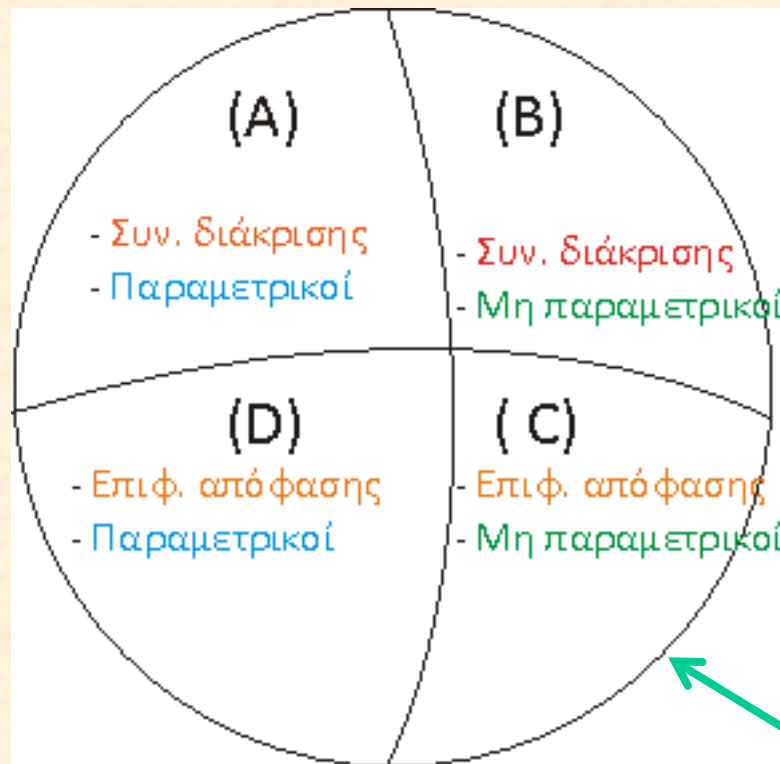


ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ (PATTERN RECOGNITION)

