

1998

sie pentru  
Structurioresie fo-  
1997.

## Restaurarea imaginilor perturbate normal prin matrice de împrăștiere

Prep. Cătălina COCIANU

Catedra de Informatică Economică, A.S.E. Bucureşti

*Matricele de împrăștiere exprimă variabilitatea în cadrul unui sistem de clase considerat, cu aplicații în probleme de extragere de caracteristici, compresie de date, recunoaștere de forme. În articolul de față sunt prezentate rezultate furnizate de matricele de împrăștiere în problema restaurării seturilor de imagini perturbate normal. Ideea ce stă la baza acestui tip de restaurare constă în modelarea pe două clase: una de intrare, formată dintr-un set de imagini cu bruijaj gaussian puternic și una intermediară (de lucru), formată din setul corespunzător de imagini filtrate binomial. Cele două clase furnizează câte un prototip, prototipul clasei intermediare fiind ajustat după informația de separabilitate determinată pe baza matricelor de împrăștiere și a prototipului clasei de intrare.*

**Cuvinte cheie:** clasă, matrice de împrăștiere, repartiție normală, informație de separabilitate, pseudoinversă

### 1. Matricele de împrăștiere în extragerea de caracteristici; informația de separabilitate a claselor

Fie  $H$  un sistem de clase,  $\xi$  distribuția claselor și fiecare  $h_i \in H$  având media  $\mu_i$  și matricea de covarianță  $\Sigma_i$ .

Definiție: Matricele de împrăștiere relative la sistemul de clase  $H$  sunt:

1. matricea de împrăștiere între clase:

$$S_b = \sum_{i=1}^{|H|} (\mu_i - \mu_0)(\mu_i - \mu_0)^T \xi(h_i); \quad \text{cu}$$

$\mu_0 = \sum_{i=1}^{|H|} \xi(h_i) \mu_i$  baricentrul sistemului de clase

2. matricea de împrăștiere în interiorul claselor:  $S_w = \sum_{i=1}^{|H|} \xi(h_i) \Sigma_i$ ;

3. matricea de împrăștiere mixtură:  $S_m = S_w + S_b$

Fie  $S_1, S_2 \in \{S_b, S_w, S_m\}$ ,  $S_2$  matrice inversabilă (deci  $S_2 \neq S_b$ ); pe baza lor se definesc indicatori globali ai separabilității sistemului de clase considerat, dacă prin funcțiile criteriu  $J_1$  și  $J_2$ , definite astfel:

$$J_1 = \text{tr}(S_2^{-1} S_1); J_2 = \ln |S_2^{-1} S_1|.$$

Observații:

1)  $J_1$  și  $J_2$  sunt invariante față de transformări nesingulare.

Într-adevăr, fie  $h_i \sim \mu_i, \Sigma_i$ , clasă de procese n-dimensionale,  $X \in h_i$  și  $C \in M_n(\mathbb{R})$  matrice nesingulară; atunci  $Y = CX \sim C\mu_i, C\Sigma_i C^T$ . Fie  $S'_b, S'_w, S'_m$  matricele de împrăștiere corespunzătoare. Rezultă că  $S'_b = CS_b C^T, S'_w = CS_w C^T, S'_m = CS_m C^T$ , deci  $S'_i = CS_i C^T, i = 1, 2$ .

$$J'_1 = \text{tr}(S_2^{-1} S'_1) = \text{tr}((C^T)^{-1} S_2^{-1} S_1 C^T) = \text{tr}(S_2^{-1} S_1 C^T (C^T)^{-1}) = \text{tr}(S_2^{-1} S_1) = J_1$$

$$J'_2 = \ln |S_2^{-1} S'_1| = \ln |(C^T)^{-1} S_2^{-1} S_1 C^T| =$$

$$\ln \frac{|CS_1 C^T|}{|CS_2 C^T|} = \ln \frac{|S_1|}{|S_2|} = \ln |S_2^{-1} S_1| = J_2$$

2)  $J_1 = \text{tr}(\Lambda)$ , unde  $\Lambda$  reprezintă matricea diagonală a valorilor proprii ale matricei  $S_2^{-1} S_1$ .

