

## Determinarea caracteristicilor lineare optimale din punct de vedere informațional în compresia și decompresia datelor

Conf. dr. Luminița STATE  
Catedra de Informatică, Universitatea București  
Prep. Cătălina COCIANU  
Catedra de Informatică Economică, A.S.E., București

*Extragerea caracteristicilor liniare revine, în esență, la un proces de eliminare a redundanței existente în date, caracteristicile rezultând ca funcții de elementele de structură ale spațiului formelor de intrare. Modelele informaționale dezvoltate furnizează algoritmi foarte eficienți de compresie/decompresie, reconstrucție și recunoaștere de forme. Este exemplificat algoritmul RLS, cu aplicații în compresia/decompresia imaginilor (binare și cu un număr de 256 nivele de gri de la alb la negru), calitățile sale fiind relevate și comparativ cu un model standard de extragere de caracteristici, și anume modelul Karhunen-Loeve.*

*Cuvinte cheie: extractor linear de caracteristici, entropie, layer, vector sinaptic, eroare Hamming, funcție criteriu.*

Fie  $X$  vector aleator  $n$ -dimensional  $E(X) = \mu$ ,  $\text{cov}(X, X^T) = \Sigma$  matrice simetrică și pozitiv definită. Dacă  $T \in M_{m \times n}(\mathbb{R})$  este un extractor de caracteristici lineare unde  $m \leq n$  și  $Y = T^T X$  este vectorul aleator reprezentând valorile caracteristicilor selectate corespun-

zătoare formei  $X$ , atunci  $E(Y) = T^T \mu$  și  $\text{cov}(Y, Y^T) = T^T \Sigma T$ . Informația reciprocă  $I(X; T^T X)$  reprezintă o măsură a cantității de informație relativ la  $X$  reținută prin utilizarea filtrului linear  $T$ :

$$I(X; T^T X) = H(T^T X) - H(T^T X | X) = H(X) - H(X | T^T X) \geq 0, \text{ unde } H \text{ este entropia Shannon.}$$

Deoarece  $H(T^T X | X) = 0$ , rezultă că  $H(T^T X) \leq H(X)$ ,  $H(X | T^T X) = H(X) - H(T^T X)$ , deci  $H(X | T^T X)$  reprezintă o măsură a pierderii de informație implicate de utilizarea filtrului linear  $T$ . Extragerea de caracteristici lineare optimale din punct de vedere informațional revine astfel la determinarea unui filtru  $T$  care să minimizeze entropia condiționată  $H(X | T^T X)$ , ceea ce este echivalent cu maximizarea entropiei  $H(T^T X)$ .

În continuare vom considera numai extractori de caracteristici lineare care conduc la repartiții nedegenerate, matricea

$T^T \Sigma T$  fiind pozitiv definită dacă și numai dacă  $\text{rang}(T) = m$ . Evident pentru orice  $T \in M_{m \times n}(\mathbb{R})$  astfel încât  $T^T T = I_m$  rezultă  $\text{rang}(T) = m$ . Fie, prin notație, mulțimea  $M(m, n) = \{T \in M_{m \times n}(\mathbb{R}) \mid T^T \Sigma T \neq 0, T^T T = I_m\}$ .

Fie  $\Phi = (\Phi_1, \dots, \Phi_n)$  matricea vectorilor proprii unitari și  $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$  matricea diagonală a valorilor proprii asociate corespunzătoare matricei  $\Sigma$ ;  $\Phi^T \Sigma \Phi = \Lambda$ ,  $\Phi$  matrice ortogonală. Determinarea caracteristicilor lineare optimale din punct de vedere informațional pentru o repartiție dată, corespunde problemei variaționale:

$$(1) \sup_{T \in M(m, n)} H(T^T X)$$

**Lema 1** Fie  $A \in M_{m \times n}(\mathbb{R})$ ,  $A = \|a_{ij}\|$ ,  $S \in M_m(\mathbb{R})$ ,  $S = \|\sigma_{ij}\|$ , matrice simetrică astfel încât  $|A^T S A| \neq 0$ , matrice simetrică. Atunci,

$$(2) \frac{\partial}{\partial A} \ln |A^T S A| = 2 S A (A^T S A)^{-1}, \text{ unde } \frac{\partial}{\partial A} \ln |A^T S A| = \left\| \frac{\partial}{\partial a_{ij}} \ln |A^T S A| \right\|.$$

**Demonstrație** Notând cu  $R(A^T S A)_{kl}$  cofactorul corespunzător componenteii  $a_{kl}$  din matricea  $A^T S A$ ,  $1 \leq k, l \leq m$  rezultă,

$$\frac{\partial}{\partial A} \ln |A^T S A| = \frac{1}{|A^T S A|} \left\| \frac{\partial}{\partial a_{ij}} |A^T S A| \right\| = \frac{1}{|A^T S A|} \left\| \frac{\partial}{\partial a_{ij}} \sum_{k=1}^m \sum_{l=1}^m (A^T S A)_{kl} R(A^T S A)_{kl} \right\|$$