Σέργιος Θεοδωρίδης
Κωνσταντίνος Κουτρούμπας

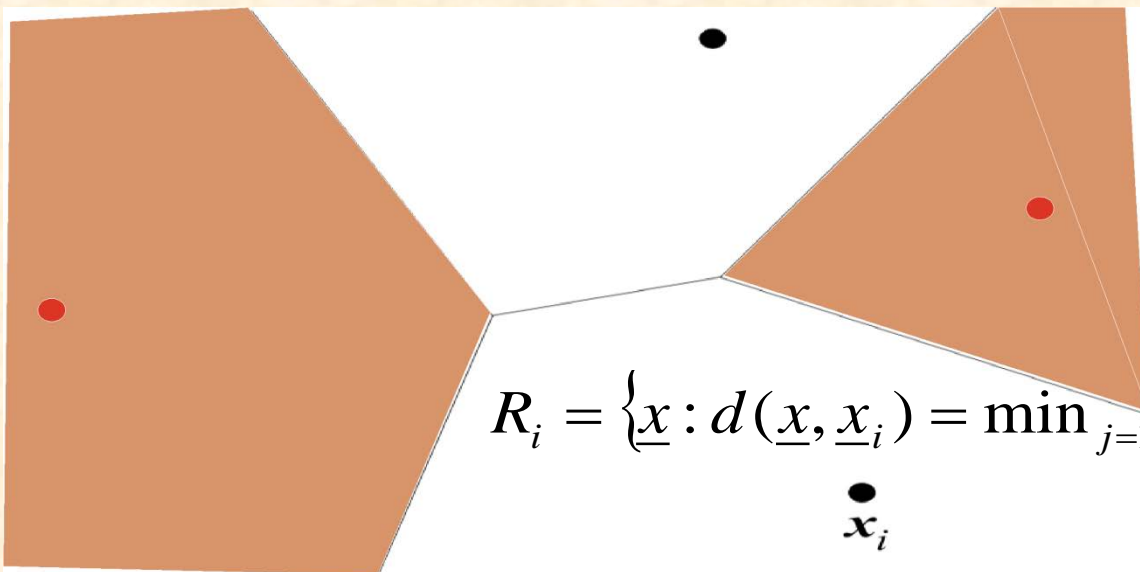


(C) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΕΠΙΦΑΝΕΙΕΣ ΑΠΟΦΑΣΗΣ

