


Tomas Hallberg

En kort introduktion till principalkomponent- transformation och kanonisk diskriminantanalys av multispektrala data



TOTALFÖRSVARETS FORSKNINGSINSTITUT

Sensorteknik
Box 1165
581 11 Linköping

FOI-R--0382--SE

Januari 2002

ISSN 1650-1942

Metodrapport

Tomas Hallberg

En kort introduktion till principalkomponent- transformation och kanonisk diskriminantanalys av multispektrala data

Utgivare Totalförsvarets Forskningsinstitut - FOI Sensorteknik Box 1165 581 11 Linköping	Rapportnummer, ISRN FOI-R--0382--SE	Klassificering Metodrapport
	Forskningsområde 4. Spaning och ledning	
	Månad, år Januari 2002	Projektnummer E3036
	Verksamhetsgren 1. Forskning för regeringens behov	
	Delområde 42. Spaningssensorer	
Författare/redaktör Tomas Hallberg	Projektledare Ingmar Renhorn	
	Godkänd av	
	Uppdragsgivare/kundbeteckning Försvarmakten	
	Tekniskt och/eller vetenskapligt ansvarig Tomas Hallberg	
Rapportens titel En kort introduktion till principkomponenttransformation och kanonisk diskriminantanalys av multispektrala data		
Sammanfattning (högst 200 ord) Denna rapport ger en översikt över två algoritmer för multispektral dataanalys: principkomponent-transformen (PC-transform) och den kanoniska diskriminantanalysen (KD-analys). Algoritmerna används flitigt inom multispektral och hyperspektral fjärranalys för klassificering och identifiering av olika objekt, oftast olika typer av grödor, vegetationer och mineraler. Båda algoritmerna tar fram en uppsättning egenvektorer eller filterfunktioner som inkluderar de delar av den spektrala karaktäristiken som behövs för optimal klassificering men exkluderar redundanta data. Medan PC-transformen behandlar de olika spektralklasserna globalt utan hänsyn till enskilda spektralklassers karaktäristik, maximerar KD-analysen kvoten mellan variansen mellan klasser och variansen inom klasser, vilket optimerar klasseparationen.		
Nyckelord Principkomponenttransform, kanonisk diskriminantanalys, multispektral, vektorrum		
Övriga bibliografiska uppgifter	Språk Svenska	
ISSN 1650-1942	Antal sidor: 12 s.	
Distribution enligt missiv	Pris: Enligt prislista	

Issuing organization FOI – Swedish Defence Research Agency Sensor Technology P.O. Box 1165 SE-581 11 Linköping	Report number, ISRN FOI-R--0382--SE	Report type Methodology report
	Research area code 4. C ⁴ ISR	
	Month year January 2002	Project no. E3036
	Customers code 1. Policy Support to the Government	
	Sub area code 42. Surveillance sensors	
Author/s (editor/s) Tomas Hallberg	Project manager Ingmar Renhorn	
	Approved by	
	Sponsoring agency Swedish Armed Forces	
	Scientifically and technically responsible Tomas Hallberg	
Report title (In translation) A short introduction to the principal components transformation and the canonical discriminant analysis of multispectral data		
Abstract (not more than 200 words) This report reviews shortly two different algorithms for multispectral data analysis: the principal components transform (PC transform) and the kanonical discriminant analysis (KD analysis). These algorithms are widely used in multispectral and hyperspectral remote sensing for classification and identification of different objects, e.g. different types of crops, vegetation and minerals. Both the algorithms find a set of eigenvectors or filter functions which include the spectral features which are necessary for optimal classification but exclude redundant spectral data. While the PC transform treats the different spectral classes globally without concern to class structure in the data the KD analysis will maximize the ratio between the among-class variance and the within-class variance, by which class separation is optimized.		
Keywords Principal components transform, canonical discriminant analysis, multispectral, vector space		
Further bibliographic information	Language Swedish	
ISSN 1650-1942	Pages 12 p.	
	Price acc. to pricelist	

