

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Μη Επιβλεπόμενη Μάθηση - Unsupervised Learning**

***K*-Means Clustering**

**Ανάλυση Κυρίων Συνιστωσών - Principal Component Analysis (PCA)**

**Self-Organizing Maps (SOM)**

**Autoencoders**

καθ. Βασίλης Μάγκλαρης

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

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

Μέσω Πλατφόρμας Webex

Τρίτη 5/3/2024

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

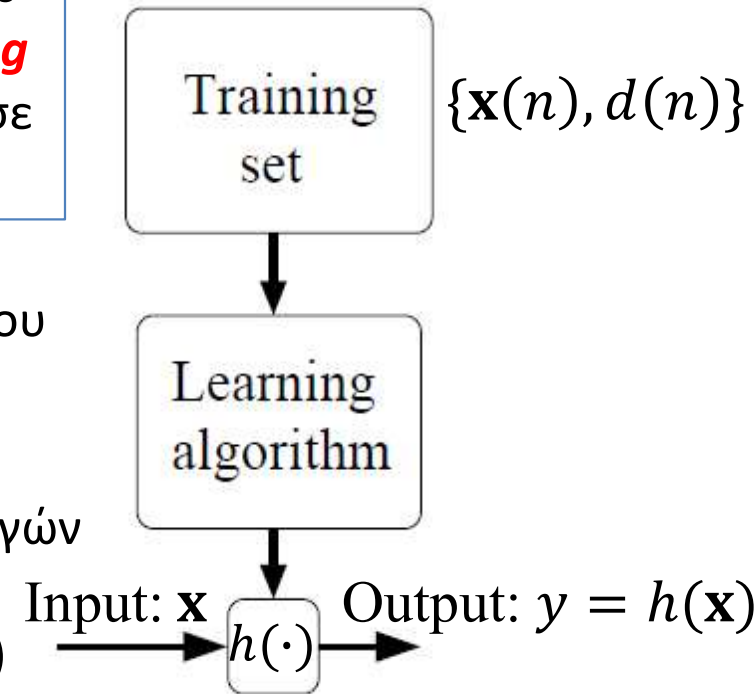
## Γενικό Μοντέλο Επιβλεπόμενης Μάθησης - Supervised Learning (επανάληψη)

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**)

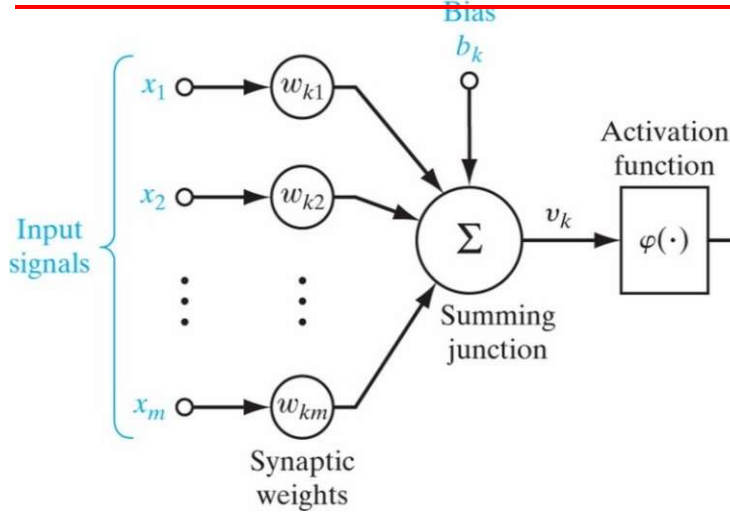
- Η μορφή και οι παράμετροι της  $h(\cdot)$  προσδιορίζονται με αλγόριθμο μάθησης που συγκλίνει σε προσέγγιση του στόχου της υπόθεσης για τα  $N$  στοιχεία του δείγματος μάθησης  $d(n) \cong y(n) = h(\mathbf{x}(n))$
- Αν ο στόχος ικανοποιείται με μικρό αριθμό διακριτών επιλογών (κλάσεων) της  $y$  πρόκειται 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

## Επιβλεπόμενη Μάθηση & Νευρωνικά Δίκτυα (επανάληψη)

### Διαδικό Μοντέλο McCulloch - Pitts




Διαδική  $\varphi(\cdot)$  μη γραμμικού νευρώνα  $k$ :

- **Signum Function:**  $y_k = \varphi(v_k) = \text{sgn}(v_k) = \begin{cases} -1, & v_k < 0 \\ 0, & v_k = 0 \\ +1, & v_k > 0 \end{cases}$


Εναλλακτικές επιλογές  $\varphi(\cdot)$ :

- **Threshold Function:**  $\varphi(v_k) = \begin{cases} 0, & v_k < 0 \\ 1, & v_k \geq 0 \end{cases}$



- **Hyperbolic Tangent:**  $\varphi(v_k) = \tanh(v_k)$

- **Logistic Function:**  $\varphi(v_k) = \frac{1}{1 + \exp(-av_k)}$




- **Γραμμικός νευρώνας:**  $\varphi(v_k) = v_k = \mathbf{w}_k^T \mathbf{x}_k$

- **Rectified Linear Unit ReLU:**  $\varphi(v_k) = \max\{0, v_k\}$

### Μultilayer Perceptron (MLP)

Διαφορίσιμες μη γραμμικές  $\varphi_j(v_j)$  νευρώνα  $j$  (π.χ. **Logistic Function**)



### Επιβλεπόμενη Μάθηση

#### Back Propagation Algorithm

Προσδιορισμός βαρών  $\mathbf{w}_k$  ώστε να ελαχιστοποιείται η μέση απόκλιση (**MSE**)  $y_k(n)$  από τα **labels**  $d(n)$ :

$$\min_{\mathbf{w}_k} \left\{ \frac{1}{2N} \sum_{n=1}^N [d(n) - y_k(n)]^2 \right\}$$

