

Στόχος της αναγνώρισης προτύπων

ομαδοποίηση προτύπων
με κοινά χαρακτηριστικά



μετά από εντοπισμό συγκεντρώσεων
προτύπων που δημιουργούνται στο
χώρο των προτύπων

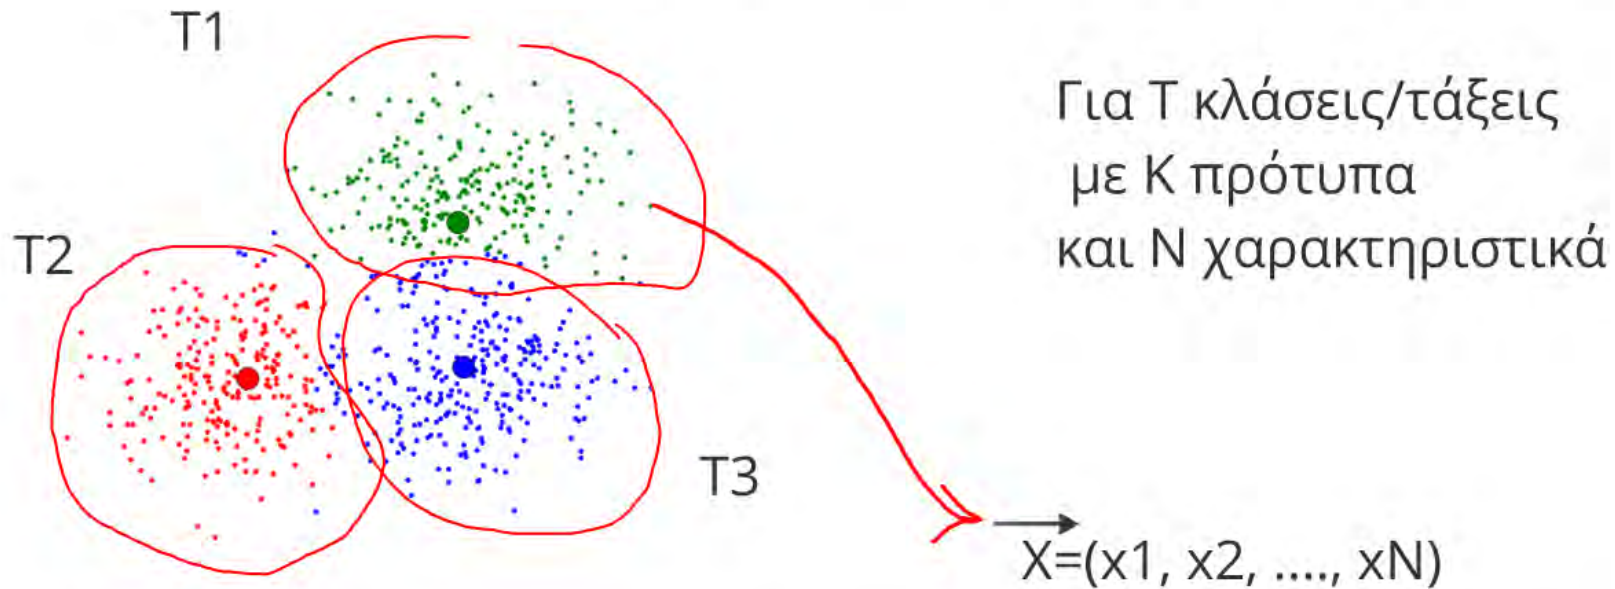
```
graph LR; A["Συγκέντρωση μετρήσεων  
Εξαγωγή χαρακτηριστικών  
Feature extraction/selection"] --> B["Εύρεση συγκεντρώσεων στο  
χώρο των προτύπων  
Ομαδοποίηση και ονομασί  
Clustering & Labeling"]
```

Συγκέντρωση μετρήσεων
Εξαγωγή χαρακτηριστικών
Feature extraction/selection



Εύρεση συγκεντρώσεων στο
χώρο των προτύπων
Ομαδοποίηση και ονομασί
Clustering & Labeling

Στη γενική περίπτωση



Κάθε Πρότυπο χαρακτηρίζεται από ένα διάνυσμα N διαστάσεων και μπορεί να αναπαρίσταται από ένα πίνακα-στήλη $N \times 1$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_N \end{bmatrix}$$

Κάθε χαρακτηριστικό (v) ενός προτύπου (k) μιας κλάσης (τ) συμβολίζεται:

$$x_{vK}^{\tau}$$

Ορισμοί στους πίνακες

Ανάστροφος πίνακας

$$A_{i,j}^T = A_{j,i}$$

Παράδειγμα:

$$A = \begin{bmatrix} 1 & 3 \\ 2 & 4 \\ 5 & 6 \end{bmatrix} \longrightarrow A^T = \begin{bmatrix} 1 & 2 & 5 \\ 3 & 4 & 6 \end{bmatrix}$$

Ορισμοί στους πίνακες

Πολλαπλασιασμός πινάκων $\left[\Gamma_{\nu\chi\mu} = \sum_{\kappa=1}^{\kappa} A_{\nu\chi\kappa} B_{\kappa\chi\mu} \right]$

Παράδειγμα:

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 2 & 1 & 3 \end{bmatrix} \quad B = \begin{bmatrix} 2 & 1 \\ 3 & 2 \\ 1 & 2 \end{bmatrix}$$

$$\Gamma = \begin{bmatrix} 1 \times 2 + 2 \times 3 + 3 \times 1 & 1 \times 1 + 2 \times 2 + 3 \times 2 \\ 2 \times 2 + 1 \times 3 + 3 \times 1 & 2 \times 1 + 1 \times 2 + 3 \times 2 \end{bmatrix} = \begin{bmatrix} 11 & 11 \\ 10 & 10 \end{bmatrix}$$

Ευκλείδεια απόσταση με πίνακες

Με βάση τον ορισμό του προλλαπλασιασμού πινάκων

Για δύο διανύσματα, η ευκλείδεια απόσταση ορίζεται

$$d(\vec{x}, \vec{y}) = \left[\sum_{v=1}^N (x_v - y_v)^2 \right]^{1/2}$$

Αναπτύσσοντας το άθροισμα έχουμε:

$$\begin{aligned} d(x, y) &= \left[(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_N - y_N)^2 \right]^{1/2} = \\ &= \left[(x_1 - y_1)(x_1 - y_1) + (x_2 - y_2)(x_2 - y_2) + \dots + (x_N - y_N)(x_N - y_N) \right]^{1/2} = \\ &= \left[(x - y)^T (x - y) \right]^{1/2} \end{aligned}$$

Ευκλείδεια απόσταση με πίνακες

Έστω $\left[\begin{array}{l} \vec{x}=(x_1, x_2) \quad \text{και} \quad \vec{y}=(y_1, y_2) \end{array} \right]$


σε χώρο δύο διαστάσεων, $N=2$

$$d(x,y) = \left[(x_1 - y_1)^2 + (x_2 - y_2)^2 \right]^{1/2} = \left[(x_1 - y_1)(x_1 - y_1) + (x_2 - y_2)(x_2 - y_2) \right]^{1/2}$$

Εάν $\vec{z} = \vec{x} - \vec{y} = \begin{bmatrix} x_1 - y_1 \\ x_2 - y_2 \end{bmatrix}$

τότε $\mathbf{z}^T \mathbf{z} = \begin{bmatrix} x_1 - y_1 & x_2 - y_2 \end{bmatrix} \begin{bmatrix} x_1 - y_1 \\ x_2 - y_2 \end{bmatrix}$

$$= (x_1 - y_1)(x_1 - y_1) + (x_2 - y_2)(x_2 - y_2)$$
$$= (x_1 - y_1)^2 + (x_2 - y_2)^2$$


$$d(x,y) = \left[\mathbf{z}^T \mathbf{z} \right]^{1/2} = \left[(\mathbf{x} - \mathbf{y})^T (\mathbf{x} - \mathbf{y}) \right]^{1/2}$$

Εσωτερικό γινόμενο

Το εσωτερικό γινόμενο δύο διανυσμάτων \vec{x}, \vec{y} που περιγράφουν αντίστοιχα δύο πρότυπα Π_x, Π_y ορίζεται ως:

$$\vec{x} \vec{y} = x_1 y_1 + x_2 y_2 + \dots + x_N y_N = \sum_{v=1}^N x_v y_v$$

Από τον πολλαπλασιασμό πινάκων είναι γνωστό ότι:

$$\mathbf{x}^T \mathbf{y} = \sum_{v=1}^N x_v y_v$$

Έτσι: $\vec{x} \vec{y} = \mathbf{x}^T \mathbf{y}$

Εσωτερικό γινόμενο

- Τα σημεία A, B στο χώρο των δύο διαστάσεων αναπαρίστανται με μορφή διανυσμάτων x, y
- Έτσι, από συντεταγμένες τώρα για την περιγραφή τους χρειάζεται μέτρο και γωνία



Είναι:

$$\vec{x}: |\vec{x}| = \sqrt{x_1^2 + x_2^2}^{1/2}, \tan\theta_x = \frac{x_2}{x_1}$$

