

❖ ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ ❖ (PATTERN RECOGNITION)

Σέργιος Θεοδωρίδης
Κωνσταντίνος Κουτρούμπας

❖ Υπερεπίπεδα απόφασης

➤ Τετραγωνικοί όροι: $\underline{x}^T \Sigma_i^{-1} \underline{x}$

Αν **ΟΛΟΙ** $\Sigma_i = \Sigma$ (είναι ίδιοι) οι τετραγωνικοί όροι δεν επηρεάζουν, αφού δεν εμπλέκονται στις συγκρίσεις. Τότε μπορούμε να γράψουμε ισοδύναμα:

$$g_i(\underline{x}) = \underline{w}_i^T \underline{x} + w_{i0}$$

$$\underline{w}_i = \Sigma^{-1} \underline{\mu}_i$$

$$w_{i0} = \ln P(\omega_i) - \frac{1}{2} \underline{\mu}_i^T \Sigma^{-1} \underline{\mu}_i$$

Οι συναρτήσεις διάκρισης είναι **ΓΡΑΜΜΙΚΕΣ**

➤ Έστω επιπλέον ότι:


- $\Sigma = \sigma^2 I$. Τότε

$$g_i(\underline{x}) = \frac{1}{\sigma^2} \underline{\mu}_i^T \underline{x} + w_{i0}$$

- $g_{ij}(\underline{x}) = g_i(\underline{x}) - g_j(\underline{x}) = 0$
 $= \underline{w}^T (\underline{x} - \underline{x}_o)$

- $\underline{w} = \underline{\mu}_i - \underline{\mu}_j$,

- $\underline{x}_o = \frac{1}{2} (\underline{\mu}_i + \underline{\mu}_j) - \sigma^2 \ln \frac{P(\omega_i)}{P(\omega_j)} \frac{\underline{\mu}_i - \underline{\mu}_j}{\|\underline{\mu}_i - \underline{\mu}_j\|^2}$




➤ Μη διαγώνιος: $\Sigma \neq \sigma^2 I$

- $g_{ij}(\underline{x}) = \underline{w}^T (\underline{x} - \underline{x}_0) = 0$

- $\underline{w} = \Sigma^{-1}(\underline{\mu}_i - \underline{\mu}_j)$

- $\underline{x}_0 = \frac{1}{2}(\underline{\mu}_i + \underline{\mu}_j) - \ln\left(\frac{P(\omega_i)}{P(\omega_j)}\right) \frac{\underline{\mu}_i - \underline{\mu}_j}{\left\| \underline{\mu}_i - \underline{\mu}_j \right\|_{\Sigma^{-1}}^2}$

$$\left\| \underline{x} \right\|_{\Sigma^{-1}} \equiv (\underline{x}^T \Sigma^{-1} \underline{x})^{\frac{1}{2}}$$

➤ Υπερεπίπεδο απόφασης  όχι κάθετο στο $\underline{\mu}_i - \underline{\mu}_j$
κάθετο στο $\Sigma^{-1}(\underline{\mu}_i - \underline{\mu}_j)$


❖ Ταξινομητές ελάχιστης απόστασης

- $P(\omega_i) = \frac{1}{M}$ ισοπίθανες
- $g_i(\underline{x}) = -\frac{1}{2}(\underline{x} - \underline{\mu}_i)^T \Sigma^{-1}(\underline{x} - \underline{\mu}_i)$
- $\Sigma = \sigma^2 I$: Καταχώρησε $\underline{x} \rightarrow \omega_i$:


Ευκλείδεια απόσταση: $d_E \equiv \left\| \underline{x} - \underline{\mu}_i \right\|$
μικρότερη

- $\Sigma \neq \sigma^2 I$: Καταχώρησε $\underline{x} \rightarrow \omega_i$:

Mahalanobis απόσταση: $d_m = \left((\underline{x} - \underline{\mu}_i)^T \Sigma^{-1} (\underline{x} - \underline{\mu}_i) \right)^{\frac{1}{2}}$
μικρότερη



(a)



(b)

