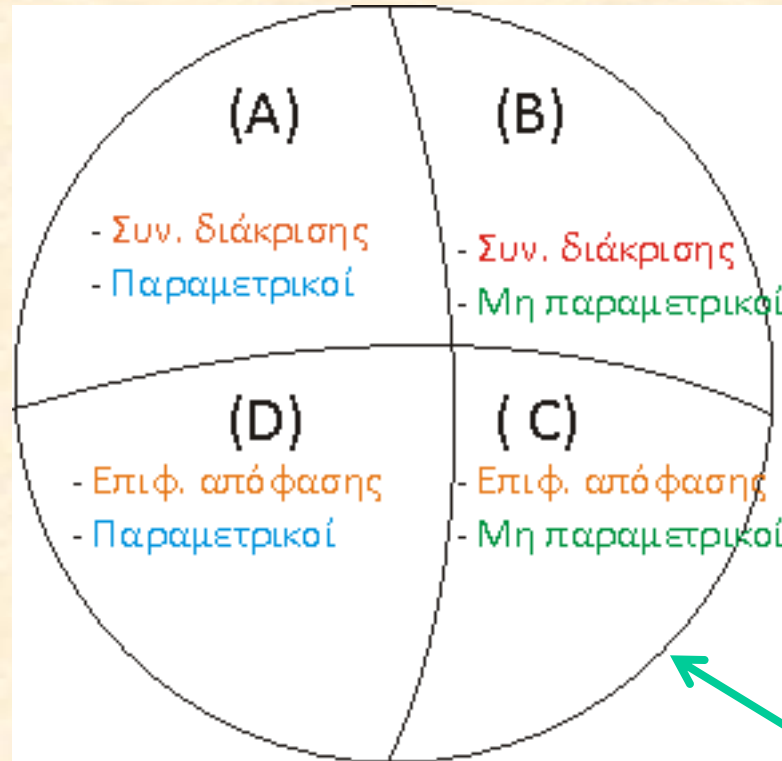


❖ ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ ❖ (PATTERN RECOGNITION)

Σέργιος Θεοδωρίδης
Κωνσταντίνος Κουτρούμπας




(C) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΕΠΙΦΑΝΕΙΕΣ ΑΠΟΦΑΣΗΣ

Υπενθύμιση: X είναι το σύνολο δεδομένων που περιέχει τα διαθέσιμα δεδομένα από όλες τις κλάσεις.

