese Unterschiede für verschiedene Objektklassen anhand eines C-Korrektur-Modelles auf. Dieses Modell beruht auf dem Cosinus-Korrekturmodell und führt einen additiven Parameter C ein, der die Himmelsstreuung modelliert. Er bekräftigt dabei, daß die Regression umso steiler ist, je stärker ein Objekt reflektiert, d.h. je höher der aufgenommene Intensitätswert ist. Es ist daher nicht möglich, einen allgemeingültigen Faktor k zu bestimmen.

Um die Klasse „Wald“ in alpinen Gebieten möglichst gut und differenziert zu klassifizieren, ist folgenderweise vorzugehen:

In einer ersten Stufe wird mit Hilfe der multispektralen Klassifizierung im Originalbild die Klasse „Wald“ extrahiert und daraus eine grobe Waldmaske abgeleitet. Diese Maske sollte nur jene Gebiete, die grob als „Wald“ abzugrenzen wären, ausschneiden. Die Grauwerte der Waldpixel des Originalbildes in den ebenen Geländeteilen dienen nun für die einzelnen Kanäle zur Berechnung der Minnaert-Konstanten.

Getestet wurde dieses Verfahren an einem TM-Ausschnitt südlich des Wolfgangsees. Dabei konnten für die Minnaert Konstanten folgende Werte ermittelt werden:

Kanal	k-Wert
1	0.24
2	0.34
3	0.38
4	0.80
5	0.88
7	0.77

Tabelle 1




Abbildung 6

$\cos^k(i)$ in Abhängigkeit vom Einfallswinkel der Sonne und der Minnaert-Konstanten k

Der Korrekturfaktor $K = \left(\frac{1}{\cos^k i} \right)$ nimmt mit wachsendem i rapide zu, damit steigt die Unsicherheit der Korrektur. Ein kleiner Fehler im Modell bewirkt daher rasch deutlich sichtbare Fehlkorrekturen. In der obigen Abbildung 6 fällt auf, daß die Funktion von $\cos^k(i)$ für die Minnaert-Konstanten der Kanäle 4, 5 und 7 eine genäherte cos-Funktion ergeben, für die optisch sichtbaren Kanäle 1, 2 und 3 zeigt die Funktion eine deutliche Abweichung von diesem Verlauf. In Bereichen mit flacher Einstrahlung ($i \sim 90^\circ$), also in Schattenbereichen oder in der Nähe des Grenzbereiches zu Schatten werden die Grauwerte bei kleinen Modellierungsfehlern rasch falsch korrigiert. Daher folgt eine nähere Betrachtung des mittleren Fehlers des Korrekturfaktors σ_K in Abhängigkeit von k und i:

$$\sigma_K = \pm \sqrt{\left(\frac{dK}{di} \right)^2 \sigma_i^2 + \left(\frac{dK}{dk} \right)^2 \sigma_k^2}$$

wobei für $\sigma_i = 0$

für $\sigma_k = 0$

$$\sigma_K = \left(\frac{dK}{dk} \right) \sigma_k$$

$$\sigma_K = \left(\frac{dK}{di} \right) \sigma_i$$

$$\frac{\sigma_K}{\sigma_k} = \left(\frac{dK}{dk} \right)$$

$$\frac{\sigma_K}{\sigma_i} = \left(\frac{dK}{di} \right)$$

Bei großem k und großem Einfallswinkel i wird das Verhältnis σ_K/σ_k schnell unendlich groß. Das Verhältnis σ_K/σ_i wächst mit dem Einfallswinkel auch gegen unendlich. Dies zeigt Abbildung 7, sie stellt den relativen mittleren Fehler des multiplikativen Korrekturfaktors K in Abhängigkeit von k und i dar.




Abbildung 7

Relativer mittlerer Fehler des multiplikativen Korrekturfaktors K in Abhängigkeit von der Minnaert-Konstante k und dem Einstrahlungswinkel i

Ist die Regressionsgerade definiert, kann die Berechnung des korrigierten Bildes erfolgen. Als Beispiel wird auf Abbildung 8 hingewiesen. Hier wird ein Waldausschnitt aus einer TM-Szene gezeigt, wo die Kanäle 5, 4 und 7 in rgb dargestellt sind. Bei visueller Betrachtung kann man im Vergleich des Originals und des korrigierten Bildes bereits feststellen, daß der 3-dimensionale Eindruck verringert wurde, das neue Bild erscheint um vieles flacher, d.h. die Grauwerte wurden homogener und heller. Das Ergebnis ist aber tendenziell leicht überkorrigiert.

Vergleich Original - Korrigiertes Bild

Kanalkombination rgb, 5,4,7

1 : 50000





Abbildung 8

Vergleich der Waldmaske des Originalen-TM Bildes mit dem topographisch korrigierten Bild

Zur Veranschaulichung dessen, was bei dieser topographischen Korrektur mit den Grauwerten tatsächlich passiert, dient Abbildung 9. Es werden 2 Wald-Testgebiete ausgewählt, ein Waldgebiet im Schatten und eines auf besonntem Gelände.

Klasse	Beschreibung
1o	Wald-dunkel <u>original</u>
2o	Wald-hell <u>original</u>
1k	Wald-dunkel <u>korrigiert</u>
2k	Wald-hell <u>korrigiert</u>




Abbildung 9

Mittelwerte der beiden „Wald“-Klassen in den Kanälen des Originalbildes und des korrigierten Bildes

Die unterste dunkle Linie stellt den Verlauf des Mittelwertes der Grauwerte des dunklen Originalbild-Waldes 1o in Abhängigkeit vom Kanal dar. Der „Wald“ im Schatten hat demzufolge auch die niedrigsten Mittelwerte.

Klasse 2o repräsentiert den hellen „Wald“ im Originalbild und hat deutlich höhere Mittelwerte. Zu erkennen ist, daß die punktierte Linie der Klasse 2k ganz knapp neben der der Klasse 2o verläuft, weil die besonnenen Waldgebiete nur sehr wenig bis gar nicht, gegebenenfalls im infraroten Bereich nach unten korrigiert werden. Auffallend ist, daß die Linie der korrigierten Klasse 1k zuerst im sichtbaren Spektralbereich höhere Grauwerte aufweist, im Kanal 4 und 5 sehr aufgehellt, aber doch etwas unter 2o und 2k liegt und im Kanal 7 wieder nahe zur Linie 2k wandert. Die Homogenität der Grauwerte wurde deutlich verbessert.

Eine Wiederholung der Klassifizierung auf dem topographisch korrigierten Bild führt zu einer deutlichen Verbesserung der Klassifikationsergebnisse. Da die Grauwerte bei der Topographischen Normalisierung verändert werden, ist eine Adaptierung der ursprünglich für die Klassifizierung verwendeten Trainingsgebiete notwendig oder man wählt neue Trainingsgebiete und reduziert ihre Anzahl erheblich. In der Literatur wird über Verbesserungen bei der Klassifikation und über die Einsparung der Trainingsgebiete von [Banko G., 1997], [Meyer P. et al., 1993], [Sandmeier S., 1997] und einigen mehr berichtet.

Als wirklich durchgreifend erfolgreich kann man die topographische Korrektur nicht bezeichnen, das Korrekturmodell ist dazu zu sehr vereinfacht. Einige physikalische Einflüsse wie das Himmelslicht, die Kalibrierung des Sensors, signifikante Abweichungen vom Lambertschen Strahler etc. werden darin nicht berücksichtigt. Es besteht die Aussicht, durch physikalische Modellierung dieser Einflüsse die Ergebnisse zu verbessern und auf ein physikalisch-basiertes Korrekturmodell zu hoffen [Sandmeier S., 1997], [Jansa J., 1998].

2.2 Interpretation von multispektralen Fernerkundungsdaten

Nach der geometrischen Rektifizierung der Fernerkundungsdaten und der Topographischen Normalisierung können multispektrale Daten aufgrund ihres spektralen Informationsgehaltes in verschiedene Landnutzungen klassifiziert werden.

2.2.1 Multispektrale Klassifizierung mit verschiedenen Wahrscheinlichkeiten

Multispektrale Bilddaten sind von einem Sensor aufgenommene, in mehreren Spektralkanälen vorliegende Aufnahmen. Die kleinste Einheit davon ist ein Bildelement. Ein Pixel dieses Bildes spiegelt die Reflexionscharakteristik eines Teiles der Erdoberfläche in einem bestimmten Spektralbereich wider. Wird ein Teil der Erdoberfläche durch mehrere Pixel in verschiedenen Spektralbereichen beschrieben, so spricht man von einer multispektralen Aufnahme. Verschiedene Objektklassen auf der Erdoberfläche weisen sehr unterschiedliche Reflexionseigenschaften auf. Deshalb unterscheiden sich Meßwerte, die ein multispektrales Fernerkundungssystem in verschiedenen Spektralbereichen aufnimmt, für bestimmte Objekte wie z.B. Boden, Vegetation und Wasser sehr deutlich.




Abbildung 10

Spektrale Reflexionsgrade verschiedener Oberflächen

(Nach E.L.Krinow, aus Schwidofsky 1976)

Definiert man nun einen Merkmalsraum, in dem die Meßwerte λ_1 , λ_2 und λ_3 die Grauwerte in den Kanälen 1,2,3 darstellen, so erhält man eine Punktverteilung wie in Abbildung 11 skizziert.




Abbildung 11

Merkmalsraum zur multispektralen Klassifizierung

[Albertz, 1991]

Die gemessenen Werte für die einzelnen Objektklassen liegen also in verschiedenen Bereichen des Merkmalsraumes. Mehrere Einzelmessungen fallen aber nicht in einem Punkt zusammen, sondern bilden wegen der verschiedenen heterogenen Klassenzusammensetzung, Streuungs- und Störeinflüsse einen Punkthaufen. Im Idealfall lassen sich zwischen diesen Punkthaufen eindeutige Grenzen ziehen. Damit ist der Merkmalsraum unterteilt und jedes Wertetripel λ_1 , λ_2 und λ_3 kann automatisch einer Objektklasse zugeordnet werden. Die Dimensionalität des Merkmalsraumes ist nicht beschränkt und hängt lediglich von der Anzahl der verwendeten Spektralbereiche ab. Als Ergebnis erhält man eine thematische Kartierung einer Szene [Albertz J., 1991], [Kraus K., 1990].

In der Praxis unterscheiden sich die Meßwerte der einzelnen Objektklassen nicht so signifikant wie im schematischen Beispiel angenommen, vielmehr berühren oder überschneiden sich die Punkthaufen in den Merkmalsräumen und sind auch sonst vielen Störeinflüssen ausgesetzt, sodaß zuerst geeignete Verfahren zur Datenvorverarbeitung und ausgewählte Klassifizierungsalgorithmen zu verwenden sind, um einigermaßen zuverlässige Ergebnisse zu erhalten.

Als Vorinformation muß bekannt sein, welche Objektklassen durch die Punkthaufen (*cluster*) im Merkmalsraum charakterisiert werden. Diese Punktwolken werden durch statistische Größen, wie Mittelwerte und die Varianz-Kovarianzmatrizen beschrieben. Die beiden Arten der Clusterbildung beschreiben die „überwachte“ und die „unüberwachte“ Klassifizierung.

Bei der unüberwachten Klassifizierung (unsupervised classification) hat man keine Referenzdaten und klassifiziert den gesamten Bildinhalt aufgrund der Grau- bzw. Farbwerte des multispektralen Bildes. Dazu werden zuerst automatisch die Cluster definiert, und dann erfolgt die Zuordnung der einzelnen Pixel über die Distanzfunktion zu den Clustern. Den Abschluß bildet die Zuweisung der Cluster zu den Objektklassen.

Bei der überwachten Klassifizierung (supervised classification) kennt man innerhalb eines jeden Objekttyps ein kleines Testgebiet, auch Trainingsgebiet genannt, welches ausschließlich Elemente einer Klasse enthält. Daraus definiert man die spektrale Signatur der Klasse, d.h. die statistische Beschreibung des aufgespannten Clusters. Anschließend wird jedes Pixel über eine Distanzfunktion, wie z.B.: Minimum Distance oder Maximum Likelihood einem Cluster zugeordnet.

Für beide Klassifikationsmethoden gilt nun, daß die Zuordnung der Klasse Aufgabe der Bearbeiterin bzw. des Bearbeiters des Bildes ist, einmal nach der Clusterbildung, bei der anderen Methode vor der Clusterbildung. Zudem ist die multispektrale Klassifizierung pixelorientiert, d.h. es wird pro Pixel eine Klasse zugewiesen, die Nachbarschaftsbeziehungen werden aber völlig außer Acht gelassen, worauf wir später zurückkommen.

Es gibt verschiedene Methoden, mit denen die überwachte Klassenzuordnung erfolgen kann, z.B. Minimum Distance, Klassifizierung mittels Quader, Methode der maximalen Mutmaßlichkeit (Maximum Likelihood) [Albertz J., 1991], [Kraus K., 1990] [Erdas, 1994]. Jene der Maximum Likelihood Klassifizierung soll hier behandelt werden, weil es jenes Verfahren ist, das zur Ermittlung der Oberflächenbedeckung aus Fernerkundungsdaten am häufigsten zum Einsatz kommt, da es eine gut fundierte theoretische Basis und einen klaren Ablauf hat:

Die Maximum Likelihood Methode berechnet zuerst die statistischen Kenngrößen wie Mittelwert der Grauwerte, Varianz-Kovarianzmatrix mit Korrelationskoeffizienten der Cluster aus den Grauwerten der Trainingsgebiete, und leitet daraus die Wahrscheinlichkeitsdichte folgendermaßen ab:

$$f(\mathbf{g}) = \left(\frac{1}{(2\pi)^{\frac{K}{2}} \sqrt{|\mathbf{C}|}} \right) e^{\left(-\frac{1}{2}(\mathbf{g}-\bar{\mathbf{g}})^T \mathbf{C}^{-1}(\mathbf{g}-\bar{\mathbf{g}}) \right)}$$

Glg 2.2.1-6

wobei

$\mathbf{g}$ = Grauwertvektor $\mathbf{g} = (g_1, \dots, g_k, \dots, g_K)^T$

$|\mathbf{C}|$ = Determinante der Varianz-Kovarianzmatrix (siehe Glg 2.2.1-7)

$\mathbf{C}^{-1}$ = Inverse der Varianz-Kovarianzmatrix

K = Anzahl der Kanäle des Multispektralbildes

und die Varianz-Kovarianzmatrix folgende Form hat:

$$\mathbf{C} = \begin{pmatrix} \sigma_1^2 & \dots & \sigma_{1K} \\ \vdots & & \vdots \\ & \sigma_{m,n} & \\ \sigma_{1K} & \dots & \sigma_K^2 \end{pmatrix}$$

Glg 2.2.1-7

In der Hauptdiagonale stehen die Varianzen σ_k^2 , das sind die Quadrate der Standardabweichungen. Außerhalb der Hauptdiagonalen sind die Kovarianzen angeordnet. Die Kovarianz $\sigma_{m,n}$ zwischen den Kanälen m und n ergibt sich wie folgt:

$$\sigma_{m,n} = \frac{1}{N-1} \sum_{i=1}^N (g_{m,i} - \bar{g}_m)(g_{n,i} - \bar{g}_n)$$

Glg 2.2.1-8

Für jedes Trainingsgebiet wird nun die Wahrscheinlichkeitsdichte $f(g)$ nach Glg 2.2.1-6 in der Form einer K-dimensionalen Normalverteilung berechnet. Für jedes zu klassifizierende Bildelement werden die Wahrscheinlichkeitsdichten $f(g)^i$ für alle durch Trainingsgebiete erfaßten Objektklassen ermittelt. Das zu klassifizierende Bildelement wird schließlich jener Objektklasse mit der größten Wahrscheinlichkeitsdichte zugeordnet.

Voraussetzung für diese Art der Klassifizierung ist die Annahme, daß die Grauwerte einer Klasse in jedem Spektralkanal normalverteilt sind. Wenn das tatsächlich zutrifft, ist diese Methode die zuverlässigste. Allerdings besteht die Gefahr, daß Klassen mit großen Werten in der Varianz-Kovarianzmatrix überklassifiziert werden. Das sind jene Klassen, deren Trainingsgebiete stark streuen, wie z.B. Stadtgebiete oder Wolken.

Um Rechenzeit zu sparen, müssen nicht die Wahrscheinlichkeitsdichten $f(g)^i$ (der Index i steht für die jeweilige Objektklasse) für alle Klassen mittels der Glg 2.2.1-6 vollständig ausgewertet werden. Es genügt vielmehr mit den Trennflächen, den Diskriminatoren, zu arbeiten, die durch Logarithmieren und Weglassen von Konstanten entstehen [Kraus K., 1990].

$$d^i = -\ln|C^i| - \frac{1}{2} (g - \bar{g}^i)^T (C^i)^{-1} (g - \bar{g}^i)$$

Glg 2.2.1-9

Vernachlässigt man dabei den ersten Term, der für alle Bildpixel einer Objektklasse gleich ist, und benutzt nur den Diskriminator, so erhält man die Mahalanobisdistanz:

$$h^2 = d^i = (g - \bar{g}^i)^T (C^i)^{-1} (g - \bar{g}^i)$$

Glg 2.2.1-10

Mit dem Wert von h und der Anzahl der Freiheitsgrade, die der Anzahl der Kanäle entspricht, kann man aus einer χ^2 -Verteilungs-Tabelle die Wahrscheinlichkeit interpolieren, mit der ein Pixel innerhalb einer Objektklasse liegt.

Da durch die multispektrale Klassifizierung die wichtigste Information aus dem Multispektralbild gewonnen wird und es besonders auf die Qualität dieser Klassifizierung ankommt, sollen die wichtigsten Arbeitsschritte hier näher beschrieben werden.

Als erster Schritt nach der Datenvorverarbeitung (Rektifizierung, Topographische Korrektur) müssen geeignete Trainingsgebiete gewählt werden. Dabei ist zu beachten, daß es besser ist, mehrere kleine homogene Trainingsgebiete zu suchen, als wenige große, die alle spektralen Streuungen einer Objektklasse abdecken. So ist es z.B. besser für „Wald“ im hellen Laubwaldbereich und im dunkeln Nadelwald einige Trainingsgebiete zu wählen. Für jede Ackerfläche, die einen anderen Farb- bzw. Grauton aufweist, soll ein eigenständiges Trainingsgebiet markiert werden, das in sich möglichst homogen ist. ERDAS-IMAGE bietet die

Auswahl der Trainingsgebiete durch Digitalisieren von Polygonen (AOI = Area of Interest) an, stellt aber auch ein Seed-Tool zur Verfügung, mit dem man ein einzelnes Pixel auswählen kann und dazu –mit einer bestimmt Standardabweichung- in der Umgebung automatisch die zugehörigen Pixel gesucht werden. Für sehr heterogene Gebiete, wie Stadtbereiche, ist dieses Seed-Tool ein sehr effizientes Werkzeug. Es ist jedoch zu beachten, daß durch die Vorgabe einer Standardabweichung die statistische Charakteristik des Clusters schon vorgegeben wird.




Abbildung 12
Seed Tool von Imagine

Zudem gibt es die Möglichkeit, das Multispektralbild in den K-dimensionalen Raum der Grauwerte, den Merkmalsraum zu transferieren, und im sogenannten „Features-Space“ einen Cluster zu definieren. Dazu läßt man sich die Grauwerte zweier Kanäle graphisch darstellen, d.h. man berechnet den „Feature-Space“ von zwei möglichst unkorrelierten Kanälen und definiert dann im Merkmalsraum, den die beiden Kanäle aufspannen, den Cluster, der ein bestimmtes Objekt beschreibt. Die Abbildung 13 zeigt den Feature-Space der Kanäle 4 und 5, die fast unkorreliert sind und im Vergleich dazu den Feature-Space der Kanäle 2 und 3, die stark korreliert sind. Damit kann man eine örtliche Festlegung der Trainingsgebiete umgehen [Erdas, 1994], [Kraus K.,1979].




Abbildung 13
Feature-Space der Kanäle 4 und 5


und Feature-Space der Kanäle 2 und 3

Das Multispektralbild wird nach der Maximum Likelihood Methode mit den Signaturen der trainierten Objektklassen klassifiziert, durch Berechnung der Wahrscheinlichkeitsdichten bzw. der Diskriminatoren aus Glg 2.2.1-9. Anschließend gibt es die Möglichkeit, das Histogramm der Pixelanzahl und die zugehörige Distanz jeder Klasse zu betrachten und unsicher klassifizierte Pixel in die Zurückweisungsklasse zurückzuweisen. Die folgende Abbildung 14 zeigt verschiedene Distanzhistogramme und deren Aussagen. Die Analyse dieser Distanzverteilungen kann sehr hilfreich für die Beurteilung der einzelnen Signaturen sein. Beim iterativen Auswählen und Definieren der Trainingsgebiete gibt diese Analyse Hinweise darauf, ob die gewählten Trainingsgebiete eine Klasse gut repräsentieren, oder ob zusätzliche Cluster definiert werden müssen, oder ob eine Klasse durch ihr Trainingsgebiet nur schlecht repräsentiert ist.

Stellt man nun fest, daß manche Signaturen eine schlechte Distanzverteilung haben oder viele Mischpixel einer falschen Klasse zufallen, so werden zusätzliche Trainingsgebiete ausgewählt und störende Signaturen, vor allem solche, die zu sehr streuen, eliminiert. Das Klassifizieren ist ein iterativer Prozeß und soll erst dann beendet werden, wenn man tatsächlich mit den Ergebnissen zufrieden ist, da die weitere Arbeit auf der Qualität dieser Auswertung aufbaut. Die Endauswertung kann (fast) nicht besser sein als die dazu verwendete multispektrale Klassifizierung [Sindhuber A., 1993].




