

Universität Jena, Institut für Geographie  
Proseminar II „Bildverarbeitung“  
WiSe 2001/2002  
Leitung: Prof. Dr. Christiane Schmullius

Matthias Basler

# Principal Components

(Datentransformation II)

Jena, den 18.12.2000

# Inhalt

<b>1</b>	<b><u>Abbildungsverzeichnis</u></b> .....	<b>2</b>
<b>2</b>	<b><u>Einleitung – Der Begriff „Principal Components“</u></b> .....	<b>3</b>
<b>3</b>	<b><u>Die Grundidee</u></b> .....	<b>4</b>
<b>4</b>	<b><u>Mathematische Details</u></b> .....	<b>6</b>
4.1	<u>Die Kovarianzmatrix</u> .....	6
4.2	<u>Die Korrelationsmatrix (correlation matrix)</u> .....	6
4.3	<u>Eigenwert und PVA</u> .....	7
4.4	<u>Die Transformationsmatrix und die Eigenvektoren</u> .....	7
<b>5</b>	<b><u>Anwendungsgebiete mit Schwerpunkt in der Bildverarbeitung</u></b> .....	<b>8</b>
5.1	<u>Kompression</u> .....	8
5.2	<u>Hochinformativ RGB-Darstellung</u> .....	8
5.3	<u>Hilfestellung bei visueller Bildsegmentierung und Klassifikation</u> .....	9
5.4	<u>Isolieren von Beleuchtungseffekten durch Relief</u> .....	9
5.5	<u>Erleichterung der Datenauswertung</u> .....	10
5.6	<u>Farbkontrasterhöhung nach Taylor</u> .....	10
5.7	<u>Andere Einsatzgebiete</u> .....	11
<b>6</b>	<b><u>Zusammenfassung</u></b> .....	<b>12</b>
<b>7</b>	<b><u>Literaturverzeichnis</u></b> .....	<b>13</b>

## 1 Abbildungsverzeichnis

Abbildung 1:	Visuelle Darstellung der Verschiebung der Koordinatenachsen bei einer PCT von 2 Dimensionen. (eigener Entwurf).....	4
Abbildung 2:	Vier Originalkanäle eines Landsat-MSS-Bildes. (Quelle: RICHARDS 1999, S. 41).....	5
Abbildung 3:	Die Principal Components der obigen Szenen. (Quelle: RICHARDS 1999, S. 41).....	5
Abbildung 4:	Eine Korrelationsmatrix für ein TM-Satellitenbild. (Quelle: CONESE 1988, S. 1600).....	6
Abbildung 5:	Transformationsmatrix, Eigenwerte und PVA für ein TM-Satellitenbild. (Quelle: CONESE 1988, S. 1600).....	7
Abbildung 6:	Vergleich zwischen einem Landsat-MSS-Komposite aus den Bändern 7, 5 und 4 (RGB) und einem PC1-2-3-Komposite (RGB). (Quelle: RICHARDS 1999, S. 142).....	8
Abbildung 7:	Lineare Kontrastverstärkung deckt nicht den gesamten Farbraum ab. (Quelle: eigener Entwurf nach DRURY 1998, S. 58).....	10
Abbildung 8:	Farbkontrasterhöhung nach Taylor. (Quelle: DRURY 1998, S. 58).....	10
Abbildung 9:	Vergleich zwischen linearer Kontraststreckung (links) und Dekorrelationsstreckung nach Taylor (rechts). (Quelle: Drury 1998, S. 57, 59).....	11

## **2 Einleitung – Der Begriff „Principal Components“**

Es existiert ein statistisches Verfahren, das im Deutschen „Hauptkomponentenanalyse“ genannt wird. Weitaus gebräuchlicher sind allerdings die englischen Ausdrücke „Principal Components Analysis“ (PCA) oder „Principal Components Transformation“ (PCT), welche genau das gleiche Verfahren beschreiben. Exakt betrachtet versteht man unter der PCA die statistische Analyse der Ausgangsdaten und unter PCT das Durchführen der Transformation der Daten aufgrund der bei der PCA ermittelten Werte. Meist werden beide Begriffe aber synonym gebraucht.