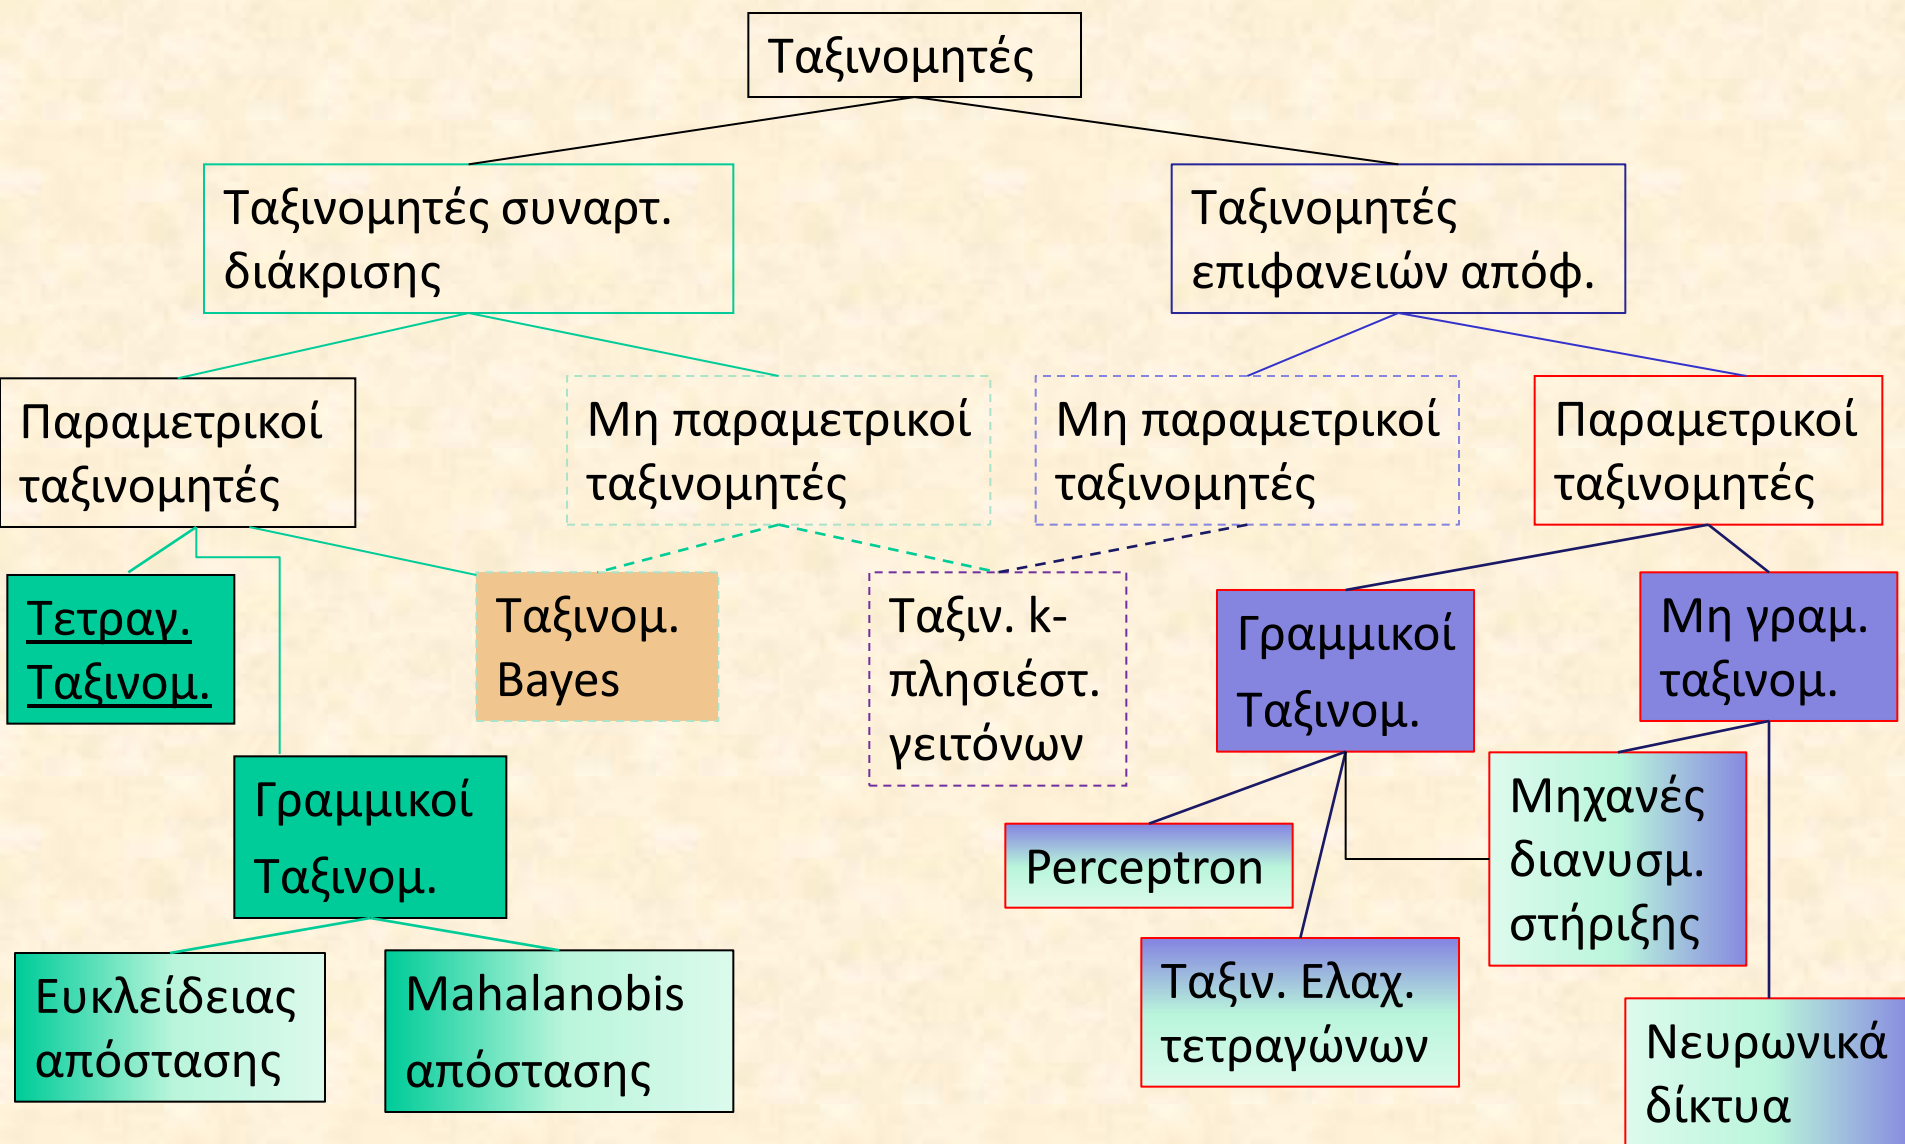
X_j είναι το υποσύνολο του X που περιέχει τα δεδομένα από την κλάση ω_j , $X = X_1 \cup \dots \cup X_M$