Componentele matricei  $\frac{\partial}{\partial A} \ln |A^T S A|$  sunt,

$$\frac{\partial}{\partial a_{ij}} |A^T S A| = \sum_{k=1}^m \sum_{l=1}^m \frac{\partial}{\partial (A^T S A)_{kl}} |A^T S A| \frac{\partial}{\partial a_{ij}} (A^T S A)_{kl} = \sum_{k=1}^m \sum_{l=1}^m R(A^T S A)_{kl} \frac{\partial}{\partial a_{ij}} (A^T S A)_{kl}$$

$$\text{Deoarece } \frac{\partial}{\partial a_{ij}} (A^T S A)_{kl} = \frac{\partial}{\partial a_{ij}} \sum_{p=1}^n \sum_{q=1}^n a_{pk} \sigma_{pq} a_{ql} = \sum_{p=1}^n \sum_{q=1}^n \frac{\partial a_{pk}}{\partial a_{ij}} \sigma_{pq} a_{ql} + \sum_{p=1}^n \sum_{q=1}^n \frac{\partial a_{pk}}{\partial a_{ij}} a_{pk} \sigma_{pq}$$

$$\text{rezultă } \frac{\partial}{\partial a_{ij}} (A^T S A)_{kl} = \begin{cases} 0, k \neq j, l \neq j \\ (S A)_{ij}, k = j, l \neq j \\ (S A)_{ik}, k \neq j, l = j \\ 2(S A)_{ij}, k = l = j \end{cases}$$

Obținem astfel,

$$\begin{aligned} \frac{\partial}{\partial a_{ij}} |A^T S A| &= \sum_{l=1}^m R(A^T S A)_{jl} (S A)_{il} + \sum_{k=1, k \neq j}^m R(A^T S A)_{kj} (S A)_{ik} + 2(S A)_{ij} R(A^T S A)_{jj} = \\ &= 2 \sum_{k=1}^m R(A^T S A)_{kj} (S A)_{ik} = 2 \left( (S A) (A^T S A)^* \right)_{ij} \end{aligned}$$

$$\text{În concluzie, } \left\| \frac{\partial}{\partial a_{ij}} |A^T S A| \right\| = 2 |A^T S A| S A (A^T S A)^{-1}, \text{ deci } \frac{\partial}{\partial A} \ln |A^T S A| = 2 S A (A^T S A)^{-1}$$

**Lema 2** Fie  $A \in M_{n \times n}(\mathbb{R})$ ,  $A = \|a_{ij}\|$ ,  $S \in M_m(\mathbb{R})$ ,  $S = \|\sigma_{ij}\|$ , matrice simetrică. Atunci,

$$(3) \frac{\partial}{\partial A} \text{tr}\{A S A^T\} = 2 A S, \text{ unde } \frac{\partial}{\partial A} \text{tr}\{A S A^T\} = \left\| \frac{\partial}{\partial a_{ij}} \text{tr}\{A S A^T\} \right\|.$$

**Demonstrație** Deoarece  $\text{tr}\{A S A^T\} = \text{tr}\{S A^T A\}$ , obținem

$$\begin{aligned} \frac{\partial}{\partial a_{ij}} \text{tr}\{A S A^T\} &= \frac{\partial}{\partial a_{ij}} \sum_{p=1}^m \sum_{q=1}^m \sum_{r=1}^n \sigma_{pq} a_{rq} a_{rp} = \sum_{p=1}^m \sum_{q=1}^m \sum_{r=1}^n \sigma_{pq} \frac{\partial a_{rq}}{\partial a_{ij}} a_{rp} + \sum_{p=1}^m \sum_{q=1}^m \sum_{r=1}^n \sigma_{pq} a_{rq} \frac{\partial a_{rp}}{\partial a_{ij}} = \\ &= 2 \sum_{p=1}^m a_{ip} \sigma_{pj} = 2 (A S)_{ij} \text{ deci } \frac{\partial}{\partial A} \text{tr}\{A S A^T\} = 2 A S. \end{aligned}$$

**Teorema 1** Dacă  $X \sim N(\mu, \Sigma)$  atunci  $\sup_{T \in M(m, n)} H(T^T X) = \frac{1}{2} \sum_{i=1}^m \ln \lambda_i + \frac{m}{2} \ln 2\pi e$ , unde  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq \dots \geq \lambda_n$  sunt valorile proprii ale matricei de covarianță  $\Sigma$ . Mulțimea soluțiilor problemei variaționale (1) este  $\{(\Phi_1, \dots, \Phi_m) \Psi \mid \Psi \in M_m(\mathbb{R}), \Psi^T \Psi = I_m\}$ .

**Demonstrație** Deoarece  $X \sim N(\mu, \Sigma)$ , pentru orice  $T \in M(m, n)$ , rezultă că  $T^T X \sim N(T^T \mu, T^T \Sigma T)$ , deci  $H(T^T X) = \frac{m}{2} \ln 2\pi e + \frac{1}{2} \ln |T^T \Sigma T|$ . Notăm cu  $S(\omega)$  spațiul punctelor critice ale funcției obiectiv.

