

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Διαδική Ταξινόμηση - Αλγόριθμοι Πυρήνα (Kernel Methods)**

**1. Διαχωρισιμότητα Προτύπων, Θεώρημα του Cover**

**2. Radial-Basis Function (RBF) Networks**

**3. RBF Hybrid Learning**

**4. Support Vector Machines (SVM)**

καθ. Βασίλης Μάγκλαρης

[maglaris@netmode.ntua.gr](mailto:maglaris@netmode.ntua.gr)

[www.netmode.ntua.gr](http://www.netmode.ntua.gr)

Αίθουσα 002, Νέα Κτίρια ΣΗΜΜΥ

Τρίτη 23/4/2024

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

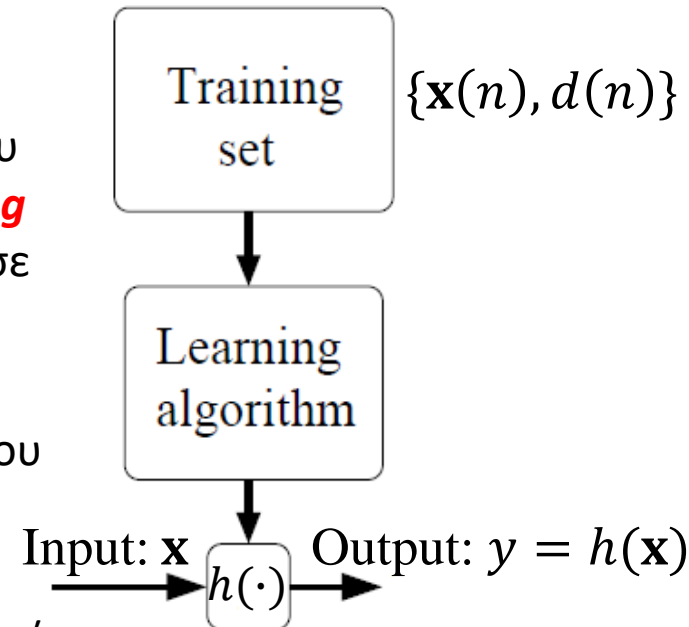
## Γενικό Μοντέλο Επιβλεπόμενης Μάθησης - Supervised Learning (επανάληψη)

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018

- Στόχος του συστήματος είναι η αντιστοίχιση ενός δειγματικού στοιχείου εισόδου (**input sample point, example, instance**)  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  σε τιμές εξόδου  $y$  που εκτιμούν επιθυμητές τιμές  $d$  (**labels, targets**) π.χ. πρόβλεψη ή ταξινόμηση. Τα στοιχεία  $x_i$  είναι αριθμητικές τιμές που κωδικοποιούν  $m$  ειδοποιά χαρακτηριστικά (**features**) του δειγματικού στοιχείου  $\mathbf{x}$ . Ζητείται ο προσδιορισμός της συνάρτησης εισόδου - εξόδου  $y = h(\mathbf{x}) \cong d$  που προκύπτει από δείγμα μάθησης (**Training Set**)  $N$  **labeled** ζευγών  $\{\mathbf{x}(n), d(n)\}$ ,  $n = 1, 2, \dots, N$  γνωστών σε εξωτερικό εκπαιδευτή (**supervisor**)




- Η μορφή και οι παράμετροι της  $h(\cdot)$  προσδιορίζονται με αλγόριθμο μάθησης που συγκλίνει σε προσέγγιση του στόχου της υπόθεσης για τα  $N$  στοιχεία του δείγματος μάθησης  $d(n) \cong y(n) = h(\mathbf{x}(n))$

- Αν ο στόχος ικανοποιείται με μικρό αριθμό διακριτών επιλογών (κλάσεων) της  $y$  πρόκειται για πρόβλημα Ταξινόμησης, **Classification** (για δύο κλάσεις έχουμε δυαδική ταξινόμηση)
- Αν η έξοδος  $y$  λαμβάνει συνεχείς τιμές, το πρόβλημα αναφέρεται σαν Παλινδρόμηση, **Regression**



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Rosenblatt's Perceptron (επανάληψη)



### Σύνοψη:

- Ένας νευρώνας με γραμμικό **induced local field**  $v$  και συνάρτηση ενεργοποίησης  $\varphi(v)$  κατωφλίου (**Threshold Function, Hard Limiter**) ή πρόσημου (**Signum Function**) για δυαδική ταξινόμηση στοιχείων  $\mathbf{x} = [x_0 \ x_1 \ \dots \ x_m]^T$  σε δύο **γραμμικά διαχωριζόμενες** κλάσεις:

$$\mathcal{C}_1 \text{ αν } y = \varphi(v) = 1, \quad \mathcal{C}_2 \text{ αν } y = \varphi(v) = 0 \text{ ή αν } y = \varphi(v) = -1$$

- Τα βάρη  $\mathbf{w} = [w_0 \ w_1 \ \dots \ w_m]^T$  ρυθμίζονται on-line (stochastic iterative method) με την εφαρμογή **Error-correction Algorithm** σε δειγματικά στοιχεία μάθησης  $\{\mathbf{x}(n), d(n)\}$ ,  $n = 1, 2, \dots, N$  σε περιβάλλον **supervised learning** προς ελαχιστοποίηση σφαλμάτων  $[d(n) - y(n)]$


$$\mathbf{w}(n+1) = \mathbf{w}(n) + \eta[d(n) - y(n)]\mathbf{x}(n)$$

Η **hyperparameter**  $\eta$ ,  $0 < \eta \leq 1$  (**learning-rate parameter**) αν είναι **μικρή** οδηγεί την επαναληπτική διαδικασία μάθησης σε σύγκλιση. Αν είναι **μεγάλη** μπορεί να επιταχύνει τη σύγκλιση π.χ. σε περιβάλλοντα με μεγάλες αποκλίσεις των δεδομένων  $\mathbf{x}(n)$ , αλλά μπορεί να οδηγήσει σε αστάθειες λόγω ταλαντώσεων περί την βέλτιστη τιμή

Σε περιβάλλον δειγματικών στοιχείων  $\mathbf{x}$  κατανομής Gauss, η ταξινόμησή τους σε δύο κλάσεις  $\mathcal{C}_1, \mathcal{C}_2$  μέσω **Bayes Classifier** (ελαχιστοποίηση ρίσκου σφάλματος με βάση a-priori πιθανότητες  $p_1, p_2$ ) ταυτίζεται με το **Rosenblatt Perceptron**

