

Sisteme de Recunoaștere a Formelor – Lab 12

Analiza Discriminanților Liniari (Linear Discriminant Analysis)

1. Obiective

În această lucrare de laborator se va studia metoda de clasificare bazată pe analiza discriminanților liniari (Linear Discriminant Analysis – LDA). Metoda va fi implementată pentru cazul în care spațiul trăsăturilor este bidimensional, și avem două clase. Exemplele de clasificat sunt o mulțime de puncte 2D, iar trăsăturile sunt coordonatele lor, cea verticală și cea orizontală. Se cunoaște că aceste puncte aparțin de două clase, și se știe pentru fiecare punct clasa din care face parte.

2. Fundamente teoretice


Scopul analizei discriminanților este de a clasifica obiecte (oameni, clienți, produse, etc) în două sau mai multe grupuri pe baza unei mulțimi de trăsături ce descriu obiectele (ex. sex, vârstă, venit, greutate, etc). În general, vom atașa un obiect la unul din grupurile pre-determinate pe baza observațiilor pe care le facem cu privire la acest obiect.

Dacă presupunem că grupurile sunt separabile liniar, putem folosi modelul discriminantului liniar (LDA). Proprietatea de separabilitate liniară sugerează că grupurile pot fi separate printr-o combinație de trăsături care descriu obiectele. Dacă avem numai două trăsături, separatorii vor deveni drepte. Dacă avem trei trăsături, separatorul devine un plan, iar dacă numărul trăsăturilor este mai mare, separatorul devine un hiperplan.


Obiectivul LDA este de a obține o **reducere a dimensiunilor** păstrând cât mai mult din informația discriminantă. Avem o mulțime de exemple D-dimensionale $\{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$, N_1 aparținând clasei ω_1 , și N_2 clasei ω_2 , și urmărim să obținem un scalar y prin proiecția exemplilor x pe o dreaptă:

$$y = \mathbf{w}^T \mathbf{x}$$

Din toate dreptele posibile, vrem să alegem pe aceea care maximizează separabilitatea scalarilor. Acest lucru este ilustrat, pentru cazul bi-dimensional, de următoarele figuri:



Separabilitate slabă



Separabilitate bună

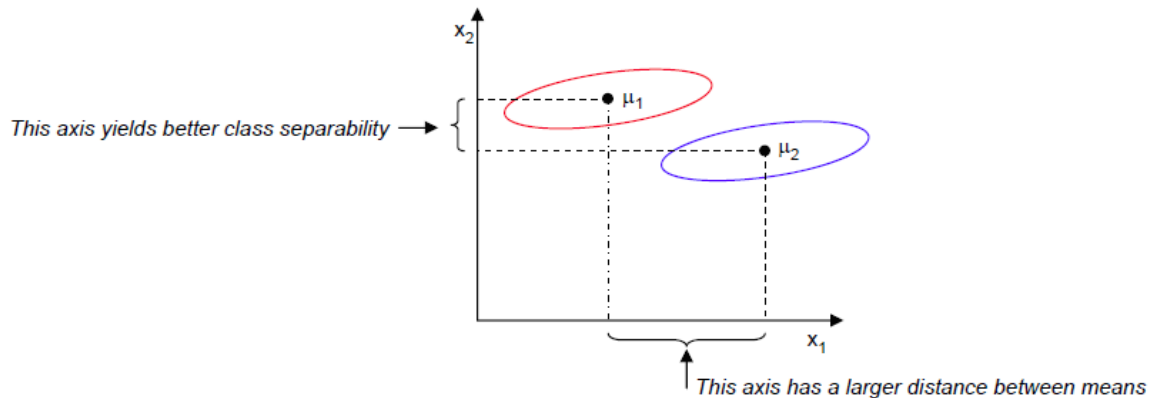
Pentru a putea găsi un vector de proiecție bun, trebuie să definim o măsură a separabilității proiecțiilor. Vectorul mediu pentru fiecare clasă în spațiul trăsăturilor \mathbf{x} și \mathbf{y} este:

$$\mu_i = \frac{1}{N_i} \sum_{\mathbf{x} \in \omega_i} \mathbf{x} \quad \text{and} \quad \tilde{\mu}_i = \frac{1}{N_i} \sum_{y \in \omega_i} y = \frac{1}{N_i} \sum_{\mathbf{x} \in \omega_i} \mathbf{w}^T \mathbf{x} = \mathbf{w}^T \mu_i$$