διαδοχικά, με εισόδους των  $N$  παραδειγμάτων μάθησης  $\mathbf{x}(n)$  σε δύο φάσεις: **Forward, Backward**

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Μη Επιβλεπόμενη Μάθηση – Unsupervised Learning, Hebbian Learning

- Εκτίμηση *a-priori* πιθανοτήτων  $p(\mathbf{x})$  του δειγματικού στοιχείου  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  με  $m$  χαρακτηριστικά - *features*  $x_i$  π.χ. *K-Means Clustering* - επιλογή  $K$  Κέντρων Βάρους Συστοιχιών (*cluster centroids*) και κατανομή σε *clusters* των σημείων  $\mathbf{x}$
- Δεν υπάρχει εκ των προτέρων κατηγοριοποίηση (*labelling*) δεδομένων. Το σύστημα με βάση στατιστικές εκτιμήσεις για τα χαρακτηριστικά (*features*) των δειγματικών στοιχείων μάθησης (*training examples*)  $\mathbf{x}$  και σχεδιαστικούς κανόνες (π.χ. κανόνα μάθησης *Hebb*) ορίζει συνάρτηση εξόδου  $y = h_{\mathbf{w}}(\mathbf{x})$ . Είσοδοι νέων δειγματικών στοιχείων *test* δοκιμάζουν την ικανότητα γενίκευσης (*generalization*) του μοντέλου  $h_{\mathbf{w}}(\cdot)$  που βασίστηκε σε στατιστικές παραδοχές του δείγματος μάθησης (*training dataset*) & επικύρωσης (*validation dataset*)
- Η μη επιβλεπόμενη μάθηση περιλαμβάνει συστήματα αυτο-οργάνωσης (π.χ. *Self-Organizing Maps - SOM, Autoencoders*) και μαθηματικά εργαλεία επιλογής κυριάρχων χαρακτηριστικών (*principal components*) για την αποτελεσματική επεξεργασία - αποθήκευση - ταξινόμηση δεδομένων, π.χ. για επεξεργασία σήματος (*speech - image processing*) και αναγνώριση προτύπων (*pattern recognition*)

### Διευκρίνιση: Στατιστική Θεώρηση Δειγματικών Δεδομένων

Ένα δείγμα (*sample*) δεδομένων είναι (υπο)σύνολο  $N$  διανυσματικών δειγματικών στοιχείων (παραδειγμάτων)  $\mathbf{x}$  που επιλέγονται ανάμεσα στα διανύσματα του δειγματικού χώρου. Οι συνιστώσες  $x_i$  των διανυσμάτων  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  κωδικοποιούν τα  $m$  χαρακτηριστικά (*features*) τους σαν δειγματικές τιμές (*sample values*) τυχαίων μεταβλητών

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Διαμόρφωση Συστάδων μέσω $K$ -Means Clustering

Οργάνωση (*encoding*)  $K$  συστάδων (*clusters*)  $N$  *unlabeled* παραδειγμάτων μάθησης

$\mathbf{x}(n) = [x_1(n) \ x_2(n) \ \dots \ x_m(n)]^T$  βάσει ομοίων χαρακτηριστικών (*unsupervised learning*)

- Καθορισμός Encoder  $C(n) = j$ : Το  $\mathbf{x}(n)$ ,  $n = 1, 2, \dots, N$  ανήκει στο *cluster*  $j = 1, 2, \dots, K$
- Symmetric Measure of Similarity  $d(\mathbf{x}(n), \mathbf{x}(n')) = d(\mathbf{x}(n'), \mathbf{x}(n))$


Τετραγωνική Ευκλείδεια Απόσταση:  $d(\mathbf{x}(n), \mathbf{x}(n')) \triangleq \|\mathbf{x}(n) - \mathbf{x}(n')\|^2$

- Εκτιμώμενο Κέντρο Βάρους  $\hat{\boldsymbol{\mu}}_j$  (*centroid*) του *cluster*  $j = 1, 2, \dots, K$  (μέσες Ευκλείδειες αποστάσεις των  $\mathbf{x}(i)$  από  $\hat{\boldsymbol{\mu}}_j$  για τις επιλογές του encoder  $C(n) = j$ )
- Κόστος  $J(C) = \frac{1}{2} \sum_{j=1}^K \sum_{C(n)=j} \sum_{C(n')=j} \|\mathbf{x}(n) - \mathbf{x}(n')\|^2 = \sum_{j=1}^K \sum_{C(n)=j} \|\mathbf{x}(n) - \hat{\boldsymbol{\mu}}_j\|^2$
- Κριτήριο Ελαχιστοποίησης: Διαφορά  $\hat{\boldsymbol{\sigma}}_j^2 \triangleq \sum_{C(n)=j} \|\mathbf{x}(n) - \hat{\boldsymbol{\mu}}_j\|^2$ ,  $\min_C J(C) = \min_C \sum_{j=1}^K \hat{\boldsymbol{\sigma}}_j^2$

**Αλγόριθμος μη επιβλεπόμενης μάθησης: Αυτό-οργάνωση  $N$  σημείων σε  $K$  συστάδες**


- Αρχική επιλογή *centroids* για υπερπαραμέτρο  $K$ : Αυθαίρετη επιλογή  $K$  κέντρων βάρους
- Τοποθέτηση των  $N$  σημείων  $\mathbf{x}(n)$  στο πλησιέστερο *centroid*, ανανέωση εκτιμήσεων *centroids*  $\hat{\boldsymbol{\mu}}_j, j = 1, 2, \dots, K$  και επαναλήψεις μέχρι τη τελική σύγκληση του  $C(n) = j$
- Η εκτέλεση του αλγορίθμου είναι αποτελεσματική αλλά χωρίς εγγύηση βέλτιστης λύσης
- Η επιλογή  $K$  συνήθως απαιτεί επαναλήψεις (π.χ. με δοκιμές και συγκρίσεις μέσω τετραγωνικών σφαλμάτων για αυξανόμενο  $K$  μέχρι το γόνατο της καμπύλης βελτίωσης)