## Αντιστοίχιση Προτύπων - Pattern Association (S. Haykin: *Introduction, Section 9*)

Διαδικασία *συσχετιστικής μάθησης* (*associative learning*) για αντιστοίχιση *παραδειγμάτων-κλειδιών*  $\mathbf{x}_k$  (*key patterns*) σε  $q$  *αποθηκευμένα πρότυπα*  $\mathbf{y}_k$  (*memorized patterns*)



**Μέθοδοι Συσχετιστικής Μάθησης :**

➤ **Αυτοαντιστοίχιση** (*Autoassociation*):  $\mathbf{x}_k = \mathbf{y}_k$

Τα διανύσματα  $\mathbf{x}_k, \mathbf{y}_k$  έχουν  $D$  διαστάσεις. Με **Multilayer Perceptron (MLP)** κωδικοποιούμε τα  $\mathbf{x}_k$  σε κρυφά (*latent*) διανύσματα  $\mathbf{z}_k$  διαστάσεων  $M < D$  και σε επόμενο στρώμα (*layer*) αποκωδικοποιούμε κατά προσέγγιση (ελαχίστων τετραγώνων) τα διανύσματα εισόδου (όπως σε *autoencoders*). Οι παράμετροι του **MLP** ρυθμίζονται στη φάση μάθησης με **Unsupervised Learning** με δείγμα μάθησης τα  $q$  παραδείγματα-κλειδιά  $\mathbf{x}_k = \mathbf{y}_k, k = 1, 2, \dots, q$

<https://www.microsoft.com/en-us/research/uploads/prod/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf>

➤ **Ετεροαντιστοίχιση** (*Heteroassociation*):  $\mathbf{x}_k \neq \mathbf{y}_k$  **Supervised Learning**

**Φάσεις Αντιστοίχισης Προτύπων:**

- Αποθήκευση (*Storage*): Αποθήκευση στη μνήμη των *key patterns* με κλειδί ανάκτησης τα  $\mathbf{x}_k$
- Ανάκληση (*Recall*): Αντιστοίχιση νέου στοιχείου  $\mathbf{x}_k$  (*stimulus, input vector*, π.χ. χειρόγραφα δεκαδικών αριθμητικά ψηφία ή παραμορφωμένες εικόνες) σε αποθηκευμένο πρότυπο  $\mathbf{y}_k$

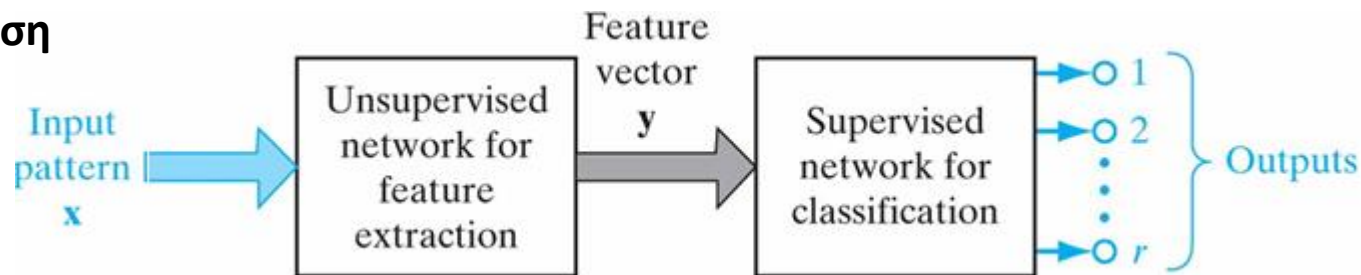
# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Αναγνώριση Προτύπων - Pattern Recognition (S. Haykin: *Introduction*, Section 9)

Αναγνώριση εισόδου, εξαγωγή κύριων χαρακτηριστικών και ανάθεση – ταξινόμηση νέων προτύπων (*patterns*) σε ορισμένη κατηγορία (*class*) με κριτήριο τη στατιστική συνάφεια με αποθηκευμένα πρότυπα στο σύστημα κατά τη διαδικασία μάθησης

Η διαδικασία συνήθως περιλαμβάνει 2 στάδια:

- **Στάδιο Εξαγωγής Χαρακτηριστικών (Feature Extraction):** Μετασχηματισμός εισόδου  $x$  (διάνυσμα διαστάσεως  $m$ ) σε ενδιάμεσο διάνυσμα  $y$  διαστάσεως  $q \leq m$  με *unsupervised learning*. Αν  $q < m$  έχουμε συμπίεση δεδομένων ή επιλογή σημαντικών χαρακτηριστικών (*important features*) για απλοποίηση της διαδικασίας ταξινόμησης
- **Στάδιο Ταξινόμησης (Classification):** Αντιστοίχιση του ενδιάμεσου πρότυπου  $y$  σε  $r$  διακριτές κλάσεις (*supervised learning* σε κρυφά στρώματα). Αν  $r = 2$  έχουμε **δυναδική ταξινόμηση**



**Παράδειγμα Labeled Δείγματος Μάθησης:** *MNIST Database* για ταξινόμηση χειρόγραφων αριθμών σε  $r = 10$  κλάσεις (0, ..., 9) [https://en.wikipedia.org/wiki/MNIST\\_database](https://en.wikipedia.org/wiki/MNIST_database)

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Διαχωρισιμότητα Προτύπων (Separability of Patterns)

### Ταξινόμηση Παραδειγμάτων μέσω Διαχωρίσιμων Προτύπων

Αντιστοίχιση παραδειγμάτων εισόδου  $\mathbf{x}$  (**examples, instances**) σε  $N$  πρότυπα (**patterns**)  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$  ( $\mathbf{x}_i$  διανύσματα με  $m_0$  συνιστώσες) για δυαδική ταξινόμηση σε δύο διαχωρίσιμες κλάσεις  $C_1$  και  $C_2$

### Θεώρημα του Cover (1965)

- Περίπλοκο πρόβλημα ταξινόμησης προτύπων μη γραμμικά ορισμένο σε χώρο πολλών διαστάσεων, είναι πιθανότερο να είναι γραμμικά διαχωρίσιμο (**linearly separable**) από ότι σε χώρο λίγων διαστάσεων, αν δεν υπάρχουν πυκνά σημεία (πρότυπα)
- Για εύκολη ταξινόμηση προτύπων προτιμάται η **γραμμική διαχωρισιμότητα** μέσω **μη γραμμικού μετασχηματισμού συντεταγμένων** και ως απαιτούνται **περισσότερες διαστάσεις**