Am putea alege distanța dintre mediile proiectate ca fiind funcția noastră obiectiv:

$$J(\mathbf{w}) = |\tilde{\mu}_1 - \tilde{\mu}_2| = |\mathbf{w}^T (\mu_1 - \mu_2)|$$

Din păcate, distanța dintre mediile proiectate nu este o măsură bună, deoarece nu ia în considerare deviația standard intra-clasă. Figura următoare descrie problema:



Soluția propusă de Fisher este de a maximiza o funcție ce reprezintă diferența dintre medii (centre), normalizată de o măsură a variației intra-clasă. Pentru fiecare clasă vom defini gradul de difuzie, un echivalent al varianței, ca


$$\tilde{s}_i^2 = \sum_{y \in \omega_i} (y - \tilde{\mu}_i)^2$$

iar cantitatea $(\tilde{s}_1^2 + \tilde{s}_2^2)$ va fi numită difuzia exemplilor proiectate.

Discriminantul linear Fisher este definit ca funcția liniară $\mathbf{w}^T \mathbf{x}$ care maximizează funcția criteriu:

$$J(w) = \frac{|\tilde{\mu}_1 - \tilde{\mu}_2|^2}{\tilde{S}_1^2 + \tilde{S}_2^2}$$

Astfel, vom căuta o proiecție unde exemplele din aceeași clasă vor fi proiectate cât mai aproape unul de celălalt, iar în același timp centrele proiectate sunt cât mai depărtate posibil.



Pentru a găsi proiecția optimă w^* , trebuie să scriem $J(w)$ ca o funcție explicită de w . Vom defini o măsură a difuziei în spațiul multivariat al trăsăturilor x , matricile de difuzie:

$$S_i = \frac{1}{N_i} \sum_{x \in \omega_i} (x - \mu_i)(x - \mu_i)^T$$

$$S_1 + S_2 = S_W$$

Unde S_W este **matricea de difuzie intra-clasă**.

Difuzia proiecției y poate fi scrisă în funcție de matricea de difuzie în spațiul x :

$$\begin{aligned} \tilde{S}_i^2 &= \frac{1}{N_i} \sum_{y \in \omega_i} (y - \tilde{\mu}_i)^2 = \frac{1}{N_i} \sum_{x \in \omega_i} (w^T x - w^T \mu_i)^2 = \frac{1}{N_i} \sum_{x \in \omega_i} w^T (x - \mu_i)(x - \mu_i)^T w = w^T S_i w \\ \tilde{S}_1^2 + \tilde{S}_2^2 &= w^T S_W w \end{aligned}$$

În mod similar, diferența dintre centrele proiectate poate fi scrisă în funcție de centrele din spațiul original al trăsăturilor:

$$(\tilde{\mu}_1 - \tilde{\mu}_2)^2 = (w^T \mu_1 - w^T \mu_2)^2 = w^T \underbrace{(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T}_{S_B} w = w^T S_B w$$

Matricea S_B este numită **matricea de difuzie între clase**. Deoarece S_B este un produs exterior a doi vectori, rangul ei este maxim 1.

În sfârșit, putem exprima criteriul Fisher în funcție de S_W și S_B ca

$$J(w) = \frac{w^T S_B w}{w^T S_W w}$$

Pentru a găsi maximul lui $J(w)$ vom căuta valorile nule ale derivatei.

$$\begin{aligned} \frac{d}{dw} [J(w)] &= \frac{d}{dw} \left[\frac{w^T S_B w}{w^T S_W w} \right] = 0 \Rightarrow \\ \Rightarrow [w^T S_W w] \frac{d[w^T S_B w]}{dw} - [w^T S_B w] \frac{d[w^T S_W w]}{dw} &= 0 \Rightarrow \\ \Rightarrow [w^T S_W w] 2S_B w - [w^T S_B w] 2S_W w &= 0 \end{aligned}$$

Împărțind cu $w^T S_W w$:

$$\begin{aligned} \frac{[w^T S_W w]}{[w^T S_W w]} S_B w - \frac{[w^T S_B w]}{[w^T S_W w]} S_W w &= 0 \Rightarrow \\ \Rightarrow S_B w - J S_W w &= 0 \Rightarrow \\ \Rightarrow S_W^{-1} S_B w - J w &= 0 \end{aligned}$$

Rezolvând problema generalizată a valorilor proprii ($S_W^{-1} S_B w = J w$) se obține:

$$w^* = \underset{w}{\operatorname{argmax}} \left\{ \frac{w^T S_B w}{w^T S_W w} \right\} = S_W^{-1} (\mu_1 - \mu_2)$$


Limitările LDA:

- **LDA produce cel mult C-1 proiecții (C este numărul claselor)**


- Dacă eroarea de clasificare stabilește că e nevoie de mai multe trăsături, alte metode trebuie folosite pentru a oferi aceste trăsături;

- **LDA este o metodă parametrică, deoarece presupune verosimilități Gaussiene unimodale.**

- Dacă distribuțiile sunt mult diferite de modelul Gaussian, proiecțiile LDA nu vor fi capabile să mențină structura complexă a datelor, necesară pentru clasificare.