$J_m(T) = \ln |T^T \Sigma T| - \text{tr} \{ \omega (T^T T - I_m) \}$  unde  $\omega$  este o matrice simetrică,

$$S(\omega) = \left\{ T \mid T \in M_{m \times n}(\mathbb{R}), |T^T \Sigma T| \neq 0, \frac{\partial J_m(T)}{\partial T} = 0 \right\}$$

Deoarece  $\frac{\partial \ln |T^T \Sigma T|}{\partial T} = 2 \Sigma T (T^T \Sigma T)^{-1}$ ,  $\frac{\partial \text{tr}(T \omega T^T)}{\partial T} = 2 T \omega$  rezultă că  $T \in S(\omega)$  dacă și numai dacă  $|T^T \Sigma T| \neq 0$  și  $2 \Sigma T (T^T \Sigma T)^{-1} = 2 T \omega$  adică  $\Sigma T = T \omega T^T \Sigma T$ .

Obținem în continuare,  $T^T \Sigma T = T^T T \omega T^T \Sigma T$ . ceea ce evident implică  $I_m = T^T T \omega$ . În particular, pentru  $\omega = I_m$  obținem  $S(I_m) \subseteq M(m, n)$ .

Deoarece  $S(I_m)$  conține punctele de extrem ale funcției obiectiv și pentru orice  $T \in S(I_m)$ ,  $\Sigma T = T T^T \Sigma T$ ,  $J_m(T) = \ln |T^T \Sigma T|$ , rezultă în particular că  $S(I_m)$  conține toate soluțiile problemei variaționale (1).

Fie  $\Psi_m$  matricea având coloanele vectorii proprii unitari ai matricei  $T^T \Sigma T$  și  $\Lambda_m$  matricea diagonală a valorilor proprii asociate;  $T^T \Sigma T = \Psi_m \Lambda_m \Psi_m^T$ .

Pentru orice  $T \in S(I_m)$  rezultă  $\Sigma T = T \Psi_m \Lambda_m \Psi_m^T$  adică  $\Sigma T \Psi_m = T \Lambda_m \Psi_m^T$ , deci componentele matricei  $\Lambda_m$  sunt valori proprii ale matricei  $\Sigma$  iar coloanele matricei  $T \Psi_m$  sunt vectorii proprii unitari asociați și  $\ln |T^T \Sigma T| = \sum_{j=1}^m \ln \lambda_j$  unde  $\Lambda_m = \text{diag}(\lambda_1, \dots, \lambda_m)$ .

Evident, pentru orice  $m$  valori proprii  $\lambda_1, \dots, \lambda_m$  ale matricei  $\Sigma$ , există  $T \in S(I_m)$  astfel încât

$$\ln |T^T \Sigma T| = \sum_{j=1}^m \ln \lambda_j. \text{ Într-adevăr, dacă } T = (\Phi_1, \dots, \Phi_m) \text{ atunci } |T^T \Sigma T| = \prod_{j=1}^m \lambda_j \neq 0 \text{ și}$$

$$\Sigma T = T \text{diag}(\lambda_1, \dots, \lambda_m) = T T^T \Sigma T \text{ deci } T \in S(I_m) \text{ și } \ln |T^T \Sigma T| = \sum_{j=1}^m \ln \lambda_j.$$

Rezultă  $\sup_{T \in M(m, n)} \ln |T^T \Sigma T| = \sum_{i=1}^m \ln \lambda_i$  deci  $\sup_{T \in M(m, n)} H(T^T X) = \frac{1}{2} \sum_{i=1}^m \ln \lambda_i + \frac{m}{2} \ln 2\pi e$  unde  $\lambda_1, \dots, \lambda_m$

sunt cele mai mari  $m$  valori proprii ale matricei de covarianță  $\Sigma$ .

Fie  $T \in S = \{ (\Phi_1, \dots, \Phi_m) \Psi \mid \Psi \in M_m(\mathbb{R}), \Psi^T \Psi = I_m \}$  arbitrar.

$$\text{Evident } \left| (\Phi_1, \dots, \Phi_m)^T \Sigma (\Phi_1, \dots, \Phi_m) \right| = \prod_{i=1}^m \lambda_i \neq 0,$$

$$T^T \Sigma T = (\Phi_1, \dots, \Phi_m) \Psi \Psi^T (\Phi_1, \dots, \Phi_m)^T \Sigma T = \Sigma T \text{ deci } T \in S(I_m).$$

Deoarece entropia este invariantă față de transformările ortogonale obținem:

$$\begin{aligned} H(T^T X) &= H(\Psi^T (\Phi_1, \dots, \Phi_m) X) = H((\Phi_1, \dots, \Phi_m) X) = \frac{1}{2} \ln \left| (\Phi_1, \dots, \Phi_m)^T \Sigma (\Phi_1, \dots, \Phi_m) \right| + \frac{m}{2} \ln 2\pi e \\ &= \frac{1}{2} \sum_{i=1}^m \ln \lambda_i + \frac{m}{2} \ln 2\pi e. \end{aligned}$$

Reciproc, fie  $T \in S(I_m)$  astfel încât  $\ln |T^T \Sigma T| = \sum_{i=1}^m \ln \lambda_i$ ; conform celor demonstrate anterior,

$T\Psi_m = (\Phi_1, \dots, \Phi_m)$ , unde  $\Psi_m$  este matricea având coloanele vectorii proprii unitari ai matricei  $T^T\Sigma T$ , deci  $T = (\Phi_1, \dots, \Phi_m) \Psi_m^T$  adică  $T \in S$ .

