
BERLINER GEOWISSENSCHAFTLICHE ABHANDLUNGEN

Reihe A/Band 35

Heinz Burger

Untersuchungen zur Klassifizierung von Gesteins-
oberflächen auf Landsat-Aufnahmen mit Hilfe von
Signatur- und Texturparametern



Berlin 1981

Verlag von Dietrich Reimer in Berlin

BERLINER GEOWISSENSCHAFTLICHE ABHANDLUNGEN

Reihe A: Geologie und Paläontologie · Reihe B: Geophysik · Reihe C: Kartographie

D 188

Herausgegeben von geowissenschaftlichen Instituten
der Freien und der Technischen Universität Berlin
und der Technischen Fachhochschule Berlin

Schriftleitung:

Dr. G. Pöhlmann (TFH), Dr. H. Seyfried (TU)
Dipl.-Geol. B. Uchdorf (FU)

Für den Inhalt der Beiträge sind die Autoren allein verantwortlich

ISBN 3-49600 221-2

© 1981 by DIETRICH REIMER VERLAG IN BERLIN

Berliner geowiss. Abh.	(A)	35	102 S.	62 Abb., 15 Tab.	Berlin 1981
------------------------	-----	----	--------	------------------	-------------

Heinz Burger

Untersuchungen zur Klassifizierung von Gesteins-
oberflächen auf Landsat-Aufnahmen mit Hilfe von
Signatur- und Texturparametern



1981

Verlag von Dietrich Reimer in Berlin

UNTERSUCHUNGEN ZUR KLASSIFIZIERUNG VON GESTEINSOBERFLÄCHEN AUF
LANDSAT-AUFNAHMEN MIT HILFE VON SIGNATUR- UND TEXTURPARAMETERN⁺

von

Heinz Burger⁺⁺

ZUSAMMENFASSUNG

Der Einsatz des LANDSAT-Satellitensystems zur Abbildung nahezu der gesamten Erdoberfläche (Maßstab 1 : 1 000 000) hat den Geowissenschaften, nicht zuletzt der Geologie, neues Datenmaterial erschlossen, das als zusätzliche Information bei der Bearbeitung großer Gebiete herangezogen werden kann. Der multispektrale Ansatz des Satellitensystems, d. h. die Abbildung der Erdoberfläche in verschiedenen Spektralbereichen vom Grün bis zum nahen Infrarot, macht neue Arbeitsmethoden zur Datenanalyse notwendig.

Während die visuelle Interpretation einer LANDSAT-Szene für geübte Photointerpreten im wesentlichen nur die Arbeit mit einem kleineren Maßstab bedeutet, erfordert die Verarbeitung der Multispektralinformation neue Untersuchungsmethoden und spezielle Auswertegeräte zur digitalen Bildverarbeitung.

Die Anwendung der digitalen Klassifizierungsverfahren in der Geologie setzt voraus, daß die Datenstruktur der Gesteinsoberflächen, d. h. ihre spektralen Merkmalswerte (Signaturen), bekannt sind. Um diese Daten für wichtige Gesteinstypen (Sedimentgesteine, Lockergesteine, Magmatite, Metamorphite) zu untersuchen, wurden Testgebiete im Sahara-Raum ausgewählt, für die ausreichend Beobachtungsmaterial (Geländebeobachtung, großmaßstäbige geologische Karten) zur Identifizierung der Gesteine im Satellitenbild vorhanden ist. Es zeigte sich, daß die Streubereiche der Merkmalswerte in allen Spektralbereichen so groß ist und die Spektralkanäle so hoch miteinander korreliert sind, daß eine Klassifizierung mit üblichen Algorithmen (Quadermethode, "nearest-neighborhood"-Methode) eine hohe Fehlerrate liefert (Kap. 3).

Eine Verbesserung der Klassifizierungsergebnisse kann erreicht werden, wenn die starken Helligkeitsschwankungen, die durch das Oberflächenrelief verursacht werden, durch Quotientenbildung von Spektralkanälen unterdrückt werden. Vor dieser Operation ist eine Eliminierung des störenden Einflusses des Streulichts der Atmosphäre notwendig. Bei Gesteinsoberflächen bietet sich hierzu eine Regressionsmethode an, wie sie in Kap. 3.4.2 entwickelt wurde.

⁺ Dissertation an der Freien Universität Berlin

⁺⁺ Anschrift des Verfassers: Dipl.-Math. Heinz Burger, Institut für Geologie, Freie Universität Berlin, Altensteinstr. 34 A, D-1000 Berlin 33

Ein wichtiges Merkmal zur visuellen Unterscheidung von Gesteinen in Luft- und Satellitenbildern ist neben den Helligkeitsunterschieden die Bildtextur. Sie kann im Digitalbild durch Merkmalswerte beschrieben werden, indem zu jedem Bildpunkt dessen umgebende Pixel analysiert und quantitative Parameter abgeleitet werden. Hauptprobleme bei dieser Art der Merkmalsextraktion liegen in der optimalen Wahl der Umgebung und in den hohen Rechenzeiten, die etwa um den Faktor 10^2 größer sind, als bei der Verwendung der Signaturwerte.

Eine Analyse von typischen Gesteinstexturen im Satellitenbild zeigt, daß eine Trennung verschiedener Gesteinseinheiten mit Hilfe linearer Trennfunktionen eine Umgebungsgröße von 9×9 bis 15×15 Pixel erfordert, um eine Fehlerrate zu erhalten, die unter 10 % liegt (Kap. 4).

Eine Reduzierung der Rechenzeit und eine Verbesserung der Klassifizierungsergebnisse erhält man durch eine passende Bildsegmentierung in "homogene" und "inhomogene" Bildbereiche. Dabei wird von der Modellvorstellung ausgegangen, daß eine große Gesteinsoberfläche ohne Relief in allen Bildpunkten - abgesehen von Signalrauschen - dieselben spektralen Reflexionswerte liefert. Die "spektrale Distanz" eines "homogenen" Bildpunktes zu seinen Nachbarpunkten ist klein gegenüber Bildpunkten, die an der Grenze zweier Gesteinseinheiten mit unterschiedlichem Spektralverhalten oder in stark texturierten Oberflächen liegen. Dementsprechend werden bei einer Klassifizierung Bildpunkte in homogenen Flächen entsprechend ihren spektralen Signaturen, in inhomogenen Flächen entsprechend den abgeleiteten Texturmerkmalen zugeordnet (Kap. 5). Der Vorteil der in der vorliegenden Arbeit entwickelten Methode liegt darin, daß für einen Bildpunkt nicht Signatur- und Texturparameter berechnet und zu einem Signatur-Textur-Merkmalvektor zusammengefaßt werden, sondern nur eine Art dieser Merkmalswerte nach einer Abfrage auf Zugehörigkeit zum "homogenen" oder "inhomogenen" Bildsegment. Eine Verallgemeinerung dieser Methode wird diskutiert.

SUMMARY

Since the launching of Landsat 1 in 1972 the surface of the earth has been covered by multispectral scanner installed on the satellite platform. This type of data represents a new dimension for earth scientists with applications in cartography, agriculture, forestry and - last not least - geology. Multispectral images must be considered as an additional tool for the investigation of large areas. For a trained photo-geologist the interpretation of monochromatic satellite imagery means only working on a smaller scale whereas multispectral images require new scientific methodology and specific instrumentation.

The application of digital classification to geological problems assumes a knowledge of the data structure of spectral vectors ("signatures"), of the surface of the rocks. In order to determine this data for important rock types (sedimentary, magmatic, metamorphic, sand and gravel plains), test areas were chosen in the Sahara where sufficient control information was available (large scale maps, field observations, aerial photographs).

It was found that the variance of signature values in all spectral channels is large and that the correlation between different channels is very high. In this case the use of simple classification algorithms ("hyper-box method", "nearest neighborhood method") would give high error rates.

Classification results can be improved by suppressing the variations of intensity caused by surface relief. This can be done by rationing two different spectral channels after eliminating the effects of diffuse skylight. For this purpose a regression method is developed (Chap. 3.4.2) which gives good results especially in the case of rock surfaces in arid areas.

Nevertheless, digital classification method utilizing spectral signatures of rocks alone are not quite satisfactory so that additional information such as texture or shape are necessary to improve identification of different rock types.

The textural structure of rock surfaces on satellite imagery can be examined by choosing different training areas within the image and by extracting local parameters for each picture element (pixel). Local parameters can be obtained by taking into account the distribution of gray values within a certain neighborhood of a pixel. Various statistical methods (principal component analysis, canonical analysis, analysis of variance etc.) are used to analyze these parameters with the aim of separating different rock types. This determination of rocktype by means of texture measures can be accomplished by linear discriminant functions using at least a 9 by 9 neighborhood for each pixel to insure an error rate of less than 10 percent (Chapt. 4).

Further improvement of classification results and a reduction of computer time can be achieved by a suitable segmentation of the image by means of its homogeneity. This parameter takes into account that the "spectral distance" of a pixel to its neighbors is small within poorly structured areas ("homogeneous image I_h ") and large at the borders of adjacent rocks or textured areas ("inhomogeneous image I_i "). A pixel is therefore classified according to its signature vector if it belongs to I_h and according to its texture parameters if it belongs to I_i . The main advantage of this method lies in the fact that time consuming computations of texture measures for a pixel are necessary only for "inhomogeneous pixels" whereas for "homogeneous pixels" the signatures of the pixel can be used. A generalization of the method is discussed at the end of the paper.

RESUME

L'utilisation du système de satellite LANDSAT pour la reproduction de presque toute la surface terrestre a apporté aux sciences de la terre, en particulier à la géologie, des données nouvelles, qui peuvent être utilisées comme information complémentaire lors de l'étude de régions étendues. L'approche multispectrale du système de satellite, c'est-à-dire la reproduction de la surface terrestre en différentes bandes spectrales allant du vert jusqu'à la limite de l'infrarouge, rend nécessaires de nouvelles méthodes d'analyse des données. Alors que l'interprétation visuelle d'une scène LANDSAT représente pour un interprète de photographies expérimenté surtout le travail à petite échelle, le traitement de l'information multispectrale requiert de nouvelles méthodes d'analyse et des appareils d'interprétation spéciaux pour le traitement informatique des images.

L'application en géologie des procédés informatiques de classification suppose que la structure des données de surfaces de roches, c'est-à-dire les valeurs spectrales de leurs caractéristiques ("Signaturen"), soit connue. Pour étudier ces données selon des types de roches importants (roches sédimentaires, magmatiques, métamorphiques), on a choisi des zones-test dans le Sahara pour lesquelles il existe suffisamment d'observations (observations sur le terrain, cartes géologiques à grande échelle) pour permettre l'identification des roches sur l'image de satellite. Il est apparu que la variabilité des valeurs des caractéristiques est si grande et que les canaux spectraux sont si corrélés, que la classification avec des algorithmes usuels ("hyper-box-method", "nearest-neighborhood-method") donne un taux d'erreurs élevé (chapitre 3). Une amélioration des résultats de la classification peut être obtenue, si l'on réduit les fortes variations de luminosité dues au relief de la surface en formant des quotients de canaux spectraux. Avant d'effectuer cette opération il est nécessaire d'éliminer l'influence perturbatrice de la lumière diffuse de l'atmosphère. Dans le cas des surfaces de roches une méthode de régression, telle qu'elle est développée au chapitre 3.4.2, est appropriée pour cela.

La texture de l'image est, outre les signatures, un caractère important pour la distinction visuelle de roches dans les images aériennes ou de satellite. La texture peut être décrite dans l'image informatisée avec les valeurs de caractéristiques, ce qui se fait en analysant les pixels voisins à chaque point de l'image et en dérivant des paramètres quantitatifs. Les problèmes majeurs de ce genre d'extraction de caractéristiques sont le choix optimal du voisinage ainsi que les temps de calcul élevés, lesquels sont 10^2 fois plus grands que lors de l'utilisation de valeurs de "signatures". Une analyse de textures typiques

de roches dans l'image de satellite montre que la distinction de différentes formations de roches à l'aide de fonctions de séparation linéaires requiert un voisinage de 9x9 jusqu'à 15x15 pour obtenir un taux d'erreurs inférieur à 10% (chapitre 4).

On obtient une réduction du temps de calcul et une amélioration des résultats en segmentant l'image en zones "homogènes" et "non-homogènes". On part de l'hypothèse qu'une grande surface de roche sans relief - excepté le "bruit" - donne en tous les points les mêmes valeurs de réflexion spectrale. La "distance spectrale" d'un point "homogène" à ses points voisins est petite par rapport à celle de points qui se trouvent à la limite de deux formations de roches ayant un comportement spectral différent ou qui se situent dans une surface fortement texturée. Ainsi, lors d'une classification, on attribue les points provenant de surfaces homogènes selon leurs "signatures" spectrales, tandis que pour les surfaces non-homogènes on se sert des caractéristiques texturales que l'on a dérivées (chapitre 5). L'avantage de la méthode développée dans ce travail réside en ce que pour un point donné de l'image, on ne calcule pas les paramètres de signatures et de texture, que l'on réunit en un vecteur de signatures et de texture; mais on calcule seulement un type de valeurs de caractéristiques après avoir reconnu l'appartenance à un segment "homogène" ou "non-homogène" de l'image. La généralisation de cette méthode est discutée ici.

VORWORT

Die vorliegende Arbeit wurde am Geologischen Institut und am Institut für Angewandte Geologie der Freien Universität Berlin angefertigt. Für die Anregung zu dieser Arbeit und die Betreuung während der Durchführung gilt Herrn Prof. Dr. F. K. List mein besonderer Dank.

Ein weiterer Dank gilt Herrn Prof. Dr. Skala, der diese Arbeit während der gesamten Zeit unterstützte und immer zur Diskussion von Fragen bereit war.

Den Mitarbeitern des Großrechenzentrums für die Wissenschaft Berlin (GRZ) danke ich für ihre Beratung bei Programmierungsfragen sowie für die Erstellung spezieller Routinen, die zur Verarbeitung der Magnetbänder als Bildinformation am TR440 unerlässlich waren.

Die Abspielung von Digitalbildern auf dem HELL-Chromograph verdanke ich den Mitarbeitern des Instituts für Satelliten-Meteorologie, den Herren K. Groth, W. Müller und E. Hilt, mit dessen FFT-Programm auch die Fouriertransformation verschiedener Landsat-Subszenen durchgeführt wurde.

Fruchtbare Diskussionen geologischer Probleme bei der digitalen Bildauswertung verdanke ich Herrn Priv. Doz. Dr. D. Helmcke, Dr. B. Meißner und Herrn Dipl. Geol. H. Schmitz. Herrn Prof. Dr. W. Schwarzacher (Belfast) möchte ich an dieser Stelle für die vielen Diskussionen über Probleme bei der Simulation von geologischen Prozessen danken, denen die Anregung zur Simulation von Bildtexturen entstammt.

Für die Zeichen- und Photoarbeiten möchte ich Fr. W. Jung und Herrn H. Graetsch an dieser Stelle nochmals danken.

INHALTSVERZEICHNIS

	Seite
1. EINLEITUNG	7
1.1 Satellitenbilddauswertung in der Geologie	7
1.2 Beschreibung des Landsat-Aufnahmesystems	8
1.2.1 Umlaufbahn	9
1.2.2 Aufnahmegeriite	10
1.2.3 Spektralbereiche	10
1.2.4 Aufnahmegeometrie	10
1.2.5 Datenaufzeichnung	11
1.2.6 Atmosphärische Einflüsse	12
1.3 Computerunterstützte Bildverarbeitung an den Geologischen Instituten der FU Berlin	13
1.3.1 Das hybride Bildverarbeitungssystem ISI-EARTHVIEW II/System 130	14
1.3.2 Programme zur Bildverarbeitung	18
1.4 Aufgabenstellung dieser Arbeit	19
2. GRUNDLAGEN DER MUSTERERKENNUNG	20
2.1 Objektraum und Bildraum	20
2.2 Merkmalsextraktion im Bildraum	21
2.2.1 Spektrale Homogenität	21
2.2.2 Operationen im Bildraum	22
2.3 Klassenbildung im Merkmalsraum	23
2.4 Entscheidungsfunktionen	24
2.4.1 Lineare Diskriminanzfunktionen	26
2.4.2 Lineare Diskriminanzfunktionen bei k Klassen ($k > 2$)	28
2.5 Klassifizierung	28
2.5.1 BAYES'sche Fehlerminimierung	28
2.5.2 Klassifizierung normalverteilter Merkmalsvektoren	30
2.5.3 Klassifizierung mit Zurückweisungsklasse	31
2.6 Reduktion der Dimension des Merkmalsraumes	33
2.6.1 Auswahl von Variablen	34
2.6.2 Reduktion der Variablenzahl durch Bildtransformation	35
3. SPEKTRALE SIGNATUREN VON GESTEINSOBERFLÄCHEN IM SAHARA-RAUM	36
3.1 Probleme der Signatuererkennung	36
3.2 Signaturen von Gesteinsoberflächen	37
3.2.1 Granitische Intrusiva	43
3.2.2 Metamorphite	43
3.2.3 Sandsteine	43
3.2.4 Vulkanite	44
3.2.5 Lockergesteine	44
3.3 Korrelationsanalyse der Landsat-Spektralkanäle	45
3.4 Spezielle Untersuchungsmethoden	47
3.4.1 Die Hauptachsentransformation	47
3.4.2 Quotientenbilder	48
3.5 Schlußfolgerungen	53
4. TEXTURPARAMETER VON GESTEINSOBERFLÄCHEN AUF LANDSAT-SZENEN DES SAHARA-RAUMES ..	54
4.1 Bildtexturen von Gesteinsoberflächen	54
4.2 Quantitative Erfassung von Texturen	56

	Seite	
4.2.1	Bisherige Arbeiten auf dem Gebiet der Texturerkennung	56
4.2.2	Elementarzelle und Bestimmungsfläche	58
4.2.3	Parameter der Elementarzelle	59
4.2.4	Parameter der Bestimmungsfläche	60
4.3	Trennungsgüte der Parameter	62
4.3.1	Beschreibung der Trainingsgebiete	62
4.3.2	Diskriminanzanalyse bei zwei Gruppen	65
4.3.3	Varianzanalyse bei mehr als zwei Gruppen	69
4.4	Canonische Transformation	70
4.5	Klassifizierung der Testgebiete mit Hilfe der Texturparameter	74
4.5.1	Berechnung der Trennfunktionen	74
5.	KLASSIFIZIERUNG AUF DER BASIS VON SIGNATUR- UND TEXTURMERKMALEN	78
5.1	Texturerkennung bei Multispektralaufnahmen	78
5.2	Bildsegmentierung	78
5.3	Klassifizierung des segmentierten Bildes	83
5.4	Diskussion und Ausblick	87
6.	LITERATURVERZEICHNIS	94
	ANHANG	97
	A1: Bildmaterial und Computerprogramme	97
	A2: Varianzanalyse	98
	A3: Hauptkomponententransformation versus Canonische Transformation	99
	A4: Summen von normalverteilten Zufallsvariablen und Absolutbeträgen	100
	A5: Bezeichnungen und Symbole	102

1. EINLEITUNG

1.1 Satellitenbilddauswertung in der Geologie

Eine wesentliche Erweiterung der Kenntnis geologischer Sachverhalte eines Gebietes erhält man durch die geologische Kartierung. Definiert man die geologische Kartierung als die Aufgabe, die räumliche Lage von Gesteinseinheiten auf Grund eines vorgegebenen stratigraphischen und petrographischen Schemas in zweidimensionalen Projektionen darzustellen, so ergeben sich u. a. folgende Unterscheidungskriterien bei der Geländeaufnahme:

- Mineralbestand und -gefüge der Gesteine (Farbe, Härte etc.)
- Fossilgehalt der Sedimentgesteine
- Lagerung der Gesteine im Raum (Bruch- und Falten tektonik).

Neben diesen klassischen Untersuchungsmethoden entwickelten sich ab etwa 1930 durch die Verwendung von Luftbildern indirekte Untersuchungsmethoden, die es erlauben, größere Gebiete in kürzerer Zeit zu bearbeiten.

Eine sprunghafte Weiterentwicklung dieser Arbeitsmethode ergab sich durch die Weltraumfahrt, durch die es möglich wurde, innerhalb weniger Jahre eine nahezu vollständige Bildbedeckung der Erdoberfläche zu erhalten.

Von besonderer Bedeutung für die Geowissenschaften ist in diesem Zusammenhang das Landsat-Satellitensystem, das seit 1972 Bilddaten liefert, die in Form von S/W-Bildern, Falschfarb-Kompositen oder in digitaler Form auf Magnetband allgemein zugänglich sind.

Die Anwendungsmöglichkeiten für diese Daten sind breit gefächert, wobei die Land- und Forstwirtschaft an erster Stelle steht. Die Gründe hierfür liegen zum Teil an den verwendeten Aufnahmesystemen (Sensoren), zum anderen Teil daran, daß Vorhersagen von Ernteerträgen oder die Erkennung von Umweltschäden von großem wirtschaftlichen Wert sind. Weitere Anwendungsmöglichkeiten liegen im Bereich der Kartographie, der Regionalanalyse, der Geomorphologie und nicht zuletzt der Geologie. Der Anfang der Satellitenbilddauswertung ist geprägt durch Untersuchungen, die das Maß der Übereinstimmung zwischen den Ergebnissen dieser Interpretation und denen herkömmlicher Arbeitsmethoden feststellen sollte.

Im Bereich der Geologie zeigte sich jedoch, daß die Information, die von Satellitenbildern geliefert wird, sich wesentlich unterscheidet von Informationen aus Geländeaufnahmen. Entsprechendes gilt in verstärktem Maße für Multispektralaufnahmen. Der unterschiedliche Charakter der Daten bei der Geländeaufnahme und der Satellitenbilddauswertung läßt nicht erwarten, daß eine Klassifizierung der Gesteine nach der einen Methode mit der Klassifizierung nach der anderen Methode völlig übereinstimmt. Vielmehr muß die Satellitenbild-Information ähnlich wie die Ergebnisse der Seismik, der Geomagnetik oder der Gravimetrie als selbständige Informationsquelle gewertet werden, die z u s ä t z l i c h zu den bisher verwendeten Methoden Daten über den geologischen Bau der Erde liefert.

Die angespannte Rohstoff- und Energiesituation macht eine zeit- und kostensparende Auswertung von Satellitendaten notwendig. Der kleine Maßstab der Landsat-Aufnahmen macht sich in diesem Zusammenhang günstig bemerkbar, da hierdurch große Gebiete einheitlich kartiert und ausgewertet werden können. Bei dieser Auswertung sind folgende Schwerpunkte festzustellen:

- Geologische Kartierung und großräumige Strukturanalyse (ROWAN et al. 1974; RAINA & SHARMA 1974; HELMCKE et al. 1976; BODECHTEL & HAYDN 1977; LIST et al. 1978; BROCKMANN et al. 1977)
- Untersuchung der Änderung der Reflexion von Gesteinen und von Vegetation durch Mineralanreicherungen im Untergrund (STANICOFF 1973; LEE 1974; ROWAN et al. 1974; LYON 1975; SMITH 1977)
- Hydrogeologische Untersuchungen (MOORE et al. 1975; MERCANTI 1977).

Diese Schwerpunkte sind nicht deutlich zu trennen, da die Untersuchung von Bruchstrukturen bei der Lagerstättenprospektion eine ebenso große Rolle spielen kann, wie bei der Analyse des regionalen Baus eines Gebietes. Spektrale Anomalien bei Gesteinseinheiten oder bei der Vegetationsbedeckung können Indizien für

erhöhte Metallkonzentrationen oder Änderungen des Feuchtigkeitshaushalts des Untergrundes sein. Diese Unterschiede im Reflexionsverhalten sind oft nur in einem Spektralkanal zu beobachten, so daß für die Analyse einer Landsat-Szene möglichst alle vier Spektralaufnahmen vorliegen sollten. Bei der geologischen Auswertung von Landsat-Aufnahmen tritt dabei als Schwierigkeit die hohe Redundanz der vier Spektralkanäle bei Festgesteinen auf (LYON 1970).

Da die bisher verwendeten Spektralkanäle im Landsat-System bei Festgesteinen kaum unterschiedliche Information liefern, bemüht man sich, für künftige Satellitenmissionen passende Spektralbereiche und Sensoren zu entwickeln, die mit optimalem technischen Aufwand gute Unterscheidungskriterien für Gesteine liefern, um eine automatische oder halbautomatische Kartierung mit Hilfe von Satellitenaufnahmen zu ermöglichen (TARANIK 1978).

Die Notwendigkeit der computerunterstützten Bildverarbeitung ergibt sich aus verschiedenen Gründen:

- die Menge des gelieferten Datenmaterials wächst sehr schnell
- die Aufspaltung in mehrere Spektralkanäle (bis zu 20) läßt eine effektive visuelle Auswertung nicht mehr zu
- der Einsatz der Satellitenbilder zur Unterstützung von Explorationsvorhaben erfordert eine schnelle und kostengünstige Auswertung, die am besten interaktiv mit einem speziell für diese Zwecke entwickelten Computer durchgeführt werden kann
- die Forderung in den Naturwissenschaften nach Objektivierung von Ergebnissen verlangt eine Reproduzierbarkeit, die nur durch eine quantitative Beschreibung von Bildeigenschaften erreicht werden kann.

Satellitenbilder erlauben den Überblick über den regionalen Bau großer Gebiete. Um z. B. das Tibesti-Gebirge (Tschad) mit Landsat-Aufnahmen zu überdecken, sind 10 bis 15 Aufnahmen (je 185 x 185 km) notwendig (LIST et al., 1978). Ein Photomosaik für eine Landsat-Szene würde

ca. 5 000 Luftbilder im Maßstab 1 : 15 000 oder

ca. 1 500 Luftbilder im Maßstab 1 : 30 000

erfordern, die in akzeptablen Zeiträumen nicht interpretiert werden könnten.

Eine geologische Bearbeitung großer Gebiete wird als ersten Arbeitsschritt die Interpretation der entsprechenden Satellitenbilder enthalten, wobei Hintergrundwissen aus verschiedenen Quellen bei der Interpretation einfließen sollte. Für die digitale Bildverarbeitung ergeben sich hieraus folgende Aufgaben:

1. Verbesserung der Bildvorverarbeitung (preprocessing), d. h. Eliminierung von Störeffekten, Kontrastverstärkung, geometrische Korrekturen etc.
2. Verstärkung von linearen Bildelementen und anderen Kurvenzügen, um Bruchsysteme und Flußnetze besser erfassen und kartieren zu können
3. Quantitative Erfassung von Texturen und Formelementen
4. Entwicklung spezieller Methoden zur Auswertung der Multispektraldaten, wobei die besondere Struktur der Reflexionsdaten von Gesteinsoberflächen berücksichtigt werden muß.

Zur Entwicklung und Anwendung solcher Algorithmen sind Prozeßrechner konstruiert worden, die spezielle Hardware zur Bildein- und -ausgabe besitzen, sowie Software, die schnelle interaktive Arbeit am Bildschirm erlauben. Dadurch können Ergebnisse aus der Geländeaufnahme oder der Geophysik bei der Bildinterpretation sofort berücksichtigt werden, um als Endprodukt der Interpretationsarbeit eine thematische Karte im weitesten Sinne zu erhalten, in der die verschiedenartigsten Informationen verarbeitet sind.

1.2 Beschreibung des Landsat-Satellitensystems

Bei der Interpretation von Fernerkundungsdaten ist es notwendig, den Einfluß des physikalischen Meßvorgangs auf die Daten zu berücksichtigen. Deshalb seien die für eine geologische Interpretation der Landsat-Aufnahmen wichtigen Charakteristika kurz beschrieben.

Bisher wurden drei Landsat-Satelliten in eine Umlaufbahn gebracht (1972, 1975 und 1978). Ein weiterer Sa-

tellit dieser Reihe ist für 1981 geplant (Abb. 1).

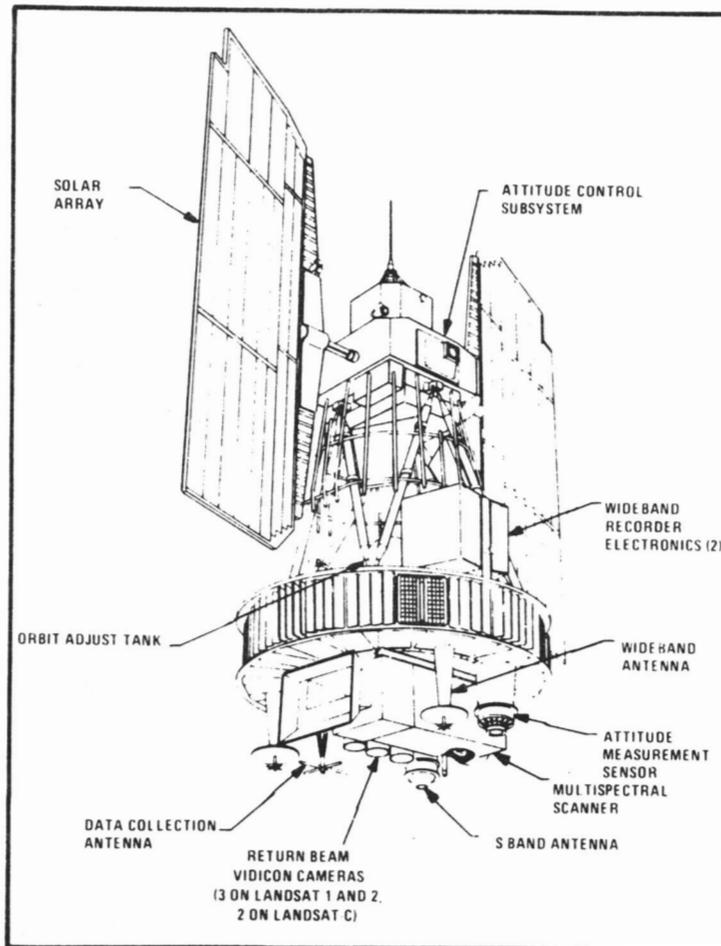


Abb. 1: Schema des Landsat-Satelliten (aus NASA: Landsat Data Users Handbook).

1.2.1 Umlaufbahn

Landsat-Satelliten umkreisen die Erde in einem 915 km hohen, sonnensynchronen Orbit mit 99° Bahnneigung. Diese Umlaufbahn hat den Vorteil, daß man Aufnahmen eines Gebietes unter denselben Beleuchtungsbedingungen erhalten kann. Diese Bedingungen ändern sich zwar im Lauf der Jahreszeiten (Sonnenazimut und Elevationswinkel), jedoch ist das Zeitintervall für eine Oberdeckung der Erdoberfläche auf 9 Tage reduziert, wenn zwei Systeme im Orbit in Betrieb sind. Während dieser Zeitspanne können die Beleuchtungsverhältnisse als konstant angesehen werden, so daß echte multitemporale Untersuchungen möglich sind.

Solche Untersuchungen spielen beispielsweise in der Vulkanologie und Hydrogeologie eine Rolle, aber auch bei der Kartierung pleistozäner Ablagerungen, wo häufig die Vegetationsdecke oder die Speicherung von Feuchtigkeit als Indikator für bestimmte Gesteinsarten benutzt wird.

Für strukturgeologische Untersuchungen ist von Bedeutung, daß sich der Elevationswinkel (in Abhängigkeit von der geographischen Breite) jahreszeitlich ändert. In Gebieten mit geringen Reliefunterschieden wird man Aufnahmen bei möglichst niedrigem Sonnenstand wählen, da die langen Schatten kleine Erhebungen und Senken deutlicher hervortreten lassen. In gebirgigen Regionen wird man Aufnahmen bei hohem Sonnenstand wählen, damit die Reflexionsunterschiede zwischen den beleuchteten Hängen und den der Sonne abgewandten

Hängen nicht zu groß werden.

Bei der statistischen Auswertung von Richtungsverteilungen von Lineationen muß beachtet werden, daß Landsat-Aufnahmen stets bei Morgensonne (9.30 h Ortszeit am Äquator) gemacht werden und hierdurch SW-NE-streichende Strukturen (Falten, Bruchsysteme) bevorzugt erfaßt werden. Wie stark sich dieser systematische Fehler auswirkt, erkennt man am Vergleich der Interpretation einer Landsat-Szene mit der entsprechenden Skylab-Aufnahme (HOUSTON et al. 1977).

1.2.2 Aufnahmegeräte

Wichtigstes Aufnahmegerät im Landsat-Satelliten neben den drei Fernseh-Kameras (RBV: Return beam vidicon) ist der Multispektral-Scanner (MSS: Multi spectral scanner = Zeilenabtaster). Dieser besteht im wesentlichen aus einem oszillierenden Spiegel, der die von der Erdoberfläche reflektierte Strahlung über bestimmte Filter auf verschiedene Detektoren wirft. Jeder Detektor erzeugt entsprechend der einfallenden Strahlung ein Analogsignal von 0...4 Volt. Dieses Signal wird in digitale Helligkeitswerte (0...63 bzw. 0...127) umgewandelt.

Für die Bildqualität ist von Bedeutung, daß bei einer Spiegelschwenkung sechs Zeilen gleichzeitig in vier Spektralkanälen aufgenommen werden. Unterschiede in der Kalibrierung der verschiedenen Detektoren bewirken, daß manche Aufnahmen einen starken Scanlinien-Effekt zeigen, der besonders bei der Kartierung von linearen Bildelementen stört, die etwa in Zeilenrichtung verlaufen.

1.2.3 Spektralbereiche

Die drei Fernseh-Kameras (RBV) im Landsat 1 fielen frühzeitig aus. Die Qualität der Scanneraufnahmen ist jedoch so gut, daß diese als vollwertiger Ersatz für die RBV-Aufnahmen betrachtet werden können, insbesondere da die Spektralkanäle 1, 2, 3 der RBVs etwa identisch mit den Spektralkanälen 4, 5, 6 des MSS sind:

- Kanal 4: 0.5 - 0.6 µm (grün)
- Kanal 5: 0.6 - 0.7 µm (rot)
- Kanal 6: 0.7 - 0.8 µm (nicht sichtbarer Infrarotbereich)
- Kanal 7: 0.8 - 1.1 µm (nicht sichtbarer Infrarotbereich)

Landsat 3 enthält anstelle der drei Multispektral-RBVs eine Breitband-RBV-Kamera mit größerem räumlichen Auflösungsvermögen als der MSS und einen thermalen Infrarot-Kanal (10.2 - 12.6 µm), der jedoch nach wenigen Umläufen abgeschaltet werden mußte. Diese Spektralkanäle wurden insbesondere im Hinblick auf Landnutzungsprobleme nach umfangreichen Voruntersuchungen und Testflügen ausgewählt.

1.2.4 Aufnahme-Geometrie

Bei jeder Spiegelschwenkung nimmt der Detektor ca. 3300 Bildpunkte entlang einer 185 km langen Linie auf. Die Aufnahmezeit beträgt 9.95 sec; hieraus ergibt sich bei einem Blickfeld (IFOV: instantaneous field of view) des Sensors von 79 m x 79 m auf der Erdoberfläche eine Auflösung von 56 m in Scanrichtung. Das 79 m x 56 m große Bildelement wird Pixel (Abkürzung aus "picture element") genannt. Bei der Reproduktion des Bildes ist dieses Seitenverhältnis von 1 : 1,4 zu beachten.

Geometrische Verzerrungen treten vor allem auf durch

- Änderungen der Umlaufbahn des Satelliten
- Rotation der Erde während der Aufnahme
- Schwankungen der Winkelgeschwindigkeit des Scan-Spiegels.

Teilweise werden diese Fehler bei der digitalen Aufbereitung der Daten eliminiert. Im Mittel beträgt die Lagegenauigkeit der Landsat-Aufnahmen 177 m; das ist genauer als jede topographische Karte im Untersuchungsgebiet. Weitergehende Korrekturen können vom Bearbeiter vorgenommen werden (COLVOCORESSES 1972; COLVOCORESSES & McEWEN 1973; KRATKY 1974; BAHR & SCHUR 1974; BAHR 1976; KONECNY 1976).

1.2.5 Datenaufzeichnung

Die Empfang-Stationen des Landsat-Systems zeichnen die Signale des Satelliten auf HDDTs (High Density Digital Tape) auf und wandeln diese bei Bedarf in computer-compatible Magnetbänder (CCT: Computer Compatible Tape), die bei verschiedenen Institutionen gekauft werden können (vgl. Anhang 1). Dabei kann man im wesentlichen zwischen zwei Formaten auswählen:

- bild-sequentiell
- (spektral-) band-sequentiell.

Im ersten Fall werden die Aufnahmen in den verschiedenen Spektralkanälen nacheinander gespeichert. Bei diesem Format kann die Aufnahme unmittelbar als Bild auf Film abgespielt werden (Film-Schreiber).

Im zweiten Fall werden die Helligkeitswerte der Bildelemente einer Scan-Zeile in allen Spektralkanälen in verschachtelter Form abgelegt (band-interleaving, line-interleaving). Dieses Format hat den Vorteil, daß alle Merkmalwerte eines Pixels physikalisch eng auf dem Datenträger (meist CCT) gespeichert sind und bei einer Klassifizierung das gesamte Bild sequentiell abgearbeitet werden kann.

Man kann sich die Multispektralaufnahme in Form einer 3-dimensionalen Bildmatrix $G = (g_{i,j,k})$ vorstellen, wobei $g_{i,j,k}$ den Helligkeitswert in der Bildzeile i , Spalte j und Spektralkanal k bezeichnet (Abb. 2).

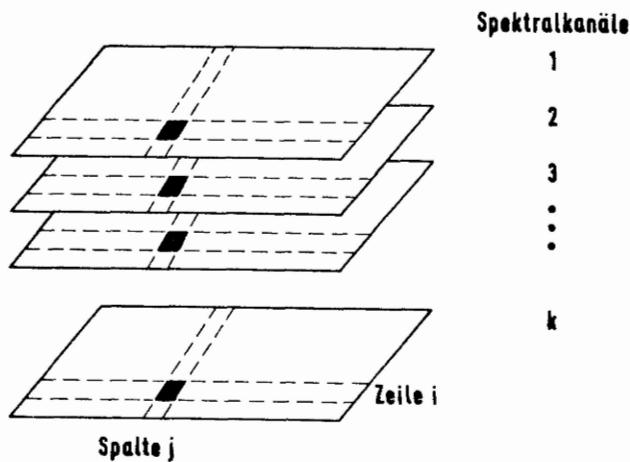


Abb. 2: Datenorganisation eines Multispektralbildes in Form einer 3-dimensionalen Matrix.

Die Grauwerteverteilung ist für die Spektralkanäle 4, 5, 6 auf das Intervall 0...127 (7 Bits) beschränkt, bei Kanal 7 auf das Intervall 0...63 (6 Bits). Dieser Grauwerteumfang wird in den meisten Landsat-Szenen nicht voll ausgeschöpft (vgl. z. B. Abb. 3), so daß eine Streckung des Grauwertebereichs vor einer Bildinterpretation angebracht ist.

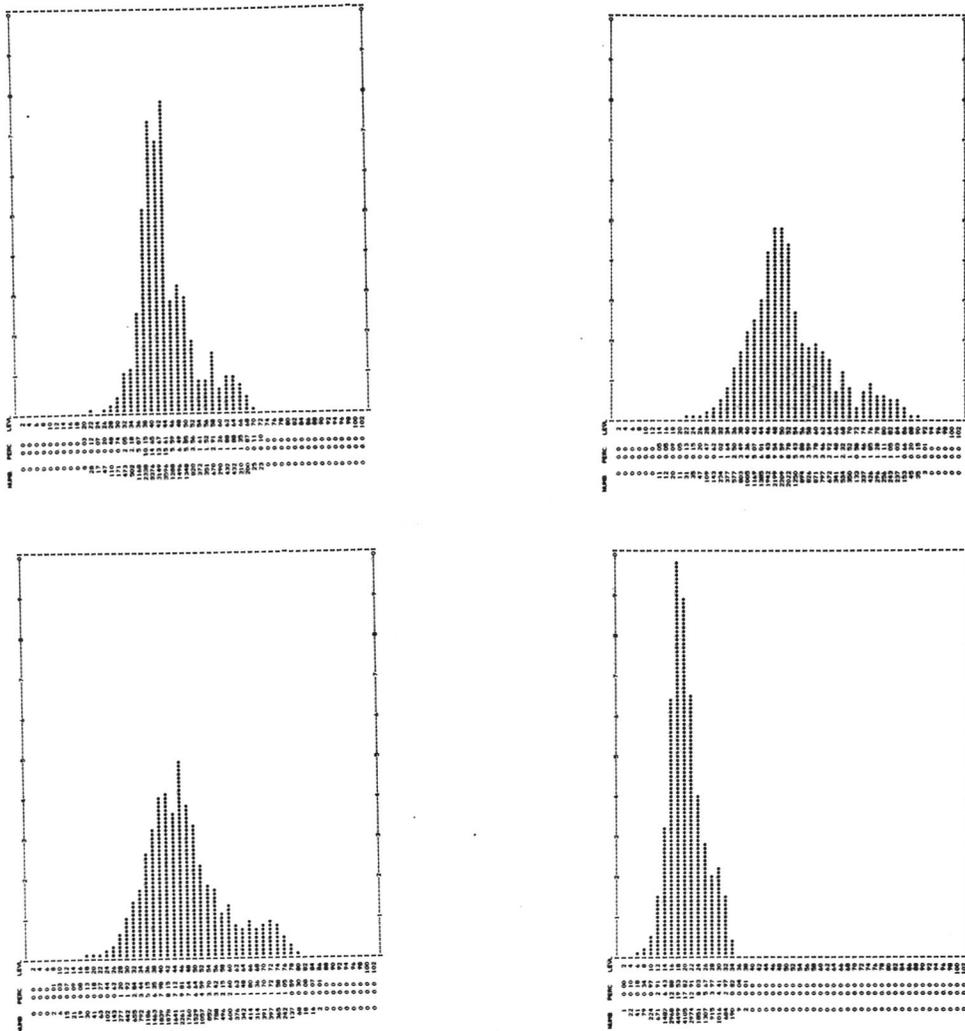


Abb. 3: Typische Grautonverteilung der 4 Spektralkanäle einer Landsat-Szene aus dem Tibesti-Gebirge (Ausschnitt aus der Landsat-Szene Nr. E12o9-o8491).

1.2.6 Atmosphärische Einflüsse

Die Grautonwerte eines Bildpunkts in den verschiedenen Spektralkanälen hängen nicht nur vom Reflexionsvermögen der abgebildeten Oberfläche ab (wobei für Gesteine und Böden ein LAMBERTSches Strahlungsverhalten angenommen wird), sondern auch von atmosphärischen Gegebenheiten wie

- Streuung des Sonnenlichts durch Gasmoleküle und Partikel
- Absorption durch Staub und Wasserdampf oder andere Gase (CO_2 etc., vgl. Abb. 4).

Auch die Höhenlage eines Punktes spielt eine Rolle, da die atmosphärischen Einflüsse mit der Höhe sehr rasch abnehmen, und dadurch die Helligkeitswerte in den verschiedenen Spektralkanälen unterschiedlich beeinflusst werden (THOMSON & SADOWSKI 1975).

Bei geologischen Anwendungen ist ferner zu beachten, daß viele Gesteinsoberflächen aufgrund ihrer kristallinen Struktur optisch anisotrop sind, so daß je nach der räumlichen Lage der Gesteinseinheiten unterschiedliche Helligkeitswerte vom Aufnahmesystem erfaßt werden. Diese Einflüsse sind bisher nur unter

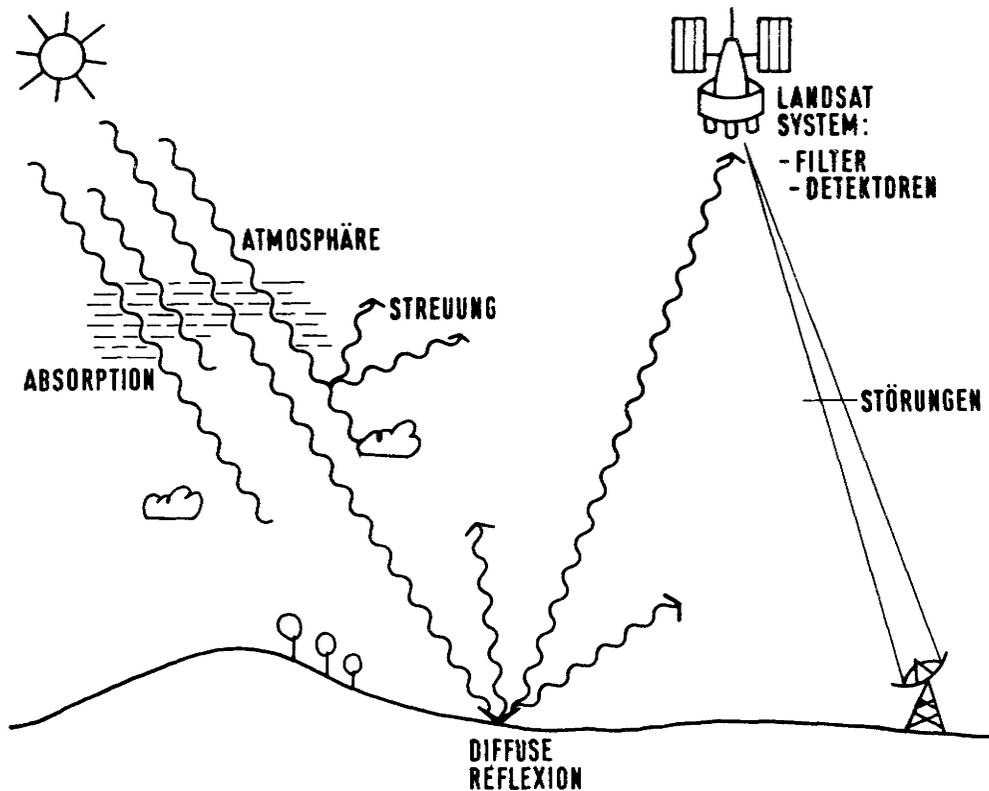


Abb. 4: Beeinflussung der Sonnenstrahlung auf dem Weg durch die Atmosphäre zum Empfänger (umgezeichnet nach: REEVES (Ed.) 1975, S. 90 und 98).