Es handelt sich wie gesagt um ein statistisches Verfahren, was auch bedeutet, dass die PCA nicht auf die Bildverarbeitung beschränkt ist, sondern dort nur besondere Anwendungen erhält. Vielmehr wird das Verfahren überall dort eingesetzt, wo mehrdimensionale Datensätze statistisch ausgewertet werden müssen – vor allem aber in der Ökologie und in Sozialwissenschaften. Dabei meint „mehrdimensionale Datensätze“ in diesem Fall so verschiedene Dinge wie Farbbilder mit drei Kanälen, Thematic-Mapper-Aufnahmen mit ihren 6 oder 7 Bändern, Aufnahmen von Multispektralscannern, Radarbilder mit verschiedenen Polarisierungen, multitemporale, koreferenzierte Bilder oder andere multitemporale Datensätze der Geographie und anderer Wissenschaften wie z.B. langjährige Meßreihen. In dieser Hausarbeit soll aber insbesondere auf den Einsatz in der Fernerkundung eingegangen werden.

### 3 Die Grundidee

Das Ausgangsmaterial für eine Principal-Components-Transformation ist ein mehrdimensionales Datenset mit  $n$  Dimensionen. In der Regel weisen diese mehrdimensionalen Datensets in zwei oder mehreren der Dimensionen Korrelationen auf. So könnten sich zum Beispiel zwei Bänder eines Satellitenbildes recht ähnlich sehen, oder zwei Untersuchungen an verschiedenen Zeitpunkten weisen große Übereinstimmungen auf. Ist dies der Fall, dann ist eine Principal-Components-Analyse (PCA) sinnvoll.

Sind zwei Dimensionen stark korreliert, so bedeutet das, daß man aus den Informationen einer Dimension die andere Dimension durch eine Regressionsgleichung ungefähr berechnen kann. (Die Informationen liegen oft auf oder nahe einer Linie, vgl. Abbildung 1). Somit ließen sich die Informationen der beiden Dimensionen ohne große Verluste auf eine Dimension reduzieren. Genau das ist der Ansatz der PCT.

Basis bildet der Merkmalsraum (*Feature Space*), in den alle Pixel je nach ihren DN-Werten in den verschiedenen Kanälen eingetragen werden. Sie bilden darin eine mehrdimensionale Wolke. Die Koordinatenachsen geben die Helligkeit in den einzelnen Bändern an. Im Grunde handelt es sich bei der PCT nur um ein „Umverlagern“ des Koordinatensystems um gerade erklärte Punkt Wolke. Die PCT erzeugt aus dem  $n$ -dimensionalen Datenraum ein neues  $n$ -dimensionales Koordinatensystem mit den Achsen PC1, PC2 usw. Dabei wird die Achse PC1 so gelegt, daß sie die am häufigsten codierten Informationen enthält, also längs der höchsten Varianz. PC2 liegt senkrecht zu PC1 und enthält die am häufigsten codierten der noch verbleibenden Informationen.

Alle anderen Achsen folgen nach dem gleichen Prinzip.

Aus den  $n$  Ausgangsbildern oder Datensätzen erhält man somit  $n$  neue Bilder bzw. Datensätze mit folgenden Eigenschaften :

- Die neuen Datensätze haben mit den ursprünglichen Eigenschaften der Datensätze (wie z.B. Wellenlänge bei FE-Bildern oder den Untersuchungszeiten) nichts mehr zu tun (RICHARDS 1999, S. 144).
- Die Datensätze sind nach Informationsgehalt geordnet. Im PC1 sind zum Beispiel 80 % der ursprünglichen Informationen enthalten, im PC2 noch 15 % im PC3 nur noch 5 %. Die Konzentrierung der Informationen ist aber abhängig von der ursprünglichen Korrelation.
- Die Datensätze enthalten zwar keine neuen Informationen, erlauben aber ähnlich den Ratiobildern, neue Zusammenhänge besser zu erkennen und auszuwerten.
- Alle neuen Datensätze sind nun nicht mehr miteinander korreliert (NCGIA (N.N.))

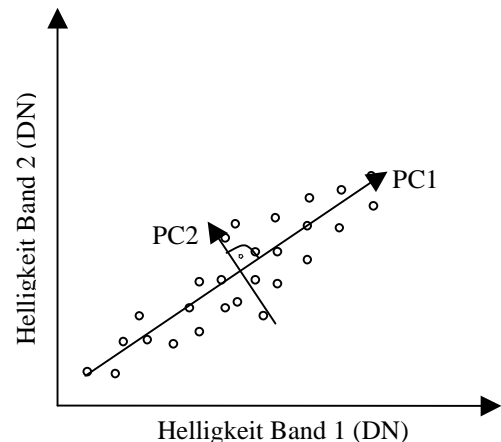


Abbildung 1: Visuelle Darstellung der Verschiebung der Koordinatenachsen bei einer PCT von 2 Dimensionen. (eigener Entwurf)