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

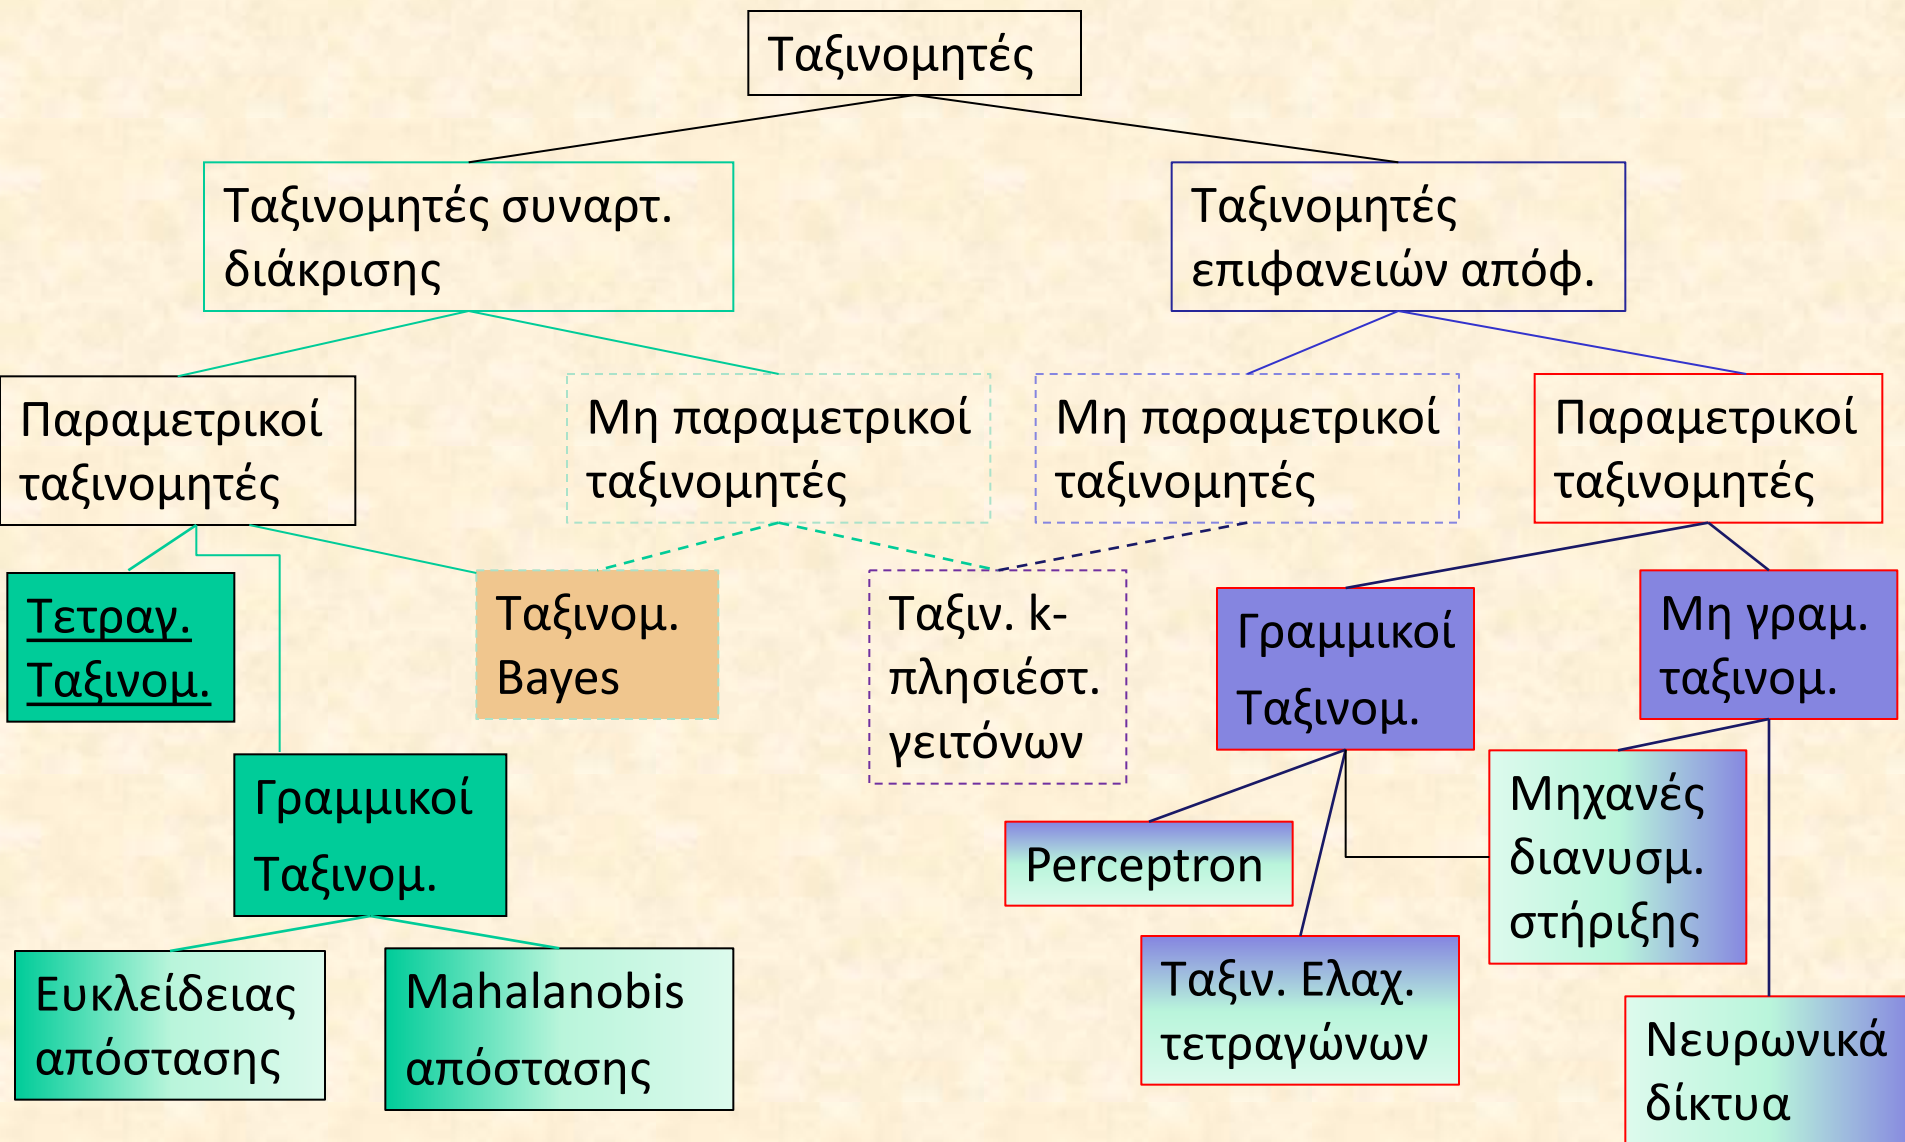
X_j είναι το υποσύνολο του X που περιέχει τα δεδομένα από την κλάση ω_j , $X = X_1 \cup \dots \cup X_M$