Παράδειγμα:  $K = 3, N = 12$   
([https://en.wikipedia.org/wiki/K-means\\_clustering](https://en.wikipedia.org/wiki/K-means_clustering))




Αρχικοποίηση

*Centroids*




1<sup>η</sup> Διαμόρφωση

*Clusters*



Προσδιορισμός

Νέων *Centroids*



Τελική Πρόταση

*Clusters*

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Μη Επιβλεπόμενη Μάθηση: Ανάλυση Κυρίων Συνιστωσών Principal Components Analysis - PCA

### The Curse of Dimensionality:

Σε ένα δειγματικό χώρο δεδομένων  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  η κωδικοποίηση των χαρακτηριστικών του δείγματος μπορεί να απαιτεί μεγάλο αριθμό διακριτών στοιχείων  $x_i$ ,  $i = 1, 2, \dots, m$ . Για καταγραφή με στατιστική επάρκεια όλων των χαρακτηριστικών απαιτείται αριθμός δειγματικών στοιχείων  $N$  πολλαπλάσιος του  $m$  (π.χ.  $N \gg 5m$ , [https://en.wikipedia.org/wiki/Curse\\_of\\_dimensionality](https://en.wikipedia.org/wiki/Curse_of_dimensionality))

### Reduction of Dimensionality - Principal Components:

Με *Unsupervised Learning* σε γραμμικό σύστημα εισόδου  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  μπορεί να μειωθεί ο αριθμός των χαρακτηριστικών (αριθμός συντεταγμένων  $m$ ) μέσω μετασχηματισμού σε **Αυσχέτιστες Κύριες Συνιστώσες** (*Principal Components*) και έξοδο  $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_l]^T$  με επιλογή των σημαντικότερων συνιστωσών ( $l \ll m$  χαρακτηριστικών) με τη μεγαλύτερη αναμενόμενη διασπορά

### Μεθοδολογίες για Επιλογή Κυρίων Συνιστωσών:

- **Covariance Method**: Μέσω στατιστικής ανάλυσης του διανυσματικού δειγματικού χώρου μάθησης, μετασχηματισμού σε ορθοκανονικό (*orthonormal*) σύστημα συντεταγμένων και με αλγόριθμους επιλογής σημαντικών (*principal*) συνιστωσών (αναλογία με μεθόδους *Γραμμικής Άλγεβρας* και *Θεωρίας Επικοινωνιών* - μετασχηματισμοί *Karhunen - Loève*)
- **Hebbian Learning Method**: Μέσω αυτο-οργάνωσης νευρωνικών δικτύων με τοπικές ρυθμίσεις κανόνων *Hebb* σε μη επιβλεπόμενη μάθηση (*unsupervised learning*)

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Orthonormal Transformation σε Principal Components (1/3)

### Ορισμοί Στατιστικής Προσέγγισης (Covariance Method) της PCA

- Θεωρούμε είσοδο από δειγματικά στοιχεία δεδομένων  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  με  $m$  χαρακτηριστικά (*features*) κωδικοποιημένα στις συνιστώσες  $x_i$
- Οι συνιστώσες  $x_i$  αποτελούν *δειγματικές τιμές* (sample values) *τυχαίων μεταβλητών*  $X_i$  που αναφέρονται σε τυχαία διανύσματα  $\mathbf{X} = [X_1 \ X_2 \ \dots \ X_m]^T$  του δειγματικού χώρου. Υποθέτουμε πως  $E[\mathbf{X}] = E[X_i] = 0$
- Η συμμετρική μήτρα ( $m \times m$ )  $\mathbf{R} = E[\mathbf{X} \mathbf{X}^T]$  είναι η μήτρα συσχέτισης (*Correlation Matrix*) των τυχαίων διανυσμάτων  $\mathbf{X}$  με ιδιοδιανύσματα (*eigenvectors*)  $\mathbf{q}_j$  και ιδιοτιμές (*eigenvalues*)  $\lambda_j$ :  $\mathbf{R} \mathbf{q}_j = \lambda_j \mathbf{q}_j$ ,  $j = 1, 2, \dots, m$  αριθμημένα κατά φθίνουσα σειρά των  $\lambda_j$ :  
$$\lambda_j \mathbf{q}_j^T \mathbf{q}_k = \begin{cases} 1, & k = j \\ 0, & k \neq j \end{cases} \quad \text{και} \quad \mathbf{q}_j^T \mathbf{R} \mathbf{q}_k = \begin{cases} \lambda_j, & k = j \\ 0, & k \neq j \end{cases}$$
- Τα ιδιοδιανύσματα  $\mathbf{q}_j$  ορίζουν ορθοκανονικές (*orthonormal*) κύριες (*principal*) κατευθύνσεις που μετασχηματίζουν το στοιχείο  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  με  $m$  συνιστώσες  $x_i$  σε  $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_m]^T = [\mathbf{x}^T \mathbf{q}_1 \ \mathbf{x}^T \mathbf{q}_2 \ \dots \ \mathbf{x}^T \mathbf{q}_m]$  με  $m$  συνιστώσες  $a_i$  που αποτελούν τις **Κύριες Συνιστώσες** (*Principal Components*). Η αρίθμηση ακολουθεί τη φθίνουσα σειρά των  $\lambda_j = \mathbf{q}_j^T \mathbf{R} \mathbf{q}_j = \text{var}(A_j) \triangleq \sigma_j^2$  όπου  $A_j$  τυχαία μεταβλητή με δειγματική τιμή την κύρια συνιστώσα  $a_j$
- Οι αρχικές συνιστώσες προκύπτουν μονοσήμαντα από τις Κύριες Συνιστώσες:


$$\mathbf{x} = \sum_{j=1}^m a_j \mathbf{q}_j$$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Orthonormal Transformation σε Principal Components (2/3)