Eine glatte χ^2 Kurve entspricht dem gewünschten Distanzhistogramm.



Kleine Spitzen in der polymodalen Kurve weisen darauf hin, daß der Klasse auch Objekte zugeteilt wurden, die nicht durch die Signatur repräsentiert werden. Für diese Objekte bedarf es einer zusätzlichen Signatur.



Die Signatur dieser Klasse repräsentiert möglicherweise eine polymodale Grauwertverteilung. Diese Signatur sollte durch eine neue bzw. mehrere Signaturen ersetzt werden.



Die Spitze ist vom Nullpunkt verschoben. Das weist darauf hin, daß der Mittelwert der Signatur nicht im Zentrum der repräsentierten Klasse liegt. Möglicherweise braucht man eine neue Signatur, die die Klasse besser repräsentiert.

Abbildung 14

Beispiele von Distanzhistogrammen aus [Erdas, 1994]

Viele Objektklassen können ohne Schwierigkeiten sicher getrennt werden. In diesem Projekt werden folgende Klassen ausgewiesen:

- Wasser
- Wald
- Grünland
- Besiedelt
- Acker
- Fels
- Gletscher

Die Klasse „Wasser“ ist die eindeutigste. Sie kann multispektral gut getrennt werden. Problematisch sind linienhafte Objekte, wie Flüsse, die zu schmal sind, um erkannt zu werden. Die Klasse „Wald“ ist multispektral auch gut zu erkennen, allerdings ist die Definitionsunsicherheit dieser Klasse groß. „Wald“ im ökologischen Sinne ist etwas anderes als „Wald“ im rechtlichen Sinne. In der Fernerkundung wird „Wald“ noch anders interpretiert. Ähnlicher Definitionsunsicherheit begegnet man bei der Abgrenzung von „Besiedelt“. Jede Interpretin und jeder Interpret wird in jedem Bild die Klasse „Besiedelt“ anders abgrenzen, unabhängig von Auflösung und Algorithmen. Es muß definiert werden, ob „Besiedelt“ nur aus Häusern, künstlichen Objekten und versiegelten Flächen besteht, oder ob angrenzende und umliegende Gärten wohl auch noch dieser Klasse angehören. Die Abgrenzung von locker bebauten Gebieten oder Streusiedlungen ist zudem sehr unklar. Bei der Texturanalyse (siehe Kapitel 2.3.3) werden Siedlungen und umliegende Gärten als hochtexturiert erkannt und dieser Klasse zugewiesen. Bei der multispektralen Klassifizierung kann es fallweise bei der Differenzierung von bebauten Gebieten und brachen Ackerböden zu Problemen kommen, da beide sehr ähnliche spektrale Signaturen aufweisen. Visuell ist es zwar meist möglich, beide Klasse aufgrund der Textur noch zu unterscheiden, auf spektraler Basis funktioniert diese Differenzierung manchmal nicht mehr einwandfrei. Außerdem ist zu beachten, daß die schlechte Bodenauflösung der Daten, mit denen die multispektrale Klassifizierung durchgeführt wird, die geometrische Qualität beeinträchtigt.

Das Klassifizierungsergebnis ist abhängig von den verwendeten Ausgangsdaten. Mit Landsat Thematic Mapper Aufnahmen, die eine spektrale Auflösung von 7 Kanälen haben, werden gute und brauchbare Ergebnisse erzielt. Wie die Corine-Klassifizierung [Aubrecht P., 1996] bestätigt und in [Stätter C et al., 1994] gezeigt wurde, können nicht nur die verschiedensten Landnutzungsarten, sondern auch verschiedene Ackerfrüchte, wie Mais, Zuckerrübe, Sonnenblumen, Erbsen, Getreide etc. identifiziert werden. Dazu werden mehrere Thematic Mapper Aufnahmen von verschiedenen Zeitpunkten (multisaisonal) verwendet.

Neben den Thematic Mapper Aufnahmen werden auch andere multispektrale Fernerkundungsaufnahmen wie die IRS-1C-LISS-Daten und SPOT-XS mit 3-4 Kanälen angeboten, mit 23.5 bzw 20 Meter Bodenauflösung. Die Differenzierung von „Wasser“, „Wald“ und „Grünland“ funktioniert sehr gut. Sollte man diese Klassen oder ähnliche suchen, so kann man diese mit einer relativ guten Bodenauflösung von ca. 20 bzw 25m extrahieren. Aufgrund der schlechteren spektralen Auflösung allerdings, können in diesen Daten die oben erwähnten brachen

Ackerböden nicht mehr von der Klasse „Besiedelt“ unterschieden werden. Die Trennung von „Besiedelt“ zu „Acker“ ist dann visuell schon sehr schwierig, obwohl hier auch die Textur vom menschlichen Interpreten einbezogen wird. Spektral unterscheiden sich die Grauwerte praktisch nicht mehr; sie eignen sich daher nicht für eine sichere Trennung.

2.2.2 Multispektrale Klassifizierung der TM-Daten

Die Thematic Mapper Daten wurden als multispektrales Klassifizierungsergebnis in die weitere Bearbeitung einbezogen. Deshalb soll der Ablauf dieser Klassifizierung anhand eines Beispiels näher beschrieben werden.

Da in den Bildverarbeitungssystemen meist nur die Klasse mit der größten Wahrscheinlichkeitsdichte ausgewiesen wird, wurde ein IMAGINE-Model erstellt, das die Klasse mit der größten und jene mit der zweitgrößten Wahrscheinlichkeitsdichte ausweist. Zusätzlich wurden die zugehörigen Mahalanobis-Distanzen berechnet. Der klassifizierte Ausschnitt der Thematic Mapper Szene umfaßt $745 \times 553 = 411985$ Pixel. Die abgeleiteten und für das DLM gewünschten Klassen sind „Wasser“, „Wald“, „Acker“, „Grünland“ und „Besiedelt“. Daraus sollen einige statistische Werte abgeleitet werden, um die grundsätzlichen Tendenzen einer Maximum Likelihood Klassifizierung und der Wahrscheinlichkeitstheorien aufzuzeigen.

Nicht nur die Klasse der größten Wahrscheinlichkeitsdichte wurde bestimmt, sondern auch jene der zweitgrößten Wahrscheinlichkeitsdichte. Um ein Maß zu finden, wie diese beiden Klassen zueinander stehen, also ob theoretisch beide Klassen wahrscheinlich sind oder ob die erste Klasse eindeutig, die zweite nur ganz unsicher zugewiesen wurde, wurde die Mahalanobisdistanz h aus der Gleichung 2.2.1-10 berechnet. Aus der χ^2 -Verteilung kann dann die Wahrscheinlichkeit entnommen werden, mit der ein Pixel in eine Klasse fällt. Dann werden beide Wahrscheinlichkeiten verglichen. Da diese Wahrscheinlichkeiten bei größerem h sich nur wenig unterscheiden, erscheint es nach einer Untersuchung sinnvoller, das Verhältnis der beiden Mahalanobisdistanzen zu untersuchen. Das Verhältnis zweier χ^2 verteilter Funktionen ist F-verteilt. Aus der Tabelle der Fischerverteilung kann man den Schwellwert für die entsprechenden Freiheitsgrade -in unserem Fall 6- herausnehmen, ab dem sich mit einer bestimmten Wahrscheinlichkeit das Verhältnis h_2^2/h_1^2 signifikant unterscheidet. Dieser Schwellwert ist mit 4,28 für eine Wahrscheinlichkeit von 95% sehr groß.

Die entsprechenden Werte für die Wahrscheinlichkeitsdichten, Mahalanobisdistanzen und deren Verhältnis für einige zufällig ausgewählte Pixel sind in der folgenden Tabelle ausgewiesen:

Klasse 1	Klasse 2	Wahrscheinlichk.dichte 1 1. f(g)*	Wahrscheinlichk.dichte 2 2. f(g)*	Mahalanobisdist. 1 h_1^2	Mahalanobisdist. 2 h_2^2	Verhältnis h_2^2/h_1^2
Wasser	Wasser	3	61	6	56	9,3
Stadt	Stadt	81	173	82	167	2,0
Wald	Wald	64	157	64	159	2,5
Acker	Acker	12	12	5	6	1,2
Acker	Stadt	6756	26718	6749	26712	4,0
Wald	Wasser	51	166	51	161	3,2
Wald	Wasser	99	117	99	112	1,1
Wald	Wasser	41	144	40	140	3,5
Stadt	Acker	187	349	181	342	1,9
Stadt	Acker	172	354	166	348	2,1
Stadt	Acker	86	326	80	319	4,0

Tabelle 2

* Diskriminator nach Glg 2.2.1-9

Da es mehrere leicht unterschiedliche Acker-, Wald-, Stadt-, etc. Trainingsgebiete und Signaturen gibt, liegen auch viele h^2 -Werte der ersten und zweiten Wahrscheinlichkeit sehr nahe beisammen. Das heißt, daß ein Pixel zuerst in „Acker1“ klassifiziert wird, mit einem h^2 -Wert von 5 und in „Acker3“ mit einem h^2 -Wert von 6. Da sich für diese Pixel die Objektklasse nicht ändert, werden in der Fortsetzung nur jene 31% der Pixel (siehe Tabelle 3) berücksichtigt, die in der ersten und zweiten Klassifizierung tatsächlich in zwei verschiedene Objektklassen fallen.

In der Tabelle 3 wird im grauen Feld die Anzahl der Pixel pro Klasse angegeben, dann die Anzahl jener Pixel, die bei der Klassifizierung nach der ersten und zweiten Wahrscheinlichkeitsdichte in der gleichen Klasse bleiben. Dann werden jene Pixel ausgewiesen, die ein Mahalanobisdistanz-Verhältnis größer als 4,28 aufweisen, und schließlich jene, deren h^2 -Werte aus den beiden Klassifizierungen sich um nicht mehr als das 4,28-fache unterscheiden und deren zwei zugeordnete Objekt-Klassen tatsächlich unterschiedlich sind. Das heißt, daß sich die Wahrscheinlichkeitsdichten der beiden Klassen für dieses Pixel sehr ähnlich sind und die Zuordnung dieses Pixels aus Sicht der Wahrscheinlichkeitsrechnung nicht ganz eindeutig ist.

Klasse	Anzahl der Pixel in 1. Wahrscheinlichk.		1. und 2. Wahrsch. in gleicher Klasse		Anzahl der Pixel, die in 2 verschiedene Klassen fallen			
		in %			$h_2^2/h_1^2 > 4,28$ sichere Zuweisung		$h_2^2/h_1^2 < 4,28$ unsichere Zuweisung	
Acker	107890	26%	66723	62%	33	0%	41134	38%
Wald	156727	38%	125739	80%	17047	11%	13941	9%
Besiedelt	20555	5%	1842	9%	3675	18%	15038	73%
Wasser	22959	6%	21843	95%	207	1%	909	4%
Grünland	103854	25%	69789	67%	3707	4%	30358	29%
Summe	411985	100%	285936	69%	24669	6%	101380	25%

Tabelle 3

Insgesamt können 25% der Ausgangspixel nicht signifikant bzw. nicht besser als $h^2_2/h^2_1 = 4,28$ klassifiziert werden. Bei der visuellen Betrachtung des Ergebnis-Bildes kann man wohl erkennen, daß auch die Mischpixelproblematik zu einem großen Teil hier einfließt, da vor allem schmale, linienförmige Objekte, wie die Autobahn, ein Fluß, Ackergrenzen und ähnliches als unsicher klassifiziert aufscheinen. Erwartungsgemäß ist der Anteil an „unsicheren Pixel“ an der Klasse „Wasser“ mit 4% sehr gering, während z.B: 73% der Klasse „Besiedelt“ nicht zuverlässig eindeutig von anderen Klassen getrennt werden können.

Auf diese Weise erhält man zwei Klassifikationsergebnisse, ein Ergebnisbild mit Klassen größter Wahrscheinlichkeitsdichte, und ein Ergebnisbild mit Klassen zweitgrößter Wahrscheinlichkeitsdichte. Durch das Verhältnis von h^2_2/h^2_1 wird zusätzlich eine Aussage über die Wahrscheinlichkeitsunterschiede gemacht, mit der beide Klassen zugeordnet wurden. Sollte nun für ein Pixel die Klasse zweiter Wahrscheinlichkeitsdichte nur sehr unsicher zutreffen, gilt nur die erste Klassifizierung; in der zweiten Klassifizierung wird das Pixel zurückgewiesen und auf Klasse 0 gesetzt.




Abbildung 15

Klassifizierung eines TM-Ausschnittes mit Klassen erster Wahrscheinlichkeitsdichte oben, Klassen zweiter Wahrscheinlichkeitsdichte unten

2.3 Analyse der panchromatischen Daten

Panchromatische Aufnahmen sind einkanalige Grauwertbilder, die in jedem Pixel die Remission des entsprechenden Objektes über eine größere spektrale Bandbreite zusammengefaßt repräsentieren. Dadurch, daß die gesamte Bandbreite der Strahlung aufgenommen wird, kann der erfaßte Objektbereich sehr klein für eine Information am Sensor gewählt werden. Darin ist auch der Grund zu sehen, warum es zur Entwicklung „hochauflösender“ panchromatischer Aufnahmen gekommen ist. Derzeit gibt es hochauflösende panchromatische Aufnahmen vom IRS-1C mit 5,8x5,8 Meter Auflösung und panchromatische SPOT-Aufnahmen mit einer Pixelgröße von 10x10 Meter am Boden. Panchromatische Daten von 1 bis 3 Meter Bodenauflösung sind angekündigt. Wann es sie tatsächlich geben wird, kann derzeit nicht abgeschätzt werden; eine Übersicht ist im Anhang unter 8.1 zu finden.

Aus diesen panchromatischen Daten sind Informationen automatisch zu extrahieren. Da die gesamte reflektierte spektrale Information in einem einzigen Grauwert aufgenommen wird, klassifiziert man diese Bilder nicht wie multispektrale Aufnahmen. Vielmehr versucht man eine bessere Adaption der lokalen Gegebenheiten zu finden. Man wird etwa untersuchen, ob es eine Klasse gibt, die sich aufgrund ihrer Grauwerte vom Rest des Bildes abhebt, und versuchen, diese mit Schwellwertoperationen hervorzuheben. Weiters fallen in panchromatischen Bildern auch Texturmerkmale auf, die es zu extrahieren und zu bewerten gilt.

Als Testbild soll eine panchromatische, hochauflösende Aufnahme des IRS-1C (IRS-1C-Pan) dienen. Diese Aufnahme hat eine Bodenauflösung von 5,8 m und deckt den Spektralbereich von 500-750 nm, d.h. vom sichtbaren grünen Licht bis zum nahen Infrarot, ab. Diese IRS-1C-Pan Aufnahme stammt vom 9. August 1996. Das Testgebiet ist wieder das Gebiet zwischen Attersee und Traunsee bei Gmunden, im Norden der ÖK50, Blatt 66.

2.3.1 Filterung

Bevor die Textur eines Bildes untersucht werden kann, ist eine Bildvorverarbeitung zweckmäßig. Abhängig von der jeweiligen Bildqualität ist ein wichtiger Schritt, für einkanalige, panchromatische Bilder eine Filterung durchzuführen, ohne dabei signifikante Grauwertsprünge zu eliminieren. Unter „Rauschen“ versteht man eine statistische Unsicherheit der Grauwerte. Je stärker das ursprüngliche Bild verrauscht ist, desto wichtiger ist eine Verringerung dieser unerwünschten Grauwertschwankungen. Durch geeignete Filteroperationen versucht man, diese Grauwertschwankungen in jenen Bildbereichen zu verringern, die ohne überlagertes Rauschen einen homogenen Grauwert hätten. Den wahren Grauwerten ist dort ein zufälliger Fehler aufgeprägt. Die Streuung der Grauwerte in homogenen Gebieten soll verkleinert werden [Kerschner, 1995].

Der einfachste Ansatz zur Glättung eines Bildes ist die gleitende Mittelwertbildung. Der neue Grauwert eines Pixels ergibt sich dabei als arithmetisches Mittel aller Grauwerte in einer bestimmten Umgebung. Der Glättungseffekt ist umso größer, je größer die Filtermatrix ist. Mit diesem Filter erreicht man in homogenen Gebieten den gewünschten Effekt. Als Vorbereitung

für Texturberechnungen ist das Mittelwertfilter als genereller Tiefpaßfilter allerdings ungeeignet, da auch über große Grauwertsprünge der Mittelwert berechnet wird und so Kanten im Ergebnisbild in texturierten Gebieten stark verschwommen wirken.

Es gibt eine Reihe von „kantenerhaltenden Glättungsfiltern“ (engl.: ‘edge-preserving smoothing’), die in homogenen Bildbereichen das Rauschen möglichst gut unterdrücken und gleichzeitig versuchen, die Grauwertkanten in ihrer ursprünglichen Schärfe zu erhalten. In [Abramson, Schowengerdt, 1993] wurden sechs solcher Filter an künstlich erzeugten Mustern und an natürlichen Satellitenbildern getestet. Die Ergebnisse wurden nach statistischen Methoden untersucht. Es wurde geprüft, wie gut Kanten, speziell auch dünne Linien, erhalten bleiben und ihr Glättungserfolg bewertet. Die besten Ergebnisse wurden durch die Filterung mit dem Sigma-Filter [Lee, 1983] erzielt.

Das Prinzip des Sigma-Filters ist folgendes: Man führt die Grauwerte eines homogenen, aber verrauschten Gebietes zurück auf den dieses Grauwertniveau beschreibenden Grauwert $\bar{g}$, der von einem Rauschen mit der Standardabweichung σ überlagert ist. Bei der Filterung wird eine Umgebung um jedes Pixel betrachtet (z.B. eine 3x3 oder 5x5-Pixel-Umgebung). Der neue Grauwert des Zentralpixels ergibt sich aus der Mittelwertbildung mit den Grauwerten $g_{i,j}$ jener Pixel der Umgebung, die mit einer bestimmten statistischen Wahrscheinlichkeit ebenfalls zu diesem Niveau gehören. Diese Bedingung läßt sich mathematisch wie folgt formulieren:

$$|g_{i,j} - \bar{g}| \leq N \cdot \sigma$$

Glg 2.3.1-1

Darin ist der wahre Grauwert des Niveaus $\bar{g}$ unbekannt. Man verwendet statt dessen den Grauwert des Zentralpixels. Der Faktor N beschreibt die Größe der Zone in der Normalverteilungsfunktion des geschätzten Rauschens, innerhalb derer der Grauwert des Nachbarpixels berücksichtigt wird. D.h. die Differenz $|g_{i,j} - \bar{g}|$ muß innerhalb der N -fachen Standardabweichung σ liegen, damit $g_{i,j}$ zur Mittelwertbildung herangezogen wird. Die Grauwerte der anderen Nachbarpixel werden bei der Mittelwertbildung nicht berücksichtigt. Sie gehören offenbar einer anderen statistischen Grundgesamtheit an. Die Wahrscheinlichkeit, die Nachbarn, welche zum selben Grauwertniveau gehören, auch wirklich zur Mittelwertberechnung zu verwenden, beträgt für $N = 1$, 68%, für $N = 2$, 95.5 %, und für $N = 3$, 99.7%.

Liegen nur ein oder zwei Pixel innerhalb der oben definierten Grauwertzone, handelt es sich beim Zentralpixel vermutlich um einen Ausreißer. In diesem Fall ergibt sich der neue Grauwert als Mittelwert aller Nachbarn der jeweiligen Umgebung. Dadurch werden „spikes“ eliminiert, das sind helle Punkte in dunklen Bildbereichen oder umgekehrt.

Der Nachteil des Sigma-Filters liegt darin, daß eine gute Kenntnis der Grauwertverteilung im Bild notwendig ist, um brauchbare Ergebnisse zu erzielen. Die Wahl der Zone $N \cdot \sigma$ bereitet dabei die größte Schwierigkeit. Sie muß unbedingt kleiner sein, als der kleinste Kontrast einer Kante oder einer Textur, die noch erkannt werden soll. Umgekehrt führt eine zu vorsichtige Wahl dieser Schranke nicht zum optimalen Glättungserfolg. Außerdem ist in den wenigsten Fällen die Wahl dieser Schranke für das ganze Bild gültig. Vielmehr wäre der Parameter für die einzelnen

Bildteile adaptiv anzupassen. Der Wert der Schranke ist entweder empirisch auszuloten, oder es erfolgt die relativ schwierige Abschätzung der Rauschvarianz eines Bild-(ausschnitt)-es.

Für die Bestimmung der Rauschvarianz betrachtet man das beobachtete Signal g , den Grauwert im Bild. Das Signal g setzt sich aus dem aufgenommenen Signal f (function) und dem Rauschen n (noise) zusammen. Die Varianz σ_g^2 des Signals ergibt sich daher wie folgt aus den Varianzen σ_f^2 und σ_n^2 :

$$g = f + n$$

Glg 2.3.1-2

$$\sigma_g^2 = \sigma_f^2 + \sigma_n^2$$

Glg 2.3.1-3

Der Rauschanteil n muß nun abgeschätzt werden. Unter der Annahme, daß das Rauschen normalverteilt ist, und zwar mit dem Erwartungswert 0 und der Varianz σ_n^2 , und daß das Rauschen unabhängig vom Signal ist, ist die erste Ableitung der Grauwertfunktion ebenfalls normalverteilt.

$$g'(x) = dg(x) / dx = f'(x) + n'(x)$$

Glg 2.3.1-4

Da die erste Ableitung $g'(x)$ in homogenen Gebieten gleich Null sein sollte, weil dort die Differenz der benachbarten Grauwerte eigentlich Null ist, wird in homogenen Gebieten $g'(x)$ vom Rauschanteil dominiert. Somit kann die Rauschvarianz abgeschätzt werden. Allerdings müßte man wiederum die Rauschvarianz kennen, um homogene Gebiete als solche auszuweisen. Daher wird die erste Näherung für σ_n^2 aus dem Histogramm aller ersten Ableitungen berechnet, was zu einem zu pessimistischen Ergebnis für die Rauschvarianz führt. Aber daraus kann wiederum die Schranke abgeleitet werden, wie groß die Grauwertdifferenzen für homogene Gebiete sein darf. Mit dieser ersten Schätzung für die Rauschvarianz werden nun die ersten Ableitungen für tatsächlich homogene Gebiete bestimmt, um daraus die Rauschvarianz neu und genauer zu berechnen. Die Details dieser Abschätzung der Rauschvarianz finden sich in [Förstner 1991, Seite 30 ff].