Într-adevăr, fie  $C$  matricea care diagonalizează simultan  $S_1, S_2$ ; deci

$$C^T S_1 C = \Lambda, C^T S_2 C = I_n, C C^T = S_2^{-1}$$

$$J_1 = \text{tr}(S_2^{-1} S_1) = \text{tr}(C C^T S_1) = \text{tr}(C^T S_1 C) = \text{tr}(\Lambda) = \sum_{i=1}^n \lambda_i$$

3) Funcția criteriu  $J_1$  recomandă în procesul extragerii a  $m$  ( $m < n$ ) caracteristicii cei  $m$  vectori proprii corespunzători celor mai mari valori proprii ale matricei  $S_2^{-1} S_1$  [2]. În consecință, extractorul de caracteristici este

$Y = A^T X$ , unde  $A = \phi^{(m)} B^{-1}$ , cu  $B \in M_m(\mathbb{R})$  matricea care diagonalizează simultan  $S_1(m) = A^T S_1 A$  și  $S_2(m) = A^T S_2 A$  și  $\phi^{(m)} = [\phi_1, \phi_2, \dots, \phi_m]$   $m$  vectorii proprii

corespunzător celor mai mari  $m$  valori proprii ale matricei  $S_2^{-1} S_1$ .  $Y$  reprezintă caracteristica ce conține întreaga informație de clasificare de separabilitatea claselor evaluată cu funcția criteriu  $J_1$ .

### Studiul informației de separabilitate în cazul particular $|H| = 2$

$$1. S_2 = S_w, S_1 = S_b$$

$$S_b = \xi(h_1)\xi(h_2)(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T, S_w = \xi(h_1)\Sigma_1 + \xi(h_2)\Sigma_2 \text{ rang}(S_b) = 1, \text{ deci rang}(S_w^{-1}S_b)$$

$$\lambda_1 \neq 0, \lambda_2 = \lambda_3 = \dots = \lambda_n = 0, \text{ deci } J_1 = \lambda_1$$

$$J_1 = \text{tr}\left(\left(\xi(h_1)\Sigma_1 + \xi(h_2)\Sigma_2\right)^{-1}\xi(h_1)\xi(h_2)(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T\right) =$$

$$= \xi(h_1)\xi(h_2)\text{tr}\left((\mu_1 - \mu_2)\left(\xi(h_1)\Sigma_1 + \xi(h_2)\Sigma_2\right)^{-1}(\mu_1 - \mu_2)^T\right) =$$

$$= \xi(h_1)\xi(h_2)(\mu_1 - \mu_2)^T \Sigma^{-1} (\mu_1 - \mu_2)$$

Din punct de vedere al criteriului  $J_1$  o singură caracteristică este optimă.

$$\phi_1 = \frac{S_w^{-1}(\mu_1 - \mu_2)}{\|S_w^{-1}(\mu_1 - \mu_2)\|}$$

$$S_w^{-1}S_b\phi_1 = \frac{\xi(h_1)\xi(h_2)}{\|S_w^{-1}(\mu_1 - \mu_2)\|} S_w^{-1}(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T S_w^{-1}(\mu_1 - \mu_2) = \lambda_1 \frac{S_w^{-1}(\mu_1 - \mu_2)}{\|S_w^{-1}(\mu_1 - \mu_2)\|} = \lambda_1 \phi_1$$

$$A = \phi_1; Y = A^T X = \frac{(\mu_1 - \mu_2)^T S_w^{-1} X}{\|(\mu_1 - \mu_2)^T S_w^{-1}\|}$$

2.  $S_2 = S_m, S_1 = S_b$ ; fie  $\Lambda$  matricea diagonală a vectorilor proprii ai lui  $S_2^{-1}S_1$  și  $\phi$  matricea vectorilor proprii asociați, deci.

$$S_m^{-1}S_b\phi = \phi\Lambda, \text{ deci } S_b\phi = S_m\phi\Lambda = (S_b + S_w)\phi\Lambda \Rightarrow S_b\phi(I_m - \Lambda) = S_w\phi\Lambda$$