În concluzie, pentru repartiția normală, direcțiile principale din punct de vedere informațional sunt vectorii proprii ai matricei de covarianță, reducerea dimensionalității revenind la selectarea caracteristicilor reprezentate de vectorii proprii asociați celor mai mari valori proprii. Determinarea caracteristicilor optime din punct de vedere informațional pentru repartiții care nu mai sunt de tip normal comportă un studiu elaborat, frecvent problema devenind de nerezolvat.

În cele ce urmează vor fi prezentate argumente de ordin informațional pentru justificarea simplificării problemei prin acceptarea unui anumit tip de suboptimalitate, caracteristicile astfel determinate fiind referite prin termenul de caracteristici sigure.

Fie  $T \in M_{n \times m}(\mathbb{R})$ ,  $U \in M_{n \times (n-m)}(\mathbb{R})$  astfel încât  $T^T T = I_m$ ,  $U^T U = I_{n-m}$ ,  $|T^T \Sigma T| \neq 0$ ,  $|U^T \Sigma U| \neq 0$ ,  $T^T \Sigma U = 0$ . Evident, există cel puțin o pereche de matrice care să verifice aceste cerințe și anume  $T = (\Phi_1, \dots, \Phi_m)$ ,  $U = (\Phi_{m+1}, \dots, \Phi_n)$ , unde  $\Phi_1, \dots, \Phi_n$  sunt vectorii proprii ai matricei de covarianță  $\Sigma$ .

Fie  $A = (T, U) \in M_n(\mathbb{R})$ ; rezultă că  $|A^T \Sigma A| = |T^T \Sigma T| |U^T \Sigma U| \neq 0$ . Dacă  $Y = A^T X = \begin{pmatrix} Y^{(1)} \\ Y^{(2)} \end{pmatrix}$ , unde  $Y^{(1)} = T^T X$ ,  $Y^{(2)} = U^T X$ ; atunci

$\text{cov}(Y^{(1)}, T^{(2)T}) = 0$ , deci  $Y^{(1)}$ ,  $Y^{(2)}$  sunt necorelați. În particular, dacă  $X$  este repartizat normal, atunci și  $Y$  este repartizat normal, deci  $Y^{(1)}$ ,  $Y^{(2)}$  sunt independenți ceea ce implică  $H(X) = H(Y) - \ln|A| = H(T^T X) + H(U^T X) - \ln|A|$ . Obținem deci,

$$H(X|T^T X) = H(X) - H(T^T X) = H(U^T X) - \ln|A|,$$

ceea ce înseamnă că tentativa de identificare a unui extractor de caracteristici  $T \in M_{n \times m}(\mathbb{R})$  suboptimal din punct de vedere informațional poate fi reformulată prin problema variațională:

$$(2) \inf_{U \in M^*(m,n)} H(U^T X), \text{ unde}$$

$$M^*(m,n) = \left\{ U \in M_{n \times (n-m)}(\mathbb{R}), |U^T \Sigma U| \neq 0, U^T U = I_{n-m} \right\}$$

Fie  $X$  vector aleator de medie  $\mu$  și matrice de covarianță  $\Sigma$ . Dacă  $U$  este o soluție a problemei (2), atunci matricea  $T \in M_{n \times m}(\mathbb{R})$  având coloanele vectori unitari și ortogonali pe vectorii coloană ai matricei  $U$  definește un extractor de caracteristici lineare "aproape" optimal din punct de vedere informațional.

Conform teoremei Gibbs, pentru orice  $U \in M^*(m,n)$ , are loc inegalitatea:

$$H(U^T X) \leq \frac{n-m}{2} \ln 2\pi e + \frac{1}{2} \ln |U^T \Sigma U|, \text{ deci}$$

minimizarea entropiei  $H(U^T X)$  pe spațiul  $M^*(m,n)$  poate fi realizată selectând  $U \in M^*(m,n)$  care minimizează termenul  $\ln |U^T \Sigma U|$ , deci soluție a problemei variaționale min-max:

$$(3) \inf_{U \in M^*(m,n)} \sup_{f \in G(U^T \mu, U^T \Sigma U)} H(f),$$

unde  $G(U^T \mu, U^T \Sigma U)$  este clasa funcțiilor de densitate  $(n-m)$ -dimensionale, de medie  $U^T \mu$  și matrice de covarianță  $U^T \Sigma U$ .

