

Restaurarea imaginilor perturbate normal utilizând coeficientul Bhattacharyya

Conf.dr. Luminita STATE

Facultatea de Matematica, Universitatea Bucuresti

Prep. Catalina COCIANU

Catedra de Informatica Economica, A.S.E. Bucuresti

Distanța Bhattacharyya reprezintă o notiune derivată din marginea Chernoff a erorii clasificatorului Bayesian și are aplicații în probleme de extragere de caracteristici, compresie de date, recunoaștere de forme. În articolul de față sunt prezentate rezultate furnizate de acest criteriu 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 zgomot gaussian puternic și una intermediară, formată din setul corespunzător de imagini filtrate binomial. Fiecare dintr-una de clase furnizează câte un prototip, prototipul clasei intermediare fiind ajustat după informația de separabilitate determinată pe baza distanței Bhattacharyya.

Cuvinte cheie: *clasa, distanța Bhattacharyya, margine Chernoff, repartiție normală, informație de separabilitate, clasificator Bayesian.*

1. Introducere

Scopul fundamental al tehnicilor de restaurare este acela de a îmbunătăți intrările perturbate conform unor criterii prestabilite (luminozitate, contrast, eliminare de zgomot, refacere a unor părți ce au fost anterior bruiate sau îndepărtate din imaginea intrare). Restaurarea poate fi descrisă ca un proces de reconstrucție a unei imagini pe baza unor cunoștințe a priori legate de fenomenul de degradare. În consecință, tehnicile de restaurare sunt orientate pe modelarea degradării și aplicarea procesului invers în scopul reconstituirii imaginii inițiale neperturbate.

Unul dintre cele mai întâlnite procese de degradare este perturbarea liniară continuă. Funcție de imaginea inițială $f(x,y)$, semnalul rezultat $g(x,y)$ poate fi exprimat pe baza unui operator H și a unui termen înglobat aditiv $\eta(x,y)$ ce reprezintă zgomotul: $g(x,y) = H(f(x,y)) + \eta(x,y)$, în care informațiile relative la η sunt de natură statistică. Procesul de restaurare revine la determinarea unei

aproximări asupra lui $f(x,y)$, cunoscându-se $g(x,y)$ și operatorul H .

În abordarea de față, modelul de degradare este dat de $g(x,y) = f(x,y) + \eta(x,y)$, în care $\eta(x,y)$ reprezintă zgomotul, presupus a fi variabilă aleatoare distribuită normal. Este cunoscut faptul că aplicarea unui filtru de tip binomial are efect de reducere a zgomotului, dar, de asemenea, și a calitatilor spațiale ale imaginii intrare (luminozitate, contrast, descrierea obiectelor componente) [7,9]. Cu alte cuvinte, simpla aplicare a unei astfel de tehnici, mai ales în condițiile în care zgomotul este foarte puternic (η cu medie mare), nu poate conduce la o aproximare suficient de bună a imaginii inițiale.

Tehnica de lucru prezentată în continuare se bazează pe combinarea efectelor induse de aplicarea unei masti binomiale de filtrare cu extragerea informației pierdute în urma acestui proces. Scopul este acela de a îmbunătăți calitatea imaginilor filtrate utilizând o anumită cantitate de informație de separabilitate globală

extrasa din seturile de exemple ini-tiale si filtrate ale imaginii degradate.

Modelul de lucru contine: $(X_1^{(2)}, X_2^{(2)}, \dots, X_N^{(2)})$ versiunile cu zgomot ale imaginii initiale, cunoscute, $(X_1^{(1)}, X_2^{(1)}, \dots, X_N^{(1)})$ versiunile corespunzatoare filtrate, $X_i^{(k)} \in M_{\text{rc}}(\{0,1, \dots, 255\})$, $1 \leq i \leq N$, $k = 1,2$. Se presupune ca exemplele $(X_1^{(1)}, X_2^{(1)}, \dots, X_N^{(1)})$ rezulta în urma aplicarii mastii de filtrare

$$M_t = \frac{1}{12+t} \begin{bmatrix} 1 & 2 & 1 \\ 2 & t & 2 \\ 1 & 2 & 1 \end{bmatrix}, \quad t \geq 4, \text{ respectiv } X_i^{(1)} =$$

$$F(X_i^{(2)}), \quad 1 \leq i \leq N.$$

2. Algoritmul euristic de restaurare bazat pe distanta Bhattacharrya

Modelul clasificatorului Bayes utilizat pentru determinarea distantei Bhattacharyya este cel de discriminare între două clase; informația disponibilă este data prin vectorii medii ai celor două clase μ_i , $i = 1,2$ și matricile de covarianță corespunzătoare Σ_i , $i = 1,2$. Marginea Chernoff superioară a erorii Bayesiene este:

