

# ❖ ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ ❖ (PATTERN RECOGNITION)

**Σέργιος Θεοδωρίδης  
Κωνσταντίνος Κουτρούμπας**

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (Maximum A posteriori

#### Probability (MAP) Estimation)

- Στην ML μέθοδο, το  $\underline{\theta}$  λογιζόταν 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

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

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

## (A) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP)

➤ 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:

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


# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP)



(a)



(b)

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP) - [Παράδειγμα](#)

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

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

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

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

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


# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος αναμονής-μεγιστοπόίησης (expectation-maximization – EM) (μοντέλα μίξης - mixture models)

**Μοντέλο μίξης:** Σταθμισμένο άθροισμα pdfs γνωστής παραμετρικής μορφής

$$p(x) = \sum_{k=1}^K P_k p(x | k), \quad \sum_{k=1}^K P_k = 1, \quad \int_{-\infty}^{+\infty} p(x | k) = 1$$



❖ Η μέθοδος ML δεν μπορεί να αξιοποιηθεί εδώ εξαιτίας των **ετικετών  $k$** , που είναι επίσης άγνωστες. **Λύση:** Ο αλγόριθμος **EM**.

**Συμβολισμοί:**

➤  $p(x | k) = p(x | k; \vartheta_k)$

➤  $\Theta = (\vartheta_1, \dots, \vartheta_K)$ ,  $P = [P_1, \dots, P_K]^T$ ,  $\Xi = (\Theta, P)$ .



➤  $X = \{x_1, \dots, x_N\}$ : **μη πλήρες (incomplete)** (παρατηρούμενο) σύνολο δεδομένων.

➤  $X^c = \{(x_1, k_1), \dots, (x_N, k_N)\}$ : **πλήρες (complete)** σύνολο δεδομένων

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος EM (μοντέλα μίξης)



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος **EM** (μοντέλα μίξης)

**Στόχος:** Εκτίμηση των  $\Theta$  και  $P$  μέσω της ελαχιστοποίησης της λογαριθμικής συνάρτησης πιθανοφάνειας (log-likelihood) του πλήρους συν. δεδομένων.

$$\ln p(X^c; \Theta, P) = \sum_{n=1}^N \ln p(x_n, k_n; \vartheta_{k_n}) = \sum_{n=1}^N \ln(p(x_n | k_n; \vartheta_{k_n}) P_{k_n})$$

**Πρόβλημα:** Για κάθε  $x$  είναι **άγνωστη** η επιμέρους **κατανομή** της μίξης από την οποία προήλθε.

**Λύση:** Μεγιστοποίηση της **μέσης τιμής** της log-likelihood ως προς  $P(k_n | x_n; \Xi)$

$$E \left[ \sum_{n=1}^N \ln(p(x_n | k_n; \vartheta_{k_n}) P_{k_n}) \right]_{P(k_n | x_n; \Xi)} = \sum_{n=1}^N E \left( \ln(p(x_n | k_n; \vartheta_{k_n}) P_{k_n}) \right)_{P(k_n | x_n; \Xi)}$$

$$\sum_{n=1}^N \sum_{k_n=1}^K \ln(p(x_n | k_n; \vartheta_{k_n}) P_{k_n}) P(k_n | x_n; \Xi) = \sum_{n=1}^N \sum_{k=1}^K \ln(p(x_n | k; \vartheta_k) P_k) P(k | x_n; \Xi)$$

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes - Η μέθοδος EM (μοντέλα μίξης)

$$\sum_{n=1}^N \sum_{k=1}^K \ln(p(x_n | k_n; \vartheta_{k_n}) P_{k_n}) P(k_n | x_n; \Xi) = \sum_{n=1}^N \sum_{k=1}^K \ln(p(x_n | k; \vartheta_k) P_k) P(k | x_n; \Xi)$$

**Επιπλέον πρόβλημα:** Οι ποσότητες  $P(k | x_n; \Xi)$  είναι άγνωστες.

**Λύση:** Δεδομένου ότι από τον κανόνα του Bayes είναι

$$P(k | x_n; \Xi) = \frac{p(x_n | k; \vartheta_k) P_k}{\sum_{j=1}^K p(x_n | j; \vartheta_j) P_j} \quad (\text{A})$$

Η λύση είναι ένας **αναδρομικός** αλγόριθμος.