INNEHÅLLSFÖRTECKNING

SID

1. Inledning	5
2. Principalkomponenttransformation	5
3. Kanonisk diskriminantanalys	8
4. Exempel, 3 klasser av syntetiska spektra	10
5. Referenser	12

1. Inledning

Denna rapport ämnar ge en kort introduktion till två olika algoritmer för transformation av multispektrala data; principalkomponenttransformation (PC-transformation) och kanonisk diskriminantanalys (KD-analys) [1-4]. Dessa metoder förekommer ofta inom multi- och hyperspektral fjärranalys av bilddata, framförallt för att kunna välja ut de viktigaste delarna av spektraldata med optimal klassificering, vilket även kan ses som en typ av datakomprimering för att ta bort redundanta data.


Vid multispektral fjärranalys används ett tiotal spektralband medan upp till några hundra kan förekomma vid hyperspektral fjärranalys. Intensitetsvärdet för en viss pixel i en bild inom ett visst spektralt intervall eller band kan beskrivas av ett vektorvärde i ett vektorrum. Detta vektorrum har lika många axlar eller dimensioner som det finns spektrala komponenter eller band för varje pixel. Matematiskt finns i princip ingen gräns för antalet dimensioner man kan hantera, medan dock t. ex. transmissionslänken mellan en fjärranalys-satellit och dess mottagarcentral på jorden har en begränsad bandbredd, eller hårddiskutrymmet som data lagras på är begränsat. Om man vill presentera data visuellt är vi begränsade till maximalt tre dimensioner. Sålunda finns det flera skäl till att komprimera spektraldata.

För tillämpningen i denna rapport är huvudsyftet att utifrån en större spektral dimension välja ett fåtal spektralband som bäst representerar eller klassificerar ett visst objekts spektrala signatur. Dessa utvalda spektralband kan för en sensor realiserars i ett antal olika optiska filter.

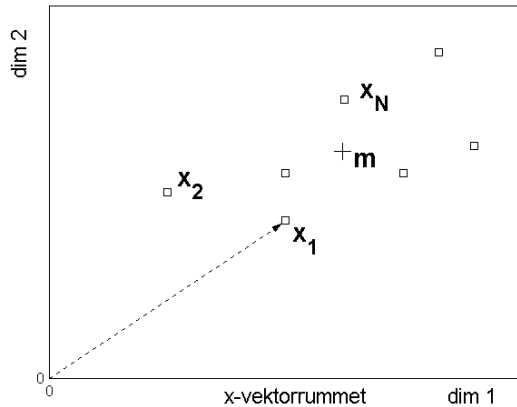
2. Principalkomponenttransformation

PC-transformen är även känd som Hotelling-, Karhunen-Loève- och egenvektor-transform. Den är i grunden en statistisk analys av bilddata där speciellt varians och korrelation av data analyseras. Principalkomponenterna för en stokastisk multivariaterande variabel är baserade på en linjär transformation vilken ger icke-korrelerade variabler med successivt minskande varians. Transformationen av data sker linjärt via rotation i vektorrummet (eller feature space) via en ny uppsättning ortogonala basvektorer, d.v.s. principalkomponenterna. Sålunda reduceras dimensionen av vektorrummet genom att framhäva spektralkomponenter med störst vikt. De med minst vikt (redundanta data) kan tas bort, samtidigt som felet minimeras.

Betrakta en multispektral bildkub med N pixlar, med den spektrala vektorn \mathbf{x}_i utmed den 3:e dimensionen i figur 1. Den spektrala dimensionen för \mathbf{x}_i är här lika med k . I ett 2-D vektorrum kan spektralvektorerna illustreras som i figur 2.



Figur 1. En multispektral bildkub med spektrala komponenter \mathbf{x}_i .



Figur 2. Ett tvådimensionellt vektorrum med individuella pixelvektorer och medelvektorn \mathbf{m} .