### Κρυφές Συναρτήσεις (Hidden Functions)




Τα  $\mathbf{x}$  μετασχηματίζονται (μη γραμμικά) σε  $\boldsymbol{\varphi}(\mathbf{x})$  με  $m_1 \geq m_0$  διαστάσεις

$$\mathbf{x} \rightarrow \boldsymbol{\varphi}(\mathbf{x}) = [\varphi_1(\mathbf{x}) \ \varphi_2(\mathbf{x}) \ \dots \ \varphi_{m_1}(\mathbf{x})]^T$$

Οι  $\varphi_j(\mathbf{x}) \in \mathbb{R}, j = 1, 2, \dots, m_1$  **είναι κρυφές συναρτήσεις**

Ο χώρος των προτύπων είναι **γραμμικά διαχωρίσιμος** κατά  $\boldsymbol{\varphi}$  ( **$\boldsymbol{\varphi}$ -separable dichotomy**) όταν υπάρχει διάνυσμα  $\mathbf{w}$  με  $m_1 \geq m_0$  συνιστώσες που να ορίζει δύο γραμμικά διακριτές περιοχές αντίστοιχες με τις  $C_1$  και  $C_2$  των  $\mathbf{x}$ :

$$\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) > 0 \Rightarrow \mathbf{x} \in C_1 \text{ και } \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) < 0 \Rightarrow \mathbf{x} \in C_2$$



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

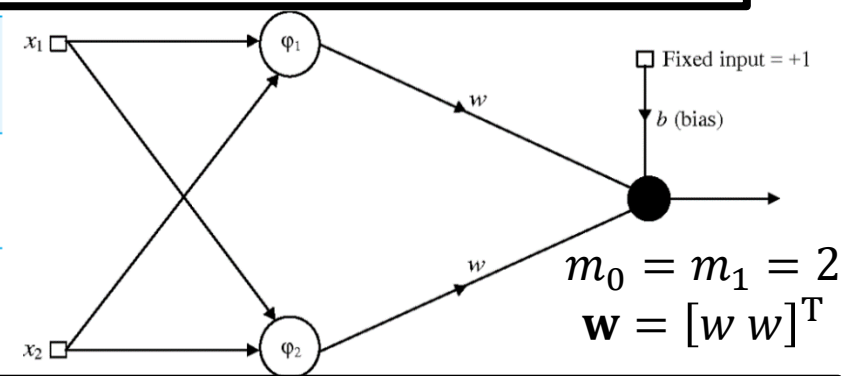
## Διαχωρισιμότητα Προτύπων – Το πρόβλημα XOR

Συνήθης επιλογή για  $\varphi_j(\mathbf{x})$ : **Gaussian Radial-Basis Function (RBF)**

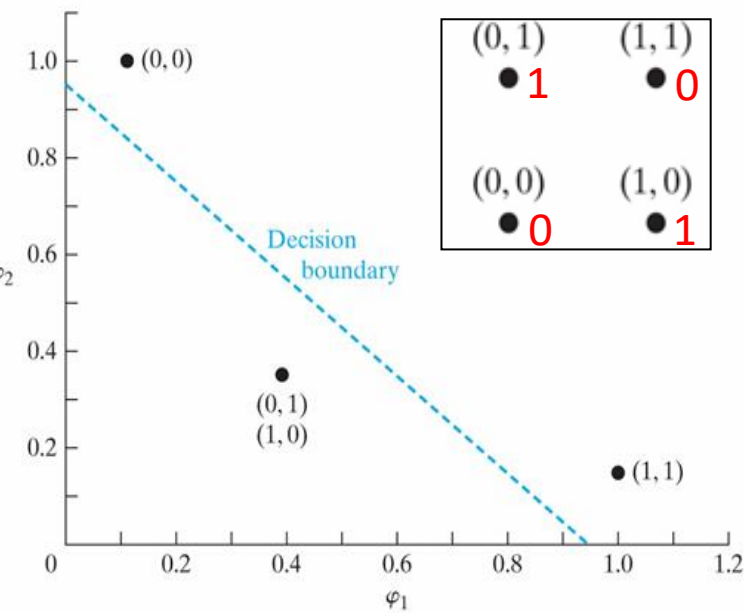
$\varphi_j(\mathbf{x}) = \exp(-\|\mathbf{x} - \boldsymbol{\mu}_j\|^2)$  όπου  $\boldsymbol{\mu}_j$  διάνυσμα διαστάσεως  $m_0$  των **μέσων τιμών** (κέντρων) της  $\varphi_j(\mathbf{x})$  και  $\|\mathbf{x} - \boldsymbol{\mu}_j\|$  η **Ευκλείδεια απόσταση** του σημείου  $\mathbf{x}$  από το  $\boldsymbol{\mu}_j$

TABLE 5.1 Specification of the Hidden Functions for the XOR Problem of Example 1

Input Pattern $\mathbf{x}$	First Hidden Function $\varphi_1(\mathbf{x})$	Second Hidden Function $\varphi_2(\mathbf{x})$
(1,1)	1	0.1353
(0,1)	0.3678	0.3678
(0,0)	0.1353	1
(1,0)	0.3678	0.3678



$\mathbf{x} = [x_1 \ x_2]^T \rightarrow \boldsymbol{\varphi}(\mathbf{x}) = [\varphi_1(\mathbf{x}) \ \varphi_2(\mathbf{x})]^T$   
 $\varphi_1(\mathbf{x}) = \exp(-\|\mathbf{x} - \boldsymbol{\mu}_1\|^2), \boldsymbol{\mu}_1 = [1,1]^T$   
 $\varphi_2(\mathbf{x}) = \exp(-\|\mathbf{x} - \boldsymbol{\mu}_2\|^2), \boldsymbol{\mu}_2 = [0,0]^T$



Παράδειγμα Υπολογισμού  $\boldsymbol{\varphi}(\mathbf{x})$ ,  $\mathbf{x} = [1 \ 1]^T$