❖ Παράδειγμα:

Δοθέντων των ω_1, ω_2 : $P(\omega_1) = P(\omega_2)$ και $p(\underline{x}|\omega_1) = N(\underline{\mu}_1, \Sigma)$,

$$p(\underline{x}|\omega_2) = N(\underline{\mu}_2, \Sigma), \quad \underline{\mu}_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \quad \underline{\mu}_2 = \begin{bmatrix} 3 \\ 3 \end{bmatrix}, \quad \Sigma = \begin{bmatrix} 1.1 & 0.3 \\ 0.3 & 1.9 \end{bmatrix}$$

κατηγοριοποίησε το διάνυσμα $\underline{x} = \begin{bmatrix} 1.0 \\ 2.2 \end{bmatrix}$ με χρήση Bayesian ταξινομητή:

- $\Sigma^{-1} = \begin{bmatrix} 0.95 & -0.15 \\ -0.15 & 0.55 \end{bmatrix}$

- Υπόλ. Mahalanobis απόστ. d_m από μ_1, μ_2 : $d_{m,1}^2 = [1.0, 2.2]$

$$\Sigma^{-1} \begin{bmatrix} 1.0 \\ 2.2 \end{bmatrix} = 2.952, \quad d_{m,2}^2 = [-2.0, -0.8] \Sigma^{-1} \begin{bmatrix} -2.0 \\ -0.8 \end{bmatrix} = 3.672$$

- Καταχώρησε $\underline{x} \rightarrow \omega_1$. Παρατηρείστε ότι $d_{E,2} < d_{E,1}$

ΕΚΤΙΜΗΣΗ ΑΓΝΩΣΤΩΝ ΣΥΑΡΤΗΣΕΩΝ ΠΥΚΝΟΤΗΤΑΣ ΠΙΘΑΝΟΤΗΤΑΣ

❖ Μέγιστη πιθανοφάνεια (Maximum Likelihood)

(*) Έστω $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N$ γνωστά και ανεξάρτητα

(*) Έστω $p(\underline{x})$ γνωστής μορφής με άγνωστο διάνυσμα παραμέτρων $\underline{\theta}$: $p(\underline{x}) \equiv p(\underline{x}; \underline{\theta})$

(*) $X = \{ \underline{x}_1, \underline{x}_2, \dots, \underline{x}_N \}$

(*) $p(X; \underline{\theta}) \equiv p(\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N; \underline{\theta})$

$$= \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})$$


που είναι γνωστή ως η πιθανοφάνεια (Likelihood)
του $\underline{\theta}$ ως προς το X

Η μέθοδος:

$$\blacktriangleright \hat{\underline{\theta}}_{\text{ML}} : \arg \max_{\underline{\theta}} \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})$$

$$\blacktriangleright L(\underline{\theta}) \equiv \ln p(X; \underline{\theta}) = \sum_{k=1}^N \ln p(\underline{x}_k; \underline{\theta})$$

$$\blacktriangleright \hat{\underline{\theta}}_{\text{ML}} : \frac{\partial L(\underline{\theta})}{\partial(\underline{\theta})} = \sum_{k=1}^N \frac{1}{p(\underline{x}_k; \underline{\theta})} \frac{\partial p(\underline{x}_k; \underline{\theta})}{\partial(\underline{\theta})} = \underline{0}$$



Αν, πράγματι, υπάρχει ένα $\underline{\theta}_0$ έτσι ώστε

$$p(\underline{x}) = p(\underline{x}; \underline{\theta}_0), \text{ τότε}$$

$$\lim_{N \rightarrow \infty} E[\underline{\theta}_{ML}] = \underline{\theta}_0$$

$$\lim_{N \rightarrow \infty} E \left\| \hat{\underline{\theta}}_{ML} - \underline{\theta}_0 \right\|^2 = 0$$

- Ασυμπτωτικά αμερόληπτος (unbiased) εκτιμητής:
Η μέση τιμή της τυχαίας μεταβλητής $\hat{\underline{\theta}}_{ML}$ είναι η πραγματική τιμή της άγνωστης παραμέτρου
- Ασυμπτωτικά συνεπής (consistent) εκτιμητής:
Η διασπορά της ML εκτίμησης τείνει στο μηδέν.