Laborbedingungen untersucht worden, da sie von anderen Effekten leicht überdeckt werden.

Die Quantifizierung der Wirkung atmosphärischer Einflüsse auf die Reflexionswerte ist notwendig, um von der Unterscheidung verschiedener Gesteinsoberflächen zu einer Identifizierung der Gesteine aufgrund ihrer spektralen Reflexion zu gelangen. Scanner-Systeme liefern hierzu gute Voraussetzungen, da bei jeder Spiegelschwenkung eine Referenzfläche abgetastet werden kann, so daß eine Normierung der am Scanner auftreffenden Strahlung möglich ist. Liegen Messungen der einfallenden Strahlung (Globalstrahlung) und der reflektierten Strahlung für eine Referenzfläche auf der Erdoberfläche vor, so können die atmosphärischen Einflüsse während des Satelliten-Oberflugs durch Vergleich dieser Messungen mit der am Scanner auftreffenden Strahlung berechnet werden.

Sind andererseits die atmosphärischen Bedingungen während einer Aufnahme bekannt, so können absolute Reflexionswerte für jeden Bildpunkt berechnet werden - eine notwendige (aber nicht hinreichende) Bedingung zur Identifizierung von Bildelementen.

1.3 Computer-unterstützte Bildverarbeitung an den Geologischen Instituten der Freien Universität Berlin

Hauptziel der digitalen Bildverarbeitung ist die voll-automatische Klassifizierung von Luft- und Satellitenbildern. Hierzu wird das Bild in digitaler Form in den Computer eingelesen und nach Ablauf eines Klassifizierungsprogramms als thematische Karte geplottet. Dieses Ziel einer automatischen Identifizierung von bildlich erfaßten Objekten ist in manchen Bereichen schon erreicht (Lesen von Texten auf Formularen, Sor-

tierung einfacher Formen etc.), im Bereich der Geologie ist man noch weit davon entfernt. Es ist deshalb zweckmäßig, auf eine voll-automatische Interpretation des Bildmaterials zu verzichten und interaktiv mit einer Bildverarbeitungsanlage zu arbeiten. Dabei können Fehlinterpretationen sofort erkannt und durch Änderung der Klassifikationsparameter berichtigt werden. Interaktive Bildverarbeitung ist nur an einem Prozeßrechner möglich, der für diesen Zweck entwickelt wurde.

Ein digitales Bildverarbeitungssystem besteht im wesentlichen aus verschiedenen Bildeingabemoduln (Fernsehkamera, Filmleser, Magnetbandeinheit), einem Prozeßrechner und Bildausgabeeinheiten (Farbmonitor, Printer-Plotter, Filmschreiber - vgl. Abb. 5).

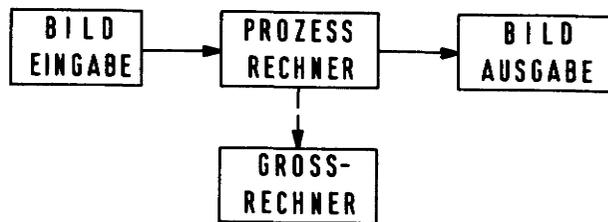


Abb. 5: Hauptkomponenten eines digitalen Bildverarbeitungssystems

Digitale Bildverarbeitung kann prinzipiell an jedem Computer betrieben werden, wenn man die Bilder über Magnetband einlesen kann und mit einer simulierten Grautonausgabe der Bilder auf dem Schnelldrucker zufrieden ist (Abb. 6). Zur Entwicklung spezieller, rechenintensiver Bildverarbeitungsalgorithmen ist ein Großrechner wegen seiner Schnelligkeit von Vorteil, so daß eine Kopplung des Prozeßrechners mit einem Großrechner wünschenswert ist.

1.3.1 Das hybride Bildverarbeitungssystem ISI-EARTHVIEW IV / SYSTEM 130

Die Hardwarekonfiguration der Bildverarbeitungsanlage ist aus Abb. 7 zu entnehmen. Der Analogteil der Anlage (SYSTEM 130) besteht aus einer Fernsehkamera zur Bildeingabe, dem Analogrechner und dem Farbmonitor zur Bildausgabe. Ein X-Y-Monitor erlaubt die Darstellung der Helligkeitswerte auf Profilen über das Bild (Mikrodensitometrie) und die Darstellung der Grautonwerte als Pseudorelief. Durch Rotation des Bildes ist es möglich, Strukturen hervorzuheben (z. B. Photolineationen), die auf dem Farbmonitor wegen der Informationsfülle nur schwer erkennbar sind.

Das Analogbild kann in Realzeit digitalisiert und im Digitalteil der Anlage weiterverarbeitet werden. Weitere Bildeingabemöglichkeiten sind durch Disketten und Magnetbänder gegeben. Die Bildausgabe erfolgt auf dem hochauflösenden Farbmonitor (512 x 512 Bildpunkte) und auf einem S/W-Kontrollmonitor. Eine digitale Kopie des Bildes auf Magnetband kann zur Ausgabe auf Film verwendet werden (HELL-Chromograph o. ä.).

Ein interaktives Terminal dient zur Eingabe von Kommandos an den Rechner, wobei ein großer Teil der Bildoperationen über Funktionstasten und eine Rollkugel ("track ball") aufgerufen werden kann.

Grundlage der Bildverarbeitung ist ein auf PROMs gespeichertes Softwarepaket, das die elementaren Bildoperationen steuert:

- lineare Transformation der Grauwertverteilung
- Codierung der Grautonwerte mit Farben (getrennt nach Farbton und -sättigung)
- Steuerung des Cursors und des Fensters auf dem Bildschirm
- Bildvergrößerungen und Festlegung des Bildausschnitts
- Abgrenzung und Speicherung von Trainingsgebieten mit unregelmäßigem Umriß

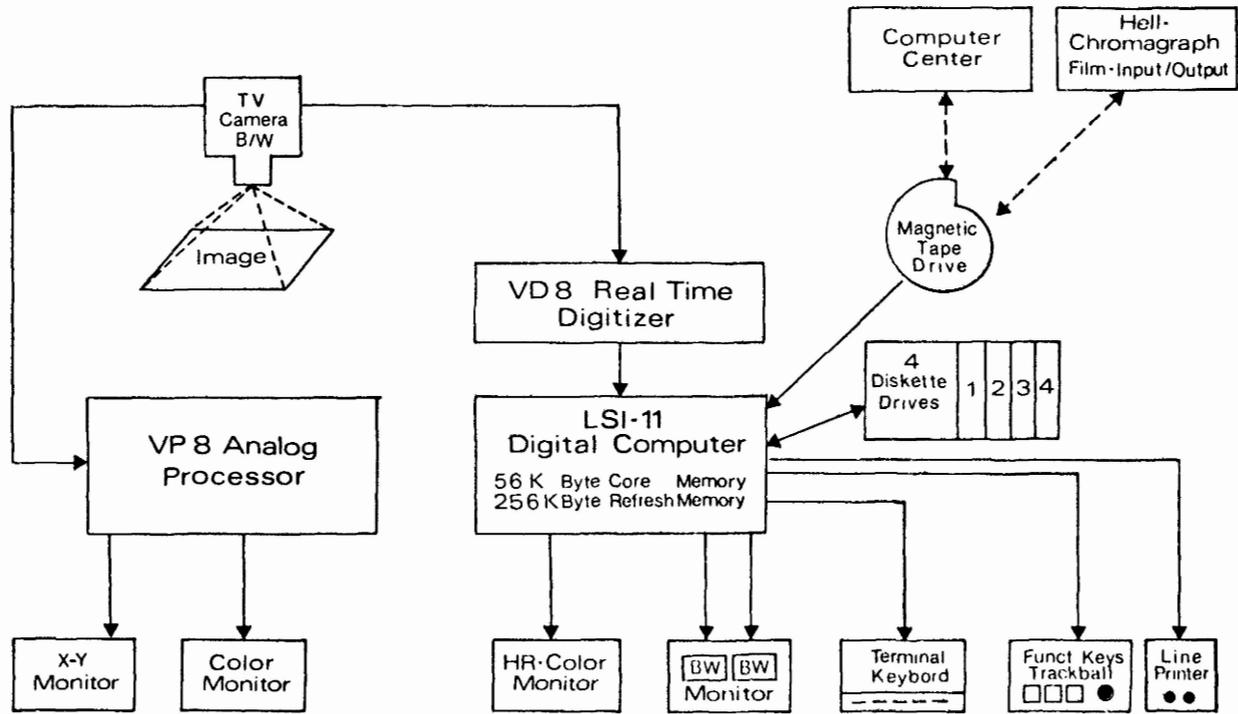


Abb. 7: Hardwarekonfiguration der Analog-Digital-Anlage ISI-System 130 / EARTHVIEW II.

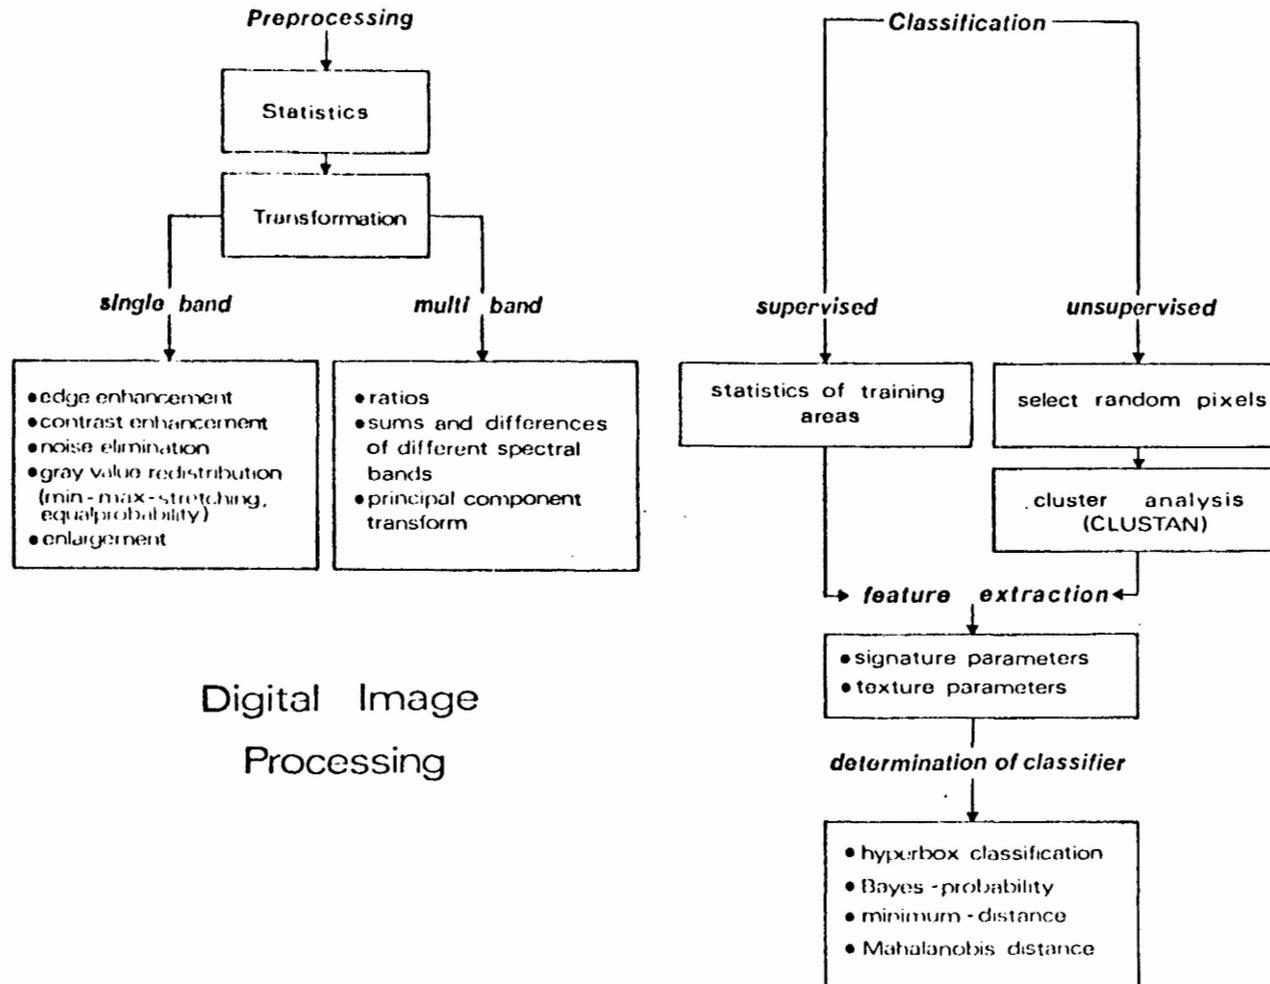


Abb. 8: Übersicht über vorhandene Programme zur digitalen Bildverarbeitung.

- Statistik der Grautonverteilung beliebiger Teilgebiete des Bildes.

Die Speicherorganisation ist so durchgeführt, daß 8 oder 16 Bits zur Kodierung des Grautonwerts eines Pixels verwendet werden, wobei verschiedene Bit-Ebenen der Helligkeit, dem Farbton und der Farbsättigung zugeordnet werden. Diese Aufspaltung hat den Vorteil, daß Änderungen der Monitordarstellung des Farbtons die anderen Bit-Ebenen nicht berühren. So kann eine echte Überlagerung verschiedener Bilder (Spektralkanäle) erfolgen und Änderungen der Darstellung eines Bildes wirken nicht auf das andere.

Mischt man dagegen 3 Bilder, die rot, grün und blau kodiert sind, so ergeben Veränderungen z. B. des Rotanteils Farbänderungen im Gesamtbild, die nur schwer interpretiert werden können.

1.3.2 Programme zur Bildverarbeitung

Eine Übersicht über die bisher vorhandenen Programme liefert Abb. 8. Dabei kann das gesamte Preprocessing interaktiv durchgeführt werden. Besonders bequem ist die Look-up-Tafel Technik, die es erlaubt, beliebige Bildtransformationen in Realzeit durchzuführen. Komplizierte Transformationen können durch stückweise lineare Transformationen approximiert werden. Schon einfache lineare Transformationen bringen eine erhebliche Bildverbesserung, wenn die Transferfunktion passend gewählt wird. Abb. 9 zeigt eine lineare Transformation, die einen engen Grautonbereich über die gesamte zur Verfügung stehende Helligkeitsskala streckt (globale Kontrastverstärkung).

Entsprechende Look-up-Tafeln können für den Farbton und die Sättigung erstellt werden, wobei die Transformationen global oder lokal an die spezielle Problematik angepaßt werden. Die Tafeln können numerisch erfaßt und abgespeichert werden, so daß eine optimale Bilddarstellung jederzeit reproduziert werden kann.

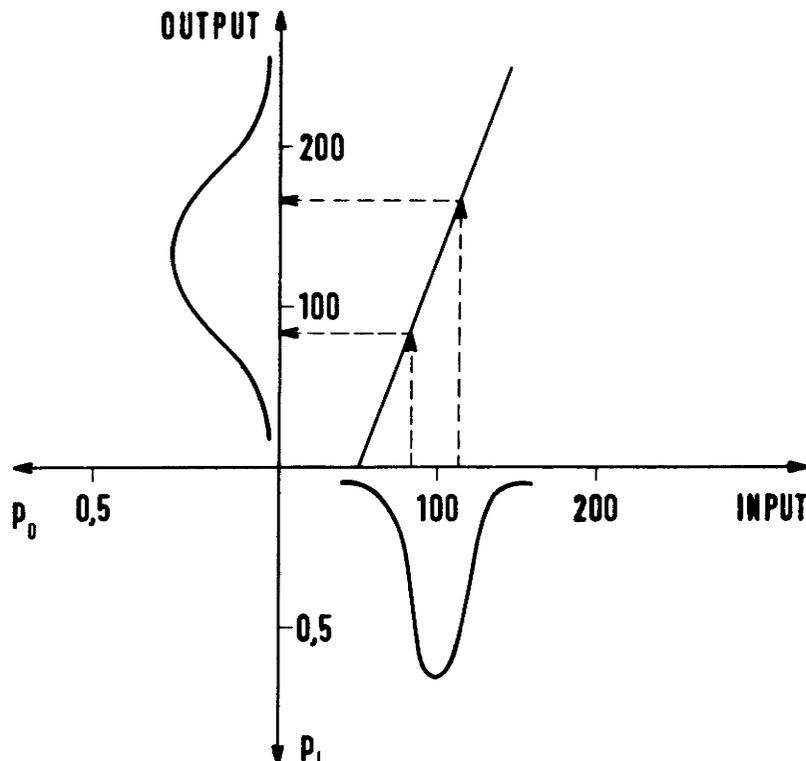


Abb. 9: Lineare Transformation zur Streckung des Grautonbereichs über die gesamte Helligkeitsskala des Bildmonitors. Die zugehörige Look-up-table enthält für jeden Eingabe-Grautonwert den transformierten Ausgabewert, so daß keine Rechnung während der Transformation notwendig ist.

Hervorhebung von Grautonwerten innerhalb frei wählbarer Intervallgrenzen (Contouring) und die Abgrenzung von Trainingsgebieten auf dem Bildschirm erlauben eine interaktive Klassifizierung von Multispektralbildern nach der Quadermethode (hyper-box-method). Linearkombinationen von Bildern können mit beliebigen Transformationsmatrizen ausgeführt werden (die z. B. auf einem anderen Rechner erstellt wurden). Programme zur Erstellung von Quotienten-, Produkt- und Differenzbildern ergänzen die Interpretationsmöglichkeiten für Multispektral- und Multitemporalaufnahmen.

Das Softwarepaket der Bildverarbeitungsanlage wird ständig erweitert, wobei der Schwerpunkt auf geologischen Fragestellungen liegt: Verstärkung von linearen Elementen (z. B. durch Richtungsfiler), Einführung anderer Klassifizierungsverfahren (z. B. nearest-neighborhood oder maximum-likelihood-method), Texturanalyse von Gesteinsoberflächen.

Die in dieser Arbeit verwendeten Programme zur Texturanalyse und Klassifizierung wurden am TR 440 des Großrechenzentrums für die Wissenschaft Berlin entwickelt, manche Ergebnisse (z. B. Transformationsmatrizen) als Eingabeparameter für das EARTHVIEW IV System weiterverwendet.

1.4 Aufgabenstellung dieser Arbeit

Im Laufe der letzten Jahre sind viele Arbeiten veröffentlicht worden, die sich mit geologischer Interpretation von Satellitenbildern beschäftigen (z. B. GÜNTHER 1972; ANDERSON et al. 1973; LEE 1974; HELMCKE et al. 1976; BROCKMANN et al. 1977; KLITZSCH & LIST 1978; LIST et al. 1978). Dabei geht es vor allem um lokale Probleme und speziell entwickelte Untersuchungsmethoden, die sich nicht auf andere Gebiete übertragen lassen. Kenntnis des Zusammenhangs zwischen geologischem Untergrund, Böden und Vegetation ermöglichen dem erfahrenen Interpreten die Kartierung ähnlich gebauter Gebiete aus dem Satellitenbild. Eine Übertragung auf andere Gebiete ist i. A. nicht möglich, weil der Einfluß von Klima, Höhenlage, Vegetation etc. quantitativ nicht so erfaßt werden kann, daß eindeutige Rückschlüsse auf den geologischen Untergrund möglich sind.

Im ariden Klima treten die Gesteine ohne störende Vegetation an die Oberfläche und bieten so ein natürliches Experimentierfeld zur Untersuchung von Gesteinsoberflächen in Satellitenbildern. Auch hier können Gesteine anhand ihrer spektralen Reflexionswerte nur unterschieden, nicht aber eindeutig identifiziert werden. Eine unmittelbare Vergleichbarkeit der Daten mit solchen aus anderen Gebieten ist auch hier nicht möglich, jedoch ergeben sich einige strukturelle Aspekte, die im Reflexionsverhalten natürlicher Gesteinsoberflächen begründet und damit von allgemeiner Bedeutung für die geologische Bildinterpretation sind.

Der Sahara-Raum wurde ausgewählt, weil

- unterschiedliche Gesteinsarten auf engem Raum aneinandergrenzen
- weiträumig dieselben klimatischen Randbedingungen herrschen
- ausgezeichnete Aufschlußverhältnisse vorliegen
- durch die Arbeit von Wissenschaftlern der Freien Universität Berlin an der Außenstation BARDAI (Tschad) und durch umfangreiche Feldarbeiten in verschiedenen Sahara-Regionen (u. a. in Ägypten, Sudan, Libyen) die notwendige Kontrolle der Fernerkundungs- und Klassifizierungsergebnisse durch Geländeuntersuchungen und großmaßstäbliche Kartierung der Geologie und zum Teil auch der Geomorphologie gegeben ist (u. a. HAGEDORN 1971; KAISER 1972; STOCK 1972; ROLAND 1973; ERGENZINGER 1978; LIST (Ed.) 1978).

Ziel der Arbeit ist

- a) die spektrale Variationsbreite verschiedener Gesteinseinheiten zu untersuchen und auf die Verwendbarkeit bei der automatischen Klassifizierung zu überprüfen
- b) textuelle Eigenschaften von Gesteinskomplexen quantitativ zu erfassen und zu prüfen, inwieweit Texturparameter zur Unterscheidung von Gesteinsoberflächen auf Satellitenbildern geeignet sind
- c) einen Algorithmus zu entwickeln, der zur Differenzierung und automatischen geologischen Kartierung die spektralen und textuellen Eigenschaften der Gesteinsoberflächen heranzieht.

Hierzu muß die besondere Struktur der Fernerkundungsdaten von Gesteinsoberflächen herausgearbeitet werden, um Klassifizierungsalgorithmen zu entwickeln, die dieser Struktur angepaßt sind.

Die Untersuchungen beschränken sich auf Landsat-Daten, da nur vom Landsat-System genügend Bildmaterial aus dem Untersuchungsgebiet vorliegt, und auch in Zukunft mit der Entsendung von Satelliten dieser Reihe gerechnet werden kann. (Der Start von Landsat D ist 1981 geplant und wird Verbesserungen des Auflösungsvermögens und der Spektralkanäle bringen.)

2. GRUNDLAGEN DER MUSTERERKENNUNG

2.1 Objektraum und Bildraum

Die geologische Interpretation von Fernerkundungsdaten für eine Interpretationskarte kann in folgende Arbeitsschritte eingeteilt werden:

- Zusammenstellung des vorhandenen Datenmaterials (Luft- und Satellitenbilder, Feldbeobachtungen und -messungen,
- Charakterisierung verschiedener geologischer Einheiten mit Hilfe von Merkmalen, die den Daten entnommen werden,
- Abgrenzung (Kartierung) der verschiedenen geologischen Einheiten entsprechend den gewonnenen Merkmalen.

Die lernpsychologischen und wahrnehmungsphysiologischen Prozesse bei dieser Arbeit sind wenig erforscht und sehr komplex (ALBERTZ 1970). Wieviel Hintergrundwissen ein erfahrener Luftbildinterpret bei der Datenauswertung einbringt, ist ihm selbst meist nicht bewußt. Eine Formalisierung dieses Prozesses ist jedoch für eine automatische Interpretation von Fernerkundungsdaten notwendig (und liefert in ihrer Unvollständigkeit gleichzeitig einen Beitrag zu den oben erwähnten Fragen).

Die Formalisierung der Mustererkennung geschieht in folgenden Schritten:

- Entscheidung, welche Objekte oder Musterklassen erkannt und dargestellt werden sollen,
- Erstellung eines Merkmalsraumes,
- Merkmalsextraktion und Beschreibung der Klassen im Merkmalsraum,
- Bestimmung von Entscheidungsfunktionen, die eine Trennung der Klassen auf Grund der Merkmalswerte erlauben,
- Anwendung der Entscheidungsfunktionen auf die Merkmalswerte aller Bildpunkte (Klassifizierung),
- Untersuchung der Fehlklassifizierungen.

Ausgangspunkt der Untersuchungen ist ein System Ω mit verschiedenen Objekten ω (z. B. Teilflächen der Erdoberfläche), die durch ihre physikalischen, chemischen und morphologischen Merkmale gekennzeichnet sind. Es ist zweckmäßig, sich diesen Merkmalsraum unendlichdimensional vorzustellen (betrachtet man das Reflexionsspektrum als Kontinuum, so erhält man allein hierdurch unendlich viele Merkmalswerte für ein Element aus Ω).

Das Aufnahmesystem liefert von den Objekten ein Bild, wobei jedem Element ω ein endlichdimensionaler Merkmalsvektor zugewiesen wird:

$$(2.1.1) \quad T_a: \Omega \longrightarrow M,$$

wobei T_a die Transferfunktion des Aufnahmesystems darstellt. Der Merkmalsraum M ist meist der m -dimensionale reelle Zahlenraum R^m , wobei durch die Diskretisierung der Merkmalswerte auf natürliche Zahlen (Helligkeitswerte) zwischen $0 \dots 127$ nur endlich viele verschiedene Merkmalsvektoren $\underline{x}' = (x_1, \dots, x_m)$ vorkommen können. Ein Vergleich der Dimensionen von Ω und M zeigt, daß die Funktion T_a nicht eindeutig umkehrbar ist. Diese Tatsache ist für die Bildinterpretation von entscheidender Bedeutung.

Führt man im Objektraum Ω eine Klasseneinteilung ein (z. B. durch Zusammenfassung von Gesteinseinheiten mit ähnlicher petrographischer Zusammensetzung), so wird hierdurch im Bildraum M i. A. keine Klasseneinteilung definiert. Es gilt jedoch die Umkehrung: im Bildraum M möge eine Klasseneinteilung mit Klassen K_i ($i = 1, \dots, k$) vorliegen. Definiert man die Mengen O_i im Objektraum durch

$$(2.1.2) \quad O_i = \left\{ \omega \mid T_a(\omega) \in K_i \right\}, \quad i = 1, \dots, k,$$

so erhält man eine Klasseneinteilung im Objektraum. In den Anwendungen versucht man diesen Klassen bestimmte geologische Einheiten zuzuordnen. Da die Abbildung T_a nicht umkehrbar eindeutig ist, können sehr unterschiedliche Objekte in den durch (2.1.2) definierten Klassen zusammengefaßt sein.

Selbst wenn man die feinste Klasseneinteilung im Merkmalsraum M wählt, d. h. nur solche Merkmalsvektoren in einer Klasse zusammenfaßt, die in allen Merkmalswerten (Komponenten) übereinstimmen, können sehr unterschiedliche Objekte auf denselben Vektor abgebildet werden. Ebenso häufig ist der Fall, daß durch eine Klassifizierung im Bildraum M nur ein Teil einer Objektklasse erfaßt wird, der andere Teil durch eine oder mehrere andere Klassen (man denke nur an die Schatteneffekte bei einem gefalteten Gesteinskomplex).

Diese Tatsachen werden von Anwendern der automatischen Klassifizierung häufig außer Betracht gelassen, so daß Fehlinterpretationen entstehen und die computer-unterstützte Bildinterpretation völlig abgelehnt wird. Wir müssen davon ausgehen, daß die Klasseneinteilung im Objektraum, wie sie sich in der Geschichte der Geologie entwickelt hat, nicht kompatibel ist mit Klasseneinteilungen, wie sie sich bei der digitalen Auswertung von Multispektraldaten anbieten.

Besonders die überwachte Klassifizierung und interaktive Arbeit am Bildschirm (Definition von Trainingsgebieten, Zusammenfassen oder Neudefinition von Klassen etc.) kann neue thematische Bilder liefern, die neben anderen Daten eine zusätzliche Information zur geologischen Interpretation des Untersuchungsgebietes darstellen.

2.2 Merkmalsextraktion im Bildraum

2.2.1 Spektrale Homogenität

Im folgenden betrachten wir den Merkmalsraum als m -dimensionalen reellen Vektorraum $M = \mathbb{R}^m$. Das Aufnahmesystem liefert für jeden Punkt des Aufnahmegebietes einen Merkmalsvektor $\underline{x}' = (x_1, \dots, x_m)$, dessen Komponenten die Reflexionswerte in den m Spektralkanälen darstellen.

Bei der Formalisierung des Klassifizierungsprozesses geht man davon aus, daß eine Objektklasse ω_i ($i = 1, \dots, k$) durch einen Prototyp p_i beschrieben werden kann und die Merkmalswerte der Elemente der Klasse innerhalb gewisser Schranken um diesen Prototyp variieren.

Eine Objektklasse heißt spektral homogen, wenn für jedes Element q von ω_i die spektrale Distanz d_s zu p_i

$$(2.2.1.1) \quad d_s = \|q^{(s)} - p_i^{(s)}\|$$

kleiner als eine vorgegebene Schranke c_s ist und als Vektorkomponenten nur die Reflexionswerte in den m Spektralkanälen des Aufnahmesystems betrachtet werden. ($\|\cdot\|$ bezeichnet eine passend gewählte Vektornorm.) In diesem Fall wird der Prototyp der Objektklasse ω_i auf einen Merkmalsvektor \underline{m}_i abgebildet

$$(2.2.1.2) \quad T_a : p_i \rightarrow \underline{m}_i,$$

und die Klasse ω_i auf eine (spektrale) Umgebung S_i von \underline{m}_i , wenn die Aufnahme-funktion T_a nur stetig ist. In diesem Fall ist $\underline{x} = T_a(q)$ ein Element von S_i und es gilt

$$(2.2.1.3) \quad \|\underline{x} - \underline{m}_i\| < c_a,$$

mit einer von T_a abhängigen Schranke c_a . Der Merkmalsvektor \underline{x} kann häufig durch seine Abweichung vom zuge-

hörigen Prototyp \underline{m}_i dargestellt werden,

$$(2.2.1.4) \quad \underline{x} = \underline{m}_i + \underline{s} .$$

In diesem Modell wird meist angenommen, daß \underline{s} einen Vektor darstellt, der einer multivariaten Normalverteilung mit Mittelwertsvektor $\underline{0}$ und Varianz-Kovarianz-Matrix C_i entstammt (Abb. 10).

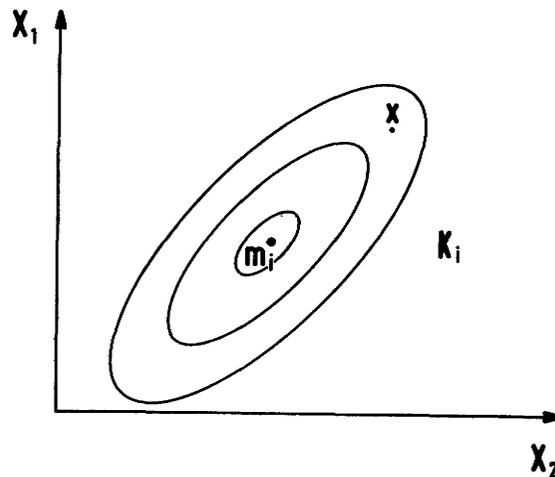


Abb. 10: Verteilung der Elemente einer Klasse K_i im zweidimensionalen Merkmalsraum. Die Ellipsen stellen Isolinien gleicher Elementhäufigkeit dar.

2.2.2 Operationen im Bildraum

Die vom Aufnahmesystem übertragenen Meßwerte enthalten neben der spektralen Information auch räumliche Information. Während die spektralen Remissionswerte als Punkteigenschaft direkt für eine Klassifizierung verwendet werden können, ist es notwendig, geeignete Verfahren zur quantitativen Erfassung der räumlichen Information zu gewinnen, die durch die geometrische Verteilung der Grautonwerte im Bild gegeben ist. (Es soll hier nicht die räumliche Lage der Gesteinsschichten erfaßt werden, die bei der Luftbildinterpretation eine entscheidende Rolle spielt, im Satellitenbild aber nur in Ausnahmefällen zu erkennen ist.) Um räumliche Merkmalswerte zu extrahieren, sind lokale oder globale Bildoperationen anzuwenden.

Eine lokale Bildoperation L liegt vor, wenn der Funktionswert in einem Punkt (i, j) vom Grautonwert $g_{i,j}$ und von den Grautonwerten einer gewissen (räumlichen) Umgebung $U_{i,j}$ des Punktes abhängt

$$(2.2.2.1) \quad L(g_{i,j}) = L(g_{i,j}, g) , \quad g \in U_{i,j} ,$$

wobei i die Bildzeile und j die Bildspalte bezeichnet. (Beispiele: gleitender Mittelwert, Gradient).

Eine globale Bildoperation G liegt vor, wenn der Funktionswert in einem Punkt (i, j) von den Funktionswerten aller Punkte des Bildes B abhängt

$$(2.2.2.2) \quad G(g_{i,j}) = G(g_{i,j}, g) \quad , \quad g \in B \quad (= \text{Gesamtbild})$$

(Beispiel: Fouriertransformation).

Bei der Merkmalsextraktion ergeben sich folgende Probleme:

- Wie groß muß die Umgebung $U_{i,j}$ gewählt werden, um die räumliche Beziehung der Grautonwerte einer Klasse zu erfassen?
- Welchen Beitrag liefern die verschiedenen Merkmale zur Charakterisierung der Klassen?
- Wie kann die Anzahl der Merkmale reduziert werden, ohne zuviel Information zu verlieren?

2.3 Klassenbildung im Merkmalsraum

Eine Klasseneinteilung auf einer Menge E liegt vor, wenn

- a) jedes Element der Menge einer Klasse angehört
- b) die Klassen keine gemeinsamen Elemente besitzen,

d. h.

$$K_i \cap K_j = \emptyset \quad \text{für alle } i \neq j.$$

Jede Äquivalenzrelation auf einer Menge definiert eine Klasseneinteilung und umgekehrt wird durch die Bedingungen a) und b) eine Äquivalenzrelation definiert.

Stellt man Bildpunkte im Merkmalsraum der Signaturen dar, so ergeben sich oft natürliche Punktgruppierungen, die man zur Klasseneinteilung verwenden kann. (Abb. 11)

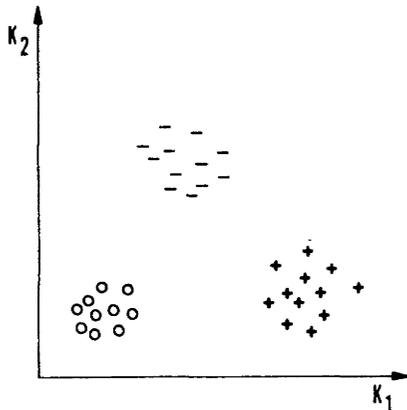


Abb. 11: Darstellung von Bildpunkten im zweidimensionalen Merkmalsraum: natürliche Gruppierung durch Punktwolken.

Entsprechend der Art der Klassenfestlegung unterscheidet man die

- überwachte Klassifizierung (SCL: supervised classification),
- nichtüberwachte Klassifizierung (USCL: unsupervised classification).

Bei der SCL werden Trainingsgebiete, die aus Feldbeobachtungen bekannt sind, im Bild festgelegt und damit Klassen definiert; bei der USCL werden die Klassen nach einem Clusterverfahren festgelegt. Hierzu wählt man nach einem Zufallsverfahren einige hundert Bildpunkte mit ihren Merkmalswerten aus und untersucht diesen Datensatz auf natürliche Gruppierungen. Einen Überblick über die Vielzahl der hierfür entwickelten Algorithmen findet man bei DURAN & ODELL (1974).

Beide Methoden widerspiegeln die in Kap. 2.1 angeführten Klassifizierungsprobleme. Die für Anwendungsprobleme bevorzugte Methode der SCL liefert im Bildraum im allgemeinen keine Klasseneinteilung, d. h. bei der Zuordnung der einzelnen Bildpunkte zu den Klassen sind Mehrdeutigkeiten möglich.

Die USCL liefert zwar eine Klasseneinteilung im Bildraum, die Zuordnung der einzelnen Klassen zu bestimmten Objektklassen (Gesteinsarten etc.) ist von der Datenstruktur und den verwendeten Clusteralgorithmen

bestimmt, so daß die Verbindung zu anwendungsorientierten Fragen im allgemeinen fehlt, oder anders ausgedrückt: die USCL liefert oft Antworten auf Fragen, die von Anwendern nicht gestellt sind.

Interaktionen zwischen beiden Methoden sind jedoch wünschenswert, um einerseits durch passende Wahl der Trainingsgebiete möglichst anwendungsorientiert zu sein und andererseits Fehlklassifizierungen zu vermeiden, die von einer vorhandenen natürlichen Gruppierung der Daten im Merkmalsraum zu stark abweicht (vgl. Kap. 2.4).

2.4 Entscheidungsfunktionen

Unter einer Entscheidungsfunktion d versteht man eine Abbildung des Merkmalsraums M in den R^1

$$(2.4.1) \quad d: M \longrightarrow R^1,$$

wobei gilt

$$(2.4.2) \quad \begin{array}{l} d(\underline{x}) > 0 \quad \text{oder} \\ d(\underline{x}) < 0, \quad \text{für alle } \underline{x} \in M. \end{array}$$

Durch die Funktion d wird der Merkmalsraum M in zwei Klassen eingeteilt, wenn man definiert

$$(2.4.3) \quad \begin{array}{l} \underline{x} \in K_1 \iff d(\underline{x}) > 0 \quad \text{und} \\ \underline{x} \in K_2 \iff d(\underline{x}) < 0. \end{array}$$

Meist sind die Klassen K_1 und K_2 durch mehrere Repräsentanten (Stichproben) vorgegeben und man sucht eine passende Entscheidungs- oder Trennfunktion (Abb. 12).

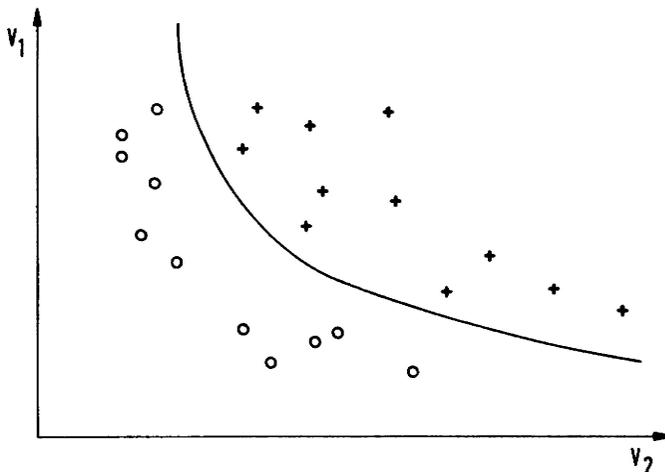


Abb. 12: Einfache Entscheidungsfunktion im zweidimensionalen Merkmalsraum bei zwei Klassen.

Das Konzept der Entscheidungsfunktionen kann direkt auf mehr als zwei Klassen verallgemeinert werden. Bei Betrachtung von Abb. 12 kann man sich jedoch leicht vorstellen, daß die Merkmalswerte von Gruppen so kompliziert verteilt sein können, daß einfache Trennfunktionen nicht zu erstellen sind.

Bei der SCL bietet es sich an, die Bildpunkte der Trainingsgebiete zur Bestimmung von Trennfunktionen heranzuziehen. Betrachtet man den Centroid-Vektor m_i jeder Klasse K_i ($i = 1, \dots, k$) als Repräsentanten der Klasse, so kann man folgende Entscheidungsregel definieren:

$$(2.4.4) \quad \underline{x} \in K_i \iff d(\underline{x}, m_i) = \text{minimum},$$

wobei $d(x,y)$ ein Distanzmaß im Merkmalsraum M ist. Die am häufigsten verwendeten Distanzmaße sind der eu-

Klidische Abstand

$$(2.4.5) \quad d(\underline{x}, \underline{y}) = \sqrt{(\underline{x}-\underline{y})'(\underline{x}-\underline{y})} ,$$

die Maximalnorm

$$(2.4.6) \quad d(\underline{x}, \underline{y}) = \max_j (|x_j - y_j|)$$

und die "block-city-Distanz"

$$(2.4.7) \quad d(\underline{x}, \underline{y}) = \sum_{j=1}^m |x_j - y_j| ,$$

wobei mit x_j, y_j die Komponenten der Merkmalsvektoren \underline{x} und \underline{y} bezeichnet sind. Die Distanzmaße (2.4.6) und (2.4.7) sind besonders computerfreundlich, da keine Wurzeln gezogen werden und nur Summen und Differenzen zur Berechnung benötigt werden.

Sind mehrere Merkmalsvektoren als Repräsentanten einer Klasse gegeben, so kann man das Konzept der Minimaldistanz (2.4.4) dahingehend verallgemeinern, daß man den Merkmalsvektor \underline{x} der Klasse K_i zuordnet, wenn ein Repräsentant dieser Klasse minimalen Abstand zu \underline{x} hat (nearest neighbor classification).

Sind die Merkmalswerte miteinander korreliert, so sind die Distanzmaße (2.4.5) bis (2.4.7) ungeeignet, weil der "Einzugsbereich" einer Gruppe anisotrop ist (Abb. 13).

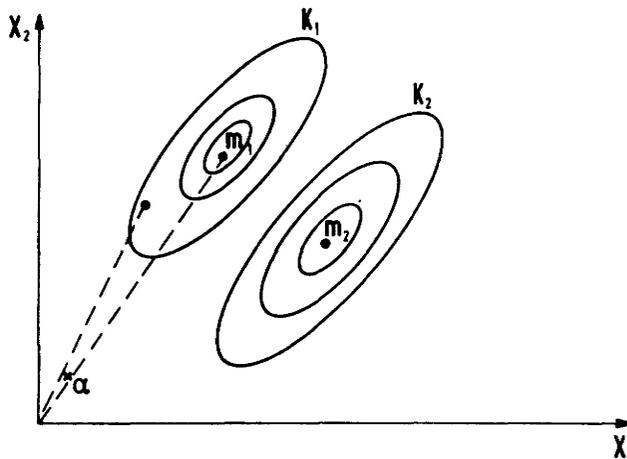


Abb. 13: Anisotropie der Distanzen im Merkmalsraum. Die Elemente der Klassen K_i folgen einer bivariaten Normalverteilung $N(\underline{m}_i, C_i)$, $i = 1, 2$.

Kann man an die Repräsentanten der Klassen das Modell einer multivariaten Normalverteilung $N(\underline{m}_i, C)$ anpassen, so ist die MAHALANOBIS-Distanz

$$(2.4.8) \quad d(\underline{x}, \underline{m}_i) = (\underline{x} - \underline{m}_i)' C^{-1} (\underline{x} - \underline{m}_i)$$

ein Maß, das die Streuung der Gruppenelemente im Merkmalsraum berücksichtigt. Ist die Varianz-Kovarianzmatrix C_i nicht für alle Gruppen gleich, so berechnet man eine entsprechend der Anzahl der Gruppenelemente gewichtete Matrix C .

Für geologische Anwendungen ist wegen der hohen Korrelation der spektralen Signaturen (vgl. Kap. 3) die Winkeldistanz von Bedeutung:

$$(2.4.9) \quad d(\underline{x}, \underline{m}_i) = \cos \alpha = \frac{\underline{x}' \underline{m}_i}{\|\underline{x}\| \|\underline{m}_i\|}$$

(vgl. Abb. 13).

Die Distanzmaße (2.4.8) und (2.4.9) verdeutlichen den Zusammenhang mit der USCL: um mit Hilfe eines Clusteralgorithmus die natürliche Gruppierung der Daten zu finden, braucht man ein Maß, das die Ähnlichkeit

zweier Merkmalsvektoren mißt. Hierzu sind die Distanzmaße gut geeignet: zwei Merkmalsvektoren \underline{x} , \underline{y} sind umso ähnlicher, je kleiner ihre Distanz $d(\underline{x}, \underline{y})$ ist.

Man muß jedoch schon etwas über die Verteilung der Merkmalsvektoren einer Gruppe wissen, um ein passendes Ähnlichkeitsmaß für den Clusteralgorithmus zu verwenden.

So werden die Distanzmaße (2.4.8) und (2.4.9) in einem Clusterverfahren die Gruppenstruktur in Abb. 13 verdeutlichen, während bei einer Verteilung wie in Abb. 14 diese Maße zur Separation der beiden Gruppen ungeeignet sind.

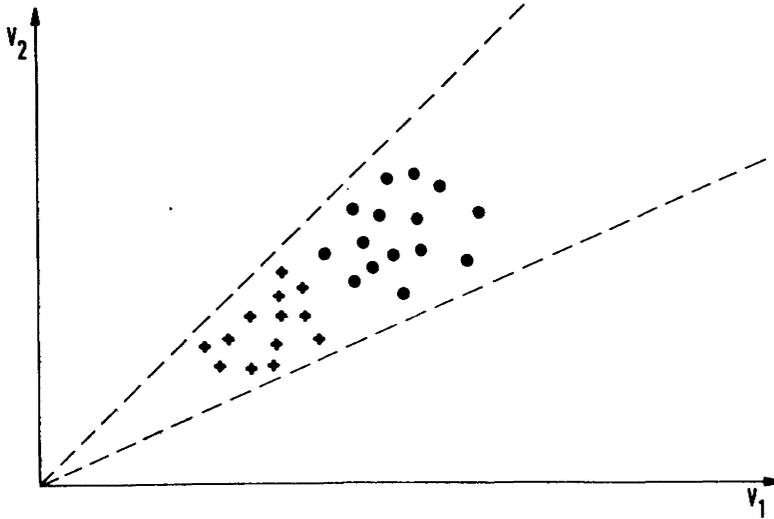


Abb. 14: Punkteverteilung im zweidimensionalen Merkmalsraum, die durch eine euklidische Distanz gut gruppiert werden kann, nicht jedoch durch eine Winkeldistanz.

Die Untersuchung der Merkmalsvektoren bekannter Trainingsgebiete kann Aufschluß über die (wahrscheinliche) Struktur der Punkteverteilung unbekannter Gruppen im Merkmalsraum geben.