$\varphi_1(1,1) = \exp(-\|[1 \ 1]^T - [1 \ 1]^T\|^2) = 1$

$\varphi_2(1,1) = \exp(-\|[1 \ 1]^T - [0 \ 0]^T\|^2) = 0.1353$

Έξοδος:  $y = w\varphi_1(\mathbf{x}) + w\varphi_2(\mathbf{x}) + b$

(1,1):  $w + w \times 0.1353 + b = 0$

(0,1):  $w \times 0.3678 + w \times 0.3678 + b = 1$

(0,0):  $w \times 0.1353 + w + b = 0$

(1,0):  $w \times 0.3678 + w \times 0.3678 + b = 1$

**Λύση**  
 $w = -2.502$   
 $b = 2.841$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Ορισμοί Radial-Basis Function (RBF), Kernels, Hybrid Learning

(βασισμένο στο **C. M. Bishop**, Ch.6: Kernel Methods <https://www.microsoft.com/en-us/research/uploads/prod/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf>)


**Radial-Basis Function (RBF):**  $\mathbf{x} \in \mathbb{R}^{m_0} \rightarrow \varphi_j(\mathbf{x}) = \varphi(\|\mathbf{x} - \mathbf{x}_j\|) = \varphi(r) \in \mathbb{R}$

$r = \|\mathbf{x} - \mathbf{x}_j\|$  μέτρο ακτινικής απόστασης διανυσμάτων  $\mathbf{x}$  και  $\mathbf{x}_j$  (συνήθως **Ευκλείδεια**)

- **Μετασχηματισμός:**  $\mathbf{x} \rightarrow \boldsymbol{\varphi}(\mathbf{x}) = [\varphi_1(\mathbf{x}) \varphi_2(\mathbf{x}) \dots \varphi_{m_1}(\mathbf{x})]^T$ ,  $m_1 \geq m_0$
- **Παράδειγμα: Gaussian RBF**  $\varphi_j(\mathbf{x}) = \exp(-\|\mathbf{x} - \mathbf{x}_j\|^2)$  που αφορά στην Ευκλείδεια απόσταση δειγματικού σημείου  $\mathbf{x}$  με  $m_0$  χαρακτηριστικά (**features**) από τα  $N$  δειγματικά σημεία μάθησης (πρότυπα, **patterns**)  $\mathbf{x}_j$
- **Ταξινόμηση Προτύπων:** Τα  $\varphi_j(\mathbf{x})$  απεικονίζουν  $N$  κρυφά χαρακτηριστικά (**hidden features**) του  $\mathbf{x}$  σαν αποστάσεις από τα κέντρα  $\mathbf{x}_j$  τα οποία προκύπτουν από το δείγμα μάθησης (**patterns**) σε **1<sup>η</sup> Φάση Υβριδικής Μάθησης (Hybrid Learning)** για ταξινόμηση προτύπων γύρω από κέντρα βάρους μέσω μη επιβλεπόμενης μάθησης (π.χ. με αλγόριθμο **K-Means**)

**Kernel:**  $k(\mathbf{x}, \mathbf{x}_j) \in \mathbb{R}$  μέτρο ομοιότητας (~εσωτερικό γινόμενο) του διανύσματος  $\mathbf{x} \in \mathbb{R}^{m_0}$  με διάνυσμα  $\mathbf{x}_j \in \mathbb{R}^{m_0}$

- **Σχέση με RBF:**  $k(\mathbf{x}, \mathbf{x}_j) = \boldsymbol{\varphi}(\mathbf{x})^T \boldsymbol{\varphi}(\mathbf{x}_j)$ ,  $j = 1, 2, \dots, m_1$  (εσωτερικό γινόμενο). Λόγω του **Θεωρήματος του Cover** συνήθως  $m_1 > m_0$  για μετασχηματισμό  $\mathbf{x} \rightarrow \boldsymbol{\varphi}(\mathbf{x})$  σε **linearly separable** περιοχές ταξινόμησης του προτύπου  $\mathbf{x}$



Kernel Trick

- **Ταξινόμηση Προτύπων:** Τελική επιλογή κλάσης για δειγματικό σημείο (**pattern**)  $\mathbf{x} \in \mathbb{R}^{m_0}$  σε **2<sup>η</sup> Φάση Υβριδικής Μάθησης (Hybrid Learning)** στο πλησιέστερο σημείο από τα κέντρα βάρους της 1<sup>ης</sup> Φάσης, μέσω επιβλεπόμενης μάθησης και με δίκτυο **feed-forward**



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Διαδική Ταξινόμηση - Kernel Perceptron


[https://en.wikipedia.org/wiki/Kernel\\_perceptron](https://en.wikipedia.org/wiki/Kernel_perceptron)

### Γραμμική Διαδική Ταξινόμηση, Αλγόριθμος Perceptron

$$y = \text{sgn}(\mathbf{w}^T \mathbf{x}) \in \{-1, 1\}$$

**Αλγόριθμος Μάθησης:** Επαναληπτικός προσδιορισμός συναπτικών βαρών με αρχικοποίηση  $\mathbf{w} = [0 \ 0 \ \dots \ 0]^T$ , διαδοχικές εισόδους *labeled* στοιχείων μάθησης  $\{\mathbf{x}_i, d_i\}$ ,  $d_i \in \{-1, 1\}$ ,  $i = 1, 2, \dots, N$  και εξόδους  $y = \text{sgn}(\mathbf{w}^T \mathbf{x}_i)$ :

$$\mathbf{w} \leftarrow \begin{cases} \mathbf{w} & \text{αν } y = d_i \text{ (ορθή επιλογή)} \\ \mathbf{w} + d_i \mathbf{x}_i & \text{αν } y \neq d_i \text{ (λάθος επιλογή)} \end{cases}$$



### Μη Γραμμική Διαδική Ταξινόμηση, Kernel Perceptron

Η *Kernel Machine* αποθηκεύει  $N$  σημεία  $\mathbf{x}_i$  διαστάσεως  $m_0$  του δείγματος μάθησης  $\{\mathbf{x}_i, d_i\}$ , ορίζει μετρητή  $\alpha_i$  για ταξινομήσεις  $\mathbf{x}_i \rightarrow y \in \{-1, 1\}$  και επιλέγει κλάση  $y$  με βάση τον κανόνα

$$y = \text{sgn} \sum_{i=1}^N \alpha_i d_i k(\mathbf{x}, \mathbf{x}_i) \in \{-1, 1\}$$