❖ Παράδειγμα:

$p(\underline{x}): N(\underline{\mu}, \Sigma): \underline{\mu}$ άγνωστο, $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N$ $p(\underline{x}_k) \equiv p(\underline{x}_k; \underline{\mu})$

$$L(\underline{\mu}) = \ln \prod_{k=1}^N p(\underline{x}_k; \underline{\mu}) = C - \frac{1}{2} \sum_{k=1}^N (\underline{x}_k - \underline{\mu})^T \Sigma^{-1} (\underline{x}_k - \underline{\mu})$$

$$p(\underline{x}_k; \underline{\mu}) = \frac{1}{(2\pi)^{\frac{l}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} (\underline{x}_k - \underline{\mu})^T \Sigma^{-1} (\underline{x}_k - \underline{\mu})\right)$$

$$\frac{\partial L(\underline{\mu})}{\partial(\underline{\mu})} \equiv \begin{bmatrix} \frac{\partial L}{\partial \mu_1} \\ \cdot \\ \cdot \\ \cdot \\ \frac{\partial L}{\partial \mu_l} \end{bmatrix} = \sum_{k=1}^N \Sigma^{-1} (\underline{x}_k - \underline{\mu}) = \underline{0} \Rightarrow \underline{\mu}_{ML} = \frac{1}{N} \sum_{k=1}^N \underline{x}_k$$

Υπενθύμιση: Αν $A = A^T \Rightarrow \frac{\partial(\underline{\alpha}^T A \underline{\alpha})}{\partial \underline{\alpha}} = 2A \underline{\alpha}$

❖ Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας
(Maximum A posteriori Probability Estimation)

- Στην ML μέθοδο, το $\underline{\theta}$ λογίζοταν ως παράμετρος
- Εδώ θα θεωρήσουμε το $\underline{\theta}$ ως τυχαίο διάνυσμα που περιγράφεται από (υποτίθεται γνωστή) pdf $p(\underline{\theta})$.

- Δοθέντος

$$X = \{ \underline{x}_1, \underline{x}_2, \dots, \underline{x}_N \}$$

Υπολόγισε το μέγιστο της

$$p(\underline{\theta} | X)$$

- From Bayes theorem

$$p(\underline{\theta}) p(X | \underline{\theta}) = p(X) p(\underline{\theta} | X) \text{ or}$$

$$p(\underline{\theta} | X) = \frac{p(\underline{\theta}) p(X | \underline{\theta})}{p(X)}$$



➤ Η μέθοδος:

$$\hat{\underline{\theta}}_{MAP} = \arg \max_{\underline{\theta}} p(\underline{\theta} | X) \text{ ή}$$

$$\hat{\underline{\theta}}_{MAP} : \frac{\partial}{\partial \underline{\theta}} (p(\underline{\theta}) p(X | \underline{\theta}))$$

Αν η $p(\underline{\theta})$ είναι ομοιόμορφη ή αρκετά ευρεία:

$$\hat{\underline{\theta}}_{MAP} \cong \underline{\theta}_{ML}$$



❖ Παράδειγμα:

$$p(\underline{x}) : N(\underline{\mu}, \sigma^2 \mathbf{I}), \quad \underline{\mu} \text{ άγνωστο}, \quad X = \{\underline{x}_1, \dots, \underline{x}_N\}$$