$$e_u = x_1^s x_2^{1-s} \int (f_1(x))^s (f_2(x))^{1-s} dx, \quad s \in [0, 1],$$

unde $x = (x_1, x_2)$ reprezintă distribuția *a priori* iar f_i reprezintă distribuția corespunzătoare celei de-a i -a clase, $i = 1,2$. Dacă ambele funcții

de densitate sunt normale, $f_i \sim N(\mu_i, \Sigma_i)$, $i = 1,2$, expresia lui e_u poate fi scrisă astfel:

$$\int (f_1(x))^s (f_2(x))^{1-s} dx = \exp(-m(s)), \quad \text{unde}$$

$$m(s) = \frac{s(1-s)}{2} (m_2 - m_1)^T (s\Sigma_1 + (1-s)\Sigma_2)^{-1} (m_2 - m_1) + \frac{1}{2} \ln \frac{|s\Sigma_1 + (1-s)\Sigma_2|}{|\Sigma_1|^s |\Sigma_2|^{1-s}}.$$

Marginea superioară

$$m\left(\frac{1}{2}\right) = \frac{1}{8} (m_2 - m_1)^T \left(\frac{\Sigma_1 + \Sigma_2}{2}\right)^{-1} (m_2 - m_1) + \frac{1}{2} \ln \frac{|\Sigma_1 + \Sigma_2|}{2\sqrt{|\Sigma_1||\Sigma_2|}}$$

este numită distanța Bhattacharyya și este folosită în general ca măsură de separabilitate a celor două distribuții.

$$m\left(\frac{1}{2}\right) = \frac{1}{8} \text{tr} \left\{ \bar{\Sigma}^{-1} (m_2 - m_1)(m_2 - m_1)^T \right\} + \frac{1}{4} \ln |2I_n + \Sigma_1 \Sigma_2^{-1} + \Sigma_2 \Sigma_1^{-1}| - \frac{n}{4} \ln 2, \quad \text{unde } \bar{\Sigma} = \frac{\Sigma_1 + \Sigma_2}{2}$$

Cum unul din termeni dispare dacă $\mu_1 = \mu_2$ sau $\Sigma_1 = \Sigma_2$, primul termen furnizează informația de separabilitate între clase pentru medii diferite, iar ultimul termen pentru covarianțe diferite.

Dezvoltând în relația anterioară cei doi termeni, se obține:

$$J = m\left(\frac{1}{2}\right) = \frac{1}{8} \text{tr} \left\{ \bar{\Sigma}^{-1} (m_2 - m_1)(m_2 - m_1)^T \right\}$$

atunci J reprezintă un caz particular al criteriului J_1 pentru matricile de împrăștiere

Distanța Bhattacharyya este folosită drept funcție criteriu ce evaluează calitatea extractorului linear de caracteristici $A \in M_{n \times m}(R)$.

Dacă $\Sigma_1 = \Sigma_2 = \Sigma$,

$$S_2 = \Sigma \quad \text{și} \quad S_1 = S_b = (m_2 - m_1)(m_2 - m_1)^T$$

[5]. În consecință, întreaga informație de separabilitate este continuată în:

$$\Phi_1 = \frac{\Sigma^{-1}(m_2 - m_1)}{\|\Sigma^{-1}(m_2 - m_1)\|}.$$

Dacă $m_1 = m_2$ și $\Sigma_1 \neq \Sigma_2$,

$$J = \frac{1}{4} \ln |2I_n + \Sigma_2^{-1}\Sigma_1 + \Sigma_1^{-1}\Sigma_2| - \frac{n}{4} \ln 2 = \frac{1}{4} \sum_{j=1}^n \left(2 + l_j + \frac{1}{l_j} \right) - \frac{n}{4} \ln 2,$$

unde $l_j, j = 1, n$ reprezintă valorile proprii ale matricei $\Sigma_1^{-1}\Sigma_2$.