Αρχικοποιώντας το  $\Xi = (\Theta, P)$  στις τιμές  $\Xi(0) = (\Theta(0), P(0))$

Εκτιμούμε τις  $P(k | x_k; \Xi(0))$  από την (A)

**(E-step)** Υπολογίζουμε τη μέση τιμή της *expected log-likelihood* με βάση τις  $P(k | x_k; \Xi(0))$

$$Q(\Xi | \Xi(0)) = \sum_{n=1}^N \sum_{k=1}^K \ln(p(x_n | k; \vartheta_k) P_k) P(k | x_n; \Xi(0))$$

**(M-step)** Μεγιστοποιούμε την  $Q(\Xi | \Xi(0))$  ως προς τις παραμέτρους  $\Xi$ .

$$\partial Q(\Xi | \Xi(0)) / \partial \vartheta_k = 0, \quad \partial Q(\Xi | \Xi(0)) / \partial P_k = 0$$

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes - Η μέθοδος EM (μοντέλα μίξης)

## Ο αλγόριθμος EM

➤ Αρχικοποίησε το  $\Xi = (\Theta, P)$  στις τιμές  $\Xi(0) = (\Theta(0), P(0))$

➤  $t=0$

➤ Επανέλαβε

□ Εκτίμησε τις  $P(k | x_k; \Xi(t))$  από την (A)

□ (E-step) Υπολόγισε τη μέση τιμή της *expected log-likelihood* με βάση τις  $P(k | x_k; \Xi(t))$

$$Q(\Xi | \Xi(t)) = \sum_{n=1}^N \sum_{k=1}^K \ln(p(x_n | k; \vartheta_k) P_k) P(k | x_n; \Xi(t))$$

□ (M-step) Εκτίμησε το  $\Xi(t+1)$  μεγιστοποιώντας την  $Q(\Xi | \Xi(t))$  ως προς τις παραμέτρους  $\Xi = (\Theta, P) = ((\vartheta_1, \dots, \vartheta_k), (P_1, \dots, P_k))$ .

$$\partial Q(\Xi | \Xi(t)) / \partial \vartheta_k = 0, \quad \partial Q(\Xi | \Xi(t)) / \partial P_k = 0$$

□  $t=t+1$

➤ Έως ότου επιτευχθεί σύγκλιση.

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η περίπτωση του ταξινομητή Bayes

Η μέθοδος **EM** (μοντέλα μίξης)

**Μίξη κανονικών κατανομών (Mixtures of Gaussians).**

$$p(x) = \sum_{k=1}^K P_k p(x | k; \mu_k, \Sigma_k),$$

$$p(x | k; \mu_k, \Sigma_k) = \frac{1}{(2\pi)^{l/2} |\Sigma_k|^{1/2}} \exp\left(-0.5 \cdot (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right)$$

Ο αλγόριθμος **EM** για την περίπτωση **μίξης κανονικών κατανομών**.

$$Q(\Xi | \Xi(t)) =$$

$$\sum_{n=1}^N \sum_{k=1}^K P(k | x_n; \Xi(t)) \left( -0.5 \ln |\Sigma_k| - 0.5 (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + \ln P_k \right)$$

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η περίπτωση του ταξινομητή Bayes

❖ Ο αλγόριθμος **EM** για την περίπτωση **μίξης κανονικών κατανομών**.

- Αρχικοποίησε  $\mu_k = \mu_k^{(0)}$ ,  $\Sigma_k = \Sigma_k^{(0)}$ ,  $P = P^{(0)}$

-  $t=0$

- Επανέλαβε

$$P(k | x_n; \Theta^{(t)}, P^{(t)}) = \frac{p(x_n | k; \vartheta_k^{(t)}) P_k^{(t)}}{\sum_{q=1}^K p(x_n | q; \vartheta_q^{(t)}) P_q^{(t)}} \equiv \gamma_{kn}^{(t)}$$

$$\mu_k^{(t+1)} = \sum_{n=1}^N \gamma_{kn}^{(t)} x_n \left/ \sum_{n=1}^N \gamma_{kn}^{(t)} \right.$$

$$\Sigma_k^{(t+1)} = \sum_{n=1}^N \gamma_{kn}^{(t)} (x_n - \mu_k^{(t+1)})(x_n - \mu_k^{(t+1)})^T \left/ \sum_{n=1}^N \gamma_{kn}^{(t)} \right.$$

$$P_k^{(t+1)} = \frac{1}{N} \sum_{n=1}^N \gamma_{kn}^{(t)}$$

$t=t+1$

- Έως ότου ικανοποιηθεί ένα κατάλληλο κριτήριο τερματισμού

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Ανασκόπηση του (προσεγγιστικού) ταξινομητή Bayes

- Available data:  $X=X_1 \cup X_2 \cup \dots \cup X_M$ . Each  $X_j$  corresponds to class  $\omega_j$ .