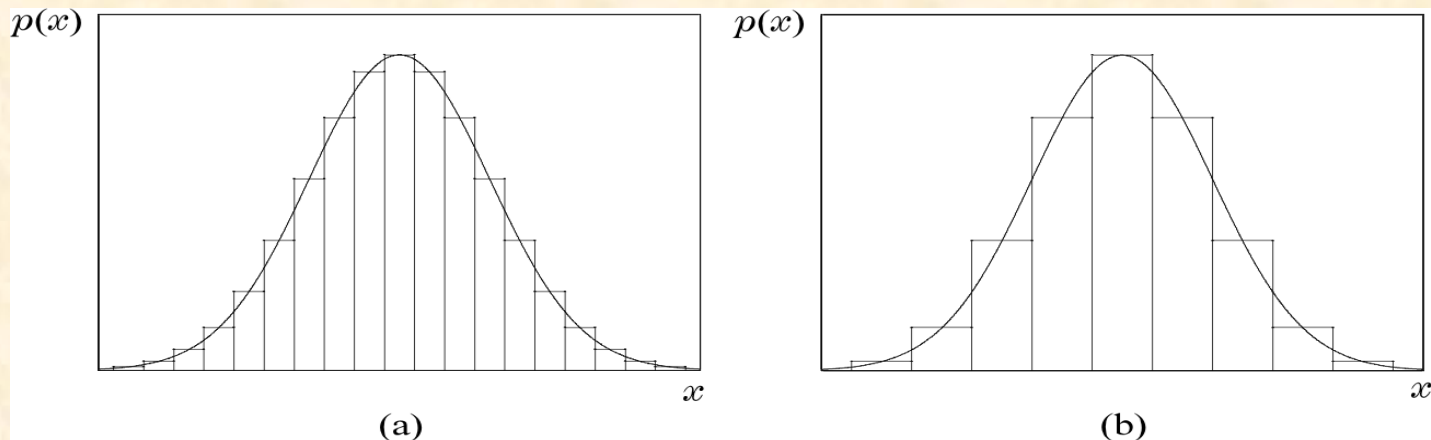
$$p(\underline{\mu}) = \frac{1}{(2\pi)^{\frac{l}{2}} \sigma_{\mu}^l} \exp\left(-\frac{\|\underline{\mu} - \underline{\mu}_0\|^2}{2\sigma_{\mu}^2}\right)$$

$$\hat{\underline{\theta}}_{MAP} : \frac{\partial}{\partial \underline{\mu}} \ln\left(\prod_{k=1}^N p(\underline{x}_k | \underline{\mu}) p(\underline{\mu})\right) = \underline{0} \quad \text{ή} \quad \sum_{k=1}^N \frac{1}{\sigma^2} (\underline{x}_k - \hat{\underline{\mu}}) - \frac{1}{\sigma_{\mu}^2} (\hat{\underline{\mu}} - \underline{\mu}_0) = \underline{0} \Rightarrow$$

$$\hat{\underline{\mu}}_{MAP} = \frac{\underline{\mu}_0 + \frac{\sigma_{\mu}^2}{\sigma^2} \sum_{k=1}^N \underline{x}_k}{1 + \frac{\sigma_{\mu}^2}{\sigma^2} N} \quad \text{For} \quad \frac{\sigma_{\mu}^2}{\sigma^2} \gg 1, \quad \text{ή για } N \rightarrow \infty$$

$$\hat{\underline{\mu}}_{MAP} \cong \hat{\underline{\mu}}_{ML} = \frac{1}{N} \sum_{k=1}^N \underline{x}_k$$

❖ Μη παραμετρική εκτίμηση



$$\triangleright P \approx \frac{k_N}{N} \begin{matrix} \nearrow k_N \text{ στο } h \\ \searrow N \text{ συνολικά} \end{matrix}$$

$$\triangleright \hat{p}(x) \equiv \hat{p}(\hat{x}) = \frac{1}{h} \frac{k_N}{N}, \quad |x - \hat{x}| \leq \frac{h}{2}$$


$\hat{x} - \frac{h}{2} \quad \hat{x} \quad \hat{x} + \frac{h}{2}$

\triangleright Αν $p(x)$ συνεχής, $\hat{p}(x) \rightarrow p(x)$ καθώς $N \rightarrow \infty$, αν

$$h_N \rightarrow 0, \quad k_N \rightarrow \infty, \quad \frac{k_N}{N} \rightarrow 0$$