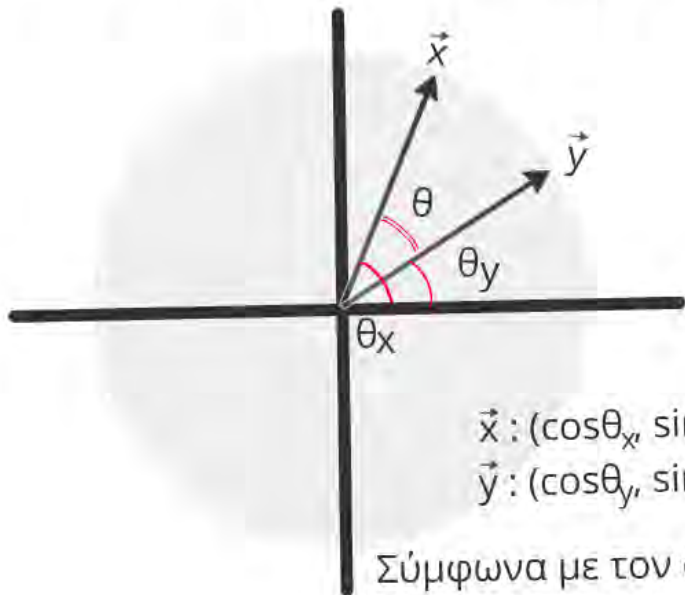
$$\vec{y}: |\vec{y}| = \sqrt{y_1^2 + y_2^2}^{1/2}, \tan\theta_y = \frac{y_2}{y_1}$$

Μπορούμε να επιτύχουμε κανονικοποίηση του εσωτερικού γινομένου των διανυσμάτων διαιρώντας με το γινόμενο των μέτρων τους:

$$\frac{\vec{x} \cdot \vec{y}}{|\vec{x}| \cdot |\vec{y}|} = \cos\theta$$

(ο λόγος αντιστοιχεί στο συνημίτονο της γωνίας μεταξύ των διανυσμάτων)

Εσωτερικό γινόμενο και συνημίτονο



$$\vec{x} : (\cos\theta_x, \sin\theta_x)$$

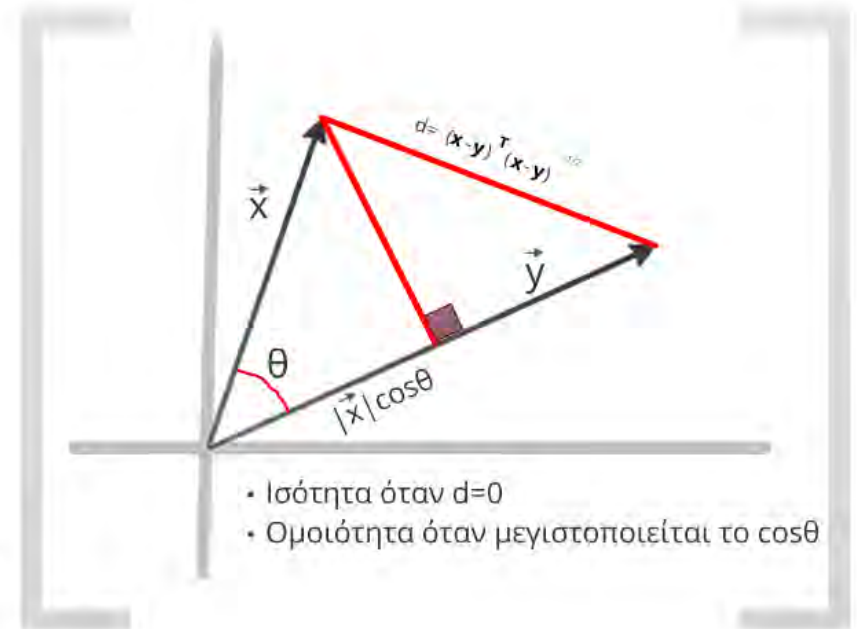
$$\vec{y} : (\cos\theta_y, \sin\theta_y)$$

Σύμφωνα με τον ορισμό του εσωτερικού γινομένου διανυσμάτων

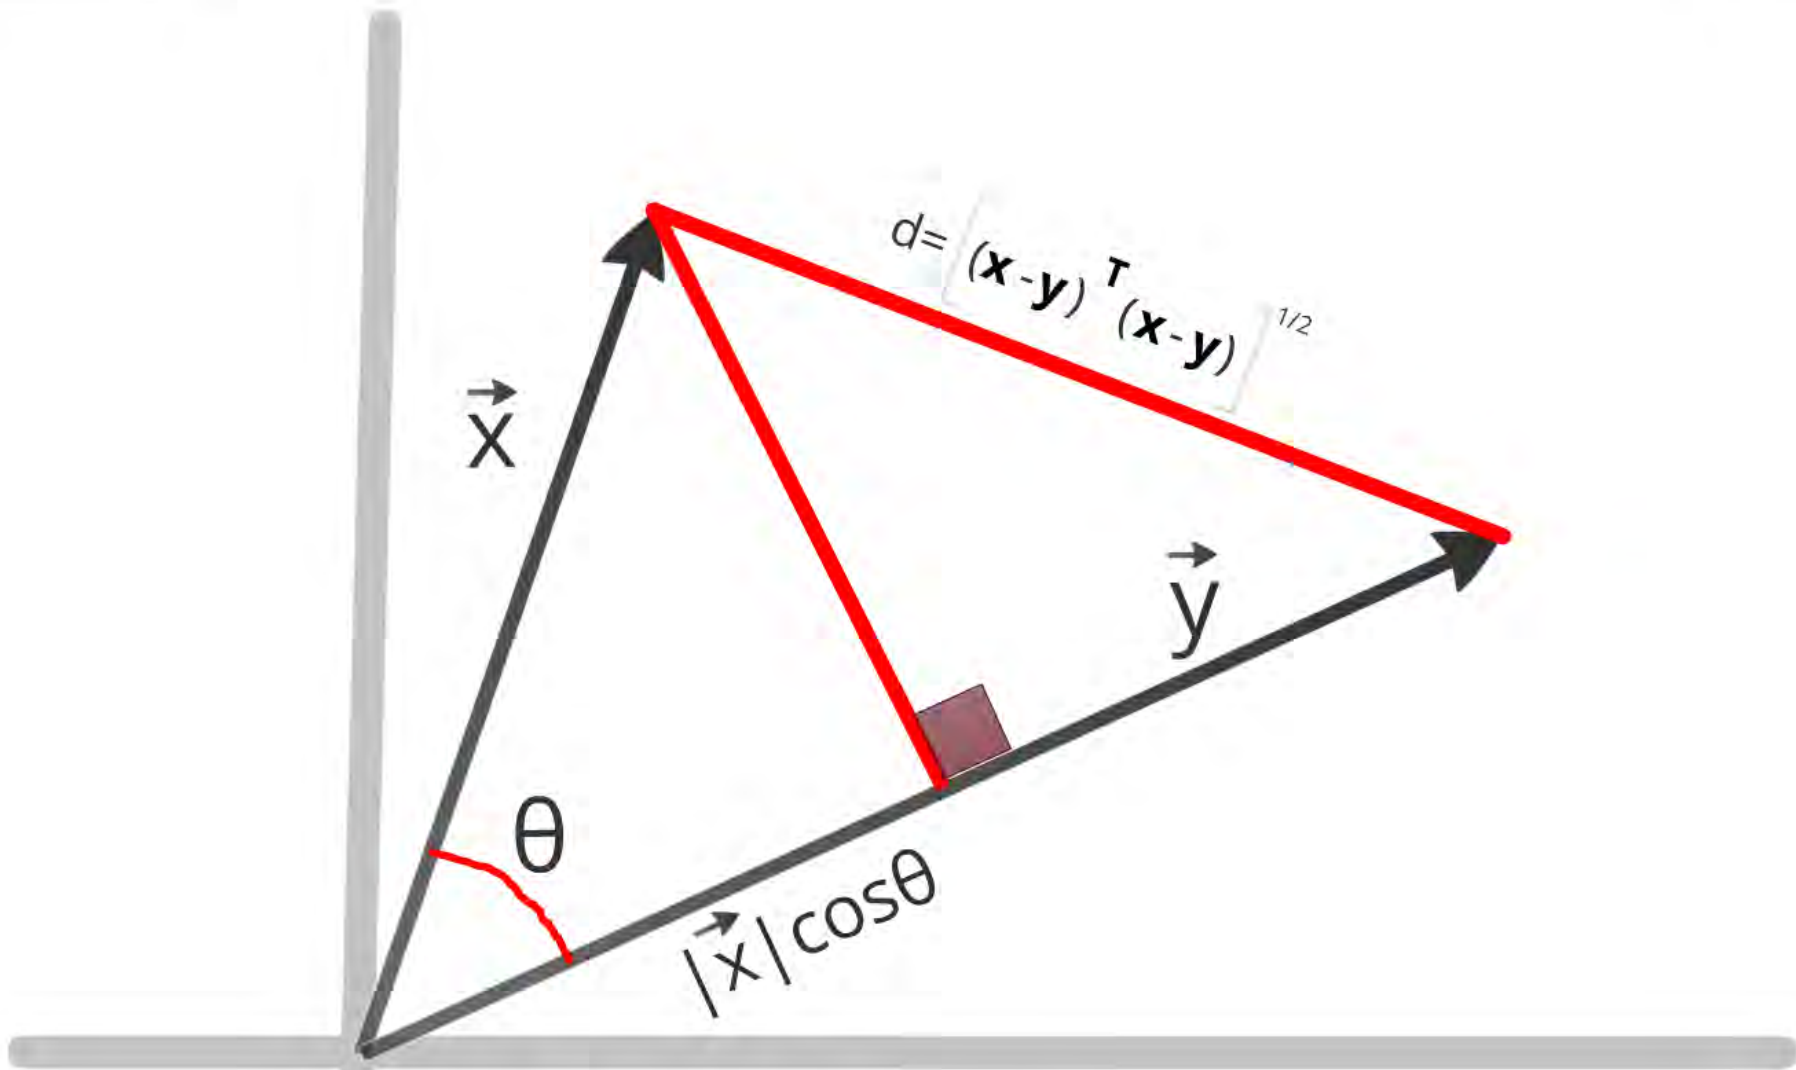
$$\mathbf{x} \cdot \mathbf{y} = \mathbf{x}^T \mathbf{y} = \begin{bmatrix} \cos\theta_x & \sin\theta_x \end{bmatrix} \begin{bmatrix} \cos\theta_y \\ \sin\theta_y \end{bmatrix} =$$

