

Universität Hannover

Institut für Photogrammetrie und Ingenieurvermessung

## Diplomarbeit

Klassifizierung von DPA Bildern  
unter Einbeziehung der Methoden  
der Neuronalen Netze und Fuzzy Sets

vorgelegt von:

cand. geod. Jessica Schnellert

Dezember 1999

---

## Inhaltsverzeichnis

1. Einleitung .....	1
2. Theoretische Grundlagen .....	3
2.1. Multispektrale Klassifizierung .....	3
2.1.1. Klassifizierung mittels größter Wahrscheinlichkeit .....	4
(Maximum Likelihood)	
2.1.2. Klassifizierung mittels künstlicher neuronaler Netze .....	5
(Backpropagation - Algorithmus)	
2.1.3. Klassifizierung mittels Fuzzy Sets .....	9
(Fuzzy - C - Means)	
2.2. Merkmalsauswahl .....	11
2.2.1. Texturmerkmale .....	12
2.2.2. Hauptkomponententransformation .....	13
2.3. Bestimmung von Klassen und Trainingsgebieten .....	15
2.4. Nachbearbeitung .....	17
2.5. Bestimmung der Klassifizierungsgenauigkeit .....	17
3. Datenmaterial und Software .....	20
3.1. Das DPA - System .....	20
3.2. Das Datenmaterial .....	22
3.3. TNTmips .....	24
4. Auswertung .....	25
4.1. Vorüberlegungen .....	25
4.1.1. Auswahl der Trainingsgebiete .....	25
4.1.2. Auswahl der Merkmale .....	28

---

---

4.2. Ausführung der Klassifizierungen .....	31
4.2.1. Maximum - Likelihood - Klassifizierung .....	33
4.2.2. Klassifizierung mit dem Backpropagation - Algorithmus.....	38
4.2.3. Klassifizierung mit dem Fuzzy - C - Means - Algorithmus.....	44
5. Schlußbetrachtung .....	47
6. Literaturverzeichnis .....	49

---

---

# 1. Einleitung

Fernerkundungssysteme erkunden seit Anfang der 70er Jahre die Erde, um über ihre Oberfläche physikalische und technische Daten zu liefern.

Dabei bedient sich die Fernerkundung u.a. spektroskopischer Verfahren<sup>1)</sup>, d. h. es werden die reflektierten Anteile des Sonnenlichts oder künstlicher Strahlenquellen, wie RADAR oder LASER, oder die thermische Eigenstrahlung bei verschiedenen Frequenzen ( „Kanälen“ ) gemessen. Aufgrund der Wechselwirkung zwischen elektromagnetischen Wellen und der Erdoberfläche, sprich Absorption, Reflexion und Streuung<sup>1)</sup>, kann mit den gemessenen Daten auf physikalische und chemische Eigenschaften der Erdoberfläche geschlossen werden.

Meist werden die Ergebnisse in bildhafter Form dargestellt. Dabei erlangt die digitale multispektrale Klassifizierung von Satelliten - und Luftbilddaten immer mehr an Bedeutung, da eine großräumige Überwachung unserer Erde auf diese Weise gewährleistet und zum Teil erst möglich wird.

Bei einer Klassifizierung multispektraler Szenen geht es um die Erfassung verschiedener Arten von Bodenbedeckungen, wie die der landwirtschaftlichen Nutzungen und ihrer Veränderungen, oder um die Erfassung wichtiger Umweltparameter, um nur einige der vielen Anwendungsmöglichkeiten zu nennen, die mit Hilfe z. T. komplexer datentechnischer Verfahren zu bestimmen und zu dokumentieren sind.

Das Interesse der Anwender liegt daher bei der Entwicklung neuer satelliten - und flugzeuggetragener Aufnahmesysteme mit sowohl hoher geometrischer als auch radiometrischer Auflösung.

Die Klassifizierung hochauflösender Luftbilder ist in der Praxis noch wenig verbreitet. Aufgabe dieser Arbeit ist es zu untersuchen, inwieweit Verfahren der Klassifizierung mit neuronalen Netzen und Fuzzy Sets dazu geeignet sind, hochauflösende Daten zu bearbeiten. Die Methoden werden dabei mit dem Maximum - Likelihood - Verfahren als herkömmliches, statistisches Verfahren der überwachten Klassifizierung verglichen.

---

<sup>1)</sup> siehe u. a. [Lillesand1994]

<sup>2)</sup> siehe u. a. [Kraus1988]

Außerdem ist es bei einem Einsatz von Klassifizierungsverfahren wichtig zu wissen, mit welcher quantitativen Genauigkeit die Einteilung der Objekte in die verschiedenen Klassen erfolgte.

Gleichzeitig wird untersucht, welchen Einfluß die für die Klassifizierung verwendeten Merkmale bzw. Kanäle auf die Ergebnisse haben.

Als Datenquelle wird eine 4 - kanalige Dpa - Szene aus dem Raum Friedland mit einer Bodenauflösung von ~80cm zur Verfügung gestellt.

Die Untersuchungen werden mit dem Softwarepaket *TNTmips* von *MicroImages, Inc.*, durchgeführt.

Da es in dieser Arbeit rein um die Durchführung von Klassifizierungen geht, soll auf weiterführende Beschreibungen der digitalen Bildverarbeitung verzichtet werden. Es sei hier deshalb nur auf das Literaturverzeichnis hingewiesen.

---

## 2. Theoretische Grundlagen

### 2.1. Multispektrale Klassifizierung

Jeder Punkt der Erdoberfläche hat aufgrund seines Reflexionsverhaltens signifikante spektrale Merkmale, die von einem Fernerkundungssystem in den einzelnen Spektralbereichen bzw. -kanälen als Grauwerte aufgezeichnet werden.

Diese spektralen Merkmale können als Merkmalsvektor zusammengefaßt und in einem sogenannten Merkmalsraum dargestellt werden, wobei die aufgezeichneten Spektralbereiche den Koordinatenachsen entsprechen.

Da jeder Punkt einer Objektklasse, wie Vegetation, Boden, Wasser, ähnliche spektrale Eigenschaften besitzt, entstehen im Merkmalsraum objekttypische Punktwolken ( Cluster ). Je nach Klassifizierungsverfahren werden Grenzen zwischen den Punktwolken gezogen (Abb. 2.1). Unbekannte Bildpunkte können dann hinsichtlich ihrer Lage im Merkmalsraum einer Klasse zugeordnet werden.

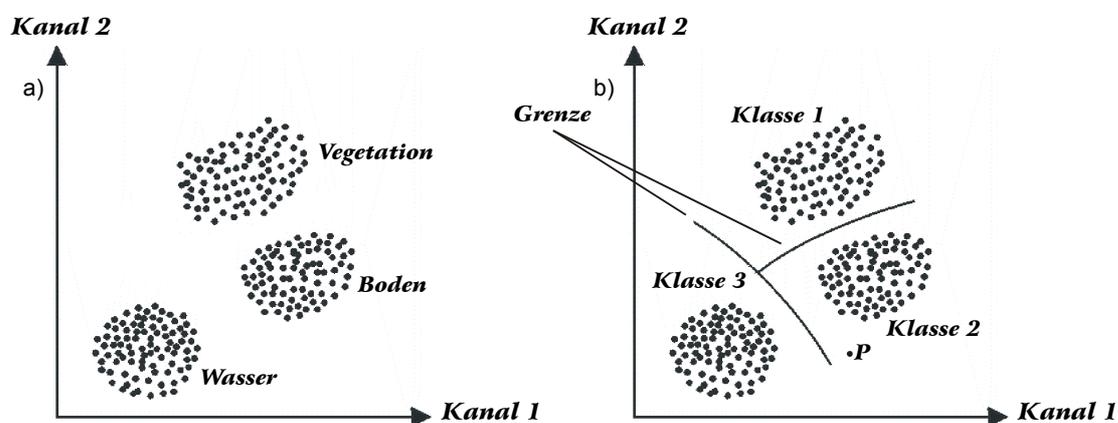


Abb. 2.1.: Beispiel eines zweidimensionalen Merkmalsraumes. Unterscheiden sich die abgebildeten Objekte in den Merkmalen, entstehen Cluster (a), die je nach Klassifizierungsverfahren voneinander getrennt werden (b).

Werden die Klassen und ihre spektralen Eigenschaften durch sogenannte Trainingsgebiete vorab aufgrund der Geländekenntnis ausgewählt, spricht man von überwachten Klassifizierungsverfahren ( engl. supervised classification ).

Bei unüberwachten Klassifizierungsverfahren wird der gesamte Bildinhalt ohne Vorkenntnisse durch sogenannte Clusterbildung klassifiziert ( engl. unsupervised classification ). Erst danach werden die Klassen aufgrund ihrer Lage im Bild interpretiert.

### 2.1.1. Klassifizierung mittels größter Wahrscheinlichkeit (Maximum Likelihood)

Die meisten der Klassifizierungsverfahren benutzen statistische Methoden.

Das oft angewandte Maximum - Likelihood - Verfahren beginnt damit, daß für das zu klassifizierende Bildelement mit dem Merkmalsvektor  $\vec{g} = (g_1 \dots g_n \dots g_N)$  die Wahrscheinlichkeitsdichten  $f(\vec{g}|K_i)$  für alle  $t$  mit Trainingsgebieten erfaßten Objektklassen  $K_i$ ,  $i = 0, \dots, t - 1$ , berechnet werden.

Man geht davon aus, daß die Klassen näherungsweise mit einer N - dimensionalen Gauß'schen Normalverteilung beschrieben werden können:

$$f(\vec{g}|K_i) = (2\pi)^{-\frac{N}{2}} \cdot \det(C_i)^{-\frac{1}{2}} \cdot e^{-\frac{1}{2}(\vec{g}-\vec{z}_i)^T \cdot C_i^{-1} \cdot (\vec{g}-\vec{z}_i)} \quad (2.1.)^1$$

Dabei ist  $C_i$  die Kovarianzmatrix und  $\vec{z}_i$  der Mittelwertvektor bzw. das Zentrum einer Klasse  $K_i$ . Wird diese Gleichung logarithmiert bekommt man eine Größe  $d_i$ :

$$d_i = \ln(p(K_i)) - \frac{1}{2} \ln(\det(C_i)) - \frac{1}{2} (\vec{g} - \vec{z}_i)^T \cdot C_i^{-1} \cdot (\vec{g} - \vec{z}_i) \quad (2.2.)^1$$

Die a priori - Wahrscheinlichkeiten  $p(K_i)$  sind in der Regel nicht bekannt.

Ein zu klassifizierendes Bildelement wird nun der Klasse  $K_j$  zugeordnet, falls gilt:

$$d_j > d_i \text{ für alle } i \neq j, \quad (2.3.)^1$$

---

<sup>1)</sup> [Haberäcker1995]

d. h., es wird der Klasse mit der größten Wahrscheinlichkeit zugewiesen.

Die Größe  $(\bar{g} - \bar{z}_i)^T \cdot C_i^{-1} \cdot (\bar{g} - \bar{z}_i)$  heißt Mahalanobis - Abstand des Merkmalvektors  $\bar{g}$  von der Klasse  $K_i$ . Wird eine Zurückweisungsklasse eingeführt, werden alle Bildpunkte, deren Mahalanobis - Abstand größer als eine vorgegebene Schwelle ist, dieser Klasse zugeteilt.

Die Orte gleicher Wahrscheinlichkeitsdichten für die mit Trainingsgebieten bestimmten Objektklassen sind Hyperellipsen, deren Zentren den Mittelwertvektoren  $\bar{z}_i$  entsprechen ( in Abb. 2.2. für den zweidimensionalen Fall dargestellt ).

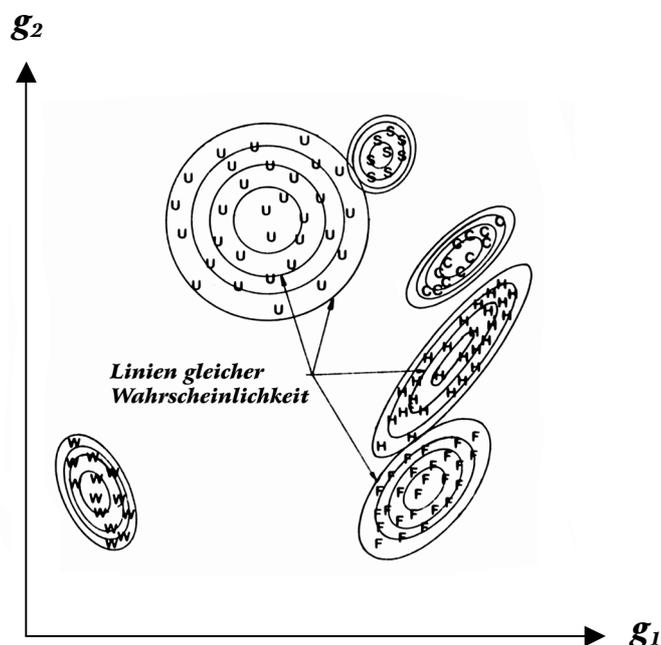


Abb. 2.2.: Linien gleicher Wahrscheinlichkeitsdichten<sup>1)</sup>

## 2.1.2. Klassifizierung mittels künstlicher neuronaler Netze (Backpropagation – Algorithmus)

Außer den klassischen Klassifizierungsverfahren, wie das Maximum - Likelihood - Verfahren, denen statistische Ansätze zugrunde liegen, werden neuerdings auch

<sup>1)</sup> aus [Lillesand1994]

sogenannte neuronale Netze zur Klassifizierung eingesetzt. Solche Netze besitzen die Eigenschaft, aufgrund von „Erfahrungen“ Entscheidungskriterien zu entwickeln. Ein neuronales Netz besteht im allgemeinen aus untereinander verknüpften „logischen Schwellwertelementen“ (McCulloch und Pitts 1943), den Neuronen, und kann unterschiedlich aufgebaut sein. Oft wird es durch Hintereinanderschaltung mehrerer Neuronenschichten  $k = 0, 1, \dots, l$  gebildet (Abb. 2.3.).

Auf die Neuronen der Eingabeschicht  $k = 0$  ( engl. input layer ) werden die Eingabewerte  $x_i, i = 1, \dots, m$ , die bei einer Klassifizierung den Merkmalen eines Bildpunktes entsprechen, verteilt. Jedes Neuron dieser Schicht ist mit den  $n_k$  Neuronen einer verdeckten Schicht  $k = 1$  ( engl. hidden layer ) verbunden. Den Verbindungen zwischen den Neuronen sind Gewichte  $w_i$  zugeordnet, so daß zum jeweiligen verdeckten Neuron die gewichtete Summe der Eingangswerte gebildet wird.