Înmulțind la dreapta cu  $(I_n - \Lambda)^{-1}$  și cu  $S_w^{-1}$  la stânga, relația precedentă devine:

$$S_w^{-1}S_b\phi = \phi\Lambda(I_n - \Lambda)^{-1}$$

Cum  $\phi\Lambda(I_n - \Lambda)^{-1} = \phi((I_n - \Lambda)\Lambda^{-1})^{-1} = \phi(\Lambda^{-1} - I_n)^{-1}$  urmează că  $S_w^{-1}S_b\phi = \phi(\Lambda^{-1} - I_n)^{-1}$ , deci

$\mu = (\Lambda^{-1} - I_n)^{-1}$  este matricea diagonală a valorilor proprii ale lui  $S_w^{-1}S_b$ ,

$$\mu_i = \frac{\chi_i}{1 - \lambda_i} \geq 0$$

Deci  $S_w^{-1}S_b$  și  $S_m^{-1}S_b$  au aceeași vectori proprii  $\phi$ .

3.  $S_2 = S_m, S_1 = S_w$ ; fie  $\Lambda$  matricea diagonală a vectorilor proprii ai lui  $S_2^{-1}S_1$  și  $\phi$  matricea vectorilor proprii asociați, deci.

$$S_m^{-1}S_w\phi = \phi\Lambda, S_w\phi = S_m\phi\Lambda = (S_b + S_w)\phi\Lambda \Rightarrow S_w\phi(I_m - \Lambda) = S_b\phi\Lambda$$

Înmulțind la stânga cu  $S_w^{-1}$  și cu  $\Lambda^{-1}$  la dreapta, relația precedentă devine:  $S_w^{-1}S_b\phi = \phi(I_n - \Lambda)\Lambda^{-1}$ ; cu aceeași observație făcută pentru alegerea precedentă, urmează că  $S_w^{-1}S_b\phi = \phi(\Lambda^{-1} - I_n)$ , deci  $\mu = (\Lambda^{-1} - I_n)$  este matricea diagonală a valorilor proprii ale lui  $S_w^{-1}S_b$ . Urmează că  $S_w^{-1}S_b$  și  $S_m^{-1}S_b$  au aceeași vectori proprii  $\phi$ .

Observație: Funcția criteriu  $J_2$  recomandă același set de caracteristici ca și  $J_1$ .

### 2. Restaurarea unui set de imagini perturbate normal prin matrice de împrăștiere

Tehnica de restaurare a unui set de imagini perturbate normal (bruijaj foarte puternic - media zgomotului foarte mare) pe baza matricelor de împrăștiere utilizează noțiunea

*n* valori  
rezintă  
formație  
claselor

de informație de separabilitate a claselor, descrisă anterior. Ideea centrală a acestui tip de restaurare este aceea de a lucra pe două clase de semnale: prima clasă este constituită din setul de imagini perturbate ce reprezintă multimea de intrare, cea de-a doua conține corespondentele imaginilor din prima clasă filtrate binomial (sau cu măști din clasa celei binomiale). Restaurarea se face în două etape, și anume: determinarea prototipurilor celor două clase, urmată de cumularea aditivă a unui procent din informația de separabilitate la prototipul clasei imaginilor nivelate.

Justificarea intuitivă a acestei tehnici por-  
ește de la ideea că nici unul dintre cele două prototipuri nu poate fi considerat o apro-  
imare acceptabilă a imaginii asupra căreia s-  
a primit setul de informații inițiale (setul perturbat). Prototipul primei clase păstrează  
încă suficient zgomot datorită, în primul  
rând, calității slabe a intrărilor și numărului

$$M_t = \frac{1}{12+t} \begin{bmatrix} 1 & 2 & 1 \\ 2 & t & 2 \\ 1 & 2 & 1 \end{bmatrix}, t \geq 4 \quad (t=4 \text{ corespunde unui filtru binomial})$$