$$= \cos\theta_x \cos\theta_y + \sin\theta_x \sin\theta_y =$$

$$= \cos(\theta_x - \theta_y) = \cos\theta$$



- Ισότητα όταν $d=0$
- Ομοιότητα όταν μεγιστοποιείται το $\cos\theta$



- Ισότητα όταν $d=0$
- Ομοιότητα όταν μεγιστοποιείται το $\cos \theta$

Στατιστικά του χώρου των προτύπων

Έστω K πρότυπα που περιγράφονται σε N -διαστάσεις

$$X_1 = \begin{bmatrix} X_{11} \\ X_{21} \\ \dots \\ X_{N1} \end{bmatrix} \quad X_2 = \begin{bmatrix} X_{12} \\ X_{22} \\ \dots \\ X_{N2} \end{bmatrix} \quad \dots \quad X_K = \begin{bmatrix} X_{1K} \\ X_{2K} \\ \dots \\ X_{NK} \end{bmatrix}$$

Η μέση τιμή των προτύπων ή "μέσο πρότυπο" ή "αναμενόμενο πρότυπο" ορίζεται ως:

$$\mu = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \dots \\ \mu_N \end{bmatrix}$$

$$\mu \text{ ε } \mu_v = \frac{1}{K} \sum_{k=1}^K X_{vk}$$

τη μέση τιμή το v -οστό χαρακτηριστικό όλων των προτύπων



Παράδειγμα

Έστω τα εξής πρότυπα Π1, Π2, Π3, Π4:

$$\Pi 1 = \begin{bmatrix} 2 \\ 6 \\ 7 \end{bmatrix}$$

$$\Pi 2 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix}$$

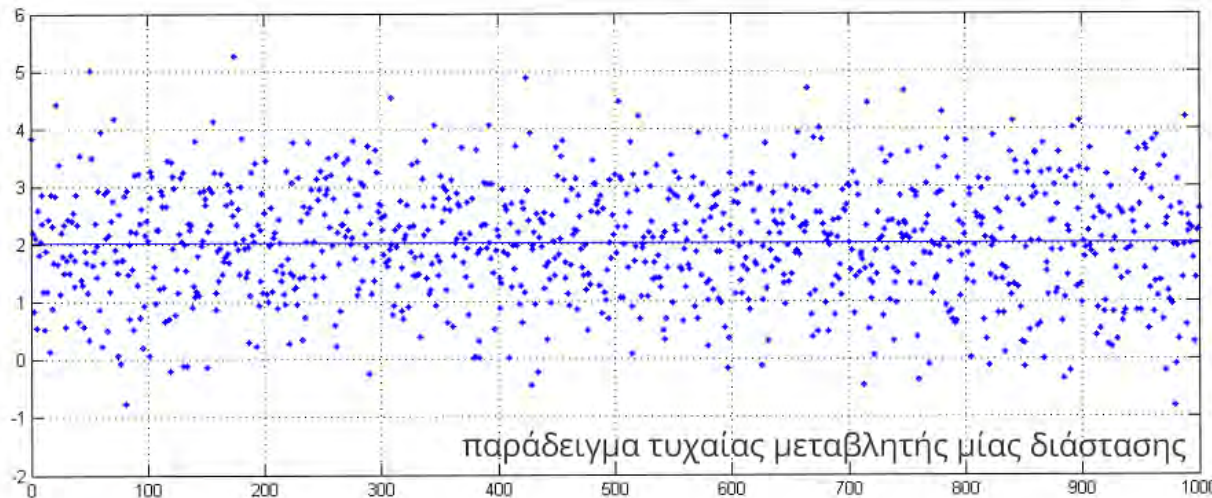
$$\Pi 3 = \begin{bmatrix} 3 \\ 1 \\ 2 \end{bmatrix}$$

$$\Pi 4 = \begin{bmatrix} 2 \\ 2 \\ 2 \end{bmatrix}$$

Η μέση τιμή υπολογίζεται ως εξής:

$$\mu = \begin{bmatrix} 1/4 (2+1+3+2) \\ 1/4 (6+3+1+2) \\ 1/4 (7+5+2+2) \end{bmatrix} = \begin{bmatrix} 2 \\ 3 \\ 4 \end{bmatrix}$$

Στατιστικά του χώρου των προτύπων



↑ διασπορά γύρω από τη μέση τιμή
↓ μέση τιμή

Η μέση τιμή είναι σημαντικό χαρακτηριστικό αλλά όχι αρκετό για τη σαφή κατανόηση μιας κατανομής

Σημαντική πληροφορία προκύπτει από τη μελέτη της διασποράς ή απόκλισης γύρω από τη μέση τιμή

Η απόκλιση αυτό ορίζεται με διάφορους τρόπους

Απόλυτη διασπορά/απόκλιση:

$$\text{Dev}(X) = \frac{1}{K} \sum_k |x_k - \mu|$$

Απόκλιση/διασπορά:

$$\text{Var}(X) = \frac{1}{K} \sum_k (x_k - \mu)^2$$

Τυπική απόκλιση:

$$\text{Std}(X) = \left[\frac{1}{K} \sum_k (x_k - \mu)^2 \right]^{1/2}$$

Αποδεικνύεται ότι: $\text{Std}(X) \geq \text{Dev}(X)$

* Jensen's inequality

Ειδικά για κανονικές κατανομές (Gaussian) υπολογίζεται ότι:

$$\frac{\text{Dev}(X)}{\text{Std}(X)} = \frac{2}{\pi}^{1/2}$$

Αποδεικνύεται ότι: $\text{Std}(X) \geq \text{Dev}(X)$

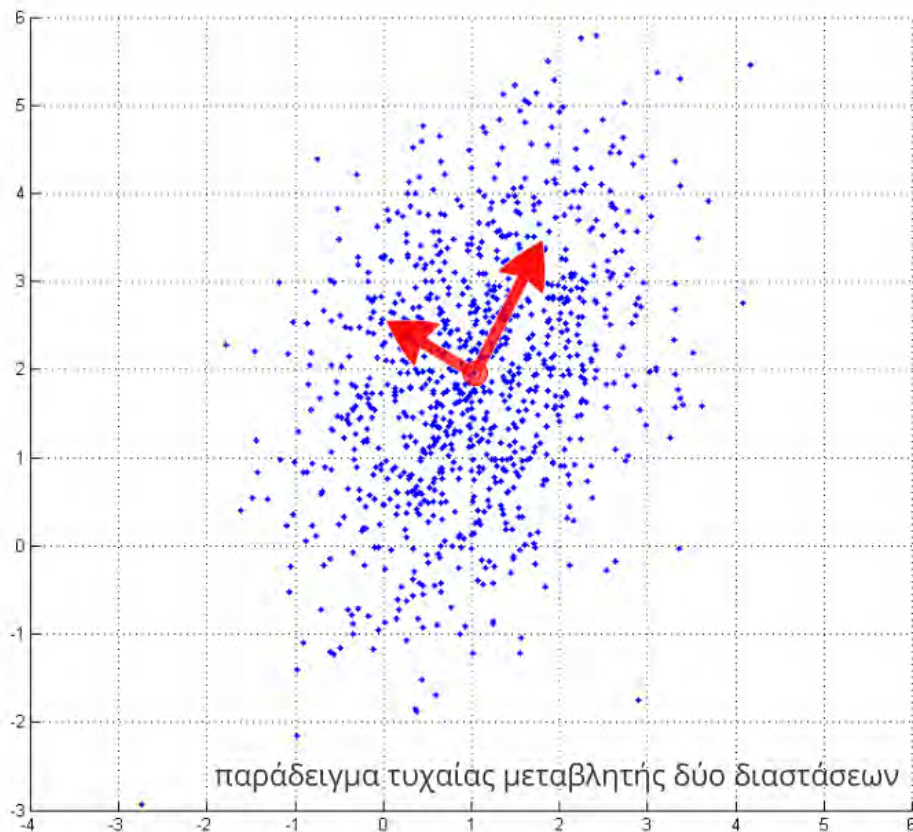
* Jensen's inequality

Ειδικά για κανονικές κατανομές
(Gaussian) υπολογίζεται ότι:

$$\left[\frac{\text{Dev}(X)}{\text{Std}(X)} = \left[\frac{2}{\pi} \right]^{1/2} \right]$$

Διασπορά σε χώρους πολλών διαστάσεων

Γενίκευση της ιδέας της διασποράς σε περισσότερες διαστάσεις οδηγεί στον ορισμό της έννοιας της **συνδιασποράς**



Σε δύο διαστάσεις δεν είναι δυνατό να περιγραφεί η κατανομή με τη διασπορά σε κάθε διάσταση γιατί υπάρχει αλληλεπίδραση