Mit Hilfe einer Aktivierungsfunktion  $f(x)$  an den Ausgängen dieser Neuronen werden dann Ausgaben berechnet, die wiederum als Eingaben bzw. Eingangsaktivierungen  $a_i, i = 1, \dots, n_{k-1}$  für Neuronen einer weiteren verdeckten Schicht dienen. Hier geschieht entsprechendes, bis schließlich die Neuronen der Ausgabeschicht  $k = l$  ( engl. output layer ) erreicht sind. Ihre Ausgaben entsprechen den Ausgabewerten  $out_j, j = 1, \dots, n_k$  des gesamten Netzes, also einem Klassifizierungsergebnis.

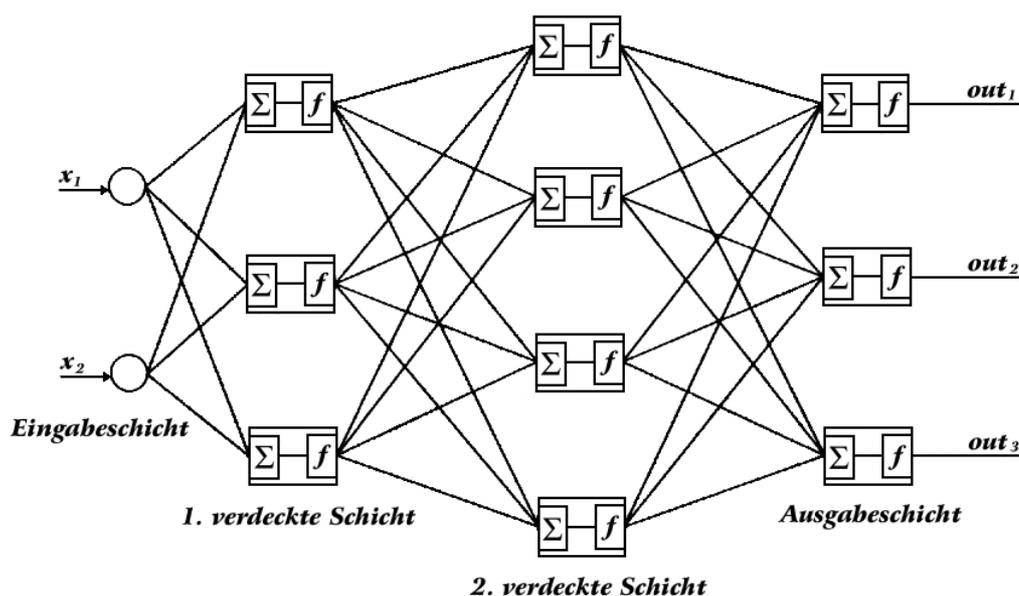


Abb. 2.3: Allgemeines mehrschichtiges neuronales Netzwerk<sup>1)</sup>

<sup>1)</sup> aus [Haberäcker1995]

Das gesamte Netz muß bei einer überwachten Klassifizierung auf die Merkmale der mit Trainingsgebieten bestimmten Objektklassen in einer sogenannten Lernphase trainiert werden.

Dazu werden die Merkmalsvektoren aus den Trainingsgebieten als Eingabevektoren  $\vec{x} = (x_1, x_2, \dots, x_m)^T$  nacheinander auf die Eingabeschicht des Netzes gegeben. Die Eingabeschicht besteht demnach aus  $m$  Neuronen. Die dazugehörigen Ausgabevektoren  $\vec{out}_{soll}$  werden bestimmt und in der Ausgabeschicht gespeichert, wobei jeder Objektklasse ein Ausgabeneuron zugeordnet wird.

Für einen ersten Verarbeitungsvorgang werden die Verbindungsgewichte zwischen den Neuronen mit zufälligen Werten belegt.

Mit den gewichteten Eingangsaktivierungen  $a_i^{(k)}$ ,  $i = 1, \dots, n_{k-1}$  eines Neurons  $j = 1, \dots, n_k$  einer Schicht  $k = 1, \dots, l$  werden die Ausgaben  $o_j^{(k)}$  berechnet:

$$o_j^{(k)} = f_j \left( \sum_{i=1}^{n_{k-1}} a_i^{(k)} w_{ij}^{(k)} \right) \quad (2.4.)^1$$

wobei  $a_i^{(k)}$  in der ersten verdeckten Schicht den Eingabewerten  $x_i$  aus der Eingabeschicht entsprechen. Als Aktivierungsfunktion  $f(x)$  wird meistens eine sigmoide Funktion verwendet, z. B. die Fermifunktion:

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2.5.)^2$$

Aufgrund des asymptotischen Verhaltens dieser Funktion nehmen die Ausgaben  $o_j^{(k)}$  Werte zwischen Eins und Null an.

Die Ausgaben der letzten Schicht sind die Ausgaben des gesamten Netzes:

$$out_j = o_j^{(l)}. \quad (2.6.)^1$$

Aus der Differenz zwischen erwünschter Ausgabe  $\vec{out}_{soll,j}$  und tatsächlicher Ausgabe  $out_j$  ergibt sich ein Fehlermaß:

---

<sup>1)</sup> aus [Haberäcker1995]

<sup>2)</sup> aus [Ritter1990]

$$E = \frac{1}{2} \sum_{j=1}^{n_j} (\text{out}_{\text{soll},j} - \text{out}_j)^2, \quad (2.7.)^1$$

welches von der Wahl der Verbindungsgewichte  $w_{ij}^{(k)}$  abhängig ist, d. h. das Fehlermaß  $E$  wird minimal, wenn die Gewichte optimal gewählt sind.

Deshalb wird in einem sogenannten Rückwärtsvermittlung durch das neuronale Netz eine Korrektur der Gewichte vorgenommen. Nach der Gradientenabstiegsmethode ergibt sich für jedes Neuron der Ausgabeschicht der Korrekturwert:

$$\delta_j^{(l)} = \text{out}_j (1 - \text{out}_j) (\text{out}_{\text{soll},j} - \text{out}_j) \quad (2.8.)^1$$

und für jedes Neuron einer verdeckten Schicht  $k = l - 1, \dots, 1$  der Korrekturwert:

$$\delta_j^{(k)} = o_j^{(k)} (1 - o_j^{(k)}) \sum_{i=1}^{n_{k+1}} w_{ji}^{(k+1)} \delta_i^{(k+1)}. \quad (2.9.)^1$$

Das Gradientenabstiegsverfahren ist eine Optimierungsmethode. Das einfachste Verfahren ist die Methode des steilsten Abstiegs. Näheres hierzu findet man in [Grauel1995].

Die Korrektur der Gewichte wird iterativ durchgeführt:

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) + \eta \delta_j^{(k)} a_i^{(k)}, \quad (2.10.)^1$$

bis das Fehlermaß  $E$  Null bzw. vernachlässigbar klein wird und das Netz möglichst genau die Trainingsdaten der Objektklassen in der Ausgabeschicht wiedergibt ( $\eta$  ist die Lernrate).

Da das Fehlermaß  $E$  eine Funktion sämtlicher Gewichte  $w_{ij}^{(k)}$  ist, besitzt es zahlreiche lokale Minima, in denen der Lernvorgang je nach Wahl der Anfangsgewichte bzw. der Lernrate vorzeitig hängenbleiben kann. Abhilfe kann die Einführung eines Momentum - Terms  $\alpha$  in die Formel (2.10.) bringen:

$$w_{ij}^{(k)}(t+1) = \alpha \cdot w_{ij}^{(k)}(t) + \eta \delta_j^{(k)} a_i^{(k)}. \quad (2.10b.)^2$$

<sup>1)</sup> aus [Haberäcker1995]

<sup>2)</sup> aus [Demant1998]

---

Dieses oben beschriebene iterative Lernverfahren, dessen Ziel es ist, Gewichte zu suchen, die das Fehlermaß  $E$  optimal minimieren, heißt Backpropagation - Algorithmus.

Ist die richtige Einstellung der Gewichte beendet, beginnt die eigentliche Klassifizierung. Die zu klassifizierenden Bildelemente werden auf die Eingabeschicht des trainierten Netzes gegeben und den Neuronen der Ausgangsschicht zugeteilt, die die Klassenzugehörigkeiten der Eingaben am besten approximieren.

### 2.1.3. Klassifizierung mittels Fuzzy Sets (Fuzzy - C - Means)

Gewöhnlich werden bei einer Klassifizierung Bildpunkte jeweils nur einer Klasse zugeordnet, auch wenn sie als sogenannte Mischpixels mehreren Klassen angehören können. Durch diese Vermischung mehrerer Klassen in einem Bildpunkt, liegt der dazugehörige Ort des Pixels im Merkmalsraum zwischen den beteiligten Clustern, und die Zuordnung zu einer Objektklasse wird ungenau.

Bei der Klassifizierung mittels Fuzzy - Logik werden die Bildpunkte allen Klassen gleichzeitig graduell zugeteilt. Dafür werden den Bildpunkten Zugehörigkeitsgradwerte  $w_{ij} = \mu_j(\vec{g}_i)$  zwischen Null und Eins zugeordnet, die den Beitrag zu den einzelnen Klassen ausdrücken.

Ein bekanntes unüberwachtes Klassifizierungsverfahren, daß diese Zugehörigkeitsgradwerte  $w_{ij}$  und die Klassenzentren  $\vec{z}_j$  der sogenannten Fuzzy - Klassen iterativ berechnet, ist der Fuzzy - C ( Cluster ) - Means - Algorithmus.

Dafür werden anfänglich aus dem Bildinhalt die gewünschten  $t$  Klassen mit den Mittelwertvektoren  $\vec{z}_j$ <sup>2)</sup>,  $j = 0, \dots, t - 1$ , festgelegt und der Abstand zu den  $M$  Merkmalsvektoren  $\vec{g}_i$ ,  $i = 0, \dots, M - 1$ , aller Bildpunkte berechnet. Als Abstandsmaß wird meistens die euklidische Distanz gewählt:

---

<sup>1)</sup> aus [Haberäcker1995]

<sup>2)</sup> die Mittelwertvektoren der Klassen werden entweder aus den gesamten Bildinhalt bestimmt, oder man ermittelt sie aus jedem  $n \times n$  - Bildelement

$$d_{ij} = \sqrt{(\vec{g}_i - \vec{z}_j)^T (\vec{g}_i - \vec{z}_j)}. \quad (2.11.)^1)$$

Ist  $d_{ij}^2 \neq 0$ , so ergibt sich für die nicht normierten Zugehörigkeitsgradwerte  $v_{ij}$  der Bildpunkte:

$$v_{ij} = \frac{1}{\sum_{k=0}^{t-1} \left( \frac{d_{ij}}{d_{ik}} \right)^{\frac{2}{m-1}}}, \quad (2.12.)^1)$$

mit  $k = 0, \dots, t-1, k \neq j$ . Für  $d_{ij}^2 = 0$  ist  $v_{ij} = 1$  und  $v_{ik} = 0$ .

Die Klassenzentren  $\vec{z}_j$  werden nun nach:

$$\vec{z}_j = \frac{\sum_{i=0}^{M-1} v_{ij}^m \vec{g}_i}{\sum_{i=0}^{M-1} v_{ij}^m} \quad (2.13.)^1)$$

berechnet.  $m$  ist ein Fuzzy - Parameter, der die Zugehörigkeitsgradwerte  $v_{ij}$  beeinflusst. Je größer  $m$  ist, desto weniger unterscheidet sich die Zugehörigkeit der Bildpunkte zu den Klassen.

Die Zugehörigkeitsgradwerte  $v_{ij}$  und die Klassenzentren  $\vec{z}_j$  werden solange neu berechnet, bis ein Abbruchkriterium:

$$Q = \left[ \sum_{i=0}^{M-1} \sum_{j=0}^{t-1} |v_{ij}(s) - v_{ij}(s-1)|^2 \right]^{\frac{1}{2}} < \varepsilon, \quad (2.14.)^1)$$

erreicht ist, für das man gewöhnlich die euklidische Norm nimmt ( für  $\varepsilon$  ist ein kleiner Wert zu wählen ).

Gibt man bei den Zugehörigkeitsgradwerten  $v_{ij}$  Schwellwerte vor, können die Beiträge der Merkmalsvektoren  $\vec{g}_i$  zu den einzelnen Klassen weiter eingeschränkt werden.

---

<sup>1)</sup> aus [Haberäcker1995]

---

Ist das Abbruchkriterium erreicht werden die Zugehörigkeitsgradwerte  $v_{ij}$  normalisiert:

$$w_{ij} = \frac{v_{ij}}{\sum_{k=0}^{t-1} v_{ik}}. \quad (2.15.)^1)$$

Nachdem zu den Merkmalsvektoren  $\vec{g}_i$  die Klassenzentren  $\vec{z}_j$  der gewünschten  $t$  Klassen berechnet sind, kann jetzt eine Defuzzifizierung durchgeführt werden, indem man die Merkmalsvektoren  $\vec{g}_i$  den Klassen mit den größten Zugehörigkeitsgradwerten  $w_{ij}$  zuordnet.

## 2.2. Merkmalsauswahl

Obwohl der Informationsgehalt eines Multispektralbildes maßgeblich durch die aufgezeichneten Spektralbereiche gegeben ist, reichen bei einer multispektralen Klassifizierung die reinen spektralen Merkmale der einzelnen Bildpunkte oft nicht aus, um eine eindeutige Zuordnung zu den verschiedenen Objektklassen zu gewährleisten.

Aus den aufgezeichneten spektralen Eigenschaften können jedoch durch Verknüpfung von Kanälen oder Berücksichtigung von Umgebungen der Bildpunkte zusätzliche Merkmale berechnet werden, die in die Klassifizierung mit einbezogen werden.

In diesem Abschnitt werden kurz die Texturmerkmale vorgestellt, die in dieser Arbeit praktische Anwendung finden.

Welche Kanäle bzw. Merkmale letztendlich in die Klassifizierung mit einbezogen werden, hängt von der Anwendung ab, da es keine allgemeingültige Aussage über die Auswahl der Merkmale gibt. Nur müssen die Merkmale eine eindeutige Zuordnung zu den Objektklassen sicherstellen.

---

<sup>1)</sup> aus [Haberäcker1995]

## 2.2.1. Texturmerkmale

Werden Multispektralbilder hoher Auflösung klassifiziert, sind nicht die spektralen Merkmale, sondern vielmehr die mehr oder weniger regelmäßige und unterschiedliche Anordnung der Bildpunkte zueinander entscheidend.