Abbildung 2: Vier Originalkanäle eines Landsat-MSS-Bildes. Die hohe Korrelation ist bereits visuell zu erkennen. (Quelle: RICHARDS 1999, S. 41)




Abbildung 3: Die Principal Components der obigen Szenen: PC1 (l.o.), PC2 (l.u.), PC3 (r.o.) und PC4 (r.u.). Die Informationsakkumulation in den ersten PC-Kanälen sowie das Ansammeln von (per Definition unkorreliertem) Rauschen in den hinteren Kanälen wird deutlich. Daß der Grauwertebereich, also der Kontrast, von PC1 bis PC4 stark abnimmt, ist hier kaum zu erkennen. (Quelle: RICHARDS 1999, S. 41)

## 4 Mathematische Details der PCA

Bei den meisten Bildbearbeitungsprogrammen mit PCA verlaufen die gesamten Berechnungen im Hintergrund. Der Nutzer erhält lediglich das fertige Bild mit den n Kanälen, die den Principal Components 1 bis n entsprechen, sowie die statistischen Daten. (Bei Erdas Imagine kann man sich auch auf die Berechnung der ersten PC beschränken.) Insofern soll an dieser Stelle auf ein komplettes Berechnungsverfahren verzichtet werden. Zur Auswertung des berechneten Bildes sind aber einige Kenntnisse der ebenfalls berechneten statistischen Parameter nötig:

### 4.1 Die Kovarianzmatrix

Die (**Varianz**)-**Kovarianzmatrix** ist das erste mathematische Hilfsmittel auf dem Weg zur Transformation. Ein Element der Kovarianzmatrix an der Stelle (i, j) berechnet sich über

$$v_{ij} = \frac{1}{n-1} \cdot \sum_{i=1}^n \left( (x_i - \bar{x}_i) \cdot (x_j - \bar{x}_j) \right)$$

mit  $\bar{x}_i$  und  $\bar{x}_j$  als mittlere Helligkeit aller Punkte auf dem Band i bzw. j,  $x_i$  und  $x_j$  als Helligkeiten der Punkte in den Bändern i und j. N ist die Anzahl der Bänder (Dimensionen).

Somit berechnet sich der Punkt (i, j) wie folgt: Die Differenz der Helligkeit eines Punktes im Bild zu der durchschnittlichen Helligkeit aller Punkte wird berechnet; dies geschieht mit den beiden zu vergleichenden Bändern. Beide Ergebnisse werden multipliziert und für alle Bildpunkte aufsummiert. Anschließend wird diese Summe noch durch die um eins verringerte Anzahl der Bänder dividiert.

### 4.2 Die Korrelationsmatrix

In der **Korrelationsmatrix** sind alle Werte der oben beschriebenen Kovarianzmatrix mit folgender Formel normiert:

$$q_{ij} = v_{ij} \cdot (v_{ii} \cdot v_{jj})^{-1/2}$$

Dabei ist  $v_{ij}$  der entsprechende Eintrag in der Kovarianzmatrix und  $v_{ii}$  und  $v_{jj}$  die Varianzen der beiden Bänder i und j.

Band	1	2	3	4	5	6	7
1	1.00	0.96	0.94	0.38	0.61	0.07	0.76
2	0.96	1.00	0.98	0.45	0.70	0.13	0.84
3	0.94	0.98	1.00	0.41	0.71	0.14	0.87
4	0.38	0.45	0.41	1.00	0.79	0.44	0.59
5	0.61	0.70	0.71	0.79	1.00	0.55	0.92
6	0.07	0.13	0.14	0.44	0.55	1.00	0.42
7	0.76	0.84	0.87	0.59	0.92	0.42	1.00

Abbildung 4: Eine Korrelationsmatrix für ein TM-Satellitenbild. Hohe Zahlen zeigen eine starke Korrelation zwischen den entsprechenden Kanälen. (Quelle: CONESE 1988, S. 1600)

Die Werte der Diagonalen einer Korrelationsmatrix sind selbstverständlich 1, da jedes Band mit sich selber eine Korrelation von 1 besitzt. Sind alle anderen Werte relativ hoch (z.B. größer als 0,7), so sind alle Bänder stark miteinander korreliert, und eine PCT ist angebracht.