### Σχεδιασμός ταξινομητή

- Υιοθέτησε ένα μοντέλο pdf για κάθε  $\omega_j$ , με άγνωστες παραμέτρους  $\vartheta_j$ .
- Εφάρμοσε την **ML** (ή τις **MAP, EM**) μεθόδους **M φορές** (μία για κάθε κλάση) για την εκτίμηση των  $\vartheta_j$ 's, με βάση τα αντίστοιχα σύνολα  $X_j$ ,

$$\hat{p}(x | \omega_j) \equiv p(x | \omega_j; \hat{\vartheta}_j)$$

-Προσέγγισε τις  $P(\omega_j)$  ως εξής

$$\hat{P}(\omega_j) = N_i / N$$

-Όρισε

$$g_j(x) = \hat{P}(\omega_j) \hat{p}(x | \omega_j)$$

### Χρήση ταξινομητή

- Για δεδομένο  $x$ ,
- Υπολόγισε τις τιμές των  $g_j(x)$ ,  $j=1, \dots, M$ .
- Καταχώρησε το  $x$  στην κλάση  $k$  με  $g_k(x) = \max_{j=1, \dots, M} g_j(x)$ .

## Ένα σημαντικό ζήτημα – Η κατάρα της διαστατικότητας (*Curse of dimensionality*)

- Σε όλες τις μεθόδους που εξετάσαμε μέχρι στιγμής είδαμε ότι όσο **μεγαλύτερος** είναι ο αριθμός των σημείων,  $N$ , τόσο **καλύτερες** είναι και οι προκύπτουσες εκτιμήσεις.
- Αν στο μονοδιάστατο χώρο για ένα διάστημα μήκους  $L$ ,  $N$  σημεία είναι **αρκετά** για να δώσουν μια καλή εκτίμηση των εμπλεκόμενων παραμέτρων, στο διδιάστατο χώρο για μια επιφάνεια διαστάσεων  $L \times L$  απαιτούνται  $N^2$  σημεία για να πάρουμε καλές εκτιμήσεις και, γενικά, στον  $l$ -διάστατο χώρο για έναν υπερκύβο διαστάσεων  $L'$  απαιτούνται  $Nl$  σημέια.
- Η εκθετική αύξηση του αριθμού των σημείων που απαιτούνται για μια καλή εκτίμηση των εμπλεκόμενων παραμέτρων με τη διάσταση του χώρου είναι γνωστή ως **κατάρα της διαστατικότητας (*curse of dimensionality*)**. Πρόκειται για ένα σημαντικό πρόβλημα που απαντάται σε προβλήματα που απεικονίζονται σε χώρους υψηλής διαστατικότητας.

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Ο απλοϊκός ταξινομητής Bayes (naive Bayes classifier)

- Διαθέσιμα δεδομένα:  $X=X_1 \cup X_2 \cup \dots \cup X_M$ . Κάθε  $X_j$  αντιστοιχεί στην κλάση  $\omega_j$ . Έστω  $X_j = X_{j1} \times \dots \times X_{jl}$

-**Υπόθεση:** Όλα τα **χαρακτηριστικά (features)** είναι μεταξύ τους **στατιστικώς ανεξάρτητα**. Έτσι

$$p(x | \omega_j) = \prod_{k=1}^l p(x_k | \omega_j), \quad j = 1, \dots, M$$

-Ως εκ τούτου, μπορούμε για κάθε κλάση να εργαστούμε για κάθε  $p(x_k | \omega_j)$  ανεξάρτητα από τις υπόλοιπες  $p(x_q | \omega_j)$ ,  $q=1, \dots, l$ ,  $q \neq k$ .

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Ο απλοϊκός ταξινομητής Bayes (naive Bayes classifier)

### Σχεδιασμός ταξινομητή

- **Υιοθέτησε** ένα μοντέλο pdf για κάθε  $\omega_j$ , με άγνωστες παραμέτρους  $\vartheta_j$ .
- **Εφάρμοσε** την **ML** μέθοδο **M / φορές** (**I** φορές για κάθε κλάση) για την εκτίμηση των  $\vartheta_{jk}$ 's των μονοδιάστατων  $p(x_k | \omega_j)$ , με βάση τα αντίστοιχα  $X_{jk}$
- Προσέγγισε** τις  $P(\omega_j)$  ως ακολούθως

$$\hat{P}(\omega_j) = N_i / N$$

### **Όρισε**

$$g_j(x) = \hat{P}(\omega_j) \hat{p}(x | \omega_j) = \hat{P}(\omega_j) \prod_{k=1}^l \hat{p}(x_k | \omega_j)$$

### Χρήση ταξινομητή

- Για δεδομένο  $x$ ,
- Υπολόγισε τις τιμές των  $g_j(x)$ ,  $j=1, \dots, M$ .
- Καταχώρησε το  $x$  στην κλάση  $k$  με  $g_k(x) = \max_{j=1, \dots, M} g_j(x)$ .