Caracteristicile lineare definite de matricea  $T \in M_{n \times m}(\mathbb{R})$ , având coloanele vectori unitari și ortogonali pe vectorii coloană ai matricei  $U$ , soluție a problemei (3), sunt evident suboptimale din punct de vedere informațional și, rezultând pe baza unui criteriu min-max, au semnificația de caracteristici sigure. Utilizând argumentele prezentate în demonstrația teoremei 1 rezultă că mulțimea soluțiilor problemei variaționale (3) este

$$\left\{ (\Phi_{m+1}, \dots, \Phi_n) \Psi \mid \Psi \in M_{n-m}(\mathbb{R}), \Psi^T \Psi = I_{n-m} \right\},$$


unde  $\Phi_{m+1}, \dots, \Phi_n$  sunt vectorii proprii unitari asociați celor mai mici  $(n-m)$  valori proprii ale matricei  $\Sigma$ . În consecință, caracteristicile sigure corespunzătoare unei repartiții de matrice de covarianță  $\Sigma$  sunt caracteristicile lineare optime din punct de vedere informațional pentru repartiția normală de matrice de covarianță  $\Sigma$ , adică

$$\{(\Phi_1, \dots, \Phi_m) \Psi \mid \Psi \in M_m(\mathbb{R}), \Psi^T \Psi = I_m\}$$

unde  $\Phi_1, \dots, \Phi_m$  sunt vectorii proprii unitari

**Algoritmul RLS**

Algoritmul RLS furnizează o metodă eficientă de compresie/decompresie prin extragerea optimală a primelor  $m$  caracteristici principale ale unei intrări corespunzând unui proces staționar  $n$ -dimensional ( $n > m$ ) ( $X(t)$ ).



asociați celor mai mari  $m$  valori proprii ale matricei  $\Sigma$ .

**Extragerea primei caracteristici principale**

Arhitectura neurală utilizată pentru extragerea primei caracteristici principale conține 3 layere  $F_X, F_H, F_Y$ , unde  $F_X$  este layer-ul de intrare,  $F_Y$  este layer-ul de ieșire,  $|F_X| = |F_Y| = n$  și  $F_H$  este layer-ul ascuns,  $|F_H| = 1$ . Reprezentarea arhitecturii:

$$F_X \xrightarrow{W_1^T} F_H \xrightarrow{W_1} F_Y$$

în care:

- $X(t) = [X^{(1)}(t), \dots, X^{(n)}(t)]$  reprezintă intrarea (proces staționar);
- activarea neuronului ascuns se face după regula:  $h_1(t) = W_1^T(t-1) X(t)$ ;
- $Y(t) = [Y^{(1)}(t), \dots, Y^{(n)}(t)]$  reprezintă ieșirea, detrmnată conform regulii  $Y(t) = W_1(t-1)h_1(t) = W_1(t-1)W_1^T(t-1) X(t)$ .

Funcția criteriu pentru determinarea estimației filtrului (ponderii)  $W_1$ , optimală din punct de vedere al erorii medii pătratice,

este:  $J_1(t) = \sum_{k=1}^t \varepsilon^2(k)$ , unde  $\varepsilon^2(k) = \|X(k) - Y(k)\|^2$ .

Presupunând că la toate momentele de timp  $k, 1 \leq k \leq t$ , a fost utilizat filtrul  $W_1(t)$ , atunci:

$$J_1(t) = \frac{1}{t} \sum_{k=1}^t (X(k) - W_1(t)h_1(k))^T (X(k) - W_1(t)h_1(k)),$$

$$\hat{W}_1(t) = \frac{\bar{X}^T(t)h_1^T(t)}{\|h_1^T(t)h_1(t)\|^2}$$

Algoritmul RSL pentru determinarea estimației  $\hat{W}_1$  (componentei principale) este:

$$h_1(t) = W_1^T(t-1) X(t)$$

$$k_1(t) = \frac{P_1(t-1)h_1(t)}{1 + h_1^2(t)P_1(t-1)}$$

$$P_1(t) = [1 - k_1(t)h_1(t)] P_1(t-1)$$

$$\hat{W}_1(t) = \hat{W}_1(t-1) + k_1(t)[X(t) - h_1(t)\hat{W}_1(t-1)]$$

**Teoremă** Algoritmul RSL permite învățarea primei componente principale  $\phi_1$  la nivelul vectorului sinaptic corespunzător neuronului ascuns:  $\lim_{t \rightarrow \infty} \hat{W}_1(t) = \phi_1$ , unde  $\phi_1$  reprezintă vectorul propriu corespunzător valorii proprii  $\lambda_1$  a matricei de covarianță  $\Sigma$  ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ ).

**Demonstrație**

$$J_1(t) = \frac{1}{t} \sum_{k=1}^t [X(k) - W_1(t)W_1^T(t)X(k)]^T [X(k) - W_1(t)W_1^T(t)X(k)] =$$

$$= \frac{1}{t} \sum_{k=1}^t X^T(k)X(k) - \frac{2}{t} \sum_{k=1}^t X^T(k)W_1(t)W_1^T(t)X(k) + \frac{1}{t} \sum_{k=1}^t X^T(k)W_1(t)W_1^T(t)W_1(t)W_1^T(t)X(k)$$