Die Korrelationsmatrix ist im Allgemeinen einfacher zu interpretieren als die Kovarianzmatrix und wird somit meist bevorzugt. Ihre Berechnung übernimmt i.d.R. der Computer.



### 4.3 Eigenwert und PVA

Natürlich läßt sich auch für das neue, vom Computer berechnete Koordinatensystem eine Kovarianzmatrix aufstellen. Dies wäre dann die Kovarianzmatrix der einzelnen PC-Kanäle zueinander. Da per Definition die Achsen so gelegt wurden, daß alle PC-Kanäle unkorreliert sind, besitzt diese Matrix nur diagonale Komponenten; alle anderen Felder sind 0 (→ keine Korrelation). Die Werte der Diagonalen werden als **Eigenwerte** bezeichnet und entsprechen den Varianzen der Kanäle. Teilt man die Eigenwerte durch ihre Gesamtsumme, erhält man die **PVA (Percentages of variance accounted)**, die den Anteil der pro PC-Kanal erklärten Varianz darstellen. Ihre Summe beträgt nun 1 bzw. 100%.

Eigenvector	1	2	3	4
1	0.39	-0.34	-0.10	0.45
2	0.42	-0.28	-0.07	0.21
3	0.42	-0.28	-0.14	0.01
4	0.30	0.40	0.75	0.33
5	0.41	0.28	0.14	-0.45
6	0.17	0.68	-0.59	0.32
7	0.43	0.05	-0.11	-0.56
Eigenvalue	4.83	1.39	0.50	0.19
PVA	69	20	7	3

Abbildung 5: Transformationsmatrix, Eigenwerte und PVA für ein TM-Satellitenbild. Bei der Transformationsmatrix, welche links die Ausgangsbänder und oben die PC1 bis PC4 zeigt, wurden die letzten drei PC-Kanäle nicht aufgelistet, da sie vernachlässigt wurden. (Quelle: CONESE 1988, S. 1600)

PVA = Percentages of variance accounted.

Die Eigenwerte und die sogenannten PVA dienen dazu, den Gesamtinformationsgehalt der Bilder abzuschätzen. Näherungsweise entspricht nämlich der Anteil der Varianz auch dem Anteil der Informationen, die in dem jeweiligen Bild einer PC-Komponente enthalten sind. Eine PVA von 0,6 (60 %) bedeutet also, daß der PC-Kanal rund 60% der Informationen des Gesamtbildes enthält. Sie sind das wichtigste Hilfsmittel, wenn es darum geht, einige hintere PC-Kanäle (z.B. zwecks Kompression) wegzulassen und den Anteil der dadurch verloren gehenden Informationen zu berechnen.

### 4.4 Die Transformationsmatrix und die Eigenvektoren

Natürlich ist es auch wichtig, zu wissen, wie sich denn die einzelnen PC genau errechnet haben, wie also das Koordinatensystem gedreht wurde. Dies läßt sich aus der **Transformationsmatrix** (siehe Abb. 5 oben) ablesen. Aus ihr lassen sich einerseits die Rotationsgleichungen direkt ableiten, zum anderen gibt sie dadurch Aufschluß über die Aussagekraft der einzelnen Principal Components. Wie auch in der Beispielmatrix ersichtlich, wird die PC1 aus mehr oder weniger gleichen Anteilen aller Kanäle gebildet (0,3 bis 0,43; Ausnahme Thermalkanal: 0,17). Somit stellt PC1 die durchschnittliche Helligkeit aller Bilder dar, was oft z.B. mit dem Relief verbunden ist. Die PC2 bildet sich zum Beispiel aus positiven IR und negativen VIS- Komponenten. Sie wird folglich das Verhältnis von Infrarot zu sichtbarem Licht darstellen, was z.B. für die Vegetationskartierung wichtig ist. Entsprechend lassen sich auch die anderen PC interpretieren.

Die Zahlen in der Transformationsmatrix werden als **Eigenvektoren** bezeichnet, da sie – zusammengenommen für einen PC-Kanal – die Vektoren der einzelnen Achsen PC1 bis PCn bilden.

## 5 Anwendungsgebiete mit Schwerpunkt in der Bildverarbeitung

In der Bildverarbeitung scheinen die Anwendungsmöglichkeiten der PCA auf den ersten Blick überwältigend. Tatsächlich ist die PCA hier ein wichtiges Verfahren. Da zur richtigen Nutzung aber einige Vorkenntnisse notwendig sind und ihre Berechnung auch einige Zeit in Anspruch nehmen kann, sollte ihr Einsatz wohlüberlegt sein. Im folgenden sind die Anwendungsmöglichkeiten ohne Wertung ihrer Wichtigkeit aufgelistet.