Αν αγνοήσουμε τις κύριες συνιστώσες (*principal components*) με τις μικρότερες διασπορές  $\sigma_j^2 = \lambda_j$ ,  $j = l + 1, l + 2, \dots, m$  προκύπτει προσεγγιστική εκτίμηση (κωδικοποίηση) του στοιχείου  $\mathbf{x}$  από το στοιχείο  $\hat{\mathbf{x}}$  με μικρότερο αριθμό συνιστωσών  $l < m$

$$\hat{\mathbf{x}} = [\hat{x}_1 \hat{x}_2 \dots \hat{x}_l] = [\mathbf{q}_1 \mathbf{q}_2 \dots \mathbf{q}_l][a_1 a_2 \dots a_l]^T = \sum_{j=1}^l a_j \mathbf{q}_j \text{ για } l < m$$



Το σφάλμα εκτίμησης  $\mathbf{e} = \mathbf{x} - \hat{\mathbf{x}} = \sum_{i=l+1}^m a_i \mathbf{q}_i$  είναι διάνυσμα ορθογώνιο προς το  $\hat{\mathbf{x}}$ :

$$\mathbf{e}^T \hat{\mathbf{x}} = \sum_{i=l+1}^m a_i \mathbf{q}_i^T \sum_{j=1}^l a_j \mathbf{q}_j = 0$$



- Η συνολική διασπορά των  $m$  ανεξαρτήτων τυχαίων μεταβλητών  $\epsilon X_j$  είναι

$$\sum_{j=1}^m \sigma_j^2 = \sum_{j=1}^m \lambda_j$$

- Η συνολική διασπορά των  $l$  τυχαίων μεταβλητών  $A_j$  είναι  $\sum_{j=1}^l \sigma_j^2 = \sum_{j=1}^l \lambda_j$

$\Rightarrow$  Η συνολική διασπορά του σφάλματος  $\mathbf{e} = \mathbf{x} - \hat{\mathbf{x}}$  είναι  $\lambda_{l+1} + \lambda_{l+2} + \dots + \lambda_m$  που αντιστοιχεί στις κύριες συνιστώσες με τις μικρότερες διακυμάνσεις



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ


## Orthonormal Transformation σε Principal Components (3/3)

Εφαρμογή PCA για Ψηφιακή Συμπύεση & Αναγνώριση Εικόνων Χειρόγραφων Αριθμών  
Image Compression & Pattern Recognition of Handwritten Numbers

### Δειγματικά Στοιχεία Μάθησης:

Σκαναρισμένες εικόνες δέκα χειρόγραφων αριθμών  $\{0,1, \dots, 9\}$

$N = 1700$  στοιχεία/αριθμό



Στήλη 1: Κωδικοποίηση με  $m = 32 \times 32 = 1024$  δυαδικά ψηφία

Στήλη 2: Δειγματικοί Μέσοι Όροι για κανονικοποίηση

Υπολογισμός των  $l = 64$  σημαντικότερων ιδιοδιανυσμάτων

της Μήτρας Συσχέτισης  $m \times m = (1024) \times (1024)$

μετά από κανονικοποίηση των δειγματικών στοιχείων

(αφαίρεση δειγματικών μέσων όρων)

Ανασύσταση Εικόνας με  $l \leq 64$  Principal Components

$$l \ll m = 32 \times 32 = 1024$$

Στήλη 3:  $l = 1$

Στήλη 4:  $l = 5$

Στήλη 5:  $l = 16$

Στήλη 6:  $l = 32$  (ικανοποιητική διάκριση αριθμών)

Στήλη 7:  $l = 64$  (άψογη διάκριση αριθμών με μεγάλη συμπίεση)

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός 1<sup>ης</sup> Κύριας Συνιστώσας από Γραμμικό Νευρώνα με Μάθηση Hebbian (1/2)


### Αρχές Αυτο-οργάνωσης Χαρακτηριστικών (Self-organized Feature Analysis)

**Αξίωμα του Hebb:** Αν τα σήματα στα άκρα μιας νευρωνικής σύναψης  $i$  ενεργοποιούνται ταυτόχρονα (*synchronous update*) στο βήμα  $n$ , το συναπτικό της βάρος  $w_i(n)$  ενισχύεται. Αλλιώς φθίνει προς μηδενισμό (*παραλλαγή από αρχικό αξίωμα για μάθηση με όρους νευροψυχολογίας*)

**Αρχή Ανταγωνιστικότητας:** Οι πιο ενεργές συνάψεις τείνουν να μηδενίσουν τις λιγότερο ενεργές

### Γραμμικό Νευρωνικό Δίκτυο Υπολογισμού *First Principal Component* από $m$ Features **Hebbian-based Maximum Eigenfilter**

$$y(n) = v(n) = \sum_{i=1}^m w_i(n)x_i(n) \text{ στο βήμα } n$$



Τα βάρη αυξάνονται στην επανάληψη  $n \rightarrow n + 1 \leq N$


αν  $y(n)x_i(n) > 0$  (*αξίωμα Hebb*)

$$\text{Hebbian Learning: } w_i(n + 1) = w_i(n) + \eta y(n)x_i(n) \\ i = 1, 2, \dots, m, \eta \text{ learning hyperparameter}$$

Απαιτείται **Normalization** για ευστάθεια. Με βάση την **Αρχή της Ανταγωνιστικότητας** διαιρούμε σε κάθε βήμα με το εκτόπισμα των  $w_k(n)$  που μειώνουν την αύξηση εις βάρος τους:

$$w_i(n + 1) = \frac{w_i(n) + \eta y(n)x_i(n)}{(\sum_{k=1}^m [w_k(n) + \eta y(n)x_k(n)]^2)^{1/2}} \cong w_i(n) + \eta y(n)[x_i(n) - y(n)w_i(n)]$$

Η προσέγγιση ισχύει για μικρές τιμές της παραμέτρου  $\eta$



$$w_i(n + 1) = w_i(n) + \eta y(n)x_i'(n), \\ x_i'(n) = x_i(n) - y(n)w_i(n)$$

Η θετική ανάδραση  $y(n)x_i(n)$  αντισταθμίζεται από την  $y(n)w_i(n)$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός 1<sup>ης</sup> Κύριας Συνιστώσας από Γραμμικό Νευρώνα με Μάθηση Hebbian (2/2)