Aus dieser als Textur bezeichneten Oberflächenstruktur lassen sich für jeden Bildpunkt  $s(x,y)$  verschiedene Merkmale berechnen. Da die Merkmale umgebungsabhängig sind, betrachtet man bei der Berechnung eine  $m \times m$  - Umgebung des Bildpunktes. Diese Umgebung muß so gewählt werden, daß alle Eigenschaften der jeweiligen Textur erfaßt werden, andererseits sind die berechneten Merkmale für diese nicht charakteristisch.

Ein Merkmal, um die Textur zu beschreiben, ist die Streuung, die über die mittlere quadratische Abweichung geschätzt wird:

$$q_{(x,y)} = \frac{1}{M} \sum_{i=-k}^k \sum_{j=-k}^k (s(x-i, y-j) - m_{(x,y)})^2, \quad (2.16.)^{1),2)}$$

wobei  $k = (m-1)/2$ ,  $M$  die Anzahl der Bildpunkte in der  $m \times m$  - Umgebung des Bildpunktes und  $m_{(x,y)}$  der Mittelwert dieser Umgebung, mit  $m = 3,5,7, \dots$ , sind:

$$m_{(x,y)} = \frac{1}{M} \sum_{i=-k}^k \sum_{j=-k}^k s(x-i, y-j). \quad (2.17.)^1)$$

Die Streuung stellt ein Maß für die Rauigkeit der Textur dar. Je inhomogener die Flächen sind, desto größer werden die Werte für die Streuung.

Ein weiteres Texturmerkmal ist der Kontrast, der sich einfach und näherungsweise durch:

$$K_{(x,y)} = \frac{\max_{(x,y)} - \min_{(x,y)}}{\max_{(x,y)} + \min_{(x,y)}} \quad (2.18.)^3)$$

<sup>1)</sup> aus [Haberäcker1987] und [Haberäcker1995]

<sup>2)</sup> wird ein Schätzwert als Streuung verwendet, muß normalerweise der Faktor  $1/(M-1)$  statt  $1/M$  verwendet; in der Praxis spielt das für große Bilder jedoch keine

<sup>3)</sup> aus [Haberäcker1987]

berechnen lässt.  $\max_{(x,y)}$  und  $\min_{(x,y)}$  sind dabei der maximale und minimale Grauwert der  $m \times m$  - Umgebung des Bildpunktes. Kontrastreiche Texturen zeichnen sich durch hohe Grauwertsprünge aus.

Andere Methoden zur Berechnung von Texturmerkmalen, wie etwa das Aufstellen einer Co-occurrence - Matrix ( Grauwertübergangsmatrix ), aus der sich u. a. Energie, Entropie, Homogenität und auch der Kontrast bestimmen lassen, werden im Rahmen dieser Arbeit nicht weiter erläutert. Näheres dazu findet man z. B. in [Bässmann1993] oder [Abmayr1994].

## 2.2.2. Hauptkomponententransformation

Durch die Verwendung mehrerer Merkmale bzw. Kanäle können bei einer multispektralen Klassifizierung Probleme auftreten, da sich der Informationsgehalt verschiedener Kanäle in der Regel signifikant überlappt.

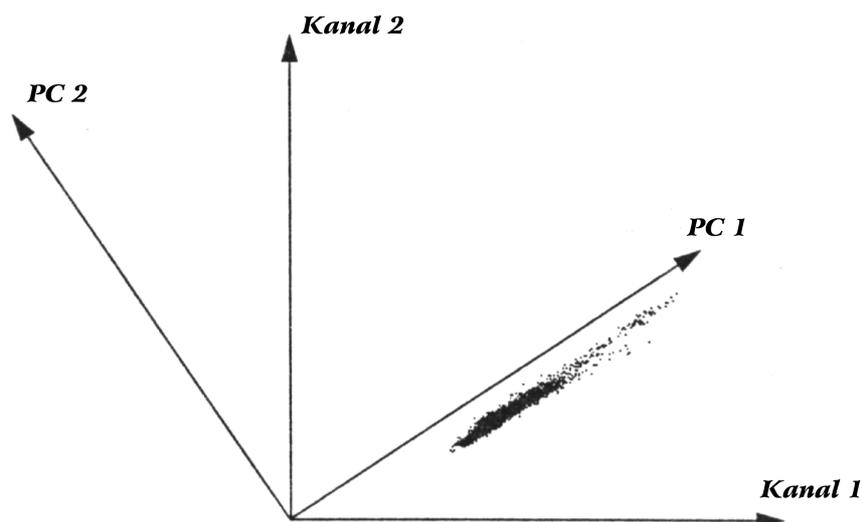


Abb. 2.4.: Transformation zweier hochkorrelierter Kanäle in die Hauptkomponenten<sup>1)</sup>

<sup>1)</sup> aus [Schowengerdt1997]

Die Hauptkomponententransformation ( engl. Principal Components Analysis ) reduziert diese Korrelation zwischen den einzelnen Merkmalen, indem die Grauwerte der  $N$  Merkmale eines Bildes  $s(x,y) = (g_1 \ g_2 \ \dots \ g_N)^T$  durch Drehung des Koordinatensystems des Merkmalsraumes in Richtung der stärksten Streuung in neue Grauwerte transformiert werden ( Abb.2.4. ):

$$s'(x,y) = As(x,y). \quad (2.19.)^1)$$

Die Transformationsmatrix  $A$  wird so bestimmt, daß sich mit:

$$C_{s'} = AC_sA^T \quad (2.20.)^1)$$

eine diagonale Matrix als Kovarianzmatrix  $C_{s'}$  des transformierten Bildes ergibt, in der die Eigenwerte  $\lambda_i$ ,  $i = 1, \dots, N$ , der Kovarianzmatrix  $C_s$  des ursprünglichen Bildes die Varianzen sind:

$$C_{s'} = \begin{bmatrix} \lambda_1 & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \lambda_N \end{bmatrix}. \quad (2.21.)^2)$$

Die  $N$  Eigenwerte werden über die charakteristische Gleichung berechnet:

$$\det(C_s - \lambda_i \cdot I) = 0, \quad (2.22.)^1)$$

mit  $I$  als Einheitsmatrix. Die Achsen des neuen Koordinatensystems werden durch die Eigenvektoren  $e_i$  definiert:

$$(C_s - \lambda_i \cdot I)e_i = 0, \quad (2.23.)^2)$$

die die Zeilen der Transformationsmatrix  $A$  ergeben.

Die Kovarianzmatrix  $C_{s'}$  wird nach abnehmenden Varianzen bzw. Eigenwerten  $\lambda_i$  geordnet, so daß sich auch für die Transformationsmatrix eine nach Größe der

<sup>1)</sup> aus [Bähr1991]

<sup>2)</sup> aus [Schowengerdt1997]

Eigenvektoren geordnete Zeilenfolge ergibt. Mit dieser Transformationsmatrix lassen sich dann neue, synthetische Kanäle, die sogenannten Hauptkomponenten, gemäß (2.19.) berechnen, die untereinander nicht korreliert sind und somit keine redundanten Informationen beinhalten. Dabei enthält die erste Hauptkomponente die maximale Streuung der Grauwerte und somit die meiste Bildinformation.

Durch die Hauptkomponententransformation läßt sich die Anzahl der Merkmale reduzieren, da nur die ersten Hauptkomponenten mit den größten Eigenwerten für die Klassifizierung relevant sind. Der Informationsgehalt der letzten Hauptkomponenten ist sehr gering und kann erfahrungsgemäß bei einer Klassifizierung weggelassen werden.

### **2.3. Bestimmung von Klassen und Trainingsgebieten**

Bei einer Klassifizierung spielt neben der Auswahl geeigneter Merkmale die Definition der Klassen und, für die überwachten Klassifizierungsverfahren, die Bestimmung entsprechender Trainingspixel eine wesentliche Rolle.

Mit der Wahl der Trainingsgebiete wird das Ergebnis einer überwachten Klassifizierung entscheidend beeinflusst. Die Trainingsgebiete sollten daher so gewählt werden, daß sie möglichst vollständig die Eigenschaften der zugehörigen Objektklassen wiedergeben.

Eine Objektklasse kann unterschiedliche spektrale Eigenschaften aufweisen. Zum einen wegen der verschiedenartigen Beschaffenheit der Objekte dieser Klasse, wie z. B. *Nadelwald* und *Laubwald* der Objektklasse *Wald*, zum anderen durch topographisch bedingte, regionale Unterschiede im spektralen Verhalten der Objekte. Daher könnte eine Einführung temporärer Unterklassen, die nach der Klassifizierung zusammengefaßt werden, für diese Objektklassen zur Verbesserung des Klassifizierungsergebnisses führen. Auch ist es sinnvoll, mehrere Trainingsgebiete,

---

die über das Bild verteilt liegen, für eine Objektklasse zu wählen, um eine gute Schätzung der Klassenstatistiken zu erhalten.

Jedoch dürfen die Trainingsgebiete nicht zu klein ausfallen, da die Klassenstatistiken, wie Mittelwertvektoren und Kovarianzmatrizen, mit einer gewissen Zuverlässigkeit aus den Trainingsdaten abgeschätzt werden müssen, um sie beurteilen zu können.

Durch die Mischung spektraler Eigenschaften angrenzender Objekte in einem Pixel, sogenannte Mischpixel, kann sowohl die Trennbarkeit als auch die Homogenität einzelner Objektklassen beeinflusst werden.

Sind die zu identifizierenden Objektklassen festgelegt, werden für diese Klassen aus den Pixel der Trainingsgebiete die Signaturen aller in die Klassifizierung eingehenden Kanäle definiert. Diese Signaturen sollten sich in den einzelnen Klassen möglichst deutlich unterscheiden, um eine Klassifizierung hoher Genauigkeit durchführen zu können. Andererseits müssen andere Merkmale mit einbezogen oder die Einteilung der angestrebten Klassen geändert werden.

Während bei einer überwachten Klassifizierung die Klassen durch die Trainingsgebiete vorab aufgrund der Geländekenntnis bestimmt werden, wird bei einer unüberwachten Klassifizierung zunächst nur die Anzahl der zu findenden Cluster definiert.

Da aber die tatsächliche Zahl der Objektklassen in der Regel nicht bekannt ist, muß eine genügend große Anzahl an Cluster festgelegt werden, die nach der Klassifizierung zu den im Bild erkannten Objektklassen mit Hilfe von Geländedaten zusammengeführt werden.

---

---

## 2.4. Nachbearbeitung

In einer multispektralen Klassifizierung treten oft Fehlklassifizierungen auf, indem einzelne Bildpunkte oder kleine Gruppen von Bildpunkten in sonst homogene Flächen der verschiedenen Objektklassen fallen.

Durch Modalfilterung versucht man zusammenhängende Flächen in einer Klasse zu erhalten. Dabei werden die Bildpunkte eines klassifizierten Bildes durch diejenigen ersetzt, die in der  $m \times m$  - Umgebung ( siehe 2.2.1. ) des jeweiligen Bildpunktes am häufigsten vorkommen. Auf diese Weise werden falsch klassifizierte Bildelemente bereinigt. Mehr über die Modalfilterung in [Kraus1990].

Der Nachteil dieser Nachbearbeitung besteht darin, daß linienhafte Objekte wie Gleisanlagen , Straßen oder Flüsse teilweise eliminiert werden können.

## 2.5. Bestimmung der Klassifizierungsgenauigkeit

Das Ergebnis einer Klassifizierung wird auf zwei Arten präsentiert. Zum einen bildlich, durch eine thematische Karte, in der die klassifizierten Pixel durch Farbe oder ein Symbol gekennzeichnet sind, um sie der entsprechenden Klasse zuordnen zu können.

Zum anderen werden die einzelnen Objektklassen durch verschiedene statistische Parameter beschrieben.

Diese Parameter sind u. a. die Mittelwerte der Grauwerte  $\bar{g}_k$  einer Objektklasse mit  $N$  Bildpunkten in den in die Klassifizierung eingegangenen  $K$  Kanälen:

$$\bar{g}_k = \frac{1}{N} \sum_{i=1}^N g_{k,i}, \quad (2.24.)^{1)}$$

---

<sup>1)</sup> aus [Kraus1990]

mit  $k = 1, \dots, K$ , und die daraus resultierenden Standardabweichungen bzw. Varianzen  $\sigma_k^2$ :

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (g_{k,i} - \bar{g}_k)^2 \quad (2.25.)^1$$

einer Kovarianzmatrix  $C$  der jeweiligen Objektklasse:

$$C = \begin{bmatrix} \sigma_1^2 & \dots & \sigma_{1K} \\ \vdots & & \vdots \\ \sigma_{1K} & \dots & \sigma_K^2 \end{bmatrix}. \quad (2.26.)^1$$

Durch visuelle Darstellung der Statistiken eines Klassifizierungsergebnisses lassen sich Klassen beurteilen oder miteinander vergleichen und im Rahmen einer Nachbearbeitung zusammenfassen ( siehe 4.2.3.: Beschreibung eines Dendogramms bei der Fuzzy - Means - Klassifizierung ).

Nach einer Klassifizierung ist es wichtig zu wissen, mit welcher Genauigkeit die Einteilung der Bildpunkte in die verschiedenen Klassen erfolgt. Im wesentlichen ist die Genauigkeit eines Klassifizierungsergebnisses durch den direkten Vergleich mit sogenannten Kontrollgebieten zu beurteilen, deren Klassenzugehörigkeit aus sogenannten *ground truth* Daten einwandfrei bekannt ist. Durch diesen Pixelweise durchgeführten Vergleich wird geschätzt, zu wieviel Prozent ein Pixel eines Kontrollgebietes korrekt bzw. falsch klassifiziert wurde. Das Ergebnis wird in tabellarischer Form als sogenannte Konfusions- oder Fehlermatrix ( siehe auch [Richards1999] ) wiedergegeben, wobei in der Spaltensumme angegeben wird, wie viele Kontrollpixel einer bestimmten Objektklasse wirklich angehören, und in der Zeilensumme, wie viele Kontrollpixel nach der Klassifizierung einer bestimmten Klasse zugeordnet wurden ( Tab. 2.1. ).

Bildet man den Durchschnitt der Diagonalelemente, die die korrekt klassifizierten Kontrollpixel wiedergeben, so erhält man die Gesamtgenauigkeit  $G_G$  ( engl. overall

---

<sup>1)</sup> aus [Kraus1990]

accuracy ), die in Prozent angegeben wird. Im Beispiel der Tab 2.1. wäre die Gesamtgenauigkeit  $G_G = 83\%$ .

