

# ❖ ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ ❖ (PATTERN RECOGNITION)

**Σέργιος Θεοδωρίδης**  
**Κωνσταντίνος Κουτρούμπας**

## Σχεδιαζόντας ταξινομητές: Τα δεδομένα

Στην πράξη η **γνώση** σχετικά **διαδικασία γέννησης των δεδομένων** είναι πολύ **σπάνια γνωστή**. Το μόνο που έχουμε στη διάθεσή μας είναι ένα **σύνολο δεδομένων (data set)**.

όπου 
$$Y = \{(x_i, d_i), x_i \in R^l, d_i \in \{1, 2, \dots, m\}, i = 1, \dots, D\}$$

$x_i$  είναι η  $l$ -διάστατη αναπαράσταση του  $i$ -στού από τις  $N$  οντότητες (**διάνυσμα δεδομένων – data vector**)

$d_i$  είναι η ετικέτα της κλάσης όπου ανήκει το  $x_i$  (**1 για την  $\omega_1$ , 2 για την  $\omega_2$ ,...**).

### Ο βασικός στόχος ενός ταξινομητή

Δοθέντος ενός  $x$  **καταχώρησέ το** στην **πιο κατάλληλη κατηγορία**.

Ανάλογα με τον τρόπο που σχεδιάζεται ένας ταξινομητής, έχουμε δύο κύριες κατηγορίες:

- ❖ **Παραμετρικοί ταξινομητές (Parametric classifiers)**
- ❖ **Μη παραμετρικοί ταξινομητές (Nonparametric classifiers)**

## Σχεδιάζοντας ταξινομητές: Η παραμετρική περίπτωση

Στην περίπτωση αυτή:

- Υποθέτουμε ότι η **μορφή** του **παραμετρικού μοντέλου** παράγει τα διανύσματα δεδομένων είναι **γνωστή**, ενώ οι (**άγνωστες**) **παράμετροί** του **εκτιμώνται** με βάση το **διαθέσιμο σύνολο δεδομένων**.
- Η **ταξινόμηση** ενός νέου διανύσματος δεδομένων  **$x$**  βασίζεται στο μοντέλο που ορίστηκε παραπάνω.
- **ΣΗΜ:** Η **ταξινόμηση** του  **$x$**  εξαρτάται **έμμεσα** από το διαθέσιμο σύνολο δεδομένων.

## Σχεδιάζοντας ταξινομητές: Η μη παραμετρική περίπτωση

Στην περίπτωση αυτή:

- Η **ταξινόμηση** του  **$x$**  εξαρτάται **άμεσα** από το διαθέσιμο σύνολο δεδομένων.

## Σχεδιάζοντας ταξινομητές: Εκτιμώντας την απόδοσή τους

Ένα σημαντικό ζήτημα: Πώς γνωρίζουμε το **βαθμό αξιοπιστίας** του **ταξινομητή** που σχεδιάστηκε;

Είναι σαφές ότι, αν χρησιμοποιήσουμε όλα τα διανύσματα δεδομένων του διαθέσιμου συνόλου δεδομένων  $Y$ , δεν μπορούμε να χρησιμοποιήσουμε τα ίδια δεδομένα για να αξιολογήσουμε αντικειμενικά την απόδοσή του, καθώς η γνώση που περιέχεται σ' αυτά έχει ήδη χρησιμοποιηθεί για το σχεδιασμό του ταξινομητή.

(\*) Άλλη σχετική τεχνική είναι το **k-fold cross validation**.