Die IRS-1C-Pan-Aufnahme ist stark verrauscht und muß vor der weiteren Bearbeitung gefiltert werden, um das Rauschen einigermaßen zu eliminieren und in homogenen Gebieten gleiche Grauwerte zu erhalten. Gleichzeitig mit der Glättung sollen die Grauwertsprünge an Kanten und in hochtexturierten Gebieten erhalten bleiben, da diese bei den weiteren Texturbearbeitungen eine wichtige Aussagekraft haben. Deshalb wird das Bild mit dem oben beschriebenen Sigma-Filter gefiltert. In einer lokalen Umgebung werden die Grauwertdifferenzen zum Mittelpixel untersucht. Wenn alle Grauwertdifferenzen unter der abgeschätzten Standardabweichung des Rauschens liegen, wird dem Mittelpixel des Berechnungsfensters der Mittelwert der betrachteten Grauwerte zugeordnet. Wenn durch das Beobachtungsfenster ein Grauwertsprung durchgeht,

dann wird der Mittelwert jener Grauwerte berechnet, deren Differenz zum Mittelpixel unter der N-fachen Standardabweichung des Rauschens liegen und dem mittleren Pixel zugeordnet. Die Größe der Filtermatrix kann frei gewählt werden, wird aber zwischen 3x3 und 5x5 Pixel liegen. Diese Aufnahme wurde mit einem 5x5 Fenster gefiltert, damit der hohe Rauschanteil aus den homogenen Gebieten herausgefiltert wird. Eine weitere Filterung mit einer 3x3 Matrix wurde zwar versuchsweise durchgeführt, wies aber keine sichtbare Verbesserung des gefilterten Bildes mehr auf. Die abgeschätzte Rauschvarianz des IRS-1C-Pan-Bildes betrug in zwei verschiedenen Bildausschnitten $\sigma_n^2 = 38.10$ und $\sigma_n^2 = 38.70$. Als Schwellwert für das Sigma-Filter wurde die dreifache Standardabweichung gewählt, d.h. mit $N \cdot \sigma = 3 \cdot \sqrt{38.4} \approx 19$ wurde das Sigma-Filter angewandt.

Die folgende Abbildung zeigt eine deutliche Glättung in homogenen Bildbereichen, z.B. in den Ackerflächen. Allerdings bleiben hochtexturierte Gebiete, wie die Siedlungsgebiete als solche erhalten. Offensichtlich liegt auch die Textur in den Waldbereichen innerhalb des Rauschens, und wird daher weggefiltert. Dies ist nicht allzu verwunderlich, da die natürliche Textur des Waldes sich im wesentlichen aus dem Kronenabstand ergibt, der normalerweise bei etwa 5-6 Metern liegt. Da dies mit der IRS-1C-Pan Auflösung übereinstimmt, ist eine echte Waldtextur nicht zu erwarten. Man sieht zufällige Texturen bzw. Verflechtungseffekte, die durch Überlagerung der Bildauflösung mit der Texturfrequenz des Waldes zustande kommen.




Abbildung 16

1 : 10000

Gegenüberstellung des Ausgangsbildes IRS-1C-Pan zum gefilterten Bild

2.3.2 Segmentierung

Unter Bildsegmentierung versteht man Verfahren, welche ein Bild in zusammengehörende, in Bezug auf gewisse Charakteristika homogene Bereiche unterteilen. Die Segmentfestlegung kann auf verschiedene Arten erfolgen:

- Clusterbildung
- Begrenzungslinien, die verschiedenartige Flächen voneinander trennen
- Schwellwertoperationen, worauf wir uns beschränken.

Schwellwertoperationen sind eine sehr einfache Form der Segmentierung. Mit Schwellwertoperationen werden Grauwertintervalle zu einem einzigen Grauwert zusammengefaßt. Sie können dazu dienen, die mehr oder weniger großen Abweichungen innerhalb der Grauwerte einer Objektklasse (z.B. von Landnutzungsarten) zu einem Grauwert bzw. einer Klasse zu vereinen.

Diesen Schwellwertoperationen können auch bildvorverarbeitende Schritte vorausgehen, sodaß die Schwellwertoperationen komplexere Strukturen annehmen. So ist es z.B. angebracht, auch die Umgebung eines Pixels zu untersuchen, bevor es aufgrund seines Grauwertes einer Klasse zugeordnet wird. In einer Matrix ausgewählter Größe, dem „focal window“, werden also statistischen Größen wie

- Mittelwert
- Standardabweichung
- Minimaler Grauwert
- Maximaler Grauwert

gesucht. Dann können Objektklassen, mit einem bestimmten Schwellwertbereich für den Mittelwert des Grauwertes, die dazugehörige Varianz, dem maximalen Grauwert und dem minimalen Grauwert im untersuchten Fenster definiert werden. Sollten diese Spezifikationen nicht ausreichen, kann man diese Parameter auch noch für verschiedene Umgebungsgrößen berechnen.

Mit Hilfe von Schwellwertoperationen können in der panchromatischen IRS-1C-Pan-Aufnahme die Klassen „Wald“ und „Wasser“ relativ gut von „Nichtwald“ unterschieden werden. Dazu wurde ein IMAGINE-Model erstellt, das in ausgewählten Untersuchungsgebieten die Statistik der Grauwerte, wie Mittelwert, Standardabweichung, Differenz des maximalen minus minimalen Grauwertes berechnet. Für diese Parameter werden Regeln aufgestellt, die dann iterativ verbessert werden und schließlich die verschiedenen Klassen ableiten.

Als Beispiel für diese Aufnahme werden die Parameter für die Klasse „Wald“ aufgelistet. Ein Pixel der IRS-1C-Pan-Aufnahme ist „Wald“, wenn folgende Bedingungen erfüllt sind:

Untersuchungsgröße 5x5 Pixel	Unterer Schwellwert	Oberer Schwellwert
Focal Max minus Min	0	14
Focal Mittelwert	70	97
Focal Standardabweichung	1.1	2.5

Tabelle 4

Durch die Mittelwertbildung und die anschließende Schwellwertanalyse werden Wälder, die in

der Umgebung von hellen Ackerflächen liegen, eng und exakt abgegrenzt. Solche, die in geringem Acker-Wald Kontrast eingebettet sind, werden unsicherer abgegrenzt. Daraus entsteht eine Ungenauigkeit der Waldabgrenzung, wie in Abbildung 17 veranschaulicht wird. Diese Abbildung zeigt den Verlauf von möglichen Grauwertprofilen zwischen den Klassen „Wald“ und „Acker“, und die Auswirkung einer Schwellwerttoleranz auf die geometrische Genauigkeit der Waldgrenze. Zusätzlich spielt auch der Waldschatten eine große Rolle bei der Waldabgrenzung. Je mehr die Waldgrenze von der Sonne abgewendet ist, und je höher die Waldbäume und je niedriger der Sonnenstand ist, desto größer wird der Schatten sein. Wenn der Schatten als Wald abgegrenzt wird, ist die Waldgrenze um eben diesen verfälscht. Diese Ungenauigkeiten sind zumeist klein im Vergleich zur Definitionsunsicherheit der Klasse „Wald“.

Grauwertprofil




Abbildung 17
Schwellwertabgrenzung von Wald

Aus dieser „Wald“-Analyse mit IRS-1C-pan Daten kann ein Layer mit einer Pixelgröße von 5x5 oder 10x10m am Boden abgeleitet werden, der sämtliche Waldgebiete abdeckt. Hier wurde die Auflösung von 10x10m als angemessen empfunden, da die untersuchte Umgebungsgröße jeweils 5x5 Pixel, also 625m² betrug.

Die Abbildung 18 zeigt einen Teil des Waldlayers, der mit Hilfe von Schwellwertoperationen abgeleitet wurde. Am rechten Bildrand kann man durch die beabsichtigte Unterbrechung des Waldlayers die exakte Abgrenzung der Klasse „Wald“ gut erkennen. Vereinzelt fallen auch dunkle Ackerflächen in den Schwellwertbereich, diese müssen dann mit Hilfe der multispektralen Thematic Mapper Klassifizierung eliminiert werden, siehe Seite 46, „Verknüpfung verschiedener Fernerkundungsdaten“.




Abbildung 18

Waldlayer aus Schwellwertbildung in der IRS-IC-Pan Aufnahme

1 : 20000

2.3.3 Texturanalyse

Aus hochauflösenden panchromatischen Daten können Informationen sowohl mittels Texturanalysen wie auch durch Segmentierung gewonnen werden. Die Textur eines Bildes wird vom menschlichen Betrachter als „fein, grob, glatt, linienhaft, körnig, unruhig, etc.“ wahrgenommen und entsteht durch unterschiedliche statistische Eigenschaften von verschiedenen Bildregionen. Textur ist die lokale Eigenschaft eines Bildelementes. Deshalb sind Texturmaße immer abhängig von der Größe der beobachteten Umgebung [Moik, 1980]. Während ein einzelnes Pixel keine Texturinformation beinhaltet, erhöht sich die texturale Ausprägung mit zunehmender Zahl der betrachteten Bildelemente. Weist ein Bildausschnitt nur wenig Variation in den Grauwerten auf, so ist der Grauton die dominante Eigenschaft. Bei starken Grauwertschwankungen hingegen ist die Textur das vorherrschende Merkmal [Steinnocher, 1993]. Die Texturanalyse versucht eine Quantifizierung dieser Eigenschaften eines Bildes durchzuführen. Gesucht wird ein thematisches digitales Bild, dessen Klassenkategorien die Textur des Ausgangsbildes beschreiben.

Statistische Parameter wie z.B. Varianz oder Mittelwert sind einfach zu berechnen, treffen aber keine Aussage über die räumliche Verteilung der Grauwerte. Sie können aber durch Schwellwertbildung leicht weiterverarbeitet werden.

Statistische Parameter zweiter Ordnung unter Verwendung von Grauwert-Abhängigkeitsmatrizen (grey-level co-occurrence matrices) berücksichtigen sowohl die spektrale als auch die räumliche Verteilung von Grauwerten.

2.3.3.1 Inverse Difference Moment

Es gibt in der Literatur verschiedene Möglichkeiten die Texturen zweiter Ordnung zu berechnen. [Haralick et al., 1973] verwenden Grauwert-Abhängigkeits-Matrizen (GAM) zur Bestimmung texturaler Eigenschaften in einem digitalen Bild. Diese Matrix beschreibt die räumliche Beziehung von Grauwerten innerhalb eines Bildes. Sie beinhaltet die normierte Häufigkeit $p_{i,j}$, mit der zwei benachbarte Pixel mit den Grauwerten i und j in einem bestimmten räumlichen Abstand d und in einer bestimmten Richtung r im Bild auftreten. Die GAM ist somit eine Funktion über das Bild mit den Parametern d und r :
$$GAM = f(d, r, \text{Bild})$$

Die Reihenfolge der Grauwerte wird nicht berücksichtigt, d.h. $p_{i,j} = p_{j,i}$. Es handelt sich also um eine symmetrische Matrix. Die Ausdehnung der GAM ergibt sich aus dem Grauwertbereich des zu untersuchenden Bildes und entspricht der Anzahl der Grauwertsprünge im ursprünglichen Bild. Über statistische Ansätze läßt sich die enthaltene Information für unterschiedliche Richtungen (horizontal, vertikal, Hauptdiagonale, Nebendiagonale) in sogenannte Texturparameter quantifizieren. [Haralick et al., 1973] geben 14 solcher Texturparameter an, die sich aus einer GAM ableiten lassen. In dieser Arbeit wurde das „inverse difference moment“ (IDM) angewandt, das als geeignetstes Texturmaß [Steinnocher K., 1997] für diese Fragestellung vorgeschlagen wird.

$$\text{IDM} = \sum_{i=1}^{N_x} \sum_{j=1}^{N_y} \frac{1}{1 + (i-j)^2} \cdot p_{i,j}$$

Beim IDM gehen nicht nur die Anzahl der Grauwertsprünge, sondern auch die Größe der Grauwertdifferenzen, ausgedrückt durch den Term $(i-j)$, reziprok gewichtet in die Analyse ein. Das IDM reagiert daher sehr sensibel auf kleine Grauwertschwankungen. Hochtexturierte Gebiete werden durch einen kleinen Wert (inverse difference) ausgewiesen, in homogenen Gebieten wird der Wert dieses Maßes dagegen groß.

Allerdings weist die Textur eines Bildes nicht nur richtungsunabhängige homogene und inhomogene Flächen auf, sondern auch richtungsabhängige Kanten. Eine Kante hat in der Richtung, die parallel zu ihr verläuft, einen großen Wert, in alle anderen Richtungen quer zu ihr weist sie einen kleinen Texturwert auf. Die Addition dieser IDM-Maße für sämtliche mögliche Richtungen ergibt dann ein Texturbild, das für homogene Gebiete einen großen Wert aufweist und für hohe Textur einen kleinen Wert. Für Kanten, die nur in einer Richtung einen großen Wert, in alle anderen Richtungen aber einen kleinen Wert haben, resultiert ein Maß dazwischen. Da aber der Unterschied zwischen den Summen in den hochtexturierten Gebieten und bei Kanten oft verschwindend klein ist, können Ackergrenzen so nicht von hoher Textur in Stadtgebieten unterschieden werden. Daher werden die Differenzen der Maße zweier aufeinander normal stehender Berechnungsrichtungen gebildet. Für homogene Gebiete und texturierte Gebiete, die richtungsunabhängig einen großen, bzw. kleinen Wert haben, wird die Differenz gegen Null gehen, während die Differenz für Kanten, die in nur einer Richtung einen großen Wert haben, und sonst einen kleinen, einmal relativ größer sein wird. Zählt man nun zur Summe der Texturanalysen auch die Differenzen dazu, so fallen Kanten, die vorher störenderweise als hochtexturiert ausgewiesen wurden, in den Wertebereich von homogenen Gebieten, und können besser von hochtexturierten Siedlungsgebieten getrennt werden. Die Abbildung 19 zeigt die Pixel mit hoher Textur in Farbe, offensichtlich bleiben aber viele Kantenpixel dennoch ein Problem bei der Texturanalyse.

2.3.3.2 Förstner Operator

Als andere Art der Texturberechnung wurde mit dem Förstner Operator [Förstner 1991] gearbeitet. Diese Art der Texturanalyse gibt nämlich die wertvolle Zusatzinformation, ob ein Pixel in seiner Umgebung als homogen, als Punkt oder als Teil einer Grauwertkante erkannt wurde. Dabei werden in der Nachbarschaft (z.B. Umgebung von 5x5 Pixel) die Komponenten des mittleren Grauwertgradienten berechnet und daraus ein Maß für die Stärke und Isotropie der Textur abgeleitet. Zuerst werden durch Schwellwertvergleich für beide Maße signifikant texturierte Pixel markiert und homogene Gebiete von texturierten Gebieten unterschieden. Anschließend werden die texturierten Gebiete noch auf „Punkt“ oder „Kante“ untersucht. Auffällige Punkte weisen lokale Maxima im Texturmaß auf. Der Schwellwert für dieses Texturmaß muß aus der Verteilung der Grauwerte abgeleitet werden. Dieser Algorithmus kann nicht nur zur Extraktion von Punkten verwendet werden, sondern auch für die Suche nach Grauwertkanten: Kanten sind jene relativen Texturmaxima, deren Isotropie-Maße unter dem Schwellwert liegen. Der Wert für die Isotropie ist bei diesem Berechnungsalgorithmus zwischen

3 Verarbeitung im GIS

Aus dieser Arbeit soll ein Bodenbedeckungslayer für ein Geo-Informationssystem (GIS) hervorgehen, dazu werden GIS-Werkzeuge verwendet. Da zugleich topographische Daten, die in einem GIS verwaltet werden, miteinbezogen werden, soll schließlich eine Abklärung über Aufgaben und Möglichkeiten eines GIS gemacht werden. Zuerst erfolgt eine allgemeine Beschreibung von Geo-Informationssystemen, anschließend eine Literaturstudie zur Verknüpfung von Fernerkundungsdaten mit topographischen Daten mit Angaben zur Sicherheit und Vollständigkeit der Daten. Ausgehend davon werden alle verfügbaren Informationen aus den Fernerkundungsaufnahmen verknüpft.

3.1 Geographische Informationssysteme

Ein raumbezogenes Geo-Informationssystem dient der Erfassung, Speicherung, Verarbeitung und Darstellung aller Daten, die einen Teil der Erdoberfläche und die darauf befindlichen technischen und administrativen Einrichtungen, sowie ökonomische und ökologische Gegebenheiten beschreiben. Nach [Bill und Fritsch, 1991] ist ein Geo-Informationssystem ein rechnergestütztes System, das aus Hardware, Software, Daten und den Anwendungen besteht. Mit ihm können raumbezogene Daten digital erfaßt und redigiert, gespeichert und reorganisiert, modelliert und analysiert, sowie alphanumerisch und graphisch präsentiert werden.

Die GIS-Daten können in Form von Vektor- oder Rasterdaten verarbeitet werden.

Unter Vektordaten wird die auf Punkten beruhende Beschreibung von raumbezogenen Objekten verstanden. Ihre Grundelemente sind der Punkt, die Linie und die Fläche. Dazu können noch Nachbarschaftsbeziehungen, wie Anfangs- und Endpunkt einer Linie, sowie angrenzende Flächen angegeben werden.

Da die gesamten bisher verwendeten Fernerkundungsdaten als Rasterdaten vorliegen, sollen diese noch näher beschrieben werden. Die Rasterdatendarstellung bezieht sich direkt auf Flächen. Das geometrische Grundelement ist das Pixel. Rasterdaten kennen keine Unterscheidung nach Punkt, Linie oder Fläche, d.h. es existieren keine logischen Verbindungen zwischen den einzelnen Bildelementen. Rasterdaten enthalten lediglich Werte über Eigenschaften der Pixel, wie Grau- oder Farbwerte, Höhen, Emmissionswerte, Klassen u.a.

Entsprechend dieser Überlegungen kann ein GIS vektor- oder rasterorientiert sein. Die Vereinigung von vektor- und rasterorientierten Systemen stellt dann ein hybrides GIS dar [Bill und Fritsch, 1991].

Sachdaten sind thematische Daten oder Attribute, die nichtgeometrische Elemente, wie Texte, Zahlensammlungen, Meßwerte, Nummern, Namen, Eigenschaften etc. repräsentieren. Erst die Kombination von graphikbeschreibenden Daten und Sachdaten beschreibt ein Objekt.

Geo-Informationssysteme zeichnen sich durch die vielfältigen Arten der Datenanalyse aus. Die Analysen dienen der Gewinnung neuer Informationen, um Entscheidungsgrundlagen zur Verfügung zu stellen. Ihre Methoden reichen von geometrischen, logischen und relationalen Verknüpfungen der Daten bis hin zu statistischen Verfahren. Viele geometrisch-topologische

Texturanalyse mit Foerstner Operator




Abbildung 20

Visuelle Interpretation und Texturanalyse mittels Förstner Operator


Vergleich der Texturanalysen

1 : 25000



Kanten und Punkte extrahiert mit Foerstner Operator

■ Kanten
■ Punkte



Texturberechnung mit Inverse Difference Moment (IDM)

■ hochtexturiert1
■ hochtexturiert2
■ hochtexturiert3
■ hochtexturiert4

Abbildung 19

Gegenüberstellung von Förestner-Operator und IDM-Texturanalyse

0 und 1, daher ist die Wahl dieses Schwellwertes für Kanten auch nicht allzu kritisch, er wird aus empirischen Gründen auf 0.7 gesetzt. [Fuchs C., 1995], [Mischke A. und Rottensteiner F., 1997]. Damit ist es möglich, einen Texturlayer zu extrahieren, der das Bild in die Klassen „homogen“, „Punkt“ und „Kante“ einteilt.

Diese Zusatzinformation, ob ein Pixel in seiner Umgebung als homogen, als hochtexturierter Punkt oder als Teil einer Grauwertkante erkannt wurde, wird auch in der Bearbeitung weiterverwendet.

