



# ΠΑΝΕΠΙΣΤΗΜΙΟΝ ΠΕΙΡΑΙΩΣ

ΕΠΩΝΥΜΟ: <u>ESTIMATION OF UNKNOWN</u>	<span style="border: 1px solid black; padding: 2px;">#1</span>
ΟΝΟΜΑ: <u>PROBABILITY DENSITY</u>	
ΠΑΤΡΩΝΥΜΟ: <u>FUNCTIONS</u>	
A.M: .....	
ΕΞΑΜΗΝΟ: .....	
ΜΑΘΗΜΑ: <u>ΕΚΤΙΜΗΣΗ ΑΓΝΩΣΤΩΝ ΣΥΝΑΡΤΗΣΕΩΝ</u>	
ΗΜΕΡΟΜΗΝΙΑ: <u>ΠΥΚΝΟΤΗΤΑΣ ΠΙΘΑΝΟΤΗΤΑΣ</u>	

## ΜΑΧΙΜΙΑ ΛΙΚΕΛΙΧΟΟ ΡΑΡΑΜΕΤΡΑ ΕΣΤΙΜΑΤΙΟΝ :

### Εκτίμηση Παραμέτρων μέσω Μέγιστης Πιθανοφάνειας

Θεωρούμε ένα  $M$ -τάξιό πρόβλημα ταξινόμησης όπου τα διαυδόμενα χαρακτηρισιστικών κατανέμουται σύμφωνα με τις εξής συνάρτησης πυκνότητας πιθανότητας (class-conditional probability density functions):

$$p(x|w_i), \forall i \in \{M\}$$

Υποθέτουμε πως οι παραπάνω συνάρτησης πιθανοφάνειας δίνουν με παραμετρική μορφή και οι αντίστοιχοι παράμετροι για κάθε αόθη αόθη σχυμαόου τα διαυδόμενα  $\theta_i$  τα οποία είναι άγνωστα.

Στόχος μας είναι η εκτίμηση αυτών των άγνωστων διαυδόμενων παραμέτρων κάνοντας χρήση ενός γνωστού συνόλου διαυδόμενων χαρακτηριστικών από κάθε αόθη. Συνήθως, υποθέτουμε πως τα δεδομένα της μιας κλάσης δεν συμπεράζουν την διαδικασία εκτίμησης των παραμέτρων της άλλης, μπορούμε να διατυπώσουμε το πρόβλημα ανεξάρτητα από τις κλάσεις ακολουθώντας την μαθηματική σύμβαση. Κατά συνέπεια το υποκείμενο μαθηματικό πρόβλημα δύναται να επιλυθεί για την κάθε κλάση ανεξάρτητα από την άλλη.

Συνήθως, για να διευκυνθεί την εκτίμηση των συνάρτησεων πιθανοφάνειας από τα αντίστοιχα διαυδόμενα παραμέτρων  $\theta_i$  γράφουμε ότι:

$$p(x|w_i) = p(x|w_i; \theta_i), \forall i \in \{M\}$$

Έστω  $X = \{ \underline{x}_1, \underline{x}_2, \dots, \underline{x}_N \}$  ένα σύνολο τυχαίων δειγμάτων τα οποία έχουν ληφθεί από την συνάρτηση πυκνότητας πιθανότητας  $p(\underline{x}; \underline{\theta})$ . Υποθέτουμε στατιστική ανεξαρτησία μεταξύ των δειγμάτων σχηματίζουμε την από κοινού συνάρτηση πυκνότητας πιθανότητας ως εξής:

$$p(X; \underline{\theta}) \equiv p(\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N; \underline{\theta}) = \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})$$

Η παραπάνω σχέση δίνει μια συνάρτηση του  $\underline{\theta}$  που ονομάζεται συνάρτηση πιθανότητας του  $\underline{\theta}$  σε σχέση με το σύνολο  $X$ . Η μέθοδος της μέγιστης πιθανοφάνειας εκτιμά την τιμή του  $\underline{\theta}$  έτσι ώστε να μεγιστοποιείται η τιμή της συνάρτησης πιθανότητας.

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

Μια αναγκαία συνθήκη που θα πρέπει να ικανοποιείται ώστε το  $\hat{\underline{\theta}}_{ML}$  να μεγιστοποιεί την συνάρτηση πιθανότητας είναι λεγόμενη συνθήκη πρώτης τάξης (First Order Conditions or FOCs):

$$\frac{\partial \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})}{\partial \underline{\theta}} = \underline{0}$$

Προκειμένου να εκμεταλλευτούμε την μορφή της λογαριθμικής συνάρτησης, ορίζουμε την λογαριθμική συνάρτηση πιθανότητας ως εξής: [log-likelihood function]

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

Ευαίσθητα, η λογαριθμική συνάρτηση πιθανότητας μπορεί να οριστεί ως εξής:

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


Συνεπώς, η συνθήκη πρώτης τάξης μπορεί να γραφεί ισοδύναμα ως εξής:

$$\frac{\partial L(\underline{\theta})}{\partial \underline{\theta}} = \frac{\partial}{\partial \underline{\theta}} \left\{ \sum_{k=1}^N \ln(p(\underline{x}_k; \underline{\theta})) \right\} = \underline{0} \Leftrightarrow$$

$$\frac{\partial L(\underline{\theta})}{\partial \underline{\theta}} = \sum_{k=1}^N \frac{\partial \ln(p(\underline{x}_k; \underline{\theta}))}{\partial \underline{\theta}} = \underline{0} \quad \left\langle \ln(p(x))' = \frac{f'(x)}{p(x)} \right\rangle$$

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

Το παραπάνω σχήμα παρουσιάζει την μέθοδο της μέγιστης πιθανότητας για την ειδική περίπτωση μιας μονοδιάστατης κατανομής  $\theta$ .