- 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)



Για Ευκλείδεια απόσταση

“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 ,

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

Παραμετρικοί ταξινομητές με βάση τις συναρτήσεις διάκρισης

Ταξινομ. Bayes

- $g_j(x) = f(P(\omega_j) p(x|\omega_j))$
- Υπόθ.: $p(x|\omega_j) \approx \hat{p}(x|\omega_j; \theta_j)$
- Εκτίμ. θ_j με βάση το X_j
(ML, EM): $X_j \rightarrow \hat{\theta}_j$
- $x \rightarrow g_j(x) = f(P(\omega_j) \hat{p}(x|\omega_j; \theta_j))$

Τετραγωνικός
ταξινομητής

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

Γραμμικός
Ευκλείδειος
ταξινομητής

- $g_j(x) = -(x - \mu_j)^T (x - \mu_j)$
- Υπόθ.: $N(\mu_j, \sigma^2 I)$
- Εκτίμ. μ_j με βάση το X_j
(ML): $X_j \rightarrow \hat{\mu}_j$
- $x \rightarrow g_j(x) = (x - \hat{\mu}_j)^T (x - \hat{\mu}_j)$

Γραμμικός
Mahalanobis
ταξινομητής

- $g_j(x) = -(x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j)$
- Υπόθ.: $N(\mu_j, \Sigma)$
- Εκτίμ. μ_j, Σ_j με βάση το X_j
(ML): $X_j \rightarrow \hat{\mu}_j, \hat{\Sigma}_j$
- Εκτίμ. Σ με βάση τα $\hat{\Sigma}_j$
(π.χ. $\hat{\Sigma} = \frac{1}{M} \sum_{j=1}^M \hat{\Sigma}_j$)
- $x \rightarrow g_j(x) = (x - \hat{\mu}_j)^T \hat{\Sigma}^{-1} (x - \hat{\mu}_j)$

“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

- $g_j(x) = f(P(\omega_j) p(x|\omega_j))$
- $x_i \rightarrow$ Εκτίμ. $p(x|\omega_j) \approx \hat{p}(x|\omega_j; X_j)$
(Παρ. Parzen, k -NN εκτ. πυκν. πιθ.)
- $x \rightarrow g_j(x) = f(P(\omega_j) \hat{p}(x|\omega_j; X_j))$

Ταξινομητής k -
πλησιέστερων
γειτόνων

$$-x \rightarrow g_j(x_i) = k^j$$



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

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

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 $J(\mathbf{w})=(w_1-1)^2+(w_2-1)^2$. 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 $A\mathbf{w}=\mathbf{b}$



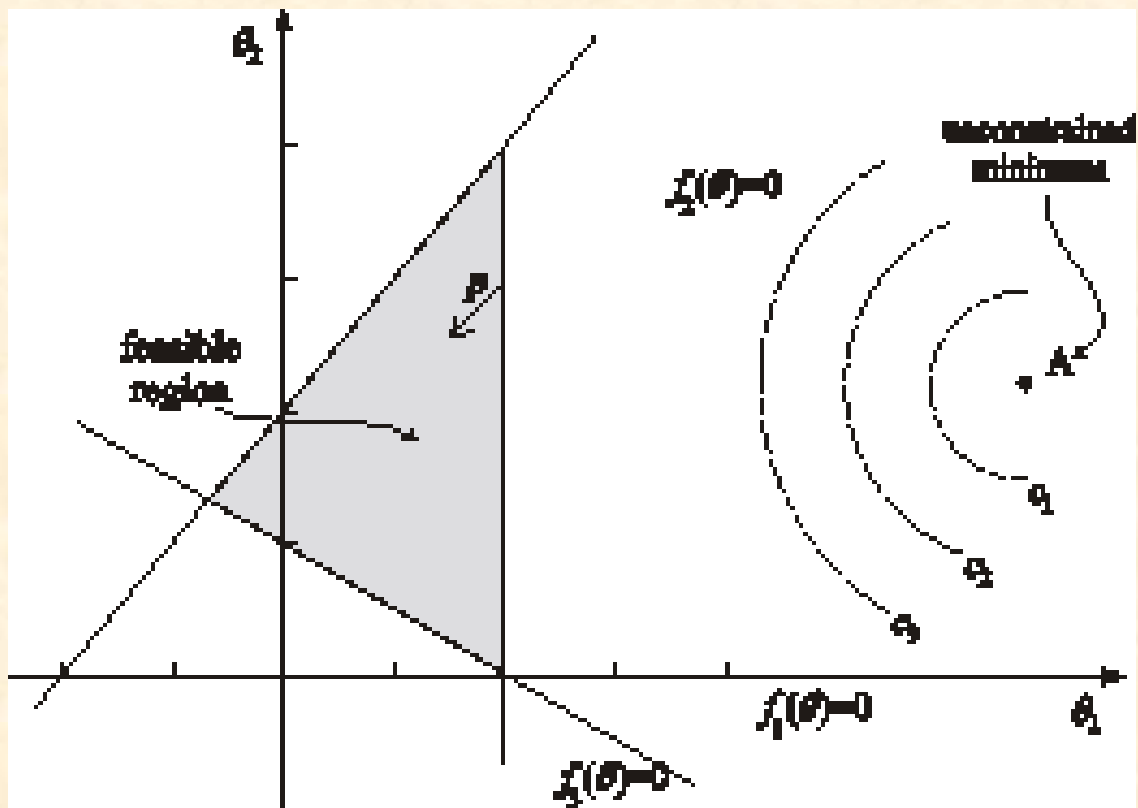
ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΘΕΩΡΙΑΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

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

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

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

- Το **(H)** ορίζεται πλήρως από τα **w** και **w₀**.