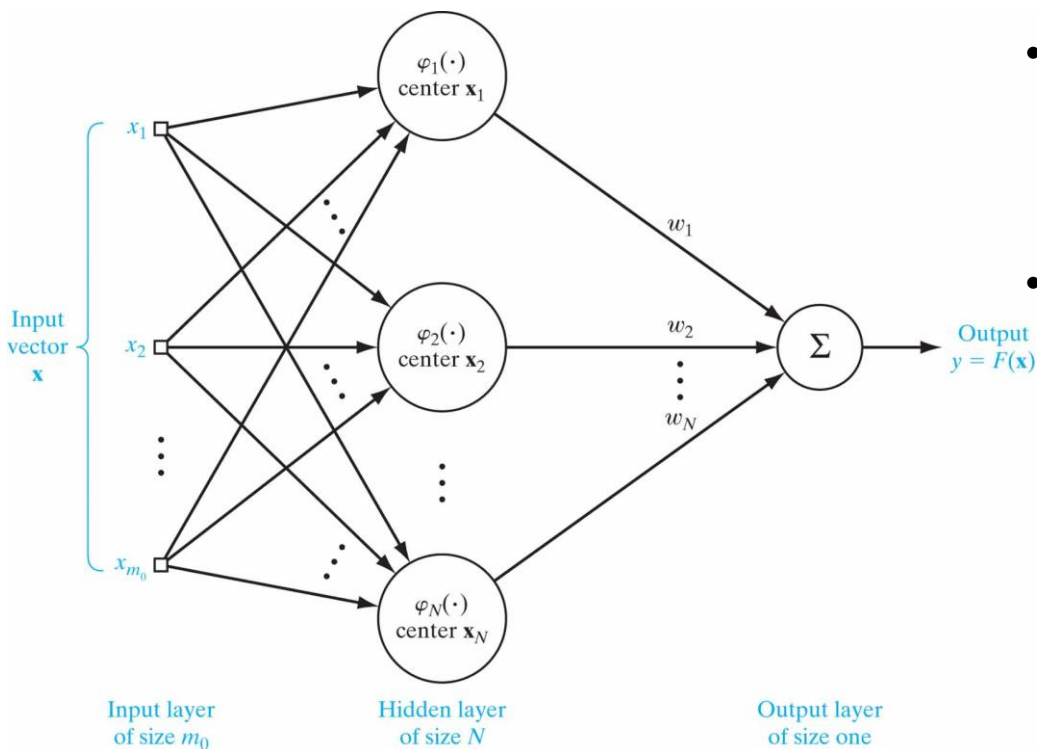
Ο πυρήνας (*Kernel*)  $k(\mathbf{x}, \mathbf{x}_i) \in \mathbb{R}$  ορίζεται σαν εσωτερικό γινόμενο διανυσμάτων διαστάσεως  $m_1 \geq m_0$  με στοιχεία μη γραμμικές *hidden functions*:  $k(\mathbf{x}, \mathbf{x}_i) = \boldsymbol{\varphi}(\mathbf{x})^T \boldsymbol{\varphi}(\mathbf{x}_i)$

**Αλγόριθμος Μάθησης:** Ανάλογη του γραμμικού Αλγορίθμου Perceptron με  $\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \mathbf{x}_i$  όπου  $\alpha_i$  μετρητής λανθασμένων επιλογών  $\mathbf{x}_i \rightarrow y \neq d_i$

Για κάθε δειγματικό σημείο μάθησης - *labeled pattern*  $\{\mathbf{x}_i, d_i\}$ ,  $i = 1, 2, \dots, N$  υπολογίζω  $y = \text{sgn}(\mathbf{w}^T \mathbf{x}_i) = \text{sgn} \sum_{j=1}^N \alpha_j d_j k(\mathbf{x}_i, \mathbf{x}_j)$ . Αν  $y \neq d_i$  αυξάνεται ο μετρητής  $\alpha_i \leftarrow \alpha_i + 1$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Radial-Basis Function (RBF) Networks



- **Input Layer:** Είσοδος διανυσμάτων  $\mathbf{x}$  με  $m_0$  χαρακτηριστικά (*features*) που τροφοδοτούν χωρίς τροποποίηση ενδιάμεσο κρυφό επίπεδο
- **Hidden Layer:** Για *Δείγμα Μάθησης* με  $N \geq m_0$  στοιχεία (*πρότυπα*), ορίζονται  $N$  κόμβοι επεξεργασίας με *Gaussian Ακτινικές Συναρτήσεις Βάσης - RBF*:

$$\begin{aligned}\varphi_j(\mathbf{x}) &= \varphi(\mathbf{x}, \mathbf{x}_j) = \varphi(\|\mathbf{x} - \mathbf{x}_j\|) \\ &= \exp(-\|\mathbf{x} - \mathbf{x}_j\|^2)\end{aligned}$$

(Gaussian συνάρτηση της απόστασης  $\|\mathbf{x} - \mathbf{x}_j\|^2$  του  $\mathbf{x}$  από τα παραδείγματα μάθησης  $\mathbf{x}_j$ )

- **Output Layer:** Γραμμικός συνδυασμός συναρτήσεων βάσης  $\boldsymbol{\varphi}(\mathbf{x}) = [\varphi_1(\mathbf{x}) \varphi_2(\mathbf{x}) \dots \varphi_N(\mathbf{x})]^T$   
 $y = F(\mathbf{x}) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) = \sum_{j=1}^N w_j \varphi(\|\mathbf{x} - \mathbf{x}_j\|), y \in \{-1, 1\}$

- **Training:**

- ✓ Επίλυση γραμμικού συστήματος  $N$  εξισώσεων  $F(\mathbf{x}_i) = \sum_j w_j \varphi(\|\mathbf{x}_i - \mathbf{x}_j\|) = d_i$  από τα  $N$  *labeled* στοιχεία  $\{\mathbf{x}_i, d_i\}$  του δείγματος μάθησης με  $N$  αγνώστους  $w_j$
- ✓ Οι  $F(\mathbf{x}_i) = d_i$  ορίζουν στο δείγμα μάθησης *υπερεπιφάνεια δυαδικού διαχωρισμού* κλάσεων
- ✓ Το σύστημα έχει πάντα λύση για διακριτά σημεία  $\mathbf{x}_i$  (*Θεώρημα Michellis*)

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Radial-Basis Function (RBF) Network για Ταξινομητή XOR

(βασισμένο στη παρουσίαση «Υβριδική Μάθηση – RBF», **A. Σταφυλοπάτη**, ΣΗΜΜΥ Ε.Μ.Π.