Η ευρισθη μέγιστη πιθανότητας  $\hat{\theta}_{ML}$  για την παράμετρο  $\theta$  αντιστοιχεί στην τιμή που μεγιστοποιεί την αντίστοιχη συνάρτηση.

Έστω  $f: U \rightarrow \mathbb{R}$  όπου  $U$  είναι ένα ανοικτό υποσύνολο του διανυσματικού χώρου  $\mathbb{R}^n$ .

⊕:

[ΑΝΟΙΚΤΟ ΣΥΝΟΛΟ: OPEN SET]

Η έννοια του ανοικτού συνόλου στον Ευκλείδειο διανυσματικό χώρο ορίζεται ως εξής: Το  $U \subseteq \mathbb{R}^n$  είναι ένα ανοικτό υποσύνολο του  $n$ -διάστατου ευκλείδειου διανυσματικού χώρου όταν:

$$\forall x \in U, \exists \varepsilon > 0 : \forall y \in \mathbb{R}^n, \|x - y\| < \varepsilon, y \in U.$$

Ισοδύναμα, μπορούμε να γράψουμε ότι το  $U$  είναι ένα ανοικτό υποσύνολο του  $\mathbb{R}^n$  όταν  $\forall x \in U, \exists \varepsilon > 0 : \Gamma_\varepsilon(x) \subseteq U$ .

[ΜΕΡΙΚΗ ΠΑΡΑΓΩΓΟΣ: PARTIAL DERIVATIVE]

⊖: Η μερική παράγωγος μιας πολυμεταβλητής συνάρτησης  $f: U \rightarrow \mathbb{R}$  σε ένα σημείο  $\underline{a} = (a_1, \dots, a_n) \in U$  σε σχέση με την  $i$ -οστή μεταβλητή  $x_i$  ορίζεται σύμφωνα με το παρακάτω όριο:

$$\frac{\partial f(\underline{a})}{\partial x_i} = \lim_{h \rightarrow 0} \frac{f(a_1, \dots, a_{i-1}, a_i + h, a_{i+1}, \dots, a_n) - f(a_1, \dots, a_i)}{h}$$

$$\frac{\partial f(\underline{a})}{\partial x_i}$$

Αυτό σημαίνει αν όλες οι μερικές παράγωγοι υπάρχουν στο σημείο  $\underline{a} \in U$  αυτό δεν συνεπάγεται πως η συνάρτηση  $f$  θα είναι συνεχής. Ωστόσο, αν όλες οι μερικές παράγωγοι υπάρχουν σε μια γειτονιά του σημείου  $\underline{a}$  και είναι συνεχείς εντός αυτής τότε η συνάρτηση  $f$  είναι ολικώς διαφορίσιμη σε αυτή των γειτονιών και η συνάρτηση του ολικού διαφορικού είναι συνεχής.

Μόλις τα σύμφωνα με το θεώρημα Clairaut ισχύει ότι:

$$\frac{\partial^2 f}{\partial x_i \partial x_j} = \frac{\partial^2 f}{\partial x_j \partial x_i}$$



# ΠΑΝΕΠΙΣΤΗΜΙΟΝ ΠΕΙΡΑΙΩΣ

ΕΠΩΝΥΜΟ:.....	[#5]
ΟΝΟΜΑ:.....	
ΠΑΤΡΩΝΥΜΟ:.....	
A.M:..... ΕΞΑΜΗΝΟ:.....	
ΜΑΘΗΜΑ:.....	
ΗΜΕΡΟΜΗΝΙΑ:.....	

## ΟΛΙΚΗ ΠΑΡΑΓΩΓΟΣ: TOTAL DERIVATIVE

(111):

Αν  $U \subseteq \mathbb{R}^m$  είναι ένα ανοικτό σύνολο και  $f: U \rightarrow \mathbb{R}^m$ , η συνάρτηση  $f$  είναι ολικά διαφορίσιμη σε ένα σημείο  $a \in U$  εάν υπάρχει ένας γραμμικός μετασχηματισμός  $df_a: \mathbb{R}^m \rightarrow \mathbb{R}^m$  τέτοιος ώστε:

$$\lim_{x \rightarrow a} \frac{\|f(x) - f(a) - df_a(x-a)\|}{\|x-a\|} = 0$$

Η γραμμική απεικόνιση  $df_a$  καλείται ολικό παράγωγο ή ολικό διαφορικό της  $f$  στο σημείο  $a$ . Το ολικό διαφορικό της συνάρτησης  $f$  στο  $a$  συμβολίζεται και ως:  $Da f$  ή  $Df(a)$ .