### Ζητήματα Σύγκλισης

Διανυσματικοί ορισμοί

$$\mathbf{x}(n) = [x_1(n) \ x_2(n) \ \dots \ x_m(n)]^T$$

$$\mathbf{w}(n) = [w_1(n) \ w_2(n) \ \dots \ w_m(n)]^T$$

$$y(n) = \mathbf{w}^T(n)\mathbf{x}(n), \quad \mathbf{w}(n+1) = \mathbf{w}(n) + \eta y(n)[\mathbf{x}(n) - y(n)\mathbf{w}(n)] \Rightarrow$$

Αλγόριθμος αυτό-οργανωμένης μη επιβλεπόμενης μάθησης:

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

- Οι όροι  $\mathbf{x}(n)\mathbf{x}^T(n)$  αποτελούν υλοποίηση της μήτρας συσχέτισης  $\mathbf{R} = E[\mathbf{X}\mathbf{X}^T]$  κατά την επανάληψη  $n \rightarrow n+1 \leq N$  χωρίς μέσους όρους και οδηγούν προς την ανάλυση της σύγκλισης του αλγορίθμου μέσω μη γραμμικής στοχαστικής εξίσωσης διαφορών (εκτός ορίων του μαθήματος)
- Δεν υπάρχει εξωτερική επιρροή στον αλγόριθμο μάθησης λόγω της μη επιβλεπόμενης (αυτό-οργανωμένης, *self-organized*) φύσης του πλην του *a-priori* καθορισμού της *hyperparameter* μάθησης  $\eta$


# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός $l$ Κυρίων Συνιστωσών από Γραμμικούς Νευρώνες με Μάθηση Hebbian (1/3) (Hebbian-based Principal-Component Analysis)

Γενίκευση του Hebbian-based maximum Eigenfilter:

**Γραμμικό Μονοστρωματικό Feedforward Νευρωνικό Δίκτυο** με  $l$  νευρώνες εξόδου για προσδιορισμό των  $l$  σημαντικών Principal Components από διανυσματικά δεδομένα διαστάσεως  $m$ ,  $l < m$

$$y_j(n) = v_j(n) = \sum_{i=1}^m w_{ji}(n)x_i(n), \quad j = 1, 2, \dots, l$$



**Hebbian Learning:** Τα βάρη  $w_{ji}(n)$  από την είσοδο  $x_i(n)$ ,  $i = 1, 2, \dots, m$  προς την  $j$  κύρια συνιστώσα  $y_j(n)$ ,  $j = 1, 2, \dots, l$  διαφοροποιούνται κατά  $\Delta w_{ji}(n)$  στην επανάληψη  $n \rightarrow n + 1$

$$\Delta w_{ji}(n) = \eta \left[ y_j(n)x_i(n) - y_j(n) \sum_{k=1}^j w_{ki}(n)y_k(n) \right], \quad j = 1, 2, \dots, l \quad \& \quad i = 1, 2, \dots, m$$



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός $l$ Κυρίων Συνιστωσών από Γραμμικούς Νευρώνες με Μάθηση Hebbian (2/3) (Hebbian-based Principal-Component Analysis)

### Γενικευμένος Αλγόριθμος του Hebb – Generalized Hebbian Algorithm (GHA)

$$\Delta w_{ji}(n) = \eta y_j(n) [x'_i(n) - w_{ji}(n) y_j(n)], \quad j = 1, 2, \dots, l \text{ και } i = 1, 2, \dots, m$$

$$x'_i(n) = x_i(n) - \sum_{k=1}^{j-1} w_{ki}(n) y_k(n)$$



$$\Delta w_{ji}(n) = \eta y_j(n) x''_i(n) \text{ όπου } x''_i(n) = x'_i(n) - w_{ji}(n) y_j(n)$$

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n), \quad w_{ji}(n) = z^{-1} [w_{ji}(n+1)]$$

### Διανυσματική Μορφή:

$$\Delta \mathbf{w}_j(n) = \eta y_j(n) \mathbf{x}'_i(n) - \eta y_j^2(n) \mathbf{w}_j(n), \quad j = 1, 2, \dots, l$$

$$\text{όπου } \mathbf{x}'(n) = \mathbf{x}(n) - \sum_{k=1}^{j-1} \mathbf{w}_k(n) y_k(n)$$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός $l$ Κυρίων Συνιστωσών από Γραμμικούς Νευρώνες με Μάθηση Hebbian (3/3) (Hebbian-based Principal-Component Analysis)

$$\mathbf{x}'(n) = \mathbf{x}(n) - \sum_{k=1}^{j-1} \mathbf{w}_k(n) y_k(n), \quad j = 1, 2, \dots, l$$

**Για  $j = 1$ :**  $\mathbf{x}'(n) = \mathbf{x}(n)$

Προσδιορισμός 1<sup>ης</sup> κύριας συνιστώσας  $y_1(n)$

**Για  $j = 2$ :**  $\mathbf{x}'(n) = \mathbf{x}(n) - \mathbf{w}_1(n) y_1(n)$

Προσδιορισμός 2<sup>ης</sup> συνιστώσας  $y_2(n)$  σαν 1<sup>η</sup> συνιστώσα μετά από αφαίρεση της ήδη υπολογισθείσας  $y_1(n)$

**Για  $j = 3$ :**  $\mathbf{x}'(n) = \mathbf{x}(n) - \mathbf{w}_1(n) y_1(n) - \mathbf{w}_2(n) y_2(n)$

Προσδιορισμός 3<sup>ης</sup> συνιστώσας  $y_3(n)$  σαν 1<sup>η</sup> συνιστώσα μετά από αφαίρεση των ήδη υπολογισθείσας  $y_1(n)$  και  $y_2(n)$


.....