Für die Extraktion der Klasse „Besiedelt“ ist diese Klassifizierung der Textur gut geeignet, da die bebauten Gebiete durchwegs durch Punkte und Kanten beschrieben werden, die Ackergrenzen jedoch fast nur als Kanten ausgewiesen werden. Daher können zuerst in Gebieten mit vielen Förstner-Punkten mittels einem Majority-Filter die Kanten in der Nähe der Punkte von Punkten überschrieben werden. Wobei ein Majority-Filter ein Filter ist, das in der beobachteten Umgebung die Klasse der Mehrheit der Pixel (Majority) bestimmt, und diese Klasse dem Zentralpixel zuweist. Anschließend wird eine Expand-Funktion angewandt, die die gesamten Punkte expandiert, d.h. Punkte wachsen eine vorgegebene Anzahl von Pixel in ihre Nachbarschaft hinein, damit nicht nur Einzelpunkte entstehen, sondern geschlossene Gebiete als hochtexturiert markiert werden. Somit werden in Stadtgebieten die Kanten durch Punkte überschrieben. Zwischen den homogenen Räumen und den Ackerflächen bleiben jedoch die Kanten erhalten. Diese Expandfunktion wird durch eine Shrink-Funktion in den Außengrenzen wieder rückgängig gemacht und in der Folge werden nur noch die markierten Punkte als potentielle Stadtgebiete weiterverwendet. Probleme können in den Feldecken entstehen, wenn zuviele Eck-Pixel als Förstner-Punkte extrahiert wurden, da dort dann scheinbare Siedlungen entstehen.

Die folgende Abbildung 19 zeigt beide Texturberechnungen. Für die IDM-Analyse ist es nicht möglich, die Kanten zwischen den Äckern zu eliminieren, bzw. von den Gebieten innerhalb hochtexturierter Flächen zu trennen, während der Förstner-Operator die gefundenen Texturelemente gleich in Punkte und Kanten trennt.

Die nächste Abbildung 20 zeigt die visuelle Interpretation im Vergleich zu den verarbeiteten Förstner-Punkten als Layer für die besiedelten Gebiete. Über die Vektoren der visuellen Interpretation sind die automatisch extrahierten Siedlungsgebiete in rot darübergerlegt.

Operationen im Umfeld von Rastermodellen können auf eine relativ kleine Anzahl von Grundoperationen zurückgeführt werden. Diese Grundoperationen zeichnen sich gegenüber Vektoroperationen durch ihre extreme Einfachheit aus. Eine genaue Beschreibung der elementaren Rasteroperationen kann man in [Bartelme, 1989] finden. Wichtig ist, daß es vier typische Klassen von Operatoren gibt, die sich aus deren Einzugsbereich ergeben: lokal, fokal, inkrementell und zonal.

Bei der Erfassung raumbezogener Daten bedarf es einer kritischen Wertung der Qualität der Daten hinsichtlich ihrer Eignung und Zuverlässigkeit. Für originär ermittelte Daten durch Vermessung, Photogrammetrie und Fernerkundung sind Genauigkeitsnachweise ableitbar, während für sekundäre Erfassungsmethoden selten Angaben zur Genauigkeit existieren. Diese Angaben zu Genauigkeit und Zuverlässigkeit sind aber für alle Daten dringend erforderlich!

Als allgemeine Ursachen für Fehler in raumbezogenen Daten sind unterschiedliches Alter, Generalisierung und verschieden dichte Gebietsbedeckung zu nennen, zudem gibt es Positionsungenauigkeiten, inhaltliche Ungenauigkeiten, sowie die natürliche Variation der Daten wegen Interpretation, Vergleichbarkeit und Auflösung.

Als schwierigstes Problem bei der Datengewinnung stellt sich die Datenverifikation dar. Das ist die Prüfung der Daten auf Vollständigkeit, Zuverlässigkeit, Korrektheit und Eindeutigkeit der Datenerfassung. Weiters ist die Datenaktualisierung von großer Bedeutung, damit die digitalen Daten den laufenden Veränderungen der erfaßten Objekte angepaßt werden.

3.2 Digitales Landschaftsmodell

Das digitale Landschaftsmodell (DLM) des Bundesamtes für Eich- und Vermessungswesen ist ein Modell, welches die Erdoberfläche nach topographischen Gesichtspunkten abbildet [Paul, 1997]. Es besteht aus Originärdaten in Vektorform, die nicht durch kartographische Bearbeitung, wie Generalisierung verändert wurden. Vor ihrer Erfassung müssen die topographisch relevanten Gegebenheiten auf klar definierte Elemente reduziert werden. Ein solches Element als kleinste Einheit heißt Objekt. Jedes Objekt ist ein konkretes, geometrisch begrenztes, durch Attribute beschriebenes und mit Namen versehenes Detail der Landschaft. Gleichartige Objekte werden zu Objektarten zusammengefaßt. Mehrere verwandte Objektarten bilden jeweils Objektgruppen, aus denen als höchste Ebene dieser Begriffshierarchie die Objektbereiche entstehen. Im Objektartenkatalog ist die Strukturierung sowie die Klassifizierung der topographischen Erscheinungsformen niedergeschrieben. Der Objektartenkatalog ist bezüglich weiterer Objekte offen und ergänzungsfähig. Derzeit modelliert das DLM die Erdoberfläche zweidimensional, wobei einzelnen Objekten Höhenattribute zugeordnet werden. Das Geländemodell wird im Objektbereich „Gelände“ vorläufig noch unabhängig von den restlichen Objektbereichen geführt. Für die nähere Beschreibung und die feinere Gliederung der Landschaftsobjekte werden Attribute eingesetzt. Neben dem Namen des Objektes und der Nummer des Blattes der ÖK50 ist jeder Objektteil noch mit drei Standardattributen versehen:

- Art der Datenerfassung
- Aktualitätsdatum
- Bearbeitungsdatum

Dann sind jedem Objektteil noch weitere, für die entsprechende Objektart spezifische Attribute zugeordnet. Die Anzahl der Attribute wurde wegen der Vielzahl der Möglichkeiten und dem damit verbundenen Arbeitsaufwand bewußt klein gehalten, ist aber jederzeit beliebig erweiterbar.

Die Abbildung 21 gibt einen Überblick über die Objektbereiche und Objektgruppen. Auf einige Objektbereiche soll noch kurz eingegangen werden:

Objektbereich **Verkehr**

Die Objektgruppe „Straßen“ besteht aus Autobahnen, Schnellstraßen, Auf- und Abfahrten, Zu- und Abfahrten zu Raststätten und Parkplätzen, Bundesstraßen, Landesstraßen und sonstige Straßen. Diese Objektgruppe ist flächendeckend erfaßt. Sie entstand aus einer Kombination von digitaler photogrammetrischer Luftbilddauswertung und Digitalisierung von Orthophotos. Die Attribute sind Straßenname, Straßenbezeichnung, Lage auf, über oder unter der Erdoberfläche (wie Brücke, Tunnel), Orts- oder Überlandsbereich. Die anderen Objektgruppen des Objektbereiches „Verkehr“ sind teilweise bereits erfaßt und befinden sich im Aufbau.

Aus diesem Objektbereich wurden die für die Rektifizierung der hochauflösenden Aufnahmen notwendigen Paßpunktfeatures extrahiert.

Objektbereich **Raumgliederung**

Vorerst befindet sich hier eine Verwaltungsgrenzendatei mit den Grenzen:

- Staatsgebiet
- Bundesland
- Vermessungsbezirk
- Gerichtsbezirk
- Ortsgemeinde
- Katastralgemeinde

die durch Digitalisierungen aus Karten im Maßstab 1:50000 gewonnen wurden.

Objektbereich **Gewässer**

Dieser Objektbereich ist flächendeckend erfaßt und konnte durch Vektorisieren der Gewässerfolie der ÖK50 gewonnen werden. Bei der Generalisierung für die ÖK50 wird die Lage des Gewässers vorrangig behandelt und daher nicht verdrängt.

Objektbereich **Bodenbedeckung**

Bei diesem Objektbereich soll für die Objektgruppe „Bodenbedeckungsflächen“ vorrangig die Fernerkundung eingesetzt werden. Das in dieser Arbeit beschriebene Verfahren soll zur Erhebung dieser Objektgruppe dienen. Des weiteren soll auch im Objektbereich Siedlung die Objektgruppe „Siedlungsflächen“ mit diesem Verfahren der Fernerkundung erhoben werden.

Objektbereich **Gelände**

In diesem Objektbereich befindet sich das digitale Geländemodell des BEV, welches auch zur Rektifizierung und topographischen Korrektur in diesem Projekt verwendet wurde.

Objektbereich Namen

Nach vollständigem Aufbau des DLM sollte jedem Objekt auch ein Attribut „Name“ zugewiesen sein. So wird dieser Objektbereich eigentlich redundante Information beinhalten. Diese Namen bieten allerdings die Möglichkeit ein gewünschtes Gebiet mit seinem Namen einfach und rasch anzusprechen.

Objektbereich: 1000 VERKEHR		
Objektgruppen:	1100	Straßen
	1200	Wege
	1300	Bahnen
	1400	Flugverkehr
	1500	Schiffsverkehr
	1600	Anlagen und Bauwerke für Verkehr, Transport, Kommunikation und Versorgung
Objektbereich: 2000 SIEDLUNG		
Objektgruppen:	2100	Siedlungsflächen
	2200	Betriebsflächen, Betriebseinrichtungen
	2300	Kultur
	2400	Freizeit und Sport
Objektbereich: 3000 RAUMGLIEDERUNG		
Objektgruppen:	3100	Verwaltungstechnische Gliederung
	3200	Schutz- und Sperrgebiete
Objektbereich: 4000 GEWÄSSER		
Objektgruppen:	4100	Fließende Gewässer
	4200	Stehende Gewässer
Objektbereich: 5000 BODENBEDECKUNG		
Objektgruppen:	5100	Bodenbedeckungsflächen
	5200	Einzelobjekte
Objektbereich: 6000 GELÄNDE		
Objektbereich: 7000 NAMEN		

Abbildung 21

Übersicht über die Objektbereiche und Gruppen

3.3 Verknüpfung verschiedener Fernerkundungsdaten

In den vorangegangenen Kapiteln wurde die Klassifizierung multispektraler Bilddaten behandelt. Auch die Texturauswertungen und Schwellwertanalysen des panchromatischen Datensatzes wurden bereits erläutert. Hier soll nun die Verbindung dieser Datensätze beschrieben werden.

Anfangs wird klargestellt, daß es nunmehr um die Verknüpfung thematischer Datensätze geht, also um Datensätze, die bereits aus den einzelnen Originaldatensätzen abgeleitet wurden. Es werden also geeignete Methoden und Regeln gesucht, diese abgeleiteten thematischen Daten miteinander zu verbinden. Einerseits soll eine neue, inhaltlich und geometrisch genaue Landnutzungsanalyse entstehen, andererseits sollen danach mit Hilfe der Zusatzdaten Veränderungen aufgezeigt und Klassifizierungssicherheiten ausgewiesen werden.

Folgende Datensätze aus der Fernerkundung werden mit den Daten aus dem DLM verknüpft:

Datensatz	Pixelgröße
Multispektrale Klassifizierung 1. Wahrsch.	25m
Multispektrale Klassifizierung 2. Wahrsch.	25m
Texturanalyse	hochauflösend (5m)
Schwellwertanalyse	hochauflösend (5m)

Tabelle 5

Da das Ergebnis der multispektralen Klassifizierung eine viel gröbere Auflösung hat als die extrahierten Layer der panchromatischen Aufnahmen, soll nun der Versuch unternommen werden, die multispektrale Klassifizierung mit hochauflösenden Informationen zu verfeinern und die viel genauere Lage der Objekte aus dem hochauflösenden Datensatz zu übernehmen. Dazu zeigt Abbildung 22 ein Ablaufdiagramm. Angenommen aus den panchromatischen Daten konnte ein Layer für die Klasse A herausgearbeitet werden. Auch in der multispektralen Klassifizierung gibt es eine Klasse A, diese soll durch die viel genaueren A-Grenzen aus der hochauflösenden Aufnahme ersetzt werden. Bisher wurden die Daten auf Pixelbasis bearbeitet. Nun muß man zusammengehörige Pixel zu Polygonen gleicher Klasse zusammenfassen, da nicht mehr das einzelne Pixel der Klasse A wichtig ist, sondern die genaue Lage der Fläche A. Damit man von der Pixelstruktur zur Polygonstruktur kommt, muß der hochauflösende thematische Layer zuerst vektorisiert werden, um so einen Datensatz geschlossener Polygone verschiedener Klassen und Attribute zu erzeugen. Dieser Vektor-Datensatz hat für jedes Polygon einen eindeutigen Namen, eine ID-Nummer. Anschließend wird berechnet, welche Klasse im gröber auflösenden Bild die dominierende innerhalb des entsprechenden hochaufgelösten Polygons ist. Diese Berechnung ist nötig, um die Übernahme eventueller Fehler in die Interpretation des panchromatischen Bildes auszuschließen. Wenn die Mehrheit der Pixel der Klassifizierung innerhalb des Polygons der Klasse A angehört, dann kann das Polygon als neue verfeinerte Klassengrenze der Klasse A übernommen werden. Der neu entstehende Datensatz muß eine entsprechend hohe Pixelauflösung haben, um dann ohne Verluste die verfeinerte Information aus dem genaueren Layer zu übernehmen. Im gröberen Datensatz werden sämtliche Pixel, die innerhalb der Polygone liegen, als Klasse A übernommen. Jene Pixel, die als Klasse A außerhalb der Polygone liegen, werden von Nachbapixel überschrieben. Damit wird der Datensatz zwar extrapoliert, da

es sich aber wegen der veränderten Pixelgröße in der Klassifizierung zumeist um sogenannte Subpixel handelt, ist das ohne Bedenken zulässig. Zusätzlich übernimmt diese Methode auch eine gewisse Kontrollfunktion, da Polygone, die im hochauflösenden Layer als Klasse A identifiziert wurden, nur dann übernommen werden, wenn auch die multispektrale Klassifizierung Klasse A ausweist. In einigen Fällen wird es außerdem notwendig sein, Polygone manuell zu verändern. Wo im hochauflösenden Bild schwer trennbare Flächen aneinander grenzen, z. B. „Wald“ und „Wasser“, folgt eine interaktive Polygonbildung. Abbildung 23 zeigt das Ergebnis der multispektralen Klassifizierung überlagert mit den Vektoren aus der Schwellwertanalyse der panchromatischen Aufnahme.




Abbildung 22

Ablaufdiagramm der Verknüpfung von multispektralen und hochauflösenden Informationen




Abbildung 23

TM-Klassifizierung überlagert mit Vektoren aus der hochauflösenden Aufnahme

Weiters ist es möglich, diese hochauflösenden Klassengrenzen mittels Snakes zu ermitteln. Snakes sind Kurven, die sich an einen Bildinhalt anpassen. Um mit Snakes aus dem hochauflösenden Bild eine Objektklasse zu extrahieren, braucht man Näherungen für die Lage dieser Objekte. Snakes nehmen diese Ausgangslage und versuchen in einem iterativen Prozeß, die endgültige Lage im hochaufgelösten Bild zu bestimmen. Die optimale Linie wird hier durch die Minimierung einer Energiefunktion $E_{\text{Snake}} = \int (E_{\text{int}} + E_{\text{Bild}}) ds$ gefunden. Die Bildterme E_{Bild} der Energiefunktion ziehen die Snake zu den Stellen im Bild, wo sich am wahrscheinlichsten eine Grauwertkante befindet. Die internen Terme E_{int} bewirken, daß die Kurve einen möglichst glatten Verlauf annimmt. Durch die Integration dieser Terme über die gesamte Länge s der Kurve und die Kombination beider Anteile der Energiefunktion können auch Stellen überbrückt werden, an denen die Bildkante unsicher ist.

Für diese Anwendung wird die Klasse A aus dem multispektralen Datensatz mittels Klassifizierung abgeleitet, vektorisiert und als Näherung für die Lage des Polygons im hochauflösenden Bild verwendet. Der Algorithmus dieser Snakes Interpolation sucht dann die entsprechende Lage dieses Objektes im hochaufgelösten Bild. Damit kann der schlechter aufgelöste Datensatz verfeinert werden, und geeignete Klassen können sehr genau aus dem panchromatischen Bild übernommen werden. Dieses Annähern der Snakes an eine Grauwertkante muß beobachtet werden, damit sie sich nicht „verirrt“. Dieses Verfahren ist ein halbautomatisches. Genaueres zur Methode der Snakes siehe [Kass, 1987] und [Kerschner, 1998]. Die Abbildung 24 zeigt die genäherte Lage der Snake in rot, das ist die entsprechende Waldgrenze aus der TM-Klassifizierung, in blau werden die Iterationen der Snake dargestellt, bis sie ihre endgültige Lage im panchromatischen Bild (in grün) gefunden hat.




Abbildung 24

Extraktion der Waldgrenze aus dem IRS-1C-PAN mittels Snakes

3.4 Fernerkundung und GIS

Viele Vorschläge zu Möglichkeiten und Methoden der wissensbasierten Integration von Fernerkundungsdaten in geographische Informationssysteme sind in der Literatur zu finden. Im folgenden werden Methoden gesucht, wie vorhandene Informationen aus GIS-Datenbeständen in die Klassifizierung von Satellitenbildern einfließen können. Die Anwendung solcher Verknüpfungen ist heute aktueller denn je, da einerseits eine Vielzahl von digitalen Datensätzen vorhanden ist und dazu verwendet werden kann. Andererseits werden neue Klassifizierungsmethoden, wie Fuzzy Logic und neuronale Netze, verwendet, um damit die Klassifizierung der Landnutzung zu verbessern. Es sollen Veränderungen gegenüber bestehenden Daten aufgezeigt werden und Informationen über die „Sicherheit“ einer Klassifizierung angegeben werden. In der Literatur findet man verschiedene Ansätze, wie sogenannte „Hilfsdaten“ zu einer Klassifizierung von Fernerkundungsdaten beigefügt werden können. Einige Vorschläge, sowie deren Vor- und Nachteile werden vorweg beschrieben, um dann die hier entwickelte Integration und Auswertung von GIS- und Fernerkundungsdaten vorzustellen.

3.4.1 Wissensbasierte Verknüpfung von GIS und Fernerkundungsdaten

Die „Klassifikation mit Hilfsdaten“ teilt [Hutchinson C, 1982] in 3 Kategorien, abhängig vom Zeitpunkt zu dem die Zusatzdaten zugefügt werden:

- a) Vor-Klassifizierung
- b) Modifizierung der Klassifikationsalgorithmen
- c) Postklassifizierung

Fall a: Die Benutzung von Hilfsdaten vor der Klassifizierung erlaubt die Aufteilung (Stratifizierung) des zu bearbeitenden Gebietes aufgrund eines ausgewählten Merkmals in kleinere homogene Bereiche. Dabei wird einerseits die Bearbeitung des Gebietes vereinfacht und andererseits können speziell spektral schwer differenzierbare Objektklassen schon von vornherein getrennt werden. Zudem wird angemerkt, daß die Verkleinerung der behandelten Arbeitseinheiten eine Reduktion der Variationen innerhalb einer Klasse und damit Vereinfachungen mit sich bringt. Das gewählte Kriterium zur Stratifizierung eines Gebietes muß signifikant mit der Variation der Objekte zusammenhängen. Zum Beispiel kann eine Vegetationsklassifizierung über verschiedene Höhenklassen in kleinere Einheiten aufgeteilt werden.

Für spektral schwer trennbare Objektklassifizierungen schlägt [Hutchinson C., 1982] vor, zuerst eine Vor-Klassifizierung mit Hilfe von Zusatzkarten, z.B. in Stadt- und Nicht-Stadt-Bereiche durchzuführen. Dann werden beide Gebiete unabhängig voneinander spektral klassifiziert und im Endergebnis wieder zusammengefügt.

Das Problem der Stratifikation liegt darin, daß Klassen schon von vornherein absolut und abrupt begrenzt werden, ohne Rücksicht auf Gradationen oder weiche, fließende Übergänge. Zudem müssen unbedingt in allen Teilen gleichwertige Trainingsgebiete gesucht werden, da sonst das Endergebnis nur sehr schwierig bis gar nicht

zusammengefügt werden kann. Außerdem muß ein geeignetes Kriterium zur Aufteilung des Gebietes gewählt werden, da sonst weitreichende Folgen entstehen und viele Schwierigkeiten eine sinnvolle Klassifizierung erschweren.

Fall b: Die Verwendung von Hilfsdaten während und zur spektralen Klassifizierung kann nach [Hutchinson C, 1982] so erfolgen, daß zu den spektralen Kanälen noch zusätzliche Informationen als logische Kanäle zugefügt werden. Dieser Ansatz ist uninteressant, da er zu schlechte bzw. unsichere Ergebnisse liefert. Für die Maximum Likelihood Klassifizierung wird nämlich eine Normalverteilung der Daten vorausgesetzt, was bei sämtlichen Zusatzinformationen nicht angenommen werden kann. Sinnvoller ist es, die Hilfsinformation für die apriori Gewichtung der Maximum Likelihood Klassifizierung einzuführen oder eine andere Art der Klassifizierung anzuwenden, wie zum Beispiel die Methode der neuronalen Netzwerke.

Fall c: Die Einbeziehung von Zusatzinformationen nach der multispektralen Klassifizierung beruht auf der Tatsache, daß Objektklassen nicht von einer einzigen spektralen Signatur repräsentiert werden, sondern daß mehrere Signaturen für eine Klasse ausgewählt werden müssen. Dies hat wiederum zur Folge, daß manche Signaturen nicht nur eine Objektklasse, sondern Teile aus zwei oder mehreren Klassen ausweisen. Diese „Problemklassen“ können dann mit zusätzlichen Hilfsdaten getrennt werden, wobei nur einfache rasterbasierte Operationen angewandt werden können.