Μια συνάρτηση  $f$  είναι ολικά διαφορίσιμη εάν το ολικό διαφορικό της υπάρχει σε κάθε σημείο του πεδίου ορισμού της.

Εννοιολογικά, ο ορισμός της ολικής παραγωγής εκφράζει την ίδια οίκη η ποσότητα  $df_a$  αποτελεί την καλύτερη δυνατή γραμμική προσέγγιση της  $f$  στο σημείο  $a$ . Η προϋπόθεση διασφάλιση μπορεί να γίνει περιβόητη ποσοτικοποιώντας το σφάλμα της γραμμικής προσέγγισης της  $f$  στο  $a$  ως εξής:

$$f(a+h) = f(a) + df_a(h) + \epsilon(h) \quad \text{όπου } \epsilon(h) \text{ το αντίστοιχο σφάλμα.}$$

Συνεπώς, η διασφάλιση πως η παράγωγος της  $f$  στο  $a$  είναι ίση με  $df_a$  είναι ισοδύναμη με την δήλωση:

$$\epsilon(h) = o(\|h\|).$$

Αυτό σημαίνει πως  $\epsilon(h) \ll \|h\|$  καθώς  $h \rightarrow 0$ .

Έστω το πρόβλημα μεγιστοποίησης: (χωρίς περιορισμούς)

$\max_{\underline{x}} f(x)$ : Το σημείο  $\underline{x}^*$  είναι μέγιστο της συνάρτησης  $f$  όταν:

Οι συνθήκες πρώτης τάξης (FOCs) για το παραπάνω πρόβλημα εκφράζονται ως:

$$\nabla_{\underline{x}} f(\underline{x}^*) = \underline{0} \quad \text{ή} \quad \frac{\partial f(\underline{x}^*)}{\partial x_i} = 0, \quad \forall i \in \{1, \dots, n\}$$

Εναλλακτικά, οι συνθήκες πρώτης τάξης μπορούν να εκφραστούν μέσω του διανύσματος βαθμίδας ως εξής: (gradient vector)

$$Df(\underline{x}^*) = \left[ \frac{\partial f(\underline{x}^*)}{\partial x_1}, \dots, \frac{\partial f(\underline{x}^*)}{\partial x_n} \right] = \underline{0}$$

Οι συνθήκες δεύτερης τάξης (SOCs) για το παραπάνω πρόβλημα εκφράζονται μέσω της λεσιανής μήτρας (Hessian matrix)

$$\underline{H} \in M_{n \times n} \text{ με } H = [H_{ij}] \quad \text{κλι} \quad H_{ij}^{(\underline{x})} = \frac{\partial^2 f(\underline{x})}{\partial x_i \partial x_j}$$

Το σημείο  $\underline{x}^*$  είναι μέγιστο της συνάρτησης  $f$  όταν η λεσιανή μήτρα είναι αρνητικά ημιορισμένη, δηλαδή: (negative semi-definite)

$$\text{για κάθε διάνυσμα } \underline{u} \in \mathbb{R}^n : \underline{u}^T \underline{H} \underline{u} \leq 0$$

\* Οι συνθήκες δεύτερης τάξης για την περίπτωση ενός προβλήματος ελαχιστοποίησης απαιτούν την λεσιανή μήτρα να είναι θετικά ημιορισμένη.

Ο εκτιμητής μέγιστης πιθανοφάνειας (ML estimate) διαθέτει ορισμένες εξαιρετικά επιθυμητές ιδιότητες. Αν  $\hat{\theta}_0$  είναι η πραγματική τιμή της άγνωστης παραμέτρου συν συνάρτησης πιθανοφάνειας  $p(x; \theta)$  τότε ισχύουν τα παρακάτω:

(I): Ο εκτιμητής μέγιστης πιθανοφάνειας είναι ασυμπτωτικά αμερόλητος (asymptotically unbiased) που εξ' ορισμού σημαίνει ότι:

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

Αυτά, η μέση τιμή του εκτιμητή συγκλίνει προς την πραγματική τιμή της παραμέτρου. Στην πραγματικότητα, η εκτιμητική μέγιστης πιθανοφάνειας  $\hat{\theta}_{ML}$  αποτελεί και αυτή μια τυχαία μεταβλητή (τυχαίο διάνυσμα) καθώς εξαρτάται κάθε φορά από το δείγμα  $\mathcal{D}$ . Ένας εκτιμητής είναι αμερόλητος όταν η μέση τιμή του συγκλίνει με την πραγματική τιμή της άγνωστης παραμέτρου. Στην περίπτωση του εκτιμητή μέγιστης πιθανοφάνειας αυτό ισχύει ασυμπτωτικά καθώς  $N \rightarrow \infty$ .