Medelvektorn \mathbf{m} beräknas genom

$$\mathbf{m} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (1)$$

För att få ett mått på spridningen av data i vektorrummet beräknas kovariansmatrisen, \mathbf{S}_x

$$\mathbf{S}_x = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^T \quad (2)$$

Diagonalelementen i \mathbf{S}_x är variansen av data (per spektralband) medan övriga element i matrisen beskriver korrelationen av data, där höga värden betyder stor korrelation medan låga värden betyder liten korrelation. Jämför här med elementen ρ_{ij} i korrelationsmatrisen

$$\rho_{ij} = \frac{v_{ij}}{\sqrt{v_{ii}v_{jj}}} \quad (3)$$

där v_{ij} är element i kovariansmatrisen, v_{ii} och v_{jj} är variansen av i :te respektive j :te spektralbandens data. Sålunda beskriver ρ_{ij} korrelationen mellan band i och band j .

Idén är nu att transformera data från ett vektorrum med en viss korrelationsgrad till ett annat med så låg korrelation som möjligt. Detta reducerar antalet nödvändiga dimensioner. Transformera från vektorrummet \mathbf{x} till vektorrummet \mathbf{y} med operatören Φ enligt

$$\mathbf{y} = \Phi^T \mathbf{x} \quad (4)$$

där Φ är en matris med egenvektorer ϕ till \mathbf{S}_x med egenvärden λ i matrisen Λ . Följande egenvärdesproblem skall lösas,

$$\Phi \Lambda = \mathbf{W} \mathbf{S}_x \Phi \quad (5)$$


där \mathbf{W} som är en diagonalmatris med viktcoefficienter eventuellt måste inkluderas för att nolla områden i spektra där atmosfären absorberar kraftigt (denna nollning kan dock göras direkt i spektrumet). I Matlab löser man egenvärdesproblemet enkelt genom kommandot *eig* eller *eigs*

($[\Phi, \Lambda] = \text{eig}(\mathbf{W}\mathbf{S}_x)$ eller $[\Phi, \Lambda] = \text{eigs}(\mathbf{W}\mathbf{S}_{x,n})$), där n anger antalet önskade egenvektorer och egenvärden). Principalaxlarna rangordnas efter storlek på egenvektorernas egenvärden, så att den första principalaxeln vilken motsvaras av den första egenvektorn, har det största egenvärdet, o.s.v. Transformen resulterar i att data (d.v.s. ϕ_1x) utmed den 1:a principalaxeln (y_1) uppvisar störst varians, vilken successivt minskar för varje lägre rangordnad principalaxel.

I det nya vektorrummet y är data ej korrelerade i förhållande till principalaxlarna. Detta kan visas genom att för kovariansmatrisen \mathbf{S}_y för det nya rummet är elementen utanför diagonalen lika med noll, d.v.s.

$$\mathbf{S}_y = \begin{bmatrix} \lambda_1 & 0 & 0 & & \\ 0 & \lambda_2 & 0 & & \\ 0 & 0 & \ddots & & \\ & & & \ddots & \\ & & & & \lambda_k \end{bmatrix}$$

där diagonalelementen λ_i är egenvärdena för \mathbf{S}_x . Figur 3 visar att spektralvektorerna i det nya vektorrummet inte är korrelerade och att variansen för datamängden är störst utmed den första principalaxeln.