Οι  $l$  πιο σημαντικές κύριες συνιστώσες αντιστοιχούν στα

ιδιοδιανύσματα  $\mathbf{q}_k$  της μήτρας συσχέτισης  $\mathbf{R} = E[\mathbf{X}\mathbf{X}^T]$ ,  $k = 1, 2, \dots, l$   
αριθμημένες κατά τη φθίνουσα σειρά των ιδιοτιμών  $\lambda_1 > \lambda_2 > \dots > \lambda_l$

και δίνουν την εκτίμηση  $\hat{\mathbf{x}}(n)$  με  $l$  χαρακτηριστικά του δειγματικού στοιχείου  $\mathbf{x}(n)$  με  $m > l$

$$\hat{\mathbf{x}}(n) = \sum_{k=1}^l y_k(n) \mathbf{q}_k \quad \text{για } l < m$$



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Εφαρμογή PCA μέσω Generalized Hebbian Algorithm (GHA) στη Κωδικοποίηση Εικόνας (1/2)

- **Δείγμα Μάθησης:** 2000 σκαναρισμένες εικόνες της **Lena**  $256 \times 256$  pixels, 256 gray levels όπως στην **1<sup>η</sup> εικόνα** δεξιά
- Δειγματικά στοιχεία μάθησης: Εικόνες χωρισμένες σε 1024 μη επικαλυπτόμενα τμήματα (**Blocks**) μεγέθους  $8 \times 8$  pixels:  $m = 64$  features/block
- Το κάθε block ορίζει δειγματικό στοιχείο εισόδου σαν διάνυσμα από  $m$  features (pixels) κωδικοποιημένες σε 256 gray levels (8 bits/pixel):

$$\mathbf{x}(n) = [x_1(n) \ x_2(n) \ \dots \ x_m(n)]^T \quad n = 1, 2, \dots, N$$

- Το δείγμα τροφοδοτεί **Linear Feedforward Δίκτυο** με  $l = 8$  Νευρώνες εξόδου
- Το σύστημα συγκλίνει σε  $m \times l = 64 \times 8$  συναπτικά βάρη  $w_{ji}(n)$  και απολήγει σε 8 εξόδους (κυριότερες συνιστώσες, **Significant Principal Components**):

$$y_j(n) = \sum_{i=1}^m w_{ji}(n) x_i(n), \quad j = 1, 2, \dots, l$$

- Ρυθμός μάθησης (**Learning Rate**):  $\eta = 10^{-4}$
- Τα βάρη (**weights**) μετά τη σύγκλιση παρίστανται στην **2<sup>η</sup> εικόνα** με  $4 \times 2 = 8$  περιοχές (**masks**), 64 τμήματα/mask, σύνολο  $64 \times 8 = 1024$  τμήματα που απεικονίζουν την συνεισφορά των 64 χαρακτηριστικών του δείγματος εισόδου στις 8 εξόδους. Το άσπρο χρώμα υποδηλώνει θετική συνεισφορά ενός χαρακτηριστικού, το μαύρο αρνητική και το γκρι μηδενική
- Στη **3<sup>η</sup> εικόνα** παρουσιάζεται η ανασύσταση της αρχικής με τη συμμετοχή μόνο των  $l = 8$  κυριότερων συνιστωσών της (**l Principal Components**)


$$\hat{\mathbf{x}}(n) = \sum_{k=1}^l y_k(n) \mathbf{q}_k, \quad \mathbf{q}_k = \lim_n \mathbf{w}_k(n), \quad \mathbf{w}_k(n) = [w_{k1}(n) \ w_{k2}(n) \ \dots \ w_{km}(n)]^T$$

- Η **4<sup>η</sup> εικόνα** αποτελεί συμπύεση της **3<sup>ης</sup> εικόνας** με κβαντισμένες τιμές των βαρών ανάλογα με το λογάριθμο της διασποράς τους ( $\sim 0.53$  bits/pixel)

Original Image



Weights



Using First 8 Components



11 to 1 compression



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Εφαρμογή PCA μέσω Generalized Hebbian Algorithm (GHA) στη Κωδικοποίηση Εικόνας (2/2)


- Αρχική Εικόνα (**Peppers**): 256 × 256 pixels, 256 gray levels στην *πάνω εικόνα*

12 to 1 compression μέσω κβαντισμού βαρών των 8 κυριότερων συνιστωσών, με βάρη όπως προσδιορίστηκαν για την εικόνα **Peppers**


Original Image



Weights



Weights




Using First 8 Components

12 to 1 compression μέσω κβαντισμού βαρών των 8 κυριότερων συνιστωσών, με βάρη όπως προσδιορίστηκαν για την εικόνα **Lena** αλλά εφαρμόστηκαν στην εικόνα **Peppers** (**GENERALIZATION ?**)



Weights





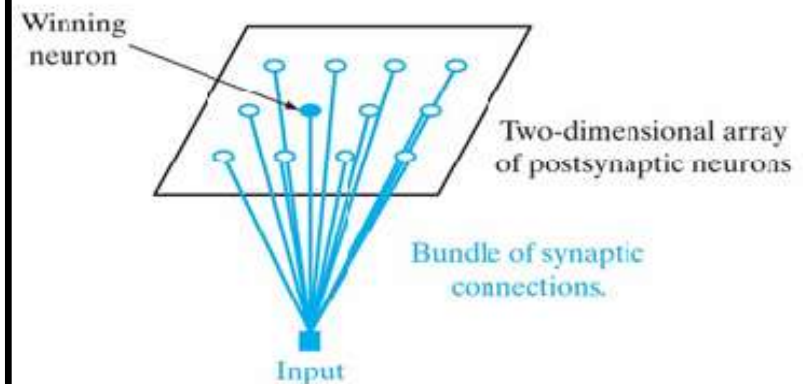
# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Απεικόνιση Διανυσματικών Δειγματικών Στοιχείων σε Νευρωνικά Δίκτυα με Τοπολογικά Κριτήρια Αυτο-οργάνωσης, **Self-Organizing Maps (SOM)**