(II): Ο εκτιμητής μέγιστης πιθανοφάνειας είναι ασυμπτωτικά συνεπής (asymptotically consistent) που σημαίνει πως:

$$\lim_{N \rightarrow \infty} \Pr\{\|\hat{\theta}_{ML} - \hat{\theta}_0\| < \varepsilon\} = 1$$

όπου η τιμή του  $\varepsilon$  μπορεί να γίνει αυθαίρετα μικρή. Με άλλα λόγια, η τιμή του εκτιμητή μέγιστης πιθανοφάνειας συγκλίνει σε πιθανότητα προς την πραγματική τιμή της άγνωστης παραμέτρου. Εναλλακτικά, μπορούμε να πούμε πως για μερόλητες τιμές του  $N$  η εκτιμητική τιμή θα βρίσκεται κοντά στην πραγματική τιμή.

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

Άσκηση 1η: Υποθέτουμε πως  $N$  ανεξάρτητα δεδομένα έχουν παραχθεί από ανεξάρτητη, πανομοιότυπη δειγματοληψία (i.i.d) από μία (μονοδιάστατη) κανονική κατανομή με γνωστή την τιμή του μέσου ( $\mu$ ) και άγνωστη διακύμανση ( $\sigma^2$ ). Να βρεθεί η ακριβής μέγιστη πιθανοφάνεια για την παράμετρο  $\sigma^2$ .

Η λογαριθμική συνάρτηση πιθανοφάνειας θα δίνεται από την σχέση:

$$L(\sigma^2) = \ln \left\{ \prod_{k=1}^N p(x_k; \sigma^2) \right\} = \ln \left\{ \prod_{k=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(x_k - \mu)^2}{2\sigma^2} \right\} \right\} \Leftrightarrow$$

$$L(\sigma^2) = \sum_{k=1}^N \ln \left\{ \frac{1}{\sqrt{2\pi}\sigma} \cdot \exp \left\{ -\frac{(x_k - \mu)^2}{2\sigma^2} \right\} \right\} \Leftrightarrow$$

$$L(\sigma^2) = \sum_{k=1}^N \left\{ \ln \frac{1}{\sqrt{2\pi}\sigma} + \ln \left\{ \exp \left\{ -\frac{(x_k - \mu)^2}{2\sigma^2} \right\} \right\} \right\} \Leftrightarrow$$

$$L(\sigma^2) = \sum_{k=1}^N \ln \frac{1}{\sqrt{2\pi}\sqrt{\sigma^2}} + \sum_{k=1}^N -\frac{(x_k - \mu)^2}{2\sigma^2} \Leftrightarrow$$

$$L(\sigma^2) = \sum_{k=1}^N -\frac{1}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (x_k - \mu)^2 \Leftrightarrow$$

$$L(\sigma^2) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (x_k - \mu)^2$$

Υπολογίζουμε την συνθήκη πρώτης τάξης (FOC):

$$\frac{\partial L(\sigma^2)}{\partial \sigma^2} = 0$$





# ΠΑΝΕΠΙΣΤΗΜΙΟΝ ΠΕΙΡΑΙΩΣ

ΕΠΩΝΥΜΟ: .....	<b>#9</b>
ΟΝΟΜΑ: .....	
ΠΑΤΡΩΝΥΜΟ: .....	
A.M: .....	
ΕΞΑΜΗΝΟ: .....	
ΜΑΘΗΜΑ: .....	
ΗΜΕΡΟΜΗΝΙΑ: .....	

$$\textcircled{*} \frac{\partial L(\sigma^2)}{\partial \sigma^2} = \frac{\partial}{\partial \sigma^2} \left[ -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (x_k - \mu)^2 \right] \Leftrightarrow$$

$$\frac{\partial L(\sigma^2)}{\partial \sigma^2} = -\frac{N}{2} \cdot \frac{\partial}{\partial \sigma^2} [\ln(2\pi\sigma^2)] - \frac{1}{2} \sum_{k=1}^N (x_k - \mu)^2 \cdot \frac{\partial}{\partial \sigma^2} \left[ \frac{1}{\sigma^2} \right] \Leftrightarrow$$

Mind that we treat  $\sigma^2$  as a single variable. That is,  $\sigma^2 = a$ .

$$\frac{\partial L(\sigma^2)}{\partial \sigma^2} = -\frac{N}{2} \cdot \frac{\partial / \partial \sigma^2 (2\pi\sigma^2)}{2\pi\sigma^2} + \frac{1}{2} \sum_{k=1}^N (x_k - \mu)^2 \cdot \frac{1}{\sigma^4} \Leftrightarrow$$

$$\frac{\partial L(\sigma^2)}{\partial \sigma^2} = -\frac{N}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^N (x_k - \mu)^2 = 0 \Leftrightarrow$$

$$-N\sigma^2 + \sum_{k=1}^N (x_k - \mu)^2 = 0 \Leftrightarrow \hat{\sigma}_{ML}^2 = \frac{1}{N} \sum_{k=1}^N (x_k - \mu)^2$$

$$\Leftrightarrow \left[ \frac{1}{N} \sum_{k=1}^N x_k^2 \right] \cdot \frac{1}{\sigma^2} - \left[ \frac{1}{N} \sum_{k=1}^N x_k \right]^2 \cdot \frac{1}{\sigma^4} = 0$$

$$\Leftrightarrow \left[ \frac{1}{N} \sum_{k=1}^N x_k^2 \right] \cdot \frac{1}{\sigma^2} - \left[ \frac{1}{N} \sum_{k=1}^N x_k \right]^2 \cdot \frac{1}{\sigma^4} = 0$$