		Ground truth classes			Total
		A	B	C	
Thematic map classes	A	35	2	2	39
	B	10	37	3	50
	C	5	1	41	47
Number of ground truth pixels		50	40	46	136

Tab. 2.1.: Beispiel einer Konfusionsmatrix mit den Klassen A, B, C<sup>1)</sup>

Teilt man ein Diagonalelement durch die entsprechende Spaltensumme, so ergibt sich die prozentuale Wahrscheinlichkeit, mit der ein Kontrollpixel einer Klasse korrekt klassifiziert wurde. Teilt man hingegen ein Diagonalelement durch die entsprechende Zeilensumme, so ergibt sich die prozentuale Wahrscheinlichkeit dafür, daß ein Pixel, das einer Klasse zugeordnet wurde, dieser auch angehört. Diese Wahrscheinlichkeiten werden als Wiedererkennungsgenauigkeit  $G_W$  ( engl. producer accuracy ) und Zuweisungsgenauigkeit  $G_Z$  ( engl. user accuracy ) bezeichnet.

Als Beispiel in Tab. 2.1. ergäbe sich für die Klasse C eine Wiedererkennungsgenauigkeit von  $G_W = 89\%$  und eine Zuweisungsgenauigkeit von  $G_Z = 87\%$ .

<sup>1)</sup> aus [Richards1999]

### 3. Datenmaterial und Software

#### 3.1. Das DPA - System

DPA ( Digital Photogrammetry Assembly) ist ein flugzeuggetragenes digitales Kamera - System, das für die Herstellung topographischer Karten im Maßstab 1:25000 und 1:50000 entwickelt wurde; in erster Linie durch die Erzeugung automatisierter DTM ( Digital Terrain Modell ) mit Genauigkeiten unter 3m, und durch die Herstellung digitaler Orthophotos mit ausreichendem Informationsgehalt, um einer Kartenspezifikation im Maßstab 1:50000 und größer zu entsprechen.

Durch die multispektrale Abbildung sollen auch thematische Karten erstellt werden können.

Das Besondere dieses Systems ist die gleichzeitige Aufnahme hochauflösender panchromatischer Stereobilder (  $\sim 0.25m$  Bodenauflösung<sup>1)</sup> ) und multispektraler Bilddaten (  $\sim 0.5m$  Bodenauflösung<sup>1)</sup> ).

Das DPA - System arbeitet nach dem 3 - Zeilen - Prinzip ( Abb. 3.1. ), so daß der Stereoeffekt durch die simultane Vor-, Rückwärts- und Senkrechtaufnahme von einer Flugbahn aus erreicht wird.

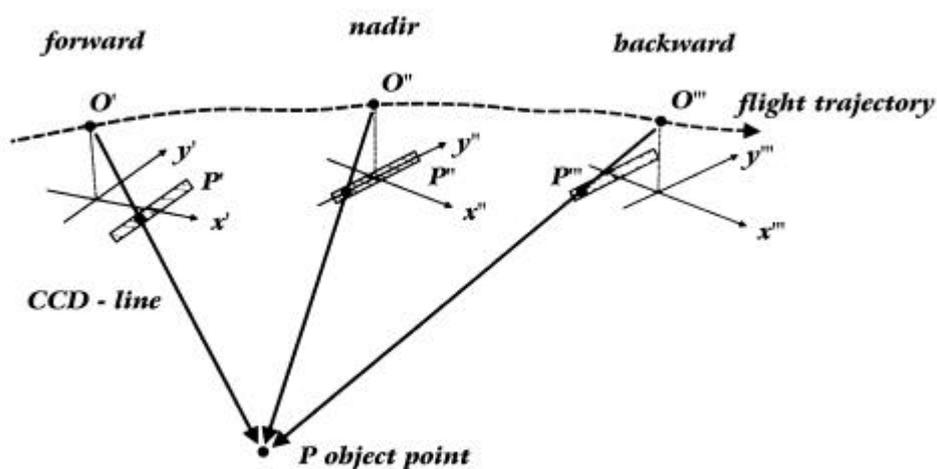


Abb. 3.1.: 3 - Zeilen - Prinzip des DPA - Systems<sup>2)</sup>

<sup>1)</sup> bei 2.5 km Flughöhe

<sup>2)</sup> aus [Fritsch1997]

Das nach dem CCD - Prinzip arbeitende DPA - System liefert insgesamt 7 Kanäle zur Stereo- und multispektralen Datenaufnahme ( Tab: 3.1a. und 3.1b. ). Die Streifenbreite sowohl für Stereo- als auch für multispektrale Datenaufnahme liegt mit einer Pixelgröße von  $10\ \mu\text{m}$  bei  $3\text{km}^1$ .

Wegen der begrenzten Datenübertragung stehen in einem hochsensiblen Aufzeichnungsgerät zwei Modi zur Verfügung, um zwischen Stereo- und multispektraler Datenaufzeichnung zu wechseln.

6 CCD line detectors (2 per line)	FAIRCHILD CCD 191
pixel size ( $10\ \mu\text{m} * 10\ \mu\text{m}$ )	line image format: 12cm
NADIR channel	12,000 pixels/line (Mode A)
FORE channel	12,000 pixels/line (Mode A)
AFTER channel	12,000 pixels/line (Mode A)
convergence (stereo) angle	25deg
focal length	80mm
radiometric resolution	12bit $\rightarrow$ 8bit
geometric resolution	0,25m (from 2,5km flying height)

Tab. 3.1a.: Parameter des Stereobetriebes<sup>2)</sup>

4 CCD line detectors (2 per line)	FAIRCHILD CCD 191
pixel size ( $10\ \mu\text{m} * 10\ \mu\text{m}$ )	line image format: 6cm
spectral bandpass	440-525nm (blue) 520-600nm (green) 610-685nm (red) 770-890nm (near IR)
focal length	40mm
radiometric resolution	12bit $\rightarrow$ 8bit
geometric resolution	0,5m (from 2,5km flying height)

Tab. 3.1b: Parameter des multispektralen Betriebes<sup>2)</sup>

<sup>1)</sup> bei 2.5 km Flughöhe

<sup>2)</sup> aus [Fritsch1997]

## 3.2. Das Datenmaterial

Für die Klassifizierung wurden 4 - kanalige DPA - Bilddaten aus dem Raum Friedland zur Verfügung gestellt, die mit einer 8 bit Pixeltiefe pro Kanal aufgenommen wurden, so daß 256 Graustufen pro Kanal darstellbar sind. Die Kanäle sind die drei des sichtbaren Spektralbereiches und des nahen Infrarot ( Tab. 3.1b ).

Die ca.  $2.5 \times 2.5$  km große Szene wurde im Juli `97 aus einer Flughöhe von ca. 3.3 km ( 10800 Fuss ) mit einer Bodenauflösung von  $\sim 80$  cm aufgenommen ( Abb. 3.2. ). Diese Szene entspricht einer Bildgröße von  $3361 \times 3062$  Pixel ( ca. 45 Mb ).

Auf eine Beschreibung der geometrischen und radiometrischen Transformationen von Bilddaten soll hier verzichtet werden, da die Daten bereits für die Klassifizierung vorverarbeitet, bzw. georeferenziert vorlagen. Deshalb sei hier nur auf das Literaturverzeichnis im Anhang hingewiesen.

Als Grundlage zur Kontrolle der Genauigkeit und für die Auswahl von Trainingsgebieten wurde eine Feldbegehung durchgeführt. Außerdem standen die Flächennutzungen zum Befliegungszeitpunkt vom Amt für Agrarstruktur in Göttingen zur Verfügung, sowie die DGK 5 Obernjesa und Klein Schneen des Katasteramtes Göttingen.

ATKIS - Daten, die für diese Region ebenfalls zur Verfügung standen, wurden nicht weiter berücksichtigt, da sie sowohl für die Bestimmung der Trainingsgebiete als auch zur Kontrolle zu ungenau sind.

---



Abb. 3.2.: Szene Friedland

### 3.3. TNTmips

Die Klassifizierungen wurden mit dem Softwarepaket *TNTmips* durchgeführt.

*TNTmips* ist ein Geoinformationssystem des Softwarehauses Microlmages, Inc., welches verschiedene Klassifizierungsmethoden zur Verfügung stellt. Im Rahmen dieser Arbeit werden die Verfahren mit dem Backpropagation - und dem Fuzzy - C - Means - Algorithmus näher untersucht und mit dem Maximum - Likelihood - Verfahren als herkömmliches Klassifizierungsverfahren verglichen.

Für diese Methoden bietet *TNTmips* zusätzlich einstellbare Parameter an, die das Klassifizierungsergebnis beeinflussen. Diese Parameter werden bei den einzelnen Verfahren im folgenden Kapitel näher erläutert.

---

## 4. Auswertung

### 4.1. Vorüberlegungen

Die hochauflösenden Bilddaten stellen besondere Anforderungen an eine Klassifizierung.

Bilddetails wie die Fahrspuren auf den Feldern oder die Kronenformen verschiedener Baumarten sind zwar bei der Betrachtung des Bildes charakteristisch für die jeweiligen Objektklassen, doch aufgrund ihrer unterschiedlichen spektralen Merkmale, können sie weit verstreut im Merkmalsraum liegen und somit nicht eindeutig einer Objektklasse zugeordnet werden.

Auch in den besiedelten Gebieten werden Klassen schwer voneinander zu trennen sein, da durch die fließenden Übergänge zwischen den einzelnen Objekten wie Straßen, Häuser und Vegetation, Mischsignaturen auftreten.

Das größte Problem liegt daher in der Festlegung der Objektklassen, bzw. der Trainingsgebiete für die überwachte Klassifizierungen. Für die unüberwachte Klassifizierung fällt diese Überlegung leichter, da die angestrebten Objektklassen durch Zusammenfassen der Cluster bestimmt wird. Es sollte nur eine genügend große Anzahl an Cluster festgelegt werden.

#### 4.1.1. Auswahl der Trainingsgebiete

Mit Hilfe von Begehungen und den in die Grundkarten eingetragenen Flächennutzungen sind die Trainingsgebiete bestimmt worden.

Die zu klassifizierende Landschaftsszene ist überwiegend durch Landnutzungen charakterisiert, insbesondere *Weizen*, *Rüben* und *Gerste*. *Hafer*, *Kartoffeln*, *Mais*, *Raps* und *Triticale* treten hingegen nur vereinzelt auf.

---

---

Die Festlegung für die Trainingsgebiete erfolgt für die oben genannten Landnutzungen, *Straßen*, *Wege*, *Gleisanlagen*, *Gewässer*, *Grünland*, *Wald* und für *bebaute Flächen*. Nimmt man noch *sonstiges Getreide* als eigene Objektklasse hinzu, ergeben sich 16 Objektklassen.

Mit einem Zeichentool im *Feature Mapping Editor* von *TNTmips* werden die Trainingsgebiete über eine Referenzfläche markiert ( Abb. 4.1. ). Als Referenzfläche diente ein Farbkomposit der ersten drei Hauptkomponenten nach einer Hauptkomponententransformation der 4 DPA - Kanäle.

Betrachtet man dieses Farbkomposit ( Abb. 4.3. ), so sind schon rein visuell viele Details interpretierbar, und die Auswahl der Trainingsgebiete fällt somit leichter.

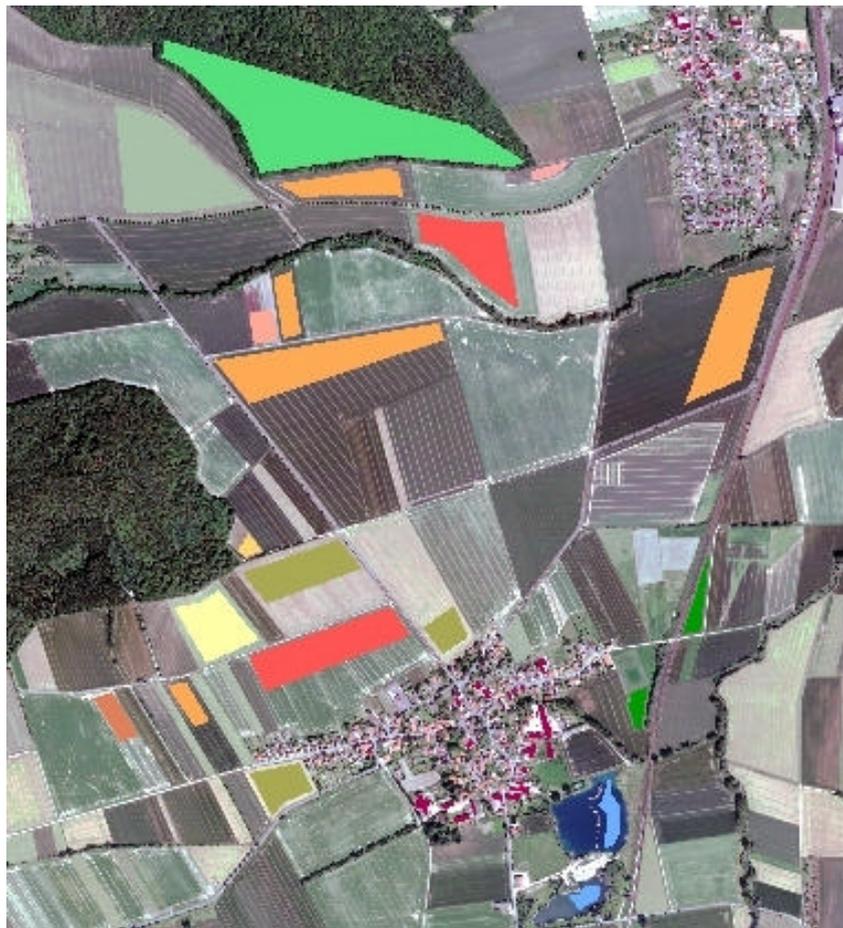


Abb. 4.1.: Festlegung der Trainingsgebiete

---

Aufgrund der unterschiedlichen Oberflächenstrukturen und topographisch bedingten Unterschiede werden für einige Objektklassen, wie *Weizen*, *Rüben*, *bebaute Flächen* und *Gleisanlagen* verschiedene Trainingsgebiete definiert. Für die bebauten Flächen werden im übrigen nur die Dächer als Trainingsgebiete markiert. *Nadelwald* und *Laubwald* werden vorerst nicht unterschieden und in einer Objektklasse *Wald* zusammengefaßt.