Cum  $\lim_{t \rightarrow \infty} \frac{1}{t} \sum_{k=1}^t X(k)X^T(k) = \Sigma$ , rezultă că  $\frac{1}{t} \sum_{k=1}^t X^T(k)X(k) \cong \text{tr } \Sigma$

$$\frac{1}{t} \sum_{k=1}^t X^T(k)W_1(t)W_1^T(t)X(k) = W_1^T(t) \left( \frac{1}{t} \sum_{k=1}^t X^T(k)X(k) \right) W_1(t) \cong W_1^T(t) \Sigma W_1(t)$$

$$\frac{1}{t} \sum_{k=1}^t X^T(k)W_1(t)W_1^T(t)W_1(t)W_1^T(t)X(k) \cong \|W_1(t)\|^2 W_1^T(t) \Sigma W_1(t)$$

$$\text{Deci } J_1(t) \cong \text{tr } \Sigma - 2W_1^T(t) \Sigma W_1(t) + \|W_1(t)\|^2 W_1^T(t) \Sigma W_1(t)$$

$$\text{grad } J_1(t) = -4 \Sigma W_1(t) + 2W_1(t)W_1^T(t) \Sigma W_1(t) + 2\|W_1(t)\|^2 \Sigma W_1(t)$$

Cum  $\|W_1(t)\|^2 \Sigma W_1(t) = W_1(t)W_1^T(t) \Sigma W_1(t)$ , rezultă că :

$$\text{grad } J_1(t) = -4 \Sigma W_1(t) + 4W_1(t)W_1^T(t) \Sigma W_1(t)$$

$$\text{Fie } S = \left\{ \hat{W} \in \mathbb{R}^n / \text{grad } J_1(t)_{W_1=\hat{W}} = 0 \right\}$$

**Observații:**

1. Toți vectorii proprii ai matricii  $\Sigma$  aparțin spațiului  $S$ .

Într-adevăr, dacă  $\hat{W}_i = \phi_i$ , atunci  $\text{grad } J_1(t)_{W_1=\phi_i} = -4 \Sigma \phi_i + 4\phi_i \phi_i^T \Sigma \phi_i = -4\lambda_i \phi_i + 4\lambda_i \phi_i = 0$

2. Orice vector nenul din  $S$  este unitar.

Într-adevăr, dacă  $\hat{W} \in S$ , atunci:

$$\Sigma \hat{W} = \hat{W} \hat{W}^T \Sigma \hat{W}, \quad \hat{W}^T \Sigma \hat{W} = \hat{W}^T \hat{W} \hat{W}^T \Sigma \hat{W}. \text{ Deci } \hat{W}^T \Sigma \hat{W} (1 - \|\hat{W}\|^2) = 0. \text{ Cum } \Sigma \text{ este pozitiv}$$

definită și  $\hat{W}$  este nenul, rezultă  $\hat{W}^T \Sigma \hat{W} \neq 0$ , deci  $\|\hat{W}\| = 1$ .

3. Punctele de minim ale funcției  $J_1$  sunt exact vectorii proprii corespunzători matricii  $\Sigma$ .

Într-adevăr, fie funcțiile criteriu  $\bar{J}_i$  ( $i = \overline{1, n}$ ) definite pe spațiul  $S$  astfel:

$$\bar{J}_i(t) = \text{tr } \Sigma - 2\hat{W}^T \Sigma \hat{W} + \|\hat{W}\|^2 \hat{W}^T \Sigma \hat{W} + \lambda_i (\hat{W}^T \hat{W} - 1), \quad i = \overline{1, n}$$

Cum  $\|\hat{W}\| = 1$  pe spațiul  $S$ , rezultă că  $\bar{J}_i(t) = \text{tr } \Sigma - \hat{W}^T \Sigma \hat{W} + \lambda_i (\hat{W}^T \hat{W} - 1), \quad i = \overline{1, n}$

Funcțiile  $J_1$  și  $\bar{J}_i$  au aceleași puncte critice și aceleași puncte de minim în raport cu spațiul  $S$ .

$\text{grad } \bar{J}_i(t) = -\Sigma \hat{W} + \lambda_i \hat{W}$ . Pe  $S$   $\text{grad } \bar{J}_i(t) = 0 \Rightarrow \Sigma \hat{W} = \lambda_i \hat{W}$ , deci  $\hat{W}$  reprezintă vectorul propriu corespunzător lui  $\lambda_i$ . Deci punctele de minim ale funcției  $J_1$  sunt exact vectorii proprii corespunzători matricii  $\Sigma$ .


$$J_1(t)_{W_1=\phi_i} = \text{tr } \Sigma - \phi_i^T \Sigma \phi_i = \sum_{j=1}^n \lambda_j - \lambda_i = \sum_{j \neq i}^n \lambda_j, \text{ deci minimul absolut pentru } J_1 \text{ corespunzător}$$

lui  $\hat{W}$  aparținând lui  $S$  este dat de  $\hat{W} = \phi_1$ .

Algoritmul RLS garantează minimizarea lui  $J_1$ ; suprafața de eroare are unul sau mai multe puncte de minim local, dar valoarea criteriului  $J_1$  este aceeași; punctul de minim absolut pentru  $J_1$  este  $\phi_1$ , deci, asimptotic, vectorul optimal este  $\phi_1$ :  $\lim_{t \rightarrow \infty} \hat{W}_1(t) = \phi_1$ .