ΧΡΗΣΙΜΕΣ ΠΑΡΑΓΩΓΗ ΜΗΤΡΩΝ ΚΑΙ ΔΙΑΦΥΣΜΑΤΩΝ

DERIVATIVES OF DETERMINANTS:

(1):  $\frac{\partial |X|}{\partial X} = |X| (X^{-1})^T$   
 ★ SOS

(2):  $\frac{\partial |A \times B|}{\partial X} = |A \times B| (X^{-1})^T = |A \times B| (X^T)^{-1}$

(3):  $\frac{\partial \ln |X|}{\partial X} = \frac{\partial |X| / \partial X}{|X|} = \frac{1}{|X|} \cdot \frac{\partial |X|}{\partial X} = \frac{1}{|X|} \cdot |X| \cdot (X^{-1})^T \Rightarrow$

$\frac{\partial \ln |X|}{\partial X} = (X^{-1})^T$   
 ★ SOS

DERIVATIVES OF INVERSES:

(4)  $\frac{\partial Y^{-1}}{\partial X} = -Y^{-1} \frac{\partial Y}{\partial X} Y^{-1}$

$\frac{\partial a^T X^{-1} b}{\partial X} = -X^{-T} a b^T X^{-T}$   
 ★ SOS

(6)  $\frac{\partial |X^{-1}|}{\partial X} = -|X^{-1}| (X^{-1})^T$

First Order: (7)  $\frac{\partial x^T a}{\partial X} = \frac{\partial a^T x}{\partial X} = a$

(9)  $\frac{\partial a^T X b}{\partial X} = a b^T$  (a)  $\frac{\partial a^T X^T b}{\partial X} = b a^T$

(10)  $\frac{\partial a^T X a}{\partial X} = \frac{\partial a^T X^T a}{\partial X} = a a^T$

Second Order: (11)  $\frac{\partial x^T B x}{\partial X} = (B + B^T) x$

Άσκηση 24: Έστω  $X = \{x_1, \dots, x_N\}$  διανύσματα τα οποία έχουν πηκίφει από δείγματα από μια πολυδιάστατης κανονικής κατανομής με γνωστή μέτρα συνδιακύμανσης  $\Sigma$  και άγνωστο μέσο  $\mu$ . Να ευρεθεί η εκτίμηση μέσης πιθανοφάνειας για τον παράμετρο  $\mu$ .

Η λογαριθμική συνάρτηση πιθανοφάνειας θα δίνεται από την σχέση:

$$L(\underline{\mu}) = \ln \left\{ \prod_{k=1}^N p(x_k; \underline{\mu}) \right\} = \ln \left\{ \prod_{k=1}^N \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \cdot \exp \left[ -\frac{1}{2} (x_k - \underline{\mu})^T \Sigma^{-1} (x_k - \underline{\mu}) \right] \right\} \Leftrightarrow$$

$$L(\underline{\mu}) = \sum_{k=1}^N \ln \left\{ \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \cdot \exp \left[ -\frac{1}{2} (x_k - \underline{\mu})^T \Sigma^{-1} (x_k - \underline{\mu}) \right] \right\} \Leftrightarrow$$

$$L(\underline{\mu}) = \sum_{k=1}^N \ln \left[ \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \right] - \frac{1}{2} \sum_{k=1}^N (x_k - \underline{\mu})^T \Sigma^{-1} (x_k - \underline{\mu}) \Leftrightarrow$$

$$L(\underline{\mu}) = \sum_{k=1}^N \left[ -\frac{1}{2} \ln((2\pi)^d |\Sigma|) - \frac{1}{2} (x_k - \underline{\mu})^T \Sigma^{-1} (x_k - \underline{\mu}) \right] \Leftrightarrow$$

$$L(\underline{\mu}) = -\frac{N}{2} \ln((2\pi)^d |\Sigma|) - \frac{1}{2} \sum_{k=1}^N x_k^T \Sigma^{-1} x_k - 2 \underline{\mu}^T \Sigma^{-1} \sum_{k=1}^N x_k + \underline{\mu}^T \Sigma^{-1} N \underline{\mu}$$

Υπολογίζοντας των συνθήκη πρώτης τάξης έχουμε: (FOC):

$$\frac{\partial L(\underline{\mu})}{\partial \underline{\mu}} = 0$$

$$\frac{\partial L(\underline{\mu})}{\partial \underline{\mu}} = \frac{\partial}{\partial \underline{\mu}} \left[ -\frac{N}{2} \ln((2\pi)^d |\Sigma|) \right] - \frac{1}{2} \sum_{k=1}^N \frac{\partial}{\partial \underline{\mu}} \left[ x_k^T \Sigma^{-1} x_k - 2 \underline{\mu}^T \Sigma^{-1} x_k + \underline{\mu}^T \Sigma^{-1} \underline{\mu} \right] \Leftrightarrow$$