Pas 2: Se determină prototipurile celor două clase  $\mu^{(1)}, \mu^{(2)}$ , matricele de covarianță de selecție corespunzătoare celor două selecții, notate  $\Sigma_2$ , respectiv  $\Sigma_1$ , precum și matricele de împrăștiere corespunzătoare

$$S_w = \frac{\Sigma_1 + \Sigma_2}{2},$$

$$S_b = \frac{(\mu^{(1)} - \mu^{(2)}) (\mu^{(1)} - \mu^{(2)})^T}{2}$$

Pas 3: Se calculează  $S_w^+$  (pseudo inversa matricii  $S_w$  conform teoremei Penrose) folosindu-se algoritmul lui Cholansky; este recomandabil ca în locul inversei să se folosească pseudoinversa pentru cazurile de slabă condiționare, în care  $S_w$  nu este matrice inversabilă.

Pas 4: Se determină caracteristica optimă din punctul de vedere al criteriului  $J_1$  pentru

limitat de imagini-selectie primite, iar cel de-al doilea prototip, deși are zgomot suficient de mic, nu poate constitui o ieșire în sine datorită pierderii de informație (contrast, luminozitate, contururi) survenite în urma filtrării. Această informație semnificativă care se pierde datorită filtrării poate fi refăcută pe baza informației de separabilitate dintre cele două clase.

În continuare vor fi descriși doi algoritmi bazați pe matricele de împrăștiere  $S_w, S_b$ , respectiv  $S_m, S_w$ .

Restaurare folosind matricele  $S_w, S_b$

Intrare: Selecția de imagini perturbate  $X^{(2)}_1, X^{(2)}_2, \dots, X^{(2)}_n$

$\forall k \in \{1, 2, \dots, n\} \quad X^{(2)}_k \in M_{lin \times col}(\{0, 1, \dots, g\}), g = \text{numărul nivelelor de gri}$

Pas 1: Se determină imaginile clasei intermediare  $X^{(1)}_k, k \in \{1, 2, \dots, n\}$ , folosind un filtru de nivelare  $3 \times 3$ , dat de masca

$$S_w^+ S_b, \quad \phi_1 = \frac{S_w^+ (\mu^{(1)} - \mu^{(2)})}{\|S_w^+ (\mu^{(1)} - \mu^{(2)})\|}, \quad \text{precum și}$$

caracteristica ce conține informația de separabilitate a celor două clase, considerându-se pentru aceasta prototipul celei de-a doua clase  $Y = \phi_1^T \mu^{(1)}$ .

Ieșirea:  $X^{(1)} = \mu^{(1)} + \phi_1 Y^* c$ , unde  $c$  reprezintă constanta subunitară ce specifică procentul de informație de separabilitate luat în considerare în procesul de restaurare.

Restaurare folosind matricele  $S_m, S_w$

Intrare: Selecția de imagini perturbate  $X^{(2)}_1, X^{(2)}_2, \dots, X^{(2)}_n$

$\forall k \in \{1, 2, \dots, n\} \quad X^{(2)}_k \in M_{lin \times col}(\{0, 1, \dots, g\}), g = \text{numărul nivelelor de gri}$

Pas 1: Se determină imaginile clasei intermediare  $X^{(1)}_k, k \in \{1, 2, \dots, n\}$ , folosind un filtru de nivelare  $3 \times 3$ , dat de masca

$$M_t = \frac{1}{12+t} \begin{bmatrix} 1 & 2 & 1 \\ 2 & t & 2 \\ 1 & 2 & 1 \end{bmatrix}, t \geq 4 \quad (t=4 \text{ corespunde unui filtru binomial})$$

Pas 2: Se determină prototipurile celor două clase  $\mu^{(1)}, \mu^{(2)}$ , matricele de covarianță de selecție corespunzătoare celor două selecții, notate  $\Sigma_2$ , respectiv  $\Sigma_1$ , precum și matricele de împărțire corespunzătoare

$$S_w = \frac{\Sigma_1 + \Sigma_2}{2}, S_m = S_w + S_b,$$

$$S_b = \frac{(\mu^{(1)} - \mu^{(2)}) (\mu^{(1)} - \mu^{(2)})^T}{2}$$

Pas 3: Se calculează vectorii și valorile proprii ai lui  $S_m^{-1}S_w$  utilizând algoritmul de diagonalizare simultană ( $S_m^{-1}S_w$  este în general nesimetrică):