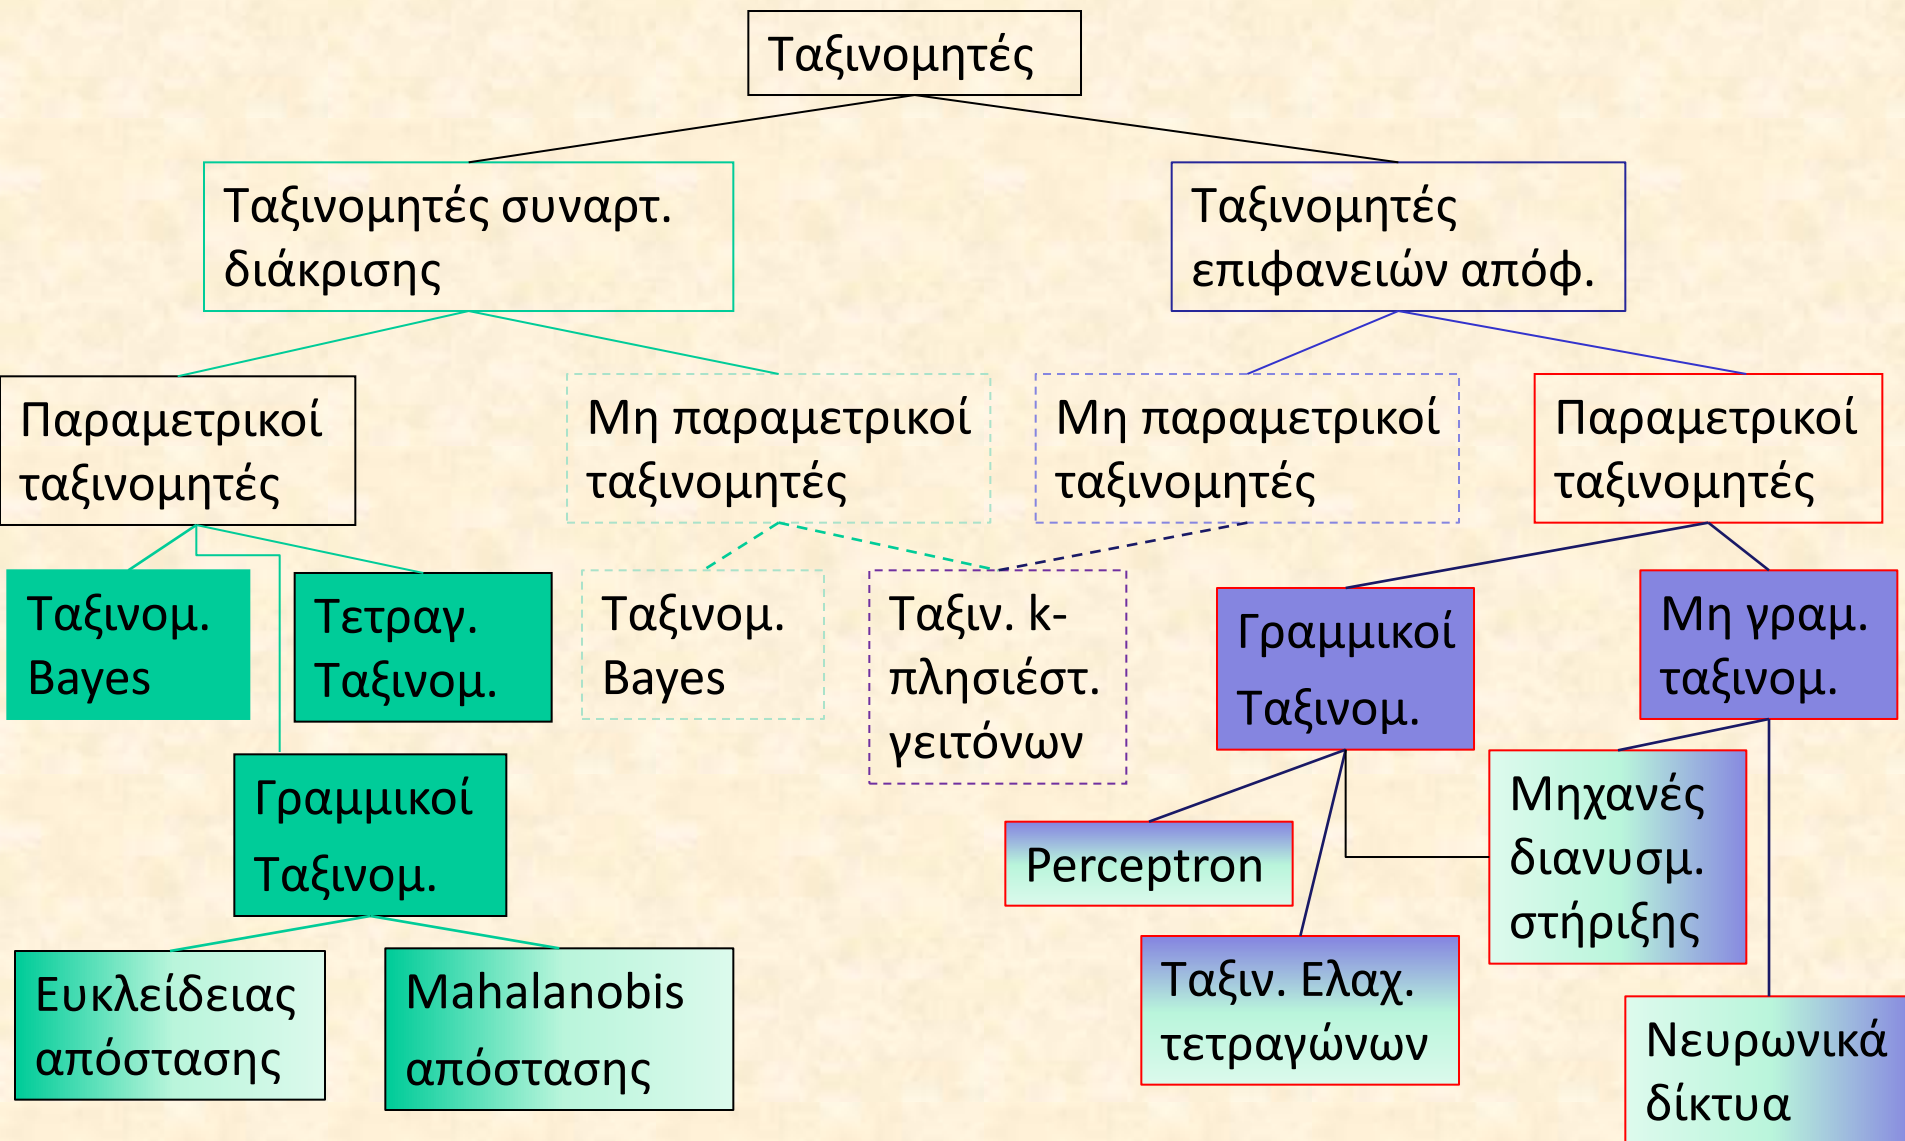
**Μια συνηθισμένη (και απλή) στρατηγική ταξινόμησης(\*):**



