

ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ (PATTERN RECOGNITION)

Σέργιος Θεοδωρίδης
Κωνσταντίνος Κουτρούμπας

Σχεδιαζόντας ταξινομητές: Τα δεδομένα

Στην πράξη η γνώση σχετικά με τη 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 ω_1 , 2 για την ω_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.

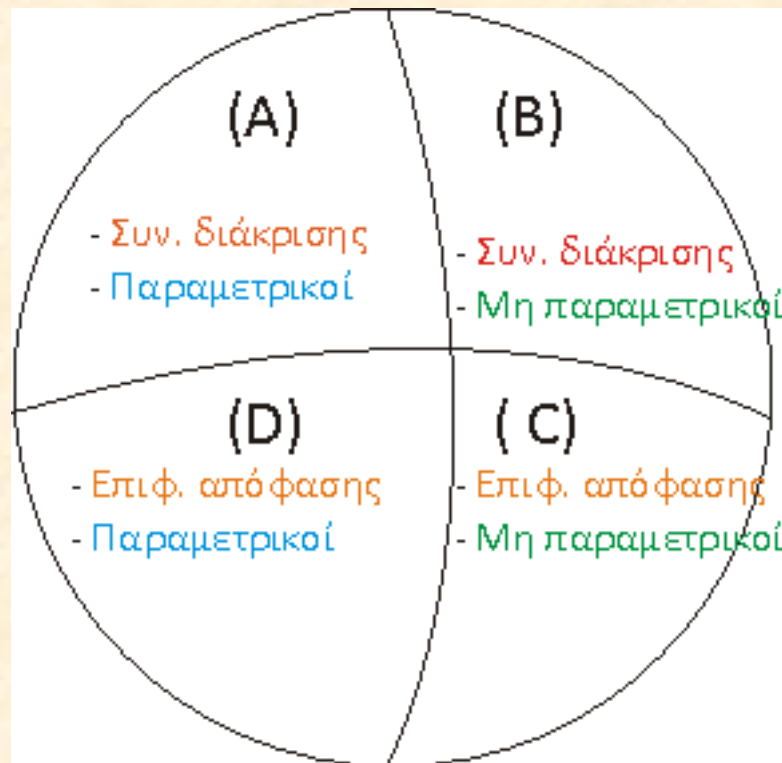
(*) Άλλη σχετική τεχνική είναι το **k-fold cross validation**.