Die markierten Flächen und die Klasseninformationen werden dann als Training Set abgespeichert. Die Klasseninformationen beinhalten neben Anzahl der Pixel ( Tab. 4.1. ) auch Mittelwert und Standardabweichungen der in die Klassifizierung eingehenden Kanäle bzw. Merkmale.

Objektklasse	Anzahl der Pixel	Anteil am Gesamtbild in %	Fläche in ha
Weizen	221772	2.1549	13.4343
Rüben	132698	1.2894	8.0385
Gerste	87156	0.8469	5.2796
Raps	41893	0.4071	2.5378
Mais	3845	0.0374	0.2329
Hafer	4530	0.0440	0.2744
Kartoffeln	12902	0.1254	0.7816
Trittikale	114892	1.1164	6.9598
sonstiges Getreide	9932	0.0965	0.6016
Grünland	15785	0.1534	0.9562
Gewässer	16726	0.1625	1.0132
Straßen	5756	0.0559	0.3487
Wege	3888	0.0378	0.2355
Gleisanlagen	8147	0.0792	0.4935
Siedlung	23811	0.2314	1.4424
Mischwald	249370	2.4231	15.1061

Tab: 4.1: Objektklassen und Größen der Trainingsgebiete

## 4.1.2. Auswahl der Merkmale

Für die Auswahl der Merkmale können verschiedene Überlegungen angestellt werden.

Zum einen erwartet man durch die Hinzunahme von Texturmerkmalen Verbesserungen, besonders für die Waldflächen, die aufgrund der sehr inhomogenen Oberflächenstruktur der Bäume stark im spektralen Verhalten variieren.

In *TNTmips* stehen dafür drei Texturfilter zur Auswahl, mit denen durch Ermittlung der Grauwertstatistik in einer lokalen  $m \times m$ - Bildumgebung die Textur berechnet wird.

Der *Standard Deviation Filter* berechnet die Standardabweichung der Bildpunkte in ihrer Umgebung. Homogene Texturen produzieren geringe Standardabweichungen und erscheinen im Ausgabebild in dunklen Tönen, während grobe Strukturen in hellen Tönen dargestellt werden.

Der *Teager Filter* ist ein Kantenverstärkungsfilter, der hier nicht weiter untersucht wird.

Der *Range Filter* gibt den Rang der lokalen Minimum- und Maximumwerte innerhalb einer Bildumgebung wieder. Kontrastreiche Texturen zeichnen sich durch hohe Grauwertsprünge aus, die in der Ausgabe große Zahlen erzeugen. Die Werte für homogene Gebiete mit wenig Textur sind hingegen klein.

Es bleibt zu überlegen, wie die Texturfilter angewendet werden. Sie können für die 4 DPA - Kanäle berechnet werden, sinnvoller erscheint es jedoch, sie nur auf die erste Hauptkomponente nach einer Hauptkomponententransformation der 4 DPA - Kanäle anzuwenden, da die erste Hauptkomponente die wichtigsten Bildinformationen aller 4 Kanäle enthält.

Für die Bildpunktumgebung kann zwischen  $m = 3, \dots, 11$  gewählt werden. Je größer die Bildpunktumgebungen, desto unschärfer werden die Übergänge zwischen den

---

---

einzelnen Oberflächenstrukturen bzw. Texturen, wie in Abb. 4.2. für den *Standard Deviation Filter* dargestellt.

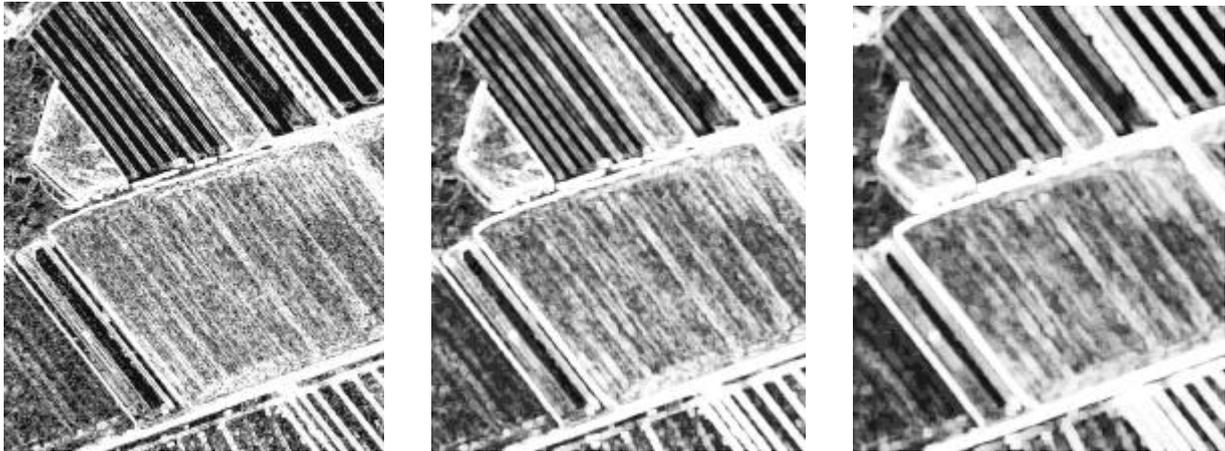


Abb. 4.2.: Einfluß der Bildpunktumgebungen  $m = 3,7,11$  bei der Texturfilterung

Für diese Arbeit wurde eine  $5 \times 5$  - Bildpunktumgebung gewählt, da durch größere Bildpunktumgebungen einige Eigenschaften der jeweiligen Texturen verloren gehen könnten, gerade im Bereich der bebauten Flächen oder der Straßen und Wege.

Inwieweit die Texturmerkmale das Ergebnis beeinflussen, wird bei den einzelnen Klassifizierungsverfahren beurteilt.

Mit den DPA - Kanälen und den zusätzlichen Texturkanälen sollte eine Hauptkomponententransformation durchgeführt werden, um einerseits die Korrelation zwischen den einzelnen Kanälen zu beseitigen, und andererseits, um die Datenmenge zu reduzieren. Je nach Wahl der Texturmerkmale ergibt sich auch die Anzahl der Merkmale, die in die Hauptkomponententransformation eingehen.

*TNTmips* berechnet zur Hauptachsentransformation alle dazugehörigen Statistiken, wie Korrelationsmatrix der in die Transformation eingehenden Kanäle und die Eigenvektoren, anhand derer entschieden werden kann, welche Hauptkomponenten für eine Klassifizierung relevant sind.

---

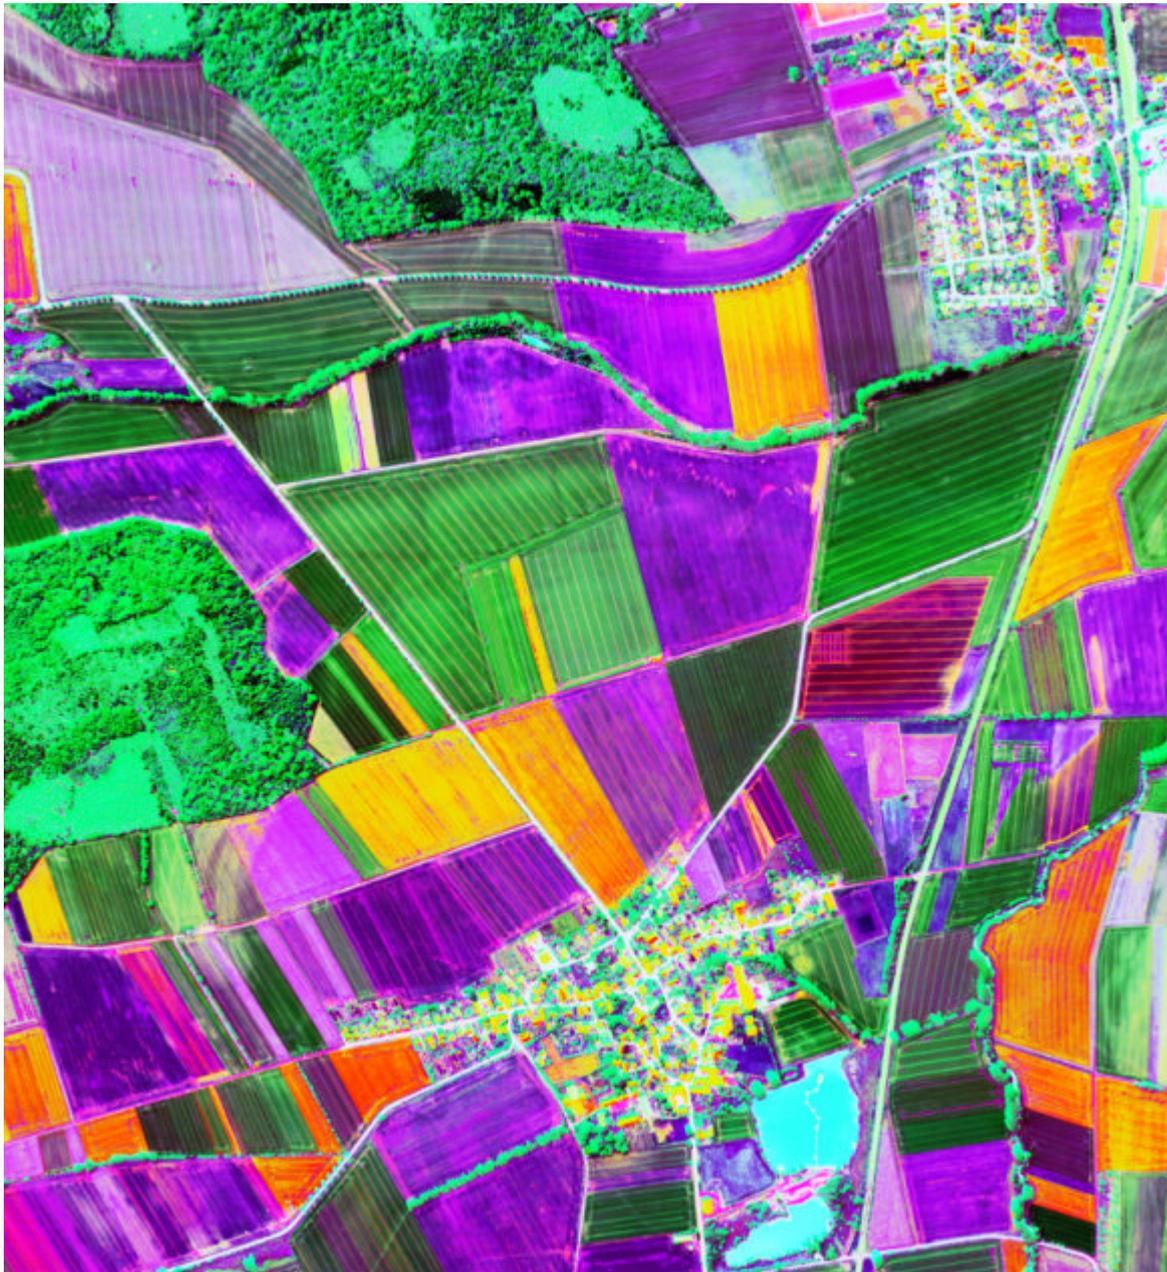


Abb. 4.3.: Farbkomposit der ersten drei Hauptkomponenten nach Hauptkomponententransformation der 4 DPA - Kanäle

Für die Klassifizierungen werden die jeweils ersten vier Hauptkomponenten genommen. Die Klassifizierungen mit nur den ersten drei Hauptkomponenten lieferten etwas schlechtere Ergebnisse.

---

## 4.2. Ausführung der Klassifizierungen

Die überwachten Klassifizierungsverfahren wurden zunächst mit derselben Merkmalsauswahl und den dazugehörigen Trainingsdaten durchgeführt.

Die Klassifizierungen wurden zum einen mit den 4 DPA - Kanälen, zum anderen mit Hauptkomponenten durchgeführt, wobei sich die Hauptkomponenten je nach Merkmalsauswahl ergaben.

Klassifiziert wurde demnach mit folgenden Kanälen bzw. Merkmalen ( in den folgenden Tabellen und Abbildungen auch mit a) - e) bezeichnet ) und den dazugehörigen Trainingsdaten der in 4.1.1. beschriebenen Trainingsgebieten:

- a) nur die vier DPA - Kanäle,
- b) die vier Hauptkomponenten nach einer Hauptkomponententransformation der vier DPA - Kanäle,
- c) die vier Hauptkomponenten nach einer Hauptkomponententransformation der vier DPA - Kanäle und der ersten Hauptkomponente aus b), auf der die Texturfilter *Standard Deviation* und *Range* angewendet wurden,
- d) die vier Hauptkomponenten nach einer Hauptkomponententransformation der vier DPA - Kanäle und der Ergebnisse der Texturfilterungen der vier Kanäle,
- e) die vier Hauptkomponenten nach einer Hauptkomponententransformation der vier DPA - Kanäle und der zweiten Hauptkomponente aus b), auf der die Texturfilter *Standard Deviation* und *Range* angewendet wurden.

Um die Parametereinstellungen der einzelnen Klassifizierungsverfahren zu beurteilen, wurde wegen des Rechenaufwandes ein Ausschnitt aus der Bildszene gewählt ( Abb. 4.4. ).

Für alle Klassifizierungsergebnisse wurde eine Nachbearbeitung mittels Modalfilterung in einer  $5 \times 5$  Umgebung der Bildpunkte durchgeführt. Diese Umgebung wurde gewählt, damit die schmalen, linienhaften Objekte *Straßen* und

---

---

Wege durch die Filterung in einer größeren Bildpunktumgebung nicht verloren gehen.



Abb. 4.4.: Ausschnitt aus der Szene Friedland, zur Überprüfung der Parametereinstellungen

Die Beurteilung der Ergebnisse, inwieweit die Pixel den richtigen Objektklassen zugeordnet worden sind, lässt sich am besten, wie bereits in 2.5. erwähnt, durch die Konfusionsmatrix, bzw. den Wahrscheinlichkeiten aus dieser Matrix errechnen.

Die Kontrollgebiete dafür wurden, wie auch die Trainingsgebiete, im *Feature Mapping Editor* mit Hilfe der vorliegenden Landnutzungen und der DGK5 erstellt (Abb. 4.5.).

---



Abb. 4.5.: Kontrollgebiete

### 4.2.1. Maximum - Likelihood - Klassifizierung

Das Maximum - Likelihood - Verfahren erwies sich als relativ unproblematisch, die Klassifizierung nur mit den DPA - Kanälen erzielte schon ein gutes Ergebnis ( Abb. 4.6. ). Die Klassifizierung der vier Hauptkomponenten aus b) verbesserte dieses Ergebnis nur unwesentlich ( Gesamtgenauigkeit von 93.64 % gegenüber 93.57 % ), während die Einführung von Texturmerkmalen sich eher störend auswirkte ( Tab. 4.1. ).