[Bolstad P. et al., 1992] beschreiben ein Klassifikationsmodell, welches eine Folge von Operationen mit Bild- und Nicht-Bilddaten ausführt und eine Landnutzungsklassifizierung als Ergebnis liefert. Dieses Modell arbeitet mit verschiedenen Entscheidungskriterien und Operatoren, um die Klassen zuzuweisen. Für die Bearbeitung der Bilddaten gilt die Maximum Likelihood Klassifizierung als wichtigster Bestandteil. Als Beispiel wird eine Landnutzungsklassifizierung in 4 Klassen angeführt: „Besiedelt“, „Wald“, „Acker“ und „Wasser“. Dabei werden

- Daten über Bevölkerungsdichte verwendet, um urbane Gebiete herauszufinden,
- topographische Karten, um Wasser zu bestimmen, und
- spektrale Klassifizierung, um „Wald“ und „Ackerland“ zu differenzieren.

Die folgende

Abbildung 25 zeigt ein Ablaufschema eines Klassifikationsmodells, wobei Zeitpunkt und Art der Restriktionen von thematischen Karten, sowie von Bilddaten abhängig sind. Abbildung 26 zeigt einen Klassifizierungsablauf für eine Landnutzungsklassifizierung mit Kriterien für die Entscheidungsfindung.

Das Klassifizierungsmodell verwendet eine Menge von Operatoren, die als Klassifizierungsprimitive angesehen werden können. Dazu gehören Texturberechnungen, Mustererkennung, Maximum Likelihood Berechnungen, boolesche Verknüpfungen und andere, deren Reihenfolge und Kombinationen erst das Modell ausmachen.

Dieses Klassifizierungsmodell beinhaltet mehr als 200 Regeln. In der zusammengestellten Tabelle für Genauigkeiten und Effizienz wird ersichtlich, daß zusätzliche Informationen die Genauigkeiten um durchschnittlich 15 Prozent verbessern, obwohl der Aufwand für die Aktualisierung der Regeln (zumindest zeitlich) minimal ist.




Abbildung 25

Beispiel eines Klassifikationsmodelles [Bolstad P. et al., 1992]




Abbildung 26

Entscheidungsfindung für eine Klassifizierung [Bolstad P. et al., 1992]

Ein völlig anderer, aber äußerst interessanter Zugang wird von [Janssen L. und Middelkoop H., 1992] vorgeschlagen. Dabei geht es um die Klassifizierung einzelner Feldfrüchte bei bekannter Fruchtfolge. Aus den Fruchtfolgen vorangegangener Jahre wurde eine Fruchtfolgematrix bestimmt, die angibt, welcher Prozentanteil der Fläche einer bestimmten Feldfrucht im darauffolgenden Jahr mit einer bestimmten anderen Feldfrucht bestellt wird. Insgesamt wurden 5

Gruppen von Ackerfrüchten erhoben: Getreide, Kartoffen, Zuckerrüben, Gras und Alternativfrüchte (Erbsen, Bohnen oder Zwiebeln).

Zum Beispiel werden 69% der Kartoffeläcker im darauffolgenden Jahr mit Getreide bestellt. 67% der Getreideflächen werden dann mit Zuckerrüben bebaut, nur 27% der Getreidefläche werden mit Kartoffeln wiederbestellt. Nach den Zuckerrüben folgen mit fast gleichem 30 Prozentanteil entweder Getreide, Erbsen oder Zwiebeln. Auf Erbsen, Bohnen und Zwiebeln folgen mit fast 90% wiederum Kartoffeln.

[Janssen L. et al., 1992] integrieren diesen bekannten Fruchtfolgewechsel als Matrix, mit deren Hilfe sie a priori Gewichte für jedes Pixel in die Maximum Likelihood Klassifizierung einbringen. Obwohl die Gesamtgenauigkeit um nur ca. 3% zunimmt, ist das so erreichte Ergebnis deutlich besser als die Maximum Likelihood Klassifizierung ohne Zusatzinformationen, da die Verbesserungen zum größten Teil die sogenannten Mischpixel betreffen, die mit Hilfe der a priori Gewichte eindeutig einer Feldfrucht zugeordnet werden können.

3.4.2 Handhabung nicht perfekter Daten

Bisher haben wir uns mit Methoden der Klassifizierung und Verknüpfung der Daten ohne Berücksichtigung irgendeiner Zuverlässigkeit der Datenquellen oder der gewonnen Informationen beschäftigt. Doch fast jede Information, die wir über die reale Erde erhalten, ist unsicher, unvollständig oder unpräzise. Sich nur mit perfekten Informationen auseinanderzusetzen hieße daher, sich nur auf ein kleines Detailproblem zu beschränken. Vor allem in der Fernerkundung gibt es viele Informationen, die nicht ganz sicher, unvollständig und unpräzise sein können. In [Parsons S., 1996] findet man eine allgemeine Beschreibung und Klassifizierung nicht perfekter Daten in 3 Klassen: *unsicher*, *unvollständig* und *unpräzise*. Andere Klassifizierungen verwenden noch dazu die Kategorien *vage* und *inkonsistent*.

- Unvollständige Daten entstehen durch das Fehlen von Werten für gewisse Attribute. Für die Handhabung unvollständiger Daten wird sehr oft der sogenannte Null-Wert vorgeschlagen. Dieser Null-Wert steht dann für ein Attribut, das entweder unbekannt, undefiniert, unzutreffend oder nicht existent ist.

- Unpräzise Daten entstehen wegen der groben „Körnigkeit“ der Sprache, im Fall der Fernerkundung aufgrund des begrenzten Auflösungsvermögens der Aufnahmesysteme.

Eine Aussage, z.B. Simon ist 26 Jahre jung, ist nur dann präzise, wenn man sich für sein genaues Alter in Form von Tag, Monat und Jahr nicht interessiert. Wenn als anderes Beispiel die vage Information angegeben wird, Simon sei ziemlich jung, so kann damit sehrwohl eine Information über die Sicherheit der unsicheren Auskunft gewonnen werden, daß Simon 26 Jahre alt ist.

- Unsicherheit beschreibt wiederum einen Mangel an Information, der es nicht erlaubt, eine Aussage als wahr oder falsch einzustufen. Sie ist also subjektiv zu einem gewissen Grad. Es kann bestenfalls eine Tendenz abgeschätzt werden, ob etwas wahr oder falsch sein wird. Unsichere Information wird meist so behandelt, daß man einen Grad der Sicherheit beifügt, der wiederum ein subjektives Maß ist, ob etwas sicher oder unsicher ist, abhängig von der

Beobachtung und vom Beobachter einer Information. Es ist aber auch möglich, eine Variable mit einem Grad der Zugehörigkeit zu einer Klasse zu versehen [Parsons S., 1996].

- Inkonsistente Informationen entstehen durch Aussagen aus verschiedenen Quellen, die sich widersprechen. Die Behandlung inkonsistenter Daten kann nur über die Zurückweisung der unsichersten Information erfolgen.

3.4.3 Verknüpfung von GIS und Fernerkundungsdaten mit Angaben zur Sicherheit

Im Artikel von [Kontoes C. et al., 1993] wird das Experiment beschrieben, eine detaillierte Landnutzungsklassifizierung mit mono-temporalen Satellitenbildern und zusätzlichen GIS-Daten durchzuführen. Mono-temporale Satellitenbilder sind Bilder von nur einem einzigen Zeitpunkt, im Gegensatz dazu stehen die multi-temporalen Datensätze, in denen jedes Pixel zu mehreren Zeitpunkten beobachtet wurde.

Die vorhandene geographische Information wurde bei diesem Experiment in den Postklassifizierungsprozeß eingeführt. Verarbeitet wurden die Daten in ARC/Info.

Das wissensbasierte System führt zuerst eine Texturanalyse und eine multispektrale Klassifizierung der Bilddaten durch, und arbeitet anschließend mit einer Abfolge von Regeln. Dieser Regelkomplex ist auf der Dempster-Shafer Theorie aufgebaut, wo die Entscheidungsfindung aus einem Set von allen möglichen Attributen erfolgt und ist kombiniert mit einem „Zugehörigkeitsgrad“ pro Pixel, der ein Maß für die Sicherheit angibt, mit der eine bestimmte Klasse zugeordnet werden kann. Dieser Zugehörigkeitsgrad liegt im Bereich von $0 \rightarrow 1$ für eine Klasse, oder von $0 \rightarrow 1$ gegen eine Klasse. Der Vorteil der Dempster-Shafer Theorie liegt darin, daß nicht nur der Grad der Zugehörigkeit zu einer Klasse berechnet wird, sondern der Zugehörigkeitsgrad zu sämtlichen in Frage kommenden Klassen. Die Regeln beinhalten getrennte „Bedingung“- und „Aktion“- Teile.

Als Beispiel werden 3 Regeln angeführt, eine soll hier explizit gezeigt werden:

Bedingung:

- der dominante Bodentyp in den 4 benachbarten Pixeln ist „Kalkboden“
- die spektrale Klassifizierung ergibt „Mais“
- die Mehrheit in der 9x9 Umgebung des Pixels ist „Sonnenblume“

Aktion:

- weise die spektral zugeordnete Klasse „Mais“ mit 0.9 zurück (starke Nicht-Zugehörigkeit)
- Bestärke die Klasse „Sonnenblume“ mit dem Zugehörigkeitsgrad 0.9 (starke Zugehörigkeit)

Erklärung:

- Es gibt eine spektrale Konfusion zwischen „Mais“ und „Sonnenblumen“ im frühen Wachstumsstadium, besonders auf kalkhaltigem Boden, weil die Wasserrückhaltefähigkeit dort besonders gering ist. Diese Regel versucht daher falsch klassifizierte „Mais“-Pixel innerhalb von Sonnenblumenäckern zu eliminieren. Deshalb wird „Mais“ zurückgewiesen und „Sonnenblume“ stark unterstützt.

Abbildung 27 zeigt ein Ablaufdiagramm dieses Systems. Nachdem alle diese Regeln durchlaufen und die Zugehörigkeitsgrade bestimmt worden sind, wird mit Hilfe der Dempster-Shafer Theorie die Unterstützung und die Ablehnung pro Klasse errechnet, und jene Klasse zugewiesen, die die stärkste Unterstützung hat.

Das Regelwerk ist auf 52 Regeln aufgebaut. Die Genauigkeit des Endergebnisses wurde mit Hilfe der Zusatzinformationen und der Regeln um ca. 13% gegenüber der normalen Maximum Likelihood Klassifizierung verbessert.




Abbildung 27

Ablaufschema des wissensbasierten Systems [Kontoes C. et al., 1993]

3.5 Fernerkundungsdaten verknüpft mit vorhandenen GIS-Daten

Wie in den soeben beschriebenen Verfahren gibt es auch in dieser Arbeit verschiedene Datenquellen, deren Informationen nun verknüpft werden sollen. Im DLM des BEV und aus den Fernerkundungsanalysen stehen mehrere unabhängige Datensätze zur Verfügung. Wegen der Überbestimmung der Information und durch Verschneidung der vorhandenen topographischen Daten mit den neu gewonnenen Daten aus der Fernerkundung sollen nun Klassen mit Stufen verschiedener Sicherheit ausgewiesen werden. Pixel, die mit größter Wahrscheinlichkeitsdichte klassifiziert sind, die durch die Analyse des hochauflösenden Bildes bestätigt werden und deren Interpretation noch dazu durch die Daten des DLMs bestärkt werden, sind mit sehr hoher Sicherheit einer Klasse zuzuordnen. Für andere Pixel wiederum, die nicht so eindeutig klassifiziert werden konnten und keine Bestätigung aus dem DLM erhalten, muß ein Weg gefunden werden, sie einer Klasse zuzuweisen und die Zuverlässigkeit dieser Klasse zu dokumentieren.

Die Fernerkundungsdaten haben noch keinerlei Qualitätskriterium. Deshalb versuchen wir, Aussagen über die Zuverlässigkeit der Klassifizierung im Vergleich zu den bestehenden DLM-Daten und der daraus resultierenden Überbestimmung zu erhalten und außerdem Veränderungshinweise herauszuarbeiten. Das heißt, es ist noch nicht bekannt, ob die Daten und damit die Interpretation des einzelnen Pixels richtig oder eher zweifelhaft ist. Damit nun nicht jedes einzelne Pixel visuell nachkontrolliert werden muß, soll eine Möglichkeit gefunden werden, die Daten auf die Zuverlässigkeit ihrer richtigen Interpretation oder auf die Veränderung zum alten Datenbestand zu überprüfen.

Ziel ist es, versuchsweise alle Daten des DLM zu integrieren und einen Datenbestand mit großer Sicherheit und guter Differenzierung abzuleiten.

3.5.1 Erstellung der Regelbasis

Die Erstellung des Regelsystems erfolgt durch eine Expertin oder einen Experten. Dazu Bedarf es eines guten Überblicks, welche Information mit welcher Genauigkeit aus den verschiedenen Datensätzen gewonnen werden kann. Grundsätzlich sollen alle verfügbaren Datensätze miteinander kombiniert werden, außerdem muß die Sinnhaftigkeit der einzelnen Konditionen gewährleistet sein. Ein einmal erstelltes System sollte für gleiche Datensätze aus anderen Gebieten wieder verwendet werden können. Dazu empfiehlt es sich, die Klassifizierung der multispektralen Daten auf wenige wichtige Klassen zu reduzieren. Allerdings geht dabei die Möglichkeit verloren, Problemklassen individuell zu behandeln, weil nicht mehr direkt auf die Ausgangsklassen zugegriffen wird. Ein alternativer Weg, der erfolgreich angewandt wurde, ist, nur eindeutige, gut gewählte Klassen zusammenzufassen. Die Problemklassen aus der Maximum Likelihood Klassifizierung werden dann extra behandelt und bleiben daher bestehen. Für diese Klassen kann und muß damit individuell eine Regel mit zu erfüllenden Bedingungen gefunden werden, die in das Regelsystem an geeigneter Stelle neu eingeführt wird.

3.5.2 Klassifizierung mit Sicherheiten

Die einzelnen Datenbestände werden übereinander gelegt und bilden gewissermaßen ein „Daten-Layer-Stack“. Dann wird ein Pixel genommen und in jedem Layer betrachtet. Dazu wird eine Regelbasis erstellt, in der sämtliches Wissen aus den topographischen Beständen, wie auch aus den Fernerkundungsdaten verknüpft wird. Ein Pixel muß, um einer Klasse mit einer gewissen Sicherheit zugewiesen zu werden, einige Bedingungen erfüllen. Je eindeutiger und konsistenter die Informationen für ein Pixel pro Layer sind, desto zuverlässiger kann eine Landnutzungs-kategorie zugewiesen werden.

Eine Verknüpfung kann so aussehen:

- *IF*

multispektrale Klassifizierung 1. Wahrscheinlichk. == Wald &&
 Panchromatisch == Wald &&
 ÖKWaldlayer == Wald

THEN Waldsicher1

- *IF*

multispektrale Klassifizierung 1. Wahrscheinlichk. == Wald &&
 Panchromatisch == Wald &&
 ÖKWaldlayer ≠ Wald

THEN Waldsicher2
 (Hinweis auf Veränderung gegenüber ÖK50)

- *IF*

multispektrale Klassifizierung 1. Wahrscheinlichk. ≠ Wald &&
 multispektrale Klassifizierung 2. Wahrscheinlichk. == Wald &&
 Panchromatisch == Wald &&
 ÖKWaldlayer == Wald

THEN Waldsicher3
 (Sollte überprüft werden)

- *IF*

multispektrale Klassifizierung 2. Wahrscheinlichk. ≠ Wald &&
 Panchromatisch == Wald &&
 ÖKWaldlayer ≠ Wald

THEN Waldsicher4
 (Sollte überprüft werden)

Der Waldlayer aus der ÖK50 kann als geeigneter Datensatz betrachtet werden, da er flächenhaft für ganz Österreich abgelegt ist. Probleme können bei einigen generalisierten und freigestellten Verkehrswegen durch Waldgebiete entstehen. Außerdem wird an Waldrändern die Generalisierung sichtbar, und eine gewisse Definitionsunsicherheit zu erkennen sein. Zudem

ändert sich Wald gehäuft im Gebiet seiner Außengrenzen. Die Aktualität des Waldlayers spielt zudem eine wichtige Rolle, hier kann allerdings die Fernerkundung gut als Aktualisierungsinstrument fungieren. Auch geschlägerte Waldstücke können so erkannt werden. Weiters interessant ist die Verknüpfung mit dem Situationslayer der ÖK50. Dieser liegt zwar nur in gerasterter Form vor, obwohl er eigentlich Vektorinformationen beinhaltet, wie Gebäude, Straßenzüge und Signaturen aller Art. Signaturen repräsentieren wiederum eigentlich flächenhafte Objekte. Der Situationslayer ist 1 für „Situation“ und 0 für „keine Situation“. Da die Pixelgröße mit 2.5m im Vergleich zu den Fernerkundungsdaten relativ klein ist, wurde dieser Layer nur als grobe Information in einer großen Umgebungsmatrix verwendet. Die Information, die dieser Layer beisteuert, ist die Bestärkung der als bebaut und hochtexturiert ausgewiesenen Pixel und deren Zuordnung zur Klasse „Besiedelt“.

- *IF*

```

multispektrale Klassifizierung 1. Wahrscheinlichk. == Stadt    &&
                                Panchromatisch == Stadt        &&
                                Focal9x9derÖK-Situation == 1

```

THEN **Besiedeltsicher1**

⋮
⋮
⋮

- *IF*

```

multispektrale Klassifizierung 1. Wahrscheinlichk. ≠ Stadt    &&
multispektrale Klassifizierung 2. Wahrscheinlichk. == Stadt    &&
                                Panchromatisch == Stadt        &&
                                Focal9x9derÖK-Situation == 1

```

THEN **Besiedeltsicher3**

- *IF*

```

multispektrale Klassifizierung 2. Wahrscheinlichk. ≠ Stadt    &&
                                Panchromatisch == Stadt        &&
                                Focal9x9derÖK-Situation == 1

```

THEN **Besiedeltsicher4**

Weiters kann der Verkehrslayer miteinbezogen werden, der für Straßen das Attribut „im Ortsgebiet“ mitführt, und daher für besiedelte Klassen und Gebiete eine Zusatzinformation liefern kann, die wiederum über die Zuverlässigkeit Auskunft gibt. Insgesamt wird eine Vielzahl von Regeln hierarchisch durchlaufen. Im angeführten Testbeispiel sind es ca. 30 Regeln in Form von Bedingungen, wobei eine erfüllt sein muß, damit dem Pixel eine bestimmte Klasse mit zugehöriger Sicherheit zugeordnet wird. Wenn für ein Pixel eine Regel zutrifft, dann wird es ungeachtet der weiteren Regeln der entsprechenden Klasse mit Sicherheit zugeordnet. Wenn das Pixel in die Regeln der multispektralen Klassifizierung erster Wahrscheinlichkeit nicht hineinpaßt, das heißt, wenn sich die Informationen aus den einzelnen Layern widersprechen, bzw. eine Inkonsistenz aufweisen, dann werden auch die Regeln mit den Pixeln der zweiten Klassifizierung betrachtet. Damit wird in einer erneuten Konsistenzprüfung auf die Klassen

zweiter Wahrscheinlichkeit aus der multispektralen Klassifizierung zurückgegriffen und versucht, auch diese Information zu integrieren.

Die so erhaltenen verschiedenen Stufen der Klassenzugehörigkeit beinhalten einerseits die Sicherheit, mit der eine Klasse zugewiesen wurde, andererseits die Hinweise auf mögliche Veränderungen. Sicherheiten werden in Stufen von 1 bis n an die jeweilige Klasse angehängt, wobei 1 die höchste Sicherheit angibt. Das heißt, Sicherheit 1 ist ein Hinweis darauf, daß aus mehreren Informationsquellen eine übereinstimmende, sichere Aussage über die Klassenzugehörigkeit getroffen werden kann, während schlechtere Sicherheit eine tatsächliche Veränderung gegenüber dem Datenbestand des DLM aufzeigt. Ganz geringe Sicherheiten wiederum deuten darauf hin, daß die Auswertungen der Fernerkundungsdaten Interpretationsfehler enthalten oder nicht genug Information vorhanden ist. Deshalb sollen gerade diese wenigen, unsicheren Pixel ausgewiesen und kontrolliert werden, damit die Daten am Ende zuverlässig und richtig sind und eine Fortführung des Datenbestandes garantiert ist.

Realisiert ist dieses Regelsystem im Model-Maker von ERDAS-IMAGINE.

In der folgenden Abbildung 28 ist das Ablaufschema dieses Klassifizierungsverfahrens dargestellt. Ausgangsdaten sind multispektrale und panchromatische Fernerkundungsaufnahmen, aus denen verschiedene Informationen abgeleitet werden, wie die Landnutzungsklassen, ein hochauflösender Besiedlungslayer und ein Waldlayer. Diese werden zusammen mit den Daten des DLM über eine Regelbasis verknüpft und zu einem hochauflösenden Bodenbedeckungslayer zusammengeführt. Die Abbildung 29 zeigt einen Ausschnitt dieses Ergebnisses vom Gebiet Gmunden. Zur Orientierungshilfe wurde der Situationslayer der ÖK50 daruntergelegt. Aus der Legende können die Klassen verschiedener Sicherheiten entnommen werden. Die obersten Klassen sind jene Klassen, die mit größter Sicherheit zugewiesen werden konnten, dann folgen jene Klassen, in denen für die Pixel nicht mehr in allen Layern die Klasse bestätigt wird.

Ablaufdiagramm




Abbildung 28

Ablaufdiagramm von der Fernerkundungsaufnahme zur Bodenbedeckung



61

- Wasser
- Wald
- Gruenland
- Besiedelt
- Acker
- Besiedelt 2
- Besiedelt 3
- Wald 2
- Gruenland :
- Besiedelt 4
- Acker 2

Abbildung 29

Landnutzung nach der Verknüpfung sämtlicher Daten mit Klassen verschiedener Sicherheiten

4 Fallbeispiel SPOT und TM

Nunmehr sollen die entwickelten Methoden für weitere Datensätze ausprobiert werden, einerseits um die Eignung dieser für verschiedene Bilddaten zu testen, andererseits um den Aufwand einer Ausarbeitung für ein bestimmtes Gebiet abzuschätzen.