Συνδιασπορά στο χώρο των προτύπων

Εφόσον ο χώρος των προτύπων είναι πολυδιάστατος υιοθετούμε την περιγραφή με τον **Πίνακα Συνδιασποράς**

$$\begin{aligned} \text{Cov} &= \frac{1}{K} \sum_{k=1}^K (x_k - \mu)(x_k - \mu)^T = \frac{1}{K} \sum_{k=1}^K \begin{bmatrix} x_{1k} - \mu_1 \\ x_{2k} - \mu_2 \\ \dots \\ x_{Nk} - \mu_N \end{bmatrix} \begin{bmatrix} (x_{1k} - \mu_1) & (x_{2k} - \mu_2) & \dots & (x_{Nk} - \mu_N) \end{bmatrix} \\ &= \frac{1}{K} \sum_{k=1}^K \begin{bmatrix} (x_{1k} - \mu_1)^2 & (x_{2k} - \mu_2)(x_{1k} - \mu_1) & \dots & (x_{1k} - \mu_1)(x_{Nk} - \mu_N) \\ (x_{2k} - \mu_2)(x_{1k} - \mu_1) & (x_{2k} - \mu_2)^2 & \dots & (x_{2k} - \mu_2)(x_{Nk} - \mu_N) \\ \dots & \dots & \dots & \dots \\ (x_{Nk} - \mu_N)(x_{1k} - \mu_1) & (x_{2k} - \mu_2)(x_{Nk} - \mu_N) & \dots & (x_{Nk} - \mu_N)^2 \end{bmatrix} \\ &= \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_2^2 & \dots & \sigma_{2N} \\ \dots & \dots & \dots & \dots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN}^2 \end{bmatrix} \quad \sigma_{\lambda\nu} = \sigma_{\nu\lambda} = \frac{1}{K} \sum_{k=1}^K (x_{\lambda k} - \mu_\lambda)(x_{\nu k} - \mu_\nu) \end{aligned}$$


- η **συμμεταβλητότητα** ή **συνδιασπορά** των τιμών των χαρακτηριστικών λ, ν των K προτύπων
- για $\lambda = \nu$ (στη διαγώνιο) προκύπτει η **διασπορά** του ν -οστού χαρακτηριστικού των K προτύπων

Ο συντελεστής συσχέτισης δύο χαρακτηριστικών λ, ν ορίζεται από τη σχέση:

$$P_{\lambda\nu} = \frac{\sigma_{\lambda\nu}}{\sigma_\lambda \cdot \sigma_\nu}$$

$$\sigma_\nu = \sigma_\nu^2^{1/2}$$

η τυπική απόκλιση του ν -οστού χαρακτηριστικού



ρη με τον πίνακα συνδιασπορας

$$\text{Cov} = \frac{1}{K} \sum_{k=1}^K (x_k - \mu)(x_k - \mu)^T = \frac{1}{K} \sum_{k=1}^K \begin{bmatrix} x_{1k} - \mu_1 \\ x_{2k} - \mu_2 \\ \dots \\ x_{Nk} - \mu_N \end{bmatrix} \begin{bmatrix} (x_{1k} - \mu_1) & (x_{2k} - \mu_2) & \dots & (x_{Nk} - \mu_N) \end{bmatrix}$$

$$= \frac{1}{K} \sum_{k=1}^K \begin{bmatrix} (x_{1k} - \mu_1)^2 & (x_{2k} - \mu_2)(x_{1k} - \mu_1) & \dots & (x_{1k} - \mu_1)(x_{Nk} - \mu_N) \\ (x_{2k} - \mu_2)(x_{1k} - \mu_1) & (x_{2k} - \mu_2)^2 & \dots & (x_{2k} - \mu_2)(x_{Nk} - \mu_N) \\ \dots & \dots & \dots & \dots \\ (x_{Nk} - \mu_N)(x_{1k} - \mu_1) & (x_{2k} - \mu_2)(x_{Nk} - \mu_N) & \dots & (x_{Nk} - \mu_N)^2 \end{bmatrix}$$

$$= \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_2^2 & \dots & \sigma_{2N} \\ \dots & \dots & \dots & \dots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN}^2 \end{bmatrix}$$

$$\sigma_{\lambda\nu} = \sigma_{\nu\lambda} = \frac{1}{K} \sum_{k=1}^K (x_{\lambda k} - \mu_\lambda)(x_{\nu k} - \mu_\nu)$$

- η **συμμεταβλητότητα** ή **συνδιασπορά** των τιμών των χαρακτηριστικών λ, ν των K προτύπων
- για $\lambda=\nu$ (στη διαγώνιο) προκύπτει η **διασπορά** του ν -οστού χαρακτηριστικού των K προτύπων

τισης δύο χαρακτηριστικών

σ_{N1} σ_{N2}

.....

 σ_{NN}^2

Ο συντελεστής συσχέτισης δύο χαρακτηριστικών λ, ν ορίζεται από τη σχέση:

$$\sigma_\nu = \left[\sigma_\nu^2 \right]^{1/2}$$

η τυπική απόκλιση του ν -οστού χαρακτηριστικού

$$P_{\lambda\nu} = \frac{\sigma_{\lambda\nu}}{\sigma_\lambda \cdot \sigma_\nu}$$

Παράδειγμα υπολογισμού πίνακα συνδιασποράς.
 Έστω τα τέσσερα διανύσματα τριών διαστάσεων:

$$x_1 = [2 \ 1 \ -1]^T, \quad x_2 = [1 \ 3 \ -1]^T, \quad x_3 = [-2 \ 1 \ 0]^T, \quad x_4 = [-3 \ -2 \ 1]^T$$

$$\mu = \frac{1}{4} \begin{bmatrix} 2+1-2-3 \\ 1+3+1-2 \\ -1-1+0+1 \end{bmatrix} = \begin{bmatrix} -1/2 \\ 3/4 \\ -1/4 \end{bmatrix}$$

$$\sigma_{\lambda\nu} = \frac{1}{K} \sum_{\kappa=1}^K (x_{\lambda\kappa} - \mu_\lambda)(x_{\nu\kappa} - \mu_\nu)$$

$$\sigma_{12} = \frac{1}{K} \sum_{\kappa=1}^K (x_{1\kappa} - \mu_1)(x_{2\kappa} - \mu_2)$$

$$= \frac{1}{4} \left[\left(2 - \frac{-1}{2}\right) \left(1 - \frac{3}{4}\right) + \left(1 - \frac{-1}{2}\right) \left(3 - \frac{3}{4}\right) + \left(-2 - \frac{-1}{2}\right) \left(1 - \frac{3}{4}\right) + \left(-3 - \frac{-1}{2}\right) \left(-2 - \frac{3}{4}\right) \right]$$

$$= \frac{1}{4} \left[\frac{51}{24} + \frac{39}{24} - \frac{31}{24} + \frac{511}{24} \right] = 2.625$$

$$\sigma_{13} = \dots = 0.6875$$

$$\sigma_{23} = \dots = -1.3125$$

$$\sigma_\lambda^2 = \frac{1}{K} \sum_{\kappa=1}^K (x_{\lambda\kappa} - \mu_\lambda)^2$$

$$\sigma_1^2 = \frac{1}{K} \left[\left(2 - \frac{-1}{2}\right)^2 + \left(1 - \frac{-1}{2}\right)^2 + \left(-2 - \frac{-1}{2}\right)^2 + \left(-3 - \frac{-1}{2}\right)^2 \right] = 4.25$$

$$\sigma_2^2 = \dots = 3.1875$$

$$\sigma_3^2 = \dots = 0.6875$$

$$C = \begin{bmatrix} 4.25 & 2.625 & -1.625 \\ 2.625 & 3.1875 & -1.3125 \\ -1.625 & -1.3125 & 0.6875 \end{bmatrix}$$


Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με βάση τα κέντρα των κλάσεων


- Κατά την εκμάθηση: υπολογισμός μέσης τιμής κάθε κλάσης
- Κατά την ταξινόμηση: ταξινόμηση κάθε νέου προτύπου στην κλάση από της οποίας το κέντρο απέχει λιγότερο

$$\mathbf{x} \longrightarrow \min_t \left[d(\mathbf{x}, \mu^t) \right]$$

με T το πλήθος των κλάσεων και μ^t τα κέντρα τους




Η μέθοδος είναι **αποδοτική** όταν οι κλάσεις έχουν μορφή υπερσφαιρών με ακτίνες μικρότερες της ημιαπόστασης των κέντρων τους



x \longrightarrow $T2$

ορθώς ταξινομείται στην κλάση $T2$



$x \longrightarrow T1$

λανθασμένα ταξινομείται στην κλάση T1

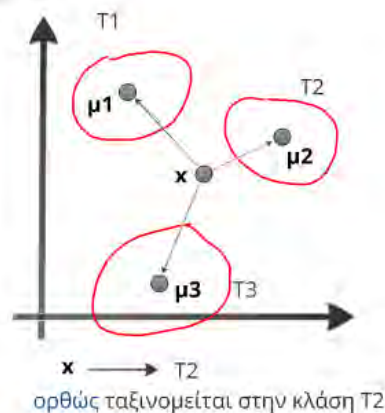
Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με βάση τα κέντρα των κλάσεων