[http://mycourses.ntua.gr/courses/ECE1080/document/%C4%E9%E1%EB%DD%EE%E5%E9%F2\\_2019-2020/rbf.pdf](http://mycourses.ntua.gr/courses/ECE1080/document/%C4%E9%E1%EB%DD%EE%E5%E9%F2_2019-2020/rbf.pdf))

**Δείγμα Μάθησης:**  $N = 4$  *labeled* στοιχεία (*πρότυπα*)  $\mathbf{x}_i = [x_i(1) \ x_i(2)]^T \rightarrow y = F(\mathbf{x}_i)$   
όπου  $\{x_i(1), x_i(2), y\}$  δυαδικές μεταβλητές  $\in \{0,1\}$  και  $i \leq N = 4$

**Ακτινικές Συναρτήσεις Βάσης:**  $\varphi_j(\mathbf{x}) = \exp(-\|\mathbf{x} - \boldsymbol{\mu}_j\|^2)$ ,  $j = 1,2,3,4$   
γύρω από 4 κέντρα βάρους:  $\boldsymbol{\mu}_1 = [1 \ 1]$ ,  $\boldsymbol{\mu}_2 = [0 \ 0]$ ,  $\boldsymbol{\mu}_3 = [0 \ 1]$ ,  $\boldsymbol{\mu}_4 = [1 \ 0]$

$$y = F(\mathbf{x}) = w_1\varphi_1(\mathbf{x}) + w_2\varphi_2(\mathbf{x}) + w_3\varphi_3(\mathbf{x}) + w_4\varphi_4(\mathbf{x})$$

$\mathbf{x}$	$\varphi_1(\mathbf{x})$	$\varphi_2(\mathbf{x})$	$\varphi_3(\mathbf{x})$	$\varphi_4(\mathbf{x})$	$y$
(1,1)	1	0.1353	0.3678	0.3678	0
(0,0)	0.1353	1	0.3678	0.3678	0
(0,1)	0.3678	0.3678	1	0.1353	1
(1,0)	0.3678	0.3678	0.1353	1	1

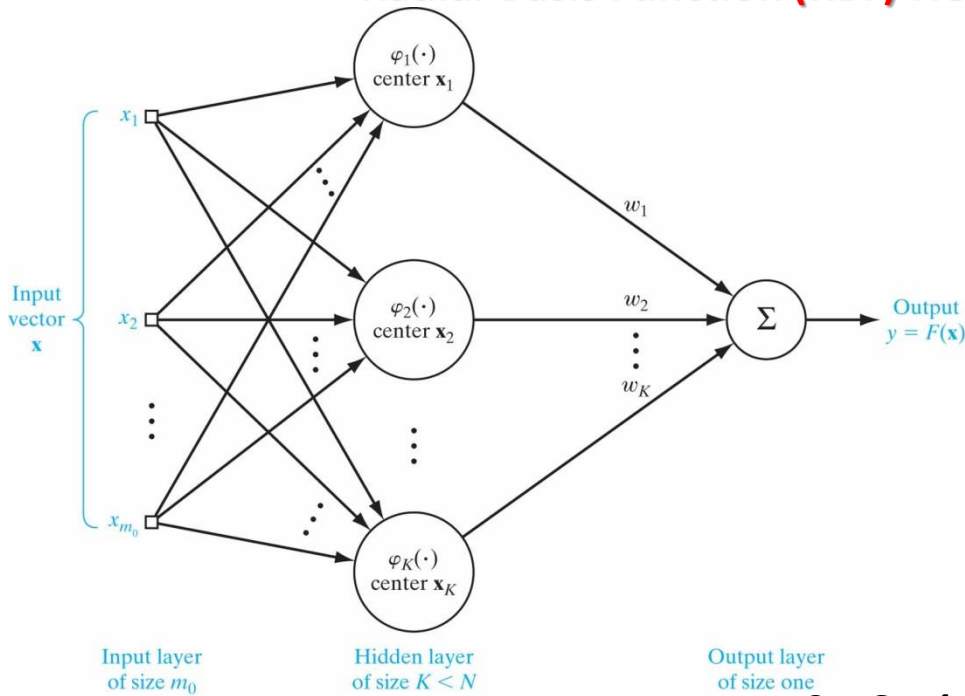
### Ρύθμιση Παραμέτρων Δικτύου

$$w_1 = w_2 = -0.9843$$

$$w_3 = w_4 = 1.5188$$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Radial-Basis Function (RBF) Networks – Πρακτική Υλοποίηση



Τα δίκτυα RBF χαρακτηρίζονται από γρήγορη **φάση μάθησης** αλλά απαιτούν αποθήκευση μεγάλου αριθμού κρυφών κόμβων  $N$  (ίσων με τον αριθμό των στοιχείων μάθησης), ακριβείς μετρήσεις των  $\{\mathbf{x}_i, d_i\}$  και παρουσιάζουν μεγάλο υπολογιστικό φόρτο στη **φάση test**

### Προσεγγιστική Υλοποίηση

Μικρότερος αριθμός κρυφών κόμβων  $K < N$  που ορίζει χώρο  $K$  διαστάσεων:

$$y = F(\mathbf{x}) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) = \sum_{j=1}^K w_j \varphi(\|\mathbf{x} - \boldsymbol{\mu}_j\|)$$

### Υβριδική Μάθηση

Προσδιορισμός των  $K < N$  **Κέντρων**  $\mathbf{x}_j$  και των **Συναπτικών Βαρών**  $w_j$ ,  $j = 1, 2, \dots, K$

- **Input Layer:** Διάνυσμα  $\mathbf{x}$  διαστάσεως  $m_0$  (αριθμός **features**)
- **Hidden Layer:**  $K$  κρυφοί κόμβοι  $\varphi(\|\mathbf{x} - \boldsymbol{\mu}_j\|)$  με κέντρα  $\boldsymbol{\mu}_j$  που προκύπτουν σαν **cluster heads** των  $\mathbf{x}$  από αλγόριθμο **μη επιβλεπόμενης μάθησης K-Means Clustering** με Ευκλείδειο μέτρο απόστασης  $\|\mathbf{x} - \boldsymbol{\mu}_j\|^2$  ( $K$  **υπερπαράμετρος**,  $m_0 \leq K < N$ )
- **Output Layer:** Γραμμικός συνδυασμός των  $K$  συναρτήσεων βάσης  $\varphi_j(\mathbf{x})$  :


$$y = F(\mathbf{x}) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) = \sum_{j=1}^K w_j \varphi(\|\mathbf{x} - \boldsymbol{\mu}_j\|)$$