Dazu wurde eine Kombination von einem panchromatischen SPOT Bild (SPOT-Pan) und Thematic Mapper Daten gewählt. Sowohl die SPOT-Pan- wie auch die TM-Szene sind Aufnahmen vom 29. Juni 1997. Bearbeitet wird wiederum das Gebiet zwischen Traunsee und Attersee des oberösterreichischen Salzkammergutes, im Norden des ÖK50-Blattes 66. Im Vergleich zum vorhergehenden Testgebiet fehlt im SPOT-Bild im Norden ein schmaler Streifen. Sämtliche Verfahren wurden neu adaptiert und wiederholt durchgeführt. Anschließend wurde ein Vergleich der Ergebnisse angestellt.

4.1.1 Auswertung des SPOT-Pan

Das panchromatische SPOT-Bild hat eine Bodenauflösung von 10x10 Meter und ist praktisch nicht verrauscht. Daher ist eine vorverarbeitende Filterung nicht notwendig. Texturanalyse und Schwellwertanalyse können unmittelbar am rektifizierten Bild durchgeführt werden.

4.1.1.1 Texturanalyse mit Förstner-Operator

Die Texturanalyse wurde mittels Förstner-Operator durchgeführt, mit dessen Hilfe markante Punkte und Grauwertkanten als hochtexturiert und homogene Gebiete als solche erkannt werden. Die Parameter wurden dazu so gewählt, daß einerseits ein kleiner Wert für die Isotropie möglichst die Punkte hervorhebt und weniger die Kanten, andererseits sollen nur die größten Grauwertsprünge als hochtexturiert ausgegeben werden, da ansonsten vor allem auch die Waldlichtungen als texturierte Gebiete ausgewiesen werden. Abbildung 30 zeigt diese Texturanalyse rund um den Traunsee. Punkte werden in rot dargestellt, die gefundenen Kanten in grün.

Diese Texturanalyse wurde so wie der IRS-1C-Pan-Texturlayer mit shrink-expand-Funktionen weiterbearbeitet. Da im Wald dennoch sehr viele hochtexturierte Gebiete entdeckt wurden, z.B. sämtliche helle Straßenkehren in relativ dunklen Waldgebieten, wurde anschließend stark gefiltert, damit solche kleine texturierte Gebiete eliminiert werden. Da der Texturlayer stark geglättet wurde, entstand ein homogener, runder Eindruck an den Rändern der besiedelten Flächen. Abbildung 31 zeigt die Ableitung des Besiedlungslayers aus dem Texturlayer im Gebiet rund um den Attersee.

Texturanalyse mittels Foerstner-Operator

1 : 20000

hochtexturierte Punkte in rot, Kanten in gruen Ausschnitt Gmunden




Abbildung 30

Texturanalyse des SPOT-Bildes mit Förstner-Operator

Texturlayer mittels Foerstner-Operator

hochtexturierte Gebiete in magenta Ausschnitt Attersee

1 : 25000




Abbildung 31

Besiedlungslayer abgeleitet von der SPOT-Texturanalyse

4.1.1.2 Waldlayer mittels Schwellwertanalyse

Für die Extraktion des Waldlayers wurde eine lokale Schwellwertanalyse durchgeführt. Wegen der größeren geometrischen Auflösung und den unverrauschten Bilddaten brauchten zur Mittelwertbildung nur 3 x 3 Pixel verwendet zu werden, um eine ausreichende Sicherheit für die Pixelzuordnung zu erreichen. Die extrahierten Mittelwerte für den Waldlayer liegen zwischen den Grauwerten 31 und 45. In diesem Grauwertbereich befindet sich auch die Klasse „Wasser“, die aber nicht weiter berücksichtigt werden muß, da Wasser aus der multispektralen Klassifizierung eindeutig hervorgeht. Da nur sehr wenige unsichere Waldpixel entdeckt wurden, konnte der Waldlayer ohne weitere Überprüfungen in die Verknüpfung der Daten einbezogen werden. Die Abbildung 32 zeigt einen Ausschnitt dieses Waldlayers aus dem SPOT-Pan Bild westlich von Gmunden.



Abbildung 32

Waldlayer abgeleitet mit Schwellwertanalysen aus dem SPOT-Bild

4.1.2 Klassifizierung der TM-Daten

Zur Klassifizierung der TM-Daten wurden die anfangs beschriebenen Algorithmen verwendet. Jeweils die Klassen erster und zweiter Wahrscheinlichkeitsdichte wurden berechnet, und anschließend bei der Verknüpfung der Daten und für die Bestimmung der Zuverlässigkeit miteinbezogen. Bei der Klassifizierung erwies sich wieder die Trennung von bebauten Gebieten von Ackerflächen als schwierig.

Für die Klassifizierung wurden 19 Trainingsgebiete gewählt, um die Klassen möglichst eindeutig mit Signaturen abzudecken. Anschließend wurden die Klassen wiederum auf die Primärklassen, „Wasser“, „Wald“, „Grünland“, „Besiedelt“ und „Acker“ reduziert. Nur eine zweite Klasse „Besiedelt“ wurde noch für spezielle Verknüpfungsregeln miteinbezogen.

4.1.3 Verknüpfung von SPOT und TM

Es stehen folgende Datenlayer zur Verfügung:

	Auflösung	abgeleitete Information
Aus SPOT-Pan abgeleitet	10m	Waldlayer
	10m	Besiedlungslayer
Aus Thematic Mapper Daten	25m	Klassifizierung 1. Wahrscheinlichkeitsdichte
	25m	Klassifizierung 2. Wahrscheinlichkeitsdichte
Aus Digitalen Landschaftsmodell	2.5m	Waldlayer
	2.5m	Situationslayer
	2.5m	Verkehrslayer

Tabelle 6

Zudem wurde der Verkehrslayer miteinbezogen, um die bekannten Bereiche der Autobahn neu zu integrieren. Die Adaptierung der Verknüpfungsregeln war relativ einfach, da nur wenige Bedingungen leicht abgeändert werden mußten.

Die Abbildung 33 zeigt das Ergebnis der SPOT-Pan und TM97 Verknüpfung, überlagert mit den Vektoren des Verkehrslayers. Noch deutlich erkennbar sind die stark gefilterten Begrenzungen des Besiedlungslayers, die durch die Klasse „Besiedelt3“ dargestellt sind. Ein Vergleich mit der Auswertung des IRS-1C-Pan-Bildes mit TM-Daten wird im Kapitel 5 „Vergleichende Analysen und Genauigkeiten“ noch durchgeführt.



Abbildung 33

Landnutzungsinterpretation aus SPOT-Pan- und TM-Aufnahme im Raum Gmunden

5 Vergleichende Analysen und Genauigkeiten

Für eine Genauigkeitsabschätzung sind Referenzdaten notwendig. Dazu werden digitale panchromatische Orthophotos des Bundesamtes für Eich- und Vermessungswesen herangezogen und darauf stichprobenartig Ausschnitte visuell klassifiziert. Die Orthophotos wurden am 3. Mai 1994 vom BEV aufgenommen, anschließend digitalisiert, entzerrt und liegen schließlich als 2,5 x 2,5 Meter-Raster vor. Über das gesamte Testgebiet werden 20 regelmäßig verteilte Ausschnitte in der Größe von 500 x 500 Meter mit ARC/Info visuell interpretiert. Das sind bei einer Pixelgröße von 5 x 5 Metern 200000 Pixel, also 2% des bearbeiteten Testgebietes, die verglichen werden. Dabei sind die Schwierigkeiten diverser Definitionsunsicherheiten klar zu bemerken. Oft ist die Waldgrenze nicht klar zu erkennen oder unsicher. Als besonders schwierig entpuppt sich die Abgrenzung von „Besiedelt“, vor allem in sehr locker bebauten Gebieten. Bei Streusiedlungen kann die Grenze der Siedlung nicht eindeutig gezogen werden. Zudem soll gesagt werden, daß hier panchromatische Luftbilder mit Informationen aus panchromatischen und multispektralen Fernerkundungsdaten verglichen werden. Für einen Vergleich der Textur ist das in Ordnung, für den Vergleich mit multispektralen Aufnahmen wären Farbinfrarot-Orthophotos besser geeignet.

Die Anordnung dieser Referenzflächen im Testgebiet kann man der Abbildung 34 entnehmen. Dabei sind die Ausschnitte des Luftbildes maßstäblich und lagemäßig richtig verteilt. Die dazugehörigen Ausschnitte der Analyse des IRS-1C-Pan Bildes kombiniert mit dem TM-Bild (IRS-1C-Pan + TM-Bild) sind jeweils rechts dazugestellt.

Man kann den Ausschnitten bereits visuell entnehmen, daß sie sehr gut übereinstimmen, bei einem Vergleich pro Pixel wird eine Übereinstimmung von 90% der Pixel erreicht. Das heißt, daß ein sehr hoher Grad, nämlich 90 Prozent der Pixel im Luftbild und in der Fernerkundungsanalyse der gleichen Klasse zugeordnet sind. Wo aber die Möglichkeiten und Grenzen des hier ausgearbeiteten Verfahrens sind, soll aus den näheren Untersuchungen hervorgehen.

Zuerst soll die Analyse IRS-1C-Pan + TM-Bild auf ihre Genauigkeit untersucht werden:

Insgesamt wurde das untersuchte Gebiet zu folgenden Anteilen in Klassen eingeteilt:

Klassen	Fernerkundungsergebnis im gesamt. Testgebiet	
	10 meter Pixel	%
Wasser	140324	5.7
Wald	1037888	41.8
Besiedelt	259681	10.5
Acker, Grünl	1041723	42.0
Summe	2479616	100

Tabelle 7

Die Genauigkeitsuntersuchung kann auch nach der zugeordneten Sicherheit der Klassen differenziert werden. 81% der Pixel in den Untersuchungsfenstern gehören den Klassen mit der

jeweils größten Sicherheit an. Bei der Untersuchung identer Pixel nur innerhalb der Klassen größter Sicherheit kann festgestellt werden, daß über 96% der sicheren Pixel auch tatsächlich mit der Klasse der Referenzflächen übereinstimmen.

Da bisher nur die Vergleiche pro Pixel betrachtet wurden, sollen auch geometrische Ungenauigkeiten berücksichtigt werden, indem man jedes Pixel der IRS-1C-Pan + TM-Interpretation nicht nur mit dem darüberliegenden Pixel aus der Luftbildinterpretation vergleicht, sondern in einer 3 x 3 Umgebung nach einem Pixel gleicher Klasse im Luftbild sucht. Dabei erhöht sich die Zuverlässigkeit der Interpretation um 3% auf 93% beim direkten Vergleich identer Pixel. Bei den sicheren Klassen beträgt die Steigerung der Genauigkeit lediglich 1% auf 97%. Das wiederum bedeutet, daß die sicheren Klassen unabhängig von der geometrischen Ungenauigkeit gut klassifiziert wurden, während für die Gesamtheit der Pixel doch auch die geometrische Genauigkeit einen Einfluß hat. Dazu ist noch zu bemerken, daß sich die sicheren Klassen durchwegs im Zentrum eines Gebietes gleicher Klasse befinden. Die Randpixel, die oft auch Mischpixel sind, sind einfach nicht so sicher klassifiziert und fallen daher in eine weniger sichere Klasse. Sie befinden sich gleichzeitig in den geometrisch ungenauen Zonen.

Die folgende Tabelle 8 stellt die einzelnen Ergebnisse gegenüber. Anschließend wird eine nähere Analyse der Genauigkeiten durchgeführt.




Abbildung 34

Gegenüberstellung der visuellen Luftbildinterpretation und der Fernerkundungsanalyse

Vergleichende Analysen und Genauigkeiten

Klassen	1 visuelle Luftbild- interpretation		2 Fernerkundung		3 idente Klassifizierung		4 idente Klassifizierung höchster Sicherheit		5 idente Klassifizierung in der 3 x 3 Umgebung		6 idente Klassifizierung größter Sicherheit in 3 x 3 Umgebung	
	5 meter Pixel	%	5 meter Pixel	%	Pixel	%	Pixel	%	Pixel	%	Pixel	%
Wasser	20789	10.4	20546	10.3	20449	99.5	20392	99.6	20458	99.6	20394	99.6
Wald	78398	39.2	78302	39.2	73177	93.5	72626	95.9	74580	95.3	73734	97.3
Besiedelt	19694	9.8	24662	12.3	16488	66.9	6148	92.8	17976	72.9	6327	95.0
Acker,Grünl	81119	40.6	76497	38.2	69897	91.4	56293	93.8	71898	94.0	57452	97.1
insgesamt % Summe	200000	100	200000	100	180011	90	155459	96	184912	93	157907	97

Tabelle 8 Gegenüberstellung der visuellen Luftbildinterpretation und der IRS-1C-Pan + TM-Fernerkundungsanalyse

In Tabelle 8 werden sämtliche Genauigkeitsabschätzungen in den untersuchten Ausschnitten gegenübergestellt. Die *Spalte 1* zeigt die Anzahl der Pixel pro Klasse in der visuellen Luftbildinterpretation. Dem gegenüber stehen in der *Spalte 2* die Anzahl der Pixel pro Klasse aus der Fernerkundungsanalyse. Der Vergleich der *Spalten 1* und *2* zeigt, daß allgemein eine relativ gute Übereinstimmung der Klassen in Prozent gegeben ist. Es gibt eine Verschiebung von „Acker/Grünland“ zu „Besiedelt“ in der Fernerkundungsanalyse, was, wie wir später sehen werden, auf den Texturlayer zurückzuführen ist. Im gesamten bearbeiteten Gebiet wurden die Klassen so zugeordnet wie in Tabelle 7 ausgeführt. Deutlich ist der hohe Anteil an Wasser in den Referenzflächen zu erkennen, da zufällig zwei der Ausschnitte in den Traun- bzw. Attersee fallen, sonst ist die Verteilung der Klassen ziemlich stark mit der Verteilung im gesamten Gebiet korreliert.

In der *Spalte 3* werden die identen Pixel beider Interpretationen aufgelistet, dazu wird der Prozentanteil angeführt, mit dem jede Klasse der Fernerkundungsinterpretation mit den Referenzdaten übereinstimmt. Diese Übereinstimmung ist erfahrungsgemäß, wie auch hier für die Klassen „Wasser“, „Wald“, „Acker“ und „Grünland“ sehr hoch, nur für die besiedelten Gebiete kommen größere Abweichungen zum Tragen. Diese Abweichungen müssen einerseits auf die Definitionsunsicherheit der Klasse „Besiedelt“, andererseits auch auf den Texturlayer zurückgeführt werden, da in diesem vielfach auch die angrenzenden Gärten noch als hochtexturiert und damit als „Besiedelt“ ausgewiesen werden. Einerseits kann dadurch der höhere Anteil an der Klasse „Besiedelt“ im Fernerkundungslayer begründet werden, wie der Vergleich der *Spalte 2* mit *Spalte 1* gezeigt hat, andererseits wird dadurch die deutlich schlechtere Übereinstimmung und der niedrige Prozentanteil in der *Spalte 3* in der Klasse „Besiedelt“ erklärt.

Die *Spalte 4* zeigt die Anzahl identer Pixel größter Sicherheit pro Klasse. Dazu wird angegeben, wieviel Prozent der Pixel höchster Sicherheit auch tatsächlich mit der Luftbildinterpretation übereinstimmen. Hier kann man deutlich sehen, daß diese Klassen auch tatsächlich zuverlässiger sind, und ein sehr hoher Anteil als richtig klassifiziert bewertet werden kann. Auch 93% der Pixel der Klasse „Besiedelt“ stimmen mit den Referenzflächen überein, allerdings ist nur ein Viertel der „Besiedelten“ Pixel mit größter Sicherheit klassifiziert. Der Rest befindet sich in unsicheren Klassen und ist entsprechend unsicherer zugeordnet.

In der *Spalte 5* werden die Pixel nicht nur mit dem darüberliegenden Pixel der Luftbildinterpretation verglichen, sondern in einer 3 x 3 Umgebung wird pro Pixel untersucht, ob es ein Pixel gleicher Klasse in der nächsten Umgebung gibt. Dabei ist zu erkennen, daß geometrische Ungenauigkeiten vor allem für die Klassen „Wald“, „Besiedelt“ und „Acker/Grünland“ berücksichtigt werden. D.h. wenn für diese Klassen nicht nur ein Pixel, sondern auch jene rundherum betrachtet werden, kommt man der Ungenauigkeit der Lage des Pixels etwas näher. Der Vergleich pro Pixels mit 5 x 5 Metern ist nicht ganz der geometrischen Genauigkeit entsprechend, vielmehr kann in einer Umgebung von 10 Metern rund um das Pixel ein identes Pixel wohl noch richtig zugeordnet sein. Für die Klasse „Wasser“ kann dadurch keine Verbesserung erkannt werden, da diese Klasse mit großer Zuverlässigkeit eindeutig und mit guter Genauigkeit von allen anderen abgegrenzt werden kann.

In der *Spalte 6* wird dieser Vergleich in der 3 x 3 Umgebung nur für die sicheren Klassen, entsprechend *Spalte 4* durchgeführt. Hier ist die Genauigkeitssteigerung um einiges geringer, da

diese sicheren Pixel nicht so sehr von der geometrischen Unschärfe betroffen sind, weil sie nicht aus dem Mischpixelbereich kommen, wie oben beschrieben. Der angeführte Prozentanteil bezieht sich auf alle als sicher klassifizierten Pixel in den Referenzgebieten.

Der Vergleich der visuellen Orthophotointerpretation mit der Auswertung der TM97- und SPOT-Pan-Daten führt zu folgendem Ergebnis:

Klassen	1 visuelle Luftbild-interpretation		2 SPOT+TM97 Fernerkundung		3 idente Klassen	
	Pixel	%	Pixel	%	Pixel	%
Wasser	20789	14,4	20544	14,3	20542	100
Wald	62999	43,6	61152	42,3	59165	96,8
Besiedelt	12762	8,8	15545	10,7	10730	69,0
Acker,Grünl	47918	33,2	47227	32,7	41716	88,3
Insgesamt % Summe						91,5
	144468	100	144468	100	132153	

Tabelle 9

In der *Spalte 1* ist die Anzahl der Pixel pro Klasse aus der Luftbildauswertung eingetragen, allerdings nur aus jenem Teil der sich mit der SPOT-Aufnahme deckt.

In der *Spalte 2* steht die zugehörige Pixelanzahl aus der Fernerkundungsanalyse des SPOT- und TM97-Bildes. Jene Pixel, die in beiden Interpretationen ident sind, werden in *Spalte 3* aufgelistet. Generell ist mit 91,5 Prozent eine gute Übereinstimmung gegeben. Interessant ist die scheinbare Verschiebung der Pixel von „Besiedelt“ zu „Wald“. Die Definitionsunsicherheit der Klassen „Wald“ und „Besiedelt“ ist ziemlich groß. Die Schwellwertoperation auf das SPOT-Pan-Bild angewendet, ist sehr sensibel auf innere und äußere Waldgrenzen und sämtliche Lichtungen des Waldes konnten als solche erkannt werden. Daher sind weniger Pixel als „Wald“ klassifiziert als im Orthophoto, aber auch im Vergleich zum IRS-1C-Pan-Waldlayer. Diese „Nicht-Wald“-Pixel werden zum Großteil der Klasse „Acker/Grünland“ zugewiesen. Der Texturlayer hingegen weist durch die hohe Sensibilität des Förstner-Operators sehr große Gebiete als hochtexturiert aus und führt damit diese Teile im Besiedlungslayer der Klasse „Besiedelt“ zu. In der multispektralen Klassifizierung ist es gelungen, Teile wie z.B. die Autobahn als versiegelt herauszuarbeiten. Damit wird auch hier der besiedelte Bereich stark betont, was dazu führt, daß viele „Acker/Grünland“ Pixel zu „Besiedelt“ werden. Insgesamt bedeutet dies, daß „Wald“ und „Besiedelt“ unabhängig voneinander klassifiziert wurden. Beide Klassen reichen durch die Definitionsunsicherheit stark in den Bereich „Acker/Grünland“ hinein und verwenden diesen als „Pufferzone“, die die Überbetonung von „Besiedelt“ mit der Verminderung der Waldpixel ausgleicht.

Abbildung 35 zeigt eine Gegenüberstellung der Ausgangsdaten und der Waldklassifizierungen aus ÖK-Waldlayer, IRS-1C-Pan und SPOT-Pan. Diese weisen große Unterschiede auf, je nach Aufnahme und Interpretation.




Abbildung 35

Gegenüberstellung der verschiedenen Waldinterpretationen

1 : 20000

Die Details der einzelnen Referenzausschnitte aus Abbildung 34 werden im folgenden näher betrachtet. Dabei werden nur jene Ausschnitte ausgewählt, die Problemfälle verdeutlichen. Das jeweils linke Bild ist der Ausschnitt aus dem Orthophoto mit den Vektoren der visuellen Interpretation; das nächste Bild ist die Interpretation mit SPOT-Pan + TM97, das dritte Bild zeigt den entsprechenden Teil mit IRS-1C-Pan + TM, wiederum überlagert mit den Vektoren aus der visuellen Klassifizierung. Das vierte Bild ist aus der IRS-1C-Pan Original-Aufnahme genommen.