- Κατά την εκμάθηση: υπολογισμός μέσης τιμής κάθε κλάσης
- Κατά την ταξινόμηση: ταξινόμηση κάθε νέου προτύπου στην κλάση από της οποίας το κέντρο απέχει λιγότερο

$$\mathbf{x} \longrightarrow \min_t [d(\mathbf{x}, \mu^t)]$$

με T το πλήθος των κλάσεων και μ^t τα κέντρα τους



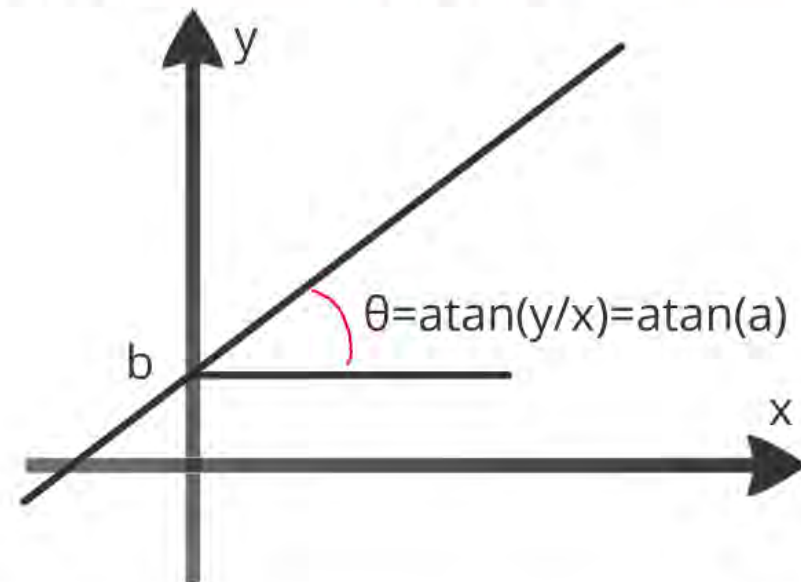
Η μέθοδος είναι **αποδοτική** όταν οι κλάσεις έχουν μορφή υπερσφαιρών με ακτίνες μικρότερες της ημιαπόστασης των κέντρων τους

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

Η γενική εξίσωση της ευθείας είναι γνωστή ως:
με γραφική παράσταση την εξής:

$$y = a x + b$$



Μετασχηματίζουμε την εξίσωση ως εξής:

$$y = ax + b \Rightarrow ax + b - y = 0 \quad \text{ή} \quad ax - y + b = 0$$

πολλαπλασιάζοντας επί έναν πραγματικό
αριθμό w_2 , προκύπτει:

$$w_1 x + w_2 y + w_3 = 0$$

με $w_1 = a$, w_2 και $w_3 = b w_2$

Στην περίπτωση μας, όταν διάνυσμα
αναπαρίσταται ως: $\vec{x} (x_1, x_2)$
τότε η εξίσωση της ευθείας που περνά
από το πέρας του είναι:

$$w_1 x_1 + w_2 x_2 + w_3 = 0 \quad \text{ή} \quad d(\mathbf{x}) = 0$$

όπου $d(\mathbf{x}) = w_1 x_1 + w_2 x_2 + w_3$ και $\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$

Μετασχηματίζουμε την εξίσωση ως εξής:

$$y=ax+b \Rightarrow ax+b-y=0 \quad \text{ή} \quad ax-y+b=0$$

πολλαπλασιάζοντας επί έναν πραγματικό αριθμό w_2 , προκύπτει:

$$\left[w_1x + w_2y + w_3 = 0 \right]$$

με $w_1 = a w_2$ και $w_3 = b w_2$

Στην περίπτωση μας, όταν διάνυσμα αναπαρίσταται ως: $\vec{x} (x_1, x_2)$ τότε η εξίσωση της ευθείας που περνά από το πέρας του είναι:

$$w_1x_1 + w_2x_2 + w_3 = 0 \quad \text{ή} \quad d(\mathbf{x}) = 0$$

όπου $d(\mathbf{x}) = w_1x_1 + w_2x_2 + w_3$ και $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις


Έστω η ευθεία (ϵ) με εξίσωση

$$w_1 x_1 + w_2 x_2 + w_3 = 0$$

Η (ϵ) χωρίζει το επίπεδο σε δύο ημιεπίπεδα ($\Pi 1$) και ($\Pi 2$).

Τέμνει τον άξονα x_2 στο σημείο: $0, -\frac{w_3}{w_2}$

ενώ η κλίση της είναι: $\tan\theta = -\frac{w_1}{w_2}$



Για $d > 0$, ορίζουμε νέα ευθεία (ϵ') ως:

$$w_1 x_1 + w_2 x_2 + w_3 - d = 0$$

Η (ϵ') τέμνει τον άξονα x_2 στο σημείο: $0, \frac{-w_3 + d}{w_2}$

ενώ η κλίση της είναι: $\tan\theta' = -\frac{w_1}{w_2}$

Συνεπώς (ϵ')//(ϵ).

Αν $w_2 > 0$ τότε όλα τα σημεία της (ϵ') βρίσκονται στο ($\Pi 1$)
και συνεπώς για κάθε $d > 0$ η (ϵ') σαρώνει όλο το ($\Pi 1$)

Σύμφωνα όμως με τον ορισμό της (ϵ'): $d(x) - d = 0$, οπότε $d(x) > 0$
και άρα η σχέση $d(x) > 0$ ισχύει για όλο το ημιεπίπεδο ($\Pi 1$).

Ομοίως αποδεικνύεται και ότι $d(x) < 0$ ισχύει για το ($\Pi 2$).

Η $d(x)$ καλείται
γραμμική διακριτή συνάρτηση
και η ταξινόμηση που παρέχει
εξαρτάται από τις σχέσεις

$$d(x) > 0, d(x) < 0$$

ενώ για $d(x) = 0$ υπάρχει
απροσδιοριστία

Για $d > 0$, ορίζουμε νέα ευθεία (ϵ') ως:

$$\left[w_1 x_1 + w_2 x_2 + w_3 - d = 0 \right]$$

Η (ϵ') τέμνει τον άξονα x_2 στο σημείο: $\left[0, \frac{-w_3 + d}{w_2} \right]$

ενώ η κλίση της είναι: $\left[\tan \theta' = -\frac{w_1}{w_2} \right]$

Συνεπώς (ϵ') // (ϵ).

Αν $w_2 > 0$ τότε όλα τα σημεία της (ϵ') βρίσκονται στο (Π_1)
και συνεπώς για κάθε $d > 0$ η (ϵ') σαρώνει όλο το (Π_1)

Σύμφωνα όμως με τον ορισμό της (ϵ'): $d(x) - d = 0$, οπότε $d(x) > 0$
και άρα η σχέση $d(x) > 0$ ισχύει για όλο το ημιεπίπεδο (Π_1).

Ομοίως αποδεικνύεται και ότι $d(x) < 0$ ισχύει για το (Π_2).

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

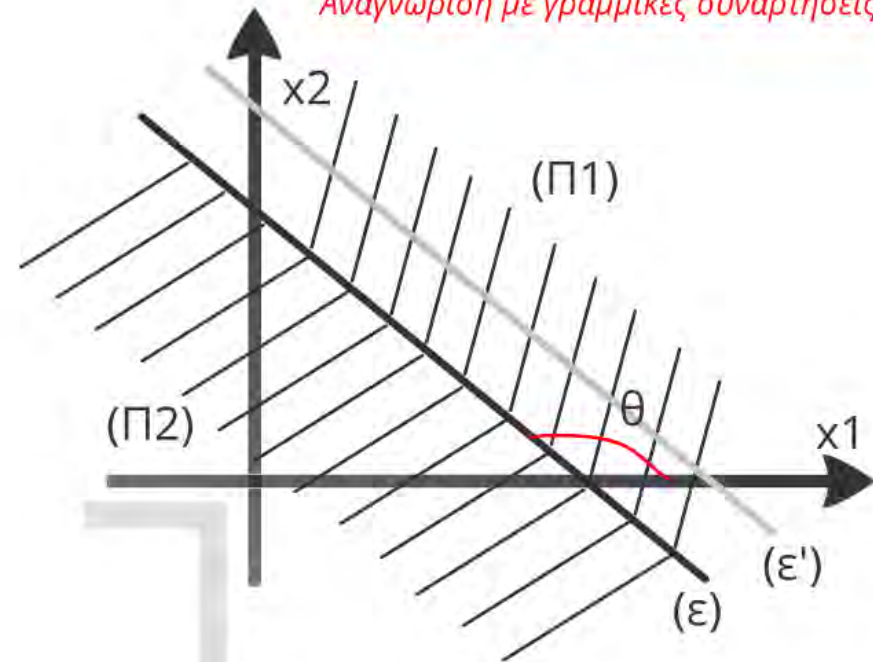
Έστω η ευθεία (ϵ) με εξίσωση

$$w_1 x_1 + w_2 x_2 + w_3 = 0$$

Η (ϵ) χωρίζει το επίπεδο σε δύο
ημιεπίπεδα ($\Pi 1$) και ($\Pi 2$).

Τέμνει τον άξονα x_2 στο σημείο: $0, -\frac{w_3}{w_2}$

ενώ η κλίση της είναι: $\tan\theta = -\frac{w_1}{w_2}$



Για $d > 0$, ορίζουμε νέα ευθεία (ϵ') ως:

$$w_1 x_1 + w_2 x_2 + w_3 - d = 0$$

Η (ϵ') τέμνει τον άξονα x_2 στο σημείο: $0, \frac{-w_3 + d}{w_2}$

ενώ η κλίση της είναι: $\tan\theta' = -\frac{w_1}{w_2}$

Συνεπώς (ϵ')//(ϵ).

Αν $w_2 > 0$ τότε όλα τα σημεία της (ϵ') βρίσκονται στο ($\Pi 1$)
και συνεπώς για κάθε $d > 0$ η (ϵ') σαρώνει όλο το ($\Pi 1$)

Σύμφωνα όμως με τον ορισμό της (ϵ'): $d(x) - d = 0$, οπότε $d(x) > 0$
και άρα η σχέση $d(x) > 0$ ισχύει για όλο το ημιεπίπεδο ($\Pi 1$).