- 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 **w₀** είναι η παράμετρος που **ταυτοποιεί μοναδικά** ένα συγκεκριμένο υπερεπίπεδο, ανάμεσα στα υπερεπίπεδα ίδιου προσανατολισμού.

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ



$$d = \frac{|w_0|}{\sqrt{w_1^2 + w_2^2}}, \quad z = \frac{|g(x)|}{\sqrt{w_1^2 + w_2^2}} \quad g(x) = w_1x_1 + w_2x_2 + w_0$$

Γενικά

$$g(x) = w_1x_1 + \dots + w_lx_l + w_0$$

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

ΜΙΑ ΣΥΜΒΑΣΗ: Προκειμένου να καταστήσουμε πιο συμπαγή το συμβολισμό

$$(H) : w^T x + w_0 = 0$$

ορίζουμε

$$w^* = [w^T, w_0]^T \text{ and } x^* = [x^T \ 1]^T.$$

Έτσι έχουμε

$$(H) : w^{*T} x^* = 0$$

ΣΗΜΕΙΩΣΗ: Στη συνέχεια, εκτός αν ορίζεται διαφορετικά, θα γράφουμε w και x , εννοώντας τα w^* και x^* , αντίστοιχα.

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

Υπόθεση: (Τα διανύσματα των) δύο κλάσεων ω_1 και ω_2 είναι γραμμικώς διαχωρίσιμα.


Έτσι, υπάρχει ένα υπερεπίπεδο (H^*): $\mathbf{w}^{*T}\mathbf{x}=0$, ώστε

$$\mathbf{w}^{*T} \mathbf{x} > 0, \quad \forall \mathbf{x} \in \omega_1$$

$$\mathbf{w}^{*T} \mathbf{x} < 0, \quad \forall \mathbf{x} \in \omega_2$$

Το κριτήριο στο perceptron: Προσδιόρισε ένα υπερεπίπεδο το οποίο διαχωρίζει τέλεια τα διανύσματα από τις δύο κλάσεις.

ΣΗΜΕΙΩΣΗ: Αν οι κλάσεις είναι γραμμικώς διαχωρίσιμες, υπάρχουν άπειρα υπερεπίπεδα που ικανοποιούν το κριτήριο perceptron.



ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

Η συνάρτηση κόστους:

$$J(\underline{w}) = \sum_{x \in Y(\underline{w})} (\delta_x \underline{w}^T x)$$

όπου

- $Y(\underline{w})$ το σύνολο των **λανθασμένα ταξινομημένων** διανυσμάτων από το \underline{w} και

$$\begin{aligned} \delta_x &= -1 \text{ if } x \in \omega_1 \\ \delta_x &= +1 \text{ if } x \in \omega_2 \end{aligned}$$

Σημειώσεις:

- Είναι $J(\underline{w}) \geq 0$.

Πράγματι, αν $x \in Y(\underline{w})$ και $x \in \omega_1$ τότε $\underline{w}^T x < 0$ και $\delta_x = -1$. Επομένως $\delta_x \underline{w}^T x > 0$.

Επίσης, αν $x \in Y(\underline{w})$ και $x \in \omega_2$ τότε $\underline{w}^T x > 0$ και $\delta_x = +1$. Επομένως $\delta_x \underline{w}^T x > 0$.


- Είναι $J(\underline{w}) = 0$ μόνον όταν $Y = \emptyset$, πράγμα που σημαίνει ότι προσδιορίστηκε **μία λύση που ικανοποιεί το κριτήριο perceptron**.