Abbildung 36

Vergleich der Waldabgrenzungen

Im ersten Ausschnitt ist zwar die prinzipielle Übereinstimmung der Klassifizierung ersichtlich, deutlich allerdings sind hier sämtliche mögliche Fehler anzutreffen, die die drei Klassifizierungen so ungleich erscheinen lassen:

- Einerseits ist das Orthophoto vom BEV zwar sehr genau georeferenziert, doch die Vektoren der Verkehrswege des DLM haben mancherorts eine deutliche Versetzung gegenüber dem Orthophoto, wie auch gegenüber den rektifizierten Satellitendaten. D.h. alle Ausgangsdaten sind unabhängig voneinander entzerrt worden und weisen geringe Abweichungen voneinander auf.
- Die Waldgrenze kann im Luftbild durch das „Umfallen“ der Bäume um einiges versetzt abgebildet werden. In einem Bildmaßstab von 1:30000 und einer Kamerakonstante von 30cm kann ein Baum, der 26 Meter über dem Höhenmodells liegt bereits einen Fehler von 1mm im Orthophoto (1:10000) verursachen, d.h. ca. 10 Meter falsch liegen [Kraus K., 1994]. Zusätzlich kommt es im Schatten zu undeutlichen Abgrenzungen, sowohl im Luft- als auch in den panchromatischen Satellitenbildern. Deutlich ist im zweiten Bild die gröbere Auflösung zu erkennen, da dieses Gebiet nicht mehr vom SPOT-Pan abgedeckt wird und nur auf der TM97-Klassifizierung beruht.

Die geometrische Abweichung der Interpretationen beträgt ca. 15 Meter.

- Durch die Mittelwertbildung und die anschließende Schwellwertanalyse werden Wälder, die in der Umgebung von hellen Ackerflächen liegen, enger abgegrenzt, als solche in einer dunklen Umgebung. Daraus entsteht wiederum eine kleine Unschärfe der Waldabgrenzung. Wenn sich nun im ungünstigsten Fall alle diese Fehlereinflüsse gegenseitig addieren, dann entsteht eine Ungenauigkeit wie in Abbildung 36 dargestellt.




Abbildung 37
Ausschnitt vom Traunsee

Diese Abbildung 37 zeigt einen Ausschnitt von Gmunden am westlichen Traunseeufer. Die Verschiebung der Wassergrenze ist ein reines Problem der Rektifizierung und der Pixelgröße in den Thematic Mapper Daten. Die Analyse der Daten ist richtig, die Fernerkundungsbilder passen auch gut übereinander, allerdings besteht eine lokale nord-süd Abweichung gegenüber dem Luftbild, die hier klar zu sehen ist. Die drei Industrieblächen in der nord-westlichen Ecke des Orthophotoausschnittes sind zu groß und homogen um mittels Texturanalyse erkannt zu werden. Die spektrale Reflexion im TM-Bild wiederum ist außerordentlich hell und hätte eines eigenen Trainingsgebietes für Industrie bedurft, um detektiert zu werden. Leider wurde dieser Auswertefehler nicht frühzeitig genug erkannt. In der SPOT-Pan und TM-97-Interpretation sind diese Fehler eigentlich nicht vorhanden.

Im nächsten Ausschnitt geht es wiederum um ein Industriegebiet.




Abbildung 38
Industrieblächen und besiedelte Gebiete

In Abbildung 38 wurde von den zwei großen Gebieten der Klasse „Besiedelt“ nur das hochtexturierte entdeckt. Das obere ist wiederum eine größere Industriebläche, die für die

Texturlanalyse zu groß und homogen ist. Die multispektrale Klassifizierung erkennt hier den versiegelten Charakter. Bei diesem Beispiel muß die Hierarchie der Verknüpfungsregeln hinterfragt werden, aber auch die Grenze der Auflösung der TM-Daten respektiert werden.




Abbildung 39

Vergleich der Waldlichtungen

Der Ausschnitt in Abbildung 39 zeigt zwei Waldlichtungen, die am Orthophoto ganz deutlich zu erkennen und abzugrenzen sind. In den panchromatischen Bildern heben sie sich nicht so deutlich ab. Während die kleinere Lichtung aufgrund ihrer Grauwerte nur sehr schwach abgehoben erscheint, ist die westliche Lichtung in beiden Interpretationen gut herausgearbeitet.




Abbildung 40

Abgrenzung hochtexturierter Gebiete

In Abbildung 40 wird die Definitionsunsicherheit der Klasse „Besiedelt“ sehr deutlich gezeigt. Im Orthophoto werden diese Gebiete ziemlich streng und eng abgegrenzt, während die Texturanalyse aus den panchromatischen Bildern auch Gärten und Einzelbäume in der Umgebung als hochtexturiert, und damit als zu „Besiedelt“ gehörig ausweist. Auf diese Weise entstehen in beiden obigen Tabellen die Verschiebung der Klasse „Acker/Grünland“ zu „Besiedelt“.

Im nächsten Ausschnitt soll gezeigt werden, in welcher Komplexität die Klasse „Besiedelt“ in dörflichen Gebieten auftreten kann. Diese Strukturen abzugrenzen ist visuell nur schwer

möglich, da die Definition von „Dorf“ und „Nicht-mehr-Dorf“ äußerst schwierig handzuhaben ist. Das SPOT-Pan-Bild deckt diesen Bereich nicht mehr ab, daher befindet sich in dieser Interpretation wiederum nur die gröbere TM97-Analyse mit den DLM-Verknüpfungen. Dennoch kann dieses Dorf mit großer Ähnlichkeit in den Interpretationen gefunden werden, die Klassen weisen einen hohen Grad an Übereinstimmung auf. Dies kann für die meisten Dörfer ebenfalls bestätigt und nachvollzogen werden.




Abbildung 41
Vergleich der Abgrenzung eines Dorfes

Abschließend sei gesagt, daß 90 bis 93 Prozent der Pixel, in sicheren Gebieten sogar bis 97 Prozent identisch sind und teilweise ganz hervorragende Übereinstimmungen erzielt werden konnten. Jene Fehler, die in den untersuchten Gebieten auftraten, wurden genauer betrachtet, um sie später so gut wie möglich zu vermeiden. Die Diskrepanzen in den Referenzausschnitten entstehen einerseits aus den Grenzen der Interpretationsmöglichkeit bedingt durch geometrische und spektrale Auflösung der Fernerkundungsdaten, aber auch durch Interpretationsfehler der Bearbeiter und Bearbeiterinnen, die wohl niemals auszuschließen sein werden. Generell soll gesagt werden, daß eine visuelle Kontrolle des Texturlayers aus dem hochauflösenden Bild schon vorab eine erhöhte Sicherheit brächte, und daher für den operationellen Betrieb unbedingt empfohlen wird. Dann kann ein größeres Gewicht auf diesen Texturlayer gelegt werden, und die besiedelten Gebiete können von vornherein mit einer größeren Übereinstimmung interpretiert werden.

Wie eignen sich nun die beiden panchromatischen Bilder für die hier beschriebene Aufgabe?

Da das IRS-1C-Pan-Bild zwar nominell die Bodenauflösung von 5.8m hat, radiometrisch aber ziemlich verrauscht ist, ist ein Vergleich der beiden Daten nicht so einfach. Die de facto Auflösung des IRS-1C-Pan-Bildes wird auf 7-8m geschätzt, was der Auflösung des Spot-Pan Bildes ziemlich nahe kommt. Das IRS-1C-Pan-Bild muß vor einer Bearbeitung gefiltert werden, damit das Rauschen eliminiert wird (siehe Kapitel 2.3.1). Dann aber lassen sich mit dem Förstner-Operator mit hoher Genauigkeit und Zuverlässigkeit die hochtexturierten Gebiete bestimmen.

Das Spot-Pan-Bild ist radiometrisch gesehen sehr scharf. Daher werden sämtliche Übergänge in den Grauwertniveaus auch als Kanten ausgewiesen. Schwierig erwies sich in unserem Beispiel

die Trennung der Waldlichtungen von besiedelten Gebieten (siehe 4.1.1.1). Dazu mußte der Texturlayer stark gefilter werden, was natürlich auf Kosten der geometrischen Genauigkeit geht, und zu den äußerst runden, geglätteten Abgrenzungen der „Besiedlung“ führte.

Der Waldlayer konnte aus beiden Aufnahmen mit guter Genauigkeit abgeleitet werden, wobei hier das Spot-Pan Bild mit der radiometrisch hohen Qualität doch die größere Zuverlässigkeit für den Waldlayer bringt.

Abschätzung von Kosten- und Arbeitsaufwand

Der Zeit- und Arbeitsaufwand pro thematischen Layer in der SPOT-Pan und TM97-Analyse betrug:

Layer	Arbeitsstunden
Waldlayer aus SPOT	4
Förstner-Textur	4
Besiedlung	3
TM-Klassifizierung	16
Verknüpfung	12
Summe	39

Tabelle 10

Das bedeutet, daß unter der Voraussetzung, daß die Daten gut rektifiziert sind, das Gebiet einer halben ÖK50 in einer Arbeitswoche bearbeitet werden kann. Die Bearbeitungsfläche kann für eine Bearbeitung aber noch ausgedehnt werden. Für die panchromatischen Daten wird eine Größe von 300 km² als sinnvoll erachtet, für die multispektrale Klassifizierung können ca. 1000 km² als Einheit behandelt werden.

Bei der Fläche von Österreich mit ca. 84000 km² folgt daraus folgender Aufwand:

Aufnahmesystem	Anzahl der Teilgebiete mal Stunden/Gebiet	Arbeitsstunden	Kosten der Aufnahmen in AtS und ECU	Datenkosten
IRS-1C-Pan à 300km ²	280 x 30	8400	ca. 44 Viertelszenen zu je AtS 34300.- (ECU 2450.-)	1509200.- (ECU 107800.-)
Thematic Mapper à 1000km ²	84 x 30	2520	12 Szenen zu je AtS 49000.- (ECU 3500.-)	588000.- (ECU 42000.-)
Rektifizierungskosten	56 Szenen		56 Szenen zu je 20000.- (ECU 1430.-)	1120000.- (ECU 80000.-)
Verknüpfung mit DLM	84 x 20	1680	vom BEV	
Summe		12600		3.217.200.- (ECU 229.800.-)

Tabelle 11

Eine flächendeckende Landnutzungsanalyse für Österreich mit 15x15m Bodenauflösung kostet

mit 500.- AtS pro Arbeitsstunde

AtS 9.517.200.-

mit 35.70 ECU pro Arbeitsstunde

ECU 679.620.-

6 Zusammenfassung, Diskussion und Ausblick

Das Ziel der vorliegenden Arbeit war die Erarbeitung geeigneter Methoden zur Erstellung eines geometrisch hochgenauen Landnutzungsdatensatzes aus multispektralen und hochauflösenden panchromatischen Fernerkundungsdaten. Die behandelten Themen reichen von der Bildvorverarbeitung wie Rektifizierung und topographische Korrektur über Methoden der multispektralen Klassifizierung und Auswertung panchromatischer Bilder bis hin zur Verknüpfung sämtlicher zur Verfügung stehender Informationen.

Auf die große Bedeutung der vorverarbeitenden Arbeitsschritte und auf die erforderliche gute Qualität der Rektifizierung sei ausdrücklich nochmals hingewiesen. Im gebirgigen Gelände empfiehlt es sich, eine topographische Korrektur durchzuführen, um die Einflüsse der Schatteneffekte zu reduzieren. Dazu wird hier das Modell der Minnaert-Korrektur vorgestellt. Der Vorteil topographisch korrigierter Daten liegt in der Homogenisierung der Ausgangsdaten und Vereinfachung der Auswahl der Trainingsgebiete für die anschließende multispektrale Klassifizierung.

Im Kapitel 2.2.1 wurde die Maximum Likelihood Klassifizierung behandelt, die nicht, wie üblich, nur die Klassen der größten Wahrscheinlichkeitsdichte ausgibt, sondern auch die Klassen mit der zweitgrößten Wahrscheinlichkeitsdichte berechnet. Aus dem Verhältnis der beiden Mahalanobisdistanzen wird die Information über die Eindeutigkeit der Klassenzuordnung entnommen.

Für die Analyse der panchromatischen Daten werden verschiedene Verfahren vorgestellt, um einerseits hochtexturierte besiedelte Gebiete mittels Texturanalyse zu erkennen, um andererseits mit einfachen lokalen Schwellwertoperationen Wald zu extrahieren.

Für den Fall, daß die panchromatischen Ausgangsdaten, wie z.B. IRS-1C-Pan Bilder, sehr verrauscht sind, empfiehlt es sich, mit einem adaptiven Sigma-Filter die Ausgangsdaten zu filtern. Anschließend wurde mit dem "Inverse Difference Moment" versucht, die hochtexturierten Gebiete zu extrahieren. Besser geeignet ist aber das Verfahren des Förstner Operators, der ein Bild in homogene Bereiche, Kanten und Punkte differenziert. Aus diesem Texturlayer wird dann mit Rasteroperationen ein "Besiedlungslayer" abgeleitet.

Für die Ableitung des Walddlayers werden in einer lokalen Umgebung Mittelwert und Standardabweichung der Grauwerte errechnet und geprüft, ob sie innerhalb des gegebenen Wertebereiches für „Wald“ liegen.

Diese Fülle von abgeleiteten Informationen wird im Kapitel 3.5 gemeinsam mit den Daten des Digitalen Landschaftsmodelles einem Regelsystem unterworfen. Wegen der Überbestimmung für jedes Pixel kann eine gut gesicherte Aussage über dessen Landnutzung gemacht werden. Zusätzlich ist eine Angabe über die Sicherheit der Klasse möglich.

Diese Regelbasis ist hierarchisch aufgebaut und besteht aus Bedingungen, die gleichzeitig erfüllt sein müssen, damit ein Pixel einer Klasse mit einer gewissen Zuverlässigkeit zugeordnet werden kann.

Das anhand dieses Beispiels abgeleitete Landnutzungsmodell wird auch einer Überprüfung durch visuell interpretierte schwarz-weiß Orthophotos unterzogen. Die Genauigkeitsuntersuchungen ergeben eine geometrische Genauigkeit von ca. 15 Metern. Inhaltlich stimmen

die klassifizierten Pixel zu 93% mit der visuellen Klassifizierung überein, was ein sehr erfreuliches und akzeptables Ergebnis ist. Dazu können aufgrund der Angabe über die Sicherheit bei einer manuellen Nachbearbeitung jene Klassen gezielt kontrolliert werden, deren Sicherheit als sehr niedrig eingestuft wurde.

Der Erfolg dieser Methoden wird mit einem SPOT-Bild und einer Landsat TM-Aufnahme überprüft, wo mit denselben Verfahren, leicht adaptiert, eine Genauigkeit von über 91% erreicht werden kann. Abschließend wurde eine Abschätzung des Arbeitsaufwandes und eine Kostenschätzung für einen flächendeckenden Landnutzungslayer für Österreich in der eben vorgestellten Vorgangsweise gemacht.

Im Anhang befindet sich eine allgemeine Beschreibung der derzeit erhältlichen und angekündigten Fernerkundungsdaten, ihrer Eigenschaften, Parameter und Qualitäten.

6.1 Diskussion

Die angeführten Methoden beschreiben einen Weg zu einer Landnutzungsklassifizierung mittels Fernerkundung. Dieses Landnutzungsmodell dient einerseits als Layer im DLM und soll den Waldlayer durch einen Bodenbedeckungslayer mit mehreren differenzierten Klassen ersetzen, andererseits kann dieses Landnutzungsmodell auch als wertvolle Grundlage für jede weitere GIS-Bearbeitung dienen. Für jede Anwendung dieser Daten ist es notwendig, das Prinzip einer solchen Auswertung zu verstehen und die „Problemgebiete“ als solche zu erkennen.

Zum einen steht fest, daß die Auswertung von Fernerkundungsdaten mit einer inhaltlichen Genauigkeit von bis zu 93% erfolgen kann, was ein ausgezeichnetes Resultat darstellt. Wie Abbildung 35 bis Abbildung 40 bestätigen, können sowohl Wasser-, Wald- wie auch Siedlungsgebiete zumeist mit sehr hoher inhaltlicher und geometrischer Genauigkeit abgeleitet werden. Gleichzeitig muß gesagt werden, daß Einzelhäuser nicht zwingend erkannt werden können, während auch nicht ausgeschlossen werden kann, daß Einzelobjekte wie ein Turm, ein Haus, etc. erkannt werden, wenn sie in einem guten Kontrast zur Umgebung stehen. Das heißt, jede Anwenderin und jeder Anwender sollte wissen, daß ein Pixel der Klasse „Besiedelt“ nicht unbedingt einem bewohnten Haus entspricht, sondern daß die Textur oder die spektralen Eigenschaften für dieses Pixels auffällig waren. Daher ist es auch vernünftig, die Endergebnisse nicht mit dem Situationslayer der ÖK50 zu verknüpfen, sondern sie in einen globaleren Zusammenhang, z.B. mit dem Verkehrs- oder Gewässerlayer zu stellen, dazu zur Orientierung vielleicht mit den georeferenzierten Namen des DLM.

Des weiteren wird festgestellt, daß ein solcher Landnutzungslayer realistisch im vernünftigen Zeit- und Aufwandsrahmen auch flächendeckend für Österreich abgeleitet werden kann, und die folgende Aktualisierung und Laufendhaltung erfahrungsgemäß einiges an Arbeitsaufwand erspart.

6.2 Ausblick

Aufgabe und Ziel dieser Arbeit war es, geeignete Methoden und Verfahren vorzustellen, um für das DLM einen Landnutzungslayer in geforderter Genauigkeit aus Fernerkundungsdaten abzuleiten. Die im Rahmen des Projektes entwickelten Verfahren eignen sich durchaus für unterschiedliche Gebiete und andere ähnliche Datensätze, wie die Fallstudie an SPOT- und Thematic Mapper Bildern zeigt. Das heißt, mit geänderten, angepaßten Parametern kann für ganz Österreich ein neues Landnutzungsmodell mit einer Genauigkeit von ca. 15x15 Metern erstellt werden.

Weiters ist es möglich, die hier extrahierten Klassen auszuweiten. Die multispektrale Klassifizierung kann auch differenzierter durchgeführt werden. Durch die Verwendung von multitemporalen und multispektralen Datensätzen können noch ganz andere Klassen sehr differenziert abgeleitet werden. In dieser Arbeit liegt die Betonung auf der geometrischen Genauigkeit, die durch Einbeziehung von panchromatischen, hochauflösenden Daten erreicht werden kann. Die Abgrenzungen von „Wald“, „Besiedelt“ und „Wasser“ kann so aus dem hochauflösenden Bild genommen werden, während weitere Differenzierungen der multispektralen Daten, ohne entsprechende Informationen aus den panchromatischen Aufnahmen nur mit schlechterer geometrischer Auflösung möglich wäre.

Eine visuelle, manuelle Kontrolle und Nachbearbeitung des abgeleiteten Besiedlungslayers kann eine große Genauigkeitssteigerung bringen. Bisher wurde gänzlich auf manuelle Nachbearbeitungen verzichtet. Da solche Eingriffe nicht objektivierbar sind, wurden sie hier vermieden. Für die Verknüpfung der Datensätze könnte man aber mit einem kontrollierten Eingriff ein stärkeres Gewicht auf diesen Layer legen und auf die Zuverlässigkeit einer solchen Information aufsetzen. Bisher mußte die Klasse „Besiedelt“ von der multispektralen Klassifizierung und vom Situationslayer bestätigt werden, um als einigermaßen zuverlässig zu gelten.

Wenn eines Tages ein vollständiger Landnutzungsdatensatz für Österreich zur Verfügung steht, dann darf man für Aktualisierungsaufgaben davon ausgehen, daß dieser Datensatz als Information aus dem DLM miteinbezogen werden kann, was die Zuverlässigkeit der folgenden Interpretation weiter erhöhen wird.

Wie bereits in der Diskussion erwähnt, sollen auch die Benutzer eines solchen Datensatzes aus der Fernerkundung davon informiert werden, daß linienförmige und punktförmige Objekte nicht unbedingt als solche erkannt werden können, da das ganze Konzept der Fernerkundung auf Rasterdaten aufbaut. Zusätzlich sollen in den Metadaten nicht nur Angaben über Aufnahmezeit und -system gemacht werden, sondern auch Genauigkeitsangaben, die aus dem Vergleich mit Referenzdaten immer wieder neu bestimmt werden müssen.

Abschließend bleibt zu sagen, daß jene angekündigte neue Generation der Fernerkundungsaufnahmen mit geometrischen Auflösungen von bis zu 1x1 Meter neue Methoden der objektorientierten Textur- und Mustererkennung fordern. Die Erfassung der Landnutzung wird dadurch eine neue Dimension erfahren.