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

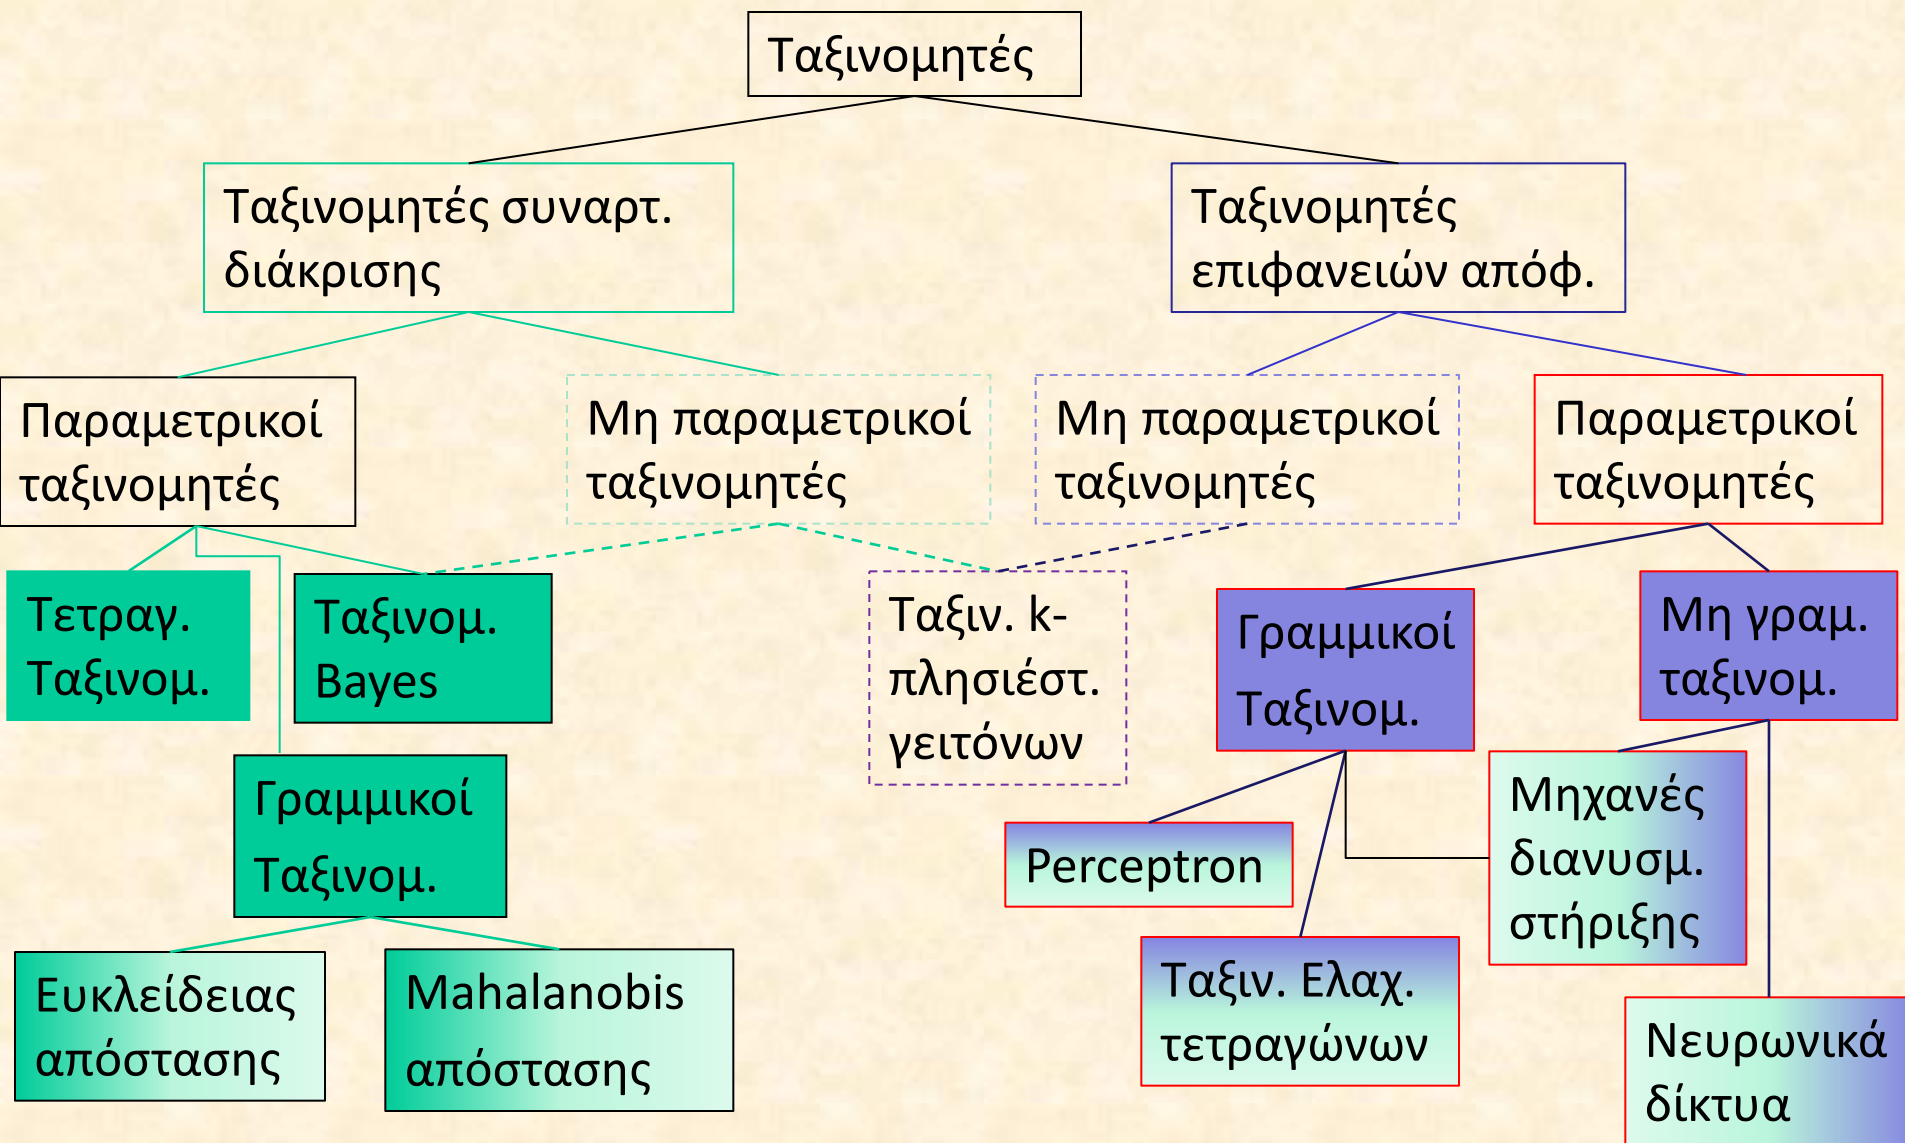
- **Διαίρεσε** το Y σε δύο σύνολα, X και X' , N και N' στοιχείων, αντιστοίχως.
- Χρησιμοποίησε το X (**σύνολο εκπαίδευσης**) για τη **σχεδίαση του ταξινομητή**
- Χρησιμοποίησε το X' (**σύνολο δοκιμής**) για την **αξιολόγηση της απόδοσης** του σχεδιασθέντος ταξινομητή
- Αν η απόδοση είναι ικανοποιητική, 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 ϑ_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 ω_1 , **2** για την ω_2 , ...).