**Extragerea primelor m componente principale**

Arhitectura neurală utilizată în scopul extragerii primelor m componente principale este, cu aceleași notații, următoarea:



Reprezentarea internă calculată de arhitectura neurală e dată de vectorii sinaptici între  $F_X$  și  $F_H$ . Antrenarea arhitecturii se realizează secvențial astfel încât procesul de antrenare pentru neuronul  $p$  începe când s-a decis terminarea procesului de antrenare pentru neuronul  $p-1$ .

$$W_p = [W_{1p}, \dots, W_{np}]^T$$

$$h_p(t) = W^T(t-1) X(t)$$

$$Y(t) = W(t-1)h_p(t) = W(t-1) W^T(t-1) X(t)$$

$$p \in 1..m$$

$$D(t) = X(t) - \text{răspunsul dorit}$$

Răspunsul dorit la momentul de timp  $t$  în procesul de calcul al neuronului  $p$  de pe layer-ul  $F_H$  este dat prin relația:

$$d_p(t) = X(t) - \sum_{i=1}^{p-1} \hat{W}_i(t)h_i(t)$$

Funcția criteriu pentru neuronul  $p$  la momentul  $t$  este dată de relația:

$$J_p(t) = \frac{1}{t} \sum_{k=1}^t (d_p(k) - W_p(k)h_p(k))^T (d_p(k) - W_p(k)h_p(k))$$

$$h_p(t) = \frac{1}{t} \sum_{k=1}^t \left[ X(k) - \sum_{i=1}^{p-1} \hat{h}_i(t)\hat{W}_i(t) - W_p(k)h_p(k) \right]^T \left[ X(k) - \sum_{i=1}^{p-1} \hat{h}_i(t)\hat{W}_i(t) - W_p(k)h_p(k) \right]$$

Presupunând că la toate momentele de timp  $k \in 1..t-1$  ar fi utilizat filtrul  $W_p(t)$  în locul filtrelor  $W_p(1), \dots, W_p(t-1)$ , atunci

$$\text{grad } J_p(t) = - \sum_{k=1}^t h_p(k) (d_p(k) - W_p(t)h_p(k))$$

, iar minimul lui  $J_p$  se atinge pentru

$$\sum_{k=1}^t h_p(k)d_p(k) = W_p(t) \sum_{k=1}^t (h_p(k))^2. \text{ Fie}$$

$$\bar{h}_p(t) = [h_p(1), \dots, h_p(t)]^T, \bar{D}_p(t) = [d_p(1), \dots, d_p(t)]^T; \text{ obținem: } \bar{D}_p(t) \bar{h}_p(t) =$$

$$= W_p(t) \|\bar{h}_p(t)\|^2, \text{ deci } W_p(t) = \frac{1}{\|\bar{h}_p(t)\|^2} \bar{D}_p(t) \bar{h}_p(t).$$

În consecință, algoritmul RLS extins pentru neuronul  $p$  este următorul:

intrare:  $X(t)$  proces staționar de medie 0 și matrice de covarianță  $\Sigma$

$$h_p(t) = W^T(t-1) X(t)$$

$$k_p(t) = \frac{P_p(t-1)h_p(t)}{1 + h_p^2(t)P_p(t-1)}$$

$$P_p(t) = [1 - k_p(t)h_p(t)] P_p(t-1)$$

$$\hat{W}_p(t) = \hat{W}_p(t-1) + k_p(t) [X(t) - h_p(t)\hat{W}_p(t-1)]$$

**Teoremă.** Algoritmul RLS descris pentru antrenarea neuronului  $p$  determină asimptotic ca vector sinaptic vectorul propriu  $\phi_p$ :  $\lim_{t \rightarrow \infty} \hat{W}_p(t) = \phi_p$

Demonstrația este similară celei din teorema anterioară (se poate găsi în [1])

## Experimente și concluzii

Algoritmul RLS a fost implementat și testat de autori pentru două clase mari de probleme, și anume reducerea dimensionalității unui semnal binar, exemplificat în cazul de față prin caractere, respectiv a unui semnal oarecare, exemplificat prin imagini cu 256 nivele de gri de la alb la negru.

Testele efectuate au demonstrat, pe de o parte, un comportament stabil la perturbații, iar pe de altă parte, variații foarte reduse de informație la o reducere a dimensionalității la o zecime și, în cazul imaginilor, chiar la o reducere mai drastică.

Implementarea acestui algoritm în cazul caracterelor a fost realizată considerând ca semnal de intrare un proces staționar de dimensiune 100 (rezultat în urma liniarizării matricilor caracter  $10 \times 10$ ), cu câte 11 instanțe pentru fiecare literă, dintre care o instanță reprezentând prototipul literei respective.

Curba de eroare Hamming corespunzătoare refacerii literelor în urma efectuării reducerii numărului de componente principale (deci a dimensionalității) de la 100 (numărul total de componente) la 5, cu pasul 13, demonstrează că perturbații puternice survin în cazul semnalului redus după aproximativ 7 pași, adică atunci când din cele 100 componente sunt selectate mai puțin de 15 componente principale.

Rezultatele obținute prin aplicarea algoritmului RLS în cazul semnalelor binare devin și mai interesante în momentul comparării lor cu rezultate similare ale aplicării unei metode standard de extragere de caracteristici, și anume metoda Karhunen-Loeve; se remarcă astfel că erorile apărute la refacere

prin compactarea cu RLS rămân acceptabile după o reducere foarte drastică, în timp ce, în cazul compactării cu Karhunen-Loeve, deși la o reducere mică erorile sunt nesemnificative, în cazul unei selecții foarte mici de caracteristici, erorile sunt mult mai mari decât cele date de RSL.