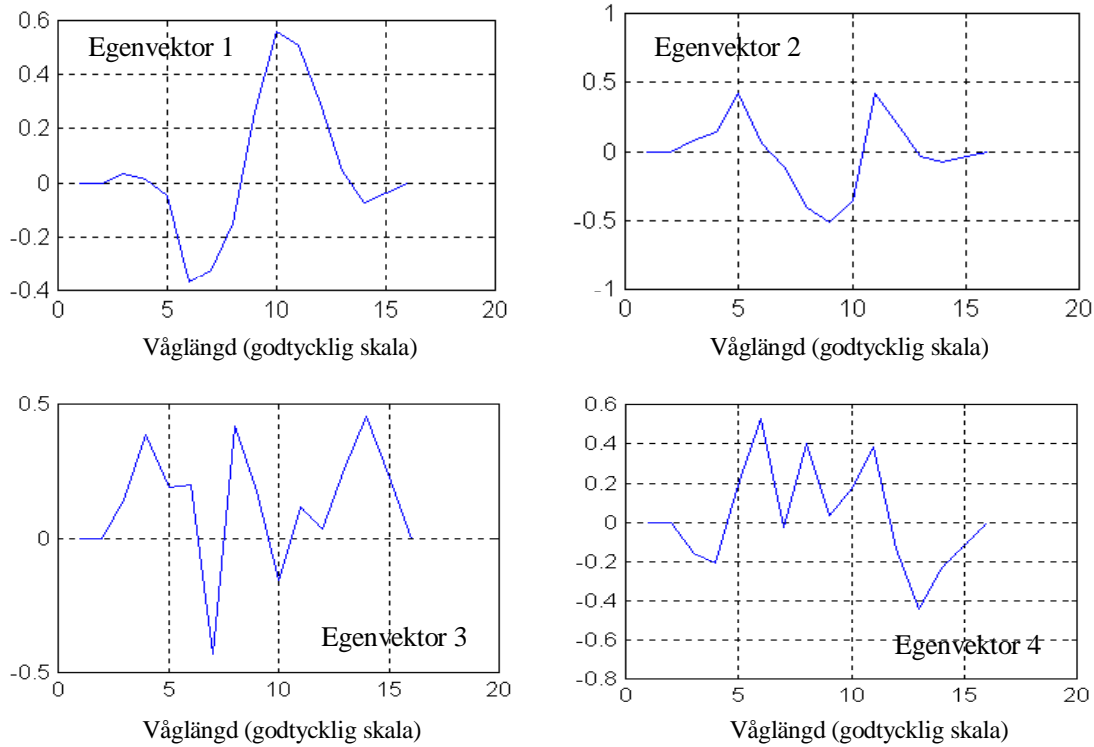
Figur 3. Illustration av ett modifierat koordinatsystem y i vilket pixelvektorerna har icke-korrelerade komponenter.

Det medelkvadratiska felet R mellan x och y ges av

$$R = \sum_{i=1}^N \lambda_i - \sum_{i=1}^K \lambda_i = \sum_{i=K+1}^N \lambda_i \quad (6)$$

vid valet av K basfunktioner av maximalt N stycken och med egenvärdena λ arrangerade i avtagande storleksordning. Vi konstaterar således att om $K=N$ så är felet lika med noll. Felet minimeras genom att välja egenvektorer associerade med de största egenvärdena.


I figur 4 illustreras som exempel några olika egenvektorer rangordnade efter associerat egenvärde i avtagande storleksordning. Några olika tolkningstips gällande egenvektorerna kan här nämnas [3,4]. Viktig information finns i spektrum där värdet för egenvektorn avviker signifikant från noll. Vidare kan nollgenomgångarna för egenvektorerna ofta vara bandkanter. Figur 4 visar även det faktum att den första egenvektorn innehåller lågupplöst spektral information medan senare egenvektorer innehåller allt mer högupplöst information.



Figur 4. Exempel på egenvektorer rangordnade i storleksordning efter associerat egenvärde.

3. Kanonisk diskriminantanalys

Nackdelen med PC-transformen är dock att kovariansmatrisen \mathbf{S}_x är global, d.v.s. oberoende av individuella spektralklasser. Den kanoniska diskriminantanalysmetoden optimerar klasseparationen [5], vilket illustreras i figur 5.



Figur 5. Ett hypotetiskt 2-D vektorrum med två klasser som inte är separerade i varken de ursprungliga spektralbanden eller i någon av principalaxlarna enligt figur a medan figur b visar en axel erhållen från den kanoniska analysmetoden utmed vilken klasserna är separerade.