- **Διαίρεσε** το  $Y$  σε δύο σύνολα,  $X$  και  $X'$ ,  $N$  και  $N'$  στοιχείων, αντιστοίχως.
- Χρησιμοποίησε το  $X$  (**σύνολο εκπαίδευσης**) για τη **σχεδίαση του ταξινομητή**
- Χρησιμοποίησε το  $X'$  (**σύνολο δοκιμής**) για την **αξιολόγηση της απόδοσης** του σχεδιασθέντος ταξινομητή
- Αν η απόδοση είναι ικανοποιητική, ο ταξινομητής χρησιμοποιείται στη συνέχεια σε “πραγματικό περιβάλλον”. Διαφορετικά, θα πρέπει να αναθεωρηθούν κάποια βήματα της διαδικασίας σχεδιασμού.

**Με βάση ποιο κριτήριο αξιολογείται η απόδοση του ταξινομητή;**

Συνήθως με βάση το **ποσοστό των εσφαλμένα ταξινομημένων διανυσμάτων** του **συνόλου δοκιμής  $X'$**  (που είναι μια **εκτίμηση της πιθανότητας σφάλματος**)

# “ΧΑΡΤΟΓΡΑΦΗΣΗ” ΤΟΥ ΧΩΡΟΥ ΤΩΝ ΤΑΞΙΝΟΜΗΤΩΝ







# (A) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Για το **σχεδιασμό ΟΛΩΝ** των παραμετρικών ταξινομητών,  $y=f(x;w)$ , υπάρχουν δύο κύριες φάσεις

- > Καθορισμός του παραμετρικού μοντέλου
- > Εκτίμηση των παραμέτρων

## Ο ταξινομητής Bayes με χρήση παραμετρικών μοντέλων

Ποιες είναι οι παράμετροι που εμπλέκονται στον ταξινομητή Bayes στην περίπτωση αυτή;

- Οι εκ των προτέρων πιθανότητες  $P(\omega_j)$ ,  $j=1, \dots, M$ .
- Οι άγνωστες παράμετροι  $\vartheta_j$  των pdf των κλάσεων  $p(x|\omega_j; \vartheta_j)$ ,  $j=1, \dots, M$ .

**Παράδειγμα 1:** Αν η  $p(x|\omega_j)$  μοντελοποιείται από μία κανονική κατανομή,  $N(\mu_j, \Sigma_j)$ , και οι άγνωστες παράμετροι είναι το μέσο διάνυσμα και το μητρώο συνδιασποράς τότε  $\vartheta_j = \{\mu_j, \Sigma_j\}$

**Παράδειγμα 2:** Αν η  $p(x|\omega_j)$  μοντελοποιείται από μία κανονική κατανομή,  $N(\mu_j, \Sigma_j)$ , και η άγνωστη παράμετρος είναι το μέσο διάνυσμα, τότε  $\vartheta_j = \mu_j$ .

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

### Στην πράξη

- οι τιμές των παραμέτρων είναι πολύ σπάνια γνωστές.
- Έτσι, χρειάζεται να τις **εκτιμήσουμε**.

Στην πράξη έχουμε στην διάθεσή μας ένα σύνολο δεδομένων (**σύνολο εκπαίδευσης**)

$$X = \{(x_i, d_i), x_i \in R^l, d_i \in \{1, 2, \dots, M\}, i = 1, \dots, N\}$$

όπου

$x_i$  είναι το  $i$ -στό διάνυσμα εκπαίδευσης (**training vector**)

$d_i$  είναι η ετικέτα της κλάσης όπου ανήκει το  $x_i$  (**1** για την  $\omega_1$ , **2** για την  $\omega_2$ , ...).



# (A) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Έστω

$$X_j = \{x_i \in R^l : d_i = j, i = 1, \dots, N_j\}, \quad j = 1, \dots, M$$

$$N_1 + \dots + N_M = N$$

Το σύνολο που περιέχει τα διανύσματα δεδομένων της  $j$ -στης κλάσης.

Εκτίμηση παραμέτρων (βασίζεται στο σύνολο  $X$ ):

- Για κάθε  $P(\omega_j)$ :  
Χρησιμοποίησε την απλή προσέγγιση  $P(\omega_j) \approx N_j / N$ .
- Για κάθε  $p(x | \omega_j)$ :
- Υπάρχουν αρκετές μέθοδοι
  - **Εκτίμηση μέγιστης πιθανοφάνειας (Maximum Likelihood (ML) estimation)**,
  - **Εκτίμησης μέγιστης εκ των υστέρων πιθανότητας (Maximum a posteriori (MAP) estimation)**,
  - **Εκτίμηση μέγιστης εντροπίας (Maximum entropy (ME) estimation)**,
  - **Expectation-Maximization (EM) estimation** (mixture models) etc

Στη συνέχεια περιγράψουμε τις μεθόδους **ML**, **MAP** και (σύντομα) την μέθοδο **EM**.