### 5.1 Kompression

Im Grunde handelt es sich bei der PCA um einen reversiblen Vorgang. Man kann also unter Kenntnis der Lage des Ausgangskoordinatensystems oder der Transformationsmatrix das ursprüngliche Bild bzw. die ursprünglichen Datensätze wieder extrahieren. Dies macht es möglich, PCA als eine Form der Datenkompression zu verwenden.

Wie bereits mehrfach erwähnt, besitzen die letzten Principal Components nur einen geringen Informationsgehalt (einen kleinen Eigenwert). Somit ist es oft möglich die letzte PC – oder im Falle von vieldimensionalen Datensätzen auch mehrere hintere Principal Components – ohne erheblichen Informationsverlust wegzulassen. Auch aus den ersten PC-Dimensionen allein lassen sich unter Kenntnis der Lage der ursprünglichen Achsen die Ausgangsdatsätze bzw. Wellenlängenbänder ungefähr wieder rekonstruieren.


An dieser Stelle sei deutlich darauf hingewiesen, daß es bei dieser Kompression (im Gegensatz zu z.B. anderen Formen der verlustbehafteten Bildkompression) vorkommen kann, daß auch oder gerade in den hinteren, zu löschenden, PC-Dimensionen Informationen enthalten sind, die für spezielle Auswertungen der Geographie wichtig sind. Nach RICHARDS (1999, S. 144) kommt es oft vor, daß geologische Strukturen erst in den hinteren PC-Dimensionen sichtbar werden.

Bei spektroskopischen Aufnahmen mit ihren über 100 Bändern ist die PCA nahezu unerlässlich.

### 5.2 Hochinformativ RGB-Darstellung

Von einem multispektralen Bild lassen sich stets nur maximal drei Komponenten auf einem Bildschirm oder Ausdruck darstellen. Somit versucht man, drei Bänder auszuwählen, die in der Summe den höchsten Informationsgehalt besitzen. Wählt man nach einer PCA die ersten drei Dimensionen (meist PC1 auf R, PC2 auf G, PC3 auf B), so kann man sicher sein, das definitive Maximum an Informationen darzustellen, da diese Kanäle die höchsten Eigenwerte besitzen. Daß sich diese Darstellung stets leichter auswerten läßt, ist damit jedoch nicht gesagt.

Abbildung 6: Vergleich zwischen einem Landsat-MSS-Komposite aus den Bändern 7, 5 und 4 (RGB) und einem PC1-2-3-Komposite (RGB). Letzteres zeigt verschiedenartige Bildbereiche und Strukturen wesentlich deutlicher. (Quelle: RICHARDS 1999, S. 142)





### **5.3 Hilfestellung bei visueller Bildsegmentierung und Klassifikation**

Aus dem eben genannten läßt sich erkennen, daß die ersten PC-Komponenten einen Großteil der Informationen des Gesamtbildes enthalten. Dies kann man sich bei einer Bildsegmentierung zu Nutze machen. Felder gleicher Farbe in einem PC1-2-3-Komposite eines TM-Bildes zeigen mit sehr hoher Wahrscheinlichkeit geologisch und botanisch gleiche Landoberflächen, was ja z.B. bei einem Komposite der drei sichtbaren Kanäle nicht der Fall ist. Es lassen sich also bereits auf dem Bildschirm Bereiche gleicher oder unterschiedlicher Bodenbedeckung/Geologie/etc. erkennen. Dies kann z.B. bei der Auswahl der homogenen Trainingsgebiete oder einer Segmentierung des Bildes zwecks Klassifikation sinnvoll sein.

An dieser Stelle sein auf den Text von BARTONI ET AL. (1997) verwiesen, welcher sich diesen Umstand zu Nutze macht, um mittels Spektrometerdaten alte Gemälde zu analysieren. Dabei fällt die exakte Analogie zur Geographie auf: Während BARTONI ET AL. ein Gemälde segmentieren, um Rückschlüsse auf die räumliche Verteilung der (chemisch unterschiedlichen) verwendeten Farben zu erhalten, wird in der Geographie das Luftbild segmentiert, um Rückschlüsse auf die (unterschiedlich zurückstreuenden) Landnutzungen u.ä. zu erhalten. Sein Schluß kann folglich auch für die Bildverarbeitung gelten: *“Image Spectroscopy in the visible and near-infrared regions, in conjunction with PCA can be profitably used for segmenting painted zones characterized by similar spectral behavior and therefore to map areas according to their chemical composition or physical properties”* (BARTONI ET AL 1997, S. 21).