Pentru exemplificare este prezentată în figurile 1 și 2 refacerea unui set de caractere (selecție asupra literei *a*) în urma reducerii dimensionalității prin metodele RLS și Karhunen Loeve, în paralel cu prezentarea curbei de eroare Hamming pentru prototipurile pentru fiecare caz în parte.

Testele efectuate în cazul unor imagini cu 256 nivele de gri de la alb la negru au demonstrat de asemenea posibilitățile mari de reducere pe care le oferă acest algoritm și în special stabilitatea la erorile survenite în determinarea efectivă a componentelor principale în cazul unor intrări foarte mari. Datorită dimensiunilor foarte mari ale unei imagini liniarizate, modul de implementare diferă de cel al extragerii caracteristicilor pentru caractere; astfel, imaginea nu este tratată în întregime la o implementare, ci linie cu linie, acest lucru neafectând, după cum se va vedea, rezultatul refacerii.

În continuare (figurile 3 și 4) sunt prezentate două exemple, pentru fiecare menționându-se doar prototipul intrării și rezultatul refacerii în urma extragerii primelor 3 caracteristici principale (din totalul de 320) pentru 8 instanțe în cazul primului exemplu, respectiv primelor 25 caracteristici principale (din același total) pentru 35 de instanțe în cazul celui de-al doilea exemplu.



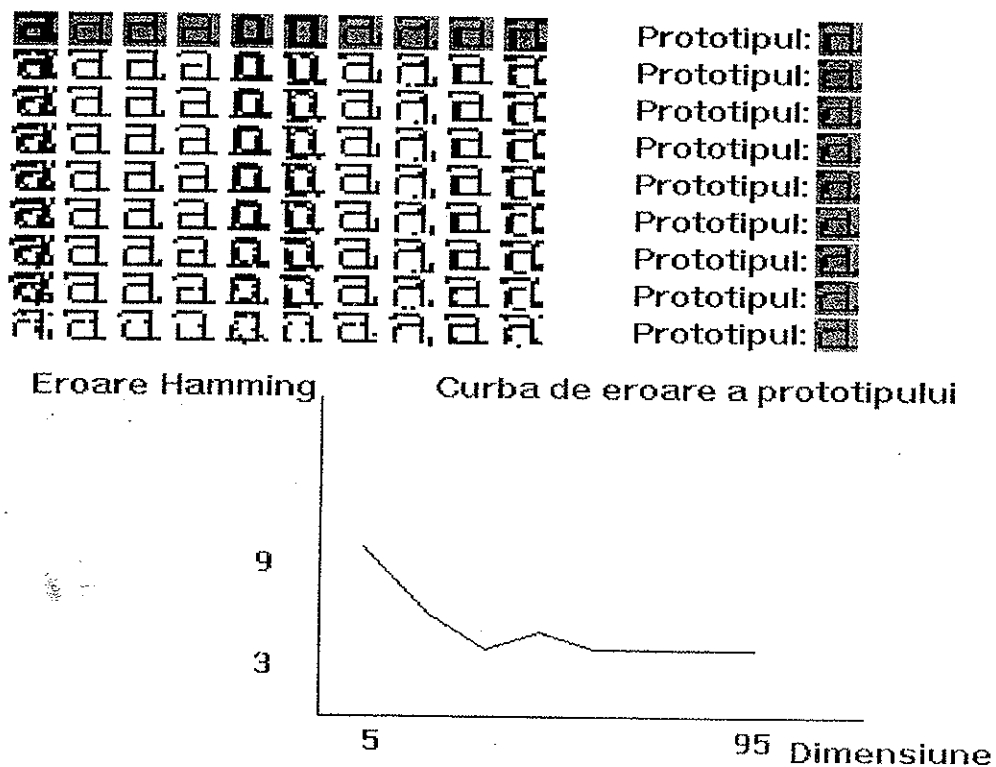


Fig. 1. Reducere Karhunen-Loeve





Fig. 2. Reducere RLS

Prototipul intrării



Ieșirea





Fig. 3. Reducere de la 320 la 3 caracteristici principale (8 instanțe ale intrării)

Prototipul intrării



Ieșirea



Fig. 4. Reducere de la 320 la 35 de caracteristici principale (35 instanțe ale intrării)

**Bibliografie**

[1] Diamantaras K.I. "*Principal Component Neural networks: Theory and Applications*", John Wiley&Sons, Inc. 1996

[2] Deco G., Obradovic D. "*An Information-Theoretic Approach to neural Computing*", Springer Verlag, 1996

[3] Cover T.M., Thomas J.A. "*Elements of Information Theory*", John Wiley&Sons, Inc, 1991

[4] State L. "*Analiza în componente principale pentru compresia/restaurarea datelor*", Informatica Economica, nr.2/1997

[5] Gonzales Rafael, Woods Richard "*Digital Image Processing*", Addison-Wesley, 1993

[6] Pitas Ioannis "*Digital Image Processing*", Prentice Hall, 1993