- Τα **SOM** είναι μη γραμμικά Νευρωνικά Δίκτυα με εισόδους δειγματικά στοιχεία (**παραδείγματα**)  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$   $m$  διαστάσεων (**χαρακτηριστικών**)
- Σε αναλογία με τρόπους αποθήκευσης και επεξεργασίας στον εγκέφαλο των θηλαστικών, ο **Kohonen** πρότεινε το 1982 μοντέλο **μονοστρωματικού Feedforward Neural Network** με μη γραμμικούς νευρώνες  $j = 1, 2, \dots, l$  σε δυσδιάστατο πλέγμα (**Feature Map lattice**) και με κατευθυντικές συνάψεις  $\mathbf{w}_j = [w_{j1} \ w_{j2} \ \dots \ w_{jm}]^T$  από τους κόμβους εισόδου προς τους (**postsynaptic**) νευρώνες του πλέγματος
- Οι έξοδοι των **postsynaptic** νευρώνων, εφόσον ενεργοποιηθούν, συνθέτουν την εκτίμηση του συστήματος για το παράδειγμα  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  ως προς την πλησιέστερη προσέγγιση σε πρότυπα (**patterns**) που αποθηκεύτηκαν σε περιοχές του πλέγματος. Οι περιοχές αντιστοιχούν σε γειτονιές ενεργών νευρώνων, που καθορίζονται από τον πλησιέστερο νευρώνα (**winner**) προς το διάνυσμα  $\mathbf{x}$  με μη επιβλεπόμενη **Ανταγωνιστική Μάθηση (Competitive Learning)** μέσω αυτο-οργάνωσης (**Self-Organizing Map**)

### Εφαρμογές SOM

- Επιλογή κυρίαρχων χαρακτηριστικών σε πολυδιάστατα δείγματα
- Συμπύεση εικόνων με εντοπισμό παρομοίων υποπεριοχών
- Αναγνώριση προτύπων, ταξινόμηση παραδειγμάτων
- Φιλτάρισμα από παρεμβολές - θορύβους
- Συμπλήρωση ατελών παραδειγμάτων




Μοντέλο SOM, **Kohonen** 1982

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Self-Organizing Maps (SOM) (1/5)

- Ο αλγόριθμος διαμόρφωσης του *feature map* συνδυάζει αρχές νευροφυσιολογίας του **Hebb** για τοπολογική αυτό-οργάνωση νευρωνικών δικτύων σε πλέγματα *postsynaptic neurons*
- Αποθηκεύει μέσω μη-επιβλεπόμενης μάθησης *πρότυπα (patterns)* που προκύπτουν από το δείγμα μάθησης με επιλογή των σημαντικότερων χαρακτηριστικών τους  $l \ll m$  (*data compression, dimensionality reduction*)
- Το ήδη διαμορφωμένο δίκτυο **SOM** ανασυνθέτει κατ' εκτίμηση και αναγνωρίζει ελλειμματικά ή παραμορφωμένα νέα παραδείγματα (π.χ. λόγω θορύβου) με βάση τη στατιστική συνάφεια προς αποθηκευμένα πρότυπα
- Σύγκριση με **K-Means Clustering**: Με ικανοποιητικό αριθμό νευρώνων το **SOM** υποδεικνύει τον κατάλληλο αριθμό *clusters (winning neurons)* χωρίς επαναλήψεις του αλγορίθμου!

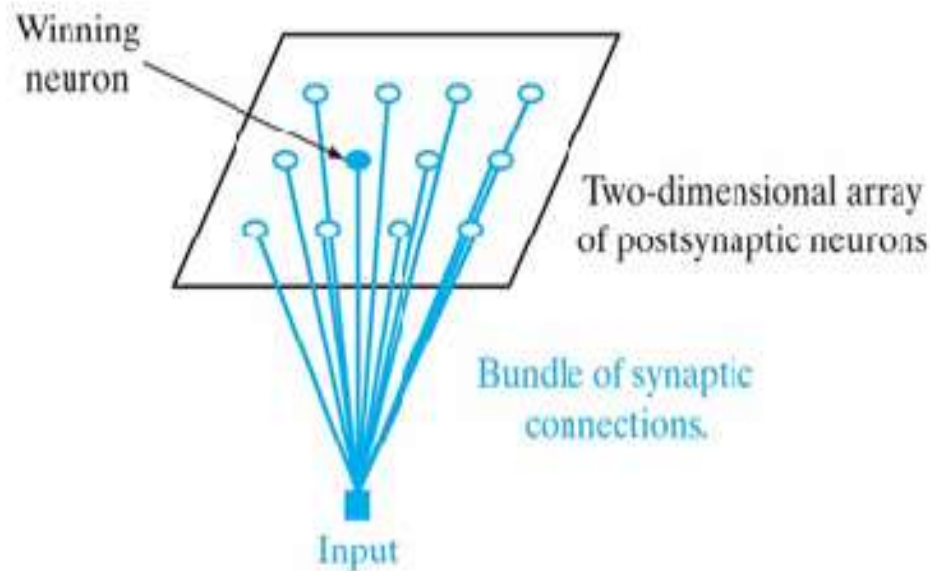


Διάταξη Πλέγματος  
Νευρώνων με Είσοδο 3  
Χαρακτηριστικών και  
4 × 4 Διάσταση Εξόδου

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Self-Organizing Maps (SOM) (2/5)