(Α) 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 $\boldsymbol{\theta}$; $p(\mathbf{x}) = p(\mathbf{x}; \boldsymbol{\theta})$.

Παραδείγματα:

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

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

Το πρόβλημα: Εκτίμησε το $\boldsymbol{\theta}$ ώστε η $p(\mathbf{x}; \boldsymbol{\theta})$ 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 ϑ 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 ϑ ως προς το Y , η οποία ορίζεται ως

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

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ





Η περίπτωση του ταξινομητή Bayes

Η μέθοδος εκτίμησης μέγιστης πιθανοφάνειας (ML)

Παράδειγμα:

- $Y = \{-2, -1, 0, 1, 2\}$
- Θεωρείστε το σύνολο των **κανονικών κατανομών** μοναδιαίας διασποράς, παραμετροποιημένων ως προς το μ .
- Η συνάρτηση πιθανοφάνειας του μ ως προς το Y είναι


$$p(Y; \mu) = p(-2, -1, 0, 1, 2; \mu) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(-2-\mu)^2}{2}\right) \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(-1-\mu)^2}{2}\right) \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(0-\mu)^2}{2}\right) \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(1-\mu)^2}{2}\right) \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(2-\mu)^2}{2}\right)$$



(A) 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 ϑ .

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

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 μ 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 μ .
 - 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 ϑ_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 ϑ , ϑ_{ML} , τείνει προς την πραγματική τιμή της άγνωστης παραμέτρου (ϑ_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 ϑ 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 ϑ 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, ω_1 και ω_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 ω_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 ω_2 .

Μοντελοποιώντας με κανονικές κατανομές τις pdfs των δύο κλάσεων για τις οποίες είναι γνωστές οι διασπορές ($\sigma_1^2=0.020$ για την ω_1 και $\sigma_2^2=0.017$ για την ω_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.