

# ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ (PATTERN RECOGNITION)

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

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων (Least square methods)

- Αν οι κλάσεις είναι γραμμικώς διαχωρίσιμες, το perceptron θα δώσει σαν έξοδο  $\pm 1$
- Αν οι κλάσεις ΔΕΝ είναι γραμμικώς διαχωρίσιμες, θα υπολογίσουμε τα βάρη (παραμέτρους)  $w_1, w_2, \dots, w_0$

έτσι ώστε η **διαφορά** ανάμεσα

- Στην **πραγματική απόκριση** του **ταξινομητή**,  $w^T x$ , και
- Την αντίστοιχη **επιθυμητή απόκριση**, δηλ. 
$$\begin{cases} +1 & \text{if } x \in \omega_1 \\ -1 & \text{if } x \in \omega_2 \end{cases}$$

να είναι όσο το δυνατόν **ΜΙΚΡΟΤΕΡΗ** για όλα τα διανύσματα του  $X$ .

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το MSE

– **ΜΙΚΡΟΤΕΡΑ**, ως προς το κριτήριο του μέσου τετραγωνικού σφάλματος (**mean square error - MSE**), σημαίνει επιλογή του  $w$  ώστε η συνάρτηση κόστους

- $J(w) \equiv E[(d - w^T x)^2]$  να ελαχιστοποιηθεί  
 $\hat{w} = \arg \min_w J(w)$

όπου  $d$  οι αντίστοιχες επιθυμητές αποκρίσεις

**Ελαχιστοποιώντας** την  $J(w)$  ως προς το  $w$  έχουμε:

$$\frac{\partial J(w)}{\partial w} = \frac{\partial}{\partial w} E[(d - w^T x)^2] = 0$$
$$= 2E[x(d - x^T w)] \Rightarrow$$

$R_x$ : Πίν. αυτοσυσχέτισης - **autocorrelation matrix**

$E[xd]$ : Διάν. Ετεροσυσχέτ.-**cross-correlation vector**

$$E[xx^T]w = E[xd] \Rightarrow \hat{w} = R_x^{-1} E[xd]$$

$$E[xd] = \begin{bmatrix} E[x_1 d] \\ \dots \\ E[x_l d] \end{bmatrix}$$

$$R_x \equiv E[xx^T] = \begin{bmatrix} E[x_1 x_1] & E[x_1 x_2] \dots & E[x_1 x_l] \\ \dots & \dots & \dots \\ E[x_l x_1] & E[x_l x_2] \dots & E[x_l x_l] \end{bmatrix}$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το MSE: Περ. από 2 κλάσεις

Στην περίπτωση που το υπό μελέτη πρόβλημα περιλαμβάνει  $M$  κλάσεις, λύνουμε  $M$  προβλήματα σαν το παραπάνω. Συγκεκριμένα:

-Για την  $j$ -στή κλάση

- Θέσε  $d_i=1$ , αν  $\mathbf{x}_i \in \omega_j$  και  $d_i=0$ , διαφορετικά.

- Λύσε το πρόβλημα δύο κλάσεων που προκύπτει και έστω  $\mathbf{w}^j$  το αντίστοιχο διάνυσμα παραμέτρων.

Μετά τον προσδιορισμό των  $\mathbf{w}^j$  's:

-Για δεδομένο  $\mathbf{x}_i$ :

- Υπολόγισε τις ποσότητες  $g^j(\mathbf{x}_i) = \mathbf{w}^{jT} \mathbf{x}_i$ ,  $j=1, \dots, M$ .

- Καταχώρησε το  $\mathbf{x}_i$  στην κλάση  $\omega_q$  για την οποία  $g^q(\mathbf{x}_i) = \max_{j=1, \dots, M} g^j(\mathbf{x}_i)$

**Σημείωση:** Το κριτήριο MSE ανήκει σε μια γενικότερη κλάση συναρτήσεων κόστους με την ακόλουθη σημαντική ιδιότητα:

Η τιμή  $g^j(\mathbf{x}_i)$  είναι μια εκτίμηση, ως προς το κριτήριο MSE, της εκ των υστέρων πιθανότητας,  $P(\omega_j | \mathbf{x})$ , υπό την προϋπόθεση ότι οι επιθυμητές αποκρίσεις που χρησιμοποιούνται κατά την εκπαίδευση είναι  $d_i=1$ , αν  $\mathbf{x}_i \in \omega_j$  και  $d_i=0$ , διαφορετικά.