Bei einer komplizierten Verteilung der Daten im Merkmalsraum sind oft viele Experimente mit verschiedenen Algorithmen notwendig, um sinnvolle Klasseneinteilungen zu erhalten. Damit kommt auch bei einer computerunterstützten Klassifizierung die Erfahrung und Intuition des Bearbeiters ins Spiel. Der Unterschied zur visuellen Interpretation liegt darin, daß die Ergebnisse der digitalen Bildverarbeitung reproduzierbar sind und durch die Quantifizierung der Merkmalswerte die Erforschung der physikalischen Grundlagen der spektralen Reflexion von Oberflächen möglich wird.

2.4.1 Lineare Diskriminanzfunktionen

Liegt ein m -dimensionaler Merkmalsraum vor, so hat eine lineare Trenn- oder Diskriminanzfunktion die Form

$$(2.4.1.1) \quad d(\underline{x}) = \sum_{j=1}^m w_j x_j + w_{m+1} .$$

Erweitert man den Merkmalsvektor \underline{x} formal mit einer Komponente 1 zu $\underline{x}' = (x_1, \dots, x_m, 1)$, so erhält man die einfachere Darstellung als Skalarprodukt

$$(2.4.1.2) \quad d(\underline{x}) = \underline{w}'\underline{x} ,$$

wobei \underline{w} als Gewichtsvektor bezeichnet wird. Im Falle zweier Klassen ergibt sich die Entscheidungsregel

$$(2.4.1.3) \quad d(\underline{x}) = \underline{w}'\underline{x} \begin{cases} \geq 0, & \text{wenn } \underline{x} \in K_1 \\ < 0, & \text{wenn } \underline{x} \in K_2 \end{cases} .$$

Geometrisch stellt die Gleichung

$$(2.4.1.4) \quad d(\underline{x}) = \underline{w}'\underline{x} = 0$$

eine Hyperebene dar, die den Raum M in zwei Halbräume aufteilt. Im zweidimensionalen Fall geht die Hyperebene in eine Gerade über, die zwei Halbebenen trennt (Abb. 15).

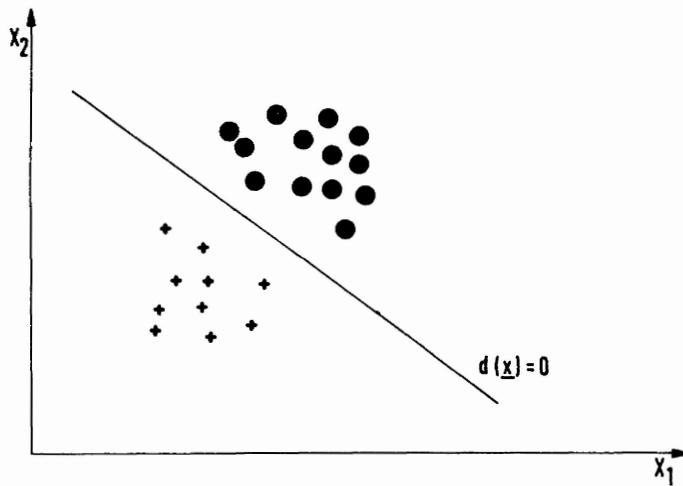


Abb. 15: Lineare Diskriminanzfunktion im zweidimensionalen Merkmalsraum.

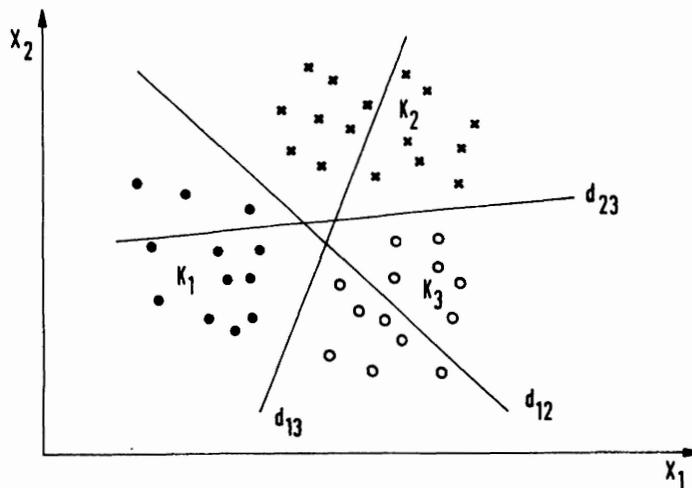


Abb. 16: Trennung von 3 Gruppen mit Hilfe von linearen Trennfunktionen, d. h. Geraden im zweidimensionalen Merkmalsraum.

2.4.2 Lineare Diskriminanzfunktionen bei k Klassen (k > 2)

Liegen k (k > 2) Gruppen vor, so kann man formal die in Kap. 2.4.1 beschriebene Methode verallgemeinern und versuchen, jede Gruppe von jeder anderen zu trennen. Dadurch erhält man k·(k-1)/2 Trennfunktionen d_{i,j} zur Trennung der Gruppen i und j (i, j = 1, ..., k), wobei d_{i,j} = -d_{j,i} und die Entscheidungsregel

(2.4.2.1)
$$\underline{x} \in K_i \iff d_{i,j}(\underline{x}) > 0 \text{ für alle } j = 1, \dots, k, j \neq i$$

gilt. Häufig kann man die Anzahl der Trennfunktionen verringern, indem man eine Gruppe mit einer Trennfunktion von allen anderen Gruppen trennt. Ist dies für alle Gruppen möglich, so benötigt man nur k Trennfunktionen, und der Rechenaufwand wird erheblich reduziert.

In der Praxis liegt die Zahl der Trennfunktionen meist zwischen den beiden Extrema k und k(k-1)/2.

Abb. 16 zeigt ein Beispiel für die Trennung von drei Gruppen mit Hilfe von linearen Trennfunktionen.

Eine Reduzierung der Rechenzeit bei der Klassifizierung wird auch erreicht, wenn man bei der Reihenfolge der Diskriminanzfunktionen darauf achtet, daß die Klasse K_i vor K_j abgefragt wird, wenn p(K_i) > p(K_j).

Liegt ein gemischtes Problem vor (d. h. ein Teil der Klassen ist durch je eine Diskriminanzfunktion von allen anderen separierbar, der andere Teil benötigt mehr Funktionen), so wird man erst die Zugehörigkeit eines Merkmalsvektors zum ersten Teil der Klassen abfragen, danach die übrigen. Die Reihenfolge wird wiederum durch die a priori-Wahrscheinlichkeiten p(K_i) festgelegt.

2.5 Klassifizierung

2.5.1 BAYES'sche Fehlerminimierung

Eine Diskriminanzfunktion d_i für eine Klasse K_i teilt den Merkmalsraum in zwei Halbräume H₊ und H₋ und es gilt

(2.5.1.1)
$$d(\underline{x}) \begin{cases} \geq 0 & \text{für } \underline{x} \in H_+ \\ < 0 & \text{für } \underline{x} \in H_- \end{cases}$$

Für einen beliebigen Merkmalsvektor \underline{x} wird die Hypothese

(2.5.1.2)
$$H_0 : \underline{x} \in K_i$$

angenommen, wenn $\underline{x} \in H_+$ und abgelehnt, wenn $\underline{x} \in H_-$. Die Anzahl der Fehlklassifizierungen, die dadurch entstehen, daß H₀ akzeptiert wird, obwohl \underline{x} ein Element von K_j ist, kann man aus der BAYES'schen Formel für bedingte Wahrscheinlichkeiten berechnen

(2.5.1.3)
$$p(K_j | \underline{x}) = \frac{p(\underline{x} | K_j) p(K_j)}{p(\underline{x})}$$
 ,

wenn die a priori-Wahrscheinlichkeiten p(K_j) und p($\underline{x} | K_j$) für alle Klassen K_j (j=1, ..., k) bekannt sind. Für die Wahrscheinlichkeit der Fehlklassifizierung ergibt sich

(2.5.1.4)
$$\begin{aligned} R_i &= \int_{H_+} \sum_{j \neq i} p(K_j | \underline{x}) p(\underline{x}) d\underline{x} \\ &= \int_{H_+} \sum_{j \neq i} p(\underline{x} | K_j) p(K_j) d\underline{x} . \end{aligned}$$

Dieser Fehler wird minimal, wenn die Entscheidungsfunktion so gewählt wird, daß für jedes \underline{x} der Ausdruck

(2.5.1.5)
$$\sum_{j \neq i} p(K_j | \underline{x}) = 1 - p(K_i | \underline{x})$$

minimal wird, d. h.

(2.5.1.6)
$$p(K_i | \underline{x}) > p(K_j | \underline{x}) \text{ für alle } j \neq i.$$

Setzt man hier die bedingten Wahrscheinlichkeiten aus (2.5.1.3) ein, so ergibt sich

$$(2.5.1.7) \quad \frac{p(\underline{x}|K_i)}{p(\underline{x}|K_j)} > \frac{p(K_j)}{p(K_i)} \quad \text{für alle } j \neq i.$$

Die linke Seite von (2.5.1.7) heißt Likelihood-Quotient; die rechte Seite ist ein Schwellenwert für die Entscheidung $\underline{x} \in K_i$ oder $\underline{x} \notin K_i$.

Definiert man eine Trennfunktion für K_i durch

$$(2.5.1.8) \quad d_i(\underline{x}) = p(K_i|\underline{x}),$$

so gilt nach (2.5.1.6) $d_i(\underline{x}) > d_j(\underline{x})$ für alle $j \neq i$, d. h.

$$(2.5.1.9) \quad d_{i,j}(\underline{x}) := d_i(\underline{x}) - d_j(\underline{x}) > 0 \quad \text{für alle } j \neq i,$$

und $d_{i,j}$ ist eine Trennfunktion, die die Zahl der Fehlklassifizierungen für K_i minimiert.

Liegen k Klassen vor, so wird der Merkmalsraum in k disjunkte Teilräume H_i ($i = 1, \dots, k$) zerlegt, und der wahrscheinliche Gesamtfehler ergibt sich nach (2.5.1.4)

$$(2.5.1.10) \quad R = \sum_{i=1}^k \int_{H_i} \sum_{j \neq i} p(K_j|\underline{x}) p(\underline{x}) dx.$$

Dieser Fehler wird minimiert, wenn die Teilräume H_i so gewählt werden, daß für $\underline{x} \in H_i$ gilt

$$\sum_{j \neq i} p(K_j|\underline{x}) < \sum_{j \neq 1} p(K_j|\underline{x}), \quad \text{für alle } 1 \neq i,$$

oder nach (2.5.1.3)

$$\sum_{j \neq i} p(K_j) p(\underline{x}|K_j) < \sum_{1 \neq j} p(K_j) p(\underline{x}|K_j) \quad \text{für alle } 1 \neq i.$$

Nach (2.5.1.5) folgt hieraus

$$(2.5.1.11) \quad p(K_i) p(\underline{x}|K_i) > p(K_j) p(\underline{x}|K_j) \quad \text{für alle } j \neq i.$$

Da die Relation ">" unter monoton steigenden Funktionen erhalten bleibt, kann man anstelle (2.5.1.11) auch die Entscheidungsregel $\underline{x} \in K_i$, wenn

$$(2.5.1.12) \quad \log p(K_i) + \log p(\underline{x}|K_i) > \log p(K_j) + \log p(\underline{x}|K_j)$$

für alle $j \neq i$ verwenden, d. h. die Entscheidungsfunktion

$$(2.5.1.13) \quad d_i(\underline{x}) = \log p(\underline{x}|K_i) + \log p(K_i).$$

Führt man eine Verlustfunktion c_{ij} ein für die Entscheidung $\underline{x} \in K_i$, wenn $\underline{x} \in K_j$, so erhält man eine allgemeinere Darstellung der BAYES'schen Klassifizierung (vgl. DUDA & HART 1973 oder FUKUNAGA 1972).

Hauptprobleme bei der BAYES'schen Klassifizierung sind nach (2.5.1.13)

- die Bestimmung der Wahrscheinlichkeitsdichten $p(\underline{x}|K_i)$
- die Schätzung der a priori Wahrscheinlichkeiten $p(K_i)$, $i = 1, \dots, k$.

In der vorliegenden Arbeit wurde - sofern nicht ausdrücklich anders vermerkt - die Parameterschätzung bei der Bestimmung von $p(\underline{x}|K_i)$ verwendet (Kap. 2.5.2). Eine einfache Abschätzung der a priori-Wahrscheinlichkeiten $p(K_i)$ ergibt sich bei der USCL: wählt man n Merkmalsvektoren zufällig aus dem Gesamtbild aus, und erhält man nach einem Clusterverfahren k Gruppen mit n_i Elementen in jeder Gruppe, so gilt

$$(2.5.1.14) \quad p(K_i) \approx \frac{n_i}{n}, \quad i = 1, \dots, k.$$

Bei der SCL kann man in analoger Weise vorgehen, indem man n Merkmalsvektoren auswählt, und diese Vektoren mit dem Ansatz $p(K_i) = 1/k$ klassifiziert. Weichen die so erhaltenen Klassenhäufigkeiten sehr stark von der Gleichverteilung $1/k$ ab, so können diese als Schätzwerte bei einer wiederholten Klassifizierung verwendet

werden. Die Zahl der Fehlklassifizierungen wird sich nur unwesentlich verändern, wenn die Häufigkeitsverteilungen $p(\underline{x}|K_i)$ vom Klassenmittelpunkt weg schnell fallen, so daß eine Verschiebung der Trennfunktion durch die Gewichte $p(K_i)$ in (2.5.1.11) keinen großen Einfluß mehr hat.

2.5.2 Klassifizierung normalverteilter Merkmalsvektoren

Die Bedeutung der multivariaten Normalverteilung bei Klassifizierungsproblemen hat zwei Gründe:

1. viele Häufigkeitsverteilungen zeigen eine unimodale Struktur, die vom Zentrum schnell nach dem Rand abfällt;
2. die Normalverteilung ist analytisch gut zu handhaben, insbesondere sind unter der Annahme dieses Modells einfache Trennfunktionen zu berechnen.

Die multivariate Normalverteilung hat die Form

$$(2.5.2.1) \quad p(\underline{x}) = \frac{1}{\sqrt{(2\pi)^m |C|}} \cdot \exp \left\{ -\frac{1}{2} (\underline{x} - \underline{\mu})' C^{-1} (\underline{x} - \underline{\mu}) \right\},$$

abgekürzt $p(\underline{x}) \sim N(\underline{\mu}, C)$, wobei $\underline{\mu}$ ein m -dimensionaler Vektor ist, der Erwartungswert der Verteilung

$$(2.5.2.2) \quad \underline{\mu} = E[X'] = (E[X_1], \dots, E[X_m])$$

und die $m \times m$ -Varianz-Kovarianz-Matrix

$$(2.5.2.3) \quad C = E[(\underline{X} - \underline{\mu})(\underline{X} - \underline{\mu})']$$

wobei in der Hauptdiagonale von C die Varianzen der einzelnen Variablen stehen und die Kovarianzen σ_{ij} zwischen verschiedenen Variablen X_i und X_j die übrigen Matrixelemente bilden

$$(2.5.2.4) \quad \sigma_{ij}^2 = E[(X_i - \mu_i)(X_j - \mu_j)']$$

Ist eine Klasse im Merkmalsraum nach $N(\underline{m}_i, C_i)$ verteilt, d. h. $p(\underline{x}|K_i) \sim N(\underline{m}_i, C_i)$, so ergibt sich nach (2.5.1.13) eine Diskriminanzfunktion mit minimaler BAYES'scher Fehlerrate durch

$$(2.5.2.5) \quad \begin{aligned} d_i(\underline{x}) &= \log p(\underline{x}|K_i) + \log p(K_i) \\ &= -\frac{1}{2} (\underline{x} - \underline{m}_i)' C_i^{-1} (\underline{x} - \underline{m}_i) - \frac{1}{2} \log(2\pi) - \\ &\quad - \frac{1}{2} \log |C_i| + \log p(K_i). \end{aligned}$$

Nimmt man an, daß die Varianz-Kovarianzmatrizen C_i für alle Klassen K_i , $i = 1, \dots, k$, gleich sind, so ist der quadratische Term $\underline{x}' C_i^{-1} \underline{x}$ unabhängig von i und man kann ihn weglassen (ebenso das konstante Glied). Sind die a priori Wahrscheinlichkeiten $p(K_i)$ für alle $i = 1, \dots, k$ gleich, so erhält man die Diskriminanzfunktion

$$(2.5.2.6) \quad d_i(\underline{x}) = (\underline{x} - \underline{m}_i)' C^{-1} (\underline{x} - \underline{m}_i)$$

und man weist den Merkmalsvektor \underline{x} derjenigen Klasse zu, für die die rechte Seite von (2.5.2.6) minimal wird, d. h. nach (2.4.8) deren Mittelpunktsvektor \underline{m}_i den kleinsten MAHALANOBIS-Abstand von \underline{x} hat. Da der quadratische Term $\underline{x}' C^{-1} \underline{x}$ von i unabhängig ist, kann der obige Ausdruck weiter vereinfacht werden und man erhält einen linearen Ausdruck für die Diskriminanzfunktion

$$(2.5.2.7) \quad d_i(\underline{x}) = \underline{w}_i' \underline{x} + w_{i,m+1},$$

wobei sich der Gewichtsvektor \underline{w}_i und das konstante Glied $w_{i,m+1}$ durch Ausmultiplizieren von (2.5.2.5) ergeben.

Ein Merkmalsvektor \underline{x} wird der Klasse K_i zugewiesen, wenn gilt

$$(2.5.2.8) \quad d_i(\underline{x}) - d_j(\underline{x}) > 0 \quad \text{für alle } j \neq i.$$

Definiert man $d_{ij} = d_i - d_j$, so erhält man die Entscheidungsregel

$$(2.5.2.9) \quad \underline{x} \in K_i \iff d_{ij}(\underline{x}) > 0 \quad \text{für alle } j \neq i, \text{ bzw.}$$

$$(2.5.2.10) \quad \underline{x} \in K_i \rightarrow d_{ij}(\underline{x}) > \frac{\log p(K_j)}{\log p(K_i)}, \text{ für alle } j \neq i,$$

wenn die a priori-Wahrscheinlichkeiten nicht alle gleich angenommen werden können.

Bemerkung: Sind die Varianz-Kovarianz-Matrizen C_i der Klassen K_i ($i = 1, \dots, k$) nicht alle gleich, so erhält man quadratische Diskriminanzfunktionen und der Rechenaufwand steigt erheblich (HABERÄCKER 1978). Es ist deshalb zweckmäßig zu prüfen, ob eine gewichtete Matrix

$$(2.5.2.11) \quad C = \frac{1}{n-k} \sum_{i=1}^k n_i C_i,$$

verwendet werden kann, wobei n die Gesamtzahl der Merkmalsvektoren und n_i die Anzahl der Klassenelemente von K_i bedeute.

Die Homogenität der Varianz-Kovarianz-Matrizen C_i kann durch einen Test genauer untersucht werden. Als Testgröße verwendet man (vgl. MORRISON 1976)

$$(2.5.2.12) \quad \text{HOM} = \frac{1}{2} \sum_{i=1}^k n_i \cdot \log \frac{|C|}{|C_i|},$$

wobei die Differenzen zwischen den C_i ($i = 1, \dots, k$) als signifikant angesehen werden, wenn HOM bei einer gewählten Sicherheitsschranke den entsprechenden χ^2 -Wert mit $(k-1)m(m+1)/2$ Freiheitsgraden überschreitet.

2.5.3 Klassifizierung mit Zurückweisungsklasse

Bei Anwendungen ist man meist nicht sicher, ob die gewählten k Klassen mit ihren Repräsentanten \underline{m}_i alle Klassen erfassen. Die BAYES'sche Klassifizierung liefert für jeden Merkmalsvektor eine Klasse, obwohl die Distanz zum Repräsentanten sehr groß sein kann. Es ist deshalb sinnvoll, stets eine Zurückweisungsklasse K_r einzuführen, und den Klassifizierungsprozeß in folgende Schritte zu gliedern:

1. Einlesen eines neuen Merkmalsvektors \underline{x}
2. Berechnung von $d_i(\underline{x}) = d(\underline{x}, \underline{m}_i)$ für alle $i = 1, \dots, k$
3. $d_j = \min \{ d_i(\underline{x}), i = 1, \dots, k \}$
4. ist $d_j < c_j$?

ja: $\underline{x} \in K_j$, Sprung nach 1.

nein: $\underline{x} \in K_r$, Sprung nach 1.

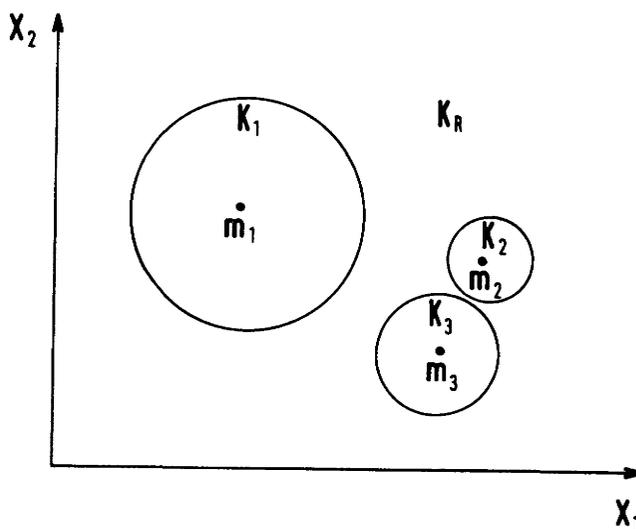


Abb. 17: Darstellung der Prototypen \underline{m}_i ($i = 1, 2, 3$) von drei Klassen und ihrer Rückweisungsschranken.



Abb. 18: Klassifizierung einer Landsat-Subszene (Murnauer Mulde) mit Rückweisungsschranke. W: Wald; blank: Wasser; -: Felder; ?: Pixel, die keiner Klasse zugeordnet werden können. Ein Vergleich mit der Karte zeigt, daß die "2" vorwiegend die Autobahn und bebautes Gebiet treffen.

Als Rückweisungsschranke wird oft ein 2σ Abstand von \underline{m}_j verwendet.

Abb. 17 zeigt ein Beispiel für diese Art der Klassifizierung. Die Elemente der Zurückweisungsklasse K_r können benutzt werden, um automatisch neue Prototypen von Klassen zu definieren und in den Klassifizierungsprozeß einzubauen. In diesem Fall erhält man einen abgewandelten Algorithmus:

1. Einlesen eines neuen Bildpunktes \underline{x}
2. Berechnung aller Distanzen $d_i = d_i(\underline{x}, \underline{m}_i)$, $i = 1, \dots, k$
3. Bestimmung der minimalen Distanz d_j ,
 $d_j = \min [d_i(\underline{x}, \underline{m}_i), i = 1, \dots, k]$
4. ist $d_j < c$?

ja: $\underline{x} \in K_j$
nein: setze $\underline{m}_{k+1} := \underline{x}$
 und $k := k+1$

5. Rücksprung nach 1.

Dieses Verfahren hat gegenüber der normalen Klassifizierung nach minimaler Distanz (minimum distance classifier) den Vorteil, daß neue Klassen automatisch entdeckt werden, deren a priori-Wahrscheinlichkeit sehr klein ist.

Die zufällige Wahl des Klassenmittelpunktes \underline{m}_{k+1} kann im Laufe des Klassifizierungsprozesses durch schrittweise Umdefinition dem tatsächlichen Klassenmittelpunkt angenähert werden:

Wird ein Bildpunkt \underline{x} einer Klasse K_j zugeordnet, die zu diesem Zeitpunkt n Bildpunkte enthält, so berechnet sich der neue Klassenmittelpunkt zu

$$(2.5.3.1) \quad \underline{m}_j := \frac{1}{n+1} (n \cdot \underline{m}_j + \underline{x}).$$

Abb. 18 zeigt ein Beispiel für diese Art der Klassifizierung. Eine Interpretation der neu definierten Klassen ist meist nur nach Geländekontrollen möglich.

2.6 Reduktion der Dimension des Merkmalsraumes

Da die Rechenzeit für eine Klassifizierung im ungünstigen Fall quadratisch mit der Anzahl der verwendeten Variablen steigt, sind Voruntersuchungen eines Datensatzes notwendig, um die Variablenzahl zu reduzieren. Im wesentlichen bieten sich hierzu zwei Methoden an:

- Auswahl von l Variablen aus einer Menge von m Variablen ($l \ll m$);
- Transformation des m -dimensionalen Merkmalsraumes in einen solchen mit niedrigerer Dimension.

Ziel dieser Methode ist es, im neuen Merkmalsraum einen möglichst hohen Prozentsatz der im ursprünglichen Merkmalsraum vorhandenen Information bei möglichst niedriger Dimension zu erhalten. Als Informationsmaß dient hierbei die Gesamtvarianz oder die Varianz innerhalb der einzelnen Gruppen oder die Entropie

$$(2.6.1) \quad H = - \int_M p(\underline{x}) \ln p(\underline{x}) d\underline{x} ,$$

wobei $p(\underline{x})$ die Wahrscheinlichkeitsdichte der Daten ist. Anschaulich gesprochen ist der Informationsgehalt einer Datenmenge umso größer, je "ungeordneter" die Daten sind (z. B. ist der Informationsgehalt der Buchstabenfolge *abbababaab* größer als der von *aaaaabbbb*, obwohl beide Folgen dieselben Buchstaben enthalten).

Als Maß für den Informationsgehalt einer Variablen kann deren Variationsbreite (oder die Varianz) verwendet werden. Die Abhängigkeiten der Variablen untereinander sind von der Varianz-Kovarianz-Matrix erfaßt, deren Determinante C maximal ist (bei gleichbleibenden Hauptdiagonalelementen), wenn alle Variablen unabhängig voneinander sind. Die Gesamtvarianz ist durch die Summe der Varianzen gegeben, d. h. durch die Spur $Sp(C)$ der Varianz-Kovarianz-Matrix.

2.6.1 Auswahl von Variablen

Wählt man aus m Variablen $1 < m$ Variable aus, so gibt es hierfür

$$(2.6.1.1) \quad \binom{m}{1} = \frac{m!}{1!(m-1)!}$$

verschiedene Möglichkeiten (Beispiel: bei 10 Variablen kann man auf 210 verschiedene Arten 5 Variable auswählen). Diese schon bei kleiner Variablenzahl große Auswahlmöglichkeit erlaubt es nicht, aus allen möglichen Variablensätzen einfach denjenigen herauszusuchen, der bei einer Klassifizierung die geringste Fehlerquote liefert. Abb. 19 zeigt, wie unterschiedlich die Anzahl der Fehlklassifizierungen bei günstiger und ungünstiger Variablenauswahl sein kann.

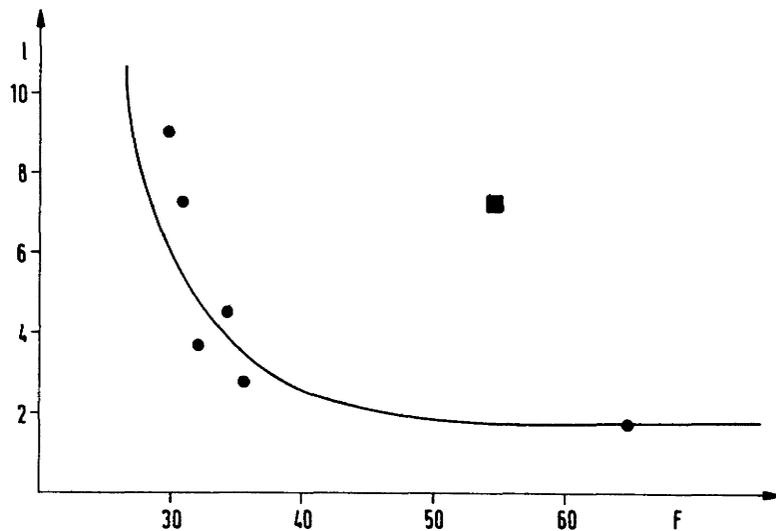


Abb. 19: Entwicklung der Fehlerrate F bei Reduzierung der Variablenzahl l nach der Strategie von Kap. 4 (Punkte). Das Quadrat gibt die Zahl der Fehlklassifizierungen bei ungünstiger Auswahl von 5 Variablen an.

Eine einfache Auswahlstrategie liegt darin, ähnliche Variable in Gruppen zusammenzufassen und aus jeder Gruppe eine Variable für den Klassifizierungsprozeß zu wählen. Ausgangspunkt für diese Art der Clusterbildung ist die Korrelationsmatrix R ("R-Modus"), wobei der Korrelationskoeffizient r als Ähnlichkeitsmaß zwischen je zwei Variablen verwendet wird. Der Korrelationskoeffizient r liegt zwischen -1 und $+1$, wobei $r=0$ bedeutet, daß zwischen zwei Variablen X und Y keine Korrelation vorhanden ist, bei $r=+1$ liegt lineare Abhängigkeit der Variablen X, Y vor, d. h. $X = cY+d$ mit $c, d \in \mathbb{R}$.

Im ersten Schritt werden solche Variablen in Paaren zusammengefaßt, die wechselseitig die größte Ähnlichkeit miteinander haben (d. h. $r_{i,j}$ muß in Spalte i und Spalte j von R maximal sein, $i \neq j$). Zwischen den Gruppen werden erneut Korrelationskoeffizienten berechnet (an dieser Stelle unterscheiden sich die zahlreichen Clusterverfahren am stärksten) und mit der reduzierten Korrelationsmatrix R_1 wird das Verfahren fortgeführt (DAVIS 1973).

Abb. 20 zeigt eine (hierarchische) Gruppierung von Texturvariablen, wobei deutlich 3 Gruppen unterschieden werden können: Die Variablen (1, 2, 3), (4, 6, 7, 8, 9) und (5, 10). Die Variablen 4 und 6 weisen dabei die höchste Ähnlichkeit auf ($r = 0.98$).

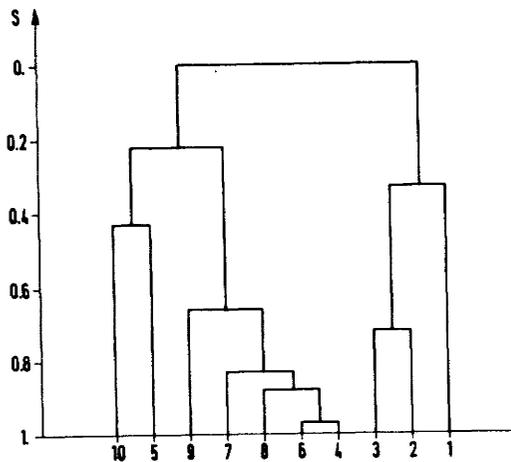


Abb. 20: Dendrogramm einer Clusteranalyse im R-Modus (Variable: Texturparameter, vgl. Kap. 4)

2.6.2 Reduktion der Variablenzahl durch Bildtransformation

Die bekannteste Transformation zur Reduzierung der Dimension des Merkmalsraums ist die Hauptachsentransformation

$$(2.6.2.1) \quad \underline{y} = A \cdot \underline{x} ,$$

wobei die Matrix A durch Varianzmaximierung bestimmt wird (vgl. Anhang 3). Die Komponenten der Zeilenvektoren \underline{a}_i von A ($i = 1, \dots, m$) können als Gewichte betrachtet werden, mit denen die einzelnen Originalvariablen X_i bei der Berechnung der transformierten Variablen Y_j eingehen ("Ladungen").

Bei der Hauptkomponententransformation (PCT: principal component transformation) bleibt die Spur $Sp(C)$ der Varianz-Covarianz-Matrix C invariant, die Varianz der transformierten Variablen Y_j ist durch die zugehörigen Eigenwerte λ_j ($j = 1, \dots, m$) gegeben. Ordnet man die Eigenwerte von C der Größe nach und verwendet nur die ersten l ($l < m$) Eigenvektoren zur Transformation

$$(2.6.2.2) \quad y_l = A_l \underline{x} ,$$

so erhält man einen reduzierten Merkmalsvektor \underline{y}_l mit l Komponenten. Setzt man die Summe der verwendeten Eigenwerte λ_i ($i = 1, \dots, l$) in Relation zu $Sp(C)$, so erhält man den Anteil der Varianz der transformierten Variablen an der ursprünglich vorhandenen Gesamtvarianz.

Ähnlich wie bei der Clusteranalyse im R-Modus wird hierbei nur die Ähnlichkeitsstruktur der Variablen zur Transformation verwendet. Bei der Canonischen Variablen-Transformation (CVT) geht man von der Struktur der vorgegebenen Gruppen im Merkmalsraum aus. Die Transformationsmatrix A wird so bestimmt, daß die Gruppen im transformierten Raum möglichst gut getrennt sind (vgl. Anh. 3).

Analog zur PCT kann man den Beitrag der "canonischen Variablen" zur Gesamtvarianz messen und die Dimension des transformierten Raumes reduzieren. Er wird auch als Diskriminanzraum bezeichnet. Da die CVT neben der Ähnlichkeitsstruktur der Variablen auch die Verteilung der Merkmalsvektoren in den verschiedenen Gruppen berücksichtigt, ist sie der PCT im allgemeinen überlegen (in Kap. 4 werden beide Transformationsmethoden in einem Beispiel verglichen).

3. SPEKTRALE SIGNATUREN VON GESTEINSOBERFLÄCHEN IM SAHARA-RAUM

3.1 Probleme der Signaturerkennung

Das Landsat-System liefert für jeden Bildpunkt einen 4-dimensionalen Vektor der Reflexionswerte in den vier Spektralkanälen. Die Aufgabe der Signaturerkennung besteht darin, eine Klassifizierung im Bildraum vorzunehmen und die entstehenden Klassen mit der Klasseneinteilung zu vergleichen, die man für die aufgenommenen Gesteinseinheiten mit anderen Methoden (Geländeaufnahmen, Luftbildinterpretation etc.) erhält. Geht man von einer homogenen Fläche aus, so erhält man einen Reflexionsvektor $\underline{x}' = (x_1, x_2, x_3, x_4)$ für jeden Punkt der Fläche. Geht man davon aus, daß das Signal durch verschiedene Einflüsse gestört ist, so kann man den Merkmalsvektor \underline{x} als Zufallsvektor mit Erwartungswert \underline{m} und Streuung \underline{s} betrachten und das Modell (2.2.1.4) anwenden (vgl. auch Abb. 10).

Will man eine maximale Obereinstimmung der Klassifizierung im Bildraum mit der Klassifizierung im Objektraum erreichen, so ergeben sich Probleme aus dem Klassifizierungsverfahren und aus dem Aufnahmeverfahren.

Geht man von einer Klasse im Objektraum aus, z. B. von einer Gesteinseinheit im Gelände, so können Unterschiede im Reflexionsverhalten der verschiedenen Bildpunkte im wesentlichen durch folgende Faktoren verursacht werden:

- Reliefausbildung
- Hangexposition (Licht- und Schattenhänge)
- ungleichmäßige Verwitterung
- Änderung der räumlichen Lage geschichteter Gesteine
- unterschiedliche tektonische Beanspruchung
- Vegetationsbedeckung
- unterschiedliche Durchfeuchtung der Oberflächen
- Faziesunterschiede

Weitere Klassifizierungsprobleme ergeben sich aus dem Auflösungsvermögen des Aufnahmesystems: eine Gesteinsschicht kann nur als solche identifiziert werden, wenn die Ausstrichbreite genügend groß ist. Um eindeutige Reflexionswerte für eine Oberfläche zu erhalten, muß sie mindestens drei bis 4 Pixel groß sein, d. h. bei Landsat-Aufnahmen etwa $200 \times 200 \text{ m}^2$.

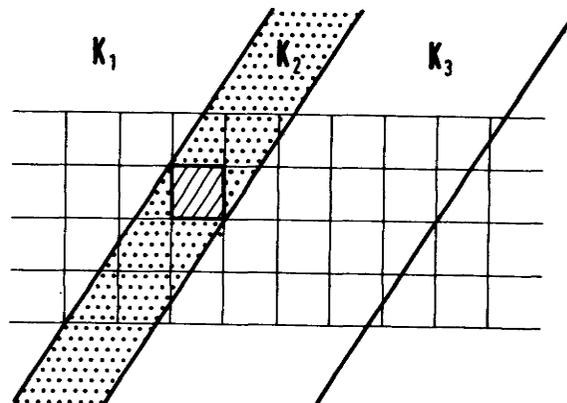


Abb. 21: Zur Entstehung von Mischsignaturen bei geringen Ausstrichbreiten: bei Steinskomplex K_2 (zwischen K_1 und K_3) ist die Wahrscheinlichkeit klein, daß ein Pixel ganz in die Ausstrichfläche fällt.

Kleinere Flächen können zwar noch erkannt werden (z. B. Straßen), wenn sie sich genügend vom Hintergrund abheben. Die Reflexionswerte solcher Flächen hängen jedoch vor allem vom Mischungsverhältnis der Grautonwerte von Objekt und Hintergrund ab, die sich aus dem Flächenverhältnis innerhalb des vom Pixel erfaßten Bereichs ergibt (Abb. 21). Entsprechende "Mischsignaturen" ergeben sich an geologischen Grenzen auch bei großflächigen Gesteinskörpern.

Man könnte versucht sein, eine feinere Klasseneinteilung einzuführen, so daß den verschiedenen morphologischen und faziellen Ausprägungen eines Gesteinskörpers verschiedene Merkmalsklassen zugeordnet werden. Hierdurch vervielfacht sich jedoch die Klassenzahl, und eine eindeutige Zuordnung wird nicht erreicht. Vielmehr entsteht ein verwirrendes Bild, dessen Interpretierbarkeit mit wachsender Klassenzahl rasch sinkt.

Ein weiteres Problem bei geologischen Fragestellungen liegt in der hohen Korrelation der Landsat-Spektralkanäle (Kap. 3.3). Einfache Klassifizierungsmethoden (z. B. die Quadermethode), die bei Landnutzungsfragen zufriedenstellende Ergebnisse liefern, können bei geologischen Problemen versagen, weil die Merkmalsvektoren von Gesteinsoberflächen im Merkmalsraum langgestreckte Ellipsoide bilden, deren Hauptachsen nicht parallel zu den Merkmalsachsen liegen (vgl. z. B. Abb. 23).

Es ist deshalb notwendig, die Klassifizierungsalgorithmen der speziellen Struktur der Reflexionswerte von Gesteinsoberflächen anzupassen, um auch bei geologischen Fragestellungen eine optimale Auswertung der Landsat-Daten zu ermöglichen.

3.2 Signaturen von Gesteinsoberflächen

Die Untersuchungen dieses Kapitels beschränken sich auf Gesteinsoberflächen, wie sie im Tibesti-Gebirge, im Sudan und SW-Ägypten auftreten (Abb. 22). Es wurden Gebiete ausgewählt, die keine Vegetationsbedeckung aufweisen und ein möglichst breites Spektrum morphologischer und geologischer Erscheinungen abdecken.

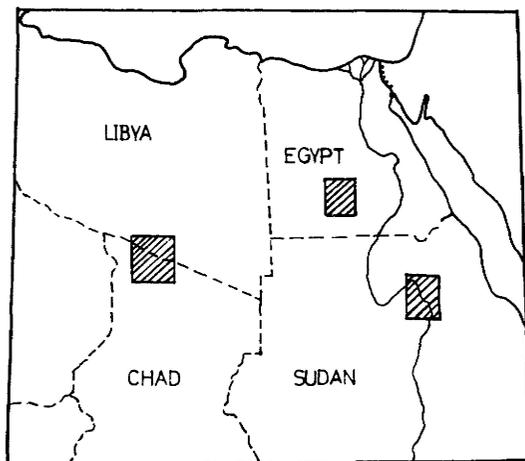


Abb. 22: Lageskizze der untersuchten Landsat-Szenen
(Bildnummern s. Anh. 1)

Das Tibesti-Gebirge liegt in der zentralen Sahara, im Norden der Republik Tschad. Der geologische Aufbau weist eine Dreigliederung auf in

- metamorphes, präkambrisches Basement,
- eine mächtige paläozoische Sandsteinserie und
- ausgedehnte Vulkanitserien in der Umgebung gewaltiger Stratovulkane.

Als besonderes lineares Element fallen große Störungen auf, die im Satellitenbild z. T. über 100 km weit verfolgt werden können.

Präkambrisches Basement ist auch in der untersuchten Landsat-Szene im nördlichen Sudan und in SW-Ägypten aufgeschlossen (z. B. Umgebung Gebel Uweinat). Die paläozoisch-mesozoische Sedimentfolge liegt hier flach

und bildet Schichtstufen, die manchmal durch eine ganze Szene verfolgt werden können.

Während im Tibesti-Gebirge Helligkeitsunterschiede, die durch das Relief verursacht werden (vgl. z. B. Abb. 33 und 34), die Variationsbreite der Grautonwerte einer Gesteinseinheit stark vergrößern, ist es bei den flach liegenden Sedimentgesteinen SW-Ägyptens vor allem die Sandbedeckung, die eine scharfe Abgrenzung der Grautonbereiche verschiedener Gesteinseinheiten verhindert. Daneben spielt in vielen Wüsten die Krustenbildung eine wichtige Rolle. Krusten und Rinden entstehen durch Verdunstung von Lösungen, die aus dem Porenraum der Gesteine an die Oberfläche aufsteigen (GABRIEL 1961). Sie sind meist braun oder schwarz und bestehen aus Eisen- und Manganoxiden. Da die Verdunstung sehr stark vom Mikroklima in einer bestimmten Umgebung abhängt, kann eine Gesteinseinheit (abgesehen von anderen Effekten) sehr unterschiedliche Signaturen liefern, je nachdem ob sie von einer Kruste überzogen ist oder nicht. Man kann davon ausgehen, daß Sandsteine stärker zur Krustenbildung neigen als Basalte.

Die Eisenkrusten-Bildung kann auch zur Konvergenz der Signaturen von Gesteinsoberflächen führen, wenn verschiedene Gesteinskomplexe von einer einheitlichen dunklen Kruste überzogen sind.

Die untersuchten Gesteinseinheiten sind auf den zur Kontrolle verwendeten geologischen Interpretationskarten (LIST (Ed.) 1978; KLITZSCH & LIST (Ed.) 1978) in folgende Kategorien eingeteilt:

- metamorphe Schiefer
- Granite
- Sandsteine
- Eruptivgesteine
- Lockergesteine

Nr.	Ort	Gesteinsart	Symbol	m ₄	4	m ₅	5	m ₆	6	m ₇	7
1	Toussidé	Basalt	BU	26.0	1.7	24.0	2.3	20.4	2.2	7.7	1.0
2	Toussidé	Basalt	BU	29.3	2.1	28.1	3.0	24.1	3.1	9.1	1.4
3	östl. Bardai	Basalt	BL	31.8	3.1	31.9	5.6	26.4	5.5	10.0	2.4
4	Tarso er Toon	Basalt	BC	32.5	2.3	33.0	3.1	28.7	2.9	10.3	1.4
5	Tarso er Toon	Ignimbrit	EL	40.4	2.9	46.9	4.1	43.1	4.1	19.4	2.1
6	südl. Toussidé	Ignimbrit	EL	47.6	2.8	58.9	5.0	53.3	4.4	22.6	2.0
7	südl. Toussidé	Ignimbrit	EL	57.0	1.5	76.5	1.3	71.3	1.8	28.6	0.5
8	Tarso er Toon	Andesit	EA	40.3	1.5	46.6	2.5	42.3	2.7	17.3	1.5
9	Tarso er Toon	Rhyolit/Trachyt	ER	40.7	3.6	49.9	5.3	46.8	5.4	21.5	2.8
10	Aozou	Sandstein	S	39.8	2.0	45.2	3.4	40.4	3.5	16.7	1.5
11	Ehi Tougouma	Sandstein	SD	37.1	2.0	37.9	2.9	33.9	2.9	14.0	1.3
12	Ehi Tougouma	Sandstein	SM	42.7	4.2	48.7	6.7	43.8	6.6	18.2	3.0
13	Double Scarp	Sandstein	DR	51.6	2.2	74.4	5.1	70.9	5.1	28.5	2.3
14	östl. Ofouni	Metamorphit	ML	40.3	3.7	46.1	5.4	41.0	4.9	16.5	2.1
15	Aozou	Metamorphit	ML	39.9	4.9	43.5	8.6	39.7	8.5	15.4	2.5
16	Mongo	Metamorphit	MD	36.2	3.2	40.8	5.4	37.5	5.7	15.0	2.7
17	Ofouni	Granit	MG	43.2	4.5	51.1	7.5	46.6	7.4	19.4	3.2
18	Méchê	Granit	MG	45.4	3.9	56.1	6.1	51.4	6.0	21.9	2.8
19	Mongo	Sand	QD	37.4	1.3	40.8	1.8	36.6	2.1	15.7	0.8
20	nördl. Toussidé	Sand	QL	50.5	1.4	58.8	1.7	51.9	1.7	20.7	0.7
21	nördl. Bardai	Sand	QL	58.5	1.6	86.8	2.2	81.0	2.3	33.6	1.0
22	Double Scarp	Sand	DR	65.8	1.2	96.2	2.0	92.2	1.9	38.6	0.8
23	Wadi Qena	Chalk, verw.	TW	94.4	5.3	117.0	6.2	107.0	5.2	43.3	2.2
24	Wadi Qena	Eisenkruste	UO	40.5	1.8	45.3	3.3	41.4	3.4	15.3	1.9

Tab. 1: Signaturmittelwerte und Streuungen von ausgewählten Gesteinsoberflächen (5 x 5 Pixel).

Tabelle 1 stellt eine repräsentative Auswahl von spektralen Signaturen verschiedener Gesteinsoberflächen im Untersuchungsgebiet dar. Die Identifizierung der Gesteine geschah mit Hilfe der von der Arbeitsgruppe "Fernerkundung" der FU in Zusammenarbeit mit der TU und der TFH Berlin herausgegebenen geologischen Interpretations-Karten (LIST (Ed.) 1978; KLITZSCH & LIST (Ed.) 1978). Die in Spalte 4 der Tabelle enthaltenen Symbole beziehen sich auf diese Karten.