7 Literaturverzeichnis

Abramson S.B., Schowengerdt R.A. (1993), Evaluation of Edge-preserving Smoothing Filters for Digital Image Mapping. ISPRS Journal of Photogrammetry and Remote Sensing, vol.48, No. 2, April 1993

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

Aubrecht P. (1996), Das europäische Landnutzungprojekt CORINE Landcover und erste Ergebnisse für Österreich, Salzburger Geographische Materialien, Heft 24, Seite 194ff, AGIT, Salzburg 1996

Banko G. (1997), Waldoptimierte Korrektur von geländebedingten Beleuchtungsunterschieden in Landsat-TM-Daten, Salzburger Geographische Materialien, Heft 26, Seite 1ff, AGIT, Salzburg 1997

Bartelme N. (1989), GIS Technologie: Geoinformationssysteme, Landinformationssysteme und ihre Grundlagen, Springer-Verlag, Berlin Heidelberg

Bill R., Fritsch D. (1991) Grundlagen der Geo-Informationssysteme, Band 1, Hardware, Software und Daten, Wichmann Verlag, Karlsruhe

Bill R. (1996), Grundlagen der Geo-Informationssysteme, Band 2, Analysen, Anwendungen und neue Entwicklungen, Wichmann Verlag, Heidelberg

Bolstad P., Lillesand T. (1992), Rule-Based Classification Models: Flexible Integration of Satellite Imagery and Thematic Spatial Data, Photogrammetric Engineering and Remote Sensing, July 1992, pp 965-971

Colby J. (1991), Topographic Normalization in Rugged Terrain, Photogrammetric Engineering & Remote Sensing, Vol. 57, No. 5, May 1991, pp.531-537

Conese C., Gilabert M.A., Maselli F. et Bottai L.,(1993) Topographic Normalization of TM Scenes through the Use of an Atmospheric Correction Method and Digital Terrain Models, Photogrammetric Engineering & Remote Sensing, Vol.59, No. 12, December 1993, pp.1745-1753

Ecker R., Kalliany R., und Steinnocher K. (1995), Fernerkundungsdaten für die Planung eines Mobilfunknetzes, Vermessung und Geoinformation 83.Jhg. VGI 1+2/95 pp.14-25

Ekstrand S. (1996), Landsat TM-Based Forest Damage Assessment: Correction for Topographic Effects, Photogrammetric Engineering & Remote Sensing, Vol.62, No.2, February 1996, pp.151-161

Erdas (1994), Field Guide, Erdas, Atlanta

Förstner W. (1991), Statistische Verfahren für die automatische Bildanalyse und ihre Bewertung bei der Objekterkennung und -vermessung, Heft Nr. 370. DGK, München

Fuchs C. (1995), Feature Extraction. Second Course in Digital Photogrammetry Institut für Photogrammetrie und Fernerkundung, Universität Bonn

Haberäcker P. (1987), Digitale Bildverarbeitung: Grundlagen und Anwendungen, Hanser Studien Bücher, 2. Auflage München

Haralick R.M., Shanmugam K. und Dinstein I. (1973), Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, Vol.SMC-3, No.6, pp. 610-621

Hutchinson Ch. (1982), Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement, Photogrammetric Engineering and Remote Sensing, January 1982, pp 123-130

Jansa J. (1998), A global topographic normalisation Algorithm for Satellite Images ISPRS, Commission VII, (im Druck) Budapest, Ungarn, 1-4.9.1998

Janssen L., Middlkoop H. (1992), Knowledge-based crop classification of a Landsat Thematic Mapper image, Intern. Journal for Remote Sensing, Vol. 13, No. 15, pp 2827-2837

Kass M., Witkin A., Terzopoulos D. (1987) Snakes: Active Contour Models, International Journal of Computer Vision, Vol. 1, No. 4, 1988, pp.321-331

Kerschner M.(1995), Kantenextraktion aus digitalen Bildern und Verfolgung glatter Linien, Diplomarbeit, Technische Universität Wien

Kerschner M.(1998), Homologous Twin Snakes Integrated in a Bundle Block Adjustment, IAPRS, Commission III, (im Druck) Ohio, USA, 5-10.7.1998

Kalliany R. (1991), Locating Ground Control Features with Subpixel-Accuracy, Proceedings of the 11th EARSel Symposium, Graz, Austria, pp.418-427

Kohlhofer G. (1991), Aufbau einer Paßpunktdatenbank für Satellitenbilder von Österreich, Diplomarbeit Technische Universität Wien

Kontoes G., Wilkinson G., Burrill A., Goffredo S., Mégier J. (1993), An experimental system for the integration of GIS data in knowledge-based image analysis for remote sensing of agriculture, International Journal of Geographical Information Systems, Vol. 7, No. 3, 1993, pp 247-262

Kraus K. (1979), Zur Theorie der Klassifizierung multispektraler Bilder, Zeitschrift für Photogrammetrie und Fernerkundung, Bildmessung und Luftbildwesen, Heft 47, pp.119-128, Karlsruhe

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

Kraus K. (1990), Fernerkundung, Band 2, Auswertung photographischer und digitaler Bilder, Dümmler Verlag, Bonn

Kraus K. (1994), Photogrammetrie, Band 1, Grundlagen und Standardverfahren, Dümmler Verlag, Bonn

Lee J.(1983), Digital Image Smoothing and the Sigma Filter, Computer Vision, Graphics and Image Processing, vol.24, 1983, pp 255-269

Meyer P., Itten K., Kellenberger T., Sandmeier S. und Sandmeier R., 1993, Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment, ISPRS Journal of Photogrammetry and Remote Sensing, Vol.48, No.4, pp.17-28

Mischke A. und Rottensteiner F.(1997), Feature Extraction in an On-line Engineering Surveying System, ÖAGM Workshop 1997, R. Oldenbourg Wien München

Moik J. G. (1980), Digital processing of remotely sensed images, NASA SP-431, National Aeronautics and Space Administration, Washington D.C

Parsons S. (1996), Current Approaches to Handling Imperfect Information in Data and Knowledge Bases, IEEE Transaction on Knowledge and Data Engineering, Vol. 8, No. 3, June, pp 353ff, 1996

Paul G. (1997), Aufbau eines Digitalen Landschaftsmodells von Österreich, Vermessung und Geoinformation 85.Jhg. VGI 4/97 pp.260-266

Ries C. (1997), Die Rektifizierung von Flugzeugscanneraufnahmen, Diplomarbeit, Technische Universität Wien

Sandmeier S. (1997), Radiometrische Korrektur des Topographieeffektes in optischen Satellitenbilddaten - Vergleich eines semi-empirischen Verfahrens mit einem physikalisch-basierten Modell, PFG, Organ der Deutschen Ges. für Photogrammetrie und Fernerkundung e. V., Jahrgang 1997, Heft 1, pp.23-32

Smith J.A., Lin L., Ranson K.J., (1980) The Lambertian Assumption and Landsat Data, Photogrammetric Engineering & Remote Sensing, Vol. 46, No. 9, September 1980, pp. 1183-1189

Sindhuber A. (1993), Der Beitrag hochauflösender kosmischer Photoaufnahmen mit der Kamera KFA-1000 zur Landnutzungsanalyse in sensiblen Naturräumen-Fallstudie Nationalpark Neusiedler See, Diplomarbeit, Technische Universität Wien

Stätter C. und Steinnocher K. (1994), Ein hierarchischer Klassifikationsansatz zur Erfassung von Landnutzung aus multitemporalen Landsat-TM Daten, Salzburger Geographische Materialien, Heft 24, Seite 683ff, AGIT, Salzburg 1994

Steinnocher K. (1993), Methodische Erweiterung der Landnutzungsklassifikation und Implementierung auf einem Transputernetzwerk. Dissertation an der TU-Wien

Steinnocher K. (1997), Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten, Salzburger Geographische Materialien, Heft 26, Seite 143ff, AGIT, Salzburg 1997

8 Anhang

8.1 Optische Fernerkundungsdaten

Derzeit werden im Bereich der Fernerkundung viele Aufnahmen angeboten und angekündigt, im Internet gibt es davon unzählige Auflistungen, Zusammenstellungen und Übersichten. Hier wurde versucht einen Überblick über die optischen Daten zu erstellen, der möglichst aktuell gehalten sein soll. Die folgende Tabelle ist eine Auflistung der bereits zur Verfügung stehenden Daten und der Aufnahmesysteme in Planung:

NAME		TYPE	AUF LÖSUNG <i>in Meter</i>	KANÄLE <i>in nm</i>	Farb- Tiefe <i>in Bit</i>	BILD- GRÖS. <i>in Kilometer</i>	Wiederhol- frequenz <i>in Tagen</i>	START <i>(geplant)</i>
KFA-1000		pan	5		Photo	80x80	sporadisch	1974-1993
		multisp	5	2	Photo	80x80	sporadisch	1974-1993
KFA-3000		pan	2		Photo	40x40	sporadisch	1978-1993
KVR-1000		pan	2	1; 490-590	Photo	40x40	sporadisch	1983-1993
TK-350		pan	10		Photo	200x300	sporadisch	1983-1993
Thematic Mapper		thermal	120	1				seit 1982
		multisp	30	6		180x180	16	
SPOT	Pan	pan	10	1; 510-730		60x60	≤5	seit 1986
	XS	multisp	20	3		60x60	≤5	
IRS-1C	Pan	pan	5,8	1; 500-750	6	70x70	5	seit 1996
	LISS	multisp	23,5	4	7	141x141	24	
IRS-1D	Pan	pan	5,2	1; 500-750	6			seit 1997
	LISS	multisp	23,7	4	7			
SPOT 4	Pan	pan	10	1; 610-680		60x60		seit 1998
	XS	multisp	20	4		60x60		
IKONOS-1		pan	1	1; 450-900		11x11		ab 1998
		multisp	4	4		11x11		
CLARK		pan	3	1				ab 1998
		multisp	15	3				
QUICK- BIRD		pan	0,82	1; 450-900	11	22x22	1-4	ab 1999
		multisp	3,28	4	11	22x22	1-4	
OrbView-3		pan	1 oder 2	1; 450-900		8	<3	ab 1999
		multisp	4	4		8	<3	
OrbView-4		pan	1 oder 2	1; 450-900		8	<3	ab 2000
		multisp	8	280 !		8	<3	
SPOT 5A	Pan	pan	5	1; 510-730				ab 2001
	XS	multisp	10	4				

Da die russischen photographischen Aufnahmen nur sporadisch und oft nur bis zum Jahr 1993 erhältlich sind, stehen derzeit nur IRS-1C-Pan, IRS-1D-Pan und SPOT-Pan-Aufnahmen als operationelle, hochauflösende digitale Datensätze zur Verfügung.

Die folgenden Abbildung 42 und 43 sind im Internet unter <http://www.icg.tu-graz.ac.at/EB> auf den Erdbeobachtungsseiten zu finden, die von R.Kalliany gestaltet werden. Hier wird ein Überblick über die Lage der IRS-1C-Szenen in Österreich gegeben. Wie man leicht erkennen kann, muß man eine sehr große Überlappung in Kauf nehmen, um das gesamte Gebiet abzudecken. Dabei ist die ganze Szene jene Fläche, die eine multispektrale LISS-Szene aufnimmt. Die Viertelszene mit $70 \times 70 \text{ km}^2$ entspricht der Größe einer panchromatischen Szene. Man kann von den LISS-Szenen ganze oder nur eine Viertelszene kaufen, von den panchromatischen Aufnahmen kann man auch sogenannte Subszenen mit einer Größe von nur $23 \times 23 \text{ km}^2$ kaufen. In dieser Abbildung ist auch der Blattschnitt der topographischen Karte 1:50000 eingezeichnet, und darin, in Form von kleinen Kreisen, die Lage der Paßpunkfeatures, die für Österreich zur Verfügung stehen.

Für dieses Projekt wurde die Aufnahme 30/35 A vom 9. August 1996 panchromatisch und multispektral angekauft.




Abbildung 42

Österreichische Überflugsgebiete von IRS-1C

Weiters wird die Abdeckung von Österreich mit Thematic Mapper Aufnahmen dargestellt. Die Abbildung 43 zeigt die Lage der aufgenommenen Streifen und die Szenen. Bei der Bestellung dieser Aufnahmen kann aber innerhalb eines Streifens das gewählte Gebiet beliebig verschoben werden ("shifted scene"), auch bei den Viertelszenen ($90 \times 90 \text{ km}^2$) ist man frei, das Gebiet

innerhalb eines Flugstreifens zu wählen. Die verwendeten TM-Aufnahmen sind die Szene 191-27 vom 1. September 1991 und eine shifted TM-Szene aus dem Streifen 191 vom 29. Juni 1997.




Abbildung 43

Lage der TM-Szenen und der Paßelemente mit dem Blattschnitt der ÖK-50

SPOT Aufnahmen können vorbestellt werden, und werden so mit höherer Priorität aufgenommen. Abgesehen von der Wolkenbedeckung können so innerhalb kurzer Zeit die gewünschten Gebiete mit SPOT-Pan-Aufnahmen abgedeckt werden. Für diese Arbeit wurde eine SPOT-Pan-Aufnahme vom 29. Juni 1997 gekauft, die das südliche Gebiet des Salzammergutes abdeckt.

Mit zunehmender Anzahl hochauflösender Aufnahmesysteme werden auch immer mehr Aufnahmen zur Verfügung stehen, die wolkenfrei und hochauflösend ein Gebiet abdecken. Unter der www-Adresse

<http://www.icg.tu-graz.ac.at/EB>

sind die neuesten Arten der Aufnahmen und deren Parameter, die von der österreichischen Erdbeobachtungsgruppe laufend aktualisiert werden, abrufbar.

Lebenslauf

- | | |
|--|---|
| 21. September 1967 | geboren als viertes von sechs Kindern der Landwirte Franz und Zäzilia Sindhuber |
| 1974 bis 1978 | Volksschule in Wolfsbach |
| 1978 bis 1986 | Gymnasium im Stift Seitenstetten, neusprachlicher Zweig |
| 4. Juni 1986 | Matura |
| 1986 bis 1993 | Studium Vermessungswesen,
Wahlfachgruppe Photogrammetrie und Kartographie |
| 27. November 1993 | Sponsion zur Diplomingenieurin für Vermessungswesen |
| 1989 bis 1997 | Konservatorium für Kirchenmusik der Erzdiözese Wien |
| 15. Dezember 1993
bis 4. Februar 1998 | Vertr.-Ass. am Institut für Photogrammetrie und Fernerkundung
der Technischen Universität Wien |
| seit 5. Februar 1998 | Forschungsassistentin am Institut für Photogrammetrie und
Fernerkundung |

Bisher erschienen:

- Heft 1 Kolloquium der Assistenten der Studienrichtung Vermessungswesen 1970 - 1973, Dezember 1973.
- Heft 2 EGGER-PERDICH-PLACH-WAGENSOMMERER, Taschenrechner HP 45 und HP 65, Programme und Anwendungen im Vermessungswesen, 1. Auflage, März 1974, Special Edition in English, Juli 1974, 2. verbesserte Auflage, November 1974.
- Heft 3 Kolloquium der Assistenten der Studienrichtung Vermessungswesen 1973 - 1974, September 1974.
- Heft 4 EGGER-PALFINGER-PERDICH-PLACH-WAGENSOMMERER, Tektronix-Tischrechner TEK 31, Programmbibliothek für den Einsatz im Vermessungswesen, November 1974.
- Heft 5 K. LEDERSTEGGER, Die horizontale Isostasie und das isostatische Geoid, Februar 1975.
- Heft 6 F. REINHART, Katalog von FK4 Horrebow-Paaren für Breiten von +30 bis +60, Oktober 1975.
- Heft 7 Arbeiten aus dem Institut für Höhere Geodäsie, Wien, Dezember 1975.
- Heft 8 Veröffentlichungen des Instituts für Photogrammetrie zum XIII. Internationalen Kongreß für Photogrammetrie in Helsinki 1976, Wien, Juli 1976.
- Heft 9 W. PILLEWIZER, Felsdarstellung aus Orthophotos, Wien, Juni 1976.
- Heft 10 PERDICH-PLACH-WAGENSOMMERER, Der Einsatz des programmierbaren Taschenrechners Texas Instruments SR-52 mit Drucker PC100 in der ingenieurgeodätischen Rechentechnik, Wien, Mai 1976.
- Heft 11 Kolloquium der Assistenten der Studienrichtung Vermessungswesen 1974 - 1976, November 1976.
- Heft 12 Kartographische Vorträge der Geodätischen Informationstage 1976, Wien, Mai 1977.
- Heft 13 Veröffentlichung des Instituts für Photogrammetrie anlässlich des 80. Geburtstages von Prof. Dr.h.c. K. Neumaier, Wien, Januar 1978.
- Heft 14 L. MOLNAR, Self Checking Analytical Relative Orientation and Strip Formation, Wien, Dezember 1978.
- Heft 15 Veröffentlichung des Instituts für Landesvermessung anlässlich des 80. Geburtstages von Prof. Dr. Alois Bavir, Wien, Januar 1979.
- Heft 16 Kolloquium der Assistenten der Studienrichtung Vermessungswesen 1976 - 1979, Wien, November 1979.
- Heft 17 E. VOZIKIS, Die photographische Differentialumbildung gekrümmter Flächen mit Beispielen aus der Architekturbildmessung, Wien, Dezember 1979.
- Heft 18 Veröffentlichung des Instituts für Allgemeine Geodäsie anlässlich des 75. Geburtstages von Prof. Dipl. Ing. Dr. F. Hauer, Die Höhe des Großglockners, Wien, 1981.
- Heft 19 H. KAGER, Bündeltriangulation mit indirekt beobachteten Kreiszentren, Wien, April 1981.
- Heft 20 Kartographische Vorträge der Geodätischen Informationstage 1980, Wien, Mai 1982.
- Heft 21 Veröffentlichung des Instituts für Kartographie anlässlich des 70. Geburtstages von Prof. Dr. Wolfgang Pillewizer: Glaziologie und Kartographie, Wien, Dezember 1982.
- Heft 22 K. TEMPFLI, Genauigkeitsschätzung digitaler Höhenmodelle mittels Spektralanalyse, Wien, Mai 1982.
- Heft 23 E. CSAPLOVICS, Interpretation von Farbinfrarotbildern, Wien, November 1982.
- Heft 24 J. JANSÁ, Rektifizierung von Multispektral-Scanneraufnahmen - Entwicklung und Erprobung eines EDV-Programms, Wien, Mai 1983.

- Heft 25 Zusammenfassungen der Diplomarbeiten, Dissertationen und Habilitationen an den geodätischen Instituten der TU Wien, Wien, November 1984.
- Heft 26 T. WUNDERLICH, Die voraussetzungsfreie Bestimmung von Refraktionswinkeln, Wien, August 1985.
- Heft 27 G. GERSTBACH (Hrsg.), Geowissenschaftliche/geotechnische Daten in Landinformationssystemen - Bedarf und Möglichkeiten in Österreich, Wien, Juni 1986.
- Heft 28 K. NOVAK, Orientierung von Amateuraufnahmen ohne Paßpunkte, Wien, August 1986.
- Heft 29 Veröffentlichung des Instituts für Landesvermessung und Ingenieurgeodäsie, Abteilung Ingenieurgeodäsie anlässlich des 80. Geburtstag von Prof. Dipl. Ing. Dr. F. Hauer, Wien, Oktober 1986.
- Heft 30 K.-H. ROCH, Über die Bedeutung dynamisch ermittelter Parameter für die Bestimmung von Gesteins- und Gebirgseigenschaften, Wien, Februar 1987.
- Heft 31 G. HE, Bildverbesserung mittels digitaler Filterung, Wien, April 1989.
- Heft 32 F. SCHLÖGELHOFER, Qualitäts- und Wirtschaftlichkeitsmodelle für die Ingenieurphotogrammetrie, Wien, April 1989.
- Heft 33 G. GERSTBACH (Hrsg.), Geowissenschaftliche/geotechnische Daten in Landinformationssystemen - Datenbestände und Datenaustausch in Österreich, Wien, Juni 1989.
- Heft 34 F. HOCHSTÖGER, Ein Beitrag zur Anwendung und Visualisierung digitaler Geländemodelle, Wien, Dezember 1989.
- Heft 35 R. WEBER, Lokale Schwerefeldmodellierung unter Berücksichtigung spektraler Methoden zur Geländereduktion, Wien, April 1990.
- Heft 36 o.Prof. Dr. Hans Schmid zum 70. Geburtstag. Veröffentlichung der Abteilung für Landesvermessung, Wien, Oktober 1990.
- Heft 37 G. GERSTBACH, H.P. HÖLLRIEGL und R. WEBER, Geowissenschaftliche Informationsbörse - Eine Nachlese zu GeoLIS II, Wien, Oktober 1990.
- Heft 38 R. ECKER, Rastergraphische Visualisierungen mittels digitaler Geländemodelle, Wien, August 1991.
- Heft 39 Kartographische Forschungen und Anwendungsorientierte Entwicklungen, herausgegeben von W. Stams und F. Kelnhofer zum 80. Geburtstag von Prof. Dr. W. Pillewizer, Wien, Juli 1991.
- Heft 39a W. RIEGER, Hydrologische Anwendungen des digitalen Geländemodelles, Wien, Juli 1992.
- Heft 40 K. STEINNOCHER, Methodische Erweiterungen der Landnutzungsklassifikation und Implementierung auf einem Transputernetzwerk, Wien, Juli 1994.
- Heft 41 G. FORKERT, die Lösung photogrammetrischer Orientierungs- und Rekonstruktionsaufgaben mittels allgemeiner kurvenförmiger Elemente, Wien, Juli 1994.
- Heft 42 M. und W. SCHÖNER, Photogrammetrische und glaziologische Untersuchungen am Gåsbre (Ergebnisse der Spitzbergenexpedition 1991), Wien, Februar 1996.
- Heft 43 M. ROIC, Erfassung von nicht signalisierten 3D-Strukturen mit Videotheodoliten, Wien, April 1996.
- Heft 44 G. RETSCHER, 3D-Gleiserfassung mit einem Multisensorsystem und linearen Filterverfahren, Wien, April 1996.
- Heft 45 W. DAXINGER, Astrogravimetrische Geoidbestimmung für Ingenieurprojekte, Wien, Juli 1996.
- Heft 46 M. PLONER, CCD-Astronomie von Objekten des geostationären Ringes, Wien, November 1996.
- Heft 47 Zum Gedenken an Karl Killian „Ingenieur“ und „Geodät“ 1903-1991, Veröffentlichung der Fachgruppe Geowissenschaften, Wien, Februar 1997