• Στην περίπτωση αυτή οι επιφάνειες απόφασης ορίζονται έμμεσα μέσω των σημείων του X .

• Για παράδειγμα ο ταξινομητής πλησιέστερου γείτονα διαχωρίζει το χώρο των χαρακτηριστικών με βάση την ψηφοθέτηση Voronoi (Voronoi tessellation)



“ΧΑΡΤΟΓΡΑΦΗΣΗ” ΤΟΥ ΧΩΡΟΥ ΤΩΝ ΤΑΞΙΝΟΜΗΤΩΝ



“ΧΑΡΤΟΓΡΑΦΗΣΗ” ΤΟΥ ΧΩΡΟΥ ΤΩΝ ΤΑΞΙΝΟΜΗΤΩΝ

Υπενθ.: X είναι το σύνολο των δεδομένων σημείων όλων των κλάσεων

X_j είναι το υποσύνολο του X που περιέχει τα διανύσματα της κλάσης ω_j ,

$$X = X_1 \cup \dots \cup X_M$$

Ταξινομητές με βάση τις συναρτήσεις διάκρισης

Ταξινομ. Bayes

- $g_j(x) = f(P(\omega_j)p(x|\omega_j))$
- Εκτιμ. $p(x|\omega_j) \approx \hat{p}(x|\omega_j; \mathcal{G}_j)$
- Εκτιμ. \mathcal{G}_j , με βάση το X_j
- $(ML, EM): X_j \rightarrow \hat{\mathcal{G}}_j$
- $x_i \rightarrow p(x_i|\omega_j) \approx \hat{p}(x_i|\omega_j; \hat{\mathcal{G}}_j)$

Τετραγωνικός
ταξινομητής

- $g_j(x) = (x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j)$
- Υπόθεση: $N(\mu_j, \Sigma_j)$
- Εκτιμ. μ_j, Σ_j , με βάση το X_j
- $(ML): X_j \rightarrow \hat{\mu}_j, \hat{\Sigma}_j$
- $x_i \rightarrow g_j(x_i) = (x_i - \hat{\mu}_j)^T \hat{\Sigma}_j^{-1} (x_i - \hat{\mu}_j)$

Γραμμικός
Ευκλείδειος
ταξινομητής

- $g_j(x) = (x - \mu_j)^T (x - \mu_j)$
- Υπόθεση: $N(\mu_j, I)$
- Εκτίμ. μ_j , με βάση το X_j
- $(ML): X_j \rightarrow \hat{\mu}_j$
- $x_i \rightarrow g_j(x_i) = (x_i - \hat{\mu}_j)^T (x_i - \hat{\mu}_j)$

Γραμμικός
Mahalanobis
ταξινομητής

- $g_j(x) = (x - \mu_j)^T \Sigma^{-1} (x - \mu_j)$
- Υπόθεση: $N(\mu_j, \Sigma)$
- Εκτίμ. μ_j, Σ , με βάση το X_j
- $(ML): X_j \rightarrow \hat{\mu}_j, \hat{\Sigma}$
- $x_i \rightarrow g_j(x_i) = (x_i - \hat{\mu}_j)^T \hat{\Sigma}^{-1} (x_i - \hat{\mu}_j)$