I KD-analysen optimeras variansen som råder mellan klasserna tillsammans med den som råder inom klasserna på så sätt att följande kvot maximeras

$$\frac{\sigma_A^2}{\sigma_W^2} = \frac{\text{varians mellan klasser}}{\text{varians inom klasser}} \quad (7)$$

Följande två kovariansmatriser beräknas, \mathbf{S}_w för inom klasser

$$\mathbf{S}_w = \sum_{i=1}^L \frac{(N_i - 1)}{N_s} \cdot \mathbf{S}_i \quad (8)$$

med L som antalet klasser, N_i antalet spektra i klass i , N_s är det totala antalet spektra inklusive samtliga klasser och \mathbf{S}_i är kovariansmatrisen för klass i , och \mathbf{S}_A för mellan klasser,

$$\mathbf{S}_A = \frac{1}{L} \sum_{i=1}^L (\mathbf{m}_i - \mathbf{m}_0)(\mathbf{m}_i - \mathbf{m}_0)^T \quad (9)$$

$$\mathbf{m}_0 = \sum_{i=1}^L \frac{N_i}{N_s} \cdot \mathbf{m}_i \quad (10)$$

där \mathbf{m}_i är medelvektorn för klass i och \mathbf{m}_0 är den globala medelvektorn. Maximal klasseparering fås nu genom att maximera kvoten

$$\lambda = \frac{\sigma_A^2}{\sigma_W^2} = \frac{\mathbf{d}^T \mathbf{S}_A \mathbf{d}}{\mathbf{d}^T \mathbf{S}_W \mathbf{d}} \quad (11)$$

där \mathbf{d} är optimal projektionsriktning. Maximering fås genom

$$\frac{\partial \lambda}{\partial \mathbf{d}} = 0 \quad (12)$$

vilket kan reduceras till

$$(\mathbf{S}_A - \lambda \mathbf{S}_W) \cdot \mathbf{d} = 0 \quad (13)$$

eller mera generellt skriver vi

$$(\mathbf{S}_A - \Lambda \mathbf{S}_W) \cdot \mathbf{D} = 0 \quad (14)$$

med Λ som en diagonalmatris med egenvärdena λ och \mathbf{D} en matris med egenvektorer \mathbf{d} . Vi söker nu lösningen till denna *generaliserade egenvärdesekvation*. Detta löses i Matlab genom $[\mathbf{D}, \Lambda] = \text{eig}(\mathbf{S}_A, \mathbf{S}_W)$ för $\mathbf{S}_A \mathbf{D} = \mathbf{S}_W \Lambda \mathbf{D}$. Som ett sista steg normaliseras den kanoniska karaktäristiken i förhållande till \mathbf{S}_W