Εκτίμηση των  $w_j$  από στοιχεία του δείγματος μάθησης  $\{\boldsymbol{\varphi}(\mathbf{x}_i), d_i\}$  με **επιβλεπόμενη μάθηση** κατά προσέγγιση **ελαχίστων τετραγώνων**:  $N$  εξισώσεις  $d_i \cong F(\mathbf{x}_i)$ ,  $K$  άγνωστοι  $w_j$  ( $K < N$ )

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

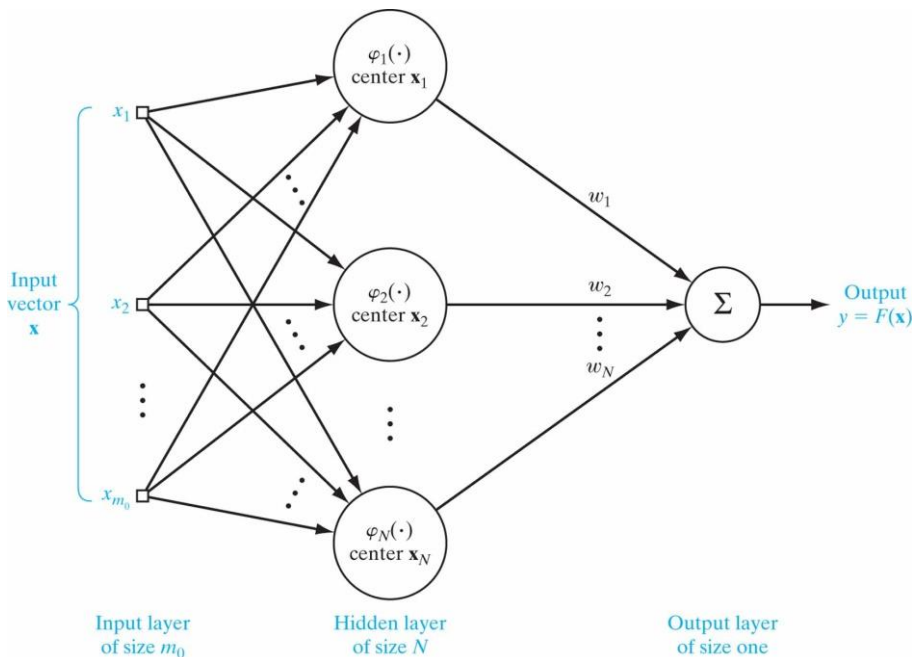
## Multi-layer Perceptron (MLP) vs. RBF

### MLP



- Πολλά επίπεδα κρυφών νευρώνων
- Επιβλεπόμενη Μάθηση
- Batch ή On-line (Stochastic) Learning
- Back-propagation Algorithm
- Μη γραμμική συνάρτηση ενεργοποίησης
- Βραδεία εκπαίδευση
- Ανοχή σε ανακρίβειες μετρήσεων εισόδου

### RBF



- Ένα κρυφό επίπεδο νευρώνων
- Υβριδική Μάθηση (Hybrid Learning)
- Μη γραμμικός μετασχηματισμός διανυσματικών σημείων μέσω Radial-Basis Functions (Gaussian)
- Ευελιξία στη διαχωριστικότητα περιοχών κατάταξης διανυσματικών σημείων (pattern vectors)
- Γρήγορη εκπαίδευση
- Ευαισθησία σε ανακρίβειες μετρήσεων δειγματικών σημείων
- Η υπερ-επιφάνεια δυαδικού διαχωρισμού γενικεύεται για ανακριβή ή νέα δειγματικά σημεία με interpolation

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ


## Support Vector Machines (SVM) – Γραμμικά Διαχωριζόμενες Περιοχές Ταξινόμησης (1/2)

- Για *labeled* δείγμα μάθησης  $\{\mathbf{x}_i, d_i\}$ ,  $d_i \in \{-1, +1\}$ ,  $i = 1, 2, \dots, N$  η **SVM** ορίζει βέλτιστες περιοχές δυαδικής ταξινόμησης με τη μέγιστη διαχωριστική ζώνη (περιθώριο διαχωρισμού - *margin of separation*) μεταξύ τους
- Για περιπτώσεις γραμμικά διαχωριζόμενων διανυσματικών στοιχείων  $\mathbf{x}$  (*patterns*) με  $m$  διαστάσεις (*features*) το υπερ-επίπεδο διαχωρισμού ορίζεται από την εξίσωση

$$\mathbf{w}^T \mathbf{x} + b = 0 \text{ όπου } \mathbf{w} \text{ συναπτικά βάρη και } b \text{ bias}$$

- Η ταξινόμηση του σημείου μάθησης  $\mathbf{x}_i$  ακολουθεί τον κανόνα:

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i + b &\geq 0 \text{ αν } d_i = +1 \\ \mathbf{w}^T \mathbf{x}_i + b &< 0 \text{ αν } d_i = -1 \end{aligned}$$



- Η απόσταση του πλησιέστερου σημείου από το υπερεπίπεδο διαχωρισμού ορίζει το περιθώριο  $\rho$  που πρέπει να μεγιστοποιηθεί για **βέλτιστο διαχωρισμό**:  $\mathbf{w}_o^T \mathbf{x} + b_o = 0$
- Γεωμετρικά προκύπτει πως  $\rho = \frac{2}{\|\mathbf{w}_o\|}$  όπου  $\|\mathbf{w}_o\|$  το Ευκλείδειο μέτρο του διανύσματος  $\mathbf{w}_o$
- Για τα στοιχεία του δείγματος μάθησης  $\{\mathbf{x}_i, d_i\}$  για κανονικό υπερεπίπεδο διαχωρισμού:
$$\begin{aligned} \mathbf{w}_o^T \mathbf{x}_i + b_o &\geq 1 \text{ αν } d_i = +1 \\ \mathbf{w}_o^T \mathbf{x}_i + b_o &\leq -1 \text{ αν } d_i = -1 \end{aligned}$$
- Τα διανύσματα  $\mathbf{x}_i$  για τα οποία ισχύει η ισότητα σε μια από τις δύο ανισότητες είναι τα **Support Vectors** (**Διανύσματα Υποστήριξης**)  $\mathbf{x}_i^S$  στα όρια της διαχωριστικής ζώνης
- Οι ανισότητες ενοποιούνται σαν περιορισμοί (**constraints**) για το δείγμα μάθησης:
$$d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, N$$

## Support Vector Machines (SVM) – Γραμμικά Διαχωριζόμενες Περιοχές Ταξινόμησης (2/2)

(βασισμένο στη παρουσίαση «Μηχανές Διανυσμάτων Υποστήριξης», **Γ. Στάμου**, ΣΗΜΜΥ Ε.Μ.Π.