“ΧΑΡΤΟΓΡΑΦΗΣΗ” ΤΟΥ ΧΩΡΟΥ ΤΩΝ ΤΑΞΙΝΟΜΗΤΩΝ

Υπενθ.: X είναι το σύνολο των δεδομένων σημείων όλων των κλάσεων

X_j είναι το υποσύνολο του X που περιέχει τα διανύσματα της κλάσης ω_j ,

$$X = X_1 \cup \dots \cup X_M$$

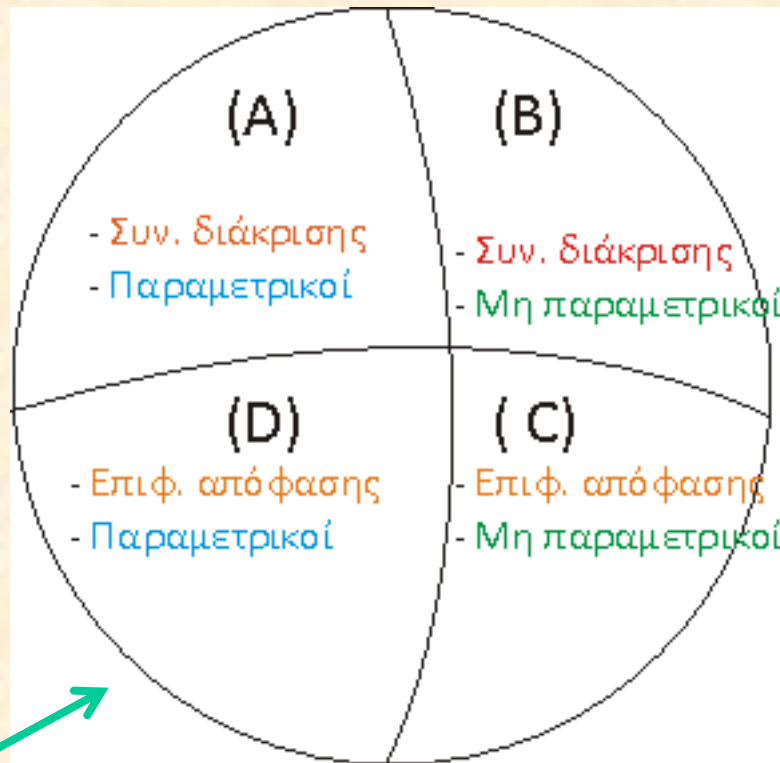
Μη παραμετρικοί ταξινομητές με βάση τις συναρτήσεις διάκρισης

Ταξινομητής
Bayes

– $g_j(x) = f(P(\omega_j)p(x|\omega_j))$
– $x_i \rightarrow p(x_i|\omega_j) \approx \hat{p}(x_i|\omega_j; X_j)$
(παράθυρα Parzen,
εκτίμ. πυκν. βάσει των k -πλησ. γειτ.)

Ταξινομητής k -
πλησιέστερων
γειτόνων

$$- x_i \rightarrow g_j(x_i) = k_i^j$$



ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Μερικά προκαταρκτικά:

- Στην πράξη έχουμε στη διάθεσή μας ένα σύνολο δεδομένων (σύν. 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 η l -διάστατη αναπαράσταση του i -στού από τις N οντότητες

(διάνυσμα εκπαίδευσης)

d_i είναι η ετικέτα της κλάσης όπου ανήκει το x_i (1 για την ω_1 , 2 για την ω_2, \dots).

- Εστιάζουμε κυρίως στην περίπτωση των δύο κλάσεων.

- Δεν υιοθετούμε καμία υπόθεση σχετικά με τις pdfs που μοντελοποιούν τις διάφορες κλάσεις.

- Αναζητούμε την επιφάνεια (γραμμική ή μη γραμμική) που επιτυγχάνει τον “βέλτιστο” διαχωρισμό των (διανυσμάτων δεδομένων των) κλάσεων.

ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Επιφάνεια απόφασης (C): Περιγράφεται από εξίσωση της μορφής $h(\mathbf{x})=0$, ή $h(\mathbf{x};\mathbf{w})=0$, όπου \mathbf{w} είναι το διάνυσμα των παραμέτρων που ορίζουν την επιφάνεια (C).

Παραδείγματα:

1. Αν η (C) είναι **καμπύλη 1^{ου} βαθμού** (υπερεπίπεδο – γραμμικός διαχωρισμός), τότε

$$h(x; w) = w_1 x_1 + \dots + w_l x_l + w_0 = \sum_{k=1}^l w_k x_k + w_0 = \mathbf{w}^T \mathbf{x} + w_0 = 0$$

όπου $\mathbf{w}=[w_1, \dots, w_l]^T$, $\mathbf{x}=[x_1, \dots, x_l]^T$. Οι παράμετροι είναι το διάνυσμα \mathbf{w} και το w_0 .

2. Αν η (C) είναι **καμπύλη 2^{ου} βαθμού** (π.χ. Υπερέλλειψη – μη γραμμικός διαχωρισμός), τότε

$$h(x; w) = \sum_{k=1}^l \sum_{q=k}^l w_{kq} x_k x_q + \sum_{k=1}^l w_k x_k + w_0 = 0$$

όπου $\mathbf{w}=[w_0, w_1, \dots, w_l, w_{11}, \dots, w_{1l}, w_{22}, \dots, w_{2l}, \dots, w_{ll}]^T$

Σημείωση: Σε αρκετούς μη γραμμικούς ταξινομητές (π.χ. στα νευρωνικά δίκτυα) η μορφή της (C) δεν μπορεί να εκφραστεί άμεσα (explicitly).

ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Υπόθεση: Αν δεν ορίζεται διαφορετικά, θεωρούμε την περίπτωση των **δύο κλάσεων**, δηλ., $\omega_1 (+1)$ και $\omega_2 (-1)$.

Ορισμός προβλήματος: Δοθέντος ενός συνόλου δεδομένων X προσδιόρισε μία **επιφάνεια** που επιτυγχάνει το **“βέλτιστο” δυνατό διαχωρισμό** των (διανυσμάτων των) δύο κλάσεων.

Στρατηγική αντιμετώπισης του προβλήματος:

1. Υιοθέτησε μια **συγκεκριμένη** (“άμεση” ή “έμμεση”) **παραμετρική μορφή** για την επιφάνεια $h(\mathbf{x}; \mathbf{w})=0$.
2. Όρισε κατάλληλη συνάρτηση (**συνάρτηση κόστους - cost function**) του \mathbf{w} , $J(\mathbf{w})$, η οποία περιλαμβάνει επίσης τα διανύσματα του X , έτσι ώστε **τα βέλτιστά της (ελάχιστα ή μέγιστα) να αντιστοιχούν στις καλύτερες δυνατές επιφάνειες για το υπό μελέτη πρόβλημα**.
3. Βελτιστοποίησε την $J(\mathbf{w})$ ως προς το \mathbf{w} . Η θέση του βέλτιστου αυτής ορίζει την επιφάνεια απόφασης.

Σημαντική παρατήρηση: Το νόημα της φράσης **“βέλτιστη δυνατή καμπύλη”** διαφέρει για **διαφορετικές επιλογές της $J(\mathbf{w})$** .

ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Έστω $J(w)$ συνεχής συνάρτηση του w .

Πρόβλημα (P1): Προσδιόρισε τη **θέση w^*** όπου η συνάρτηση $J(w)$ λαμβάνει την **ελάχιστη** τιμή της.

Μια απλή μέθοδος για την επίλυση του **(P1)** είναι αυτή της **οξύτερης καθόδου (gradient descent - GD)**.

- Αρχικοποίησε $w=w(0)$

- $t=0$


- Επανάλαβε

$$- w(t+1) = w(t) - \mu \frac{\partial J(w)}{\partial w} \Big|_{w=w(t)}$$

- $t=t+1$

- Έως ότου επιτευχθεί σύγκλιση

ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ



ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ


-Ένα παράδειγμα: Έστω $\mathbf{w}=[w_1, w_2]^T$ και $J(\mathbf{w})=(w_1-1)^2+(w_1-1)^2$. Είναι σαφές ότι η $J(\mathbf{w})$ λαμβάνει την ελάχιστη τιμή της στο $\mathbf{w}^*=[1, 1]^T$.