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το SSE

- **ΜΙΚΡΟΤΕΡΟ**, ως προς το κριτήριο του **αθροίσματος των τετραγώνων των σφαλμάτων**, σημαίνει επιλογή του  $\mathcal{W}$  που **ελαχιστοποιεί** τη συνάρτηση κόστους

$$\bullet J(\mathbf{w}) = \sum_{i=1}^N (d_i - \mathbf{w}^T \mathbf{x}_i)^2$$

όπου  $d_i = +1$ , αν  $\mathbf{x}_i \in \omega_1$  και  $d_i = -1$ , αν  $\mathbf{x}_i \in \omega_2$ .

**Minimizing  $J(\mathbf{w})$  with respect to  $\mathbf{w}$  results in:**

$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = \frac{\partial}{\partial \mathbf{w}} \sum_{i=1}^N (d_i - \mathbf{w}^T \mathbf{x}_i)^2 = 0 \Rightarrow$$

$$\left( \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^T \right) \mathbf{w} = \sum_{i=1}^N \mathbf{x}_i d_i$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το SSE

Ένας εναλλακτικός τρόπος διατύπωσης:

Ορίζουμε τα ακόλουθα

$$X = \begin{bmatrix} x_1^T \\ x_2^T \\ \dots \\ x_N^T \end{bmatrix} \quad N \times l \text{ πίνακας} \quad \underline{d} = \begin{bmatrix} d_1 \\ \dots \\ d_N \end{bmatrix} \quad \text{Αντίστοιχες επιθυμητές αποκρίσεις}$$

$$X^T = [x_1, x_2, \dots, x_N] \quad l \times N \text{ πίνακας}$$

$$X^T X = \sum_{i=1}^N x_i x_i^T$$

$$X^T d = \sum_{i=1}^N x_i d_i$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το SSE

Ένας εναλλακτικός τρόπος διατύπωσης:

Τότε

$$\left( \sum_{i=1}^N x_i^T x_i \right) \hat{w} = \left( \sum_{i=1}^N x_i d_i \right) \Leftrightarrow (X^T X) \hat{w} = X^T d \Rightarrow \hat{w} = (X^T X)^{-1} X^T d = X^\# d$$

$$X^\# \equiv (X^T X)^{-1} X^T$$

Ψευδοαντίστροφος (pseudoinverse) του  $X$

Έστω  $N=I$ . Τότε ο  $X$  είναι τετραγωνικός και (γενικά) αντιστρέψιμος. Τότε έχουμε

$$(X^T X)^{-1} X^T = X^{-1} X^{-T} X^T = X^{-1} \Rightarrow X^\# = X^{-1}$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το SSE

Ένας εναλλακτικός τρόπος διατύπωσης:

Έστω  $N > l$ . Τότε, γενικά, **δεν υπάρχει λύση** που να ικανοποιεί ταυτόχρονα όλους τους περιορισμούς

$$Xw = d : \begin{array}{l} x_1^T w = d_1 \\ x_2^T w = d_2 \\ \dots \\ x_N^T w = d_N \end{array} \quad N \text{ equations} > l \text{ unknowns}$$

Σ' αυτή την περίπτωση, η **“λύση”**  $w = X^\# d$  ελαχιστοποιεί το **άθροισμα των τετραγώνων των σφαλμάτων**.




# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Μέθοδοι ελαχίστων τετραγώνων – μικρά ως προς το SSE

Ένα παράδειγμα:

$$\omega_1 : \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix}, \begin{bmatrix} 0.6 \\ 0.5 \end{bmatrix}, \begin{bmatrix} 0.1 \\ 0.4 \end{bmatrix}, \begin{bmatrix} 0.2 \\ 0.7 \end{bmatrix}, \begin{bmatrix} 0.3 \\ 0.3 \end{bmatrix} \quad \omega_2 : \begin{bmatrix} 0.4 \\ 0.6 \end{bmatrix}, \begin{bmatrix} 0.6 \\ 0.2 \end{bmatrix}, \begin{bmatrix} 0.7 \\ 0.4 \end{bmatrix}, \begin{bmatrix} 0.8 \\ 0.6 \end{bmatrix}, \begin{bmatrix} 0.7 \\ 0.5 \end{bmatrix}$$