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

- Έστω  $Y = \{ \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N \}$  ένα σύνολο από ανεξάρτητα διανύσματα δεδομένων
- Έστω  $p(\mathbf{x})$  μια pdf γνωστής παραμετρικής μορφής αλλά με άγνωστο το διάνυσμα παραμέτρων του  $\theta$ ;  $p(\mathbf{x}) = p(\mathbf{x}; \theta)$ .

### Παραδείγματα:

Αν η  $p(\mathbf{x}; \theta)$  είναι κανονική με άγνωστο μέσο διάνυσμα  $\mu$ , το  $\theta$  είναι απλά το  $\mu$ .

Αν η  $p(\mathbf{x}; \theta)$  είναι κανονική με άγνωστο μέσο διάνυσμα  $\mu$  και άγνωστο μητρώο συνδιασποράς  $\Sigma$ , το  $\theta$  περιέχει τις συνιστώσες τόσο του  $\mu$  όσο και του  $\Sigma$ .

**Το πρόβλημα:** Εκτίμησε το  $\theta$  ώστε η  $p(\mathbf{x}; \theta)$  να είναι το καλύτερο δυνατό ταίριασμα για το σύνολο δεδομένων  $Y$ .

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes



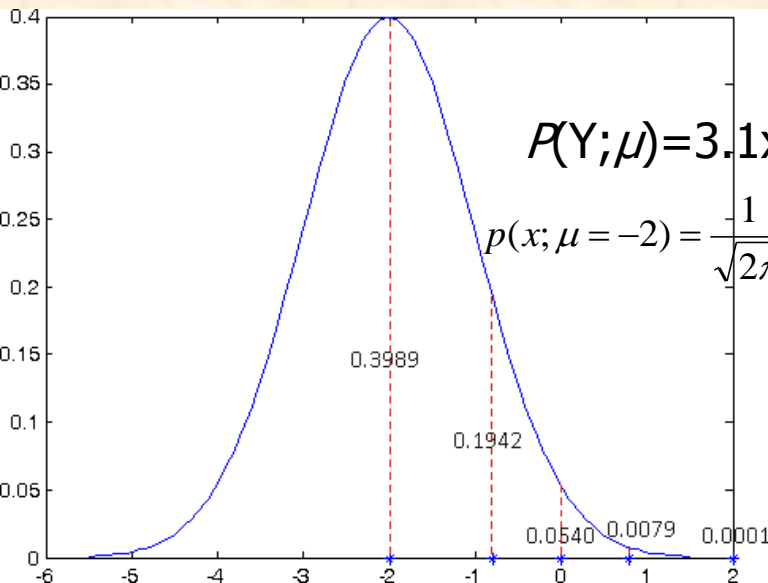
Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

- Έστω η **συνάρτηση πιθανοφάνειας (likelihood function)** του  $\vartheta$  ως προς το  $Y$ :


$$p(Y; \vartheta) = p(x_1, \dots, x_N; \vartheta) = \prod_{i=1}^N p(x_i; \vartheta)$$

- **Στην πράξη**, είναι πιο βολικό να μεγιστοποιήσουμε την συνάρτηση του **λογάριθμου της πιθανοφάνειας (log-likelihood function)  $L(\vartheta)$**  του  $\vartheta$  ως προς το  $Y$ , η οποία ορίζεται ως

$$L(\vartheta) = \ln p(Y; \vartheta) = \ln p(x_1, \dots, x_N; \vartheta) = \sum_{i=1}^N \ln p(x_i; \vartheta)$$




$P(Y; \mu)$



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ


## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας: Μεγιστοποίησε την  $p(Y;\vartheta)$  (ή την  $L(\vartheta)$ ) ως προς το  $\vartheta$ .