JAN VERHOEYE und ROBERT DE WULF untersuchten den Einsatz der PCT in einer Bildverarbeitungskette, ausgehend von ERS-1-Radardaten (PRI) mit mehreren Kanälen (multitemporär, zusätzlich Texturkanal). Auch sie setzten die PCT als einen Zwischenschritt vor der Bildsegmentierung mittels eines Pyramidensegmentierungsverfahrens ein. Ihr Ergebnis ist: *„... PCT yields a modest gain in accuracy. Nevertheless the application of PCT can be valuable considering the modest amount of processing time involved“* (VERHOEYE & WULF 1999, S. 1184).

Auch bei der Klassifikation selbst kann die Principal Components Analysis helfen. MAIERSPERGER ET AL. (2001) erzeugten sich zur klassifikatorischen Unterscheidung von alten und jungen Coniferen sowie von Laubgehölzen einen zweidimensionalen Merkmalsraum aus PC1 und PC2. Dieser Scatter plot enthielt 97,8% der ursprünglichen (Landsat-TM)-Informationen. Auf ihm ließen sich die drei Regionen „alte Nadelgehölze“, „junge Nadelgehölze“ und „Laubgehölze“ gut trennen und somit Referenzpunkte für weitergehende Klassifikationen festlegen (MAIERSPERGER ET AL. 2001, S. 1058 f.).

### **5.4 Isolieren von Beleuchtungseffekten durch Relief**

Relief stellt bei einer helligkeitsbasierten Klassifikation wie oft bei Landnutzungs-klassifikationen ein ernsthaftes Problem dar, welches zu falschen Einordnungen von beleuchteten oder beschatteten Flächen führen kann. Es wäre sehr wünschenswert, könnte man die reliefbedingten Helligkeitsunterschiede von den landnutzungsbedingten trennen. In gewissem Umfange ist die PCA

dazu in der Lage. Sie macht sich den Umstand zunutze, daß reliefbedingte Helligkeitsunterschiede (bei am Tage aufgenommenen TM-Daten) auf allen Kanälen sichtbar sind, während landnutzungsbedingte Helligkeitsunterschiede i.d.R. kanalspezifisch unterschiedlich sind. Die PCA wird also die reliefbedingten Unterschiede als stärkste Varianz identifizieren und auf die Achse PC1 legen (nach CRIST und CICONE, FRANKLIN, HORLER und AHERN, zitiert in CONESE ET AL. 1988 ). Somit läßt sich die PC1 i.d.R. als „Durchschnittshelligkeit“ deuten. Die Achse PC2 besitzt bereits nur noch einen sehr geringen Anteil an reliefbedingten Helligkeitsunterschieden, in PC3 sind sie noch geringer usw.; die landnutzungsbedingten Unterschiede treten relativ dazu in den Vordergrund.

CENESE ET AL. (1988) verwenden deswegen beispielsweise zur Waldklassifikation Verfahren, die auf den Achsen PC2-PC7 basieren. Sie können zeigen, daß sich auf diese Weise bessere Ergebnisse erzeugen lassen, als durch Ratiobilder aus zwei Bänder, einem anderen Verfahren zur Verminderung der Reliefeinflüsse.

### 5.5 Erleichterung der Datenauswertung

Bestimmte Strukturen sind in einzelnen Wellenlängenbändern oder -kombinationen nicht zu sehen, sondern lassen sich erst bei Kombination aller Wellenlängen z.B. in einem Komposite auswerten. Mit der PCA lassen sich die in dem Multispektralbild enthaltenen Informationen so umordnen, daß Strukturen, die in den Graustufenbildern oder selbst in RGB-Kompositen nicht auffielen, plötzlich hervortreten. So kann es sein, daß eine bestimmte PC-Dimension oder ein RGB-Komposite mehrerer PC-Kanäle geologische oder andere „unsichtbare“ Strukturen prägnant heraushebt.