[http://mycourses.ntua.gr/courses/ECE1078/document/%D5%EB%E9%EA%FC\\_%C4%E9%E1%EB%D%E5%E5%F9%ED\\_2019-2020/NN-SVM-handouts.pdf](http://mycourses.ntua.gr/courses/ECE1078/document/%D5%EB%E9%EA%FC_%C4%E9%E1%EB%D%E5%E5%F9%ED_2019-2020/NN-SVM-handouts.pdf))

### Διατύπωση σαν Πρόβλημα Μη Γραμμικού Προγραμματισμού

**Μεγιστοποίηση** περιθωρίου διαχωρισμού  $\rho = \frac{2}{\|\mathbf{w}_o\|} \Leftrightarrow$  **Ελαχιστοποίηση**  $\|\mathbf{w}_o\|^2 = \mathbf{w}_o^T \mathbf{w}_o$

Πρόβλημα βελτιστοποίησης με περιορισμούς για προσδιορισμό των παραμέτρων της SVM (synaptic weights  $\mathbf{w}$  και bias  $b$ ):

$$\min_{\mathbf{w}} \Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} \quad \text{όταν} \quad d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, N$$

Η συνάρτηση κόστους είναι άθροισμα τετραγώνων και οι περιορισμοί γραμμικοί. Το βέλτιστο  $\mathbf{w}$  μπορεί να προσδιορισθεί με κλασική μέθοδο μη γραμμικού προγραμματισμού, π.χ. με χρήση **Lagrange Multipliers**  $\lambda_i$  για τους περιορισμούς  $d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1$

Ορίζω συνάρτηση κόστους  $J(\mathbf{w}, b, \lambda_1, \lambda_2, \dots, \lambda_N) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \lambda_i [d_i(\mathbf{w}^T \mathbf{x}_i + b)]$

Στο βέλτιστο σημείο και για τα  $N$  στοιχεία μάθησης  $\mathbf{x}_i$  ισχύουν οι συνθήκες **Kuhn-Tucker**:


$$\frac{\partial J}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \lambda_i d_i \mathbf{x}_i$$

$$\frac{\partial J}{\partial b} = 0 \rightarrow \sum_{i=1}^N \lambda_i d_i = 0$$

- Τα  $\mathbf{w}, b$  προσδιορίζουν το βέλτιστο υπερεπίπεδο διαχωρισμού  $\mathbf{w}^T \mathbf{x} + b = 0$
- Τα **Support Vectors**  $\mathbf{x}_i^s$  αντιστοιχούν σε  $\lambda_i > 0$ . Τα υπόλοιπα  $\mathbf{x}_i$  σε  $\lambda_i = 0$

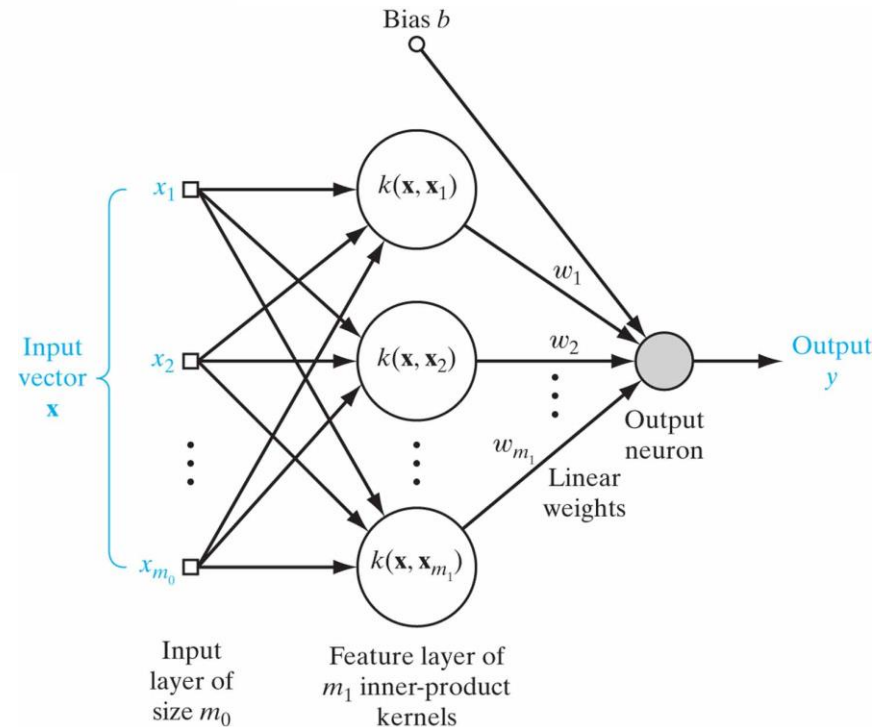
# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Support Vector Machines (SVM) – Μη Γραμμικά Διαχωριζόμενες Περιοχές Ταξινόμησης



### Παραβάσεις Γραμμικής Διαχωρισιμότητας:

- $\{\mathbf{x}_i, d_i\}$  εντός της διαχωριστικής ζώνης από την σωστή πλευρά του βέλτιστου υπερεπιπέδου
- $\{\mathbf{x}_i, d_i\}$  εντός της διαχωριστικής ζώνης από την λάθος πλευρά του βέλτιστου υπερεπιπέδου



### Αρχιτεκτονική SVM με χρήση Δικτύου RBF

Χρήση μεγάλου αριθμού *hidden nodes*  $m_1$  (μικρότερο ή ίσο από τον αριθμό στοιχείων του δείγματος μάθησης  $N$ ) που μετασχηματίζουν μη γραμμικά διαχωρίσιμες περιοχές των διανυσμάτων εισόδου  $\mathbf{x}$  διαστάσεως  $m_0 \ll m_1$  σε γραμμικά διαχωρίσιμες περιοχές