Die Grautonwerte stellen relative Reflexionswerte dar, wobei zwischen den Tibesti-Szenen eine Normierung durchgeführt wurde. Durch die geringfügige Überlappung der Landsat-Szenen können die Reflexionswerte in entsprechenden Gebieten verglichen und durch eine additive Konstante (1 bis 2 Grautonstufen) einander angeglichen werden. Das Streulicht wurde nicht eliminiert (vgl. Kap. 3.4).

Zur Verdeutlichung des spektralen Reflexionsverhaltens von Gesteinsoberflächen im Sahara-Raum sind die Grautonmittelwerte verschiedener Gesteinseinheiten in den vier Landsat-Spektralkanälen in Abb. 23 dargestellt.

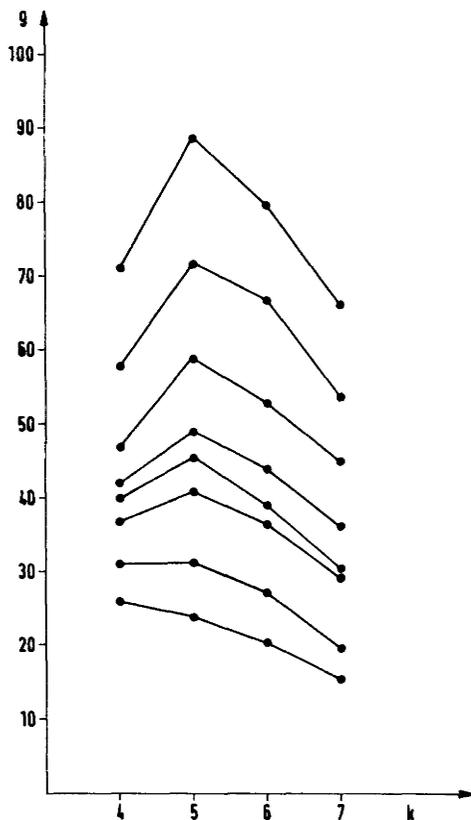


Abb. 23: Grautonmittelwerte verschiedener Gesteinseinheiten in den Kanälen 4 - 7 (Werte in Kanal 7 verdoppelt). In Kanal 4 von unten nach oben: Basalt 1 - 3, Metamorphit, Sandstein, Ignimbrit, Sande 1 - 3

Charakteristisch an dieser Abbildung ist die Erhaltung der Ordnung in allen Spektralkanälen, d. h. ist eine lithologische Einheit in einem Kanal heller als eine andere, so gilt diese Relation für alle Spektralkanäle (dieser Sachverhalt wird in Kap. 3.3 genauer erfaßt).

Dieses Spektralverhalten von Gesteinsoberflächen im ariden Klimabereich ist wesentlich verschieden vom Spektralverhalten vegetationsbedeckter Oberflächen (Abb. 26).

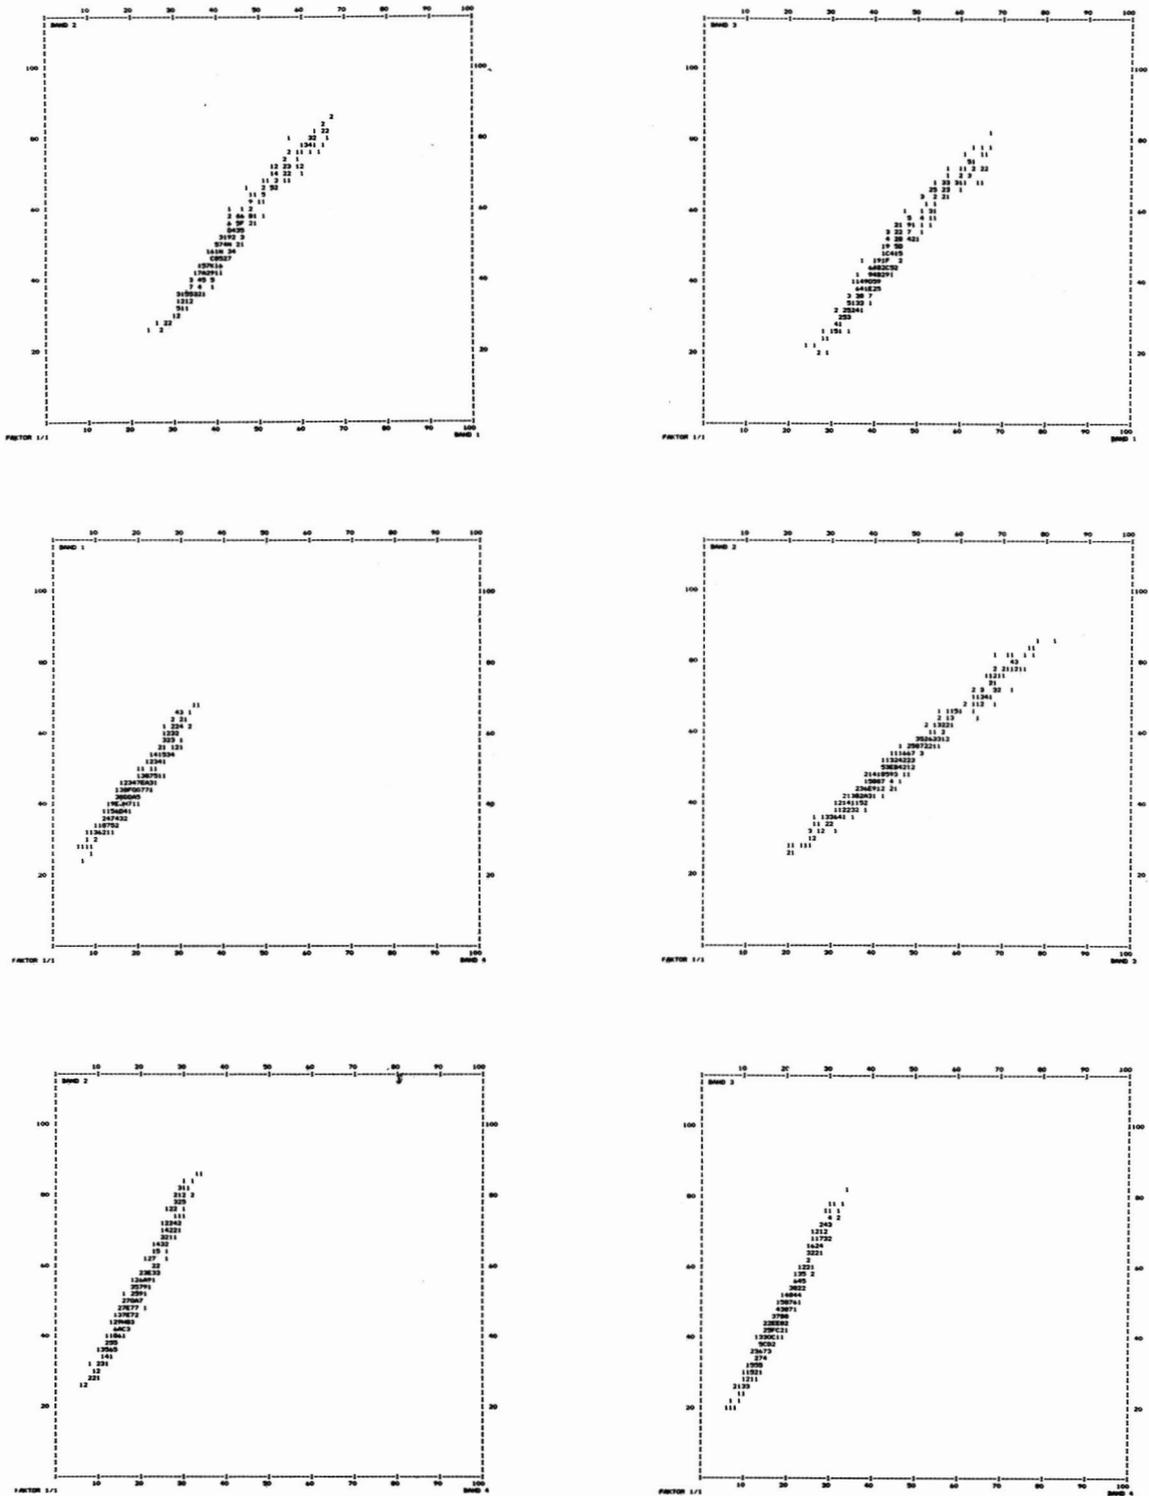


Abb. 24: Scattergramme der Grautonwerte von 450 zufällig gewählten Bildpunkten einer Tibest-Szene (Umgebung Ofouni, Tschad; E 12o9 - o8491). Es sind alle Kombinationen von je zwei Spektralkanälen dargestellt.

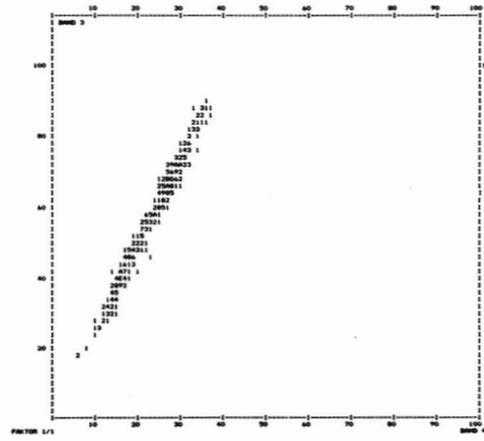
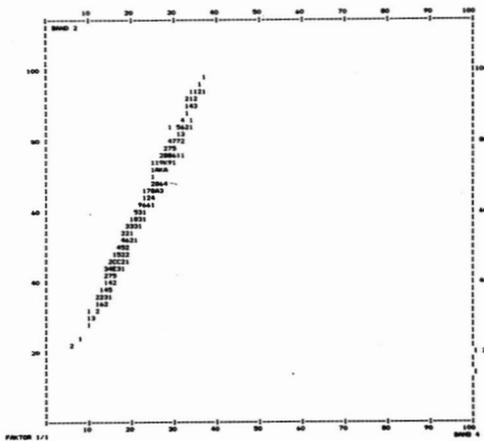
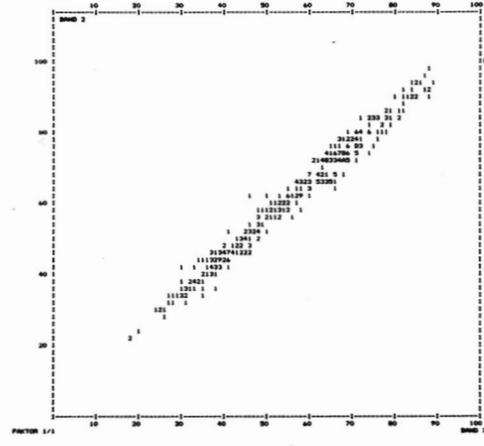
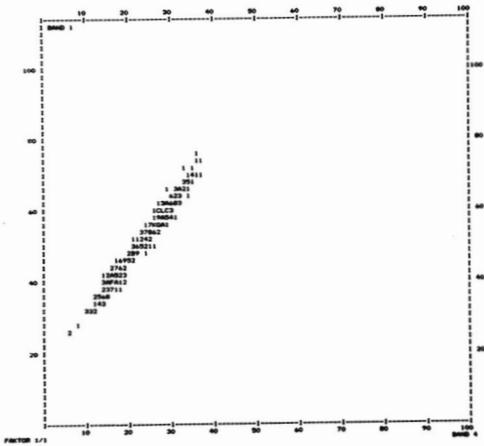
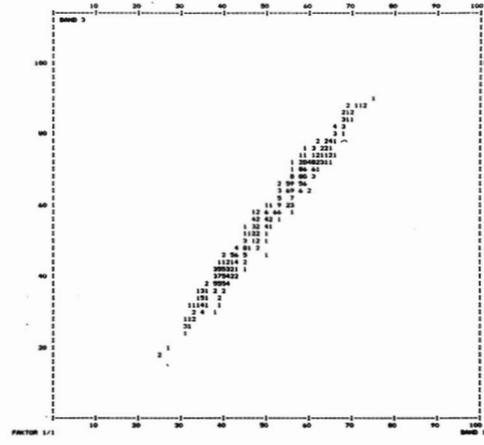
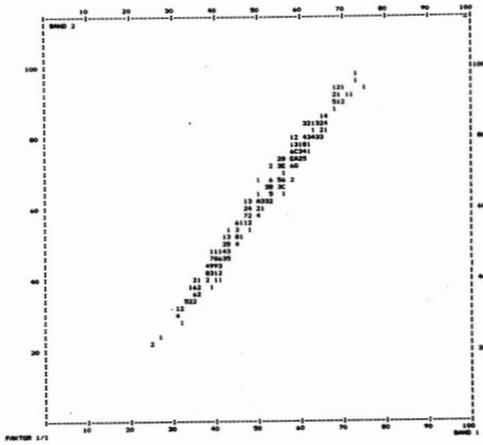


Abb. 25: (wie Abb. 24) Scattergramme der Grautonwerte von 450 zufällig gewählten Bildpunkten einer Sudan-Szene (Umgebung El Aiadia, Sudan; E-1197 - 07410).

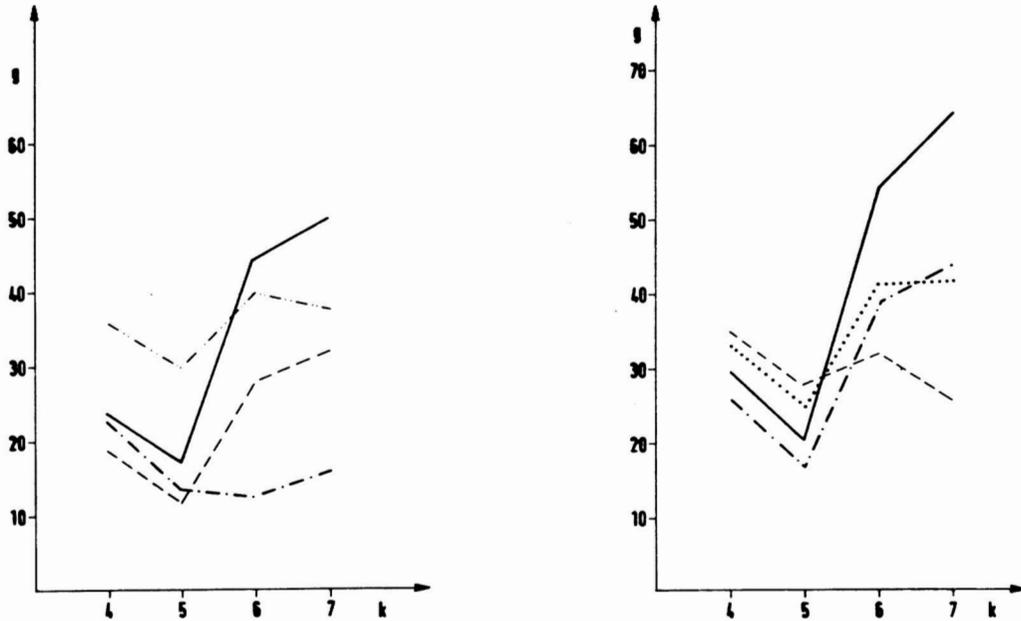
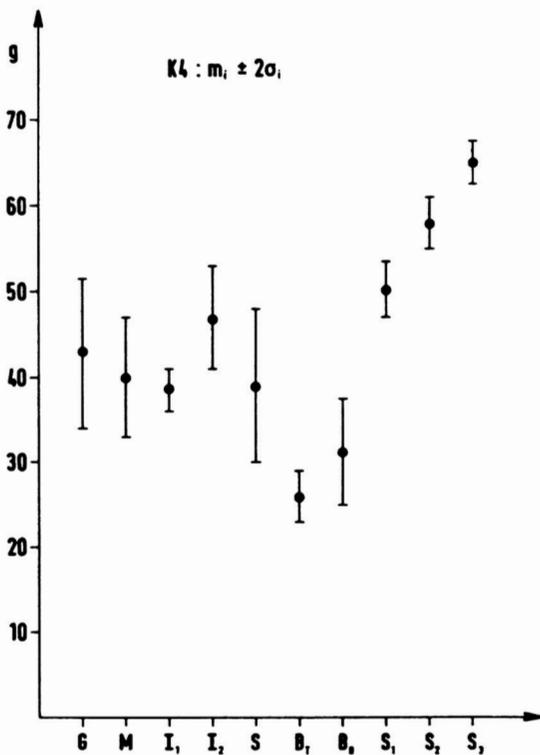


Abb. 26: Grautonmittelwerte vegetationsbedeckter Oberflächen im Alpenvorland (links) und in Neuguinea (rechts). Erfasste Flächen: Wald, Wasser, Felder, bebautes Gebiet, Urwald und gerodete Flächen.

Charakteristisch ist hier das unterschiedliche Verhalten der verschiedenen Flächen im Infrarot-Bereich.

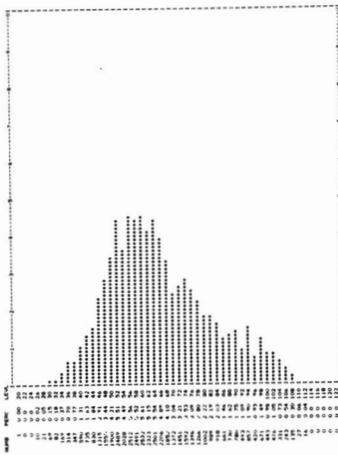


Wie Abb. 27 zeigt, ist der Grautonbereich zwischen 30 und 50 bei Gesteinsoberflächen von sehr unterschiedlichen Gesteinseinheiten ausgefüllt (Vulkanite, Plutonite, Metamorphite, Sandsteine). Gut zu trennen sind auf Grund der Helligkeitsunterschiede nur die Sande und junge Basalte von den übrigen Gesteinen (die Kanäle 5 - 7 zeigen eine analoge Verteilung der Mittelwerte und Streuungen wie Kanal 4).

Abb. 27: Grautonmittelwerte und Streuungen verschiedener Gesteinseinheiten im Sahara-Raum (Landsat-Spektralkanal 4). Von links nach rechts: Granit, Metamorphit, Ignimbrit 1, 2, Sandstein, Basalt 1, 2, Sande 1 - 3.

3.2.1 Granitische Intrusiva

Die Granitintrusionen zeigen im Untersuchungsgebiet die größte Variationsbreite. Dies liegt vor allem an der charakteristischen Verwitterung des Granits im ariden Klimabereich. Im Satellitenbild erscheinen die Intrusivkörper in große Blöcke zerlegt, die von Trockentälern getrennt werden. Dadurch treten große Helligkeitsunterschiede unmittelbar benachbart auf. Unterschiedliche Alter und Hebungsbeträge der Intrusionen bewirken, daß alle Stadien der Entwicklung nebeneinander vorkommen: junge Granite, die sich farblich kaum von den umgebenden Metamorphiten unterscheiden, ältere Intrusivkörper, die von der Verwitterung in große Blöcke zerlegt sind (die im Satellitenbild der "Wollsackverwitterung" entsprechen, die im Luftbild für Granite charakteristisch ist), und als Endstadium der Verwitterung eingesandete Depressionen.



Betrachtet man die Grautonverteilung einer Granitintrusion, so erkennt man, daß die Variationsbreite durch Licht- und Schatteneffekte, Mischsignaturen bei sandbedeckten Trockentälern etc., fast so groß ist, wie die Variationsbreite der Grautonwerte der gesamten Landsat-Szene (Abb. 28).

Abb. 28: Grautonverteilung einer Granitintrusion. Die Variationsbreite umfaßt nahezu die gesamte Skala (Kanal 6).

Diese Eigenschaft macht es unmöglich, eine Klassifizierung auf Grund der Signaturen eines einzelnen Pixels durchzuführen. Bei der Identifizierung von Graniten spielt die Lagerungsform (meist runde Stöcke) und Bildtextur (grobe Oberflächenstruktur) meist eine größere Rolle als der Grautonwert.

3.2.2 Metamorphite

Die Metamorphite sind in der geologischen Karte des Tibesti in eine "helle" und eine "dunkle" Einheit unterteilt. Die Morphologie ist durch eine intensive Faltung geprägt, die sich im Satellitenbild durch eine feine streifige Textur bei mittel- bis dunkelgrauen einheitlichen Flächen bemerkbar macht (z. B. südl. Tarso Tieroko). Die dunklen Metamorphite ("Tibestien II") zeigen im Süden ("Mongo-Schiefer") eine gröbere Textur, die von breiten Kerbtälern herrührt. Die Signaturen der Testgebiete wiesen eine hohe Streuung auf, die vor allem durch die intensiven Schatten hervorgerufen wird.

Die Helligkeitsunterschiede zwischen beiden Gesteinseinheiten zeigen sich am stärksten in Kanal 4, während sie in Kanal 7 nicht mehr vorhanden sind. Generell sind die Signaturen der Metamorphite dunkler als die der Granite; von den Sandsteinen können sie meist nur auf Grund ihrer Textur unterschieden werden, da die Grauton-Mittelwerte innerhalb der einfachen Streubereiche liegen (vgl. Abb. 27).

3.2.3 Sandsteine

Die Sandsteine liegen fast im gesamten Untersuchungsgebiet sehr flach, das Entwässerungssystem ist nur im Tibesti-Gebirge gut ausgeprägt. Auffälligste Formen sind die stark zertalten Sandsteinkomplexe am Ostrand

des Tibesti und die von breiten Trockentälern zerschnittenen massigen Sandsteine im Süden (Marmar, Gounoga). Letztere zeigen sehr homogene Grautonflächen, die leicht zu klassifizieren sind, während bei den stark zertalten Sandsteinkomplexen die Streuung der Grautonwerte innerhalb der Trainingsgebiete ebenso groß ist, wie bei den gefalteten Metamorphiten.

In SW-Ägypten sind die Signaturen der Sandsteine durch Flug- und Schwemmsande so verändert, daß ein Vergleich mit den Sandsteinserien des Tibesti nicht möglich ist. Man kann davon ausgehen, daß die flachliegenden Sedimente SW-Ägyptens nur Mischsignaturen aufweisen (Bedeckung durch Sand oder Krusten verschiedener Art), und nur an den Schichtstufen, wo stärkere Reliefbildung auftritt, der Sand einen geringeren Einfluß auf das Reflexionsverhalten hat.

3.2.4 Vulkanite

Die Basalte stellen die dunkelsten Gesteinseinheiten im Untersuchungsgebiet dar, wobei die jungen (quartären) Basalte dunkler erscheinen als die älteren Deckenbasalte, die häufig als Deckenreste darunter liegende Gesteine vor der Erosion schützen und typische Tafelberge bilden (z. B. bei Ofouni). Die Variationsbreite der Grautonwerte in den Trainingsgebieten ist geringer als bei den Metamorphiten, über größere Entfernungen (10 - 20 km) ändern sich die Signaturen jedoch signifikant (z. B. östlich von Bardai). Hieraus ergibt sich eine unruhige, dunkle Bildtextur, die im Osten der Sahara in der gleichen typischen Ausprägung auftritt, wie im Tibesti-Gebirge (vgl. Abb. 38).

Ähnliche Probleme tauchen bei den Ignimbriten auf, die im allgemeinen umso heller erscheinen, je weiter sie von ihrem Ursprungsort entfernt abgelagert werden (ROLAND 1973). Durch ihre Entstehung aus teilbeweglichen Glutwolken bilden die Ignimbritdecken weitgehend ebene Flächen, so daß lokal nur eine geringe Variation der Grautonwerte auftritt. Die Übergänge von dunkleren zu helleren Einheiten sind stetig, so daß die Klassifizierung breite Übergangszonen liefert, in denen eine eindeutige Zuordnung nicht möglich ist. Die Ignimbrite finden sich als mächtige Decken in der Umgebung der großen Stratovulkane (Emi Koussi, Toussidé, Tarso Voon). In dunkleren Grautönen heben sich davon die andesitischen und rhyolitischen Gesteine ab, die zudem lokal eine größere Streuung aufweisen (vgl. Abb. 30, oben).

3.2.5 Lockergesteine

Die Lockergesteine in ariden Gebieten können, entsprechend ihrer Genese (vor allem Abspülung und Deflation), folgendermaßen untergliedert werden (STOCK 1972):

- rezente Flußbetten
- Terrassen
- Schwemmfächer und Pedimente
- Dünen
- Flugsandflächen
- Hangschutt.

Charakteristisch für die Lockergesteine ist der durchweg hellere Grauton im Satellitenbild, wodurch eine Trennung von den dunkleren Festgesteinen möglich wird. In den großen Depressionen (z. B. östl. Gilf Kebir) und Sandebenen erscheinen die Sande als helle homogene Flächen, die meist durch Dünenzüge gegliedert sind. Größere Grautonunterschiede in den Sanden zeigen sich vor allem in den Schwemmfächern der Vorebenen des Tibesti-Gebirges. Oft liegen sehr helle unmittelbar neben sehr dunklen Sanden, obwohl die umgebenden Gesteinseinheiten im Satellitenbild einen einheitlichen Grauton besitzen (z. B. östl. Mongo-Metamorphite).

Da die Herkunft der Sande dem Satellitenbild nicht entnommen werden kann und feinste Sandbedeckung die Reflexionswerte der darunter liegenden Festgesteine - und nur diese sind für die geologische Interpretation von Bedeutung - in unkontrollierbarer Weise verändert, sind Sande ein bedeutender Störfaktor bei der Satellitenbilddauswertung.

Obwohl die Wüstensande im Gelände viele Farbschattierungen zeigen, machen sich diese im Landsat-Multispektralbild kaum bemerkbar. Dennoch weisen die Sande im Vergleich zu den Festgesteinen die größte Abweichung vom linearen Zusammenhang zwischen den Spektralkanälen auf (Kap. 3.3). Vermutlich sind Korngrößen- und Oberflächeneffekte, wohl auch Feuchtigkeitsunterschiede in den Sanden, für das Reflexionsverhalten von Bedeutung.

3.3 Korrelationsanalyse der Landsat-Spektralkanäle

Das Bildmaterial aus dem Sahara-Raum zeigt hohe Korrelationen zwischen allen Spektralkanälen. Eine graphische Darstellung der Reflexionswerte von zufällig gewählten Bildpunkten in je zwei Spektralkanälen macht deutlich, daß fast ein linearer Zusammenhang besteht.

Die Abb. 24 und 25 zeigen Scattergramme von Remissionswerten aus dem Tibesti und dem Sudan, die Landsat-Szenen entnommen wurden, die im Abstand von 18 Tagen aufgenommen wurden. Berechnet man die Korrelationsmatrizen und führt eine Hauptkomponentenanalyse durch, so zeigt sich (vgl. Abb. 29), daß alle Korrelationskoeffizienten größer als 0.95 sind und der erste Eigenwert 98 % bis 99 % der Gesamtvarianz erfaßt.

OFOUNT	SUDAN
NUMBER OF PIXELS/LINE: 252	NUMBER OF PIXELS/LINE: 792
NUMBER OF RANDOM PIXELS/LINE: 5	NUMBER OF RANDOM PIXELS/LINE: 3
LINE-INTERVAL: 1 TO 90	LINE-INTERVAL: 1 TO 150
COLUMN INTERVAL: 1 TO 252	COLUMN INTERVAL: 1 TO 600
NUMBER OF VARIABLES: 4	NUMBER OF VARIABLES: 4
NUMBER OF POINTS: 450	NUMBER OF POINTS: 450
MEAN VECTOR:	MEAN VECTOR:
43.5	51.2
51.2	62.0
46.3	57.0
19.0	23.4
VARIANCE-COVARIANCE-MATRIX	VARIANCE-COVARIANCE-MATRIX
66.032 99.085 95.580 39.951	104.629 163.008 157.085 65.093
99.085 155.164 148.661 62.778	163.008 259.604 248.321 103.045
95.580 148.661 146.392 61.093	157.085 248.321 243.020 99.481
39.951 62.778 61.093 26.597	65.093 103.045 99.481 41.823
CORRELATION MATRIX	CORRELATION MATRIX
1.000 0.979 0.972 0.953	1.000 0.989 0.985 0.984
0.979 1.000 0.986 0.977	0.989 1.000 0.989 0.989
0.972 0.986 1.000 0.979	0.985 0.989 1.000 0.987
0.953 0.977 0.979 1.000	0.984 0.989 0.987 1.000
EIGEN-VALUES OF COVARIANCE-MATRIX:	EIGEN-VALUES OF COVARIANCE-MATRIX:
388.856 2.742 1.781 0.806	643.787 2.968 1.620 0.701
COLUMNS = EIGEN-VECTORS	COLUMNS = EIGEN-VECTORS
0.406 -0.753 0.471 0.217	0.400 -0.259 0.875 -0.083
0.630 -0.180 -0.708 -0.266	0.633 -0.574 -0.478 -0.202
0.611 0.566 0.494 -0.251	0.612 0.776 -0.063 -0.136
0.257 0.285 -0.184 0.905	0.253 -0.033 -0.034 0.966

Abb. 29: Korrelationsmatrizen und Eigenvektoren von 450 zufällig gewählten Remissionsvektoren aus dem Tibesti und Sudan. Besonders auffällig ist die Obereinstimmung der beiden ersten Eigenvektoren.

Abb. 30 stellt Ausschnitte aus zwei Landsat-Szenen aus dem ariden und gemäßigten Klimabereich gegenüber (Tarso er Toon und Inntal, jeweils Kanäle 4 und 6). Während die Bilder aus dem Tibesti-Gebirge kaum Helligkeitsunterschiede aufweisen, zeigen sich bei den Bildern aus dem Alpenraum deutliche Unterschiede im Spektralverhalten verschiedener Oberflächen - bis hin zu entgegengesetztem Reflexionsverhalten benachbarter Flächen, d. h. eine hell-dunkel-Grenze in Kanal 4 kann zur dunkel-hell-Grenze im anderen Kanal werden (besonders deutlich bei den Wasserflächen und den landwirtschaftlich genutzten Gebieten im oberen Teil des Bildes).

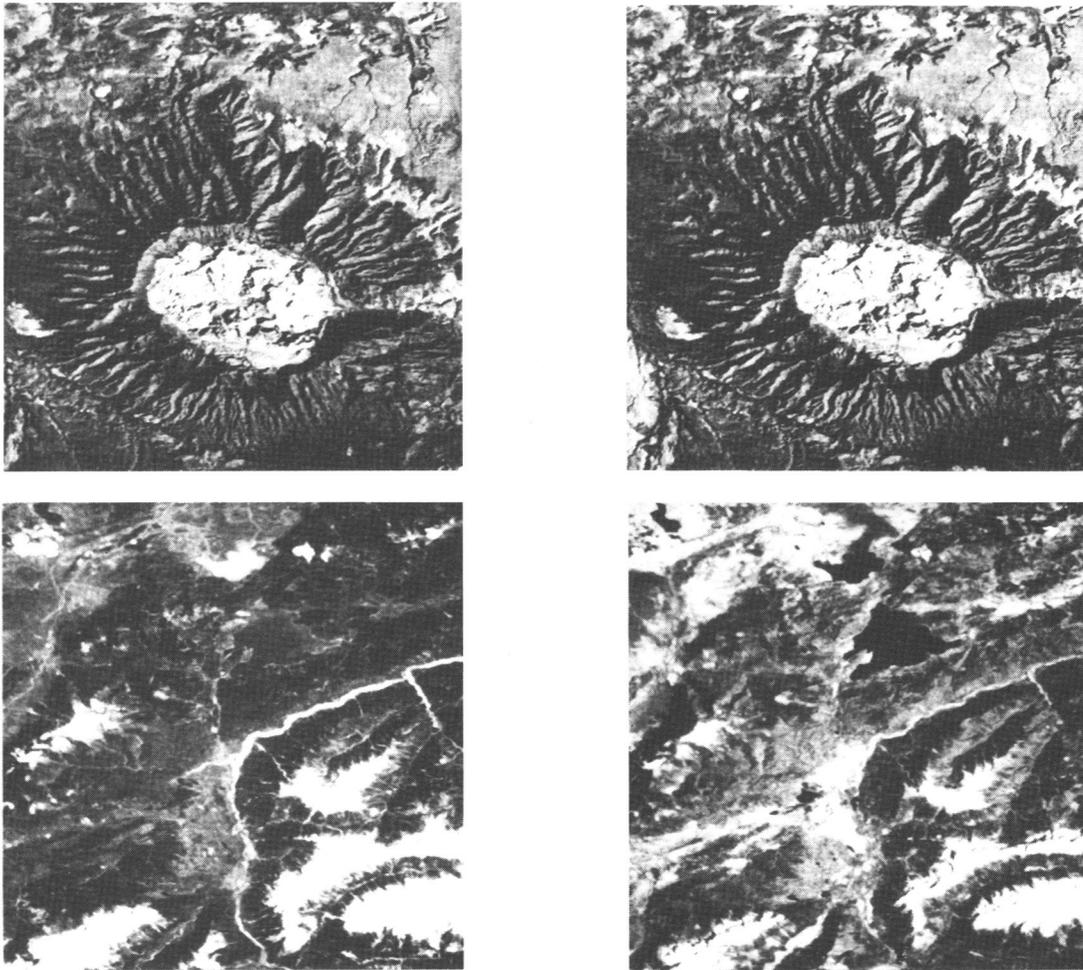


Abb. 30: Vergleich der Spektralkanäle 4 und 6 zweier Landsat-Subszenen aus dem ariden (Tarso er Toon, oben) und gemäßigten Klimabereich (Umgebung Inntal, unten).

Führt man diese Analysen in anderen Teilen des Untersuchungsgebietes durch, so ergeben sich nahezu dieselben Ergebnisse; insbesondere scheint der erste Eigenvektor für den gesamten Sahara-Raum relativ konstant zu sein, wenn nur Festgesteinsoberflächen bei der Pixel-Auswahl erfaßt werden.

Abweichungen von diesem Verhalten weisen auf Vegetationsbedeckung hin: wenn z. B. Teile des Niltals von einer Landsat-Szene erfaßt werden, treten neben der linearen Punktwolke deutlich separiert Cluster auf, die von Wasserflächen und landwirtschaftlich genutzten Flächen herrühren. Aber auch wenn große Sandflächen erfaßt werden, verändern sich die Scattergramme: die langgestreckten Punktwolken (vgl. Abb. 24 und 25) verbreitern sich, es treten Punkthäufungen auf. Darin zeigen sich die in Kap. 3.2 festgestellten Unterschiede im Reflexionsverhalten der Sande.

Die hohe Redundanz der Spektralkanäle bewirkt, daß die Gesteinsoberflächen vor allem durch ihre Helligkeitswerte unterschieden werden, während Farbunterschiede praktisch keine Rolle spielen. Sind die Grautonwerte zweier Gesteinseinheiten nahezu gleich, so müssen Bildoperationen durchgeführt werden, die geringe Unterschiede im Spektralverhalten verstärken und dadurch eine Klassifizierung ermöglichen.

3.4 Spezielle Untersuchungsmethoden

Betrachtet man die Scattergramme des letzten Kapitels, so ergeben sich für die Trennung verschiedener Gesteinseinheiten folgende Modellvorstellungen:

- a) die Gruppen unterscheiden sich aufgrund ihrer Grautonmittelwerte, wobei unterschiedliches Spektralverhalten praktisch keine Rolle spielt;
- b) die Grautonmittelwerte der Gruppen unterscheiden sich nicht signifikant, es gibt jedoch deutliche Unterschiede im Spektralverhalten.

(vgl. Abb. 31).

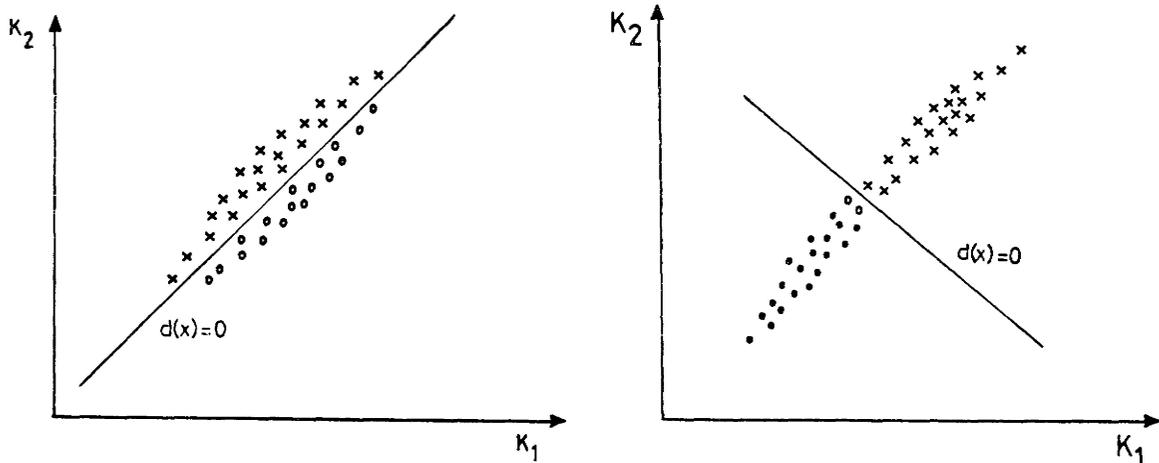


Abb. 31: Modellvorstellungen für die Verteilung der Grautonwerte verschiedener Gesteinsoberflächen.

In der Realität werden beide Modelle gemischt auftreten, d. h. es gibt Oberflächen, die man aufgrund des ersten Modells trennen kann, das im wesentlichen die "Gesamthelligkeit" erfaßt, und andere Oberflächen, die man mit Hilfe des zweiten Modells trennen kann, das die "Farbunterschiede" beschreibt.

Da sich in den Scattergrammen (Abb. 24 / 25) keine deutlichen Häufungen von Punkten ergeben, muß angenommen werden, daß sich die Punktwolken der verschiedenen Gruppen stark überlappen, so daß eine Maximum-Likelihood-Methode bei der Klassifizierung notwendig ist.

3.4.1 Die Hauptachsentransformation

Verwendet man die Matrix der Eigenvektoren zur Transformation des Multispektralbildes, so bedeutet das geometrisch eine Drehung des Koordinatensystems in die Hauptachsen des durch die Korrelationsmatrix (oder der Varianz-Kovarianzmatrix) beschriebenen Hyperellipsoids.

Die erste Hauptkomponente ergibt sich aus dem ersten Eigenvektor (vgl. Anh. 3)

$$(3.4.1.1) \quad \underline{v}_1^i = (0.40, 0.63, 0.61, 0.25),$$

der bei nahezu allen Landsat-Szenen, die nur Gesteinsoberflächen erfassen, erscheint. Die Transformation

$$(3.4.1.2) \quad \underline{g} = \underline{v}_1^i \cdot \underline{g},$$

wobei \underline{g} den Merkmalsvektor der 4 Landsat-Reflexionswerte darstellt, ist eine gewichtete Summe dieser Werte und stellt praktisch ein gewöhnliches Schwarz/Weiß-Photo der Erdoberfläche dar, erweitert um die Information des Nahen Infrarot-Bereichs. Durch die Summation der vier Landsat-Kanäle ergibt sich eine Verbesserung des Signal/Rauschen-Verhältnisses und damit eine bessere Bildqualität. Die erste Hauptkomponente beschreibt im wesentlichen den Faktor "Gesamthelligkeit", während die anderen Eigenvektoren die Restvarianz erfassen, d. h. die "Farbunterschiede".

Im Gegensatz zum ersten Eigenvektor sind die übrigen Eigenvektoren in allen untersuchten Gebieten verschie-

den, so daß keine einfache Interpretation möglich ist. Auch der Informationsgehalt ist sehr gering, so daß der dritte Eigenvektor als Transformationsvektor praktisch nur noch den Rauschanteil des Signals liefert (ebenso der vierte Eigenvektor). Abb. 32 zeigt die ersten drei Hauptkomponenten einer PCT. Besonders auffällig ist die Nachzeichnung des Reliefs in der zweiten Hauptkomponente, die im statistischen Sinn unabhängig von der ersten ist.

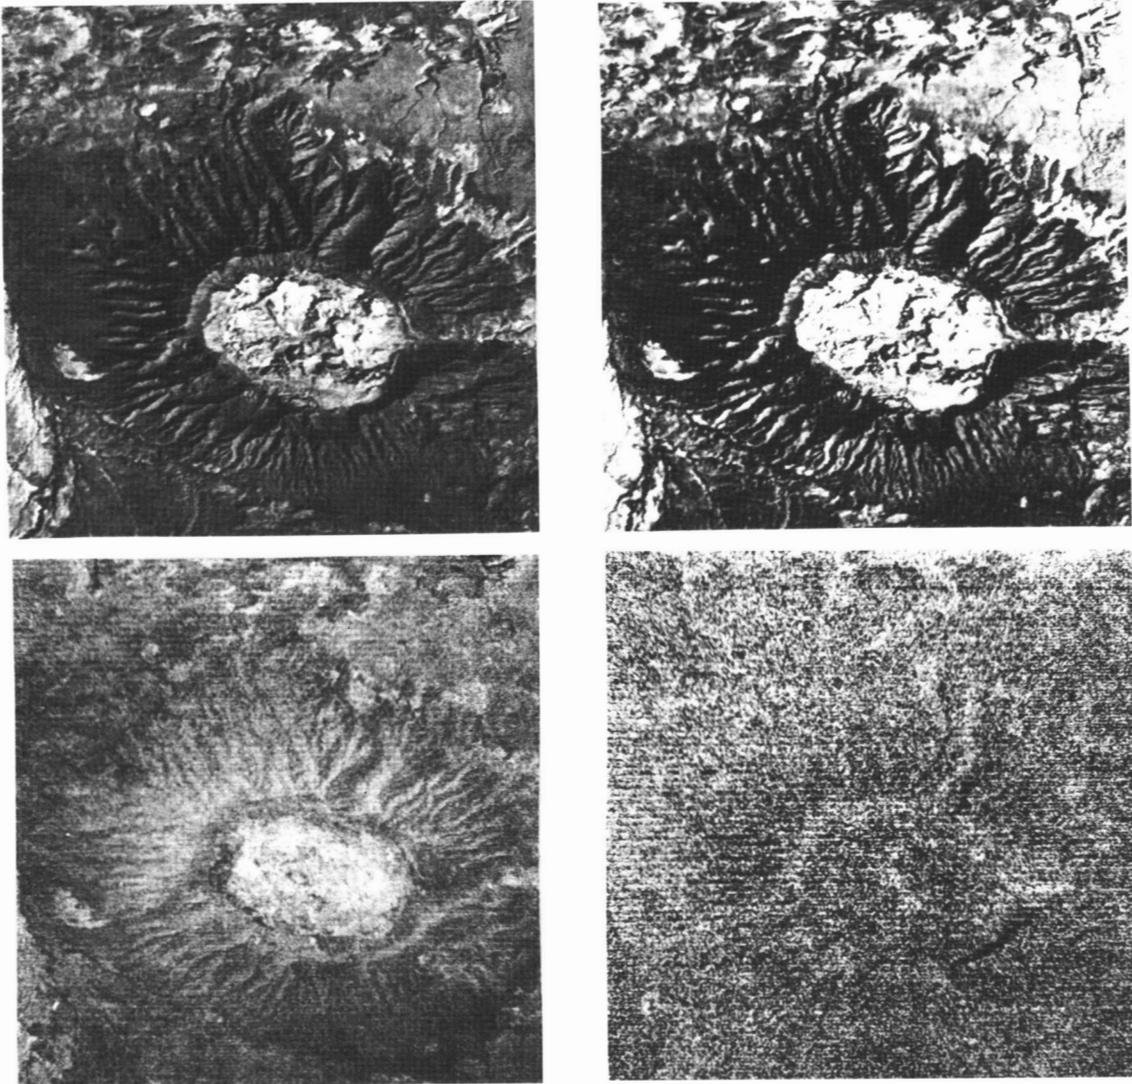


Abb. 32: Hauptachsentransformation einer Landsat-Szene aus dem Tibesti (Tarso er Toon). Oben links: Kanal 6; oben rechts: 1. Hauptkomponente; unten links: 2. Hauptkomponente; unten rechts: 3. Hauptkomponente.

Die dritte und vierte Hauptkomponente verdeutlichen besonders den Scaneffekt, der durch die unterschiedliche Kalibrierung der Detektoren zustande kommt. Bei der Klassifizierung des Bildes kann man sich somit auf die beiden ersten Hauptkomponenten als Merkmalswerte beschränken und erhält eine Reduktion der Dimension des Merkmalsraums von 4 auf 2. Die Merkmalswerte sind statistisch unabhängig und repräsentieren die "Gesamthelligkeit" und die "Farbunterschiede" der Gesteinsoberfläche in den 4 Landsat-Spektralkanälen.

3.4.2 Quotientenbilder

Wegen der hohen Korrelationen der Landsat-Spektralkanäle bietet sich bei geologischen Fragestellungen ne-

ben der Hauptkomponententransformation die Quotientenbildung zwischen zwei Kanälen als besonders einfache Bildtransformation an, um Abweichungen vom linearen Zusammenhang (kurz: "Farb"-Unterschiede) zu erfassen. Die Quotienten- (oder Ratio-) Bildung hat auch den Vorteil, daß Auswirkungen des Reliefs auf die Reflexion gemindert werden, weil der Einfluß der Hangneigung bei allen Spektralkanälen praktisch in gleicher Weise (multiplikativ) wirkt.

Geht man vom LAMBERT'schen Modell der Reflexion aus, so ergibt sich für die am Scanner empfangene Strahlungsleistung $L(\lambda)$:

$$(3.4.2.1) \quad L(\lambda) = S \cdot E(\lambda) \cdot \tau(\lambda) \cdot \rho(\lambda) / \pi + L_p(\lambda),$$

wobei S = Beleuchtungsfaktor ($0 < S < 1$), unabhängig von
 $E(\lambda)$ = remittierte Strahlung an der Erdoberfläche
 $\tau(\lambda)$ = Durchlässigkeit der Atmosphäre
 $\rho(\lambda)$ = Remissionskoeffizient des Objekts
 $L_p(\lambda)$ = Streustrahlung auf dem Weg durch die Atmosphäre

(THOMSON & SADOWSKI 1975). Die Streustrahlung $L_p(\lambda)$ ist für kurzwelliges Licht größer als für langwelliges, d. h. sie ist in Kanal 4 am größten, in Kanal 7 zu vernachlässigen, wie die Erfahrung zeigt. Bei der Quotientenbildung macht sich der Term $L_p(\lambda)$ störend bemerkbar, da er vom Relief unabhängig ist. VINCENT (1977) hat vorgeschlagen, diesen Term dadurch abzuschätzen, daß man Schattenhänge im Bild sucht, wo $S=0$ gilt und somit $L(\lambda) = L_p(\lambda)$. Das Bild wird normiert, indem der Grautonwert solcher Schattenobjekte von jedem Grautonwert des Bildes subtrahiert wird.