-Είναι
$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = \begin{bmatrix} 2w_1 - 2 \\ 2w_2 - 2 \end{bmatrix}$$


-Εφαρμόζοντας τον αλγόριθμο GD για $\mathbf{w}(0)=[0, 5]^T$, και $\mu=0.1$, έχουμε

$$\mathbf{w}(1) = \begin{bmatrix} 0 \\ 5 \end{bmatrix} - 0.1 \begin{bmatrix} -2 \\ 8 \end{bmatrix} = \begin{bmatrix} 0.2 \\ 4.2 \end{bmatrix}$$

-Βλέπουμε ότι το $\mathbf{w}(1)$ βρίσκεται εγγύτερα στο \mathbf{w}^* .




ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ



ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Σχόλια για τον αλγόριθμο GD:

- Η τιμή του μ πρέπει να είναι **όχι πολύ μεγάλη**, ώστε να αποφεύγονται ταλαντώσεις γύρω από το ελάχιστο της συνάρτησης και **όχι πολύ μικρή**, ώστε να αποφεύγονται άσκοπες καθυστερήσεις στη σύγκλιση.
- Αν η $J(\mathbf{w})$ έχει **περισσότερα από ένα ελάχιστα**, ο αλγόριθμος GD θα συγκλίνει (γενικά) σε εκείνο που βρίσκεται εγγύτερα στο $\mathbf{w}(0)$.
- Αν ο αλγόριθμος παγιδευτεί σε ένα **τοπικό ελάχιστο που αντιστοιχεί σε μια “κακή” λύση**, ο μόνος τρόπος για να το **αποφύγουμε** είναι να **επανεκκινήσουμε** τον αλγόριθμο από μια διαφορετική αρχική θέση.
- Μπορεί να αποδειχθεί ότι, κάτω από κάποιες συνθήκες, ο αλγόριθμος **συγκλίνει ασυμπτωτικά** σε ένα **τοπικό ελάχιστο** της $J(\mathbf{w})$.



ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Έστω $J(\mathbf{w})$ μια συνεχής συνάρτηση του \mathbf{w} .

Πρόβλημα (P2): Προσδιόρισε τη **θέση \mathbf{w}^*** όπου η συνάρτηση $J(\mathbf{w})$ λαμβάνει την **ελάχιστη** τιμή της, υπό την προϋπόθεση ότι το \mathbf{w} ικανοποιεί μερικούς **περιορισμούς ισότητας (equality constraints)**.