Ομοίως αποδεικνύεται και ότι $d(x) < 0$ ισχύει για το ($\Pi 2$).


Η $d(x)$ καλείται
γραμμική διακριτή συνάρτηση
και η ταξινόμηση που παρέχει
εξαρτάται από τις σχέσεις

$$d(x) > 0, d(x) < 0$$

ενώ για $d(x) = 0$ υπάρχει
απροσδιοριστία

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις



Με τη βοήθεια πινάκων οι σχέσεις εκφράζονται ως εξής

$$\begin{aligned} d(x) &= w_1 x_1 + w_2 x_2 + w_3 \\ &= \mathbf{w}^T \mathbf{x} + w_3 \end{aligned}$$

$$\text{όπου } \mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} \text{ και } \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

Εάν το πέρας των x_A, x_B είναι πάνω στην (ε) τότε για το καθένα ικανοποιείται η εξίσωση $d(x)$

$$\left. \begin{aligned} w_1 x_{A1} + w_2 x_{A2} + w_3 &= 0 \\ w_1 x_{B1} + w_2 x_{B2} + w_3 &= 0 \end{aligned} \right\} \Rightarrow w_1 x_{A1} + w_2 x_{A2} = w_1 x_{B1} + w_2 x_{B2}$$

$$w_1 (x_{A1} - x_{B1}) + w_2 (x_{A2} - x_{B2}) = 0$$

$$[w_1 \quad w_2] \begin{bmatrix} x_{A1} - x_{B1} \\ x_{A2} - x_{B2} \end{bmatrix} = 0$$

$$\mathbf{w}^T (\mathbf{x}_A - \mathbf{x}_B) = 0$$

Αυτό σημαίνει όμως ότι το \mathbf{w} είναι κάθετο στην (ε)
(σύμφωνα με τα όσα ορίστηκαν στο εσωτερικό γινόμενο)

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

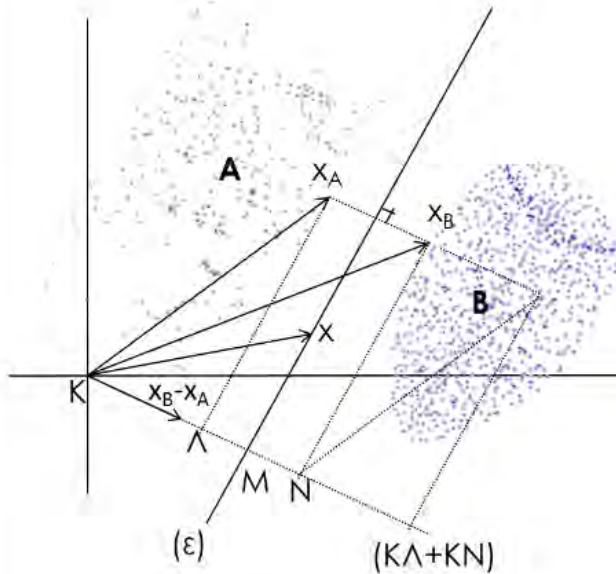
Ζητούμενο κατά την εκπαίδευση του ταξινομητή
είναι να οριστούν οι συντελεστές της (ε): w_1, w_2, w_3

αφού όπως φάνηκε, η ευθεία αυτή μπορεί να
παρέχει μια σχέση για την ταξινόμηση

$$d(x) > 0 \quad \text{ή} \quad d(x) < 0$$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις



Αν x_A και x_B οι πίνακες
των πιο κοντινών σημείων
των δύο κλάσεων

τότε μια κατάλληλη ευθεία (ϵ)
για τον καθορισμό των ημιεπιπέδων
είναι η μεσοκάθετος στο

$$\left[\begin{array}{c} \vec{x}_B - \vec{x}_A \end{array} \right]$$

Η προβολή κάθε
διανύσματος x με
πέρας στην (ϵ)

$$\begin{aligned} \text{Έτσι: } (x_A - x_B)^T \cdot x &= \frac{1}{2} [(x_A - x_B)^T \cdot x_A + (x_A - x_B)^T \cdot x_B] \\ &= \frac{1}{2} [x_A^T \cdot x_A - x_B^T \cdot x_B] \end{aligned}$$

$$(x_A - x_B)^T \cdot x - \frac{1}{2} [x_A^T \cdot x_A - x_B^T \cdot x_B] = 0$$

και συνεπώς πάνω στην ευθεία (ϵ):

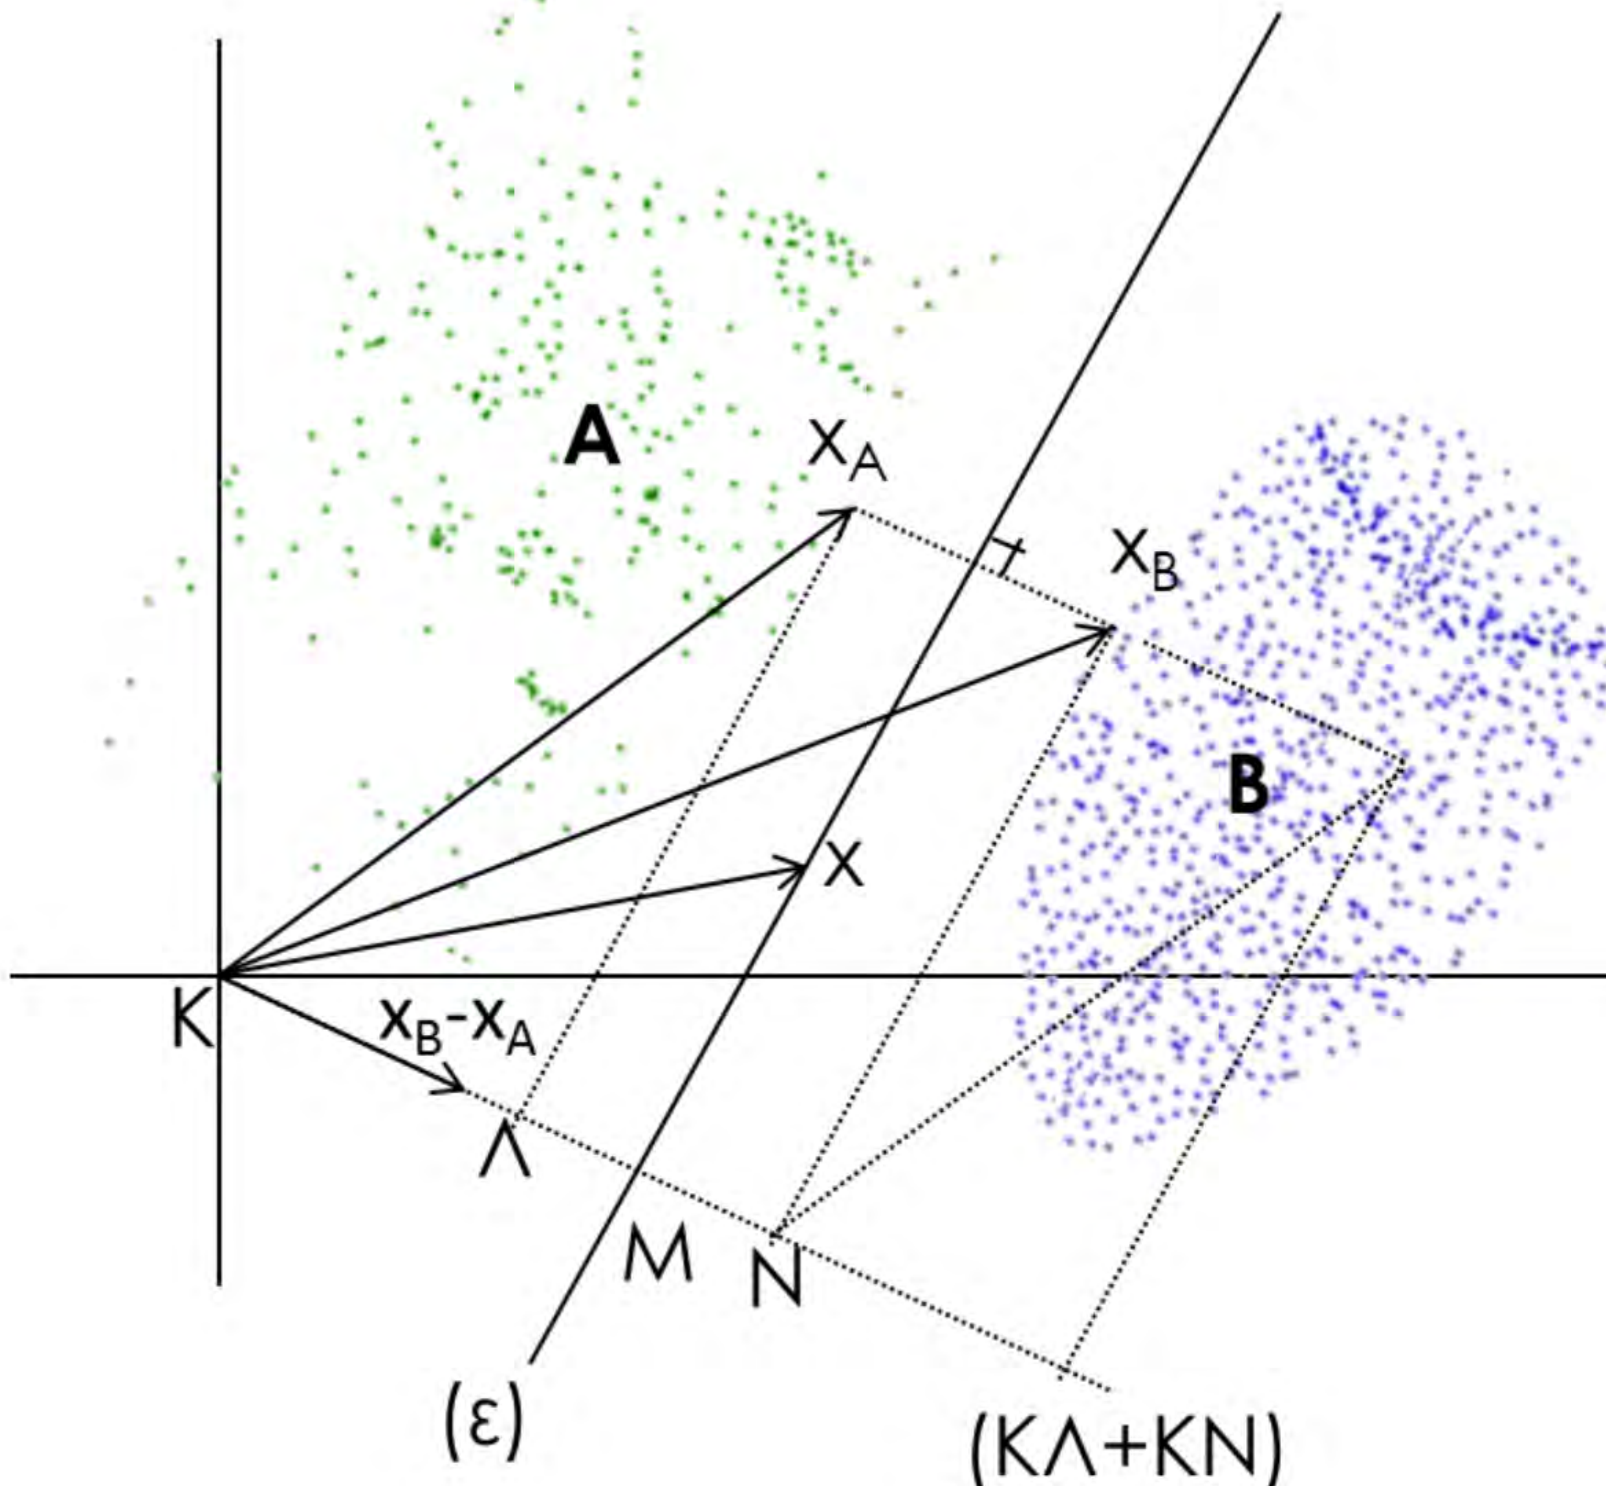
$$(\epsilon): d(x) = w^T x + w_3 = 0 \rightarrow \begin{cases} w = x_A - x_B \\ w_3 = -\frac{1}{2} (x_A^T \cdot x_A - x_B^T \cdot x_B) \end{cases}$$