$$X = \begin{bmatrix} 0.4 & 0.5 & 1 \\ 0.6 & 0.5 & 1 \\ 0.1 & 0.4 & 1 \\ 0.2 & 0.7 & 1 \\ 0.3 & 0.3 & 1 \\ 0.4 & 0.6 & 1 \\ 0.6 & 0.2 & 1 \\ 0.7 & 0.4 & 1 \\ 0.8 & 0.6 & 1 \\ 0.7 & 0.5 & 1 \end{bmatrix} \quad \underline{d} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ -1 \\ -1 \\ -1 \\ -1 \\ -1 \end{bmatrix}$$

$$X^T X = \begin{bmatrix} 2.8 & 2.24 & 4.8 \\ 2.24 & 2.41 & 4.7 \\ 4.8 & 4.7 & 10 \end{bmatrix}, \quad X^T \underline{d} = \begin{bmatrix} -1.6 \\ 0.1 \\ 0.0 \end{bmatrix} \quad \underline{w} = (X^T X)^{-1} X^T \underline{d} = \begin{bmatrix} -3.13 \\ 0.24 \\ 1.34 \end{bmatrix}$$


# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

Ο στόχος: Δοθέντων δύο **γραμμικώς διαχωρίσιμων** κλάσεων, προσδιόρισε τον ταξινομητή

$$g(x) = w^T x + w_0 = 0$$

που αφήνει το **μέγιστο περιθώριο** από τις δύο κλάσεις.



Support vector machines:  
Μηχανές διανυσματικής στήριξης

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

–Περιθώριο (Margin): Κάθε υπερεπίπεδο χαρακτηρίζεται από

- Τον **προσανατολισμό** του στο χώρο, δηλ. το διάνυσμα  $\mathbf{w}$

- Τη **θέση** του χώρο, i.e.,  $w_0$

- Για **ΚΑΘΕ** προσανατολισμό,  $\mathbf{w}$ , επέλεξε το υπερεπίπεδο που **αφήνει την ΙΔΙΑ απόσταση** από τα **εγγύτερα** σημεία από κάθε κλάση. Το περιθώριο είναι το διπλάσιο αυτής της απόστασης.

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

– Η απόσταση ενός σημείου  $\hat{x}$  από ένα υπερεπίπεδο είναι

$$z_{\hat{x}} = \frac{g(\hat{x})}{\|w\|}$$

– Διαβάθμισε τα  $w$ ,  $w_0$ , ώστε για τα **εγγύτερα σημεία** από κάθε κλάση να είναι:

$$|g(x)| = 1 \quad \left\{ g(x) = +1 \text{ for } \omega_1 \text{ and } g(x) = -1 \text{ for } \omega_2 \right\}$$

– Τότε το **περιθώριο** είναι

$$\frac{1}{\|w\|} + \frac{1}{\|w\|} = \frac{2}{\|w\|}$$

– Επίσης, ισχύουν και οι ακόλουθοι περιορισμοί

$$\begin{aligned} w^T x + w_0 &\geq 1 \quad \forall x \in \omega_1 \\ w^T x + w_0 &\leq -1 \quad \forall x \in \omega_2 \end{aligned}$$

(δηλ. όλα τα στοιχεία της κλάσης +1 (-1) βρίσκονται στη θετική (αρνητική) πλευρά του υπερεπιπέδου)

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

– SVM (γραμμικός) ταξινομητής

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0$$

– (Πρόβλημα SVM) Ελαχιστοποίησε την

$$J(\underline{w}) = \frac{1}{2} \|\underline{w}\|^2$$

– Υπό τους περιορισμούς



$$d_i(\underline{w}^T \underline{x}_i + w_0) \geq 1, \quad i = 1, 2, \dots, N \quad \begin{array}{l} d_i = 1, \text{ for } \underline{x}_i \in \omega_1, \\ d_i = -1, \text{ for } \underline{x}_i \in \omega_2 \end{array}$$

– Τα παραπάνω δικαιολογούνται από το γεγονός ότι ελαχιστοποιώντας το  $\|\underline{w}\|^2$

μεγιστοποιείται το περιθώριο  $\frac{2}{\|\underline{w}\|}$  .

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις



Οι επιπλέον περιορισμοί ισότητας αποθαρρύνουν λύσεις σαν αυτή του 2<sup>ου</sup> σεναρίου πιο πάνω.

# ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΥΝΑΡΤΗΣΗΣ ΥΠΟ ΓΡΑΜ. ΑΝΙΣΟΤΙΚΟΥΣ ΠΕΡΙΟΡΙΣΜΟΥΣ

Έστω το πρόβλημα

$$\text{Min } J(\vartheta)$$

Υπό τους περιορισμούς  $f_i(\vartheta) \geq 0, i=1, \dots, m$ .

Ορίζουμε τη **συνάρτηση Lagrange**

$$L(\vartheta, \lambda) = J(\vartheta) - \sum \lambda_i f_i(\vartheta)$$

**Συνθήκες KKT (Karush-Kuhn-Tacker):** Για τη θέση του **ελαχίστου** ισχύουν τα ακόλουθα

$$\frac{\partial}{\partial \vartheta} L(\vartheta, \lambda) = 0$$

$$\lambda_i \geq 0, i = 1, 2, \dots, m$$

$$\lambda_i f_i(\vartheta) = 0, i = 1, 2, \dots, m$$

# ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΥΝΑΡΤΗΣΗΣ ΥΠΟ ΓΡΑΜ. ΑΝΙΣΟΤΙΚΟΥΣ ΠΕΡΙΟΡΙΣΜΟΥΣ

Έστω

$$L^*(\vartheta) = \max_{\lambda} L(\vartheta, \lambda) = \max_{\lambda} (J(\vartheta) - \sum_i \lambda_i f_i(\vartheta))$$

Αφού  $\lambda_i \geq 0$ ,  $f_i(\vartheta) \geq 0$  έχουμε

$$L^*(\vartheta) = J(\vartheta)$$

Άρα

$$\min_{\vartheta} J(\vartheta) = \min_{\vartheta} L^*(\vartheta) = \min_{\vartheta} \max_{\lambda \geq 0} L(\vartheta, \lambda)$$

**Θεώρημα:**

- Έστω (α) η  $J(\vartheta)$  είναι **κυρτή** και (β) οι  $f_i(\vartheta)$  είναι **γραμμικές**.
- Έστω  $\vartheta^*$  μία θέση ελαχίστου για το πρόβλημα ελαχιστοποίησης και  $\lambda^*$  το αντίστοιχο διάνυσμα των πολ/στών Lagrange.
- Τότε το  $(\vartheta^*, \lambda^*)$  είναι ένα σαγματικό σημείο (saddle point) της συνάρτησης

Lagrange, για το οποίο ισχύει

Πρωτογενές (primal) πρόβλημα

Δυϊκό (dual) πρόβλημα

$$L(\vartheta^*, \lambda^*) = \min_{\vartheta} \max_{\lambda \geq 0} L(\vartheta, \lambda) = \max_{\lambda \geq 0} \min_{\vartheta} L(\vartheta, \lambda)$$

Συνεπώς, σύμφωνα με το θεώρημα, για τον προσδιορισμό του ελαχίστου **δεν παίζει ρόλο η σειρά με την οποία βελτιστοποιούμε την  $L(\vartheta, \lambda)$  ως προς τα  $\vartheta$  και  $\lambda$ .**

Στο πλαίσιο του **SVM** λύνουμε το **δυϊκό πρόβλημα**: θα **ελαχιστοποιήσουμε** την  $L(\cdot)$  πρώτα ως προς  $\vartheta$  και μετά θα την **μεγιστοποιήσουμε** ως προς  $\lambda$ .



# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

**Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις**

–Το πρόβλημα SVM είναι μια διαδικασία (κυρτής) τετραγωνικής βελτιστοποίησης (quadratic optimization task), με γραμμικούς περιορισμούς. Οι συνθήκες Karush-Kuhn-Tucker ορίζουν ότι για τη θέση του ελαχίστου ισχύουν τα ακόλουθα:

- (1)  $\frac{\partial}{\partial w} L(w, w_0, \lambda) = 0$
- (2)  $\frac{\partial}{\partial w_0} L(w, w_0, \lambda) = 0$
- (3)  $\lambda_i \geq 0, i = 1, 2, \dots, N$
- (4)  $\lambda_i [d_i (w^T x_i + w_0) - 1] = 0, i = 1, 2, \dots, N$
- Όπου  $L(\bullet, \bullet, \bullet)$  είναι η συνάρτηση Lagrange

$$L(w, w_0, \lambda) \equiv \frac{1}{2} w^T w - \sum_{i=1}^N \lambda_i [d_i (w^T x_i + w_0) - 1]$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