❖ Παράθυρα Parzen

- Διαίρεση του πολυδιάστατου χώρου σε υπερκύβους



➤ Ορίζουμε

$$\phi(\underline{x}_i) = \left\{ \begin{array}{l} 1 \quad |x_{ij}| \leq 1/2 \\ 0 \quad \text{διαφορετικά} \end{array} \right\}$$

- Δηλαδή, είναι 1 μέσα σε υπερκύβο μοναδιαίας πλευράς με κέντρο το 0

- $$\hat{p}(\underline{x}) = \frac{1}{h^l} \left(\frac{1}{N} \sum_{i=1}^N \phi\left(\frac{\underline{x}_i - \underline{x}}{h}\right) \right)$$

• $\frac{1}{\text{όγκος}} * \frac{1}{N} *$ αριθμός σημείων εντός

έναν υπερκύβον πλευράς h κεντραρισμένο στο \underline{x}

- Το πρόβλημα: $p(\underline{x})$ συνεχής
 $\phi(\cdot)$ ασυνεχής
- Παράθυρα Parzen-Πυρήνες-συναρτήσεις δυναμικού
 $\phi(\underline{x})$ είναι ομαλή

$$\phi(\underline{x}) \geq 0, \quad \int_{\underline{x}} \phi(\underline{x}) d\underline{x} = 1$$

➤ Μέση τιμή

$$E[\hat{p}(\underline{x})] = \frac{1}{h^l} \left(\frac{1}{N} \sum_{i=1}^N E[\varphi(\frac{\underline{x}_i - \underline{x}}{h})] \right) = \int_{\underline{x}'} \frac{1}{h^l} \varphi(\frac{\underline{x}' - \underline{x}}{h}) p(\underline{x}') d\underline{x}'$$

- $h \rightarrow 0, \frac{1}{h^l} \rightarrow \infty$
- $h \rightarrow 0$ το εύρος της $\varphi(\frac{\underline{x}' - \underline{x}}{h}) \rightarrow 0$
- $\int \frac{1}{h^l} \varphi(\frac{\underline{x}' - \underline{x}}{h}) d\underline{x} = 1$
- $h \rightarrow 0 \frac{1}{h^l} \varphi(\frac{\underline{x}}{h}) \rightarrow \delta(\underline{x})$


$$E[\hat{p}(\underline{x})] = \int_{\underline{x}'} \delta(\underline{x}' - \underline{x}) p(\underline{x}') d\underline{x}' = p(\underline{x})$$

Συνεπώς απροκατάληπτος στο όριο

➤ Διασπορά


- Όσο **μικρότερο** το h , τόσο **μεγαλύτερη** η διασπορά

$h=0.1, N=1000$




(a)

$h=0.8, N=1000$



(b)

$h=0.1, N=10000$



➤ Όσο μεγαλύτερο το N , τόσο καλύτερη η ακρίβεια

➤ Av

- $h \rightarrow 0$
- $N \rightarrow \infty$
- $h_N \rightarrow \infty$

Ασυμπτωτικά απροκατάλητος

❖ ΚΑΤΑΡΑ ΤΗΣ ΔΙΑΣΤΑΤΙΚΟΤΗΤΑΣ (CURSE OF DIMENSIONALITY)

- Σε όλες τις μεθόδους, μέχρι τώρα, είδαμε ότι όσο **μεγαλύτερος** είναι ο αριθμός των σημείων, N , τόσο **καλύτερη** είναι η προκύπτουσα εκτίμηση.
- Αν στο μονοδιάστατο χώρο ένα διάστημα, που περιέχει N σημεία, is **αρκετό** (για καλή εκτίμηση), στον δισδιάστατο χώρο το αντίστοιχο τετράγωνο θα απαιτεί N^2 και στον ℓ -διάστατο χώρο ο ℓ -διάστατος κύβος θα απαιτεί N^ℓ σημεία.
- Η εκθετικά αύξηση του αριθμού των αναγκαίων σημείων είναι γνωστή ως **κατάρρα της διαστατικότητας** (**curse of dimensionality**). Πρόκειται για σημαντικό πρόβλημα που αντιμετωπίζει κανείς σε χώρους υψηλής διάστασης.