$$\frac{\partial L(\underline{\mu})}{\partial \underline{\mu}} = -\frac{1}{2} \sum_{k=1}^N \frac{\partial}{\partial \underline{\mu}} \left[ x_k^T \Sigma^{-1} x_k \right] - 2 \frac{\partial}{\partial \underline{\mu}} \left[ \underline{\mu}^T \Sigma^{-1} x_k \right] + \frac{\partial}{\partial \underline{\mu}} \left[ \underline{\mu}^T \Sigma^{-1} \underline{\mu} \right] \Leftrightarrow$$

$$\frac{\partial L(\mu)}{\partial \mu} = -\frac{1}{2} * \left\{ \sum_{k=1}^N \left[ -2 \Sigma^{-1} x_k + (\Sigma^{-1} + (\Sigma^{-1})^T) \mu \right] \right\} \Leftrightarrow$$

$$\frac{\partial L(\mu)}{\partial \mu} = -\frac{1}{2} * \sum_{k=1}^N -2 \Sigma^{-1} x_k + 2 \Sigma^{-1} \mu \Leftrightarrow$$

$$\frac{\partial L(\mu)}{\partial \mu} = -\frac{1}{2} * 2 * \sum_{k=1}^N -\Sigma^{-1} x_k + \Sigma^{-1} \mu \Leftrightarrow$$

$$\frac{\partial L(\mu)}{\partial \mu} = + \sum_{k=1}^N \left\{ \Sigma^{-1} * x_k - \Sigma^{-1} * \mu \right\} = \mathbf{0} \Leftrightarrow$$

$$\sum_{k=1}^N \sum_{i=1}^M * (x_k - \mu) = \mathbf{0} \Leftrightarrow$$

Here we multiply by  $\Sigma$  both sides of the equation.

$$\sum_{k=1}^N * \sum_{i=1}^M (x_k - \mu) = \mathbf{0} \Leftrightarrow$$

$$\sum_{k=1}^N (x_k - \mu) = \mathbf{0} \Leftrightarrow \sum_{k=1}^N x_k - N\mu = \mathbf{0} \Leftrightarrow$$

$$\hat{\mu}_{ML} = \frac{1}{N} \sum_{k=1}^N x_k$$

Άσκηση: Έστω  $X = \{x_1, x_2, \dots, x_N\}$  ένα σύνολο διανυσμάτων χαρακτηρισιστικών τα οποία έχουν προκύψει από δειγματοληψία μιας πολυδιάστατης κανονικής κατανομής με άγνωστο μέσο  $\underline{\mu}$  και πίνακα συνδιακύμανσης  $\underline{\Sigma}$ . Να ευρεθούν οι ευχρηστικές μέγιστες πιθανοφάνειας για τις παραμέτρους,  $\hat{\underline{\mu}}$  και  $\hat{\underline{\Sigma}}$ .

#1

Παράβουλας υπόψιν το γεγονός πως η συνάρτηση πυκνότητας πιθανότητας που συνδέεται με την πιθανότητα παρατήρησης του κάθε δείγματος δίνεται από την σχέση:

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

Η συνολική λογαριθμική συνάρτηση πιθανοφάνειας θα δίνεται από την σχέση:

$$L(\underline{\mu}, \underline{\Sigma}) = \ln \left\{ \prod_{k=1}^N p(\underline{x}_k; \underline{\mu}, \underline{\Sigma}) \right\} = \sum_{k=1}^N \ln(p(\underline{x}_k; \underline{\mu}, \underline{\Sigma})) \Leftrightarrow$$

$$L(\underline{\mu}, \underline{\Sigma}) = \sum_{k=1}^N \ln \left\{ \frac{1}{(2\pi)^e |\underline{\Sigma}|^{1/2}} * \exp \left\{ -\frac{1}{2} (\underline{x}_k - \underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}_k - \underline{\mu}) \right\} \right\} \Leftrightarrow$$

$$L(\underline{\mu}, \underline{\Sigma}) = \sum_{k=1}^N -\frac{1}{2} \ln[(2\pi)^e |\underline{\Sigma}|] + \sum_{k=1}^N -\frac{1}{2} (\underline{x}_k - \underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}_k - \underline{\mu}) \Leftrightarrow$$

$$L(\underline{\mu}, \underline{\Sigma}) = -\frac{N}{2} \ln[(2\pi)^e |\underline{\Sigma}|] - \frac{1}{2} \sum_{k=1}^N \underline{x}_k^T \underline{\Sigma}^{-1} \underline{x}_k - 2 \underline{\mu}^T \underline{\Sigma}^{-1} \sum_{k=1}^N \underline{x}_k + \underline{\mu}^T \underline{\Sigma}^{-1} N \underline{\mu} \quad \text{--- 5M} \quad \textcircled{A}$$

$$L(\underline{\mu}, \underline{\Sigma}) = -\frac{N}{2} \{ \ln(2\pi)^e + \ln(|\underline{\Sigma}|) \} - \frac{1}{2} \sum_{k=1}^N \underline{x}_k^T \underline{\Sigma}^{-1} \underline{x}_k - 2 \underline{\mu}^T \underline{\Sigma}^{-1} \sum_{k=1}^N \underline{x}_k + \underline{\mu}^T \underline{\Sigma}^{-1} N \underline{\mu} \Leftrightarrow$$