Για **γραμμικούς περιορισμούς ισότητας**, το πρόβλημα διατυπώνεται ως εξής

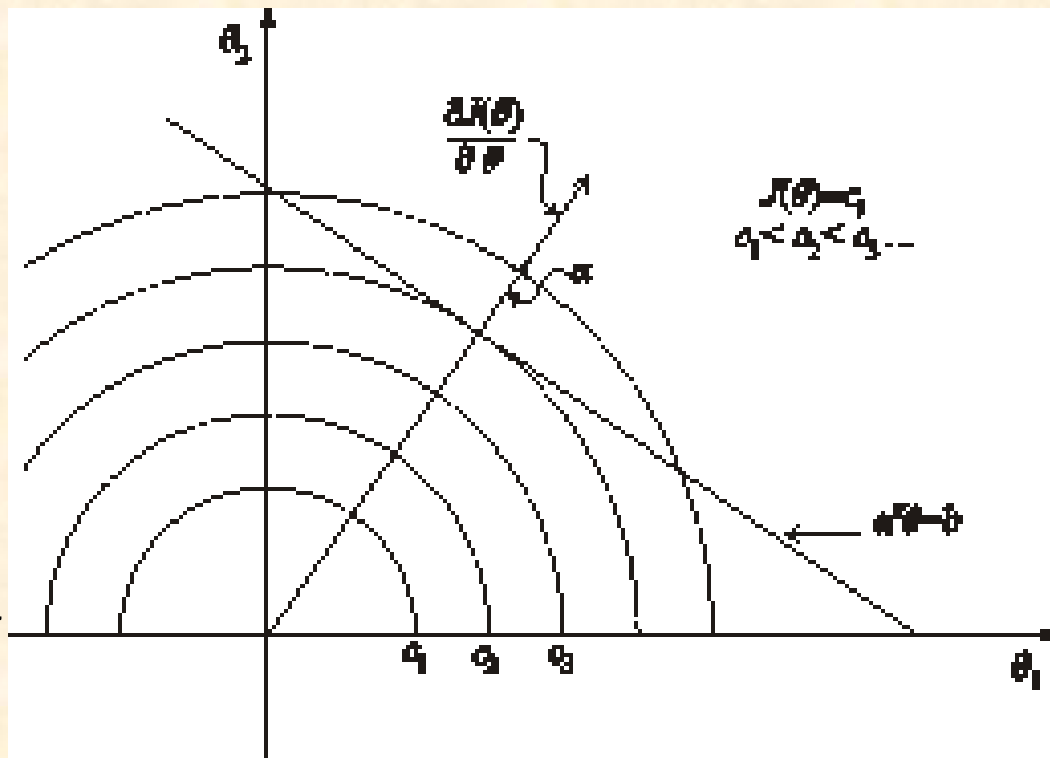
- Ελαχιστοποίησε την $J(\mathbf{w})$
- Υπό τους περιορισμούς $A\mathbf{w}=\mathbf{b}$, όπου A ένας $m \times l$ πίνακας και \mathbf{b} ένα m -διάστατο διάνυσμα.

Λύση: Πολ/στές Lagrange

Ελαχιστοποίησε την

$$-L(\mathbf{w})=J(\mathbf{w})+\boldsymbol{\lambda}^T(A\mathbf{w}-\mathbf{b})$$

- $\boldsymbol{\lambda}$ είναι ένα m -διάστατο διάνυσμα που εκτιμάται μέσω των περιορισμών $A\mathbf{w}=\mathbf{b}$




ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Έστω $J(\mathbf{w})$ μια συνεχής συνάρτηση του \mathbf{w} .

Πρόβλημα (P3): Προσδιόρισε τη **θέση \mathbf{w}^*** όπου η συνάρτηση $J(\mathbf{w})$ λαμβάνει την **ελάχιστη** τιμή της, υπό τις την προϋπόθεση ότι το \mathbf{w} ικανοποιεί μερικούς **περιορισμούς ανισότητας**.

Για **γραμμικούς περιορισμούς ανισότητας**, το πρόβλημα διατυπώνεται ως εξής

- Ελαχιστοποίησε την $J(\mathbf{w})$
- Υπό τους περιορισμούς $A\mathbf{w} \geq \mathbf{b}$, όπου A ένας $m \times l$ πίνακας και \mathbf{b} ένα m -διάστατο διάνυσμα.



ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

- Στην περίπτωση αυτή η επιφάνεια είναι ένα **υπερεπίπεδο** (H) της μορφής

$$(H) : h(x; w) = w_1 x_1 + \dots + w_l x_l + w_0 = \sum_{k=1}^l w_k x_k + w_0 = w^T x + w_0 = 0$$

όπου $w = [w_1, \dots, w_l]^T$, $x = [x_1, \dots, x_l]^T$

- Το (H) ορίζεται πλήρως από τα w και w_0 .

- Μερικά στοιχεία από τη Γεωμετρία:

- Το διάνυσμα w είναι **κάθετο** στο (H).


- Το w ορίζει τον **προσανατολισμό** (orientation) του (H).

- Όλα τα **υπερεπίπεδα** που είναι **παράλληλα** με το (H) έχουν τον **ίδιο προσανατολισμό** με αυτό.

- Το w είναι **κάθετο** σε **όλα** τα **υπερεπίπεδα** που είναι **παράλληλα** με το (H).

- Το w_0 είναι η παράμετρος που **ταυτοποιεί μοναδικά** ένα συγκεκριμένο υπερεπίπεδο, ανάμεσα από υπερεπίπεδα ίδιου προσανατολισμού.

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ



$$d = \frac{|w_0|}{\sqrt{w_1^2 + w_2^2}}, \quad z = \frac{|g(\underline{x})|}{\sqrt{w_1^2 + w_2^2}}$$