Dacă extractorul linear de caracteristici este

definit de matricea $A \in M_{n \times m}(R)$, atunci valoarea distanței Bhattacharyya în spațiul transformat $Y = A^T X$ este dată de:

$$J(m, A) = \frac{1}{4} \ln \left| 2I_m + (A^T \Sigma_2 A)^{-1} (A^T \Sigma_1 A) + (A^T \Sigma_1 A)^{-1} (A^T \Sigma_2 A) \right| - \frac{m}{4} \ln 2.$$

Punctele critice ale funcției $J(m, A)$ sunt soluții ale ecuației $\frac{\nabla J(m, A)}{\nabla A} = 0$, adică:

$$B \{ \Sigma_2 A \Sigma_2^{-1}(m) \Sigma_1(m) \Sigma_2^{-1}(m) - \Sigma_1 A \Sigma_2^{-1}(m) \} + B \{ \Sigma_1 A \Sigma_2^{-1}(m) \Sigma_2(m) \Sigma_1^{-1}(m) - \Sigma_2 A \Sigma_1^{-1}(m) \} = 0$$

în care $\Sigma_i(m) = A^T \Sigma_i A, i = 1, 2$ și $B = \left[(A^T \Sigma_1 A)^{-1} (A^T \Sigma_2 A) + (A^T \Sigma_2 A)^{-1} (A^T \Sigma_1 A) + 2I_m \right]^{-1}$

Soluțiile suboptimale ale ecuației precedente sunt soluții ale sistemului:

$$\begin{cases} \Sigma_2 A \Sigma_2^{-1}(m) \Sigma_1(m) \Sigma_2^{-1}(m) - \Sigma_1 A \Sigma_2^{-1}(m) = 0 \\ \Sigma_1 A \Sigma_1^{-1}(m) \Sigma_2(m) \Sigma_1^{-1}(m) - \Sigma_2 A \Sigma_1^{-1}(m) = 0 \end{cases}$$

sau echivalent, $\Sigma_2^{-1}\Sigma_1 A = A \Sigma_2^{-1}(m) \Sigma_1(m)$.

Evident, funcția criteriu J este invariantă la transformări nesingulare de aceea, $\Phi^{(m)} = (\Phi_1, \dots, \Phi_m)$ poate fi considerat drept extractor linear de caracteristici suboptimal, unde $\Phi_i, i = 1, m$ sunt vectorii proprii corespunzători valorilor proprii $l_1, \dots, l_m$ ale matricei $\Sigma_2^{-1}\Sigma_1$, unde:

$$l_1 + \frac{1}{l_1} \geq \dots \geq l_m + \frac{1}{l_m} \geq \dots \geq l_n + \frac{1}{l_n}.$$

În cazul problemelor de restaurare, ambele presupuneri $m_1 = m_2$, $\Sigma_1 = \Sigma_2$ sunt în general nerealiste, de aceea trebuie acceptate presupunerile $m_1 \neq m_2$ și $\Sigma_1 \neq \Sigma_2$. Cum nu există nici o procedură disponibilă în cazul $\Sigma_1 \neq \Sigma_2$ și $m_1 \neq m_2$, în literatura de

specialitate există deja abordări suboptimale [8].

Algoritm de restaurare HBA (Heuristic Bhattacharyya Algorithm)

Intrare: Exemplele perturbate $\{X_1^{(2)}, \dots, X_N^{(2)}\}$ ale unei imagini $r \times c$ -dimensionale X și numărul dorit k de caracteristici

Pas 1. Se calculează exemplele $\{X_1^{(1)}, \dots, X_N^{(1)}\}$ utilizând masca de filtrare

$$M_t = \frac{1}{12+t} \begin{bmatrix} 1 & 2 & 1 \\ 2 & t & 2 \\ 1 & 2 & 1 \end{bmatrix}, t \geq 4: X_i^{(1)} = F(X_i^{(2)}), 1$$

$\leq i \leq N$.

Pas 2. Pentru fiecare coloană $1 \leq i \leq r$, se execută Step 3 - Step 8

Pas 3. Se calculează $\hat{m}^{(p)}(i) = \frac{1}{N} \sum_{k=1}^N X_k^{(p)}(i)$,

$$\hat{\Sigma}_p(i) = \frac{1}{N-1} \sum_{k=1}^N \left(X_k^{(p)}(i) - \hat{m}^{(p)}(i) \right) \left(X_k^{(p)}(i) - \hat{m}^{(p)}(i) \right)^T, \quad p = 1, 2.$$

Pas 4. Se determina:

$$m\left(\frac{1}{2}, i\right) = \frac{1}{8} \left(\hat{m}^{(2)}(i) - \hat{m}^{(1)}(i) \right)^T \left(\frac{\hat{\Sigma}_1(i) + \hat{\Sigma}_2(i)}{2} \right)^{-1} \left(\hat{m}^{(2)}(i) - \hat{m}^{(1)}(i) \right) + \frac{1}{2} \ln \frac{\left| \frac{\hat{\Sigma}_1(i) + \hat{\Sigma}_2(i)}{2} \right|}{\sqrt{|\hat{\Sigma}_1(i)| |\hat{\Sigma}_2(i)|}}$$