$$L(\underline{\mu}, \underline{\Sigma}) = -\frac{e \cdot N}{2} \ln(2\pi) - \frac{N}{2} \ln(|\underline{\Sigma}|) - \frac{1}{2} \sum_{k=1}^N \underline{x}_k^T \underline{\Sigma}^{-1} \underline{x}_k - 2 \underline{\mu}^T \underline{\Sigma}^{-1} \sum_{k=1}^N \underline{x}_k + \underline{\mu}^T \underline{\Sigma}^{-1} N \underline{\mu} \quad \text{--- 1M} \quad \textcircled{B}$$

$$L(\underline{\mu}, \underline{\Sigma}) = -\frac{N \cdot e}{2} \ln(2\pi) - \frac{N}{2} \ln(|\underline{\Sigma}|) - \frac{1}{2} \sum_{k=1}^N (\underline{x}_k - \underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}_k - \underline{\mu}) \quad \textcircled{B}$$

#2

Διατύπωση ως συνθήκες πρώτης τάξης (FOC) έχουμε ότι:

$$\left\{ \begin{array}{l} \frac{\partial L(\underline{\mu}, \underline{\Sigma})}{\partial \underline{\mu}} = \underline{\mathbf{0}} \quad (1) \\ \frac{\partial L(\underline{\mu}, \underline{\Sigma})}{\partial \underline{\Sigma}} = \underline{\mathbf{0}} \quad (2) \end{array} \right.$$

Η διατύπωση ως συνθήκες (1) γίνεται καλύτερα από την σχέση (A):

$$\frac{\partial L}{\partial \underline{\mu}} = \frac{\partial}{\partial \underline{\mu}} \left[ -\frac{N}{2} \ln \left( \det(\Sigma) \right) \right] - \frac{1}{2} \frac{\partial}{\partial \underline{\mu}} \left[ \sum_{k=1}^N x_k^T \Sigma^{-1} x_k - 2 \underline{\mu}^T \Sigma^{-1} x_k + \underline{\mu}^T \Sigma^{-1} \underline{\mu} \right] \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\mu}} = -\frac{1}{2} \sum_{k=1}^N \frac{\partial}{\partial \underline{\mu}} \left[ x_k^T \Sigma^{-1} x_k \right] - 2 \frac{\partial}{\partial \underline{\mu}} \left[ \underline{\mu}^T \Sigma^{-1} x_k \right] + \frac{\partial}{\partial \underline{\mu}} \left[ \underline{\mu}^T \Sigma^{-1} \underline{\mu} \right] \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\mu}} = -\frac{1}{2} \sum_{k=1}^N -2 \Sigma^{-1} x_k + (\Sigma^{-1} + (\Sigma^{-1})^T) \underline{\mu} \Leftrightarrow \Sigma^{-1} = (\Sigma^{-1})^T \quad \underline{\text{ΣΥΜΜΕΤΡΙΚΟΣ}}$$

$$\frac{\partial L}{\partial \underline{\mu}} = -\frac{1}{2} \sum_{k=1}^N -2 \Sigma^{-1} x_k + 2 \Sigma^{-1} \underline{\mu} \Leftrightarrow \frac{\partial L}{\partial \underline{\mu}} = \sum_{k=1}^N \Sigma^{-1} x_k - \Sigma^{-1} \underline{\mu} \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\mu}} = \Sigma^{-1} * \sum_{k=1}^N (x_k - \underline{\mu}) = \underline{\mathbf{0}} \quad * \Sigma \text{ (both hand sides)}$$

$$\Sigma \cdot \Sigma^{-1} \cdot \sum_{k=1}^N (x_k - \underline{\mu}) = \underline{\Sigma} \cdot \underline{\mathbf{0}} \Leftrightarrow$$

$$\sum_{k=1}^N (x_k - \underline{\mu}) = \underline{\mathbf{0}} \Leftrightarrow$$

$$\sum_{k=1}^N x_k - N \underline{\mu} = \underline{\mathbf{0}} \Leftrightarrow \hat{\underline{\mu}}_{ML} = \frac{1}{N} \sum_{k=1}^N x_k$$

#3 Η διατήρηση της συνθήκης (2) γίνεται καλύτερα από την σχέση (3):

$$\frac{\partial L}{\partial \underline{\Sigma}} = \frac{\partial}{\partial \underline{\Sigma}} \left[ -\frac{N}{2} \ln |\underline{\Sigma}| \right] - \frac{1}{2} \frac{\partial}{\partial \underline{\Sigma}} \sum_{k=1}^N (x_k - \mu)^T \underline{\Sigma}^{-1} (x_k - \mu) \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\Sigma}} = -\frac{N}{2} \cdot \frac{\partial \ln |\underline{\Sigma}|}{\partial \underline{\Sigma}} - \frac{1}{2} \sum_{k=1}^N \frac{\partial (x_k - \mu)^T \underline{\Sigma}^{-1} (x_k - \mu)}{\partial \underline{\Sigma}} \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\Sigma}} = -\frac{N}{2} \cdot \underline{\Sigma}^{-1} - \frac{1}{2} \sum_{k=1}^N -\underline{\Sigma}^{-1} (x_k - \mu)(x_k - \mu)^T \underline{\Sigma}^{-1} \Leftrightarrow$$