---

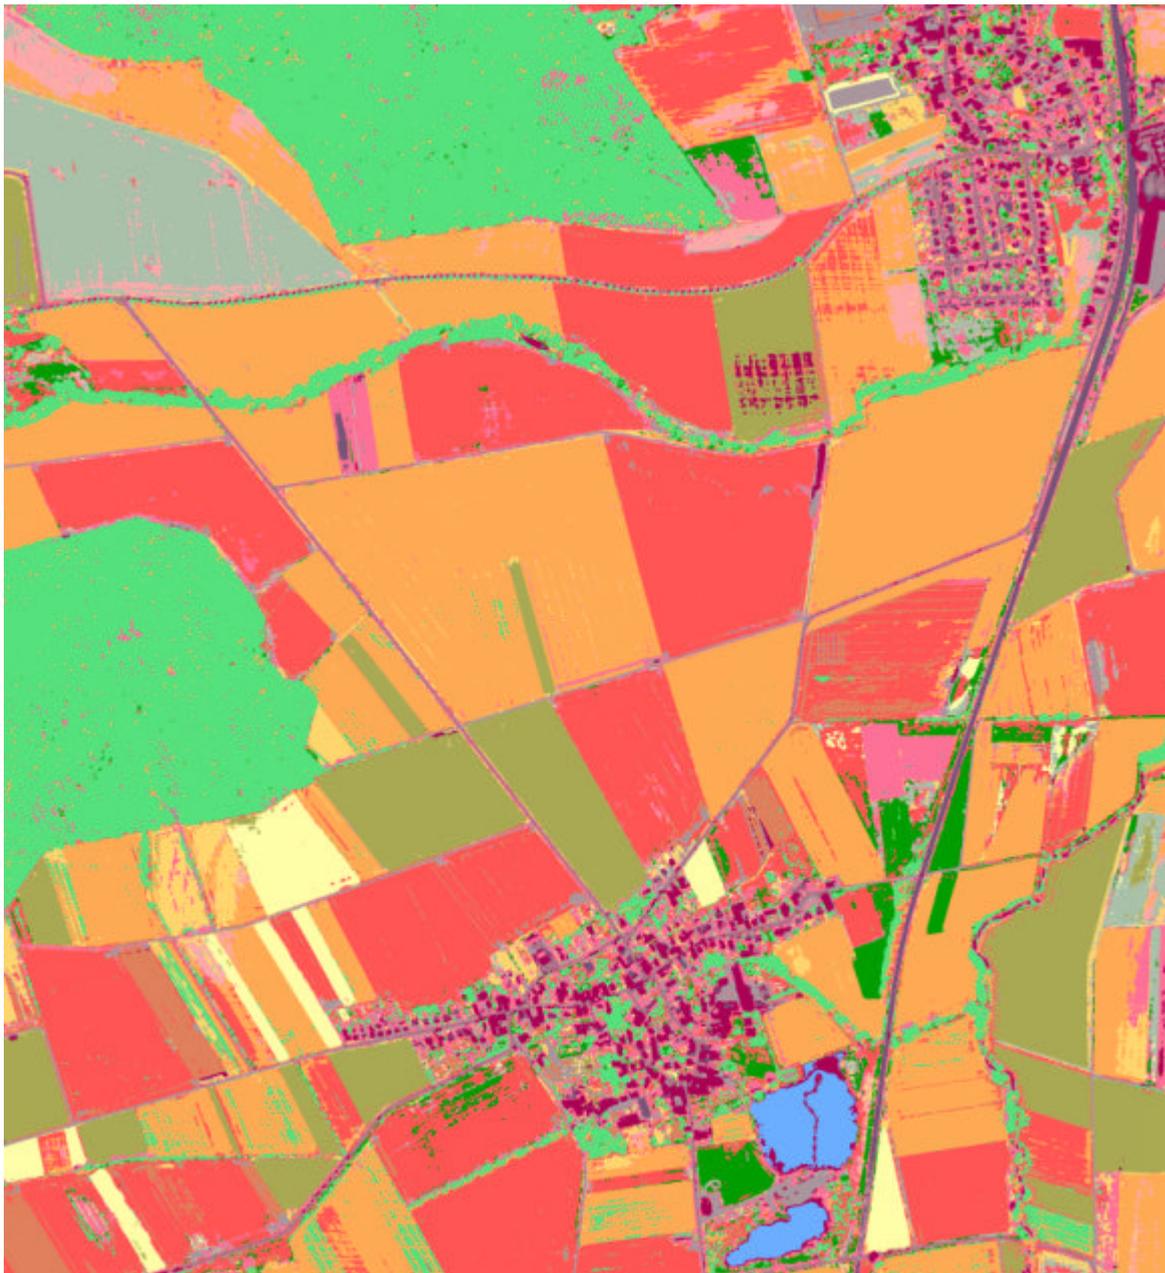


Abb. 4.6.: Maximum - Likelihood - Klassifizierung der 4 DPA - Kanäle

Die Wirksamkeit der Maximum - Likelihood - Methode hängt von einer ziemlich genauen Schätzung der Mittelwertvektoren und der Kovarianzen der Objektklassen ab, die wiederum von der Anzahl der Trainingspixel in jedem Trainingsgebiet abhängig sind.

Betrachtet man Tab. 4.1., so fällt auf, daß sich die Wiedererkennungsgenauigkeit  $G_G$  der Objektklasse *Grünland* erheblich von den anderen Objektklassen unterscheidet. Dieses schlechte Ergebnis könnte damit erklärt werden, daß sich die Pixel innerhalb dieser Trainingsklasse spektral sehr ähnlich sind, und das Maximum - Likelihood - Verfahren deshalb die Wahrscheinlichkeit unterschätzt, daß Pixel weiter vom Klassenmittelpunkt entfernt liegen.

Bei starker Inhomogenität der Pixel in einer Trainingsklasse hingegen, z.B. in der Objektklasse *Wald*, streuen die Pixel im Merkmalsraum so, daß die aus ihnen berechnete Normalverteilungskurve im Merkmalsraum sehr flach verläuft, so daß die Zuweisungsgrenzen weit vom Klassenmittelpunkt entfernt liegen.

Durch die hohen Auflösungen sind die meisten Klassen aufgrund der unterschiedlichen spektralen Oberflächenstrukturen, wie z.B. die Fahrspuren auf den Feldern oder die Kronenformen verschiedener Baumarten, sehr inhomogen, so daß das Maximum - Likelihood - Verfahren die Wahrscheinlichkeit, daß die Pixel weit vom Klassenmittelpunkt der jeweiligen Klasse entfernt liegen können, auch entsprechend hoch einschätzt. Doch durch diese Wahrscheinlichkeit können jedoch manchmal Pixel nicht eindeutig einer Objektklasse zugeordnet werden, wodurch es zu Fehlklassifizierungen kommt. Dieses Problem könnte die teilweise schlechten Zuweisungsgenauigkeiten  $G_Z$  begründen.

Die Einführung von Texturmerkmalen brachte nicht die erwartete Genauigkeitssteigerung ( Abb. 4.7. ). Die Texturmerkmale führten zu geringeren Standardabweichungen und daher zu einem steilen aber engeren Verlauf der Normalverteilungskurve wodurch die Wahrscheinlichkeit weit vom Klassenmittelpunkt entfernt liegender Pixel reduziert wurde.

---



Abb. 4.7.: Maximum - Likelihood - Klassifizierung der 4 Hauptkomponenten nach d)

---

Für das Maximum - Likelihood - Verfahren kann ein Schwellwert gesetzt werden, um nur die Bildpunkte zu klassifizieren, deren Zuordnung mit einer gewissen Zuverlässigkeit erfolgen kann ( Abb.4.7. ). Ist die Wahrscheinlichkeit einer Klassenzugehörigkeit eines Bildpunktes kleiner als dieser Wert, so wird dieser Bildpunkt einer Zurückweisungsklasse zugeteilt. Zum anderen kann durch die Angabe einer a priori Wahrscheinlichkeit berücksichtigt werden, daß die unterschiedlichen Klassen eine unterschiedliche Auftrittswahrscheinlichkeit haben. Die a priori Wahrscheinlichkeit ist hier nicht bekannt. Ein Schwellwert wurde nicht gesetzt, da selbst bei einem Schwellwert von 90% nur wenige Pixel der Zurückweisungsklasse zugeordnet wurden, die im Rahmen einer Nachbearbeitung weiter reduziert würden. Andernfalls werden die Pixel jedoch fälschlicherweise anderen Klassen zugeordnet, was die Zuweisungsgenauigkeit mindert.

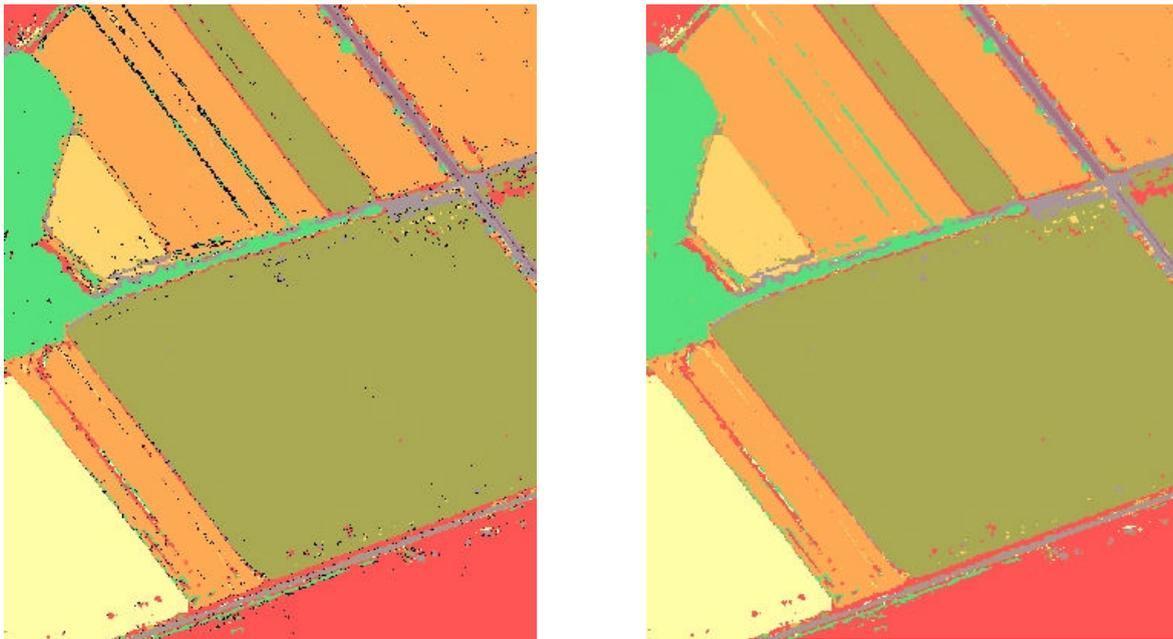


Abb. 4.7.: Einfluß von Schwellwerten: a) ein Pixel wird zurückgewiesen, wenn die Wahrscheinlichkeit der Zugehörigkeit eines Pixels weniger als 90% beträgt, b) ohne Zurückweisungsschwelle

---

Objektklassen	a)		b)		c)		d)		e)	
	$G_W$ %	$G_Z$ %	$G_W$ %	$G_Z$ %	$G_W$ %	$G_Z$ %	$G_W$ %	$G_Z$ %	$G_W$ %	$G_Z$ %
Weizen	91.05	99.00	91.08	98.96	90.44	98.06	80.19	98.58	89.13	99.69
Rüben	94.37	99.03	94.45	99.02	90.77	98.48	85.02	99.20	92.27	99.29
Gerste	95.71	99.97	95.82	99.98	93.16	100.00	80.11	99.20	93.43	100.00
Raps	99.63	94.01	99.70	93.99	87.20	88.88	88.74	32.49	83.78	74.90
Mais	99.78	6.08	99.78	6.18	93.57	6.03	97.60	7.07	95.84	5.46
Hafer	90.46	5.73	90.28	5.40	87.67	4.70	62.93	3.24	86.59	4.64
Kartoffeln	95.37	25.02	95.29	25.49	94.12	16.61	75.06	10.06	97.54	14.89
Triticale	92.44	95.85	92.62	95.59	92.61	92.52	89.19	82.91	90.09	89.58
sonst. Getreide	85.05	13.04	84.77	13.68	88.70	9.43	39.21	4.92	91.18	12.38
Grünland	57.85	45.17	59.12	44.19	53.47	40.72	55.09	5.79	51.06	41.22
Gewässer	97.58	100.00	97.69	100.00	97.69	100.00	99.68	83.07	97.54	100.00
Straßen	99.86	99.71	99.85	99.72	99.02	99.88	88.86	94.90	98.94	98.02
Wege	91.30	19.88	91.02	19.91	80.17	18.31	66.86	15.90	76.12	26.27
Gleisanlagen	92.16	93.80	92.25	93.82	82.07	93.18	59.30	87.73	87.78	94.17
bebaute Flächen	89.00	41.26	89.16	42.66	93.83	68.76	83.49	51.05	89.14	73.56
Mischwald	95.66	97.71	95.72	97.96	95.17	97.54	96.12	94.96	96.24	95.67
	$G_G = 93.57$ %		$G_G = 93.64$		$G_G = 91.77$		$G_G = 85.16$		$G_G = 91.92$	

Tab. 4.1.: Wiedererkennungs- und Zuweisungsgenauigkeit der Maximum - Likelihood - Klassifizierungen

## 4.2.2. Klassifizierung mit dem Backpropagation - Algorithmus

Die Klassifizierung mit dem Backpropagation - Algorithmus erwies sich als wesentlich komplizierter als die Klassifizierung mit dem Maximum - Likelihood - Verfahren.

Bei der Durchführung dieses Verfahrens mußten unbedingt die als Standard gesetzten Parameter geändert werden.

---

So wurde die Lernrate ( siehe Abschnitt 2.1.2. ) von 0.2 auf 1.0 hochgesetzt. Ein kleinerer Wert als der Standardwert von 0.2 verschlechterte das Ergebnis wesentlich ( Abb. 4.8. ), während die Erhöhung des Wertes das Ergebnis steigerte.