- **LDA va eșua dacă informația discriminantă nu este în medie, ci în varianța datelor.**




3. Exemplu numeric

Să se calculeze proiecția discriminant linear pentru următorul set de date bidimensional.

$$X_1=(x_1,x_2)=\{(4,1),(2,4),(2,3),(3,6),(4,4)\}$$

$$X_2=(x_1,x_2)=\{(9,10),(6,8),(9,5),(8,7),(10,8)\}$$



Statisticile claselor sunt:

$$S_1 = \begin{bmatrix} 0.80 & -0.40 \\ -0.40 & 2.60 \end{bmatrix}; S_2 = \begin{bmatrix} 1.84 & -0.04 \\ -0.04 & 2.64 \end{bmatrix}$$

$$\mu_1^T = [3.00 \quad 3.60]; \quad \mu_2^T = [8.40 \quad 7.60]$$

Difuziile intra-clasă și între clase sunt:

$$S_B = \begin{bmatrix} 29.16 & 21.60 \\ 21.60 & 16.00 \end{bmatrix}; S_W = \begin{bmatrix} 2.64 & -0.44 \\ -0.44 & 5.28 \end{bmatrix}$$

Proiecția LDA este obținută ca o soluție la problema generalizată a valorilor proprii:

$$S_W^{-1} S_B v = \lambda v \Rightarrow |S_W^{-1} S_B - \lambda I| = 0 \Rightarrow \begin{vmatrix} 11.89 - \lambda & 8.81 \\ 5.08 & 3.76 - \lambda \end{vmatrix} = 0 \Rightarrow \lambda = 15.65$$

$$\begin{bmatrix} 11.89 & 8.81 \\ 5.08 & 3.76 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} = 15.65 \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} \Rightarrow \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} = \begin{bmatrix} 0.91 \\ 0.39 \end{bmatrix}$$

Sau direct ca

$$w^* = S_W^{-1}(\mu_1 - \mu_2) = [-0.91 \quad -0.39]^T$$

4. Exerciții

Se dă o imagine (8 bit/pixel) conținând o mulțime de puncte 2D ce aparțin de două clase, roșu și albastru. Paleta imaginii este modificată în așa fel încât pe poziția 1 avem culoarea roșie, iar pe poziția 2 avem culoarea albastră.

Aplicați algoritmul LDA (soluția Fisher) pentru a găsi vectorul proiecției liniare care maximizează separabilitatea scalarilor (trăsăturile proiectate). Desenați dreapta care este definită de componentele vectorului de proiecție.

Note și detalii de implementare (în DIBLook):

- Dacă vectorul de proiecție este $w^* = [w_{x1}, w_{x2}]^T$ unde x_1 și x_2 sunt coordonatele punctelor 2D, atunci ecuația dreptei care definește această proiecție, în spațiul trăsăturilor, este $x_2 = (w_{x2}/w_{x1}) * x_1$. Această dreaptă trece prin originea imaginii (0, 0) și are panta w_{x2}/w_{x1} .

- Dacă $w_{x2}/w_{x1} < 0$ atunci dreapta este situată în al doilea cadran trigonometric, și dacă ea trece prin origine nu se poate desena pe imagine. În acest caz se poate considera o dreaptă care trece nu prin origine, ci prin (dwWidth-1, 0). Ecuația dreptei devine $x_2 = (w_{x2}/w_{x1}) * (x_1 - dwWidth + 1)$. O soluție care merge în ambele cazuri este să se deseneze o dreaptă ce trece prin centrul imaginii, cu ecuația $x_2 = (w_{x2}/w_{x1}) * (x_1 - dwWidth/2) + dwHeight/2$.

- În ecuațiile de mai sus considerăm x_1 pe axa orizontală, și x_2 pe axa verticală.

5. Bibliografie

- [1] Ricardo Gutierrez-Osuna, *Introduction to Pattern Analysis*, Texas A&M University.
- [2] Kardi Teknomo, *Linear Discriminant Analysis – tutorial*, <http://people.revoledu.com/kardi/tutorial/LDA/LDA.html>