$$\frac{\partial L}{\partial \underline{\Sigma}} = -N \underline{\Sigma}^{-1} + \underline{\Sigma}^{-1} * \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T * \underline{\Sigma}^{-1} = \underline{\mathbb{0}} \Leftrightarrow$$

$$N \underline{\Sigma}^{-1} = \underline{\Sigma}^{-1} * \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T * \underline{\Sigma}^{-1} \Rightarrow$$

$$N = \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T \underline{\Sigma}^{-1} \Leftrightarrow$$

$$N \cdot \underline{\Sigma} = \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T \Rightarrow \hat{\underline{\Sigma}}_{ML} = \frac{1}{N} \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T$$

Άσκηση: Έστω ένα πείραμα είψης νομισματός η πιθανότητα εμφάνισης κεφαλής (head) ( $\Omega$ ) είναι  $q$  ενώ η πιθανότητα εμφάνισης γραφηγίων (tails) ( $\bar{\Omega}$ ) είναι  $1-q$ . Έστω  $X = \{x_1, x_2, \dots, x_N\}$  το σύνολο που περιγράφει την έκβαση  $N$  πειραμάτων με  $x_i \in \{0, 1\}, \forall i \in \{1, 2, \dots, N\}$ .

# 4

Να δείξετε ότι ο επιθυμής μέσιος πιθανοφανής για την πιθανότητα εμφάνισης κεφαλής δίνεται από την σχέση:

$$\hat{q}_{ML} = \frac{1}{N} \sum_{k=1}^N x_k$$

⊛ Υπόδειξη: Η συνάρτηση πιθανοφάνειας δίνεται από την σχέση:

$$p(x; q) = \prod_{k=1}^N q^{x_k} \cdot (1-q)^{(1-x_k)}$$

⊛ Σχηματίζουμε την λογαριθμική συνάρτηση πιθανοφάνειας:

$$L(q) = \ln \left[ \prod_{k=1}^N q^{x_k} (1-q)^{(1-x_k)} \right] \Leftrightarrow$$

$$L(q) = \sum_{k=1}^N \ln \left[ q^{x_k} (1-q)^{(1-x_k)} \right] \Leftrightarrow$$

$$L(q) = \sum_{k=1}^N \ln(q^{x_k}) + \ln(1-q)^{(1-x_k)} \Leftrightarrow$$

$$L(q) = \sum_{k=1}^N x_k \ln(q) + \sum_{k=1}^N (1-x_k) \ln(1-q) \Leftrightarrow$$

$$L(q) = \ln(q) \sum_{k=1}^N x_k + \ln(1-q) \sum_{k=1}^N (1-x_k)$$



$$\frac{\partial L}{\partial q} = \sum_{k=1}^N x_k \cdot \frac{\partial (\ln q)}{\partial q} + \sum_{k=1}^N (1-x_k) \cdot \frac{\partial (\ln(1-q))}{\partial q} \quad \Leftrightarrow$$

#5

$$\frac{\partial L}{\partial q} = \sum_{k=1}^N x_k \cdot \frac{1}{q} + \sum_{k=1}^N (1-x_k) \cdot \frac{\partial (1-q)/\partial q}{1-q} \quad \Leftrightarrow$$

$$\frac{\partial L}{\partial q} = \sum_{k=1}^N x_k \cdot \frac{1}{q} + \sum_{k=1}^N (1-x_k) \frac{-1}{1-q} = 0 \quad \Leftrightarrow$$

$$\frac{1}{q} * \sum_{k=1}^N x_k - \frac{1}{1-q} \sum_{k=1}^N (1-x_k) = 0 \quad \Leftrightarrow$$

$$\frac{1}{q} \sum_{k=1}^N x_k - \frac{1}{1-q} * \left\{ \sum_{k=1}^N 1 - \sum_{k=1}^N x_k \right\} = 0 \quad \Leftrightarrow$$

$$\frac{1}{q} \sum_{k=1}^N x_k - \frac{1}{1-q} * \left\{ N - \sum_{k=1}^N x_k \right\} = 0$$

$$\sum_{k=1}^N x_k = S$$

$$\frac{1}{q} * S - \frac{1}{1-q} \{ N - S \} = 0 \quad \Leftrightarrow$$

$$\frac{S}{q} - \frac{N}{1-q} + \frac{S}{1-q} = 0 \quad \Leftrightarrow$$

$$\frac{S(1-q)}{q(1-q)} - \frac{N \cdot q}{(1-q) \cdot q} + \frac{S \cdot q}{q(1-q)} = 0 \quad \Leftrightarrow$$

$$\frac{-Nq + S(1-q) + Sq}{q(1-q)} = 0 \quad \Leftrightarrow$$

$$\frac{-Nq + S - Sq + Sq}{q(1-q)} = 0 \quad \Leftrightarrow$$

$$Nq = S \Rightarrow \hat{q} = \frac{S}{N} \Rightarrow$$

$$\hat{q} = \frac{1}{N} \sum_{k=1}^N x_k$$