Pas 5. Se calculeaza valorile proprii $(l_1, \dots, l_c)$ si vectorii proprii corespunzatori Φ_i , $i = 1, c$ ai matricei $\hat{\Sigma}_2^{-1}(i) \hat{\Sigma}_1(i)$ utilizând

$$\frac{\left[\Phi_s^T \left(\hat{m}^{(2)}(i) - \hat{m}^{(1)}(i) \right) \right]^2}{1 + l_s} + \ln \left(2 + l_s + \frac{1}{l_s} \right) \geq \frac{\left[\Phi_j^T \left(\hat{m}^{(2)}(i) - \hat{m}^{(1)}(i) \right) \right]^2}{1 + l_{ij}} + \ln \left(2 + l_j + \frac{1}{l_j} \right)$$

si se determina matricea de caracteristici $M(i) = (\Phi_1, \dots, \Phi_c)^T$.

Pas 7. Se calculeaza $T(\hat{m}^{(1)}(i))$ prin aplica-rea unui filtru prag asupra vectorului medie $\hat{m}^{(1)}(i)$ si termenul de corectie $Y(i) = M^T(i) T(\hat{m}^{(1)}(i))$

Pas 8. Se determina linia $\bar{X}(i)$ din imaginea restaurata $\bar{X}$ aplicând o corectie imaginii filtrate $T(\hat{m}^{(1)}(i))$ pe baza informatiei continute de caracteristicile de selectie $\bar{X}(i) = T(\hat{m}^{(1)}(i)) + sM(i)Y(i)$ în care s este o constanta utilizata pentru prevenirea zgometului, $0 < s < 1$.

3. Experimente si concluzii

Au fost efectuate experimente pentru imagini cu 256 nivele de gri de la alb la negru; implementarea algoritmului descris conduce la

algoritmul de diagonalizare simultana.

Pas 6. Se ordoneaza valorile proprii astfel încât, pentru orice s si j cu $1 \leq s < j \leq c$,

imagini superioare din punct de vedere al contrastului, luminozitatii si zgomotului aproximările prin medie sau prin media filtrata binomial.

Pentru algoritmi de calcul pentru pasii 4 si 5 din HBA s-au folosit metodele Chonlansky, respectiv metoda diagonalizării simultane (în general, datorita filtrării fara procesarea liniilor si coloanelor marginale prin simetrie, matricea de covarianța corespunzatoare celei de-a doua clase nu este inversabila, deci se calculeaza pseudoinversa).

Constantele folosite la pasii 1 si 8 depind în general de gradul de perturbare a intrarilor, tipul de filtru utilizat în nivelare (binomial sau extensii ale sale), numarul de date care pot fi acceptate (vectorii proprii asociati valorilor proprii nenegative).

În continuare este prezentat un exemplu de executie a acestui algoritm.



Imaginile de intrare



Imaginea obtinuta prin aplicarea algoritmului HBA

Bibliografie

- [1] Andrews, H., Hunt, B. *"Digital Image Restoration"*, Prentice-Hall, Englewood Cliffs, 1977
- [2] Anderson, T.W. *"An Introduction to Multivariate Statistical Analysis"*, John Wiley & Sons, 1958
- [3] Chellappa, R., Jinchi, H. *"A nonrecursive Filter for Edge Preserving Image Restoration"*, Proc. Intl.Conf.on Acoustic, Speech and Signal Processing, Tampa, 1985
- [4] Chellappa, R., Kashyap, R.L. *"Digital Image Restoration Using Spatial Interaction Models"*, Proc. Intl.Conf.on Acoustic, Speech and Signal Processing, vol. ASSP-30, 1982
- [5] Cocianu C., *"Restaurarea imaginilor perturbate normal prin matrice de imprastiere"*, Informatica Economica, nr. 5/1998
- [6] Devijver, P.A., Kittler, J. *"Pattern Recognition: A Statistical Approach"*, Prentice-Hall Int. Inc., 1982
- [7] Gonzales, R., Woods, R. *"Digital Image Processing"*, Addison Wesley, 1993
- [8] Fukunaga K. *"Introduction to Statistical Pattern Recognition"*, Academic Press, Inc. 1990
- [9] Pratt, W.K., *"Digital Image Processing"*, Wiley, New York, 1978
- [10] State L., *"Analiza in componente principale pentru compresia/restaurarea datelor"* Informatica Economica, Nr.2/1997
- [11] State L., Cocianu C., *"Determinarea caracteristicilor lineare optime din punct de vedere informational in compresia si decompresia datelor"* Informatica Economica, nr. 4/1997