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ Γραμμικοί ταξινομητές – Ο ταξινομητής ελάχιστης Ευκλείδειας απόστασης

- Διαθέσιμα δεδομένα:  $X=X_1 \cup X_2 \cup \dots \cup X_M$ . Κάθε  $X_j$  αντιστοιχεί στην κλάση  $\omega_j$ .

### Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα ,  $m_j$ , κάθε κλάσης  $\omega_j$ , με βάση το  $X_j$  ,  $j=1,\dots,N_j$ .

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και το  $m_j$  τίθεται ίσο με την προκύπτουσα **εκτίμηση** του **μέσου διανύσματος**)

-**Όρισε**

$$g_j(x) = - \|x - m_j\|^2$$

### Χρήση ταξινομητή

-Για δεδομένο  $x$ ,

-Υπολόγισε τις τιμές των  $g_j(x)$ ,  $j=1,\dots,M$ .

-Καταχώρησε το  $x$  στην κλάση  $k$  με  $g_k(x) = \max_{j=1,\dots,M} g_j(x)$ .

**ΣΗΜ:** Γενικά, ο ταξινομητής ελάχιστης Ευκλείδειας απόστασης δεν είναι βέλτιστος ως προς το κριτήριο της πιθανότητας λάθους (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Γραμμικοί ταξινομητές – Ο ταξινομητής ελάχιστης Mahalanobis απόστασης

- Διαθέσιμα δεδομένα:  $\mathbf{X} = \mathbf{X}_1 \cup \mathbf{X}_2 \cup \dots \mathbf{X}_M$ . Κάθε  $\mathbf{X}_j$  αντιστοιχεί στην κλάση  $\omega_j$ .

### Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα ,  $\mathbf{m}_j$ , και το μητρώο συνδιασποράς,  $\mathbf{S}_j$ , κάθε κλάσης  $\omega_j$ , με βάση το  $\mathbf{X}_j$ ,  $j=1,\dots,N_j$ .

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και μητρώου συνδιασποράς και τα  $\mathbf{m}_j$  και  $\mathbf{S}_j$ , τίθενται ίσα με τις προκύπτουσες εκτιμήσεις (το κοινό μητρώο συνδιασποράς μπορεί να τεθεί ίσο με το μέσο των εκτιμήσεων για τα  $\mathbf{S}_j$ )

- Όρισε

$$g_j(\mathbf{x}) = -(\mathbf{x} - \mathbf{m}_j)^T \mathbf{S}_j^{-1} (\mathbf{x} - \mathbf{m}_j)$$

### Χρήση ταξινομητή

- Για δεδομένο  $\mathbf{x}$ ,

- Υπολόγισε τις τιμές των  $g_j(\mathbf{x})$ ,  $j=1,\dots,M$ .

- Καταχώρησε το  $\mathbf{x}$  στην κλάση  $k$  με  $g_k(\mathbf{x}) = \max_{j=1,\dots,M} g_j(\mathbf{x})$ .

**ΣΗΜ:** Γενικά, ο ταξινομητής ελάχιστης Mahalanobis απόστασης δεν είναι βέλτιστος ως προς το κριτήριο της **πιθανότητας λάθους** (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)

## (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Τετραγωνικοί ταξινομητές

- Διαθέσιμα δεδομένα:  $X=X_1 \cup X_2 \cup \dots \cup X_M$ . Κάθε  $X_j$  αντιστοιχεί στην κλάση  $\omega_j$ .

#### Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα,  $m_j$ , και το μητρώο συνδιασποράς,  $S_j$ , κάθε κλάσης  $\omega_j$ , με βάση το  $X_j$ ,  $j=1,\dots,N_j$ .

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και μητρώου συνδιασποράς και τα  $m_j$  και  $S_j$ , τίθενται ίσα με τις προκύπτουσες εκτιμήσεις)

-**Όρισε**

$$g_j(x) = -(x - m_j)^T S_j^{-1} (x - m_j)$$

#### Χρήση ταξινομητή

-Για δεδομένο  $x$ ,

-Υπολόγισε τις τιμές των  $g_j(x)$ ,  $j=1,\dots,M$ .

-Καταχώρησε το  $x$  στην κλάση  $k$  με  $g_k(x) = \max_{j=1,\dots,M} g_j(x)$ .

**ΣΗΜ:** Γενικά, ο τετραγωνικός ταξινομητής **δεν είναι βέλτιστος** ως προς το κριτήριο της **πιθανότητας λάθους** (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)