Eine Schwierigkeit bei diesem Verfahren liegt darin, daß im Satellitenbild (im Gegensatz zum Luftbild) meist nicht zu erkennen ist, ob ein Objekt völlig im Schatten liegt oder nicht.

Bildet man ein Quotientenbild aus zwei Spektralkanälen, so werden die Schatteneffekte nicht unterdrückt, wenn das Streulicht nicht vollständig eliminiert wurde. Selbst bei einer vollständigen linearen Abhängigkeit zwischen den Merkmalen x und y

$$(3.4.2.1) \quad y = bx + a$$

bildet der additive Term a bei der Quotientenbildung einen Störfaktor, der bewirkt, daß der Quotient y/x nicht konstant ist, wie man aus

$$(3.4.2.2) \quad \frac{y}{x} = b + \frac{a}{x} \quad (x \neq 0)$$

sofort erkennt. Betrachtet man die Farbunterschiede als Abweichungen von der Linearität, so kann man die Regressionsrechnung benutzen, um den additiven Term zu schätzen. Die hierzu notwendigen arithmetischen Ausdrücke erhält man bei der Korrelationsanalyse der Daten ohnehin: die Steigung der Regressionsgeraden ("Regressionskoeffizient") ergibt sich zu

$$(3.4.2.3) \quad b = s_{xy} / s_x^2$$

und der additive Term zu

$$(3.4.2.4) \quad a = \bar{y} - b\bar{x},$$

wobei \bar{y} , \bar{x} die Mittelwerte, s_{xy} die Kovarianz und s_x^2 die Varianz der beiden Variablen darstellen.

Wendet man diese Methode auf die Spektralkanäle 4 und 7 einer Landsat-Szene aus dem Sahara-Raum an, so ergeben sich für den additiven Term $L_p(\lambda)$ Werte um 15, bei der Kombination Kanal 5 und 7 Werte um 7. (Dabei ist davon ausgegangen, daß der Streulichtanteil in Kanal 7 praktisch null ist). Wird der additive Term von allen Grautonwerten in Kanal 4 subtrahiert, so erhält man nach der Quotientenbildung ein Bild mit einer Grautonverteilung, deren Varianz minimal wird.

Die Standardabweichung der Quotientenbilder im Untersuchungsgebiet liegt im Bereich 2 - 3 Grautonstufen.

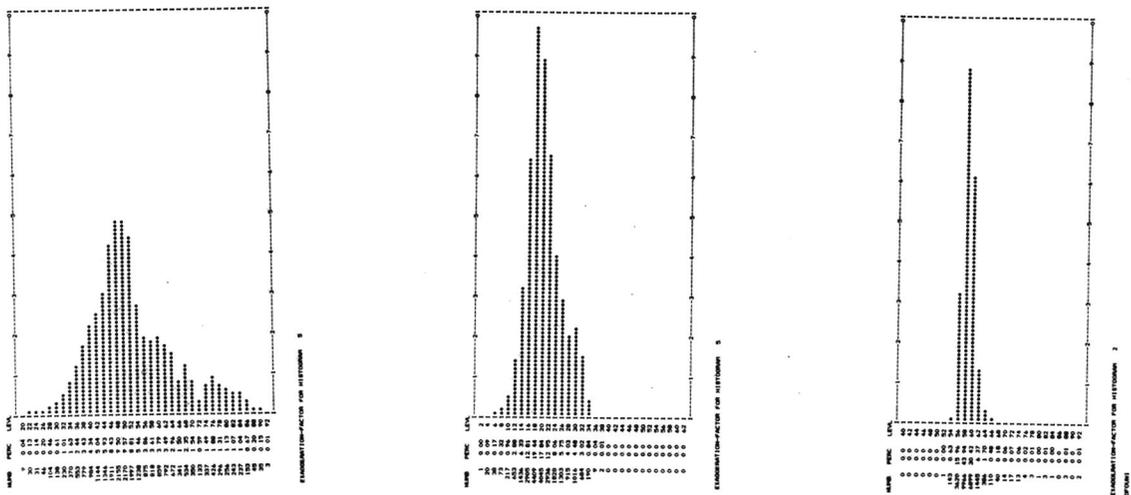


Abb. 33: Häufigkeitsverteilung der Grautonwerte in den Kanälen 5 und 7 (links). Daneben die Grautonverteilung des Quotientenbildes (gespreizt mit Faktor 10).

Der Bildkontrast muß deshalb wesentlich verstärkt werden, um Grautonunterschiede in verschiedenen Bildflächen erkennen zu können. Abb. 33 zeigt, wie eng die Grautonverteilung bei der Quotientenbildung durch die hohe Korrelation wird, obwohl die Ausgangsverteilungen wesentlich breiter sind.

Führt man die Quotientenbildung nach einer Normierung der Grautonverteilung mit Hilfe der "Schattenmethode" und der "Regressionsmethode" durch, so zeigt sich bei der letzteren eine deutliche Unterdrückung des Reliefs (vgl. Abb. 34). Die Grautonwerte in den Schattengebieten des Bildes liegen bei 22 in Kanal 4, bei 15 in Kanal 5.

Deutlich zeigen sich die "Farb"-Unterschiede (i. o. erwähnten Sinne) zweier Metamorphiteinheiten in einer anderen Szene, die nach der Regressionsmethode normiert wurde (Abb. 35).

Auch hier ist das Relief fast vollständig unterdrückt. Die Metamorphite ("Mongo-Schiefer") sind in eine streifige und eine grobtexturierte Einheit gegliedert, die als breites Band diagonal durch das Bild zieht und im Quotientenbild deutlich dunkler erscheint. Eine Untersuchung der Grautonmittelwerte und Streuungen beider Einheiten zeigt, daß wegen der starken Überlappungen der Grautonverteilungen eine Trennung mit Hilfe der Grautonunterschiede im Originalbild nicht möglich ist. Das Auge trennt beide Einheiten somit aufgrund der verschiedenen Oberflächentexturen. Die "Farb"-Unterschiede, die im Quotientenbild als Helligkeitsunterschiede erscheinen, bestätigen diese Differenzierung auf wesentlich andere Weise.

Umgekehrt erscheinen die Sande in Kanal 7 mit deutlichen Helligkeitsunterschieden, die im Quotientenbild völlig verschwinden, während das anstehende Gestein sich deutlich durch dunklere Grautöne abhebt. Bei der engen Grautonverteilung von Quotientenbildern (Streuung 2 bis 3) ist die hohe Auflösungsfähigkeit für Grautonunterschiede durch den Schnelldrucker von Vorteil. Abb. 36 zeigt die Grautonsimulation einer Landsat-Subszene östlich von Ofouni (Tschad). Die dunkle Diagonale, die von SSW nach NNE streicht, stellt eine Störung dar, die Metamorphite (links) und Reste von Basaltdecken von Sandsteinen (rechts) trennt. Da sich die Grautonverteilungen wegen des starken Reliefs fast vollständig überlappen, wäre eine Trennung der Einheiten nur mit Hilfe aufwendiger Klassifizierungsprogramme möglich. Die Ratio-Bildung $K5/K7$ zeigt jedoch eine deutliche Trennung im Druckerbild.

Die Quotientenbilder liefern somit nach einer Eliminierung des Streulichtanteils durch die "Regressionsmethode" eine einfache Möglichkeit, zusätzliche Information über Gesteinsoberflächen zu erhalten und bei einer Klassifizierung zu verwenden.

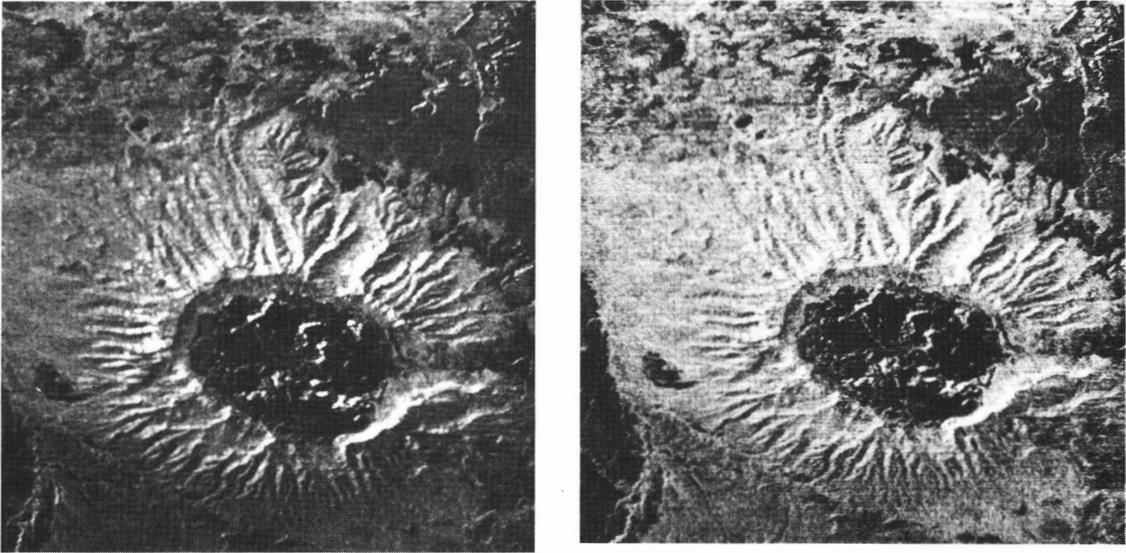


Abb. 34: Quotientenbilder nach Eliminierung des Streulichts mit Hilfe der "Schattenmethode" (links) und der "Regressionsmethode" (rechts).

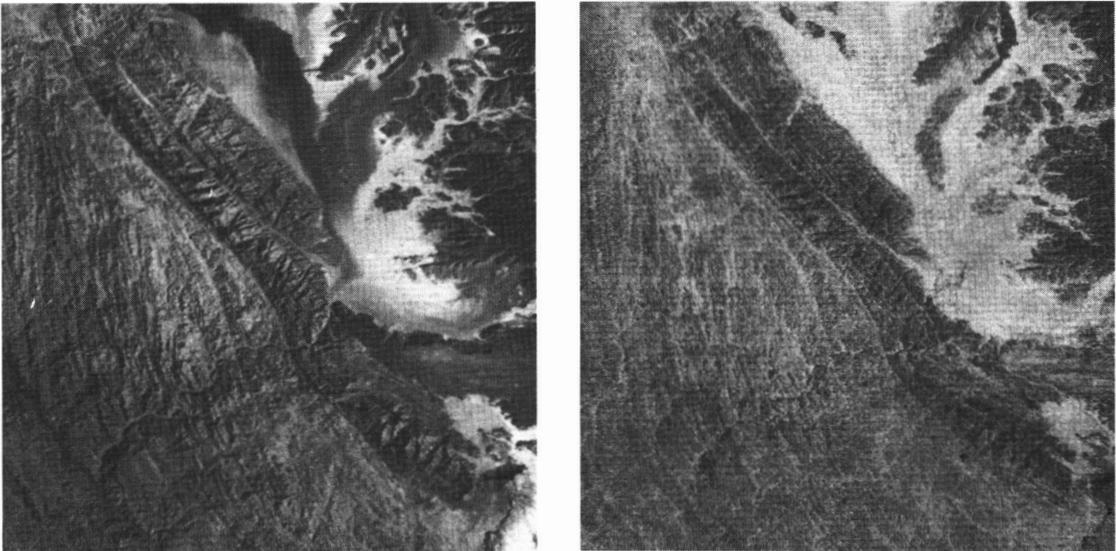


Abb. 35: Verstärkung der "Farb"-Unterschiede durch Quotientenbildung. Links Spektralkanal 7 einer Landsat-Subszene (E-119o - o8433), rechts das Quotientenbild K5/K7.

3.5 Schlußfolgerungen

Die Analyse der Signaturen von Landsat-Szenen im Sahara-Raum ergibt, daß die verwendeten Spektralkanäle bei Gesteinsoberflächen hoch redundante Information liefern. Eine bessere Differenzierung von Gesteinseinheiten aufgrund unterschiedlichen Spektralverhaltens scheint im Infrarotbereich gegeben.

Laborversuche machten deutlich (LYON 1970), daß im thermalen Infrarot von 7 - 15 μm die wichtigsten gesteinsbildenden Minerale scharfe Absorptionslinien zeigen. Gesteine, die aus diesen Mineralien aufgebaut sind, haben entsprechend breitere Absorptionsbänder in den entsprechenden Spektralbereichen, z. B. Granit zwischen 8.5 und 9.5 μm , Basalt bei 10.1 μm .

Ein großer Anteil des thermalen Spektrums kommt für Satellitenaufnahmen nicht in Frage, da die Atmosphäre nur in bestimmten "Fenstern" einen Blick auf die Erdoberfläche erlaubt (im wesentlichen der Bereich von 8.2 bis 9.6 μm und von 10.2 bis 12.8 μm ; letzteren Thermal Kanal hat Skylab für Aufnahmen benutzt). Die anderen Thermalbereiche sind durch Absorptionsbänder von Gasen (z. B. H_2O von 6 bis 8 μm , CO_2 von 4.5 bis 5.0 μm , Ozon von 9.6 bis 10.2 μm) für Scanneraufnahmen von Satelliten aus nicht geeignet.

Im mittleren Infrarot ist für geologische Anwendungen der Bereich von 2.3 bis 2.5 μm interessant, der vor allem Feuchtigkeitsunterschiede erfaßt und für Karbonate starke Absorptionsbänder zeigt (HUNT & SALISBURY 1971).

Für künftige Satellitenmissionen ergeben sich zur Verbesserung der geologischen Interpretierbarkeit folgende Forderungen:

- a) stärkere Auflösung der Spektralkanäle im sichtbaren Bereich, um die Farbunterschiede der Gesteine, wie sie bei der Geländeaufnahme erfaßt werden, für eine Identifizierung aus Satellitenaufnahmen nutzbar zu machen;
- b) Einsatz von Sensoren im thermalen Infrarot, wobei vor allem die Bereiche 2.3 - 2.5 μm , 8.2 - 9.6 μm und 10.2 - 12.8 μm infrage kommen.

Solange diese zusätzlichen Informationen nicht zur Verfügung stehen, müssen verfeinerte Algorithmen herangezogen werden, um aus dem vorhandenen Datenmaterial ein Maximum an geologischer Information zu erhalten.

Die Untersuchungen dieses Kapitels zeigten, daß folgende Merkmale für eine Differenzierung von Gesteinseinheiten am besten geeignet sind:

1. Die Linearkombination der vier Spektralkanäle, wobei der erste Eigenvektor der PCT als Gewichtsvektor verwendet wird (vgl. (3.4.I.2)). Dieser Merkmalswert erfaßt die Helligkeitsunterschiede der verschiedenen Gesteinseinheiten.
2. Die Transformation mit dem zweiten Eigenvektor oder die Verwendung verschiedener Quotienten aus je zwei Spektralkanälen, um die Farbunterschiede der Gesteine zu erfassen.

Eine völlig andere Methode der Differenzierung von Gesteinseinheiten mit Hilfe von Fernerkundungsdaten kann oft im gemäßigten Klimabereich angewendet werden: der Wechsel der Morphologie und der Vegetationsbedeckung ermöglicht es, unter bestimmten Bedingungen Rückschlüsse auf die unterliegenden Gesteinseinheiten zu ziehen. Als Beispiel sei hier die "Murnauer Mulde" erwähnt (vgl. Abb. 30 links oben bzw. Abb. 18), wo der Wald sehr genau das Gebiet der steil stehenden Molasse-Sandsteine bedeckt, während landwirtschaftlich genutzte Flächen auf den pleistozänen Terrassen und Moränen angelegt sind.

Für die Prospektion nach mineralischen Rohstoffen ist von besonderer Bedeutung, daß bei bestimmten Metallkonzentrationen die Böden bzw. die Pflanzendecke spektrale Anomalien aufweisen (BALLEW 1975; LYON 1975; VINCENT 1977). Abb. 37 zeigt ein Beispiel für eine Anomalie in einem sonst gleichförmig mit Urwald bedeckten Gebiet Neu-Guineas. D. HELMCKE (Berlin) verdanke ich den Hinweis, daß in dieser Gegend bedeutende Kupfervorkommen nachgewiesen sind. Die Kontrolle der geographischen Lage der Anomalie zeigt, daß sie genau die porphyrische Kupferlagerstätte Frieda River abdeckt (PAGE & McDOUGALL 1972). Bei der Beschreibung

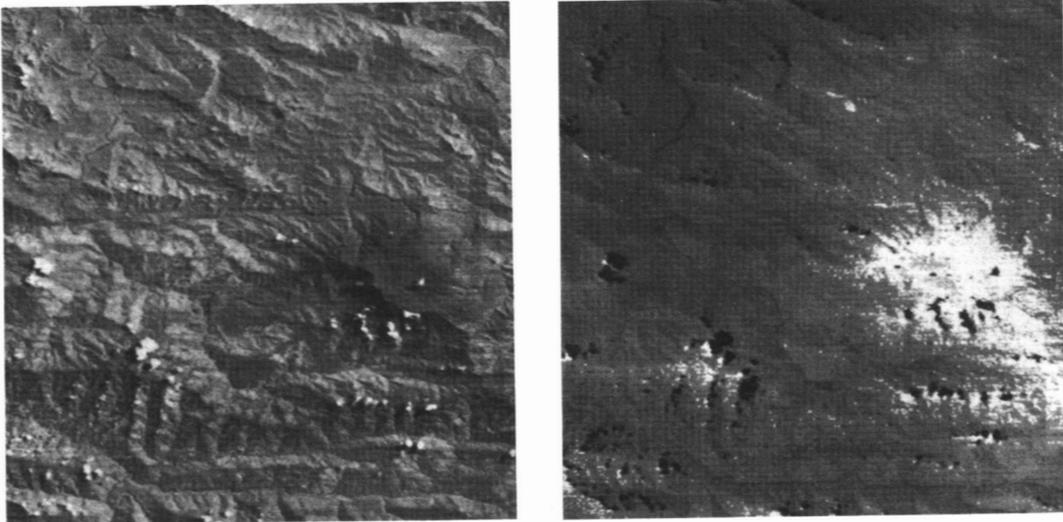


Abb. 37: Spektrale Anomalie im tropischen Regenwald von Papua-Neuguinea. Links: Kanal 6, rechts: Ver-
deutlichung der Anomalie durch eine Helligkeitskontur.

einer Lagerstätte gleichen Typs, die ca. 100 km weiter südlich liegt (BAMFORD 1972), weist der Verfasser darauf hin, daß der tropische Regenwald über der Lagerstätte deutlich niedrigeren Wuchs zeigt, als die Umgebung. Inwieweit hierfür die Permeabilität der Gesteine, anderes Erosionsverhalten oder Kontaminierung der Pflanzen durch angereicherte Metallionen im Boden verantwortlich gemacht werden kann, ist in diesem Zusammenhang von untergeordneter Bedeutung. Leider ist diese Lagerstätte auf der untersuchten Landsat-Szene von Wolken bedeckt, so daß ein unmittelbarer Vergleich des Spektralverhaltens nicht möglich ist. Um die spektrale Anomalie der Vegetationsdecke oder morphologische Unterschiede für eine geologische Interpretation nutzbar zu machen, ist eine gute Lokalkennntnis notwendig, sowie eine detaillierte Untersuchung des Zusammenhangs zwischen Morphologie, Pflanzendecke, Klima und lithologischen Einheiten in verschiedenen Gebieten.

Die Extrapolation von bekannten auf unbekannte Gebiete ist immer mit Fehlern behaftet, die durch ergänzende Untersuchungsmethoden reduziert werden müssen.

4. TEXTURPARAMETER VON GESTEINSOBERFLÄCHEN AUF LANDSAT-SZENEN DES SAHARA-RAUMES

4.1 Bildtexturen von Gesteinsoberflächen

Bei einer Luft- oder Satellitenbildinterpretation benutzt der Geologe neben den Grautonunterschieden vor allem die texturellen Charakteristika zur Identifizierung verschiedener Gesteinseinheiten. Über die Wahrnehmung und Erkennung von Texturen ist, wie schon erwähnt, nur wenig bekannt. Ein wichtiger Aspekt bei diesem Prozeß scheint jedoch das Erkennen eines lokalen Musters zu sein, das durch seine Wiederholung den Eindruck der Regelmäßigkeit hervorruft. Zur qualitativen Beschreibung der Bildtexturen werden Begriffe wie

- | | |
|-------------|-----------------|
| - grob/fein | - gegittert |
| - streifig | - flaserig |
| - fleckig | - homogen |
| - körnig | - kontrastreich |

etc. verwendet. Diese Begriffe machen im Gegensatz zu anderen (z. B. klüftig, gebankt, geschiefert etc.) keine Aussage über die Genese der Textur, die oft aus dem Luft- oder Satellitenbild nicht mit Sicherheit

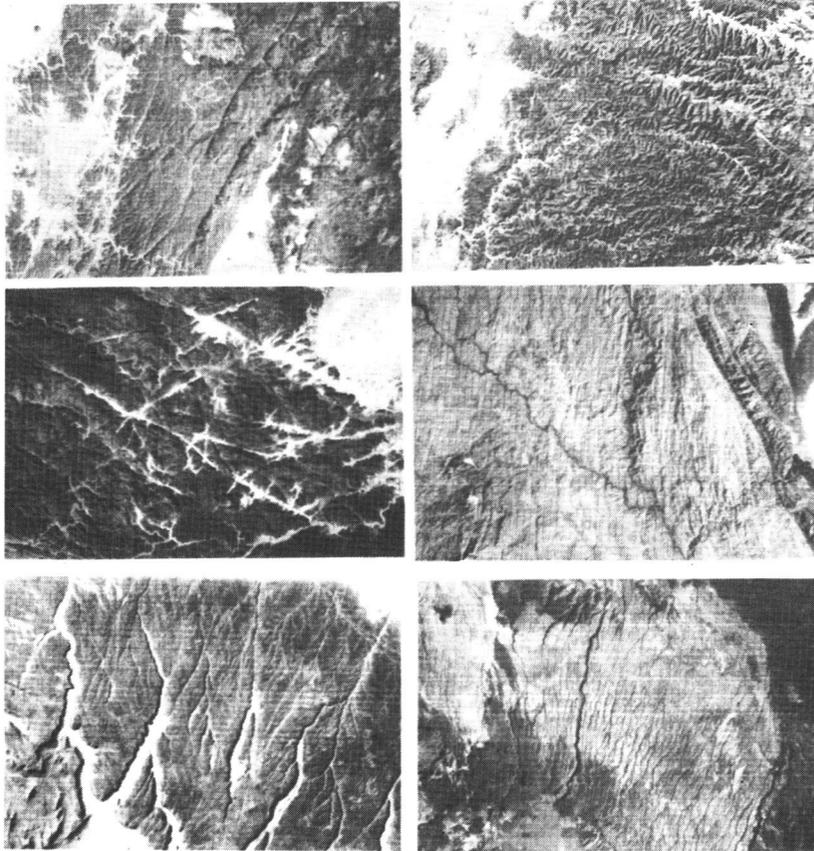


Abb. 38: Typische Bildtexturen von Gesteinsoberflächen auf Landsat-Szenen des Tibesti (Vulkanite, Sandsteine, Metamorphite, Granit).

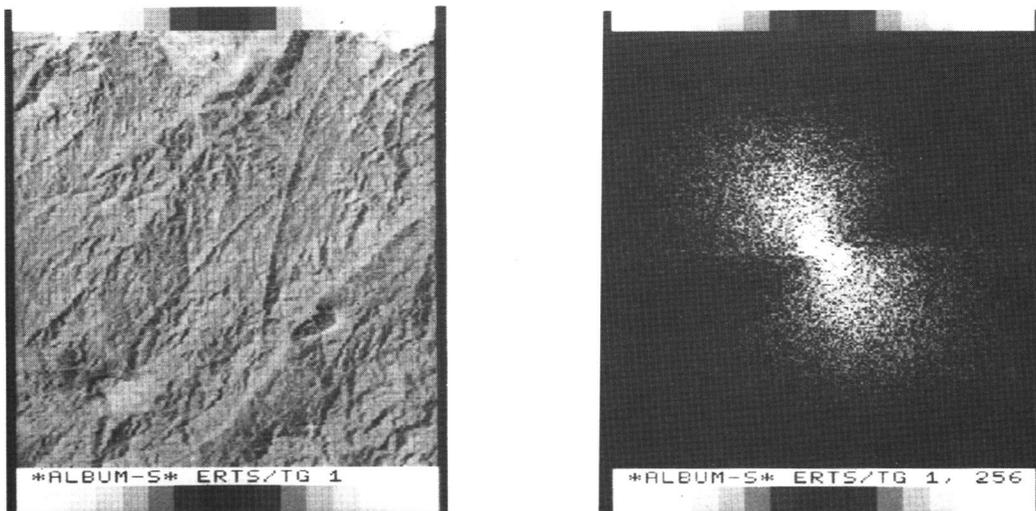


Abb. 39: Ausschnitt aus einer Landsat-Szene (E 1209 - 08491, links) im Tibesti-Gebirge und zugehöriges Leistungs-Spektrum (rechts). Die NE-streichenden Texturelemente bewirken eine um 90° gedrehte Richtungsanisotropie der Helligkeitsmaxima im Frequenzbereich.

erkannt werden kann.

Die Erscheinungsform einer Gesteinstextur im Bild hängt sehr stark vom Bildmaßstab ab, bzw. vom Auflösungsvermögen des Aufnahmesystems. Je nach Bildmaßstab sind es auch verschiedene physikalische Prozesse, die das Erscheinungsbild einer Textur bestimmen.

Im Luftbild sind es vor allem die Auswirkungen von kleintektonischen Prozessen wie Klüftung und Schieferung, Sedimentationsprozessen wie Bankung und schließlich Verwitterungsprozessen wie Wollsackverwitterung bei Graniten oder Verkarstung bei Kalken, die eine charakteristische Textur entstehen lassen.

Im Satellitenbild sind es entsprechend dem Bildmaßstab vor allem die Auswirkungen großtektonischer Prozesse, die das Erscheinungsbild einer Oberflächentextur prägen:

- Faltung von Gesteinskomplexen
- große Störungssysteme
- Erosionsprozesse
- vulkanologische Prozesse.

Abb. 38 zeigt typische Gesteinstexturen aus Landsat-Szenen des Tibesti, die in anderen Gebieten der Sahara in nahezu gleicher Ausprägung auftreten.

Die Abhängigkeit der Texturausprägung von Bildmaßstab, Beleuchtungsverhältnissen, klimatischen Gegebenheiten etc. macht die Entwicklung einer physikalischen Theorie, wie sie für die spektrale Remission bereits existiert, sehr kompliziert. Ziel der Signaturerkennung ist die Identifizierung von Oberflächen aufgrund ihres Spektralverhaltens. In ähnlicher Weise kann man das Ziel der Texturanalyse definieren:

Identifizierung von (endogenen und exogenen) geologischen Prozessen mit Hilfe der Bildtexturen verschiedener Aufnahmesysteme.

Der erste Schritt auf dem Weg zu diesem Ziel ist die quantitative Beschreibung von Bildtexturen natürlicher Gesteinsoberflächen. Ein weiterer Schritt in diese Richtung ist die Modellierung von Bilddaten in Abhängigkeit von Relief, Gesteinsart und Aufnahmebedingungen. Hierzu ist die Erstellung eines digitalen Geländemodells notwendig, das neben den Höhenwerten Angaben über die spektralen Remissionseigenschaften enthält. Durch Modifikationen des Modells und Vergleiche mit tatsächlichen Landsat-Aufnahmen ist es möglich, den Einfluß verschiedener Faktoren auf die Entstehung der Bilddaten zu untersuchen.

4.2 Quantitative Erfassung von Texturen

4.2.1 Bisherige Arbeiten auf dem Gebiet der Texturerkennung

Um eine automatische Klassifizierung von Bildtexturen durchzuführen, müssen die qualitativen Texturmerkmale (vgl. Kap. 4.1) quantitativ erfaßt werden. Zur quantitativen Texturbeschreibung sind im wesentlichen folgende Methoden untersucht worden:

- lokale Grauwertstatistik
- Berechnung von "Nachbarschafts-Beziehungen"
- Analyse globaler Bildtransformationen (Power-Spektrum und andere Orthogonalentwicklungen).

Bei der lokalen Grauwertstatistik werden die statistischen Parameter der Grautonwerte in einer Umgebung U_{ij} des Pixels g_{ij} als Texturparameter verwendet:

- Mittelwert m
- Streuung
- Schiefe
- Kurtosis

- Variationskoeffizient m/σ
- Perzentilwerte
- Modalwerte.

Ein Nachteil dieser Parameter liegt darin, daß die räumlichen Beziehungen der Grautonwerte in U_{ij} nicht erfaßt werden (Abb. 40).

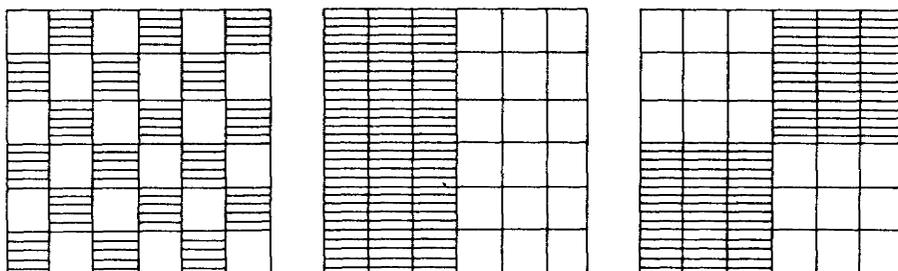


Abb. 40: Verschiedene Umgebungsmuster eines Bildpunktes, die dieselben statistischen Parameter aufweisen (bei zwei Grautonstufen).

Diese "Nachbarschaftsbeziehungen" werden durch andere Methoden erfaßt. HARALICK entwickelte hierzu "Nachbarschafts-Matrizen" (HARALICK 1971; HARALICK et al. 1973; HARALICK 1978), in denen die Anordnung benachbarter Grautonwerte erfaßt wird. Dabei wird gezählt, wie oft bestimmte Paare von Grautonwerten g_i, g_j in einer gerichteten Distanz vom Zentralpixel vorkommen und diese Häufigkeit wird in der entsprechenden Matrix abgespeichert. Für jede Richtung und jede Distanz erhält man auf diese Weise eine Matrix mit t^2 Elementen, wobei t die Anzahl der Grautonstufen im Bild bezeichnet. HARALICK hat eine Anzahl von Texturparametern angegeben, die aus diesen Matrizen gewonnen werden können. Obwohl er diese Parameter mit den in der Bildverarbeitung üblichen Bezeichnungen wie Kontrast, Korrelation etc. versieht, erfassen sie eher abstrakte Matrixeigenschaften als bekannte qualitative Texturmerkmale.

Das gilt auch für eine ähnliche Methode, bei der die Verteilung der "run"-Längen, d. h. der Längen längs einer Geraden, in der keine oder nur eine geringe Änderung des Grautonwertes erfolgt, bestimmt wird (GALLOWAY 1974). Die Länge und Anzahl der "runs" wird in Matrizen eingetragen, aus denen wiederum numerische Texturmerkmale extrahiert werden.

Beschränkt man globale Bildtransformationen auf die Umgebung eines Pixels, so erhält man ebenfalls Texturparameter (WESZKA et al. 1976; FIEDLER 1979). Ausgangspunkt dieser Methode ist die Fourier-Transformation, die Cosinus-Transformation oder andere Orthonormal-Entwicklungen der Bildfunktion. Meist werden die Parameter aus dem Leistungs-Spektrum (power spectrum) extrahiert: ist $g(x,y)$ der Grautonwert im Punkt (x,y) , so berechnet sich die Fourier-Transformation durch

$$(4.2.1.1) \quad G(u,v) = \iint g(x,y) e^{2\pi i(ux+vy)} dx dy ,$$

und das Leistungs-Spektrum aus

$$(4.2.1.2) \quad |G(u,v)|^2 = G(u,v) \cdot G^*(u,v) ,$$

wobei $i = \sqrt{-1}$ und G^* den konjugiert komplexen Wert von G bezeichnet.

Bei einer "feinkörnigen" Textur befinden sich die hohen Werte des Leistungs-Spektrums im Gebiet hoher Ortsfrequenzen, bei einer "groben" Textur dicht beim Ursprung des Ortsfrequenzbereichs. Ist eine Textur in einer bestimmten Richtung orientiert, so zeigt sich eine entsprechende Anisotropie im Leistungs-Spektrum (Abb. 39).

Aus diesen Eigenschaften lassen sich verschiedene Texturparameter ableiten, die invariant gegenüber Drehungen der Textur im Ortsbereich sind, z. B. "Ringsummen" von G im Abstand r vom Ursprung:

$$(4.2.1.3) \quad RS(r) = \int_0^{2\pi} |G(u,v)|^2 d \quad ,$$

oder die die Richtungsabhängigkeit der Textur erfassen, z. B. durch Integration über bestimmte Richtungssektoren ("wedge sampling"):

$$(4.2.1.4) \quad RA(\phi) = \int_0^{\infty} |G(u,v)|^2 dr \quad .$$

Zur praktischen Durchführung dieser Rechnungen verwendet man spezielle schnelle Algorithmen (z. B. die FFT: Fast Fourier Transformation), die bestimmte Umgebungen erfordern ($2^n \times 2^n$ Bildpunkte bei der FFT, $n \leq N$).

Eine ausführliche Untersuchung der verschiedenen Methoden hat eine Projektgruppe unter Leitung von P. HARTL (TU Berlin) durchgeführt (HARTL et al. 1978). Dabei zeigte sich, daß es nicht möglich ist, Texturphänomene durch einzelne Parameter zu beschreiben. Praktisch gibt es bisher keine Untersuchungen, um festzustellen, welche Methode der Parameterextraktion für bestimmte Aufgabenstellungen optimal ist. Die bisherigen Untersuchungen (HARTL et al. 1978; HARALICK 1971; FIEDLER 1979) an natürlichen Texturen (z. B. Bilder von Korbgeflechten, Stoffmustern etc., vgl. BRODATZ (1966)) und Bilddaten (z. B. aus dem "Flugzeugmeßprogramm") zeigen, daß alle o. a. Methoden eine Unterscheidung verschiedener Texturen erlauben, wobei die Fehlerquoten bei der Zuordnung in der Größenordnung von 10 - 35 % liegen.

In den folgenden Kapiteln (4.3 bis 4.5) wird untersucht, inwieweit solche (und einige neue) Parameter geeignet sind, Texturen von Gesteinsoberflächen in den Landsat-Szenen des Untersuchungsgebietes zu beschreiben. Dabei kann man sich auf einen Spektralkanal beschränken, da in diesem Spezialfall alle Landsat-Kanäle im wesentlichen dieselbe Information - also auch Textur - enthalten.

4.2.2 Elementarzelle und Bestimmungsfläche

Bildtextur ist eine lokale Eigenschaft des Bildes und dementsprechend müssen die Parameter zu ihrer Beschreibung die Umgebung eines Bildpunktes berücksichtigen. Ausgangspunkt der Berechnungen ist eine 3×3 -Umgebung von Punkten - die Elementarzelle (Abb. 41). Sie erfaßt Punkteigenschaften, wobei durch die Einbeziehung der unmittelbaren Nachbarpunkte das Verhältnis Signal/Rauschen verbessert wird. Einige Eigenschaften eines Bildpunktes (z. B. Grenzpunkt zwischen zwei Flächen oder "Homogenitäts-Punkt" zu sein) werden durch 3 bis 4 Parameter aus der Elementarzelle beschrieben.

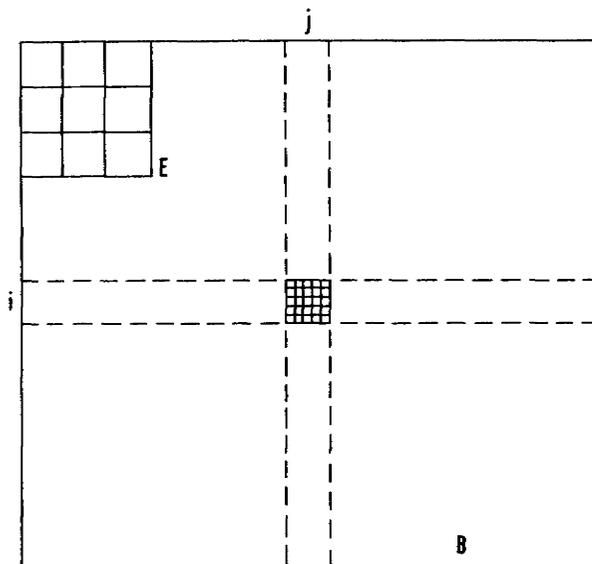


Abb. 41: Elementarzelle E und Bestimmungsfläche B zur Extrahierung von Texturparametern. E wird zeilenweise über B verschoben; die berechneten Parameter gelten für den Zentralpunkt (i,j).

Eine Textur wird erfaßt, indem die Elementarzelle über eine "repräsentative" Fläche, die Bestimmungsfläche, geschoben und die Parameter der Elementarzelle in jeder Position berechnet und abgespeichert bzw. aufsummiert werden (Abb. 41).

Bemerkung: Die Begriffe "Elementarzelle" und "Bestimmungsfläche" stammen von FIEDLER (1979), die Methode der Parameterextraktion geht m. W. auf TRIENDL (1973) zurück.

4.2.3 Parameter der Elementarzelle

4.2.3.1 Kontrast

Beim Kontrast unterscheidet man den globalen Kontrast (Bildkontrast), der durch die Streuung der Grautonverteilung des Gesamtbildes beschrieben werden kann, und dem Punktkontrast, der sich auf ein einzelnes Pixel und seine Umgebung bezieht. HARALICK (1973) gibt in seinem Stichwortkatalog zur Mustererkennung verschiedene Kontrastmaße an, wobei stets der Grautonwert g_p des Pixels mit den Grautonwerten seiner Umgebung verglichen wird:

$$(4.2.3.1) \quad KTV = \frac{g_p}{g_u} \quad (\text{Kontrastverhältnis})$$

$$(4.2.3.2) \quad KTD = |g_p - g_u| \quad (\text{Kontrastdifferenz})$$

$$(4.2.3.3) \quad KTR = \frac{|g_p - g_u|}{g_p + g_u} \quad (\text{Kontrastmodul})$$

(g_u bezeichnet den mittleren Grautonwert der Umgebung des Pixels). Liegt ein Pixel in einer homogenen Fläche, so wird $KTV = 1$, während die anderen beiden Kontrastmaße den Wert 0 annehmen. Das Maß KTD hat den Nachteil, daß es von der absoluten Größe des Grautonwertes abhängt, während die anderen Maße der Tatsache Rechnung tragen, daß bei hellen Flächen die Grauwertdifferenz größer sein muß als bei dunkleren, um als gleich kontrastreich vom Auge wahrgenommen zu werden.

Bei der Berechnung der Texturparameter der Elementarzelle wurde stets KTR als Kontrastmaß verwendet, g_u als Mittelwert der acht umgebenden Punkte des Zentralpixels.

4.2.3.2 Der Gradient

Betrachtet man das Bild des R^2 in den R^1 , so kann man die Bildmenge als Raumfläche auffassen und entsprechend beschreiben. Dabei faßt man die diskreten Grautonwerte als Stützwerte einer Fläche auf, die wenigstens zweimal stetig differenzierbar ist: zur lokalen Beschreibung der Fläche $g(x,y)$ können die Ableitungen gewählt werden. Der Gradientenvektor $G = (g_x, g_y)$ gibt dabei die Richtung und Größe des maximalen Gefälles in einem Punkt (x,y) an. Da die Richtung des Gradientenvektors besonders stark von den Beleuchtungsverhältnissen während der Aufnahme abhängt, ist zur Beschreibung einer Textur der Betrag des Gradienten GRB besser geeignet:

$$(4.2.3.4) \quad GRB = \sqrt{g_x^2 + g_y^2}.$$

Aus der Numerischen Mathematik sind verschiedene Diskretisierungen des Gradientenoperators bekannt. Im Bereich der Bildverarbeitung werden diese Differenzenoperatoren weiter vereinfacht, indem man anstelle der Wurzeln und Quadrate die (computerfreundlichen) Absolutbeträge der Differenzen der Grautonwerte verwendet. Der ROBERTS-Gradient RGR ist das bekannteste diskrete Äquivalent des Gradienten:

$$(4.2.3.5) \quad RGR = \max(|g_{i,j} - g_{i+1,j+1}|, |g_{i+1,j} - g_{i,j+1}|)$$

(ROSENFELD & KAK 1976). Diese Form hat bei Scanneraufnahmen den Nachteil, daß die x- und y-Richtung nicht unabhängig voneinander sind: die Grauwertvariation in Zeilenrichtung ist fast immer kleiner als in der Richtung senkrecht dazu. In der Form (4.2.3.5) wird somit vorzugsweise die Grauwertvariation senkrecht zu den Scanlinien erfaßt.

Aus diesem Grunde bietet sich eine symmetrische Form des diskreten Gradienten an (NIEMANN 1974):

$$\begin{aligned}
 (4.2.3.6) \quad GX &= g_{i+1,j+1} - g_{i-1,j-1} + 2(g_{i+1,j} - g_{i-1,j}) + \\
 &\quad + g_{i+1,j+1} - g_{i-1,j+1} \\
 GY &= g_{i-1,j+1} - g_{i+1,j-1} + 2(g_{i,j+1} - g_{i,j-1}) + \\
 &\quad + g_{i+1,j+1} - g_{i-1,j-1} .
 \end{aligned}$$

Der Betrag des Gradienten kann nun durch

$$(4.2.3.7) \quad GXY = |GX| + |GY|$$

approximiert werden. Eine vereinfachte Form, die die x- und y-Richtung gleichwertig erfaßt, erhält man durch

$$\begin{aligned}
 (4.2.3.8) \quad LX &= g_{i+1,j} - g_{i,j} \\
 LY &= g_{i,j+1} - g_{i,j} \\
 LXY &= |LX| + |LY| .
 \end{aligned}$$

Eine Korrelationsanalyse der verschiedenen Gradientenformen ergab folgende Werte (Tab. 2):

	GRB	LXY	GXY
GRB	1	.85	.92
LXY		1	.98
GXY			1

Tab. 2: Korrelationskoeffizienten bei verschiedenen Formen des diskreten Gradienten.

Berechnet man den Gradienten in verschiedenen Spektralkanälen, so ergeben sich ähnlich hohe Korrelationen wie bei den Signaturen (Tab. 3).

	4	5	6	7
4	1	.91	.89	.92
5		1	.92	.91
6			1	.89
7				1

Tab. 3: Korrelationskoeffizienten für GRB in verschiedenen Spektralkanälen.

4.2.3.3 Der LAPLACE-Operator

Durch die zweite Ableitung in einem Punkt wird die Krümmung der Fläche gemessen. Aus der mathematischen Definition des Laplace-Operators

$$(4.2.3.9) \quad \Delta = \frac{\delta^2 g}{\delta x^2} + \frac{\delta^2 g}{\delta y^2}$$

ergeben sich wiederum verschiedene Möglichkeiten der diskreten Approximation. Die zur Berechnung des Gradienten verwendeten Grauwertdifferenzen d_i ($i = 1, \dots, 8$) zu den acht Nachbarn können auch zur Bestimmung des diskreten Laplace-Wertes herangezogen werden:

$$(4.2.3.10) \quad LPL = d_1 + \dots + d_8 .$$

Sind die 9 Punkte der Elementarzelle Stützwerte einer Ebene, so nimmt LPL den Wert 0 an. Ist die Fläche konkav gewölbt, so wird LPL positiv, ist sie konvex, so wird LPL negativ.

4.2.4 Parameter der Bestimmungsfläche

Ausgangspunkt der Analyse von Texturen ist die Modellvorstellung, daß sich durch die Wiederholung einer Elementartextur ein charakteristisches Muster bildet, das vom Auge als Textur wahrgenommen wird. Die Elementartextur ergibt sich auf der niedrigsten Stufe durch den Grautonwert der Pixel. Auf einer nächsten

Stufe durch die Verteilung der Grautonwerte in einer Elementarzelle; die Anordnung verschiedener Elementarzellen in der Bestimmungsfläche beschreibt Texturen auf der nächsthöheren Stufe. Dieser hierarchische Aufbau eines Texturmodells entspricht den Problemen der Fernerkundung sehr gut, da hier entsprechend der Bildauflösung verschiedene Texturebenen eines Objekts wahrgenommen werden.

Zur Beschreibung einer Textur ist deshalb die Berechnung von Parametern aus den verschiedenen Ebenen der Wahrnehmung notwendig:

1. Erfassung des Grautonwerts eines Bildpunktes
2. Quantitative Beschreibung der Elementarzellen
3. Untersuchung der Anordnung von Elementarzellen
4. Zusammensetzung von komplexeren Texturen etc.

Zur Beschreibung und Analyse von komplexeren Texturen (d. h. über der Ebene der Bestimmungsfläche) gibt es kaum Untersuchungen (FOITH 1977). Bei der praktischen Texturanalyse ergeben sich folgende Probleme:

- welche Parameter sind zur Texturbeschreibung ausreichend;
- wie erfaßt man die Anordnung der Elementarzellen;
- welche Minimalfläche reicht als Bestimmungsfläche?

Da es bisher keine theoretischen Ansätze zur Lösung dieser Probleme gibt, ist es notwendig heuristisch vorzugehen, um die Texturinformation eines Bildes für Anwendungen nutzbar zu machen.