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

Η συνάρτηση κόστους:

Η $J(w)$ είναι τμηματικά γραμμική (piecewise linear) (γιατί;)



Η **ελαχιστοποίηση** της $J(w)$ επιτυγχάνεται μέσω διαδικασίας που ακολουθεί τη φιλοσοφία της **GD**.

Όπου είναι έγκυρο, ορίζουμε
$$\frac{\partial J(w)}{\partial w} = \frac{\partial}{\partial w} \left(\sum_{x \in Y(w)} \delta_x w^T x \right) = \sum_{x \in Y(w)} \delta_x x$$

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

- Αρχικοποίησε $w=w(0)$

- $t=0$

- Επανάλαβε

- Προσδιόρισε τα **λανθασμένα ταξινομημένα διανύσματα** του X από το $w(t)$ και συσσωρεύσέ τα στο $Y(w_t)$.

$$w(t+1) = w(t) - \rho_t \sum_{x \in Y(w_t)} \delta_x x$$

- $t=t+1$

- Έως ότου επιτευχθεί σύγκλιση

Σημειώσεις:

• Πρόκειται για αλγόριθμο επεξεργασίας **κατά δέσμες** (batch algorithm), όπου η ενημέρωση των παραμέτρων σε κάθε επανάληψη πραγματοποιείται μετά την επεξεργασία όλων των διανυσμάτων του X .

• Ο αλγόριθμος perceptron **συγκλίνει μόνον όταν** οι κλάσεις είναι **γραμμικώς διαχωρίσιμες**. Διαφορετικά, αποτυγχάνει να συγκλίνει.


• Αν οι κλάσεις είναι **γραμμικώς διαχωρίσιμες**, ο αλγόριθμος **συγκλίνει** σε **πεπερασμένο αριθμό βημάτων**

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k \rightarrow \infty, \quad \lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k^2 < +\infty \text{ π.χ. } \rho_t = c/t$$

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

Παράδειγμα 1:




ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Ο αλγόριθμος perceptron

Παράδειγμα 2: Σε κάποια επανάληψη t ο αλγόριθμος perceptron δίνει $w_1 = 1$, $w_2 = 1$, $w_0 = -0.5$ που αντιστοιχεί στην ευθεία $x_1 + x_2 - 0.5 = 0$

Το υπερέπιπεδο της επόμενης επανάληψης είναι



$$\underline{w}(t+1) = \begin{bmatrix} 1 \\ 1 \\ -0.5 \end{bmatrix} - 0.7(-1) \begin{bmatrix} 0.4 \\ 0.05 \\ 1 \end{bmatrix} - 0.7(+1) \begin{bmatrix} -0.2 \\ 0.75 \\ 1 \end{bmatrix} = \begin{bmatrix} 1.42 \\ 0.51 \\ -0.5 \end{bmatrix}$$

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Παραλλαγές του αλγόριθμου perceptron:

-Ο αλγόριθμος “τσέπης” (rocket algorithm).

- Κρατά την καλύτερη λύση που βρέθηκε κατά την εκτέλεση του αλγόριθμου perceptron για συγκεκριμένο αριθμό επαναλήψεων.

- Κατάλληλος για προβλήματα μη γραμμικώς διαχωρίσιμων κλάσεων.


-Ο on-line αλγόριθμος perceptron:

- Η ενημέρωση των παραμέτρων λαμβάνει χώρα μετά την μεμονωμένη επεξεργασία κάθε διανύσματος του X .

$$\begin{aligned} w(t+1) &= w(t) + \rho x_{(t)}, & w^T(t)x_{(t)} &\leq 0 \\ & & x_{(t)} &\in \omega_1 \\ w(t+1) &= w(t) - \rho x_{(t)}, & w^T(t)x_{(t)} &\geq 0 \\ & & x_{(t)} &\in \omega_2 \\ w(t+1) &= w(t) & \text{otherwise} & \end{aligned}$$

ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Η δομή perceptron



w_i 's synapses or synaptic weights
 w_0 threshold

- Η δομή αυτή καλείται **perceptron** ή **νευρώνας (neuron)**
- Είναι μια **μηχανή** που μπορεί να **“μάθει”** (δηλ. να προσδιορίσει τις τιμές των εμπλεκόμενων παραμέτρων) από τα **διανύσματα εκπαίδευσης** μέσω του **αλγόριθμου perceptron**.