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



Μια παρένθεση: Το **gradient** συνάρτησης



Π.χ.: Το gradient της συνάρτησης

$$f(x_1, x_2) = -(\cos^2 x_1 + \cos^2 x_2)^2$$

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML) - Ένα παράδειγμα

-Έστω  $Y$  ένα σύνολο  $N$  διανυσμάτων δεδομένων,  $\mathbf{x}_i, i=1, \dots, N$ .

-Ποια είναι η κανονική κατανομή  $p(\mathbf{x}; \boldsymbol{\theta})$  γνωστού μητρώου συνδιασποράς που μοντελοποιεί καλύτερα τα διανύσματα του συνόλου  $Y$ ?

**Λύση:**

-Το άγνωστο διάνυσμα παραμέτρων στην περίπτωση αυτή είναι το μέσο διάνυσμα  $\boldsymbol{\mu}$ , δηλ.  $\boldsymbol{\theta} = \boldsymbol{\mu}$ .

-Είναι

$$p(\mathbf{x}; \boldsymbol{\theta}) \equiv p(\mathbf{x}; \boldsymbol{\mu}) = \frac{1}{(2\pi)^{l/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

$$\ln p(\mathbf{x}; \boldsymbol{\mu}) = \ln\left(\frac{1}{(2\pi)^{l/2} |\boldsymbol{\Sigma}|^{1/2}}\right) - \frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) = C - \frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})$$

$$L(\boldsymbol{\mu}) = \sum_{i=1}^N \ln p(\mathbf{x}_i; \boldsymbol{\mu}) = NC - \frac{1}{2} \sum_{i=1}^N (\mathbf{x}_i - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}_i - \boldsymbol{\mu})$$

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML) - Ένα παράδειγμα

-Θέτοντας την παράγωγο της  $L(\mu)$  ως προς το  $\mu$  ίση με  $\mathbf{0}$  έχουμε

$$\frac{\partial L(\mu)}{\partial \mu} = \frac{\partial}{\partial \mu} \left( NC - \sum_{i=1}^N \frac{1}{2} (x_i - \mu)^T \Sigma^{-1} (x_i - \mu) \right) = 0$$

$$\sum_{i=1}^N \Sigma^{-1} (x_i - \mu) = 0 \Leftrightarrow \sum_{i=1}^N (x_i - \mu) = 0 \Leftrightarrow \sum_{i=1}^N x_i - N\mu = 0$$

$$\mu_{ML} = \frac{1}{N} \sum_{i=1}^N x_i$$


# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

- Έστω  $N=10$  σημεία που παρήχθησαν από τη μονοδιάστατη κανονική κατανομή μηδενικής μέσης τιμής και μοναδιαίας συνδιασφοράς,  $N(0,1)$ .
- Ας **προσποιηθούμε** ότι έχουμε στη διάθεσή μας μόνο τα ακόλουθα:
  - Τη γνώση ότι η κατανομή που παρήγαγε τα σημεία είναι **κανονική** με διασπορά ίση με **1** και άγνωστο μέσο διάνυσμα  $\mu$ .
  - τα **10** σημεία.
- Η **ML εκτίμηση** του μέσου διανύσματος,  $\hat{\mu}$ , της κατανομής είναι **0.6210** (η πραγματική τιμή είναι **0**).

Όσο **περισσότερα σημεία** είναι διαθέσιμα, τόσο **πιο ακριβείς εκτιμήσεις** θα έχουμε για το μέσο διάνυσμα.

N	Σφάλμα εκτίμησης
10	0.6210 – 0
100	0.0727 – 0
1000	0.0138 – 0
10000	0.0118 – 0
100000	0.0034 – 0



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

Αν πράγματι υπάρχει  $\vartheta_0$  έτσι ώστε  $p(\mathbf{x})=p(\mathbf{x};\vartheta_0)$  τότε

$$\lim_{N \rightarrow \infty} E[\vartheta_{ML}] = \vartheta_0$$

$$\lim_{N \rightarrow \infty} E \|\vartheta_{ML} - \vartheta_0\|^2 = 0$$

- **Ασυμπτωτικά αμερόληπτος (Asymptotically unbiased)** εκτιμητής:

Η **μέση τιμή** του  $\vartheta$ ,  $\vartheta_{ML}$ , τείνει προς την πραγματική τιμή της άγνωστης παραμέτρου ( $\vartheta_0$ ), καθώς  $N \rightarrow \infty$ .