Die Größe der Bestimmungsfläche kann prinzipiell mit varianzanalytischen Methoden bestimmt werden: liegt eine Texturfläche vor, so darf sich die Varianz der extrahierten Parameter innerhalb der Bestimmungsfläche (V_1) nicht signifikant von der Varianz der Parameter zwischen verschiedenen Bestimmungsflächen (V_2) in der Texturfläche unterscheiden, d. h.

$$(4.2.4.1) \quad V_2/V_1 \approx 1 .$$

Ist die Bestimmungsfläche zu klein, so wird der Quotient V_2/V_1 deutlich größer als 1. Da die Größe der Bestimmungsfläche verschiedener Texturen im allgemeinen ebenfalls verschieden ist, wurde in der vorliegenden Arbeit die Bestimmungsfläche einheitlich so groß gewählt, daß bei einer Klassifizierung die Fehlerrate eine bestimmte Schwelle (10 %) nicht überschreitet. In analoger Weise wird eine Auswahl der Parameter getroffen: es werden diejenigen Parameter ausgewählt, die bei der Diskriminanzanalyse den größten Beitrag zur Trennung verschiedener Klassen liefern.

Zur Untersuchung der Gesteinstexturen in den Landsat-Szenen wurden folgende Parameter aus der Bestimmungsfläche B extrahiert (wobei die ersten drei Texturebenen - im Sinne von FOITH (1977) - durch wenigstens einen Parameter erfaßt werden):

- MW: Mittelwert der Grautonverteilung in B
- ST: Streuung der Grautonverteilung in B
- GRM: Mittelwert des Gradientenbetrags GXY bei Verschiebung der Elementarzelle E über B
- GRS: Streuung von GXY in B
- LPM: Summe über die Absolutbeträge von LPL
- HOM: Summe über die Absolutbeträge der Differenzen d_i ($i = 1, \dots, 8$) von E
- NX: Anzahl der Vorzeichenwechsel von GX in B
- NY: Anzahl der Vorzeichenwechsel von GY in B
- SLX: Streuung von GX in B
- SLY: Streuung von GY in B
- KTM: Mittelwert des Kontrasts KTR in B
- AX1: Autokorrelation in x-Richtung (Schrittweite 1)
- AY1: Autokorrelation in y-Richtung (Schrittweite 1)
- AXY: Autokorrelation in 45° -Richtung.

Von diesen Parametern erfaßt MM die mittlere Helligkeit von B, GRM, LPM und HOM beschreiben die Verteilung der Grautonwerte in der Elementarzelle E, ST und GRS die statistische Verteilung dieser Parameter in B und die letzten Parameter die räumliche Anordnung ("Nachbarschaftsbeziehungen") der Grautonwerte in der Bestimmungsfläche B.

4.3 Trennungsgüte der Parameter

4.3.1 Beschreibung der Trainingsgebiete

Zur Untersuchung der Texturparameter wurden für dieses Kapitel vier charakteristische Gesteinstexturen aus Landsat-Szenen ausgewählt:

- Ignimbrit
- Sandstein, stark zertalt
- Granit
- Metamorphit

(vgl. Abb. 38). Die Testszenen enthalten ca. 150 Zeilen und 250 Spalten. Ergänzend wurden zwei Bilder künstlich erzeugt, um die Parameter der natürlichen Texturen mit theoretisch vorhersehbaren Werten vergleichen zu können. Das erste Bild besteht aus Zufallszahlen, die nach $N(64, 16)$ verteilt sind. Das zweite Bild wurde mit Hilfe eines autokorrelativen Prozesses erzeugt, wobei die Grautonwerte einer Bildzeile aus den Grautonwerten der vorangegangenen Zeile nach dem Schema

$$(4.3.1.1) \quad g_{i,j+1} = \alpha g_{i,j} + \gamma(g_{i-1,j} + g_{i+1,j}) + e_{i,j}$$

berechnet werden und die Bedingung $\alpha + 2\gamma < 1$ erfüllt ist. $e_{i,j}$ stellt eine Folge von unkorrelierten Fehlern dar, die den Erwartungswert 0 und die Streuung 1 hat (Abb. 42).

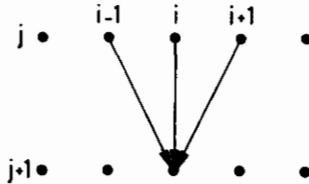


Abb. 42: Schema des Autokorrelationsprozesses.

Die Autokorrelationsfunktion eines solchen Prozesses kann mit Hilfe von Rekursionsformeln berechnet werden (BESAG 1972), ebenso die anderen Parameter der so erzeugten Textur. Dieses Bild wurde ebenso wie die anderen Bilder auf Mittelwert 64 und Streuung 16 normiert: hat das Ausgangsbild den Mittelwert m und die Streuung s , so ergibt die Normierungsgleichung

$$(4.3.1.2) \quad g_t = \frac{g - m}{s} \cdot 16 + 64,$$

wobei g_t den transformierten Grauwert von g bezeichnet. Die Parameter α und γ bestimmen den Autokorrelationsprozeß (4.3.1.1) vollständig. Für $\alpha = \gamma = 0$ erhält man die Verteilung $N(0, 1)$, die mit Gleichung (4.3.1.2) auf $N(64, 16)$ transformiert werden kann. Dieses Testgebiet wird nachfolgend mit N 6416 bezeichnet. Das zweite Testgebiet dieser Art ist A5C2, das mit $\alpha = 0.5$ und $\gamma = 0.2$ gewonnen wurde (Abb. 44). Während das Gebiet N 6416 nur "white noise" enthält, ist A5C2 deutlich strukturiert. Mit Hilfe stochastischer Prozesse kann untersucht werden, inwieweit derartige Prozesse geeignet sind, natürliche Bildtexturen zu simulieren, um hieraus Rückschlüsse auf diejenigen Prozesse zu ziehen, die das Erscheinungsbild einer Oberflächentextur im Satellitenbild prägen (Verwitterung etc., vgl. Kap. 4.1). Es zeigt sich, daß einfache Autokorrelations-Schemata der Form (4.3.1.1) deutliche Unterschiede zu natürlichen Bildtexturen zeigen. Eine Verbesserung der Simulation von Texturen kann erreicht werden, indem eine deterministische

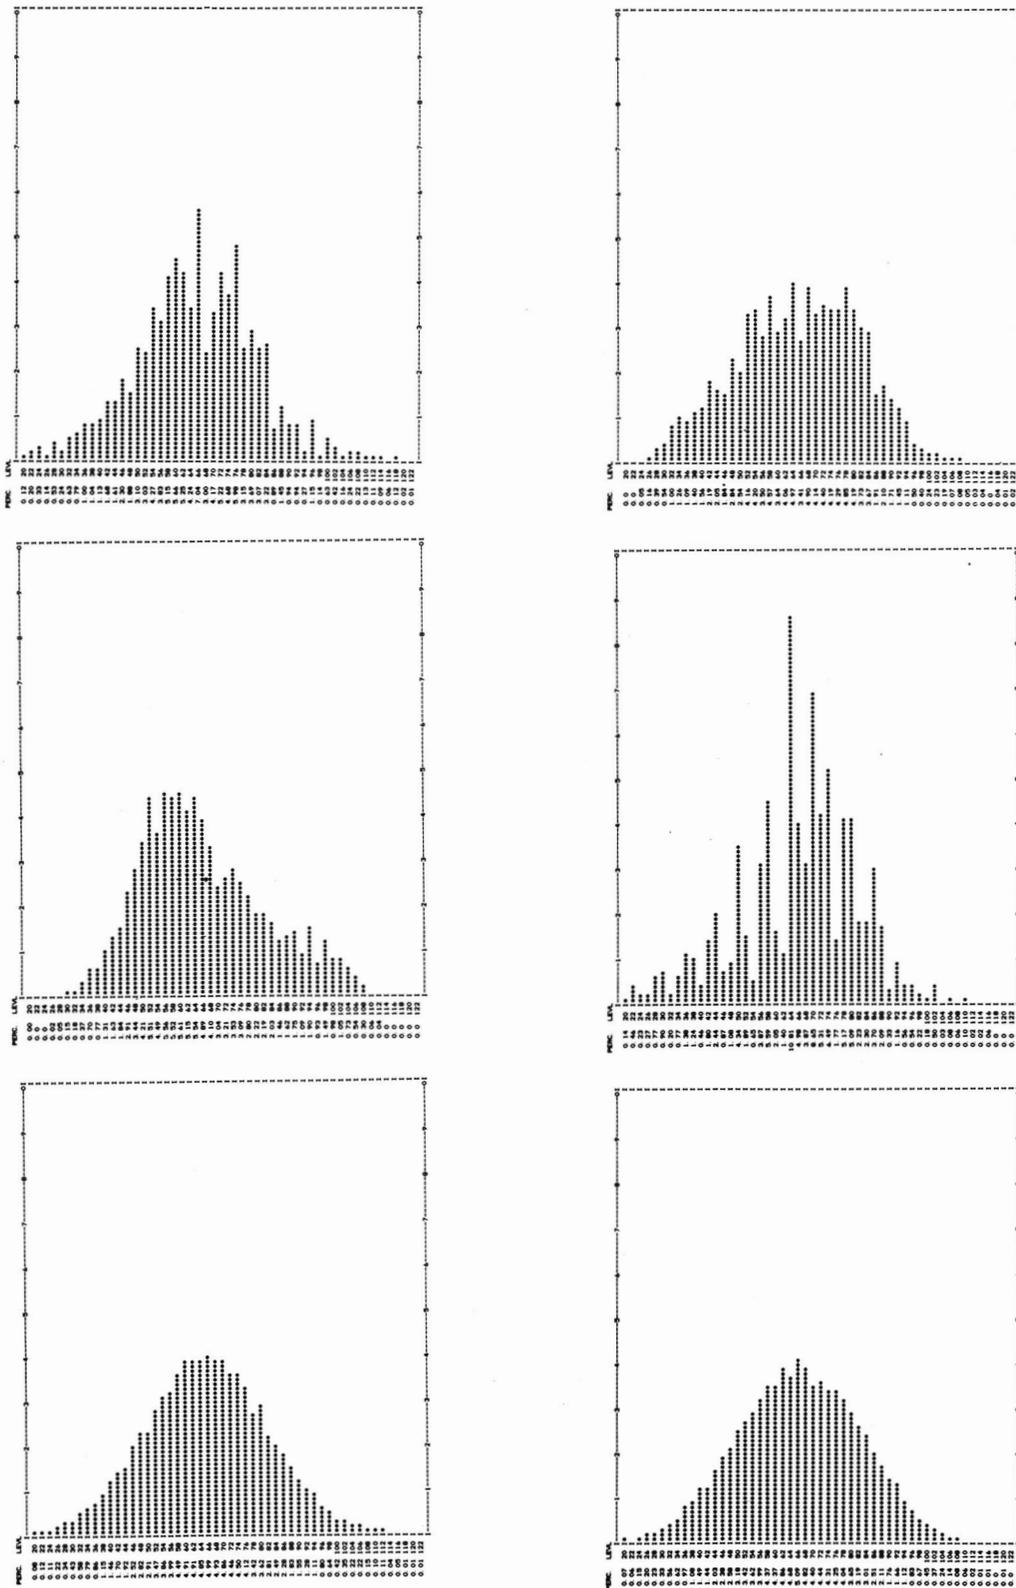


Abb. 43: Häufigkeitsverteilungen der Graftonwerte der sechs Testgebiete normiert auf $m = 64$, $s = 16$. Von links oben nach rechts unten: Ignimbrit, Sandstein, Granit, Metamorphit, Zufallsverteilung $N(64, 16)$, Autoregressionsmodell.

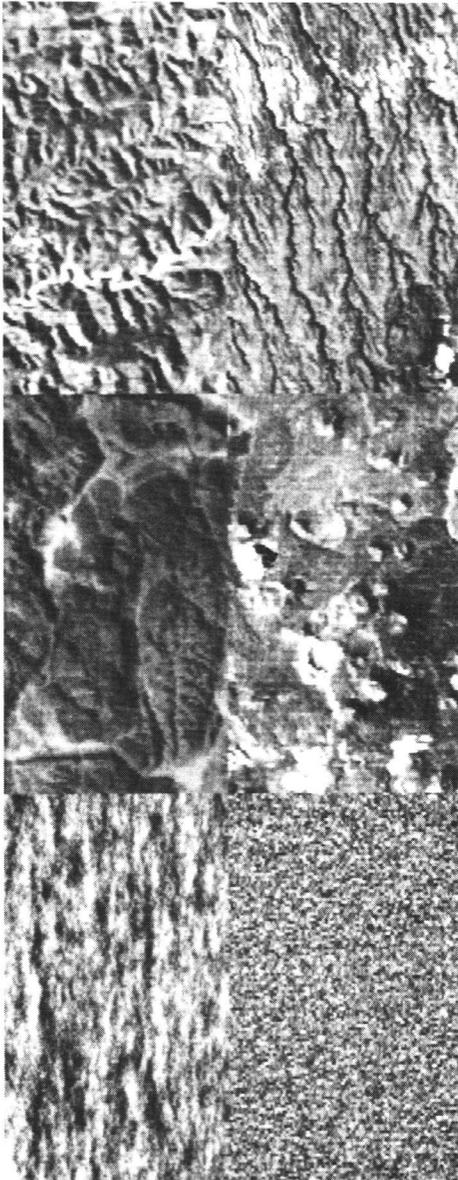


Abb. 44: Darstellung der Textur-Testgebiete:
a) Sandstein, b) Ignimbrit, c) Granit,
d) Basalt, e) N 6416, f) A5C2.

Komponente durch entsprechende Algorithmen eingeführt wird (z. B. Simulation eines Entwässerungsnetzes nach LEOPOLD & LANGBEIN (1962); SCHEIDEGGER (1970)).

Zur Untersuchung der Texturparameter sind Texturen, die durch stochastische Prozesse erzeugt werden, besser geeignet als synthetische Texturen, da bei letzteren die statistischen Parameter der Elementarzelle bzw. der Bestimmungsfläche formelmäßig nur schwer zu erfassen sind. Die Testgebiete N 6416 und A6C2 dienen dazu

- nach Normierung auf $N(64, 16^2)$ die abgeleiteten Texturparameter mit denen der natürlichen Texturen zu vergleichen;
- die mit dem Computer berechneten Texturparameter mit den theoretische erwarteten Werten zu kontrollieren.

Letzteres ist möglich, da die meisten in dieser Arbeit verwendeten Texturparameter auf der Bildung von Summen von Grautondifferenzen benachbarter Pixel beruht (z. B. HOM, GRM, LXY, LPL, SXY) und Mittelwert,

Streuung und Autokorrelationsfunktion der Bildpunkte der durch den Prozeß (4.3.1.1) erzeugten Bilder bekannt sind.

Exemplarisch sei dies für die diskrete Form des Gradientenbetrags

$$(4.2.3.8) \quad L_{XY} = |L_X| + |L_Y|$$

gezeigt. Betrachtet man N 6416, so kann jeder Bildpunkt als Zufallsvariable betrachtet werden, die nach $N(64, 16)$ verteilt und mit den Nachbarnpunkten unkorreliert ist. Sei $L_X = g_{i,j+1} - g_{i,j}$, so gilt nach Anh. 4, Lemma 1

$$(4.3.1.3) \quad E[L_X] = 0$$

und

$$(4.3.1.4) \quad E[L_X^2] = \sigma_{L_X}^2 = 2 \cdot \sigma^2,$$

d. h. für die Streuung der Grautondifferenz folgt hieraus $\sigma_{L_X} = \sqrt{2} \sigma$, wobei σ die Streuung der Punktvariablen bezeichnet. Für $|L_X|$ ergibt sich nach Anh. 4, Satz 3

$$(4.3.1.5) \quad E[|L_X|] = \sqrt{\frac{2}{\pi}} \cdot \sigma_{L_X} = 32/\sqrt{\pi} \approx 18.05$$

und

$$(4.3.1.6) \quad \sigma_{|L_X|} = \sqrt{2} \sigma = \sqrt{2} \cdot 16 \approx 22.63.$$

Diese Werte stimmen sehr gut mit den im Programm errechneten Parametern $\mu_{L_X}^* = 17.88$ und $\sigma_{L_X}^* = 22.27$ überein. Für den Gradientenbetrag L_{XY} ergibt sich

$$(4.3.1.7) \quad E[L_{XY}] = E[|L_X|] + E[|L_Y|] = 64/\sqrt{\pi}.$$

Eine analoge Rechnung ergibt für den Texturparameter

$$(4.3.1.8) \quad HOM = \sum_{i=1}^8 |d_i|,$$

wobei über die Grautondifferenzen der 8 umgebenden Nachbarnpunkte summiert wird

$$(4.3.1.9) \quad E[HOM] = 8\sqrt{\frac{2}{\pi}} \cdot \sigma_{L_X} = 256/\sqrt{\pi} \approx 144.43,$$

gegenüber dem Stichprobenwert 145.30!

Da die statistischen Parameter von Summen und Differenzen korrelierter Zufallsvariablen bekannt sind (vgl. Anh. 4, Satz 2), können entsprechende Formeln für alle Bilder abgeleitet werden, die durch Autokorrelationsprozesse der Form (4.3.1.1) erzeugt werden.

4.3.2 Diskriminanzanalyse bei zwei Gruppen

Das Problem der Trennung von zwei Klassen (oder Gruppen) tritt in der Bildverarbeitung sehr häufig auf: Unterscheidung von Wald/Nicht-Wald, vegetationsbedeckte Flächen von vegetationslosen, Sande von anstehendem Gestein etc.

Trennt man zwei Klassen mittels einer linearen Diskriminanzfunktion

$$(4.3.2.1) \quad d_{1,2}(\underline{x}) = w_1 x_1 + \dots + w_m x_m + w_{m+1},$$

so können die Gewichte w_j ($j = 1, \dots, m$) benutzt werden, um den Einfluß der Variablen X_j auf die Trennung der beiden Klassen abzuschätzen.

Dabei geht man davon aus, daß eine Variable umso besser zur Trennung von verschiedenen Gruppen geeignet ist, je größer die Mittelwertsdifferenz $m_{1,j} - m_{2,j}$ der Variablen X_j und je größer das Gewicht w_j ist.

DAVIS (1973) hat als Trennmaß die Größe

$$(4.3.2.2) \quad E_j = \frac{w_j(m_{1,j} - m_{2,j})}{D^2}$$

vorgeschlagen, wobei D^2 die MAHALANOBIS-Distanz bezeichnet. Bei diesem Maß für die Brauchbarkeit einer Variablen zur Trennung der Klassen wird die eventuell vorhandene Korrelation zwischen den Variablen nicht berücksichtigt, so daß der tatsächliche Einfluß der Variablen X_j vom Wert E_j abweichen kann.

Eine Reihe von Experimenten zeigte jedoch, daß E_j gut zur Reduzierung der Variablenzahl eingesetzt werden kann. Geht man von zwei Gruppen aus, so liefert die Diskriminanzanalyse folgende Werte:

- MAHALANOBIS-Distanz der beiden Gruppen
- F-Wert, der die Signifikanz der Trennbarkeit angibt
- die Koeffizienten w_j ($j = 1, \dots, m$) der Diskriminanzfunktion
- die Trennungsmaße E_j ($j = 1, \dots, m$) für die Variablen
- die Diskriminanzscores für die Proben (Pixel).

Im folgenden Beispiel wurde von zwei Texturklassen (Ignimbrit und Sandstein) und einer Variablenzahl 10 ausgegangen. Das Ergebnis der Diskriminanzanalyse ist in Tab. 4 zusammengefaßt.

MAHALANOBIS-Distanz:			3.75
F-Wert (10 und 205 Freiheitsgrade):			19.42
Centroid-Mittelwerte der 2 Klassen:	4.44	&	8.20
Trennpunkt:			6.33

V_j	w_j	E_j	R_1
1	0.02	0.11	9
2	-0.13	1.47	7
3	-0.02	5.12	5
4	-0.08	1.05	8
5	0.06	15.09	2
6	-0.09	8.07	4
7	0.08	2.13	6
8	0.00	0.00	10
9	0.07	12.67	3
10	0.76	64.53	1

Tab. 4: Beispiel einer Diskriminanzanalyse von Texturparametern zweier Gesteinsoberflächen. Spalte 1: Variable; Sp. 2: Gewichte der Diskriminanzfunktion; Sp. 3: Gütemaß für die Trennungseigenschaft der entsprechenden Variablen; Sp. 4: Rangfolge der Variablen entsprechend Sp. 3.

Der F-Wert von 19.4 ist deutlich signifikant (Tafelwert $F_{10, 205} = 2.41$ bei einer Irrtumswahrscheinlichkeit von 1 %). Dieser F-Wert sagt aber nur aus, daß die beiden Mittelwertsvektoren \underline{m}_i ($i = 1, 2$) sich deutlich unterscheiden. Wie gut die Diskriminanzfunktion die beiden Klassen trennt kann an der Verteilung der Diskriminanz-Scores abgelesen werden (Abb. 45). Eine vollständige Trennung ist gegeben, wenn alle Diskriminanz-Scores der ersten Klasse kleiner als der Trennpunkt sind, die der zweiten Klasse größer als dieser Wert. Die Anzahl der Fehlklassifizierungen liegt in diesem Beispiel bei 18 Bildpunkten, die statt der ersten Klasse der zweiten zugeordnet sind und elf Bildpunkte der zweiten Klasse, die der ersten fälschlicherweise zugeordnet sind. Gesamtfehler: 29 Pixel (13 %).

Die Variablen 1 und 8 tragen am wenigsten zur Trennung der Gruppen bei, gefolgt von den Variablen 4, 2, 7. Reduziert man nun die Anzahl der Variablen entsprechend der Rangfolge R_1 , so ergibt sich, daß die MAHALANOBIS-Distanz abnimmt, und die Zahl der Fehlklassifizierungen zunimmt (Tab. 5).

Eliminiert man die Variablen 9 und 10, die am meisten zur Trennung der beiden Gruppen beitragen, so ist die Fehlerquote bei der Klassifizierung trotz der verbleibenden 8 Variablen fast so groß wie bei der Verwendung nur dieser beiden Variablen (vgl. die letzten zwei Zeilen der Tab. 5).

Eine andere Möglichkeit, die Trenngüte von Variablen zu messen und eine optimale Auswahl zu treffen, geht von der Tatsache aus, daß eine Variable eine umso größere Trennschärfe besitzt, je größer die Centroid-Distanz ist und je kleiner die Gruppenvarianzen sind. Beide Bedingungen können im Quotienten

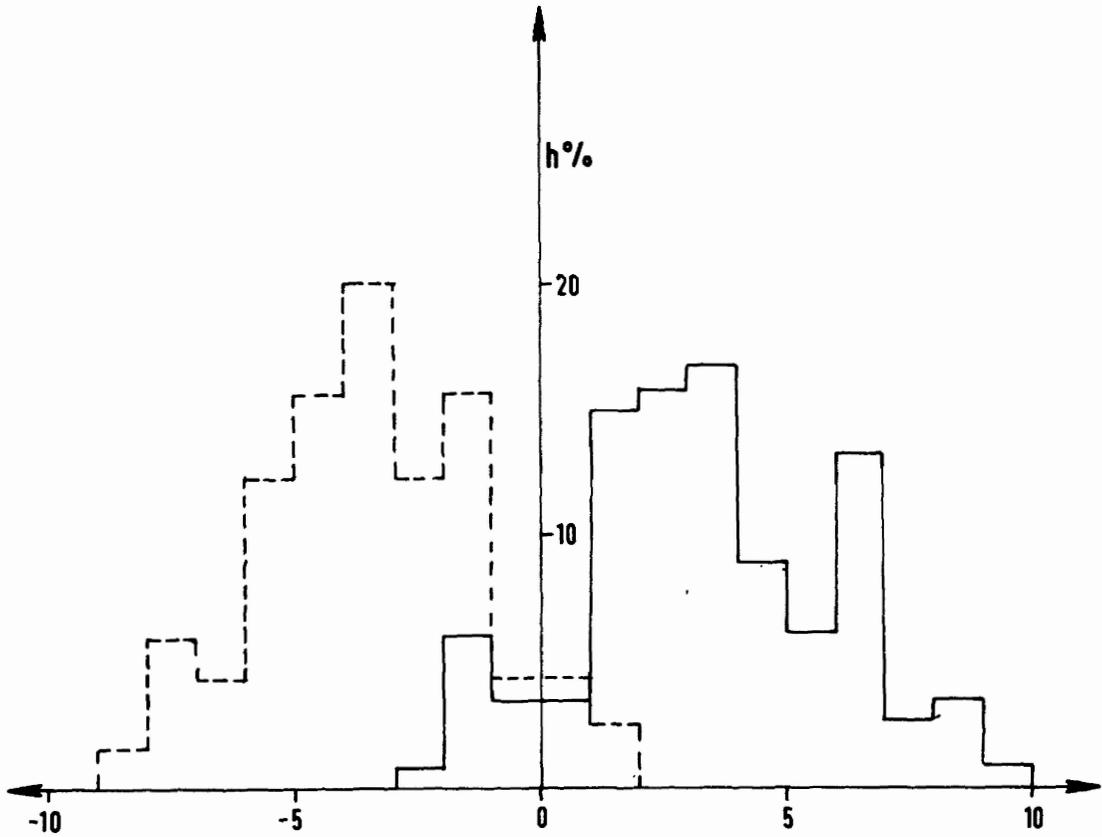


Abb. 45: Häufigkeitsverteilungen der Diskriminanz-Scores zweier Klassen, normiert auf Trennwert 0. Der Überlappungsbereich der Häufigkeitskurven gibt einen Schätzwert für die Zahl der Fehlklassifizierungen.

(4.3.2.3)
$$F_j = \frac{m_{1,j} - m_{2,j}}{s_{1,2}}$$

zusammengefaßt werden, wobei $s_{1,2}$ die mit den Klassengrößen gewichtete Streuung der Variablen X_j bezeichnet. Tab. 6 zeigt, daß auch bei diesem Ansatz die Variablen 1 und 8 die geringste Trenngüte besitzen, die Variablen 9 und 10 die größte.

m	D	F	FK _a	FK _%	Variablen
10	3.75	19.4	29	13.4	1, ..., 10
8	3.75	24.5	30	13.9	2, 3, 4, 5, 6, 7, 9, 10
5	3.63	38.5	33	15.3	3, 5, 6, 9, 10
4	3.63	48.3	31	14.4	5, 6, 9, 10
3	3.47	61.9	34	15.7	5, 9, 10
2	1.87	50.2	61	28.2	9, 10
8	1.99	13.0	52	24.0	1, 2, 3, 4, 5, 6, 7, 8

Tab. 5: Reduzierung der Variablenzahl entsprechend der Rangfolge von Tab. 4, Sp. 4. m: Variablenzahl; D: MAHALANOBIS-Distanz; F: F-Wert; FK_a, FK_%: Fehlklassifizierungen absolut und in Prozent.

V	D _{1,2}	s _{1,2}	F · 100	R ₂
1	0.17	6.16	2.8	10
2	-0.43	3.48	12.	8
3	8.22	21.90	37.	5
4	-0.49	3.59	14.	7
5	8.89	15.56	57.	3
6	-3.51	25.60	14.	6
7	1.04	1.93	54.	4
8	0.49	17.20	3.	9
9	7.12	8.12	88.	1
10	3.20	3.92	82.	2

Tab. 6: Bestimmung der Trennungsgüte von Variablen mit (4.3.2.3). V: Variable; D_{1,2}: Mittelwert-Distanz; s_{1,2}: Streuung der Variablen; F · 100: F-Wert aus (4.3.2.3) mit 100 multipliziert; R₂: Rangfolge der Trennungsgüte.

Auch bei dieser Methode bleiben Korrelationen zwischen den einzelnen Variablen unberücksichtigt, so daß vor der endgültigen Auswahl der zur Gruppentrennung verwendeten Variablen eine Hauptkomponentenanalyse durchgeführt werden sollte, um eventuell hochkorrelierte Variable in geeigneter Weise zusammenzufassen.

Vergleicht man die Rangfolgen R₁ und R₂ der Variablen, die sich aus beiden Methoden ergeben, mit Hilfe des SPEARMANSchen Rangkorrelationskoeffizienten (MARSAL 1967), so ergibt sich ein Wert r = 0.89, der auf eine sehr gute Übereinstimmung der beiden Rangfolgen hinweist (vgl. Tab. 7).

V	1	2	3	4	5	6	7	8	9	10
R ₁	9	7	5	8	2	4	6	10	3	1
R ₂	10	8	5	7	3	6	4	9	1	2
R ₁ -R ₂	-1	-1	0	1	-1	-2	2	1	2	-1
Q	1	1	0	1	1	4	4	1	4	1
Quadratsumme	QS = 18				$r = 1 - 6QS / (m^3 - m) = 0.89$					

Tab. 7: Vergleich der Rangfolge der Variablen V_i (i = 1, ..., 10) bei Verwendung der MAHALANOBIS-Distanz und des F-Werts zur Bestimmung der Trennungsgüte der Variable.

Testet man den Rangkorrelations-Koeffizienten mit einem t-Test, so ergibt sich ein Wert

$$(4.3.2.4) \quad t = r \sqrt{\frac{m-2}{1-r^2}} = 5.52,$$

bei einem Tabellenwert von t_{99%} = 3.17 und 8 Freiheitsgraden, so daß von einer Übereinstimmung der Rangfolgen ausgegangen werden kann.

Diskussion des ausgewerteten Beispiels:

Die Variablen in diesem Beispiel sind Texturparameter mit folgender Bedeutung (vgl. Kap. 4.2):

Nr.	1	2	3	4	5	6	7	8	9	10
Bdtg.	MW	ST	HOM	LPL	LPM	GRM	KTM	GRS	NX	SLX

Die hohen Ränge der Variablen 1 und 2 (Mittelwert und Streuung) sind auf die Normierung des Bildes auf m = 64 und s = 16 zurückzuführen. Die zur Trennung am besten geeigneten Texturparameter sind in diesem Beispiel die Variablen NX, SLX, LPM, HOM, GRM und KTM, d. h. Variable, die die Richtungswechsel des Gradienten und die Homogenität der Bestimmungsfläche erfassen. Eine Korrelationsanalyse dieser Variablen zeigt, daß nur die Variable 9 (Anzahl der Vorzeichenwechsel des Gradienten in x-Richtung) praktisch mit keiner anderen Variablen korreliert ist. Die hohen Korrelationen zwischen den übrigen Texturparametern

weisen darauf hin, daß eine weitere Reduktion der Variablenzahl möglich ist, ohne die Anzahl der Fehl-klassifizierungen sprunghaft zu erhöhen.

Variable	LPM	GRM	KTM	NX	SLX
HOM	.96	.89	.86	.01	.85
LPM		.77	.87	.12	.83
GRM			.73	-.24	.72
KTM				.09	.82
NX					.12

Tab. 8: Korrelationsmatrix der Texturparameter mit den besten Trenneigenschaften.

4.3.3 Varianzanalyse bei mehr als zwei Klassen

Die zuletzt angewendete Methode zur Bestimmung derjenigen Variablen, die zur Trennung zweier Klassen am meisten beitragen, hat den Vorteil, daß sie in natürlicher Weise auf k ($k > 2$) Klassen verallgemeinert werden kann. Mit Hilfe der Varianzanalyse untersucht man für jede Variable die Hypothese

$$(4.3.3.1) \quad H_0 : m_1 = m_2 = \dots = m_k = m ,$$

wobei mit m_i ($i = 1, \dots, k$) die Klassenmittelwerte und mit m der Gesamtmittelwert für die betrachtete Variable bezeichnet werden (vgl. Anhang 2).

Die Hypothese H_0 wird abgelehnt, wenn die Varianz σ_i^2 innerhalb der Klassen signifikant von der Varianz σ_z^2 zwischen den Klassenmittelwerten abweicht. Ein Maß für diese Abweichung ist der Quotient

$$(4.3.3.2) \quad q = \sigma_z^2 / \sigma_i^2 ,$$

der einer F-Verteilung mit $(k-1, n-k)$ Freiheitsgraden folgt, wenn die k Klassen Normalverteilungen mit derselben Varianz entstammen. Die Erfahrung in vielen Experimenten hat jedoch gezeigt, daß der F-Test ein robustes Verfahren darstellt, das auch dann angewendet werden kann, wenn die Häufigkeitsverteilungen erheblich von der Normalverteilung abweichen (BLACKITH & REYMENT 1971). Da es hier nur auf die Erstellung einer Reihenfolge unter den Variablen ankommt, kann q direkt zu Vergleichen herangezogen werden.

Gilt bei vorgegebener Signifikanzzahl α

$$(4.3.3.3) \quad q > F(k-1, n-k, \alpha) ,$$

so kann H_0 nicht abgelehnt werden, und der Klassenmittelwert unterscheidet sich nicht signifikant vom Gesamtmittel, d. h. die untersuchte Variable ist zur Trennung der Klassen ungeeignet. Die Nichterfüllung der Bedingung (4.3.3.3) ist eine notwendige, aber keine hinreichende Bedingung dafür, daß die Variable

Variable	Bedeutung	q	Rang
1	MW	0.64	10
2	ST	146.28	8
3	HOM	616.57	3
4	LPL	6.59	9
5	LPM	755.16	2
6	GRM	205.62	7
7	KTM	487.13	5
8	SLX	590.62	4
9	SLY	474.74	6
10	NX	947.28	1

Abb. 9: Univariate F-Werte für 10 Texturparameter und Rangfolge entsprechend der Größe dieser Werte.

zur Trennung der Klassen geeignet ist. Ist q signifikant größer als der entsprechende F -Wert, so kann man davon ausgehen, daß sich mindestens ein Klassenmittelwert deutlich von den anderen unterscheidet.

Tab. 9 zeigt die q -Werte der 10 Texturparameter der 6 ausgewählten Testflächen.

Die hohen Ränge der Variablen MW und ST spiegeln die Normierung der Grautonverteilung der Testgebiete wieder.

Reduziert man die Variablenzahl entsprechend der durch Tab. 9 gegebenen Rangfolge, so ergibt eine Diskriminanzanalyse folgende Fehlklassifizierungen:

Variablen-Zahl	10	9	7	6	5	3	2	5
Fehler-Zahl	24	25	20	31	46	56	66	117

Tab. 10: Reduzierung der Parameterzahl entsprechend der Rangfolge in Tab. 9. Die letzte Spalte enthält die Zahl der Fehlklassifizierungen, die bei Verwendung der Parameter mit den Rängen 6, ..., 10 entstehen.

Obwohl diese "Rangmethoden" i. A. nicht die beste Variablenkombination liefern, stellen sie ein sub-optimales Verfahren zur Variablenauswahl dar.

4.4 Canonische Transformation

Vergleicht man die in Kap. 2.6.2 beschriebenen Methoden der Datenreduktion durch Bildtransformation, so stellt sich heraus, daß die Canonische Transformation fast immer bessere Ergebnisse liefert als die Hauptkomponententransformation. Bei der Verwendung von Texturparametern zur Klassifizierung spielt die optimale Wahl der Variablenzahl eine entscheidende Rolle, da durch die Größe q^2 der Bestimmungsfläche für jedes Pixel die Zahl der Operationen und damit die Rechenzeit entsprechend zunimmt.

Reduziert man die Zahl der Eigenvektoren der Transformationsmatrizen, so erhält man einen Merkmalsraum mit entsprechend niedriger Dimension. Reduziert man diese Dimension Schritt für Schritt, so erhält man bei einer Klassifizierung eine Steigerung der Zahl der Fehlklassifizierungen. Untersuchungen an vielen Beispielen zeigen, daß diese Zahl bis zu einem bestimmten Punkt nur langsam steigt, bei einer weiteren Reduktion der Dimension des Merkmalsraums jedoch sprunghaft wächst. Dies kann auch am Beispiel der sechs Textur-Testflächen gezeigt werden.

Betrachtet man die Verteilung der Texturparameter in den Scattergrammen (Abb. 46), so erkennt man, daß die künstlichen Texturflächen gut zentrierte Cluster bilden (Symbol 5 und 6), während bei den Gesteinsoberflächen nur der Granit (3) leicht von den übrigen Klassen zu trennen ist. Die Überlappungsbereiche bei den Klassen 1, 2, 4 (Ignimbrit, Sandstein, Metamorphit) sind bei der Projektion auf zwei Dimensionen sehr groß. Eine Untersuchung der 10 Texturparameter mit Hilfe der multiplen Diskriminanzanalyse zeigt jedoch, daß die Klassen gut mit linearen Diskriminanzfunktionen zu trennen sind. Tab. 11 liefert eine Übersicht über die auftretenden Fehlklassifizierungen.

Klasse	1	2	3	4	5	6	Fehler
1	55	3	-	4	-	2	9
2	2	61	1	-	-	-	3
3	-	-	80	-	-	-	-
4	11	1	-	52	-	-	12
5	-	-	-	-	64	-	-
6	-	-	-	-	-	64	-
							Gesamtfehlerzahl
							24 (6 %)

Tab. 11: Die Matrix enthält in Zeile i , Spalte j die Zahl der Bildpunkte, die zu K_i gehören und K_j zugeordnet wurden.

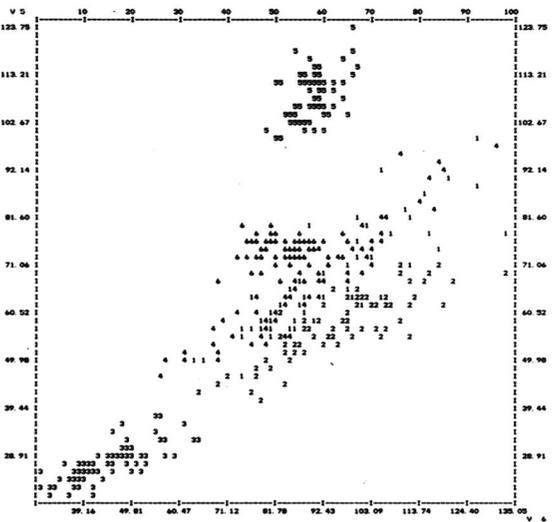
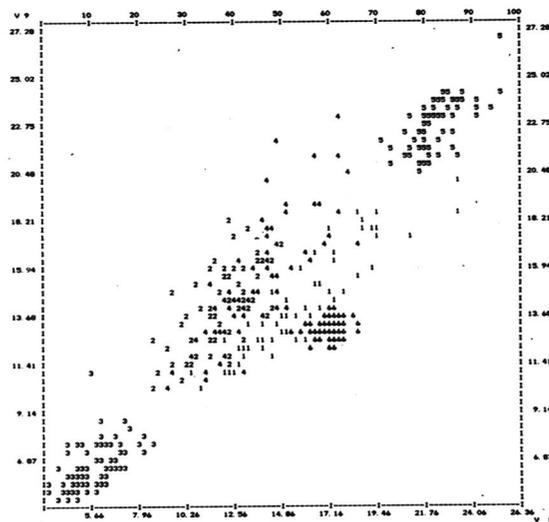
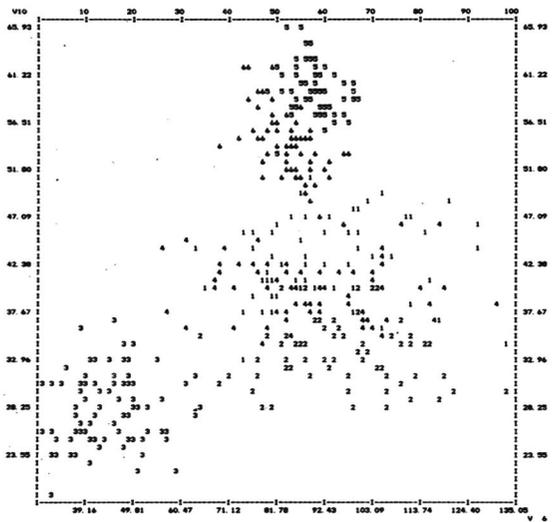
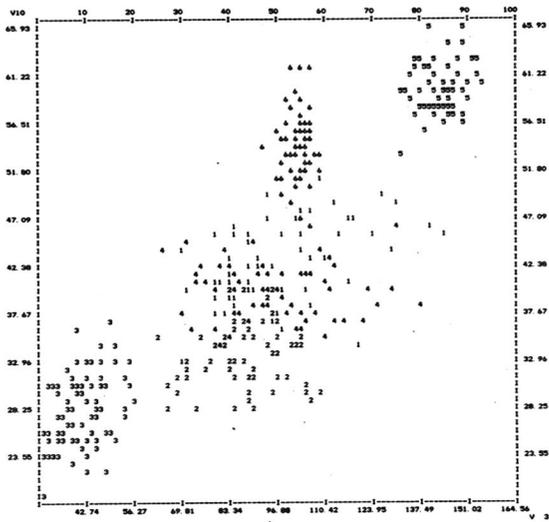


Abb. 46: Scattergramme von Texturparametern der 6 Test-Flächen (1 - 4: Gesteinsoberflächen, 5 - 6: künstliche Texturen). Die Cluster der künstlichen Texturen sind gut zentriert, die Gesteinstexturen sind (mit Ausnahme von Nr. 3) im zweidimensionalen Merkmalsraum praktisch nicht zu trennen.

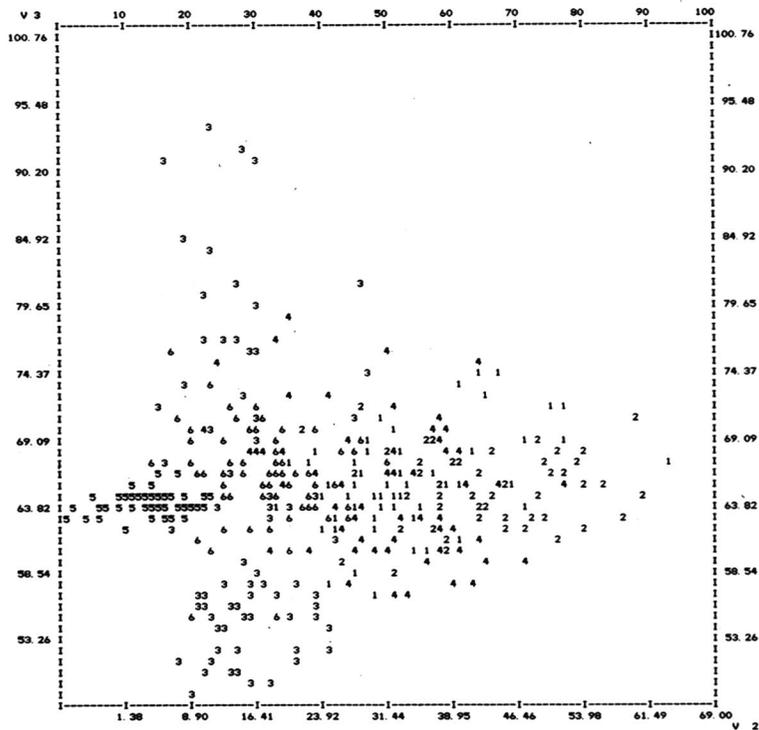
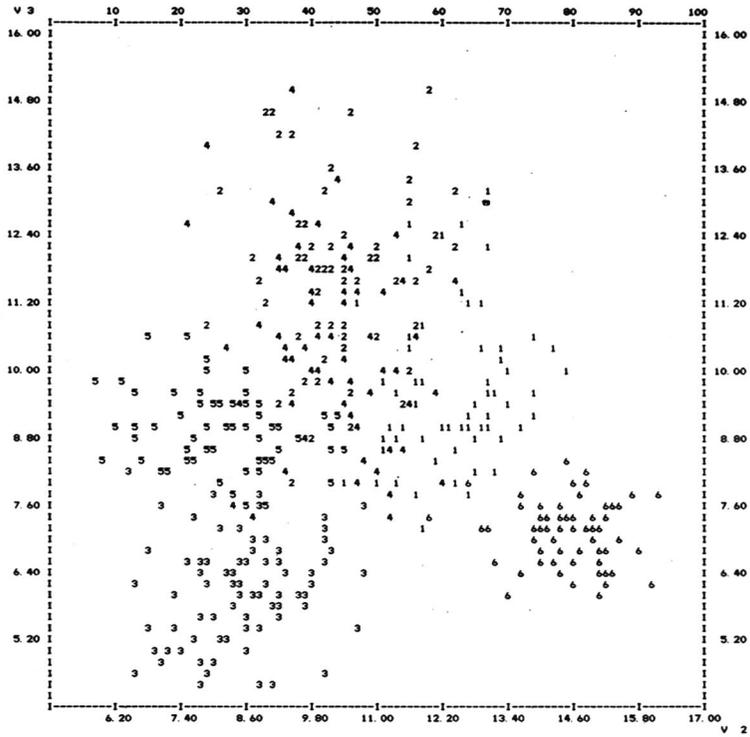


Abb. 47: Vergleich der Trennungsgüte von zwei Variablen: 2. und 3. canonische Variable (oben) und 2. und 3. Hauptkomponente nach einer PCT (unten). Während bei der CVT die Gruppen 1, 3, 5, 6 gut zentriert sind, ist die Verteilung der Gruppenelemente nach der PCT deutlich diffuser.

Führt man eine PCT und eine CVT durch, so ergibt sich bei Reduktion der Dimension des transformierten Merkmalsraumes die folgende Entwicklung der Fehlerzahl bei der Diskriminanzanalyse:

Dimension	5	4	3	2
Fehlerzahl CVT	24	26	24	55
Fehlerzahl PCT	37	40	83	82

Tab. 12: Steigerung der Zahl der Fehlklassifizierungen bei Reduktion der Dimension des Merkmalsraumes.