$$\forall x: \cos \theta = \frac{(x_A - x_B)^T x}{|x_A - x_B| |x|} \Rightarrow \overline{KM} = \cos \theta |x| = \frac{(x_A - x_B)^T x}{|x_A - x_B|}$$

$$\begin{aligned} x_A: \cos \theta &= \frac{(x_A - x_B)^T x_A}{|x_A - x_B| |x_A|} \Rightarrow \\ \overline{K\Lambda} &= \cos \theta |x_A| = \frac{(x_A - x_B)^T x_A}{|x_A - x_B|} \end{aligned}$$

$$x_B: \overline{KN} = \frac{(x_A - x_B)^T x_B}{|x_A - x_B|}$$

$$\overline{KM} = \frac{1}{2} (\overline{K\Lambda} + \overline{KN})$$



Αν x ,
 των
 των
 τότε
 για τ
 είναι

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

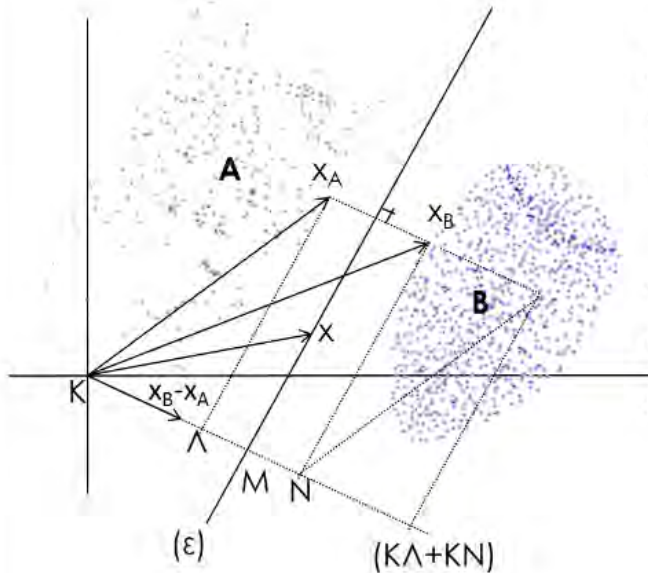
Αναγνώριση με γραμμικές συναρτήσεις

Αν X_A και X_B οι πίνακες
των πιο κοντινών σημείων
των δύο κλάσεων

τότε μια κατάλληλη ευθεία (ε)
για τον καθορισμό των ημιεπιπέδων
είναι η μεσοκάθετος στο

$$\left[\begin{array}{c} \vec{x} \\ X_B - X_A \end{array} \right]$$

Η προβολή κάθε
διανύσματος x με
πέρας στην (ε)



$$\begin{aligned} \text{Έτσι: } (x_A - x_B)^T \cdot x &= \frac{1}{2} [(x_A - x_B)^T \cdot x_A + (x_A - x_B)^T \cdot x_B] \\ &= \frac{1}{2} [x_A^T \cdot x_A - x_B^T \cdot x_B] \end{aligned}$$

$$(x_A - x_B)^T \cdot x - \frac{1}{2} [x_A^T \cdot x_A - x_B^T \cdot x_B] = 0$$

και συνεπώς πάνω στην ευθεία (ε):

$$(\varepsilon): d(x) = w^T x + w_3 = 0 \rightarrow \begin{cases} w = x_A - x_B \\ w_3 = -\frac{1}{2} (x_A^T \cdot x_A - x_B^T \cdot x_B) \end{cases}$$

$$\forall x: \cos \theta = \frac{(x_A - x_B)^T x}{|x_A - x_B| |x|} \Rightarrow$$

$$\overline{KM} = \cos \theta |x| = \frac{(x_A - x_B)^T x}{|x_A - x_B|}$$

$$x_A: \cos \theta = \frac{(x_A - x_B)^T x_A}{|x_A - x_B| |x_A|} \Rightarrow$$

$$\overline{KL} = \cos \theta |x_A| = \frac{(x_A - x_B)^T x_A}{|x_A - x_B|}$$

$$x_B: \overline{KN} = \frac{(x_A - x_B)^T x_B}{|x_A - x_B|}$$

$$\overline{KM} = \frac{1}{2} (\overline{KL} + \overline{KN})$$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

Παράδειγμα για την εύρεση της μεσοκαθέτου ως
ευθείας (ε) διαχωρισμού σε ημιεπίπεδα

$$x_A = [0 \ 1]^T, x_B = [2 \ 3]^T$$

Η εξίσωση της μεσοκαθέτου στο ευθύγραμμο τμήμα με άκρα τα διανύσματα αυτά είναι:

$$w^T \cdot x + w_3 = 0$$

$$w = x_A - x_B = [-2 \ -2]^T$$

$$w_3 = -\frac{1}{2}(x_A^T x_A - x_B^T x_B) = -\frac{1}{2}\left([0 \ 1] \begin{bmatrix} 0 \\ 1 \end{bmatrix} - [2 \ 3] \begin{bmatrix} 2 \\ 3 \end{bmatrix}\right) = 6$$

Άρα, τελικά η εξίσωση της ζητούμενης ευθείας (ε) είναι:

$$d(x) = w^T \cdot x + w_3 = 0 \Rightarrow$$

$$[-2 \ -2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + 6 = 0 \Rightarrow$$

$$(\varepsilon) \rightarrow x_1 + x_2 - 3 = 0$$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

Έστω τρία διανύσματα:

$$x_A = [1 \ 2]^T, x_B = [0 \ 3]^T \xrightarrow{?} x_C = [2 \ 1]^T$$

Η μεσοκάθετος σε σχέση με τα δύο πρώτα είναι:

$$w^T \cdot x + w_3 = 0$$

$$w = x_A - x_B = [1 \ -1]^T$$

$$w_3 = -\frac{1}{2}(x_A^T x_A - x_B^T x_B) = -\frac{1}{2}\left([1 \ 2] \begin{bmatrix} 1 \\ 2 \end{bmatrix} - [0 \ 3] \begin{bmatrix} 0 \\ 3 \end{bmatrix}\right) = 2$$

Άρα η εξίσωση της μεσοκαθέτου δίνεται:

$$d(x) = w^T \cdot x + w_3 = 0 \Rightarrow [1 \ -1] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + 2 = 0 \Rightarrow (\varepsilon) \rightarrow x_1 - x_2 + 2 = 0$$

Συνεπώς, το κάθε διάνυσμα βρίσκεται σε ένα ημιεπίπεδο και το τρίτο διάνυσμα βρίσκεται:

$$d(x_A) = 1 > 0 (\Pi_A), \quad d(x_B) = -1 < 0 (\Pi_B), \quad d(x_C) = 3 > 0 \rightarrow (\Pi_A)$$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