– **Η λύση:** από τα παραπάνω προκύπτει ότι είναι

$$w = \sum_{i=1}^N \lambda_i d_i x_i \quad \sum_{i=1}^N \lambda_i d_i = 0$$

Αντικαθιστώντας τα παραπάνω στην  $L(\cdot)$ , τα  $\lambda_i$ 's εκτιμώνται ως οι λύσεις του ακόλουθου προβλήματος:

**Μεγιστοποίησε την**  $\left( \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{ij} \lambda_i \lambda_j d_i d_j x_i^T x_j \right)$  **ως προς το**  $\lambda = [\lambda_1, \dots, \lambda_N]^T$

**Έτσι ώστε**  $\sum_{i=1}^N \lambda_i d_i = 0$   
 $\underline{\lambda} \geq \underline{0}$

**ΣΗΜ.:** Το πρόβλημα λύνεται συνήθως με χρήση τεχνικών **τετραγωνικού προγραμματισμού** (quadratic programming – QP)

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – γραμ. διαχ. κλάσεις

## Παρατηρήσεις:

- Οι πολ/στές Lagrange  $\lambda_i$  είναι είτε **θετικοί** είτε **μηδέν**. Έτσι

$$w = \sum_{i=1}^{N_s} \lambda_i d_i x_i$$

όπου  $N_s$  είναι ο αριθμός των διανυσμάτων με θετικά  $\lambda_i$ 's.


- Θετικά  $\lambda_i$  έχουν τα διανύσματα που ικανοποιούν τη συνθήκη  $w^T x_i + w_0 = \pm 1$  λόγω των περιορισμών  $\lambda_i [d_i (w^T x_i + w_0) - 1] = 0, \quad i = 1, 2, \dots, N$

Τα διανύσματα αυτά ονομάζονται **ΔΙΑΝΥΣΜΑΤΑ ΣΤΗΡΙΞΗΣ (SUPPORT VECTORS)** και είναι τα εγγύτερα προς το υπερεπίπεδο του ταξινομητή διανύσματα από κάθε κλάση. Αυτά είναι που καθορίζουν το  $w$ .

- Μετά τον προσδιορισμό του  $w$ , το  $w_0$  προσδιορίζεται από τις συνθήκες (4).
- Το βέλτιστο υπερεπίπεδο ως προς το κριτήριο της μεγιστοποίησης του περιθωρίου είναι **ΜΟΝΑΔΙΚΟ**.
- Παρότι η λύση είναι μοναδική, οι πολ. Lagrange **δεν είναι απαραίτητα** μοναδικοί.

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις



## ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις

- Στην περίπτωση αυτή, δεν υπάρχει υπερεπίπεδο έτσι ώστε

$$w^T x + w_0 (><)1, \forall x$$

- Υπενθυμίζεται ότι το **περιθώριο** ορίζεται ως το **διπλάσιο της απόστασης** μεταξύ των ακόλουθων δύο υπερεπιπέδων

$$w^T x + w_0 = 1 \text{ and } w^T x + w_0 = -1$$

– Για τα **διανύσματα εκπαίδευσης** έχουμε ένα από τα ακόλουθα τρία δυνατά σενάρια

1) Διανύσματα **εκτός** της ζώνης των δύο επιπέδων που είναι **ορθά** ταξινομημένα

$$d_i(w^T x + w_0) > 1$$

2) Διανύσματα **εντός** της ζώνης των δύο επιπέδων που είναι **ορθά** ταξινομημένα

$$0 \leq d_i(w^T x + w_0) < 1$$

3) Διανύσματα τα οποία είναι **μη ορθά ταξινομημένα**

$$d_i(w^T x + w_0) < 0$$

## ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις

– Οι παραπάνω περιπτώσεις μπορούν να παρασταθούν με συμπαγή τρόπο ως εξής

$$d_i(\underline{w}^T \underline{x} + w_0) \geq 1 - \xi_i$$

Όπου για

1<sup>ο</sup> σενάριο  $\rightarrow \xi_i = 0$

2<sup>ο</sup> σενάριο  $\rightarrow 0 < \xi_i \leq 1$

3<sup>ο</sup> σενάριο  $\rightarrow 1 < \xi_i$

Οι μεταβλητές  $\xi_i$  είναι γνωστές ως **μεταβλητές χαλαρότητας (slack variables)**