Man erkennt, daß bei 3 canonischen Variablen die Zahl der Fehlklassifizierungen nicht größer ist, als bei Verwendung von 10 Originalvariablen und erst bei 2 Variablen tritt ein deutlicher Sprung auf. Die ent-

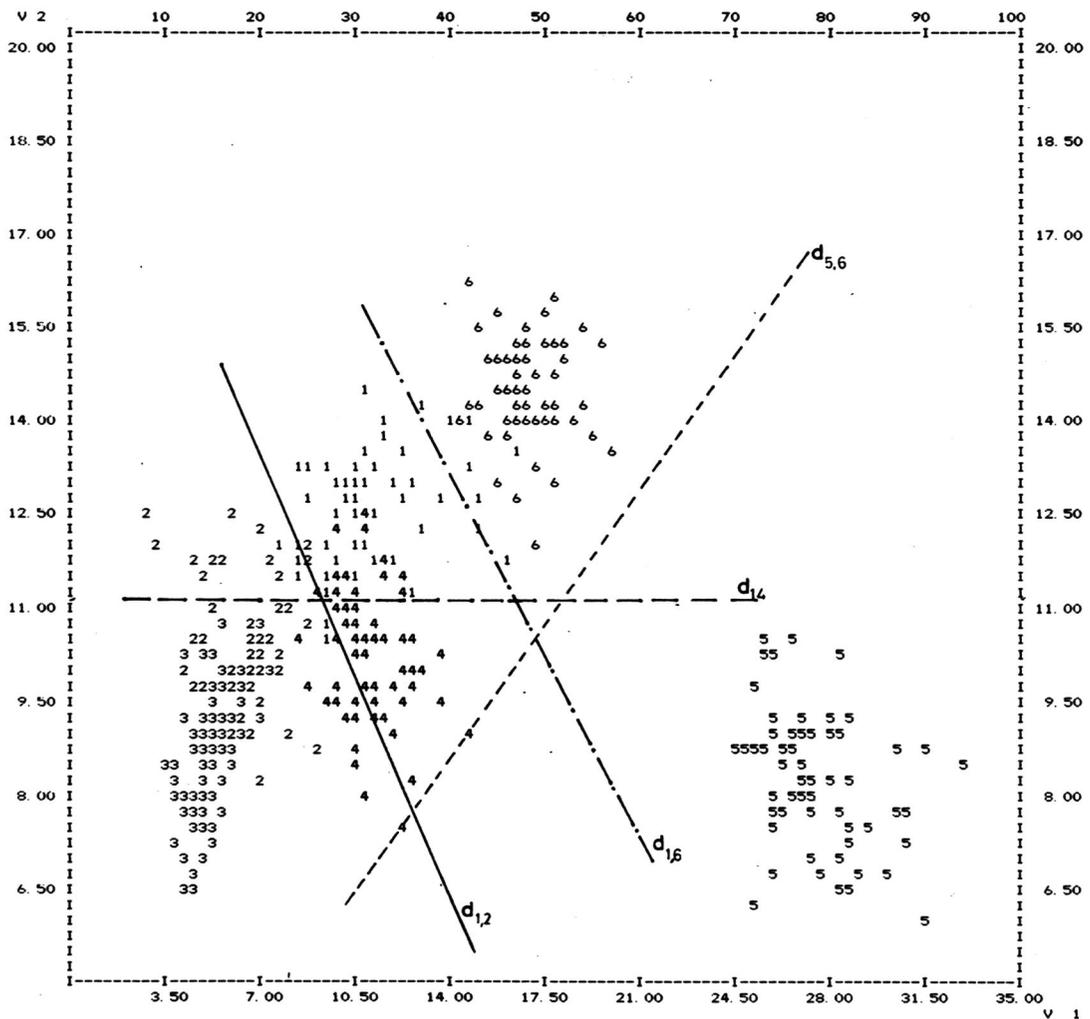


Abb. 48: Darstellung der canonisch transformierten Texturparameter von 6 Testflächen. Zur Trennung der 6 Klassen genügen 4 lineare Diskriminanzfunktionen.

sprechenden Fehlerzahlen liegen bei der PCT wesentlich ungünstiger. Betrachtet man die 2. und 3. transformierten Variablen, so erkennt man, daß die Projektion der Daten auf diese Achsen bei der CVT noch eine gute Trennung von 5 Gruppen zuläßt, während bei der PCT nur die Klasse 5 noch gut durch lineare Trennfunktionen abzugrenzen ist (Abb. 47).

Berechnet man im zweidimensionalen Merkmalsraum der 1. und 2. canonischen Variablen die linearen Trennfunktionen für alle Gruppen, so erkennt man, daß anstelle von $6 \cdot 5/2 = 15$ Trennfunktionen nur 4 genügen, um eine Zuordnung der Punkte zu den verschiedenen Klassen durchzuführen (Abb. 48).

4.5 Klassifizierung der Testgebiete mit Hilfe der Texturparameter

4.5.1 Berechnung der Trennfunktionen

Zur Klassifizierung der in Kap. 4.3.1 beschriebenen, auf $N(64, 16)$ normierten Testgebiete sind folgende Schritte notwendig:

- Aus jedem Testgebiet werden 50 - 100 Bildpunkte gewählt und die zugehörigen Texturparameter berechnet (Stichprobe).
- Die Stichprobe wird einer multiplen (linearen) Diskriminanzanalyse unterworfen, wobei man eine Liste der Fehlklassifizierungen innerhalb der Stichprobe und die Diskriminanzfunktionen d_{ij} erhält (vgl. Kap. 2.4.2).
- Die Diskriminanzfunktionen d_{ij} werden entsprechend der Entscheidungsregel

$$(2.4.2.1) \quad \underline{x} \in K_i \iff d_{ij}(\underline{x}) > 0 \quad \text{für alle } j, j \neq i$$

zur Klassifizierung der Gesamtszene verwendet.

Bei der Auswahl der Stichprobe muß darauf geachtet werden, daß sich die Bestimmungsflächen der Bildpunkte nicht überlappen, um unerwünschte Korrelationen zu vermeiden, die die Struktur der Varianz-Kovarianz-Matrix verändern würden. Die Stichprobe kann auch dazu benutzt werden, die Transformationsmatrix für eine PCT oder CVT zu berechnen, so daß nach einer entsprechenden Parametertransformation die Klassifizierung in einem reduzierten Merkmalsraum ausgeführt werden kann.

Zur Berechnung der Diskriminanzfunktionen wurde das Programm MDISK (Multiple Diskriminanzanalyse) entwickelt. Eingangsparameter sind die Anzahl der Gruppen k , die Zahl der Texturparameter m und die Zahl der Gruppenelemente n_i ($i = 1, \dots, k$). Hieraus ergibt sich der Stichprobenumfang n , $n = n_1 + \dots + n_k$. Es werden die linearen Diskriminanzfunktionen nach (2.5.2.6) berechnet, wobei eine gepoolte (d. h. entsprechend der Gruppengröße n_i gewichtete) Varianz-Kovarianz-Matrix C verwendet wird (vgl. 2.5.2.11).

Gedruckt bzw. auf Dateien gespeichert werden

- die Diskriminanzfunktionen d_{ij} ($i = 1, \dots, k; j = i, \dots, k-1$);
- die Gruppenmittelwerte \underline{m}_i ($i = 1, \dots, k$);
- die Varianz-Kovarianz-Matrix C und die zugehörige Korrelationsmatrix R ;
- die Diskriminanzwerte $d_{ij}(\underline{x})$ für alle Stichproben \underline{x} ;
- die MAHALANOBIS-Distanzen der Gruppenmittel:

$$(\underline{m}_i - \underline{m}_j)' C^{-1} (\underline{m}_i - \underline{m}_j)$$

- die univariaten F-Werte (vgl. 4.3.3.3);
- eine Kontingenztafel der Zuordnung der Merkmalsvektoren \underline{x} zu den einzelnen Gruppen entsprechend der Entscheidungsregel (2.4.2.1).

Die Kontingenztafel der Fehlklassifizierungen innerhalb der Stichprobe ist von besonderer Bedeutung, denn sie läßt Rückschlüsse auf die Zahl der Fehlklassifizierungen in der Gesamtszene zu. Tab. 13 zeigt die Verteilung der Fehlklassifizierungen für die ausgewählten 6 Testgebiete bei einer Bestimmungsfläche B von 15×15 Pixel.



Abb. 49: Klassifizierungsergebnis der in Abb. 44 dargestellten Gesteinstexturen mit Hilfe von Texturparametern. Die Zahl der Fehlklassifizierungen beträgt ca. 12 %.

Gebiet	1	2	3	4	5	6	Fehler
1	52	4	3	-	-	5	12
2	-	64	6	2	-	-	8
3	2	8	52	2	-	-	12
4	-	1	-	71	-	-	1
5	-	-	-	-	64	-	-
6	-	-	-	-	-	64	-
Gesamtfehler:							33 (8.3 %)

Tab. 13: Kontingenztabelle der Fehlklassifizierungen aus den sechs Testgebieten: Ignimbrit, Basalt, Sandstein, Granit, N 6416 und A5C2 (m = 10, n = 400, k = 6).

Auffallend an Tab. 13 ist die Tatsache, daß alle Fehlklassifizierungen bei den Gesteinstexturen (Gebiete 1 - 4) vorkommen, während die künstlich erzeugten Texturen (Gebiete 5 und 6) trotz der Normierung auf N(64, 16) (vgl. hierzu die Histogramme in Abb. 43) keine Fehlklassifizierungen aufweisen.

Beschränkt man die Berechnung der Diskriminanzfunktionen auf die Stichprobe aus den natürlichen Texturen (vgl. Abb. 44), so erhält man die in Tab. 14 dargestellte Kontingenztabelle der Fehlklassifizierungen.

Das zu diesen Diskriminanzfunktionen gehörige Klassifizierungsergebnis ist als Druckerbild in Abb. 49 dargestellt. Die Zahl der Fehlklassifizierungen von 12 % entspricht dabei dem in Tab. 14 erhaltenen Schätzwert.

Gebiet	1	2	3	4	Fehler
1	56	5	3	-	8
2	-	65	5	2	7
3	1	7	53	3	11
4	-	2	-	70	2
Gesamtfehler:					28 (10.5 %)

Tab. 14: Kontingenztabelle der Fehlklassifizierungen der Stichprobe aus den Testgebieten 1 - 4 (Ignimbrit, Sandstein, Basalt, Granit; m = 10, n = 272, k = 4).

Die Gesamtfehlerzahl reduziert sich auf 28, der prozentuale Anteil steigt jedoch auf 10.5 %. Reduziert man die Variablenzahl auf m = 6, so steigt die Fehlerquote auf 16.5 %.

Gebiet	1	2	3	4	Fehler
1	51	9	4	-	13
2	1	57	9	5	15
3	2	10	50	2	14
4	-	3	-	69	3
Gesamtfehler:					45 (16.5 %)

Tab. 15: Kontingenztabelle wie Tab. 14, mit Variablenzahl m = 6 (HOM, GRS, KTM, SLX, SLY, NX).

Abb. 50 stellt die Klassifizierungsergebnisse für die Testgebiete Sandstein/Ignimbrit bei Verwendung von 10 und 6 Variablen gegenüber. Die Variablenreduktion bewirkt insbesondere eine Vergrößerung derjenigen Bildbereiche, die schon bei großer Variablenzahl fehlerklassifiziert waren.

Zusammenfassend kann festgestellt werden, daß die untersuchten Gesteinstexturen mit 6 - 8 Texturparametern und einer Bestimmungsfläche von 9 x 9 bis 15 x 15 Pixel gut zu trennen sind (Fehlerrate 3 - 12 %).

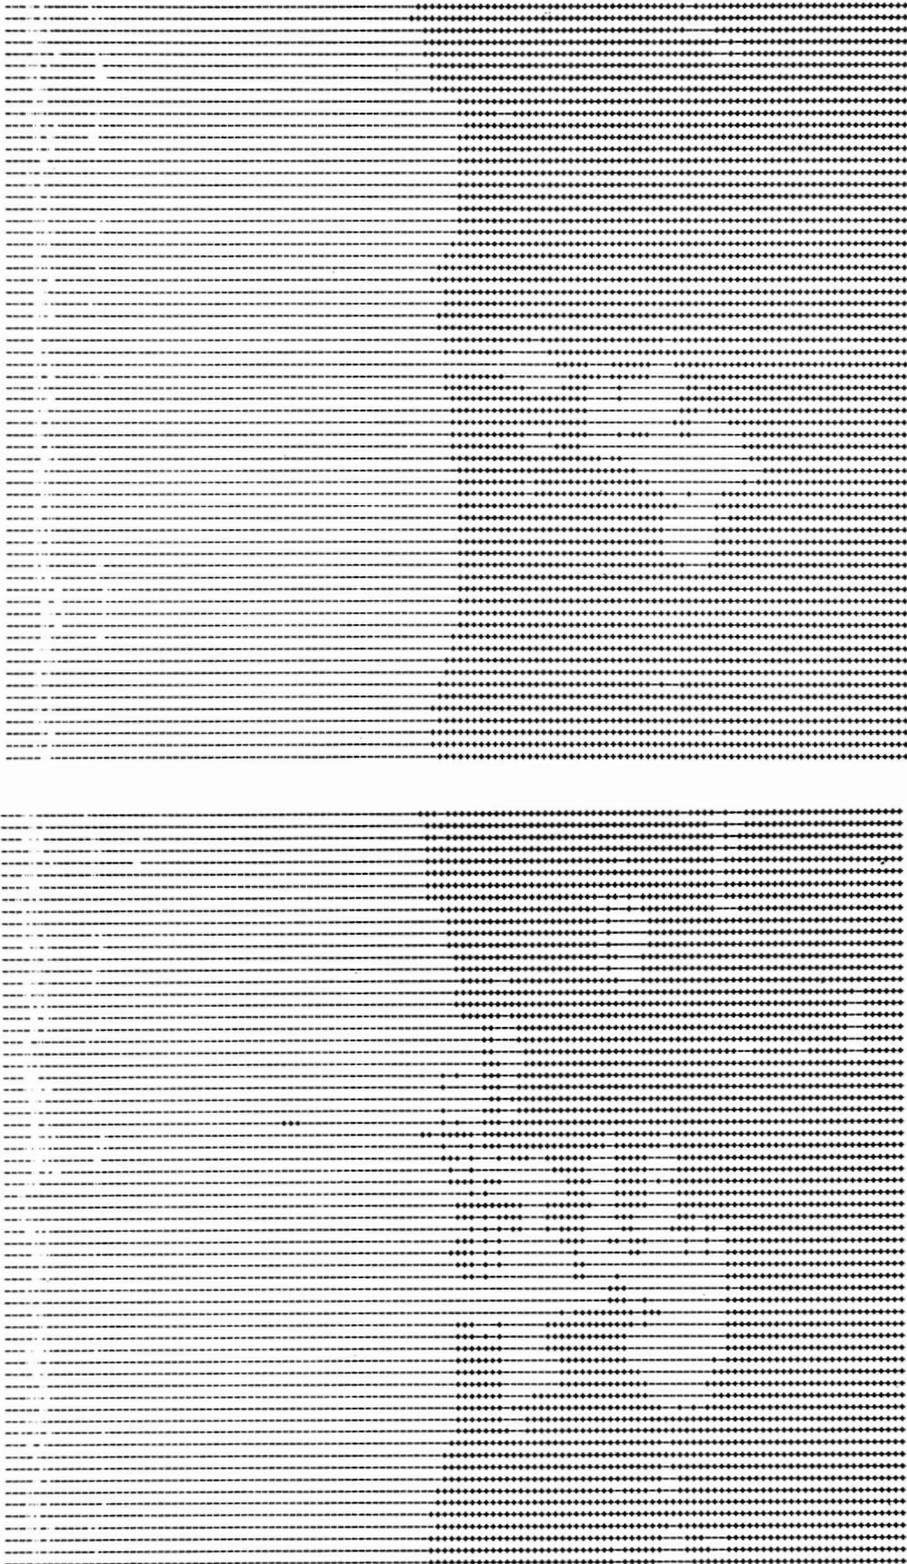


Abb. 50: Klassifizierung von Sandstein (links) und Ignimbrit (rechts). Vergrößerung fehlklassifizierter Bildbereiche bei Reduktion der Parameterzahl von 10 (oben) auf 6 (unten).

5. KLASSIFIZIERUNG AUF DER BASIS VON SIGNATUR- UND TEXTURMERKMALEN

5.1 Texturerkennung bei Multispektralaufnahmen

Während in Kap. 4 die Texturparameter nur für einen Spektralkanal berechnet und damit eine Klassifizierung durchgeführt wurde, soll in diesem Kapitel untersucht werden, wie sich die Multispektral-Information zusammen mit der Textur-Information zu einer Verbesserung der Klassifizierungsergebnisse benutzen lassen.

Eine naheliegende Möglichkeit der Verallgemeinerung ist die Berechnung der Texturparameter in allen Spektralkanälen und die Erweiterung des Merkmalsvektors \underline{x} auf die k -fache Länge, wobei k die Anzahl der Spektralkanäle bezeichnet. Dieser Ansatz ist aus mehreren Gründen nicht praktikabel:

- die Rechenzeit wächst auf das k -fache bei einfachen Klassifizierungsalgorithmen (z. B. Quadermethode), etwa quadratisch mit k bei maximum-likelihood-Verfahren;
- die Korrelationen zwischen den entsprechenden Merkmalswerten in verschiedenen Kanälen sind so groß, daß es unökonomisch wäre, sie einzeln zu berechnen.

HARALICK & BOSLEY (1974) haben als erste versucht, durch Verallgemeinerung der "Nachbarschaftsmatrizen" (vgl. Kap. 4.2.1) die vier Landsat-Kanäle für die Texturklassifizierung nutzbar zu machen. Bei diesem Verfahren werden die entsprechenden Matrizen sehr groß, wenn auch in einigem Abstand von der Hauptdiagonalen nur Nullen stehen. Eine Verbesserung der Klassifizierungsergebnisse erhält man, wenn der Merkmalsvektor der m Texturparameter eines Spektralkanals durch die vier Signaturwerte erweitert und mit diesem vergrößerten Merkmalsvektor gearbeitet wird (HARALICK & SHANMUGAM 1974). Auch hier tritt das Problem der Rechenzeit auf, da für jeden Bildpunkt dieser erweiterte Parametersatz berechnet bzw. eingelesen werden muß, um eine Zuordnung zu einer Klasse vornehmen zu können.

Eine wesentliche Reduktion der Rechenzeit ergibt sich aus einer getrennten Verarbeitung von Signatur- und Texturmerkmalen bei der Klassifizierung von Multispektralbildern. Ausgangspunkt dieses Verfahrens (BURGER 1978) ist eine passende Bildsegmentierung, wobei im Bildsegment I_h nach Signaturmerkmalen und im Bildsegment I_t nach Texturmerkmalen klassifiziert wird. Diese Methode hat folgende Vorteile:

- die rechenaufwendigen Texturparameter werden nur für einen Spektralkanal berechnet;
- die Texturparameter werden nur für einen Teil der Bildpunkte berechnet, während für den anderen Teil die Signaturmerkmale direkt zur Klassifizierung verwendet werden.

In den folgenden Kapiteln wird diese Methode ausführlich dargestellt und es werden Beispiele für den Klassifizierungsalgorithmus gegeben.

5.2 Bildsegmentierung

Ein besonderes Problem bei der Klassifizierung von Signaturmerkmalen bilden Mischsignaturen, die nicht nur an der Grenze zwischen verschiedenen Gesteinseinheiten entstehen, sondern insbesondere - weil flächenhaft verteilt - bei gefalteten, verwitterten, erodierten, verkarsteten oder durch andere Prozesse morphologisch stark gegliederte Gesteinseinheiten. Beim Begriff "Mischsignatur" geht die Vorstellung ein, daß es auch "reine Signaturen" gibt, obwohl dieser Begriff bisher nicht verwendet wurde.

Eine Fläche wird im Bild "homogen" erscheinen, wenn die Pixel, aus denen sie besteht, denselben Grautonwert besitzen, wobei eine gewisse Streuung durch Signalrauschen und andere Einflüsse zugelassen ist. Bei Multispektralbildern muß berücksichtigt werden, daß eine z. B. im grünen Spektralkanal homogen erscheinende Fläche im Infrarot-Kanal deutlich strukturiert - also inhomogen - erscheinen kann (Beispiel: Mischwald in den Landsat-Kanälen 4 und 7). Geht man umgekehrt von einer "homogenen" Fläche im Objektraum aus, müssen die Bildpunkte in allen Spektralkanälen denselben Grautonwert besitzen (überlagert vom o. a. Signalrau-

schen). Zur Quantifizierung des Begriffs "homogene Fläche" dient folgende Definition.

Def. 5.2.1: Eine Fläche wird als spektral homogen bezeichnet, wenn sie in allen Spektralkanälen einheitliche Grautonwerte besitzt, d. h. für jedes Pixel der Fläche mit Signaturvektor $\underline{x}' = (x_1, \dots, x_k)$ muß gelten

$$(5.2.1) \quad |x_i - m_i| < \epsilon_i, \quad i = 1, \dots, k,$$

wobei ϵ_i statistische, vom Spektralkanal abhängige Schwankungen um den für die Fläche repräsentativen Signaturvektor $\underline{m}' = (m_1, \dots, m_k)$ sind.

Da bei einer Klassifizierung die Zuordnung einzelner Pixel zu vorgegebenen Klassen vorgenommen wird, ist es notwendig festzustellen, ob ein Bildpunkt einer spektral homogenen Fläche angehört oder nicht.

Def. 5.2.2: Ein Bildpunkt mit Signaturvektor \underline{z} heißt Homogenitätspunkt, wenn alle Bildpunkte in einer gewissen Umgebung $U(\underline{z})$ eine spektral homogene Fläche bilden, d. h.

$$(5.2.2) \quad |x_i - z_i| < \epsilon_i, \quad \text{für alle } i = 1, \dots, k \text{ und} \\ \text{für alle } \underline{x} \in U(\underline{z}).$$

Da die Ungleichung (5.2.1) k Abfragen erfordert (für die k Spektralkanäle), wird in der vorliegenden Arbeit das Distanzmaß

$$(5.2.3) \quad d(\underline{z}, \underline{x}) = \frac{1}{k} \sum_{i=1}^k |x_i - z_i| / \sigma_i$$

verwendet und als spektrale Distanz der Pixel \underline{z} , \underline{x} bezeichnet. σ_i ist dabei die Streuung der Grautonwerte in Kanal i.

Zu dieser Definition führt folgende Überlegung: Sind die Grautonwerte normalverteilt, so ist auch die Zufallsvariable $Z = X - Y$ normalverteilt (FELLER 1971) und nach Anh. 4, Satz 3 kann für Z eine Verteilung der Form (A 4.10) angenommen werden. Die Streuung der Variablen Z ergibt sich nach Anh. 4, Satz 2 zu

$$(5.2.4) \quad \sigma_Z^2 = 2 \cdot \sigma^2 - \sigma_{XY} \\ = 2 \cdot \sigma^2 (1 - r),$$

wobei r den Korrelationskoeffizienten der Variablen X , Y bedeutet (d. h. die Korrelation der Grautonwerte benachbarter Bildpunkte) und σ^2 die gemeinsame Varianz. Eine Überprüfung der Verteilung der Grautondifferenzen an Bildern von Gesteinsoberflächen ergab stets eine gute Obereinstimmung mit der Normalverteilung (vgl. Abb. 51).

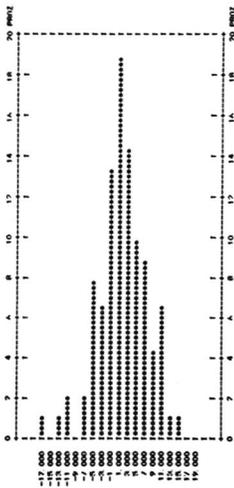


Abb. 51: Histogramm der Grautondifferenzen benachbarter Pixel (Umgebung Ofouni). Ein χ^2 -Quadrat-Test zeigt, daß auf dem 95 %-Signifikanzniveau die Hypothese der Normalverteilung nicht abgelehnt werden kann.

Da sich bei Gesteinsoberflächen die Bildtexturen in den verschiedenen Landsat-Spektralkanälen nur durch ihre Helligkeit unterscheiden, kann man davon ausgehen, daß der Faktor $(1-r)$ in (5.2.4) für alle Spektralkanäle annähernd gleich ist. Durch die Division durch σ_i in (5.2.3) wird erreicht, daß die Spektralkanäle gleichgewichtet zur spektralen Distanz beitragen.

Betrachtet man eine Umgebung $U(\underline{z})$ von \underline{z} mit m Elementen $\underline{x}_i, i = 1, \dots, m$, so erhält man m spektrale Distanzen $d_i = d_i(\underline{z}, \underline{x}_i), \underline{x}_i \in U(\underline{z})$, für die eine multivariate Verteilung der Form

$$(5.2.5) \quad g(\underline{d}) = \begin{cases} 2^m N(0, C) & \text{für } d_i > 0; i = 1, \dots, m \\ 0 & \text{sonst} \end{cases}$$

angenommen wird (\underline{d} bezeichnet den Distanzvektor $\underline{d} = (d_1, \dots, d_m)$). Eine Verallgemeinerung von (5.2.2) auf mehrere Nachbarpunkte $\underline{x}_i \in U(\underline{z})$ kann - analog zu (2.4.8) - durch

$$(5.2.6) \quad d_U^2 = d_U^2(\underline{z}, U) = \underline{d}' C^{-1} \underline{d}$$

definiert werden. Mit diesem verallgemeinerten Distanzmaß erhält man

Def. 5.2.3: Ein Pixel mit Signaturvektor \underline{z} heißt Homogenitätspunkt in Bezug auf die Umgebung $U(\underline{z})$, wenn

$$(5.2.7) \quad d_U^2 = \underline{d}' C^{-1} \underline{d} < c$$

gilt, mit einer vorgegebenen Schranke $c, c \in R$.

Def. 5.2.4: Die Menge der Homogenitätspunkte eines Bildes I wird mit I_h (Homogenitätsbild), die Menge der Bildpunkte, für die Ungleichung (5.2.7) nicht erfüllt ist, wird mit I_i (Inhomogenitätsbild) bezeichnet.

Die Zahl der Homogenitätspunkte in einem Bild hängt damit von der Schranke c ab. Die Extremwerte $c = 0$ und $c = \infty$ liefern $I_h = \emptyset$ und $I_h = I$.

Betrachtet man als Umgebung $U(\underline{z})$ nur die nächsten Nachbarn in x - und y -Richtung, so erhält man eine bivariate Merkmalsverteilung für die entsprechenden spektralen Distanzen d_x und d_y . Durch Ausmultiplizieren der quadratischen Form (5.2.7) erhält man die spektrale Distanz für zwei Umgebungspunkte (BURGER 1978)

$$(5.2.8) \quad d_U^2 = \alpha d_x^2 + \beta d_y^2 + \gamma d_x d_y$$

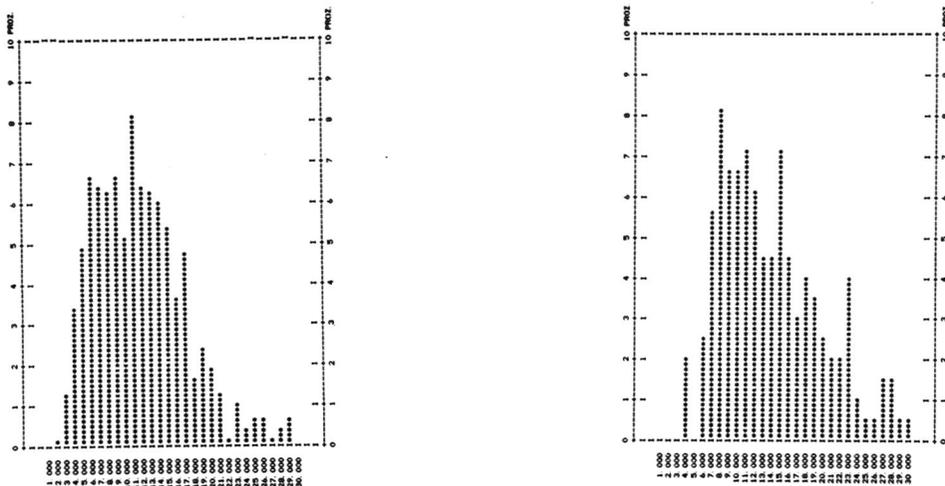


Abb. 52: Häufigkeitsverteilungen der spektralen Distanzen zweier Testgebiete (Umgebung Ofouni und süd1. Bardai, Landsat-Szene E-12o9 - o8491).

Die Verteilung der spektralen Distanzen der verschiedenen Testgebiete ist deutlich schief, das Maximum liegt jedoch nicht (vgl. Abb. 52), wie aus (5.2.5) zu erwarten, bei Null, sondern ist zu positiven Werten hin verschoben.

Dies zeigt, daß die Modellvorstellung, die der obigen Ableitung zugrunde liegt, nur eine erste Annäherung darstellt (z. B. überlagert das Signalrauschen die Modellverteilung (A 4.10)).

Das wichtigere Problem in diesem Zusammenhang ist die Wahl der Schranke c in (5.2.7). Besteht das Bild aus großen, homogenen Flächen, so wird d_U eine bimodale Häufigkeitsverteilung bilden, wobei für c sinnvollerweise zwischen den beiden Modalwerten angenommen wird. Dieser Art der Schwellenbildung, die insbesondere bei der Abgrenzung geochemischer Anomalien verwendet wird, liegt die Annahme zugrunde, daß sich die Verteilungsfunktion $S(d_U)$ additiv aus zwei Normalverteilungen zusammensetzt, wobei die erste (die dem kleineren Modus zugeordnet ist) von den Homogenitätsflächen herrührt, die zweite von den texturierten Flächen. Auch unimodale Häufigkeitsverteilungen können oft durch Superposition von verschiedenen Normalverteilungen erklärt werden (BURGER 1976).

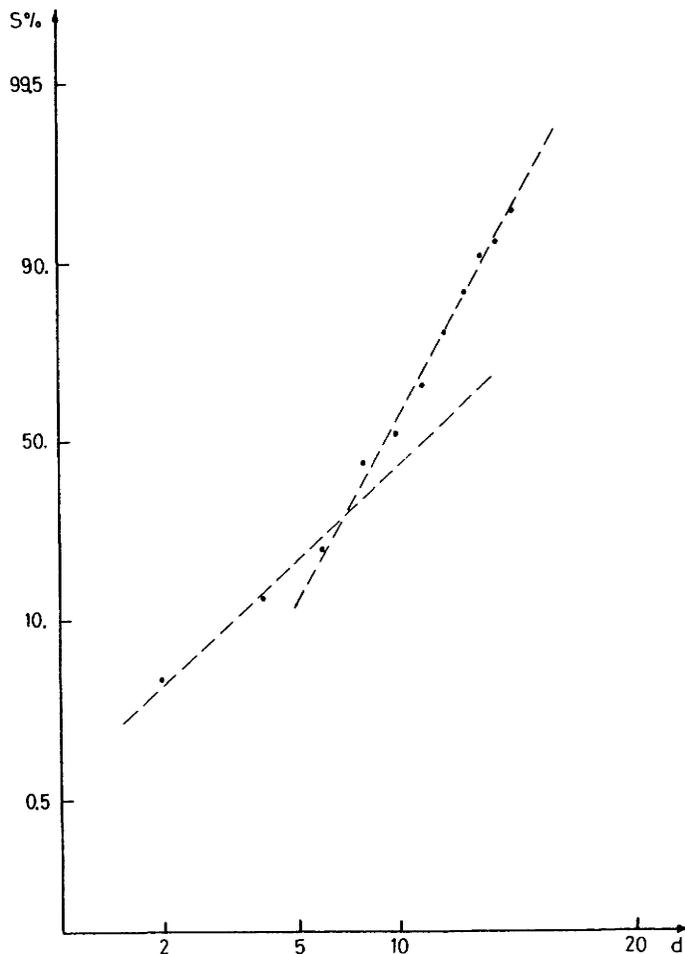


Abb. 53: Bestimmung des Schwellenwertes c durch Zerlegung der Summenkurve der spektralen Distanz d in Normalkomponenten (Darstellung im Wahrscheinlichkeitsnetz).

Trägt man die Verteilungsfunktion einer Zufallsvariablen in ein Wahrscheinlichkeitsnetz ein, so ergeben sich in diesem Fall zwei oder mehr lineare Kurventeile, die durch "Wendekurven" miteinander verbunden sind. Die Lage der Wendepunkte gibt einen Schätzwert für den Anteil der entsprechenden Normal-Komponente

an der Gesamtverteilung (vgl. Abb. 53).

Ergibt sich aus dem Histogramm und aus der Summenkurve der spektralen Distanzen kein "natürlicher" Schwellenwert c zur Trennung von I_h und I_f , so wird ein bestimmter Perzentilwert der Verteilung gewählt. Bilden die Probepunkte, aus denen die Verteilungskurve der spektralen Distanzen gewonnen wurde, ein gleichmäßiges Gitter auf dem Bild, so ergibt die Wahl von c einen Schätzwert für den Flächenanteil $A(I_h)$ des Homogenitätsbildes I_h .

Ist $S(d_U)$ die Verteilungsfunktion der spektralen Distanzen d_U , so gilt (vgl. Abb. 54)

$$(5.2.9) \quad A(I_h) = S(c), \quad (0 \leq A \leq 1),$$

wobei der Schätzwert A umso besser sein wird, je feiner das Probepunkte-Gitter gewählt wird.

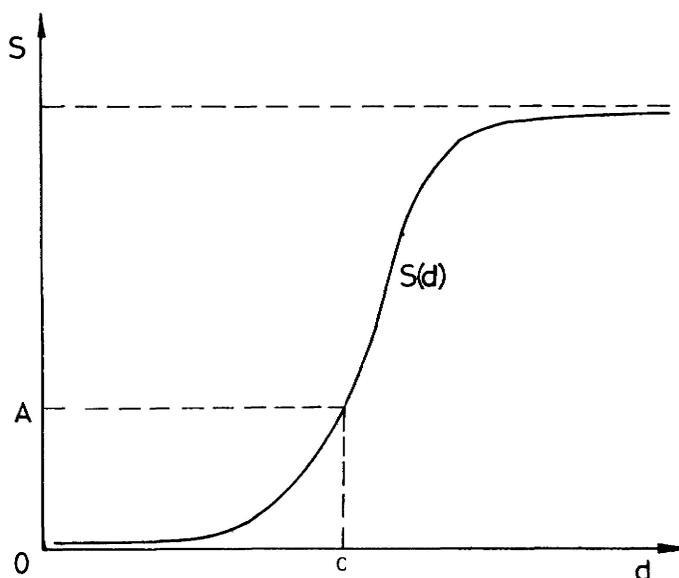


Abb. 54: Darstellung des Zusammenhangs zwischen der Verteilungsfunktion $S(d)$ der spektralen Distanzen d , dem Schwellenwert c und dem Schätzwert für $A(I_h)$.

Umgekehrt kann aus der a priori-Kennntnis von $A(I_h)$ oder aus einer visuellen Schätzung des Flächenanteils der "homogenen" Flächen durch Umkehrung von (5.2.9) eine passende Schranke c gefunden werden.

Die Wahl von c hat unmittelbare Auswirkungen auf den Rechenzeitbedarf für die anschließende Klassifizierung, da die Berechnung der Texturparameter, je nach Größe des Bestimmungsquadrats, um einen Faktor 10 - 100 größer ist, als die Erstellung des Signaturvektors.

So dauert die Klassifizierung einer Landsat-Subszene von 140 x 130 Pixel mit Hilfe von Signaturwerten am Großrechner TR 440 etwa 10 s, auf der Basis von Texturparametern ($B = 11 \times 11$ Pixel, 10 Parameter) jedoch 633 s - ein Wert, der für praktische Anwendungen auf eine ganze Landsat-Szene untragbar ist. Eine Reduktion dieser Rechenzeit ist durch Reduktion der Parameterzahl, durch Verkleinerung der Bestimmungsfläche und durch passende Wahl des Schwellenwerts c möglich.

Die Bildsegmentierung gliedert sich somit in folgende Schritte:

- Auswahl einer genügend großen Stichprobe von Bildpunkten (zufällig verteilt oder als regelmäßiges Gitter);
- Berechnung und Ausgabe der spektralen Distanzen (gleichzeitig mit Signaturwerten und Texturparametern);
- Darstellung der Verteilungsfunktion der spektralen Distanzen und Wahl einer passenden Schranke c nach den oben beschriebenen Gesichtspunkten.

Die folgenden Abbildungen zeigen eine Subszene (Ofouni-Granit), die nach Wahl von c in ein Homogenitätsbild I_h (Abb. 55) - hier schon nach Signaturklassen untergliedert - und ein Inhomogenitätsbild I_i (Abb. 56) entsprechend der Entscheidungsregel (5.2.8) segmentiert wurde. (Weitere Erläuterungen zu diesen Bildern in Kap. 5.3).

5.3 Klassifizierung des segmentierten Bildes

Nach den in den Kap. 3 und Kap. 4 dargestellten Methoden kann nach der Segmentierung des Bildes die Klassifizierung nach Signaturwerten in I_h und nach Texturparametern in I_i vorgenommen werden.

Die Texturparameter werden nur für einen Spektralkanal berechnet. Bei geologischen Fragestellungen bietet sich hierzu der Landsat-Kanal 6 an, denn in diesem Kanal spielt das Streulicht praktisch keine Rolle und der Grautonbereich umfaßt die Werte zwischen 0...127 (in Kanal 7 nur die Werte 0...63), so daß die Gesteinstexturen besonders deutlich werden.

Diese Auswahl ist stärker an praktischen Erfahrungen orientiert, als an methodischen Notwendigkeiten. Die Korrelationen zwischen entsprechenden Texturparametern in den verschiedenen Spektralkanälen sind jedoch so hoch (bei 0.90; vgl. Tab. 3), daß die Klassifizierung bei Verwendung eines anderen Kanals kaum wesentliche Änderungen bringen würde. (Prinzipiell kann bei der Auswahl des Spektralkanals nach der in Kap. 4.3 beschriebenen Methode verfahren werden: es werden Texturparameter für eine Stichprobe aus allen Spektralkanälen berechnet und derjenige Kanal ausgewählt, der bei der Trennung der Gruppen durch Klassifikatoren die geringste Fehlerquote aufweist.)

Ausgangspunkt der Klassifizierung ist eine Stichprobe, die neben der spektralen Distanz zu den Nachbarpunkten die Signatur- und Texturparameter der ausgewählten Pixel enthält. Die Stichprobe kann nach bestimmten Testgebieten geordnet sein (für eine überwachte Klassifizierung SCL) oder ungeordnet, nach zufälliger Wahl von Bildzeile und -spalte (für eine nicht-überwachte Klassifizierung USCL).

Während sich die Wahl der Homogenitätsschranke c aus der Verteilungsfunktion aller spektralen Distanzen der Stichprobe ergibt, können die Mittelpunktsvektoren und Trennfunktionen für die einzelnen Klassen (Gesteinseinheiten) erst nach der Wahl von c bestimmt werden. Bei den folgenden Klassifizierungsbeispielen wird von einer Stichprobe vom Umfang n ($200 \leq n \leq 500$) ausgegangen, die k verschiedene Klassen K_i mit jeweils n_i Bildpunkten enthält. Es gilt somit

$$(5.3.1) \quad n = \sum_{i=1}^k n_i .$$

Durch die Wahl der Schranke c wird jede Klasse K_i in zwei Unterklassen S_i, T_i zerlegt (wobei eine der beiden Unterklassen leer sein kann) für die gilt

$$(5.3.2) \quad S_i = \{ \underline{x} \mid \underline{x} \in K_i, \quad d_U(\underline{x}) < c, \quad i = 1, \dots, k \}$$

$$(5.3.3) \quad T_i = \{ \underline{x} \mid \underline{x} \in K_i, \quad d_U(\underline{x}) \geq c, \quad i = 1, \dots, k \}$$

$$(5.3.4) \quad K_i = S_i \cup T_i \quad \text{und} \quad S_i \cap T_i = \emptyset .$$

Nach diesen Bedingungen errechnen sich die Mittelpunktsvektoren bzw. die Diskriminanzfunktionen der einzelnen Klassen S_i, T_i ($i = 1, \dots, k$).

Für die Klassifizierung ergibt sich hieraus das folgende Ablaufschema:

1. Einlesen des nächsten Pixels \underline{x}
2. Berechnung der spektralen Distanz $d_U(\underline{x})$
3. Abfrage $d_U(\underline{x}) < c$?





Abb. 55: Homogenitätsbild einer Subszene (Umgebung Ofouni) in Signaturklassen weiter untergliedert (vgl. Kap. 5.3). Das Inhomogenitätsbild ist weiß.



Abb. 56: Komplementärbild von Abb. 55: das Inhomogenitätsbild ist mit Symbolen ("%", "=") gedruckt, das Homogenitätsbild ist weiß.

- | <u>ja</u> | <u>nein</u> |
|----------------------------|--|
| 4. Signaturklassifizierung | Berechnung der Texturparameter |
| 5. $x \in S_i$ | Texturklassifizierung
$\underline{x} \in T_j$ |
| 6. Sprung nach 1. | |

Als erstes Beispiel für diese Art der Klassifizierung wurde die Granitintrusion bei Ofouni gewählt (TG1), eine fast kreisförmige Struktur (vgl. Abb. 57, oben links), in deren nördlichen Teil der Granit nahezu völlig erodiert und eingesandet ist, während im südlichen Teil ein starkes Relief ausgebildet ist.

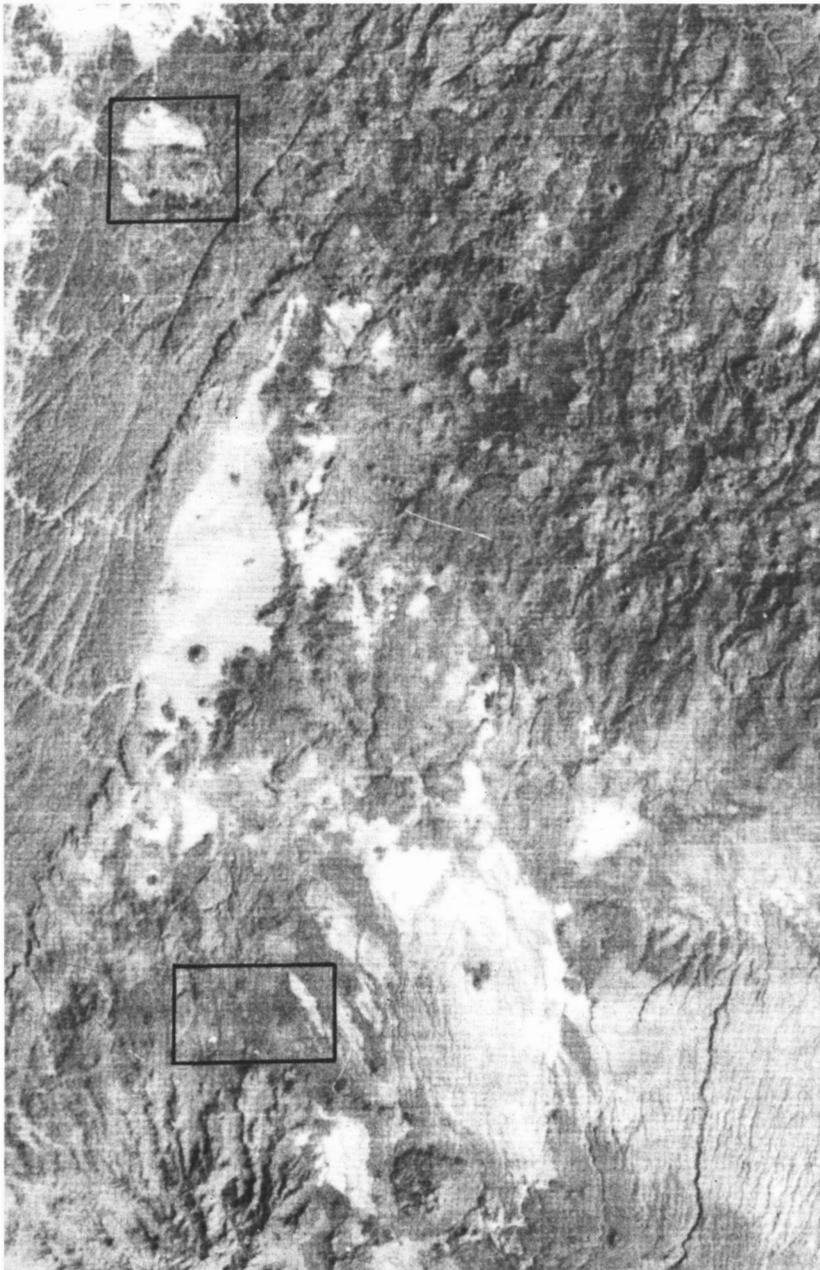


Abb. 57: Ausschnitt aus der Landsat-Szene E-12o9 - o8491 (Umgebung Bardai, Tschad) mit den Testgebieten TG1 (oben) und TG2 (unten). Charakteristische Gesteinstexturen: Basalt (rechts oben), Metamorphit (Bildmitte links), Ignimbrit (rechts unten), Sand (helle elliptische Fläche).

Das umgebende Gestein sind metamorphe Schiefer, teilweise sind Reste von Basaltdecken vorhanden (z. B. an der Grenze Sand/Granit).

Durch die starke Licht- und Schattenwirkung des Reliefs ist die Streuung der Grautonverteilung von Granit so groß, daß in allen Spektralkanälen starke Überlappungen mit Grautonverteilungen anderer Gesteinseinheiten (z. B. Metamorphit, vgl. Abb. 27) auftreten.

Betrachtet man das Homogenitätsbild I_h von TGI, so erkennt man ein sehr unruhiges Muster, wobei nur die Sandflächen (Symbol ":") größere zusammenhängende Flächen bilden. Das Inhomogenitätsbild I_i ist stark mit I_h verzahnt. Erst wenn man beide Bilder zusammenfaßt, d. h. die Signaturklassen S_i und die zugehörigen Texturklassen T_i mit demselben Symbol versieht, ergibt sich ein Bild (Abb. 58), das sehr einheitlich ist und die tatsächliche Verteilung der Gesteinseinheiten gut erfaßt: die nahezu kreisförmige Granitintrusion ("-"), die Sandflächen (":"), die Metamorphithülle ("+") und Basaltreste (" ").