### 5.6 Farbkontrasterhöhung nach Taylor

Ein Verfahren zur Erhöhung des Farbkontrasts mittels PCT wird von DRURY (1998) und RICHARDS & XIUPING (1999) erläutert. Im Gegensatz zu einer linearen Farbstreckung („linearly stretched FCC“, Abbildung 7), welche in allen Kanälen separat eine lineare Kontraststreckung durchführt, erhält man mit der PCT bei dem auch „decorrelation stretch“ genannten Verfahren weit bessere Ergebnisse; die Bilder wirken viel farbiger (vgl. Abbildung 7) und nutzen fast den kompletten Farbraum, obwohl sich laut DRURY (1998, S. 58) der Farbwert (*hue*) der einzelnen Pixel kaum ändert.


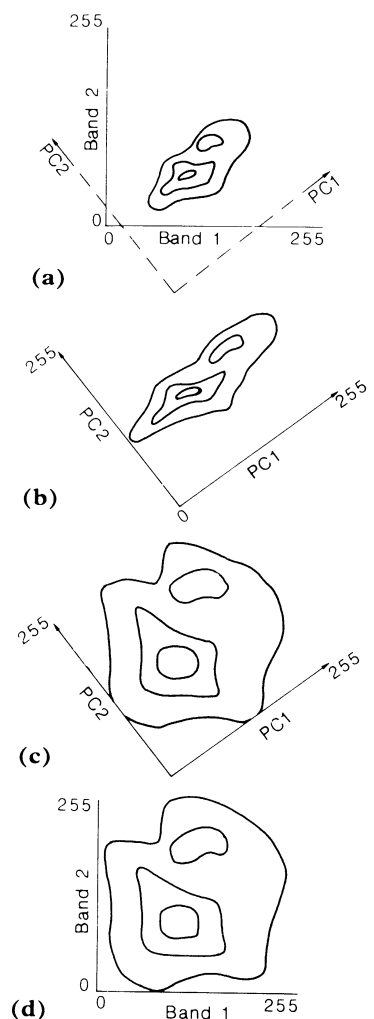


Abbildung 7 (li.): Lineare Kontrastverstärkung deckt nicht den gesamten Farbraum ab. (Quelle: eigener Entwurf nach DRURY 1998, S. 58)

Abbildung 8 (re.): Farbkontrasterhöhung nach Taylor. Man erkennt, daß die Punktwolke nach der Streckung den gesamten Farbraum einnimmt. (Quelle: DRURY 1998, S. 58)




Das Verfahren (siehe Abbildung 8) führt zuerst eine reguläre PCA durch. Anschließend werden alle PC-Kanäle (anstatt der ursprünglichen Bänder) kontrastverstärkt, bis sie den ganzen Grauwertebereich abdecken. Eine Rücktransformation in den ursprünglichen Farbraum (umgekehrte PCA) ordnet nun die Farbwerte wieder den ursprünglichen Bändern zu. Das Bild wirkt nun als Komposite geradezu grellbunt, was aber bei einer Segmentierung oder einer visuellen Interpretation durchaus ein Vorteil sein kann.

Das Verfahren wurde ursprünglich 1973 von Taylor erdacht, anschließend dann u.a. durch Campbell 1996 weiterentwickelt (RICHARDS & XIUPING 1999).



Abbildung 9: Vergleich zwischen linearer Kontraststreckung (links) und Dekorrelationsstreckung nach Taylor (rechts). Letzteres zeigt ein wesentlich größeres Farbspektrum als das linear gestreckte Komposite der gleichen Landsat-TM-Kanäle 5, 3 & 1, welches fast monochrom erscheint. (Quelle: Drury 1998, S. 57, 59)  
(Anmerkung: Das linke Bild wurde eventuell schlecht gedruckt, was den monochromen Eindruck noch verstärkt.)



## 5.7 Andere Einsatzgebiete

Andere Autoren haben die PCA auch ohne die eigentliche Transformation eingesetzt. Dabei dienen die statistisch ermittelten Daten anderen Auswertungszwecken, beispielsweise auch der Entwicklung eines dichotomen Klassifizierungsschlüssels (bei HOLDEN & LEDREW 1999 beispielsweise für Korallen, Algen, Schlamm und andere Meeresbedeckungen). Da die Interpretation der statistischen Daten je nach Fragestellung sehr speziell sein kann, soll hier auf Details verzichtet werden.