Γενίκευση σε περισσότερες των 2 διαστάσεων: N-διάστασεις

Η σχέση γίνεται:

$$(\varepsilon): d(x) = w^T x + w_{N+1} = 0 \rightarrow \begin{cases} w = x_A - x_B \\ w_{N+1} = -\frac{1}{2}(x_A^T \cdot x_A - x_B^T \cdot x_B) \end{cases}$$

Και τώρα η $d(x)$ περιγράφει ένα υπερεπίπεδο που χωρίζει τον E^N σε δύο μέρη για $d(x) > 0$ και $d(x) < 0$

Παράδειγμα τριών 4-διάστατων διανυσμάτων:

$$x_A = [0 \ 2 \ 0 \ 1]^T, x_B = [1 \ 0 \ -1 \ 0]^T \rightarrow x_C = [-1 \ 2 \ 1 \ 0]^T$$

Η εξίσωση της μεσοκαθέτου στα δύο πρώτα:

$$w^T \cdot x + w_5 = 0$$

$$w = x_A - x_B = [-1 \ 2 \ 1 \ 1]^T$$

$$w_5 = -\frac{1}{2}(x_A^T x_A - x_B^T x_B) = -\frac{1}{2} \left([0 \ 2 \ 0 \ 1] \begin{bmatrix} 0 \\ 2 \\ 0 \\ 1 \end{bmatrix} - [1 \ 0 \ -1 \ 0] \begin{bmatrix} 1 \\ 0 \\ -1 \\ 0 \end{bmatrix} \right) = -1.5$$

Συνεπώς η εξίσωση (ε) είναι:

$$d(x) = w^T \cdot x + w_5 = 0 \Rightarrow [-1 \ 2 \ 1 \ 1] \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} - 1.5 = 0 \Rightarrow (\varepsilon) \rightarrow -x_1 + 2x_2 + x_3 + x_4 - 1.5 = 0$$

Και έτσι, τα διανύσματα βρίσκονται στα εξής υπερεπίπεδα:

$$d(x_A) = 3.5 > 0 (\Pi_A), \quad d(x_B) = -3.5 < 0 (\Pi_B), \quad d(x_C) = 4.5 > 0 \rightarrow (\Pi_A)$$

γράφει ένα υπερεπίπεδο που
ο μέρη για $d(x) > 0$ και $d(x) < 0$

Παράδειγμα τριών 4-διάστατων διανυσμάτων:

$$x_A = [0 \ 2 \ 0 \ 1]^T, x_B = [1 \ 0 \ -1 \ 0]^T \xrightarrow{?} x_C = [-1 \ 2 \ 1 \ 0]^T$$

Η εξίσωση της μεσοκαθέτου στα δύο πρώτα:

$$w^T \cdot x + w_5 = 0$$

$$w = x_A - x_B = [-1 \ 2 \ 1 \ 1]^T$$

$$w_5 = -\frac{1}{2}(x_A^T x_A - x_B^T x_B) = -\frac{1}{2} \left([0 \ 2 \ 0 \ 1] \begin{bmatrix} 0 \\ 2 \\ 0 \\ 1 \end{bmatrix} - [1 \ 0 \ -1 \ 0] \begin{bmatrix} 1 \\ 0 \\ -1 \\ 0 \end{bmatrix} \right) = -1.5$$

Συνεπώς η εξίσωση (ε) είναι:

$$d(x) = w^T \cdot x + w_5 = 0 \Rightarrow [-1 \ 2 \ 1 \ 1] \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} - 1.5 = 0 \Rightarrow (\varepsilon) \rightarrow -x_1 + 2x_2 + x_3 + x_4 - 1.5 = 0$$

Και έτσι, τα διανύσματα βρίσκονται στα εξής υπερεπίπεδα:

$$d(x_A) = 3.5 > 0 (\Pi_A), \quad d(x_B) = -3.5 < 0 (\Pi_B), \quad d(x_C) = 4.5 > 0 \rightarrow (\Pi_A)$$

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις

Γενίκευση σε περισσότερες των 2 διαστάσεων: N-διάστασεις

Η σχέση γίνεται:

$$(\varepsilon): d(x) = w^T x + w_{N+1} = 0 \rightarrow \begin{cases} w = x_A - x_B \\ w_{N+1} = -\frac{1}{2}(x_A^T \cdot x_A - x_B^T \cdot x_B) \end{cases}$$

Και τώρα η $d(x)$ περιγράφει ένα υπερεπίπεδο που χωρίζει τον E^N σε δύο μέρη για $d(x) > 0$ και $d(x) < 0$

Παράδειγμα τριών 4-διάστατων διανυσμάτων:

$$x_A = [0 \ 2 \ 0 \ 1]^T, x_B = [1 \ 0 \ -1 \ 0]^T \rightarrow x_C = [-1 \ 2 \ 1 \ 0]^T$$

Η εξίσωση της μεσοκαθέτου στα δύο πρώτα:

$$w^T \cdot x + w_5 = 0$$

$$w = x_A - x_B = [-1 \ 2 \ 1 \ 1]^T$$

$$w_5 = -\frac{1}{2}(x_A^T x_A - x_B^T x_B) = -\frac{1}{2} \left([0 \ 2 \ 0 \ 1] \begin{bmatrix} 0 \\ 2 \\ 0 \\ 1 \end{bmatrix} - [1 \ 0 \ -1 \ 0] \begin{bmatrix} 1 \\ 0 \\ -1 \\ 0 \end{bmatrix} \right) = -1.5$$

Συνεπώς η εξίσωση (ε) είναι:

$$d(x) = w^T \cdot x + w_5 = 0 \Rightarrow [-1 \ 2 \ 1 \ 1] \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} - 1.5 = 0 \Rightarrow (\varepsilon) \rightarrow -x_1 + 2x_2 + x_3 + x_4 - 1.5 = 0$$

Και έτσι, τα διανύσματα βρίσκονται στα εξής υπερεπίπεδα:

$$d(x_A) = 3.5 > 0 (\Pi_A), \quad d(x_B) = -3.5 < 0 (\Pi_B), \quad d(x_C) = 4.5 > 0 \rightarrow (\Pi_A)$$

Επαυξημένα διανύσματα

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις


Σε δύο διαστάσεις:

$$d(x) = w_1x_1 + w_2x_2 + w_3 = \mathbf{w}^T \mathbf{x} + w_3$$

όπου $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$ και $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

αν $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$, $\tilde{\mathbf{x}} = \begin{bmatrix} x_1 \\ x_2 \\ 1 \end{bmatrix}$

$$d(x) = \mathbf{w}^T \tilde{\mathbf{x}}$$



Για N χαρακτηριστικά:

$$d(x) = 0 \Rightarrow \mathbf{w}^T \mathbf{x} = 0 \Rightarrow [\mathbf{w}_1 \quad \dots \quad \mathbf{w}_{N+1}] \begin{bmatrix} x_1 \\ \vdots \\ x_N \\ 1 \end{bmatrix} = 0$$

Ταξινομητές με επόπ

Αναγνώριση με γραμμικές συναρτήσεις

Σε δύο διαστάσεις:


$$d(\mathbf{x}) = w_1 x_1 + w_2 x_2 + w_3 = \mathbf{w}^T \mathbf{x} + w_3$$

όπου $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$ και $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

αν $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$,

$$\tilde{\mathbf{x}} = \begin{bmatrix} x_1 \\ x_2 \\ 1 \end{bmatrix}$$


$$d(\mathbf{x}) = \mathbf{w}^T \tilde{\mathbf{x}}$$



$$d(x) = w_1x_1 + w_2x_2 + w_3 = \mathbf{w}^T \mathbf{x} + w_3$$

όπου $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$ και $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

αν $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$, $\tilde{\mathbf{x}} = \begin{bmatrix} x_1 \\ x_2 \\ 1 \end{bmatrix}$



Για Ν χαρ

$$d(\mathbf{x}) = 0 \Rightarrow \mathbf{w}^T \mathbf{x} = 0$$

$$(\varepsilon): d(\mathbf{x}) = 0 \Rightarrow \mathbf{w}^T \tilde{\mathbf{x}} = 0$$

Για N χαρακτηριστικά:

$$d(\mathbf{x}) = \mathbf{0} \Rightarrow \mathbf{w}^T \mathbf{x} = \mathbf{0} \Rightarrow [\mathbf{w}_1 \quad \dots \quad \mathbf{w}_{N+1}] \begin{bmatrix} \mathbf{x}_1 \\ \vdots \\ \mathbf{x}_N \\ \mathbf{1} \end{bmatrix} = \mathbf{0}$$

Επαυξημένα διανύσματα

Μέθοδοι αναγνώρισης Ταξινομητές με επόπτη

Αναγνώριση με γραμμικές συναρτήσεις


Σε δύο διαστάσεις:

$$d(x) = w_1x_1 + w_2x_2 + w_3 = \mathbf{w}^T \mathbf{x} + w_3$$

όπου $w = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$ και $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

αν $w = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$, $\tilde{\mathbf{x}} = \begin{bmatrix} x_1 \\ x_2 \\ 1 \end{bmatrix}$

$$d(x) = \mathbf{w}^T \tilde{\mathbf{x}}$$



Για N χαρακτηριστικά:

$$d(x) = 0 \Rightarrow \mathbf{w}^T \mathbf{x} = 0 \Rightarrow [\mathbf{w}_1 \quad \dots \quad \mathbf{w}_{N+1}] \begin{bmatrix} x_1 \\ \vdots \\ x_N \\ 1 \end{bmatrix} = 0$$