$$\mathbf{D}^T \mathbf{S}_W \mathbf{D} = \mathbf{I} \quad (15)$$

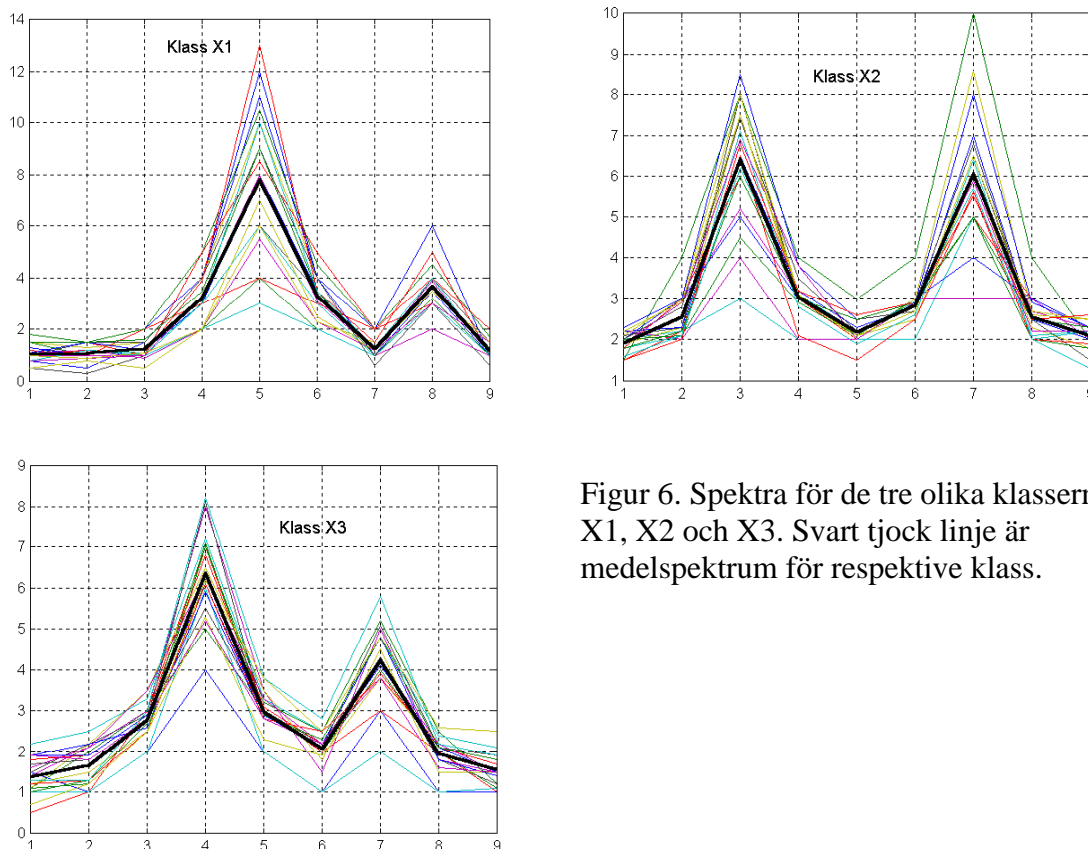
som skapar en sfärisk fördelning inom klasserna. Transformationen som ger maximal klasseparering i ett vektorrum \mathbf{y} är således

$$\mathbf{y} = \mathbf{D}^T \mathbf{x} \quad (16)$$

vilken kallas för en kanonisk diskriminantfunktion. Den första kanoniska axeln eller den första kanoniska diskriminantfunktionen \mathbf{d}_1 (med det största egenvärdet), ger maximal diskriminering mellan klasserna i förhållande till de andra kanoniska axlarna. Dessa diskriminantfunktioner är i allmänhet inte ortogonala i förhållande till varandra. Vid beräkningen erhålles L-1 egenvektorer med egenvärden >0 .

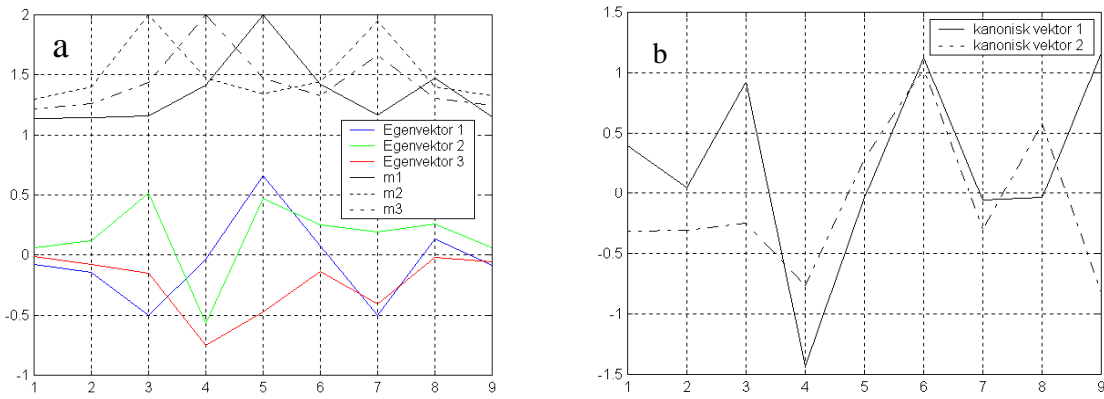
4. Exempel, 3 klasser av syntetiska spektra

För att belysa skillnaden mellan PC- och KD-analysen exemplifieras metoderna med tre olika klasser av syntetiska spektra, med 20 spektra i varje klass samplade inom 9 olika spektralband, enligt figur 6.