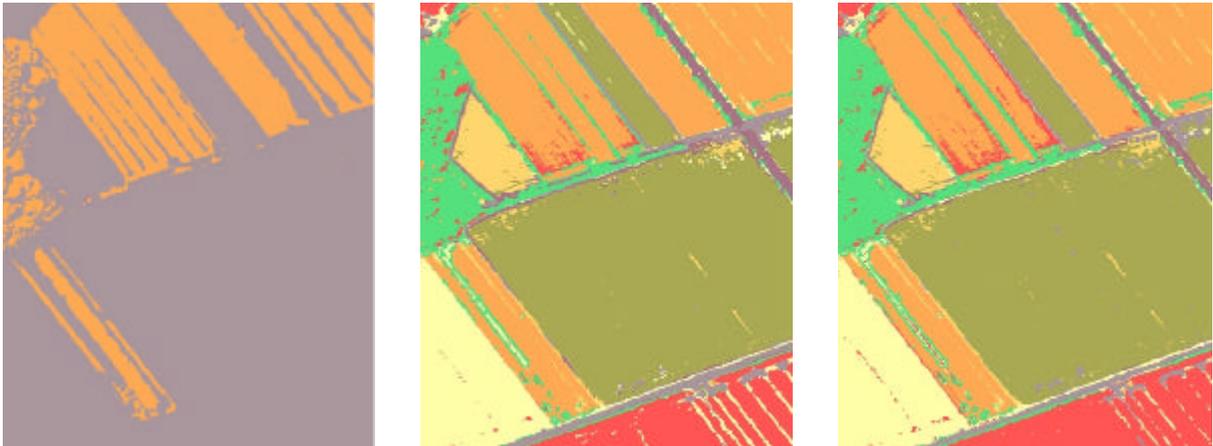


Abb. 4.8.: Einfluß der Lernrate bei einem Wert von 0.01, 0.4 und 1.0

Die Reduzierung des Schwellwertes, der die Lernphase beendet ( siehe 2.1.2. ), von 0.01 auf 0.001 brachte ebenfalls eine Verbesserung des Klassifizierungsergebnisses ( Abb. 4.9. ). Das Heraufsetzen des Wertes beeinflusste die Klassifizierung zum Negativen. Wird der Schwellwert zu klein gewählt, verschlechtert sich das Ergebnis ebenfalls.

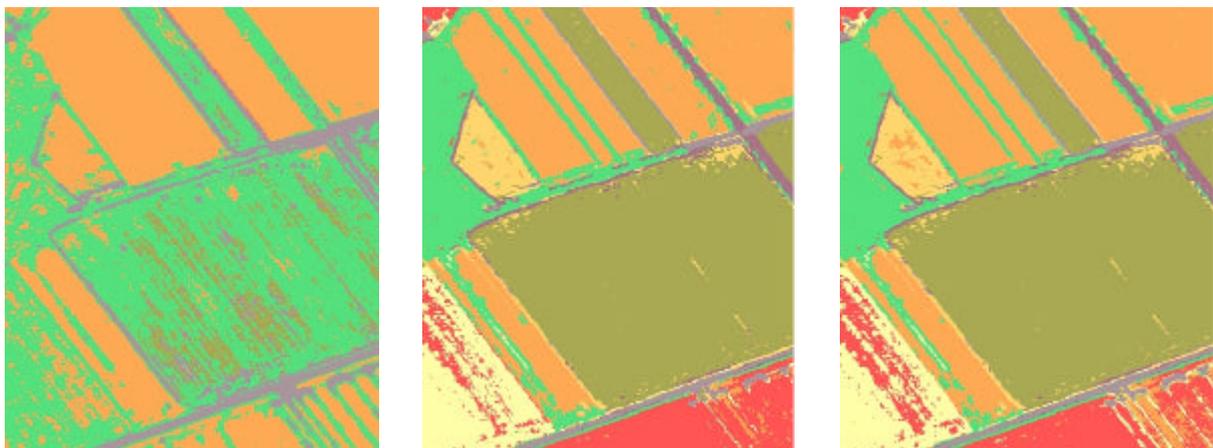


Abb. 4.9.: Einfluß des Schwellwertes bei 0.1, 0.001, 0.0001

---

Betrachtet man Tab. 4.2. so erkennt man, daß die Textur ein wesentliches Merkmal ist, um das Bild zu klassifizieren. Nur die DPA - Daten reichen für eine Klassifizierung mittels neuronaler Netze nicht aus, um das Bild korrekt zu klassifizieren. Einige Klassen sind sogar gar nicht erkannt worden. Das kann daran liegen, daß der Lernvorgang des Backpropagation - Netzes aufgrund der falschen Anfangsgewichte, die zufällig gewählt sind, zum Erliegen gekommen ist ( siehe auch 2.1.2. ). Obwohl diese Gewichte keine Klassensignaturen repräsentieren, sind sie jedoch die Eigenschaften, die aus den Trainingsdaten angelernt werden, um Klassen unterscheiden zu können.

Objektklassen	a)		b)		c)		d)		e)	
	$G_W$ %	$G_Z$ %								
Weizen	0.20	69.66	7.25	99.56	5.24	92.06	78.17	99.17	9.77	93.23
Rüben	96.64	73.05	84.41	96.43	84.76	94.87	86.98	95.25	85.91	96.38
Gerste	0.07	97.62	90.73	98.74	89.69	98.23	89.78	97.55	88.52	99.10
Raps	nicht erkannt		98.48	65.64	99.83	52.72	89.75	63.52	92.17	55.01
Mais	0.29	2.05	83.24	2.82	89.77	3.51	95.49	1.55	93.41	1.62
Hafer	0.00	0.00	28.40	1.24	0.00	0.00	0.00	0.00	0.00	0.00
Kartoffeln	22.72	0.98	56.11	5.18	60.03	3.85	61.62	5.27	53.46	4.19
Triticale	nicht erkannt		1.15	31.08	33.98	90.39	4.21	36.78	1.76	12.12
sonst. Getreide	0.80	37.88	26.47	12.42	30.43	13.36	22.10	70.63	29.91	14.13
Grünland	nicht erkannt		45.60	2.78	4.94	0.40	4.59	0.34	2.24	0.17
Gewässer	100.00	15.91	100.00	97.35	100.00	98.68	99.85	31.80	100.00	64.19
Straßen	90.48	73.56	99.57	76.72	99.96	81.52	54.17	46.44	100.00	70.96
Wege	90.48	0.63	87.25	22.16	66.05	23.12	66.48	8.44	73.98	21.82
Gleisanlagen	92.88	0.00	1.19	86.64	0.29	100.00	61.14	98.37	0.01	50.00
bebaute Flächen	9.32	65.88	54.44	98.70	62.50	81.86	8.00	8.16	70.85	99.47
Mischwald	80.89	39.57	95.95	44.98	95.49	44.12	91.56	98.06	97.02	47.65
	$G_G = 45.14$		$G_G = 59.25$		$G_G = 59.54$		$G_G = 81.47$		$G_G = 60.23$	

Tab 4.2.: Wiedererkennungsgenauigkeiten und Zuweisungsgenauigkeiten bei der Klassifizierung mit dem Backpropagation - Algorithmus

---

Durch die Klassifizierung der Hauptkomponenten ( Abb.4.11. ) konnte das Ergebnis zwar minimal verbessert werden, und auch die Einbeziehung der Texturmerkmale brachte eine Verbesserung ( Abb. 4.12. ), doch sind die Ergebnisse dieser Klassifizierung allgemein nicht zufriedenstellend.

Dieses Problem kann verschiedene Ursachen haben, anzunehmen ist, daß es an der Wahl der Trainingsgebiete liegt. Die Trainingsgebiete sollten eine Objektklasse hinreichend genau und umfassend repräsentieren, d. h., Trainingsgebiete können auch Mischpixels als Randelemente einer Klasse beinhalten. Außerdem sollten alle Objektklassen in etwa gleich stark vertreten sein, da eine unterrepräsentierte Klasse weniger zur Optimierung des Fehlermaßes  $E$  in der Lernphase beiträgt, und daher auch schlechter gelernt wird ( siehe 2.1.2. ).

Eine weitere Schwierigkeit ist, daß durch die in der Regel zufällige Belegung der Anfangsgewichte in der Lernphase des Backpropagation - Algorithmus mit denselben Trainingsdaten nicht exakt derselbe Klassifikator entstehen muß ( Abb. 4.10. ).

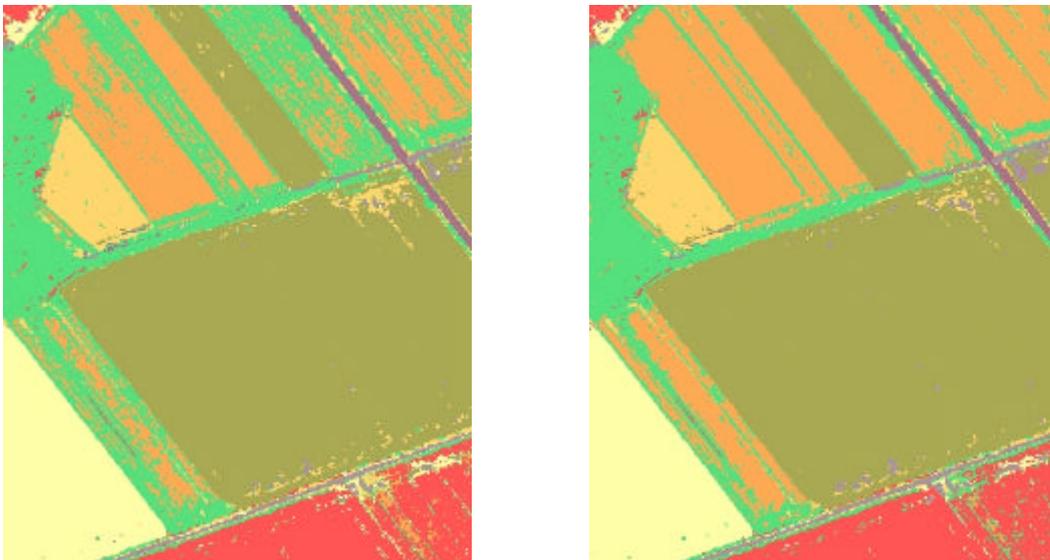


Abb. 4.10.: Klassifizierungen mit dem Backpropagation - Algorithmus und denselben Trainingsdaten

---



Abb.4.12.: Klassifizierung mit dem Backpropagation - Algorithmus der Hauptkomponenten nach Hauptkomponententransformation der 4 DPA - Kanäle ( b) )

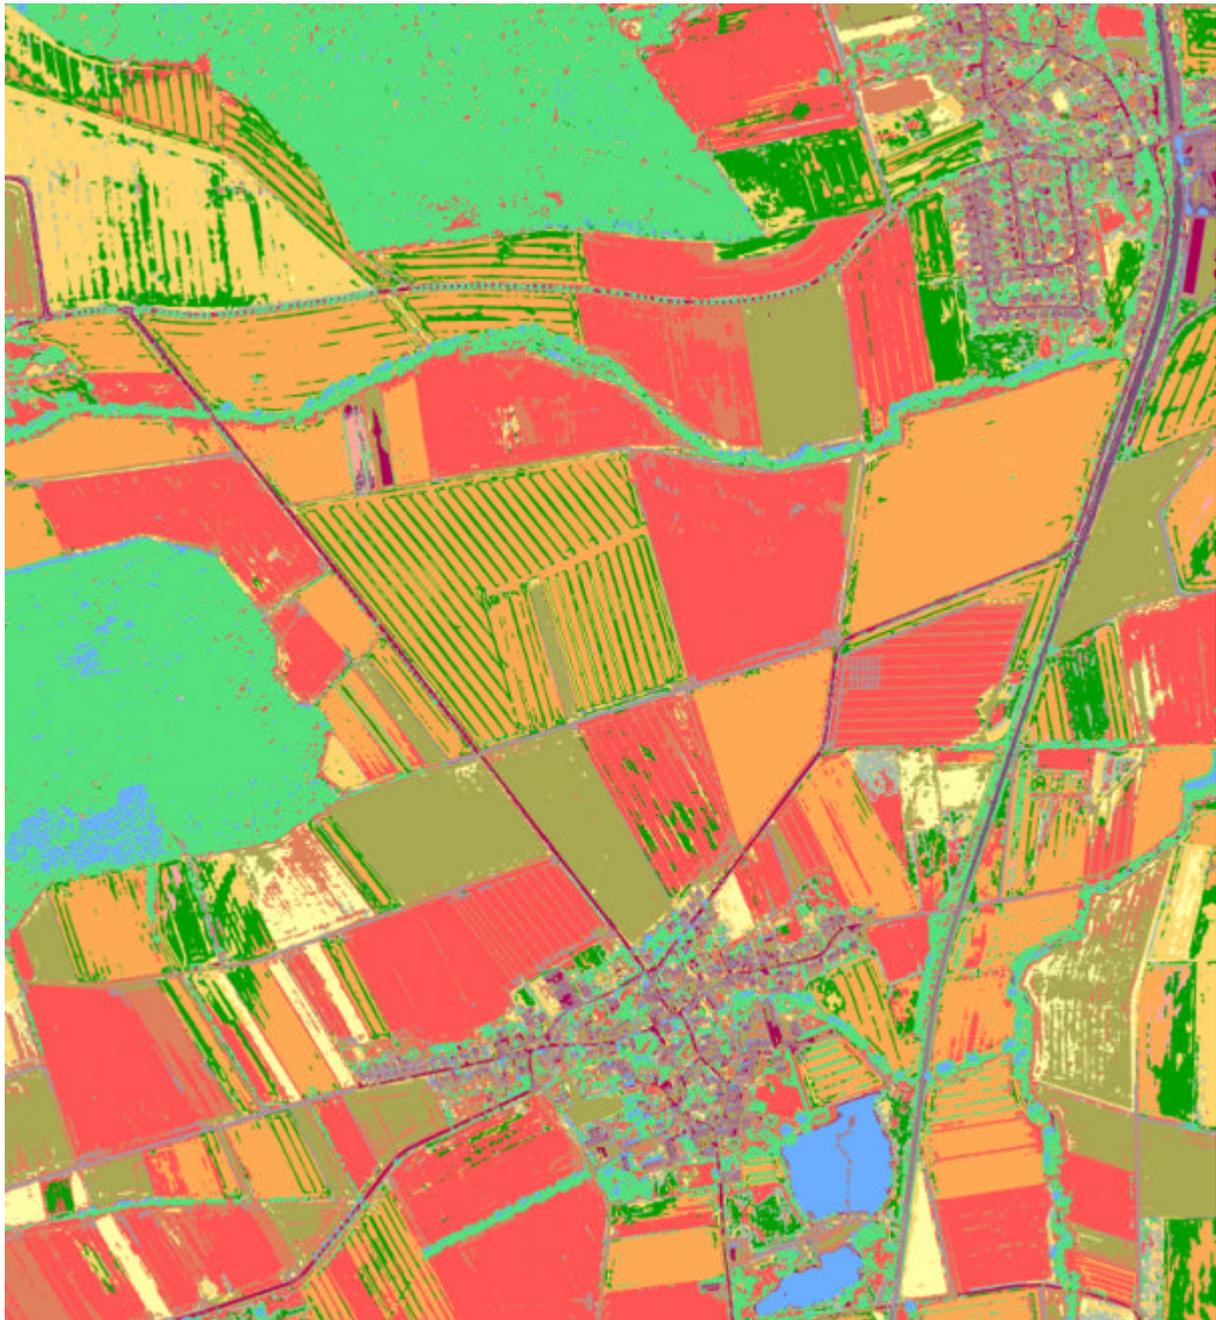


Abb. 4.13.: Klassifizierung mit dem Backpropagation - Algorithmus der 4 Hauptkomponenten nach d)

---

### 4.2.3. Klassifizierung mit dem Fuzzy - C - Means - Algorithmus

Die unüberwachte Klassifizierung ist ein analytisches Verfahren, das sich auf die Clusteranalyse stützt, in der Algorithmen verwendet werden. Durch sogenanntes Clustern werden die Klassen gebildet, die von Interesse sind.