3.1 Se determină  $\Lambda_1, \phi_1$  - matricele valorilor proprii, respectiv vectorilor proprii corespunzătoare lui  $S_m$ ; dacă  $S_m$  este doar semipozitiv definită (în acest caz, corespunzător faptului că este singulară) se elimină vectorii proprii corespunzător valorilor proprii nule. În continuare se vor nota cu  $\Lambda_1^*, \phi_1^* \in M_{(n-t) \times (n-t)}(\mathbb{R})$  matricele obținute în urma acestuei eliminări, unde  $t$  reprezintă numărul de valori proprii nule ale matricei  $S_m$ .

3.2 Se calculează  $K = \left( \phi_1^* \Lambda_1^{*-1} \right)^T S_w \phi_1^* \Lambda_1^{*-1}$

$\in M_{(n-t) \times (n-t)}(\mathbb{R})$ , precum și matricea vectorilor proprii corespunzători lui  $K$ , notată  $\Psi_{n-t}$ .

3.3 Se determină matricea caracteristicilor

$$A = \phi_1^* \Lambda_1^{*-1} \Psi_{n-t}$$

Pas 4: Se calculează caracteristica ce conține informația de separabilitate a celor două clase, considerându-se pentru aceasta prototipul celei de-a două clase  $Y = A^T \mu^{(1)}$   
Ieșirea:  $X^{(1)} = \mu^{(1)} + AY^*c$ , unde  $c$  reprezintă

constanta subunitară ce specifică procentul de informație de separabilitate luat în considerare în procesul de restaurare.


### 3. Experimente și concluzii

Au fost efectuate o serie de experimente pe imagini cu 256 de nivele de gri de la alb la negru, cu rezultate care au demonstrat că gradul de refacere din zgomot al acestor algoritmi este suficient de mare încât să justifice efortul computațional pe care aceștia îl solicită. Pentru implementarea lor au fost folosiți algoritmi de analiză numerică extrem de performanți din punct de vedere al erorilor (algoritmul lui Cholansky pentru determinarea pseudoinversei, algoritmul de diagonalizare simultană pentru calculul vectorilor proprii).


Constantele folosite în algoritmii descriși depind în general de gradul de perturbare a intrărilor, tipul de filtru utilizat în procesul de nivelare aplicat pentru eliminarea zgomotului (filtru binomial sau extensii ale sale), numărul de date care pot fi acceptate (numărul vectorilor proprii asociați valorilor proprii nenegative); în implementările realizate, constantele utilizate sunt în general apropiate de  $1/t$  (unde  $t$  reprezintă numărul datelor aberante care se elimină pe parcursul algoritmului de diagonalizare simultană) pentru cea de-a două implementare, respectiv  $1/\text{col}$  pentru prima implementare.

În continuare sunt prezentate rezultatele celor doi algoritmi descriși pentru un set de 7 imagini intrare, fiecare imagine având un zgomot gaussian cu media variind între 30 și 50.

Setul de imagini de intrare



*Rezultatul aplicării algoritmului bazat pe matricele de împărăștiere  $S_w, S_b$*



*Rezultatul aplicării algoritmului bazat pe matricele de împărăștiere  $S_m, S_w$*



### Bibliografie:

- [1] Chang Shi-Kuo *Principles of Pictorial Information Systems Designs*, Prentice Hall, 1989
- [2] P. Devijver, J. Kittler *Pattern Recognition. A Statistical Approach*, Prentice Hall, 1989
- [3] K. Fukunaga *Introduction to Statistical Pattern Recognition*, Academic Press, 1990
- [4] B. Jahne *Digital Image Processing: Concepts, Algorithms and Scientific Applications*, Springer Verlag, 1993
- [5] T. Young, T. Calvert *Classification, Estimation and Pattern Recognition*, Elsevier, 1974