## 6 Zusammenfassung

Die Hauptkomponentenanalyse oder Principal Components Analysis/Transformation ist ein bedeutsames statistisches Verfahren zur Auswertung multidimensionaler Datensätze (z.B. mehrkanaliger Bilder, multitemporaler Daten oder polarimetrischer Radarbilder). Es beruht darauf, das Koordinatensystem im Merkmalsraum (Feature Space) so zu drehen, daß die Achsen, welche mit PC1, PC2, PC3 usw. bezeichnet werden, wie folgt erzeugt werden: PC1 liegt entlang der Achse der größten Varianz in der mehrdimensionalen Punktwolke des Merkmalsraumes. Alle weiteren Achsen liegen senkrecht zueinander und zur ersten, dabei wiederum geordnet nach der Varianz. Dieses Vorgehen führt zu einer völligen Unkorreliertheit der einzelnen PC-Kanäle.

Wie diese PCT exakt abläuft, wird durch die Statistik der einzelnen Bänder/Aufnahmezeitpunkte etc. bestimmt. Die PCA berechnet unter anderem die Korrelationsmatrix, welche die Korrelation zwischen den Kanälen angibt. Bei starker Korrelation ist eine PCT besonders sinnvoll und eine hohe Datenkompression möglich. Die ebenfalls berechnete Transformationsmatrix mit den Eigenvektoren gibt dem Nutzer an, wie exakt die neuen Kanäle PC1, PC2 usw. berechnet wurden. Sie erlaubt Rückschlüsse auf die Art der in den einzelnen Principal Components zu findenden Informationen. Die Eigenwerte bzw. PVA stellen die in den Komponenten enthaltenen Varianz dar und erlauben eine ungefähre Einschätzung des Informationsgehaltes der einzelnen Bilder.

Die Einsatzmöglichkeiten der PCA sind vielfältig: Sie reichen von Datenkompression (insbesondere bei Spektrometerdaten mit ihren z.T. über 100 Kanälen) über eine verbesserte Bildschirmdarstellung (hochinformativ Kompositen und farbkontrastreiche Bilder), der Erleichterung der Segmentierung und überwachten Klassifizierung (Festlegen von Trainingsgebieten) bis hin zur Unterdrückung von Reliefeinflüssen bei der Klassifizierung. Auch macht die PCT das Erkennen von Strukturen möglich, die in den einzelnen Kanälen oder zweidimensionalen Merkmalsräumen unsichtbar geblieben sind, da sie alle Kanäle beeinflussen. Einige Autoren verwenden die PCA auch als statistisches Auswerteverfahren für verschiedenste Zwecke, ohne die eigentliche Transformation durchzuführen.

Die großen Anwendungsmöglichkeiten stehen einem vertretbaren Rechenaufwand gegenüber. Insofern ist die Principal Components Analysis eine in der geographischen Bildverarbeitung oft angewandte Methode.

## 7 Literaturverzeichnis

- BARTONI, S., A. CASINI, F. LOTTI & S. PORCINAI (1997): **Segmentation of Multispectral Images of Works of Art Through Principal Component Analysis**; In: ICIAP (1997): Image analysis and processing: 9<sup>th</sup> international conference; Springer; Berlin, Heidelberg, New York u.a.
- CONESE, C., G. MARACCHI, F. MIGLIETTA, F. MASELLI UND V. M. SACCO (1988): **Forest classification by principal component analysis of TM data**; In: International Journal of Remote Sensing; V. 9, S. 1597-1612.
- DRURY, S. A. (1998<sup>2</sup>): **Images of the earth. A guide to remote sensing**; Oxford University Press; Oxford, New York, Tokyo.
- HOLDEN, H. & E. LEDREW (1999): **Hyperspectral identification of coral reef features**; In: International Journal of Remote Sensing; V. 20, S. 2545-2563.
- MAIERSPERGER, T. K., W. B. COHEN & L. M. GANIO (2001): **A TM-based hardwood-conifer mixture index for closed canopy forests in the Oregon Coast Range**; In: International Journal of Remote Sensing; V. 22, S. 1053-1066.
- NCGIA et al. (N.N.) **The remote sensing core curriculum: NCGIA Core Curriculum exercise 1**; <http://umbc7.umbc.edu/~tbenja1/exer1.html> (17.12.2001).
- RICHARDS, J. A. & J. XIUPING (1999<sup>3</sup>): **Remote Sensing digital image analysis. An introduction**; Springer; Berlin, Heidelberg, New York, Barcelona, Hong Kong, London, Milan, Paris, Singapur, Tokyo.
- VERHOEYE, J. & R. DE WULF (1999): **An Image Processing Chain for Land-Cover Classification Using Multitemporal ERS-1 Data**; In: Photogrammetric Engineering & Remote Sensing, Vol. 65, S. 1179-1186.