Bei der Klassifizierung mit dem Fuzzy - C - Means - Algorithmus werden als Parameter die Anzahl der Cluster und die maximale Anzahl der Iterationsschritte festgelegt.

Die Clusterbildung ist sehr stark von der anfänglich festzulegenden Anzahl der Klassen und der Bestimmung der Mittelwertvektoren abhängig. Die Mittelwertvektoren der Klassen können aus dem gesamten Bildinhalt oder aus jedem  $n \times n$ - Bildelement ( bis zu 100x100 ) bestimmt werden. Das Verfahren ist jedoch um so genauer, je mehr Bildelemente zur Bestimmung der Mittelwertvektoren genutzt werden, also am genauesten, wenn alle Bildpunkte dafür hinzugezogen werden. Aufgrund des sehr hohen Rechenaufwands bei der Klassifizierung dieser Bildszene konnten die Mittelwertvektoren der Cluster nur aus jedem 100x100 - Bildelement bestimmt werden, maximal aus jedem 20x20 - Bildelement ( Abb. 4.14. ).

Die Zahl der Klassen sollte genügend groß gewählt werden, da die tatsächliche Zahl der Objektklassen in der Regel nicht bekannt ist. Es stellte sich nach einigen Versuchen heraus, daß bei diesem Bild eine anfänglich gewählte Clusterzahl zwischen 80 und 100 auf die 16 festgelegten Objektklassen zusammengefaßt werden konnten.

Das Zusammenfassen der einzelnen Cluster wird durch ein sogenanntes Dendogramm vereinfacht ( Abb. 4.15. ).

Die horizontale Achse zeigt die jeweilige euklidische Distanz ( siehe 2.1.3. ) zwischen zwei Klassenzentren im Merkmalsraum an, die vertikale Achse listet dabei die Objektklassen in geeigneter Reihenfolge auf. Liegen zwei Klassenzentren im Merkmalsraum nah beieinander, so haben sie ähnliche spektrale Eigenschaften und könnten demnach zusammengefaßt werden.

---



Abb. 4.14.: Klassifizierung mit Fuzzy - C - Means - Algorithmus: Mittelwertvektoren der 100 anfänglichen Cluster wurden aus 20x20 - Bildelementen berechnet

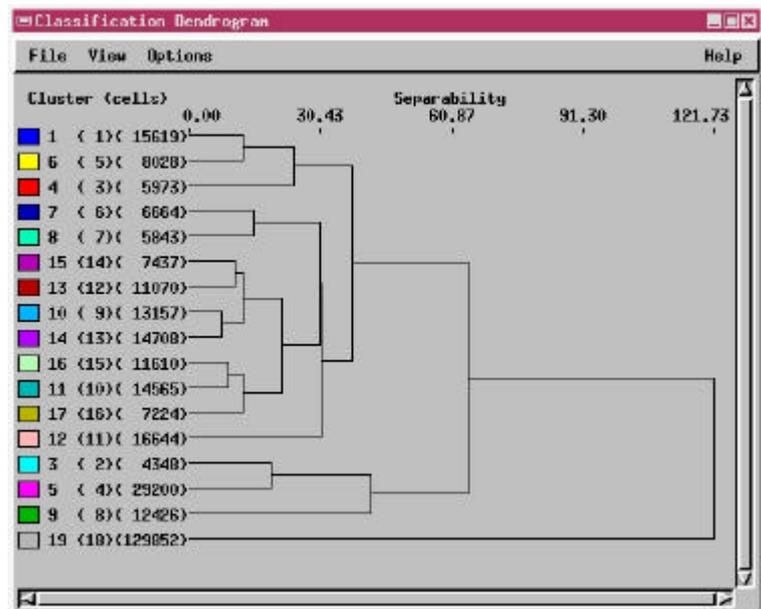
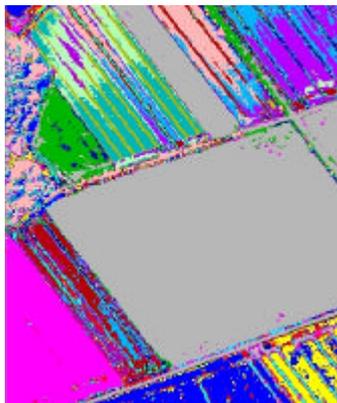


Abb. 4.15.: Klassifizierungsergebnis und zugehöriges Dendrogramm

Das Zusammenfassen der Cluster konnte jedoch nicht immer eindeutig mit dem Dendrogramm durchgeführt werden, da viele Bildpunkte einer Objektklasse weit verstreut im Merkmalsraum liegen, und deshalb fälschlicherweise einer anderen Klasse, nämlich derjenigen mit der kürzeren euklidischen Distanz, zugeordnet werden können. Daher wurde teilweise die Zusammenfassung der Cluster rein visuell durchgeführt.

Bei diesem Verfahren ergaben sich die gleichen Schwierigkeiten wie bei dem Backpropagation - Algorithmus, nämlich, daß die vier Spektralkanäle des Aufnahmesystems allein nicht ausreichen, um dieses Bild zu klassifizieren. Auch hier lieferten erst die Texturmerkmale die Informationen für eine ausreichende Klassifizierung. Jedoch scheinen die genutzten Merkmale nicht auszureichen, da die Klassen *Gleisanlagen*, *Gewässer* und *bebaute Flächen* aufgrund dieser Informationen kaum voneinander zu trennen sind.

---

## 5. Schlußbetrachtung

Die Untersuchungen brachten nicht die gewünschten Resultate hinsichtlich der Genauigkeit bei einer Klassifizierung mit neuronalen Netzen und Fuzzy Sets. Das Maximum - Likelihood - Verfahren ist nach dieser Untersuchung für eine Klassifizierung hochauflösender Bilddaten am ehesten geeignet, da es das sicherste Klassifizierungsergebnis lieferte.

Wenn weitere Merkmale in die Klassifizierung einbezogen würden, wäre die Genauigkeit der Verfahren, zumindest das der Fuzzy Sets, zu steigern.

Die Form als ein weiteres Merkmal, die man durch Segmentierung erhält, wäre ein weiterer interessanter Aspekt.

Die Schwierigkeiten bei der Klassifizierung mit neuronalen Netzen liegen eher in der Bestimmung der Trainingsgebiete und der daraus folgenden Trainingsdaten. Auch die anfänglich zufällige Wahl der Gewichte ist problematisch. Die Klassifizierungen sollten deshalb mehrmals durchgeführt werden, um das bestmögliche Ergebnis zu erhalten.

Das Problem der Fehlklassifizierungen durch räumlich stark differenzierte ( topographisch ) bedingte Beleuchtungsverhältnisse tritt bei allen Verfahren auf.

Was auch für alle Verfahren gleichermaßen gilt, ist der beträchtliche Zeitaufwand der Klassifizierung hochauflösender Daten.

Trotzdem scheinen die hochauflösenden Bilddaten an sich für eine Klassifizierung, zumindest für das Maximum - Likelihood - Verfahren, gut geeignet zu sein.

Die Auswahl eines Klassifizierungsverfahrens und auch die Durchführung ist ein anspruchsvolles Arbeitsgebiet, da die Genauigkeit einer Klassifizierung nicht nur vom Datenmaterial und dem Verfahren abhängt, sondern hauptsächlich von der Erfahrung des Anwenders, der über mehrere Grundlagenkenntnisse in Bereichen wie Statistik, Radiometrie und der jeweiligen Thematik verfügen muß.

Die aus den Trainingsdaten abgeleiteten Signaturen sollen auf die Grundgesamtheit zu übertragen sein. Da die Trainingsgebiete bzw. -daten nur aus diesem Bildmaterial entnommen sind, sind auch nur sichere Aussagen über dieses Bildmaterial möglich.

---

Die Übertragbarkeit der Ergebnisse auf die Bilddaten zu anderen Zeiten werden vor allem durch systematische Veränderungen zwischen den Bilddaten der verschiedenen Jahren bzw. Jahreszeiten, wie z.B. unterschiedlicher Sonnenstand und Jahreszeit, begrenzt.

Die Trainingsklassen sind vermutlich nicht die optimalsten, aber sie sollten zumindest repräsentativ sein und zu verhältnismäßig guten Klassifizierungsergebnissen führen.

---

---

## 6. Literaturverzeichnis

- [Abmayr1994] Abmayr, W.  
Einführung in die digitale Bildverarbeitung  
Teubner, 1994
- [Bähr1991] Bähr, H. - P. / Vögtle, T.  
Digitale Bildverarbeitung - Anwendung in Photogrammetrie,  
Kartographie und Fernerkundung  
Wichmann, 1991
- [Bässmann1993] Bässmann, H. / Besslich, P. W.  
Bildverarbeitung - Ad Oculos  
Springer, 1993
- Canty, M. J. / Kirstein, W.  
Theorie und Praxis der Klassifizierung von multispektralen  
Satellitenbildern mit neuronalen Netzen  
in ZPF (Zeitschrift für Photogrammetrie und Fernerkundung),  
1998
- [Demant1998] Demant, C. / Streicher - Abel, B. / Waszkewitz, P.  
Industrielle Bildverarbeitung - Wie optische  
Qualitätskontrolle wirklich funktioniert  
Springer, 1998
- Dennert - Möller, E.  
Untersuchungen zur digitalen multispektralen Klassifizierung  
von Fernerkundungsaufnahmen mit Beispielen aus den  
Wattgebieten der deutschen Nordseeküste  
Dissertation, 1983
-

- [Fritsch1997] Fritsch, D. / Hobbie, D.  
Photogrammetric Week `97  
Wichmann, 1997
- [Gonzales1992] Gonzales, R. C. / Woods, R. E.  
Digital Image Processing  
Addison - Wesley, 1992
- [Grauel1995] Grauel, A.  
Fuzzy - Logik - Einführung in die Grundlagen mit  
Anwendungen  
BI - Wissenschaftsverlag, 1995
- [Haberäcker1987] Haberäcker, P.  
Digitale Bildverarbeitung - Grundlagen und Anwendungen  
Hanser, 1987
- [Haberäcker1995] Haberäcker, P.  
Praxis der digitalen Bildverarbeitung und Mustererkennung  
Hanser, 1995
- Hachmann, R.  
Untersuchungen zur Grünland - Ackerland - Wald -  
Trennung in ERS-1 Radarbildern  
Diplomarbeit, IPI, 1998
- [Kraus1988] Kraus, K. / Schneider, W.  
Fernerkundung - Band 1, Physikalische Grundlagen und  
Aufnahmetechniken  
Dümmler, 1988
-

- [Kraus1990] Kraus, K.  
Fernerkundung - Band 2, Auswertung photographischer und digitaler Bilder  
Dümmler, 1990
- [Lillesand1994] Lillesand, T. M. / Kiefer, R. W.  
Remote Sensing and Image Interpretation  
John Wiley & Sons, 1994
- [Markwitz1989] Markwitz, W. / Winter, R.  
Fernerkundung - Daten und Anwendungen, Leitfaden 1  
Wichmann, 1989
- [Prinz1997] Prinz, B. / Wiemker, R. / Spitzer, H.  
Simulation of High Resolution Satellite Imagery from Multispectral Airborne Scanner Imagery for Accuracy Assessment of Fusion Algorithms  
Beitrag zum Joint Workshop ISPRS, Hannover, 1997
- [Richards1999] Richards, J. A. / Xiuping, J.  
Remote Sensing  
Digital Image Analysis  
Springer, 1999
- [Ritter1990] Ritter, H. / Martinetz, T. / Schulten, K.  
Neuronale Netze, Eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke  
Addison - Wesley, 1990
-

- [Schowengerdt1997] Schowengerdt, R. A.  
Remote Sensing - Models and Methods for Image  
Processing  
Academic Press, 1997
- [Schumacher1992] Schumacher, H.  
Überwachte Klassifikation von Fernerkundungsaufnahmen  
Forschungsbericht, DLR - FB 92 - 07
- Sentner, U.  
Untersuchungen zur Erkennbarkeit von Torfflächen in ERS-1  
Radarbildern  
Diplomarbeit, IPI 1997
- [Tilli1993] Tilli, T.  
Mustererkennung mit Fuzzy - Logik - Analysieren,  
klassifizieren, erkennen und diagnostizieren  
Franzis, 1993
- Wiemker, R.  
Unsupervised Fuzzy Classification of Multispectral Imagery  
Using Spatial - Spectral Features  
in  
Balderjahn, I. / Mathar, R. / Schader, M.  
Data Highways and Information Flooding - a Challenge for  
Classification and Data Analysis  
Springer, 1997
- TNTmips  
Reference Manual  
Getting Started Booklets
-

## Erklärung

Hiermit erkläre ich, daß ich die vorliegende Diplomarbeit selbständig und nur mit den angegebenen Hilfsmitteln angefertigt habe.

Vehlen, den 20.12.1999

A handwritten signature in black ink, reading 'J. Schnellert'. The signature is written in a cursive style with a large initial 'J'.

( Jessica Schnellert )