Bemerkungen:

Die Verzerrung der Kreisstruktur in Abb. 58 hat ihre Ursache im unterschiedlichen Bildmaßstab des Druckerbildes in Zeilen- und Spaltenrichtung.

Fehlklassifizierungen treten vor allem im Bereich der Basalte auf, da für diese (wegen der kleinen Flächenanteile) keine Texturparameter berechnet werden konnten. Die breiten, mit Sand und Geröll bedeckten Trockentäler im Süden werden ebenfalls als Granit klassifiziert; die Gesamtzahl der Fehlklassifizierungen liegt bei 6 % (durch Vergleich mit Luftbild und Zählung der Fehlerpixel geschätzt).

Als weiteres Testgebiet (TG2) wurde ein Bildausschnitt südlich von Bardai gewählt, in dem auf engem Raum Sandstein, Basalt und Ignimbrit aneinandergrenzen. Die Größe des Testgebiets ist 150 x 400 Bildpunkte. Eine überwachte Signaturklassifizierung mit der nearest-neighborhood-Methode erbrachte eine Fehlerrate von 25 %.

Führt man eine Bildsegmentierung nach I_h und I_i durch, so erkennt man, daß inhomogene Bereiche vor allem in Gebieten auftreten, in denen verschiedene Gesteinseinheiten aneinandergrenzen (Abb. 59).

Eine Zusammenfassung der entsprechenden Signatur- und Texturklassen erbringt auch hier eine klarere Verteilung der Sandsteine ("%"), der Ignimbrite ("+") und der Basaltdecke (":") - vgl. Abb. 60.

Der Zusammenhang zwischen den einzelnen Textur- und Signaturklassen wird im westlichen Teil von TG2 deutlich (Abb. 61). Die Texturklassen sind mit Ziffern bezeichnet, die Signaturklassen mit Drucker-Sonderzeichen (Sandstein: "1,%"; Basalt: "2,."; Ignimbrit: "3,+").

Man erkennt, daß kleine Gruppen von Ziffern oder Sonderzeichen fast stets in den zugehörigen Komplementärklassen liegen (z. B. "2" in größeren Flächen mit ":" - Basalt). Die kombinierte Signatur-Texturklassifizierung wirkt wie ein "low-pass-Filter", bei dem singuläre Pixel eliminiert werden, indem man sie derselben Klasse zuordnet, der die Umgebungspixel angehören. Durch diesen Bereinigungseffekt entstehen Bilder, die für eine geologische Interpretation besser geeignet sind als solche, die durch Signatur- oder Texturklassifikation allein erzeugt werden können.

5.4 Diskussion und Ausblick

Aus den vorliegenden Untersuchungen ergibt sich, daß die Spektralkanäle des Landsat-Satellitensystems für geologische Fragestellungen nicht optimal ausgewählt sind. Solange keine anderen Daten in ausreichendem Umfang vorliegen, können durch kombinierte Signatur-Textur-Untersuchungen Verbesserungen bei der digitalen Bildauswertung erzielt werden. Bei der Untersuchung der Signifikanz der verschiedenen Texturparameter zeigt sich, daß zwei Aspekte eine wesentliche Rolle spielen:

1. die statistische Verteilung der Grautonwerte in einer Umgebung (Bestimmungsfläche) des Zentralpixels - ausgedrückt durch Parameter wie Streuung, Körnigkeit, Homogenität;
2. die räumliche Anordnung von Elementartexturen - ausgedrückt durch "Nachbarschaftsmatrizen", Zahl der



Abb. 58: Zusammenfassung der Signatur- und Texturklassen zu einer Gesamtklassifizierung nach der in Kap. 5.3 beschriebenen Methode (Bedeutung der Symbole: s. Text).



Abb. 59: Signaturklassen in Testgebiet TG2. Sandstein: "%", Basalt: ":", Ignimbrite: "+", Inhomogenitätsflächen sind weiß.



Abb. 60: Zusammenfassung der Signatur- und Texturklassen aus Abb. 59 zu einer Gesamtklassifizierung.



Abb. 62: Zusammenfassung der Signatur- und Texturklassen aus Abb. 61 zu drei Gesteinsklassen: "%": Sandstein, ":" Basalt, "+" Ignimbrit.

Grautonschwankungen in verschiedenen Richtungen, Korrelation der Grautonwerte benachbarter Bildpunkte etc.

Die Größe der Bestimmungsfläche, die zur Berechnung der Texturparameter verwendet wird, vergrößert bei der reinen Texturklassifizierung die Fehlerrate an Texturgrenzen. FIEDLER (1979) hat die Verwendung variabler Umgebungsgröße vorgeschlagen, um die Fehlerrate an Texturgrenzen zu verringern. Die in Kap. 5 beschriebene Methode der gemischten Signatur-Textur-Klassifizierung umfaßt diesen Verbesserungsvorschlag in folgendem Sinn: liegt ein Bildpunkt im Homogenitätsbild, so genügt für eine Klassenzuordnung der Signaturvektor, d. h. eine 2 x 2 oder 3 x 3-Umgebung, die zur Homogenitätsabfrage benötigt wird; unterschiedliche Gesteinstexturen sind meist durch deutliche Störungszonen voneinander getrennt (im Untersuchungsgebiet sind dies oft mit Sand und Abtragungsschutt bedeckte Trockentäler), die kleine, homogene Bildbereiche ergeben und damit verschiedene Texturflächen durch linear angeordnete, homogene Bildelemente trennen. Eine weitere Bildsegmentierung kann vorgenommen werden, wenn außer den Signatur- und Texturparametern weitere Merkmalswerte (z. B. Geländebeobachtungen, geophysikalische und geochemische Untersuchungsergebnisse) in passender Form zur Klassifizierung herangezogen werden. Diese zusätzlichen Daten sind meist Punktbeobachtungen oder Profile im Bildbereich, die in einer Datenbank abgespeichert werden können. Kann beim Klassifizierungsprozeß aufgrund der Signaturwerte keine Zuordnung eines Bildpunktes vorgenommen werden, wird in der Datenbank abgefragt, ob andere Informationen vorliegen oder ob Texturparameter berechnet werden müssen.

Die größeren Zugriffszeiten auf bild-externe Information und die hohen Rechenzeiten für die Texturparameter legen jedoch nahe, bei künftigen Satellitenmissionen auf eine Ausweitung des Spektralbereichs ins mittlere und thermale Infrarot hinzuwirken, um auch für geologische Fragestellungen aussagekräftigere Merkmalswerte zu erhalten.

6. LITERATURVERZEICHNIS

- ALBERTZ, J. (1970): Sehen und Wahrnehmen bei der Luftbildinterpretation. - Bildmessung u. Luftbildwesen, 38, 25 - 34.
- ANDERSON, D.M., MCKIM, H. L., GATTO, L. W., HAUGEN, R. K. & CROWDER, W. K. (1973): The use of ERTS-1 imagery in the regional interpretation of geology, vegetation, perma frost distribution and estuarine processes in Alaska. - Remote Sensing of Earth Resources, 2, 1049 - 1071.
- ANDERSON, T.W.:(1958): An introduction to multivariate statistical analysis. - 374 S., New York (Wiley).
- BÄHR, H. P. (1976): Geometrische Modelle für Abtasteraufzeichnungen von Erderkundungssatelliten. - Bildmessung u. Luftbildwesen, 44, 198 - 202.
- BÄHR, H. P. & SCHUR, W. (1974): Versuche zur Ermittlung der geometrischen Genauigkeit von ERTS-Multispektralbildern. - Bildmessung u. Luftbildwesen, 42, 22 - 24.
- BALLEW, G. I. (1975): Correlation of Landsat-1 multispectral data with surface chemistry. - Proc. Tenth. Int. Symp. on Remote Sensing of Environment, 1045 - 1055.
- BAMFORD, R. W. (1972): The Mount Fubilan (Ok Tedi) porphyry copper deposit, territory of Papua and New Guinea. - Economic Geol., 67, 1019 - 1033.
- BESAG, J. E. (1972): On the correlation structure of some two-dimensional stationary processes. - Biometrika, 59, 43 - 48.
- BLACKITH, R.E. & REYMENT, R.A. (1971): Multivariate morphometrics. - 412 S., London, New York (Academic Press).
- BODECHTEL, J. & HAYDN, R. (1977): Analog and digital processing of multispectral data for geologic application. - Remote Sensing of the Terrestrial Environment (Ed.: PEEL, R. F., CURTIS, L. F. & BARRETT, E. C.), 159 - 168.
- BROCKMANN, C. E., FERNANDEZ, R. B. & CLAURE, H. (1977): Analysis of geological structures based on Landsat-1 images. - Remote sensing applications for mineral exploration (Ed.: SMITH, W. L.), 292 - 317.
- BRODATZ, P. (1966): Textures. - New York (Dover Publ. Inc.).
- BURGER, H. (1976): Log-normal interpolation in grain size analysis. - Sedimentology, 23, 395 - 405.
- BURGER, H. (1978): Classification of rocks on the basis of signatures and texture-measures from Landsat imagery. - Proc. Image Processing - Interactions with Photogrammetry and Remote Sensing. Graz, 1977, 33 - 35.
- CASSINS, R. (1975): Applications of satellite studies for structural geology in Italy. - Remote Sensing of the Terrestrial Environment (Ed.: PEEL, R. F., CURTIS, L. F. & BARRETT, E. C.), 169 - 181, London (Butterworths).
- COLVOCORESSES, A. P. (1972): Image resolution for ERTS, SKYLAB and GEMINI-APOLLO. - Photogram. Eng., 38, 33 - 35.
- COLVOCORESSES, A. P. & McEWEN, R. B. (1973): EROS cartographic progress. - Photogram. Eng., 39, 1303 - 1309.
- COOLEY, W. W. & LOHNES, P. R. (1971): Multivariate data analysis. - 364 S., New York (Wiley).
- DAVIS, J.C. (1973): Statistics and data analysis. - 550 S., New York (Wiley).
- DUDA, R.O. & HART, P.E. (1973): Pattern classification and scene analysis, - 482 S., New York (Wiley).
- DURAN, B.S. & ODELL, P.L. (1974): Cluster analysis. A Survey. - 137 S., Berlin (Springer).
- ERGENZINGER, P. (1978): Das Gebiet des Enneri Misky im Tibesti-Gebirge, Republique du Tchad. Erläuterungen zu einer geomorphologischen Karte 1 : 200 000. - Berliner geogr. Abh., 23, 49 S., Berlin.
- FELLER, W. (1971): An introduction to probability theory and its applications. - Bd. 2, 669 S., New York (Wiley).
- FIEDLER, R. (1979): Beitrag zur automatischen Untersuchung und Erkennung von Texturen in digitalen Bildern aus der Fernerkundung. - Forschungsbericht DFVLR - FB 79-08, 243 S., Köln.
- FOITH, J.P. (1977): Ein hierarchisches Textur-Modell. - Digitale Bildverarbeitung (Ed.: NAGEL, H.-H.), 252 - 259, Berlin (Springer).
- FUKUNAGA, K. (1972): Introduction to statistical pattern recognition. - 369 S., New York (Academic Press).
- GABRIEL, A. (1961): Die Wüsten der Erde und ihre Erforschung. - 167 S., Berlin (Springer).
- GALLOWAY, M. M. (1975): Texture analysis using gray level run length. - Comp. Graphics and Image Proc., 4, 172 - 179.
- GONTHER, R. (1972): Remote Sensing in der Geologie. Möglichkeiten und Probleme der Erderkundung mit Hilfe von Flugzeugen und Satelliten. - Forschungsbericht W 72-29 Weltraumforschung des Bundesm. für Bildung und Wissenschaft, München.

- HABERACKER, P. (1978): Untersuchungen zur Klassifizierung multispektraler Bilddaten aus der Fernerkundung. - Diss., 134 S., Berlin.
- HAGEDORN, H. (1971): Untersuchungen über Relieftypen arider Räume an Beispielen aus dem Tibesti-Gebirge und seiner Umgebung. - Z. Geomorph., Suppl.-Bd., 11, 251 S., Berlin.
- HALBOUTY, T. M. (1975): Application of remote sensing (Landsat data) to petroleum exploration. - Proc. First Annual Pecora Symp., Sioux Falls, South Dakota, 19 - 32.
- HARALICK, R. M. (1971): On a texture-context feature extraction algorithm for remotely sensed imagery. - Proc. IEEE Decision and Control Conf., Gainesville, Florida, 650 - 657.
- HARALICK, R. M., SHANMUGAN, K. & DINSTEIN, I. (1973): Textural features for image classification. - IEEE Trans. on System, Man and Cybernetics, 3, 610 - 621.
- HARALICK, R. M. (1973): Glossary and index to remotely sensed pattern recognition concepts. - Pattern Recogn., 5, 391 - 403.
- HARALICK, R. M. & BOSLEY, R. (1973): Spectral and textural processing of ERTS-imagery. - Third Earth Res. Techn. Satellite-1 Symp., 1, Techn. Pres. Sec. B, 1929 - 1970.
- HARALICK, R. M. & SHANMUGAN, K. (1974): Combined spectral and spatial processing of ERTS imagery data. - Remote Sensing of Environment, 3, 3 - 13.
- HARALICK, R. M. (1978): Statistical and structural approach to texture. - Proc. Int. Symp. Remote Sensing for Observations and Inventory of Earth Resources and the Endangered Environment, 379 - 431.
- HARTL, P., ROSE, P. & SCHULZ, R. (1978): Klassifizierung von Objekten multispektraler Bilder mit unsupervised Methoden unter besonderer Berücksichtigung der natürlichen Texturen. - Endbericht Forschungsvorh. m. d. Kennziffer 01 QS 496 - ZA/SNA WEO2 75-4.2, Inst. f. Luft- und Raumfahrt d. TU Berlin.
- HELMCKE, D., LIST, F. K. & ROLAND, N. (1976): Geologische Interpretation von Luft- und Satellitenbildern des Tibesti-Gebirges (Zentral-Sahara, Tschad). - Geol. Jb., A33, 89 - 115.
- HODGSON, R. A. (1975): Regional linear analysis as a guide to mineral resource exploration using Landsat (ERTS) data. - Geol. Surv. Prof. Paper 1015, 155 - 171.
- HOUSTON, R. S., MARRS, R. W., SHORT, N. M. & LOWMAN, P. D., Jr. (1977): Earth observations from remote-sensing platforms: outlook. - Remote sensing appl. for mineral exploration (Ed.: SMITH, W. L.), 99 - 156, Stroudsburg, PA.
- HUNT, G. R. & SALISBURY, J. W. (1970): Visible and near-infrared spectra of minerals and rocks: I, Silicate minerals. - Modern Geology, 1, 283 - 300.
- HUNT, G. R. & SALISBURY, J. W. (1971): Visible and near-infrared spectra of minerals and rocks: II, Carbonates. - Modern Geology, 2, 23 - 30.
- KAISER, K. (1972): Prozesse und Formen der ariden Verwitterung am Beispiel des Tibesti-Gebirges und seiner Rahmenbereiche in der zentralen Sahara. - Berliner Geogr. Abh., 16, 59 - 92, Berlin.
- KLITZSCH, E. & LIST, F. K. (Ed.) (1978): Southwest Egypt 1 : 500 000 - Geological interpretation map, Prelim. Ed.: Sheet 2525 Ammonite Hills, Sheet 2825 El Kharga, Sheet 2523 Gilf Kebir, Sheet 2832 Baris, Sheet 2527 Farafra, Sheet 2827 El Minya, Sheet 2521 Gebel Uweinat, Sheet 2821 Selima. - Berlin.
- KONECNY, G. (1976): Mathematische Modelle und Verfahren zur geometrischen Auswertung von Zeilenabtaster-Aufnahmen. - Bildmessung u. Luftbildwesen, 44, 188 - 197.
- KRATKY, V. (1974): Cartographic accuracy of ERTS. - Photogram. Eng., 40, 203 - 212.
- KREYSZIG, E. (1968): Statistische Methoden und ihre Anwendungen. - 422 S., 3. Auf., Göttingen (Vandenhoeck & Ruprecht).
- LEE, K. (1974): Geologic information from satellite images. - Remote Sensing of Environment, 3, 411 - 447.
- LEOPOLD, L. B. & LANGBEIN, W. B. (1962): The concept of entropy in landscape evolution. - U. S. Geol. Prof. Paper 500-A, 20 S.
- LIST, F. K., ROLAND, N. & HELMCKE, D. (1974): Comparison of geological information from satellite imagery, aerial photography and ground investigations in the Tibesti Mountains, Chad. - Proc. Symp. Remote Sensing and Photointerpretation. Banff, Alberta. Oct., 7 - 11, 543 - 553.
- LIST, F. K. & PÖHLMANN, G. (1976): Geologische Interpretation des Tibesti 1 : 1 000 000 - Beispiel für eine thematische Auswertung von Landsat-1 Bildern. - Z. dt. geol. Ges., 127, 485 - 498.
- LIST, F. K., BURGER, H., KLITZSCH, E., MEISSNER, B., PÖHLMANN, G. & SCHMITZ, H. (1978): Geological interpretation of Landsat-imagery of Southwestern Egypt. - Proc. Int. Symp. for Observation and Inventory of Earth Resources and the Endangered Environment, Freiburg, 2195 - 2208.
- LIST, F. K., HELMCKE, D., MEISSNER, B., PÖHLMANN, G., ROLAND, N. W. (1978): Geologische Interpretation des Tibesti nach Aufnahmen von Landsat-1 (Republik Tschad). - Bildmessung u. Luftbildwesen, 46, 139 - 145.

- LYON, R. J. P. (1970): The multiband approach to geological mapping from orbiting satellites: is it redundant or vital. - Remote Sensing of Environment, 1, 237 - 244.
- LYON, R. J. P. (1975): Mineral exploration applications of digitally processed Landsat imagery. - Geol. Surv. Prof. Paper, 1015, 271 - 292.
- MARSAL, D. (1967): Statistische Methoden für Erdwissenschaftler. - 152 S., Stuttgart (Schweizerbart'sche Verlagsbuchhandlung).
- MERCANTI, E. P. (1977): Summary of Landsat applications and results. - Remote sensing applications for mineral exploration (Ed.: SMITH, W. L.), 42 - 72.
- MOORE, G. K. & HOLLYDAY, E. F. (1975): Prospecting for ground water with Skylab photographs, Central Tennessee. - Remote Sensing of Earth Resources, 4, 499 - 520.
- MORRISON, D. F. (1967): Multivariate statistical analysis. - 338 S., New York (McGraw-Hill).
- NASA: Landsat data users handbook. - U. S. Geol. Survey.
- NIEMANN, H. (1974): Methoden der Mustererkennung. - 482 S., Frankfurt a. Main (Akadem. Verlagsanstalt).
- OFFIELD, T. W., ABBOTT, E. A., GILLESPIE, A. R. & LOGUERCIO, S. O. (1977): Structure mapping on enhanced Landsat images of Southern Brazil: Tectonic control of mineralization and speculations on metallogeny. - Geophysics, 42, 482 - 500.
- PAGE, R. W. & McDOUGALL, I. (1972): Ages of mineralization of gold and porphyry copper deposits in the New Guinea Highlands. - Econ. Geol., 67, 1034 - 1048.
- RAINA, B. N. & SHARMA, S. K. (1974): Tectonic and geomorphical interpretations from a satellite photograph of Kutch-Aravalli region. - Remote Sensing of Environment, 3, 397 - 409.
- RAINES, G. L. & LEE, K. (1974): An evaluation of multiband photography for rock discrimination. - Remote Sensing of Environment, 3, 361 - 396.
- REEVES, R. G. (Ed.) (1975): Manual of remote Sensing. - 2 Bde., Falls Church, VA.
- ROLAND, N. (1973): Die Anwendung der Photointerpretation zur Lösung stratigraphischer und tektonischer Probleme im Bereich von Bardai und Aozou (Tibesti-Gebirge, Zentral-Sahara). - Berliner Geogr. Abh., 19, Berlin.
- ROSENFELD, A. & KAK, A. C. (1976): Digital picture processing. - 458 S., New York (Academic Press).
- ROWAN, L. C., GOETZ, A. F. H. & ASHLEY, R. P. (1977): Discrimination of hydrothermally altered and unaltered rocks in visible and near infrared multispectral images. - Geophysics, 42, 522 - 535.
- ROWAN, L. C., WETTLAUFER, P. H., GOETZ, A. F., BILLINGSLEY, F. C. & STEWARD, J. H. (1974): Discrimination of rock types and detection of hydrothermally altered areas in southcentral Nevada by use of computer enhanced ERTS images. - U. S. Geol. Prof. Paper, 883, 35 S.
- SCHEIDEGGER, A. E. (1970): Theoretical geomorphology. - 435 S., Berlin (Springer).
- SCHUR, W. (1976): Digitale Entzerrung multispektraler Bilder. - Bildmessung u. Luftbildwesen, 44, 202 - 208.
- SMITH, W. L. (Ed.) (1977): Remote sensing applications for mineral exploration. - 391 S., Stroudsburg, Pa. (Dowden, Hutchinson & Ross Inc.).
- STANICOFF, A. (1973): ERTS application to mineral exploration in Sonora, Mexico. - Symp. Proc. Management and Utilization of Remote Sensing Data, 313 - 332.
- STOCK, P. (1972): Photogeologische und tektonische Untersuchungen am Nordrand des Tibesti-Gebirges, Zentral-Sahara, Tchad. - Berliner Geogr. Abh., 14.
- TARANIK, J. V. (1978): Characteristics of the Landsat multispectral system. - U. S. Dept. of the Int. Geol. Surv. Open File Report, 78 - 187.
- THOMSON, F. & SADOWSKI, F. (1975): A study of atmospheric effects on pattern recognition devices. - NASA Report No. CR-ERIM 193300-62-F.
- TRIENDL, E. (1973): Texturerkennung und Texturreproduktion. - Kybernetik, 13, 1 - 5.
- VELDMAN, D.J. (1967): FORTRAN programming for the behavioral sciences. - 406 S., New York (Holt, Rinehart and Winston).
- VILJOEN, R. P., VILJOEN, M. J. & GROOTENBOER, J. (1975): ERTS imagery: an appraisal of applications in geology and mineral exploration. - Mineral Sci. Eng., 7, 132 - 168.
- VINCENT, R. K. (1977): Uranium exploration with computer processed Landsat data. - Geophysics, 42, 536 - 541.

Anhang

A1: Bildmaterial und Computerprogramme

Für die vorliegende Arbeit wurden folgende Landsatzenen verwendet (allgemeine Lageskizze s. Kap. 3.1):

E 12o9-o8494	südl. Toussidee, Tschad
E 119o-o8433	süd-östl. Toussidee
E 12o9-o8491	Bardai und nördlich (Tschad)
E 1197-o741o	Bajudasteppes (Sudan)
E 1o28-oo134	Frieda River (Neu Guinea)
E 1112-o8o8o	Double Scarp (Ägypten)
E 11o9-o7495	Wadi Quena (Ägypten)

Bildmaterial und Magnetbänder für Mitteleuropa und Nordafrika erhält man bei

DFVLR - GSOC
NPOC - Datenmanagement
8o31 Oberpfaffenhofen

und für andere Gebiete der Erdoberfläche bei

U.S. Geological Survey
EROS Data Center
Sioux Falls, SD 57198

oder bei regionalen Empfangsstationen z. B. in Kanada, Indien, Brasilien und Schweden.

Kurzbeschreibung der verwendeten Computerprogramme

Folgende Programme zur digitalen Bildverarbeitung wurden im Rahmen der vorliegenden Arbeit entwickelt und eingesetzt:

ERTS 1:	Statistik der Grautonverteilung in allen Landsatkanälen; Histogrammdarstellungen
ERTS 2:	Grautonsimulation
CORNER:	Ausgabe von Grautonwerten in Trainingsgebieten; Statistik für die überwachte Klassifizierung
RAMPEL:	Auswahl von Zufallsbildpunkten und Darstellung in Scattergrammen
PCA:	Hauptkomponentenanalyse
DIST:	Clusteralgorithmus zur unsupervised classification
MDISPL:	Scattergramme von Variablen im zweidimensionalen Merkmalsraum, wobei verschiedene Klassen mit verschiedenen Symbolen dargestellt werden
MDISK:	Multiple lineare Diskriminanzanalyse
KOMPAKT:	Extraktion eines Landsatbildes aus den 4 Kanälen und Vorbereitung zur Ausgabe auf Film am HELL-Chromographen
TRAFO:	verschiedene Bildtransformationen: Linearkombination, Quotientenbilder, Normierung auf frei wählbaren Mittelwert und Streuung
ACOR 1:	Berechnung der eindimensionalen Autokorrelationsfunktion (z. B. für eine Scanlinie)
ACOR 2:	Berechnung der zweidimensionalen Autokorrelationsfunktion
SIGKL:	Programm zur Klassifizierung mit Hilfe der Signaturen
TEXKL:	Programm zur Klassifizierung mit Hilfe von Texturparametern
TEXPAR:	Extraktion von Texturparametern aus ERTS-Bildern und ihre statistische Analyse
TEXSIG:	Klassifizierung mit Hilfe von ausgewählten Signatur- und Textur-Klassen
AREG:	Simulation von Texturen mit Hilfe eines Autoregressionsmodells.

Bei der Erstellung der Programme wurden Unterprogramme aus der Programmbibliothek des Großrechenzentrums

für die Wissenschaft Berlin, von DAVIS (1973) und von VELDMAN (1967) verwendet. Das Programm zur Darstellung von Grautonbildern stammt im wesentlichen von Herrn Jacobs, Inst. für Luft- und Raumfahrt der TU Berlin. Die Programme wurden am TR 44o entwickelt und zum Teil auch am EARTHVIEW-System adaptiert.

A2: Varianzanalyse

Liegen k Klassen K_i ($i = 1, \dots, k$) vor mit n_i Elementen $x_{j,i}$ ($j = 1, \dots, n_i$) in jeder Klasse, so gilt für die Klassenmittelwerte

$$(A2.1) \quad m_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{j,i}$$

und für die Varianzen

$$(A2.2) \quad \sigma_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (x_{j,i} - m_i)^2$$

Man testet die Nullhypothese

$$(A2.3) \quad H_0: m_1 = m_2 = \dots = m_k = m,$$

wobei m den Gesamtmittelwert bezeichnet. Diese Hypothese wird verworfen, wenn die Varianz zwischen den Klassenmittelwerten σ_z^2 signifikant größer ist, als die Varianz σ_i^2 innerhalb der Klassen:

$$(A2.4) \quad \sigma_z^2 = \frac{1}{n-k} \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{i,j} - m_i)^2$$

$$(A2.5) \quad \sigma_z^2 = \frac{1}{k-1} \sum_{i=1}^k n_i (m_i - m)^2$$

Testgröße ist

$$(A2.6) \quad q = \frac{\sigma_z^2}{\sigma_i^2}$$

Sind die Merkmalswerte der Klassen normalverteilt mit gleicher Varianz, so folgt q einer F-Verteilung mit $(k-1, n-k)$ Freiheitsgraden. Bei vorgegebenem Signifikanzniveau α vergleicht man q mit dem F-Wert $c = c(\alpha, k-1, n-k)$ und verwirft H_0 , wenn $q > c$ (KREYSZIG 1972).

Im multivariaten Fall werden die entsprechenden Varianz-Kovarianzmatrizen verglichen: sind \underline{m}_i ($i = 1, \dots, k$) die Mittelpunktsvektoren der Klassen (Klassencentroide) und $\underline{x}_{j,i}$ die n_i Merkmalsvektoren der Klasse K_i ($i = 1, \dots, k$), so ergibt sich für die Varianz-Kovarianzmatrix A zwischen den Klassen und W innerhalb der Klassen

$$(A2.7) \quad A = \sum_{i=1}^k n_i (\underline{m}_i - \underline{m})(\underline{m}_i - \underline{m})'$$

$$(A2.8) \quad W = \sum_{i=1}^k \sum_{j=1}^{n_i} (\underline{x}_{j,i} - \underline{m}_i)(\underline{x}_{j,i} - \underline{m}_i)'$$

(man beachte, daß hier erst die Summen der "Abweichungsquadrate" stehen und die entsprechenden Mittelwerte nach Division durch $k-1$ bzw. $n-k$ erhalten werden).

Setzt man $T = A + W$ und

$$(A2.9) \quad \Lambda = \frac{W}{T},$$

so kann man Λ als Testgröße für die Hypothese

$$(A2.10) \quad H_0: \underline{m}_1 = \underline{m}_2 = \dots = \underline{m}_k = \underline{m}$$

benutzen (WILKS' Lambda). Es gibt verschiedene Möglichkeiten Λ mit einem F-Wert zu testen (COOLEY & LOHNES 1971). Wird H_0 verworfen, so kann man den univariaten F-Test benutzen, um festzustellen, welche Variablen am meisten zur Trennung $\underline{m}_i \neq \underline{m}$ beitragen.

A3: Hauptkomponententransformation versus Canonische Transformation

Standardisiert man die Variablen einer Datenmatrix auf Mittelwert 0 und Varianz 1, so wird bei der Hauptkomponententransformation (PCT) eine Transformation mit einem Vektor \underline{v} durchgeführt

$$(A3.1) \quad y = \underline{v}'\underline{z},$$

(\underline{z} ist ein Merkmalsvektor) wobei \underline{v} so gewählt wird, daß die Varianz der transformierten Variablen y maximal wird

$$(A3.2) \quad \frac{1}{n} \sum_{i=1}^n y^2 = \frac{1}{n} \sum_{i=1}^n \underline{v}'\underline{z}\underline{z}'\underline{v} = \underline{v}'R\underline{v}$$

(R ist die Korrelationsmatrix). Führt man die Nebenbedingung $\underline{v}'\underline{v}=1$ mit Hilfe eines Lagrange-Multiplikators ein, so ergibt sich die Extremalaufgabe

$$(A3.3) \quad \phi = \underline{v}'R\underline{v} - \lambda(\underline{v}'\underline{v} - 1) = \text{maximal.}$$

Differenziert man die quadratische Form ϕ , so ergibt sich

$$\frac{\delta\phi}{\delta\underline{v}} = (R - \lambda I)\underline{v} = \underline{0}.$$

Dies ist ein Eigenwertproblem mit symmetrischer Matrix R . Die Eigenwerte λ_i ergeben sich aus der Gleichung

$$(A3.4) \quad |R - \lambda I| = 0,$$

wobei jeder Eigenwert λ_i ($i = 1, \dots, m$) einen Eigenvektor als Transformationsvektor \underline{v}_i liefert. Da R positiv definit ist, sind alle Eigenwerte reell und positiv. Ordnet man sie der Größe nach, so wird der zum größten Eigenwert gehörige Eigenvektor \underline{v}_1 als erster Transformationsvektor benutzt, dann der zum zweitgrößten Eigenwert gehörige Eigenvektor \underline{v}_2 etc. Bricht man das Verfahren nach m' Eigenwerten ab ($m' < m$), so erfassen die transformierten Variablen nur

$$(A3.5) \quad 100 \cdot \frac{\sum_{i=1}^{m'} \lambda_i}{\sum_{i=1}^m \lambda_i}$$

Prozent der ursprünglichen Gesamtvarianz. Sind die Ursprungsvariablen hoch miteinander korreliert, so genügen oft 2 - 3 Eigenvektoren zur Erfassung von über 90 % der Gesamtvarianz.

Durch die Verwendung der Korrelationsmatrix R bleibt bei der PCT die Verteilung der Klassen im Merkmalsraum unberücksichtigt. Bei der Canonischen Variablentransformation CVT wird der Transformationsvektor \underline{v} so bestimmt, daß im transformierten Merkmalsraum die Varianz zwischen den Klassenmittelpunkten maximal und die Varianz innerhalb der Klassen minimal wird:

$$(A3.6) \quad \begin{aligned} \sigma_z^2 &= \underline{v}'A\underline{v} \\ \sigma_i^2 &= \underline{v}'W\underline{v} \end{aligned}$$

(Bezeichnungen wie in A2). Beide Bedingungen kann man erfassen, indem man fordert, daß der Quotient

$$\sigma_z^2 / \sigma_i^2$$

maximal wird. Analog zu (A3.3) ergibt sich die quadratische Form

$$(A3.7) \quad \underline{\phi} = \underline{v}' W^{-1} A \underline{v} - \lambda (v'v - 1) = \text{maximal}$$

Differenzierung nach \underline{v} ergibt ein Eigenwertproblem mit einer nichtsymmetrischen Matrix $W^{-1}A$

$$(A3.8) \quad |W^{-1}A - \lambda I| = 0.$$

Die zu λ_i ($i = 1, \dots, m'$) gehörigen Eigenvektoren werden nach einer Normierung zur canonicischen Transformation verwendet. Im Raum der transformierten Variablen sind die Mittelpunktsvektoren der Klassen optimal getrennt, so daß eine Klassifizierung in diesem Raum der Dimension $m' < m$ i. A. bessere Ergebnisse liefert als nach der PCT.

A4: Summen von normalverteilten Zufallsvariablen und Absolutbeträgen

Satz 1: Sind X_1, \dots, X_n normalverteilte unabhängige Zufallsvariable mit Mittelwerten μ_1, \dots, μ_n und Varianzen $\sigma_1^2, \dots, \sigma_n^2$, dann hat die Zufallsvariable Y mit

$$(A4.1) \quad Y = \sum_{i=1}^n X_i$$

den Erwartungswert

$$(A4.2) \quad E[Y] = \mu = \sum_{i=1}^n \mu_i$$

und die Varianz

$$(A4.3) \quad E[Y^2] = \sigma^2 = \sum_{i=1}^n \sigma_i^2.$$

Anwendung auf Differenzen von Zufallsvariablen:

Lemma 1: Sind X, Y normalverteilte unabhängige Zufallsvariable mit gleichem Mittelwert μ und gleicher Varianz σ^2 , so hat die Zufallsvariable $Z = X - Y$ den Mittelwert 0 und die Varianz $2\sigma^2$.

Lemma 2: Kann man die Werte einer Stichprobe x_1, \dots, x_n als beobachtete Werte von n Zufallsvariablen X_1, \dots, X_n ansehen, die alle dieselbe Verteilungsfunktion $N(\mu, \sigma^2)$ besitzen und unabhängig sind, so ist die Zufallsvariable

$$(A4.4) \quad \bar{X} = \frac{1}{n} (X_1 + \dots + X_n)$$

normalverteilt mit Mittelwert $E[\bar{X}] = \mu$ und Varianz

$$(A4.5) \quad E[(X - \mu)^2] = \frac{\sigma^2}{n}.$$

Satz 2: Gegeben seien zwei Zufallsvariable X, Y mit Erwartungswerten μ_x, μ_y , Varianzen σ_x^2, σ_y^2 und der Kovarianz σ_{xy}^2 , so hat die Zufallsvariable

$$(A4.6) \quad Z = X \pm Y$$

den Erwartungswert $\mu_z = \mu_x \pm \mu_y$ und die Varianz

$$(A4.7) \quad \sigma_z^2 = \sigma_x^2 + \sigma_y^2 + \sigma_{xy}^2.$$

Bemerkung: Die Größe $r = \sigma_{xy}^2 / \sigma_x \cdot \sigma_y$ wird als Korrelationskoeffizient bezeichnet.

Die Beweise für diese Sätze findet man in jedem Buch über Statistik oder Wahrscheinlichkeitstheorie (z. B. KREYSZIG 1972).

Satz 3: Ist X normalverteilt nach $N(0, \sigma)$, so gilt für den Absolutbetrag $Z = |X|$

$$(A4.8) \quad E[Z] = E[|X|] = \sqrt{\frac{2}{\pi}}$$

und

$$(A4.9) \quad E[Z^2] = \sigma^2.$$

Beweis: X hat die Dichtefunktion

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot \exp\left(-\frac{1}{2}\left(\frac{x}{\sigma}\right)^2\right)$$

und X hat die Dichte

$$(A4.10) \quad g(x) = \begin{cases} 2 \cdot f(x) & \text{für } x \geq 0 \\ 0 & \text{für } x < 0. \end{cases}$$

Für den Erwartungswert von $|X|$ folgt hieraus

$$\begin{aligned} E[|X|] &= \int_{-\infty}^{\infty} t \cdot g(t) \cdot dt \\ &= 2 \int_0^{\infty} t \cdot f(t) \cdot dt \\ &= \sqrt{\frac{2}{\pi}} \sigma. \end{aligned}$$

In analoger Weise ergibt sich für das zweite Moment

$$E[|X|^2] = \sigma^2.$$

Hieraus folgt für die Varianz von Z : $\sigma_Z^2 = \sigma^2 - \mu^2$.

A5: Bezeichnungen und Symbole

\underline{x}	Vektoren (Spaltenvektoren)
$\underline{x}'=(x_1, \dots, x_m)$	transponierter Vektor (Zeilenvektor)
$X'=(X_1, \dots, X_m)$	Zufallsvektor (X_i : Zufallsvariable)
n	Anzahl der Stichproben
m	Anzahl der Merkmale
Ω	Objektraum
M	Merkmalsraum
O_i	Klasse im Objektraum
K_i	Klasse im Merkmalsraum
S_i	Klasse im Merkmalsraum der Signaturen
T_i	Klasse im Merkmalsraum der Texturen
k	Anzahl der Klassen oder Gruppen
n_i	Anzahl der Elemente in der i -ten Klasse
$p(\underline{x})$	Wahrscheinlichkeitsdichte von \underline{x}
$p(K_i)$	a priori Wahrscheinlichkeit für K_i
$p(\underline{x} K_i)$	bedingte Wahrscheinlichkeit für \underline{x} , $\underline{x} \in K_i$
$p(K_i \underline{x})$	a posteriori Wahrscheinlichkeit für K_i
d_i	Diskriminanzfunktion für K_i
w_j	Koeffizienten einer Diskriminanzfunktion
$d_{i,j}$	Trennfunktion für K_i und K_j
A, B, W	Matrizen
$ A , A^{-1}$	Determinante, Inverse von A
$Sp(A)$	Spur von A (= Summe der Hauptdiagonalelemente)
λ_i	Eigenwerte einer Matrix
I	Einheitsmatrix
$C (C_i)$	Varianz-Kovarianz-Matrix (der Klasse K_i)
R	Korrelationsmatrix
$r_{i,j}$	Korrelationskoeffizient der Variablen X_i, X_j
$\underline{m} = E X$	Mittelwertsvektor (Erwartungswert von X)
\underline{m}_i	Mittelwertsvektor der Klasse K_i (Centroid)
$N(\underline{m}, C)$	multivariate Normalverteilung mit Mittelwertsvektor \underline{m} und Varianz-Kovarianzmatrix C
$E, x \in E$	Menge, x ist Element von E
\emptyset	leere Menge
$E_1 \cap (\cup) E_2$	Durchschnitt (Vereinigung) zweier Mengen
$A_1 \rightarrow A_2$	Implikation (Aussage A_2 folgt aus A_1)
R^m	m -dimensionaler euklidischer Raum
N	Menge der natürlichen Zahlen $1, 2, \dots$
$n!$	n -Fakultät ($n! = 1 \cdot 2 \cdot 3 \cdot \dots \cdot n$)
$g(x,y)$	Bildfunktion (Grautonwert im Punkt (x,y))
$g_{i,j}$	diskrete Bildfunktion (Grautonwert in Zeile i , Spalte j)

BERLINER GEOWISSENSCHAFTLICHE ABHANDLUNGEN

Freie Universität Berlin — Technische Universität Berlin — Technische Fachhochschule Berlin

Bisher sind erschienen:

Reihe B

Heft 1: Joachim Steinbeck, Modelleismische Untersuchungen von Rayleighwellen unter besonderer Berücksichtigung einer Deckschicht von variabler Mächtigkeit. 128 S., 58 Abb., 1965. DM 25,—.

Heft 2: Peter Giese, Versuche einer Gliederung der Erdkruste im nördlichen Alpenvorland, in den Ostalpen und in Teilen der Westalpen mit Hilfe charakteristischer Refraktions-Laufzeit-Kurven sowie eine geologische Deutung. 218 S., 83 Abb., 1965. DM 40,—.

Heft 3: Joachim Meyer, Zur Modulation der erdmagnetischen Aktivität. 72 S., 26 Abb., 1973. DM 18,—.

Heft 4: Kurt Bram, Zum Aufbau der Kruste und des oberen Mantels im Bereich des westlichen Grabens des ostafrikanischen Grabensystems und im östlichen Zaire-Becken. Ergebnisse einer Untersuchung der Raumwellen von Nah-Erdbeben. 65 S., 32 Abb., 1975. DM 25,—.

Heft 5: Detlef Damaske, Der Weltzeitgang der erdmagnetischen Aktivität als magnetosphärischer Modulationseffekt. 75 S., 33 Abb., 1976. DM 20,—.

Heft 6: Michael Leppin, Modellversuche zur erdmagnetischen und magnetotellurischen Tiefensondierung mit Hilfe eines elektrolytischen Troges. 68 S., 39 Abb., 1977. DM 19,—.

Heft 7: Hussein El-Ali, Geothermische Modelle für ein Profil zwischen Südadria und Tyrrenis. 51 S., 20 Abb., 1978. DM 18,—.

Hefte 1–6: Vormalig „Geophysikalische Abhandlungen“ des Instituts für Geophysikalische Wissenschaften der FU Berlin

VERLAG VON DIETRICH REIMER IN BERLIN

Berlin 45, Unter den Eichen 57

BERLINER GEOWISSENSCHAFTLICHE ABHANDLUNGEN

Freie Universität Berlin – Technische Universität Berlin – Technische Fachhochschule Berlin

Bisher sind erschienen:

Reihe A

Band 22 / Pedro Fernando Ramirez Castro: Qualitative und quantitative petrographische Untersuchungen der Kohlen aus den flözführenden Schichten der Antioquia-Formation/Kolumbien. 110 S., 1980. DM 35,—.

Band 23 / Siegmund Schulz: Verteilung und Genese von Fluorit im Hauptdolomit Norddeutschlands. 85 S., 71 Abb., 26 Tab., 1 Taf., 1980. DM 24,—.

Band 24 / Wolfgang Herrmann-Degen: Eine Hexactinelliden-Fauna aus dem »Chalk« (Maastricht?, Paläozän) Südwest-Ägyptens. 29 S., 3 Abb., 1 Tab., 10 Taf., 1980.

Eberhard Klitzsch: Konzeption des geplanten Berliner Sonderforschungsbereiches »Geowissenschaftliche Probleme arider Gebiete«. 8 S., 1980. DM 24,—.

Band 25 / Peter Winter: Die Bedeutung einheimischer Braunkohlevorräte für die Energiebedarfsdeckung ausgewählter Entwicklungsländer (Indien und Thailand). 104 S., 22 Abb., 30 Tab., 1980. DM 24,—.

Band 26 / Werner Schwarzhans: Die tertiäre Teleosteer-Fauna Neuseelands, rekonstruiert anhand von Otolithen. 211 S., 637 Abb., 4 Tab., 6 Taf., 1980. DM 35,—.

Band 27 / Michael Buchelt: Petrographische und geochemische Untersuchungen an drei Graniten im Nationalpark Bayerischer Wald. 70 S., 18 Abb., 12 Tab., 10 Taf., 1980.

Jan-Jürgen Göttner: Der Einfluß unterschiedlicher Umweltfaktoren auf Größenwachstum und Schalenbau bei Ostracoden. 47 S., 8 Abb., 6 Tab., 5 Taf., 1980.

Nigem el-Din Yusuf: Zur Geologie des Großen Walsertals bei Buchboden. 16 S., 6 Abb., 1 Karte, 1980. DM 38,—.

Band 28 / Peter Dulski: Spurenanalyse als Hilfsmittel bei der geochemischen Untersuchung der Genese bolivianischer Sn-Lagerstätten. 79 S., 30 Abb., 37 Tab., 1980. DM 24,—.

Band 29 / Behruz Kaschanian: Korngrößenverteilung und Schwermineralführung in den Flußsanden der Ziller (Tirol/Österreich). 58 S., 11 Abb., 8 Tab., 3 Taf., 1 Karte, 1980. DM 29,—.

Band 30 / Resa H. M. Tehrani: Geologische und petrographische Untersuchungen am Ostrand des Akapol-Batholithen im Zentral-Alborz/Iran. 71 S., 28 Abb., 16 Tab., 6 Taf., 1 Karte, 1980. DM 32,—.

Band 31 / Thomas Lindner: Korrelation lithofazieller und bodenmechanischer Eigenschaften von Sedimenten des Küstenholozäns der südlichen Nordsee mit multivariaten statistischen Methoden. 88 S., 44 Abb., 15 Tab., 8 Taf., 1980. DM 28,—.

Band 32 / Thomas Schlüter (ed.): Beiträge zur Paläontologie. 210 S., 1981, DM 45,—.

Beiträge von Thomas Schlüter, Dietmar Andres, Werner Schwarzhans, Abdulkader M. Abed, Friedrich-Franz Helmdach, Curt-Albert Schwietzer.

Band 33 / Gerwulf Schneider & Wilhelm Büsch: Zur Geochemie von Migmatiten am Beispiel von Gesteinen des Schwarzwaldes. 82 S., 121 Abb., 14 Tab., 8 Taf., 1980, DM 28,—.

Band 34 / Axel Kroker: Sedimentologische Untersuchungen im Bereich der Uranmineralisation Phu Wiang, Provinz Khon Kaen (NE-Thailand). 85 S., 34 Abb., 9 Tab., 1 Taf., 1 Karte, 1981.

Christian Schlag: Die magmatischen Gesteine in NE-Thailand und ihre Bedeutung als Quelle von Uranmineralisationen in Sandsteinen des Khorat-Plateaus. 70 S., 24 Abb., 28 Tab., 1 Taf., 1 Karte, 1981. DM 39,—.

Band 35 / Heinz Burger: Untersuchungen zur Klassifizierung von Gesteinsoberflächen auf Landsat-Aufnahmen mit Hilfe von Signatur- und Texturparametern. 102 S., 62 Abb., 15 Tab., 1981. DM 29,—.

VERLAG VON DIETRICH REIMER IN BERLIN

Berlin 45, Unter den Eichen 57