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις

–Ο στόχος της βελτιστοποίησης είναι τώρα διττός

- Μεγιστοποίηση του **περιθωρίου**

- Ελαχιστοποίηση του **αριθμού των διανυσμάτων** με  $\xi_i > 0$ ,

- Ένας τρόπος να επιτύχουμε τον παραπάνω στόχο είναι μέσω της ακόλουθης συνάρτησης κόστους

$$J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N I(\xi_i)$$

όπου  $C$  είναι μια **σταθερά** και

$$I(\xi_i) = \begin{cases} 1 & \xi_i > 0 \\ 0 & \xi_i = 0 \end{cases}$$

- Η συνάρτηση  $I(\cdot)$  **ΔΕΝ** είναι **διαφορίσιμη**. Στην πράξη, μπορούμε να

χρησιμοποιήσουμε μια **προσέγγιση**

$$J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N \xi_i$$

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις

➤ Η **συνάρτηση Lagrange** για την περίπτωση αυτή γίνεται

$$L(w, w_0, \xi, \lambda, \mu) \equiv \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \mu_i \xi_i - \sum_{i=1}^N \lambda_i [d_i (w^T x_i + w_0) - 1 + \xi_i]$$

(τα  $\lambda_i$  και  $\mu_i$  είναι πολ/στές Lagrange)

➤ Οι αντίστοιχες **ΚΚΤ συνθήκες** είναι:

$$(1) \quad w = \sum_{i=1}^N \lambda_i d_i x_i$$

$$(2) \quad \sum_{i=1}^N \lambda_i d_i = 0$$

$$(3) \quad C - \mu_i - \lambda_i = 0, \quad i = 1, 2, \dots, N$$

$$(4) \quad \lambda_i [y_i (w^T x_i + w_0) - 1 + \xi_i] = 0, \quad i = 1, 2, \dots, N$$

$$(5) \quad \mu_i \xi_i = 0, \quad i = 1, 2, \dots, N$$

$$(6) \quad \mu_i, \lambda_i \geq 0, \quad i = 1, 2, \dots, N$$



➤ Αντικαθιστώντας τα παραπάνω στην  $L(\cdot)$ , οι πολ/στές Lagrange προσδιορίζονται ως οι λύσεις του ακόλουθου δυϊκού SVM προβλήματος

Μεγιστοποίηση  $\lambda_{\geq 0} \left( \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{ij} \lambda_i \lambda_j d_i d_j x_i^T x_j \right)$  ως προς το  $\lambda = [\lambda_1, \dots, \lambda_N]^T$

υπό τις προϋποθέσεις

$$0 \leq \lambda_i \leq C, \quad i = 1, 2, \dots, N$$

$$\sum_{i=1}^N \lambda_i d_i = 0$$

➤ Σχόλιο:


Η μόνη διαφορά με την περίπτωση των διαχωρίσιμων κλάσεων είναι η ύπαρξη του  $C$  στους περιορισμούς.

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ


Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις

Η λύση του SVM προβλήματος ακολουθεί βήματα ανάλογα με αυτά της προηγούμενης περίπτωσης.

Ωστόσο, στην παρούσα περίπτωση, η παράμετρος  $C$  επηρεάζει την επιλογή της τελικής λύσης.



(a)




(b)

Στο παραπάνω παράδειγμα η  $C$  έχει “μικρότερη τιμή” για το σχήμα (a) και “μεγαλύτερη τιμή” για το σχήμα (b).

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις



**C = 0.1**

Pe\_tr = 0.0225


Pe\_te = 0.0325

sup\_vec = 82

marg = 0.9412

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

## Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις



**C = 1**

Pe\_tr = 0.0225


Pe\_te = 0.0325

sup\_vec = 37

marg = 0.6317

# ΓΡΑΜΜΙΚΟΙ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΕΠΙΦΑΝΕΙΩΝ ΑΠΟΦΑΣΗΣ

Support vector machines – η γραμμική περίπτωση – μη γραμ. διαχ. κλάσεις



**C = 20**

Pe\_tr = 0.0225

Pe\_te = 0.0350

sup\_vec = 25

marg = 0.3573