- **Ασυμπτωτικά συνεπής (Asymptotically consistent)** εκτιμητής:

Η **διασπορά** της ML εκτίμησης τείνει στο **0**, καθώς  $N \rightarrow \infty$ .



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

**Άσκηση:** Η τυχαία μεταβλητή  $x$  ακολουθεί την κατανομή Erlang

$$p(x; \vartheta) = \vartheta^2 x \exp(-\vartheta x) u(x)$$

με  $u(x)=1$  αν  $x>0$  και 0, διαφορετικά.

(α) Δεδομένου ενός συνόλου δειγμάτων  $x_1, \dots, x_N$ , του  $x$ , να δείξετε ότι η **εκτίμηση ML** του  $\vartheta$  είναι

$$\vartheta_{ML} = \frac{2N}{\sum_{k=1}^N x_k}$$

(β) Δεδομένου ότι η **μέση τιμή** της κατανομής ισούται με  $2/\vartheta$  ποια είναι η ML εκτίμησή της με βάση το παραπάνω σύνολο δειγμάτων;



# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

**Άσκηση:** Η τυχαία μεταβλητή  $x$  ακολουθεί την κατανομή Rayleigh

$$p(x; \vartheta) = 2\vartheta x \exp(-\vartheta x^2) u(x)$$

με  $u(x)=1$  αν  $x>0$  και 0, διαφορετικά.

(α) Δεδομένου ενός συνόλου δειγμάτων  $x_1, \dots, x_N$ , του  $x$ , να δείξετε ότι η **εκτίμηση ML** του  $\vartheta$  είναι

$$\vartheta_{ML} = \frac{N}{\sum_{k=1}^N x_k^2}$$

(β) Δεδομένου ότι η **μέση τιμή** της κατανομής ισούται με  $\sqrt{\pi/4\vartheta}$  ποια είναι η ML εκτίμησή της με βάση το παραπάνω σύνολο δειγμάτων;

# (Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

## Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

**Άσκηση:** Θεωρείστε ένα πρόβλημα ταξινόμησης δύο κλάσεων,  $\omega_1$  και  $\omega_2$ , όπου οι εμπλεκόμενες οντότητες χαρακτηρίζονται από ένα μόνο χαρακτηριστικό. Είναι γνωστό ότι οι τιμές

0.90, 0.95, 1.02, 1.01, 0.99, 1.30, 1.25, 0.87, 0.93, 1.02

ανήκουν στην κατηγορία  $\omega_1$ , ενώ οι τιμές

1.90, 1.95, 2.02, 2.01, 1.99, 2.30, 2.25, 1.87, 1.93, 2.02, 2.03, 1.91, 2.15, 1.88, 2.07

ανήκουν στην κατηγορία  $\omega_2$ .

Μοντελοποιώντας με κανονικές κατανομές τις pdfs των δύο κλάσεων για τις οποίες είναι γνωστές οι διασπορές ( $\sigma_1^2=0.020$  για την  $\omega_1$  και  $\sigma_2^2=0.017$  για την  $\omega_2$ ) αλλά άγνωστες οι μέσες τιμές τους:

(α) Εκτιμήστε τις μέσες τιμές των κατανομών

(β) Διατυπώστε τον (προσεγγιστικό) κανόνα του Bayes για το πρόβλημα.

(γ) Ταξινομήστε τα σημεία 1.4, 1.7, 0.2, 2.5 με βάση τον παραπάνω κανόνα.