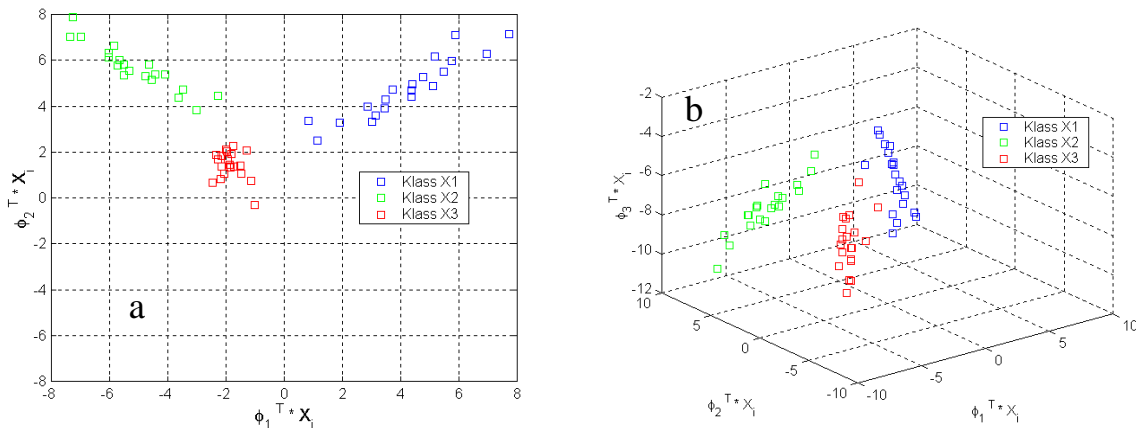


Figur 6. Spektra för de tre olika klasserna X1, X2 och X3. Svart tjock linje är medelspektrum för respektive klass.


Egenvektorer och egenvärden beräknas för PC-analysen (genom ekv. (1), (2) och (5)) och i figur 7a ges de tre egenvektorena som har de största egenvärdena (16, 4 och 3). Erhållna egenvektorena för KD-analysen (L-1 stycken) visas i figur 7b (genom ekv. (1), (2), (8)-(10), (14) och (15)). Spektraldata transformeras för PC- och KD-analysen genom ekv. (4) respektive (15). Klassernas fördelning i det så erhållna vektorrummet med PC-analysen visas i 2-D och 3-D i figur 8 och vi konstaterar att maximal varians av data fås utmed den första principalaxeln. Resultatet av KD-analysen i figur 9 visar att klasserna är tydligare separerade och mera sfäriskt fördelade jämfört med resultaten i figur 8.



Figur 7. Egenvektorerna med de tre största egenvärdena för PC-transformen tillsammans med medelspektra för de tre klasserna visas i (a) medan (b) visar de två erhållna egenvektorerna från KD-analysen.



Figur 8. Data transformerat med de av PC-analysen erhållna egenvektorerna ϕ_1 , ϕ_2 och ϕ_3 plottat i 2-D (a) och 3-D (b).



Figur 9. Data transformerat med de av KD-analysen erhållna egenvektorerna d_1 och d_2 .

5. Referenser

- 1 Richards, J.A., Jia, X, *Remote Sensing Digital Image Analysis, An Introduction*, 3:e upplagan, Springer-Verlag Berlin Heidelberg New York, ISBN 3-540-64860-7, 1999.
- 2 Schowengerdt, R.A., *Remote Sensing, Models and Methods for Image Processing*, 2:a upplagan, Academic Press, ISBN 0-12-628981-6, 1997.
- 3 Chen, C-C.T, Landgrebe, D.A., A Spectral Feature Design System for the HIRIS/MODIS Era, *IEEE transactions on geoscience and remote sensing*, **27** (6) 681, 1989.
- 4 Wiersma, D.J., Landgrebe, D.A., *Analytical Design of Multispectral Sensors*, *IEEE transactions on geoscience and remote sensing*, **GE-18** (2) 180, 1980.
- 5 Fisher, R.A., The Utilization of Multiple Measurements in Taxonomic Problems, *Annals of Eugenics*, **7**, 179-188, 1936.