- Ο αλγόριθμος **μη επιβλεπόμενης μάθησης** ανακαλύπτει τον **πλησιέστερο** νευρώνα (**winning neuron**) για κάθε διάνυσμα εισόδου (δειγματικό στοιχείο μάθησης)  $x$  με **Ανταγωνιστική Διαδικασία** (**Competition Process**) που μεγιστοποιεί διακριτική συνάρτηση (**discriminant function**)
- Ο **winner** καθορίζει την περιοχή των ενεργών νευρώνων σε **Συνεργατική Διαδικασία** (**Cooperation Process**) με γειτονικούς του νευρώνες στο πλέγμα, με αποτέλεσμα την αυτο-οργάνωση ενεργών χαρακτηριστικών σε τοπογραφικό **feature map**
- Σε περιβάλλον **αυτο-οργάνωσης**, που ακολουθεί τους κανόνες του **Hebb**, το διάνυσμα των παραμέτρων (συναπτικών βαρών)  $w_j$  αλλάζει με τη διαδοχική είσοδο παραδειγμάτων  $x$ . Απαιτείται διόρθωση με **Διαδικασία Προσαρμογής** (**Adaptive Process**) που να εγγυάται πως τα βάρη δεν αυξάνουν συνεχώς και επομένως ο επαναληπτικός αλγόριθμος μάθησης είναι ευσταθής



Μοντέλο SOM, **Kohonen** 1982

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ


## Self-Organizing Maps (SOM) (3/5)

### Ανταγωνιστική Διαδικασία

Ο αλγόριθμος **μη επιβλεπόμενης μάθησης** ανακαλύπτει τον **πλησιέστερο** νευρώνα  $j$  (**winner**) για κάθε διάνυσμα εισόδου (δειγματικό στοιχείο, παράδειγμα μάθησης)  $\mathbf{x}$  με **ανταγωνισμό** (**Competition**) που μεγιστοποιεί διακριτική συνάρτηση (**discriminant function**) ανάλογη με το εσωτερικό γινόμενο  $\mathbf{w}_j^T \mathbf{x}$

- Για κάθε παράδειγμα μάθησης  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  επιλέγεται διάνυσμα συναπτικών βαρών  $\mathbf{w}_j = [w_{j1} \ w_{j2} \ \dots \ w_{jm}]^T$  προς τους  $j = 1, 2, \dots, l$  **postsynaptic neurons** του πλέγματος
- Επιλέγεται σαν **winning neuron** ο νευρώνας  $i(\mathbf{x})$  με το μέγιστο εσωτερικό γινόμενο  $\mathbf{w}_j^T \mathbf{x}$  σαν το κέντρο διέγερσης της περιοχής του πλέγματος. Η επιλογή του ισοδυναμεί με το σημείο ελάχιστης Ευκλείδειας απόστασης μεταξύ των διανυσμάτων  $\mathbf{x}$  και  $\mathbf{w}_j$  αν  $\|\mathbf{w}_j\| = 1$  οπότε


$$i(\mathbf{x}) = \arg \min_j \|\mathbf{x} - \mathbf{w}_j\|$$



Μοντέλο SOM, *Kohonen* 1982

### Συνεργατική Διαδικασία

- Ο *winning neuron*  $i(\mathbf{x})$  προσδιορίζει περιοχή  $h_{j,i(\mathbf{x})}$  διεγερμένων γειτονικών νευρώνων  $j$  σε απόσταση (*lateral distance*)  $d_{j,i(x)}$
- Συνήθης επιλογή: *Gaussian Function*  $h_{j,i(\mathbf{x})} = \exp\left(-\frac{d_{j,i(x)}^2}{2\sigma^2}\right)$
- Η παράμετρος  $\sigma$  μπορεί να μειώνεται όσο προχωράει η διαδικασία μάθησης, μειώνοντας τις χωρικές εξαρτήσεις (*correlations*) των νευρώνων στο πλέγμα και τον χρόνο ανανέωσης των συναπτικών βαρών (*updates of synaptic weights*)



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Self-Organizing Maps (SOM) (5/5)

### Διαδικασία Προσαρμογής

- Σε περιβάλλον *αυτό-οργάνωσης*, που ακολουθεί τους κανόνες του **Hebb**, το διάνυσμα των παραμέτρων (συναπτικών βαρών)  $\mathbf{w}_j$  αλλάζει με τη διαδοχική είσοδο παραδειγμάτων  $\mathbf{x}$
- Απαιτείται διόρθωση που να εγγυάται πως τα βάρη δεν αυξάνουν συνεχώς και επομένως ο επαναληπτικός αλγόριθμος μάθησης είναι ευσταθής
- Ορισμός **όρου λήθης** (*forgetting term*)  $g(y_i)\mathbf{w}_j$  όπου  $g(y_i)$  θετική συνάρτηση της εξόδου  $y_i$  με  $g(y_i) = 0$  για  $y_i = 0$
- Οι επαναλήψεις προσδιορισμού των συναπτικών βαρών οδηγούνται από τις διαφορές

$$\Delta \mathbf{w}_j = \eta y_i \mathbf{x} - g(y_i) \mathbf{w}_j$$

$\eta$ : *learning hyperparameter*,

$y_i \mathbf{x}$ : *Hebbian term*

$g(y_i) \mathbf{w}_j$ : *forgetting term*

- Με γραμμικό ορισμό του *forgetting term*  $g(y_i) = \eta y_i$  και με  $y_i = h_{j,i(\mathbf{x})}$  έχουμε

$$\Delta \mathbf{w}_j = \eta h_{j,i(\mathbf{x})} (\mathbf{x} - \mathbf{w}_j) \text{ όπου } i(\mathbf{x}) \text{ ο } \mathbf{winning neuron} \text{ για είσοδο } \mathbf{x}$$

- Στην επανάληψη  $n \rightarrow n + 1$  με μειούμενη υπερπαραμέτρο  $\eta(n)$ :

$$\mathbf{w}_j(n + 1) = \mathbf{w}_j(n) + \eta(n) h_{j,i(\mathbf{x})}(n) (\mathbf{x}(n) - \mathbf{w}_j(n))$$

- Τα συναπτικά βάρη του *winning neuron* τείνουν προς το παράδειγμα εισόδου  $\mathbf{x}$  και τα συναπτικά βάρη των νευρώνων της γειτονιάς του τείνουν στατιστικά προς την κατανομή του δείγματος των  $\mathbf{x}$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Autoencoders

### Encoder:

Input  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$

Output  $\mathbf{h} = \mathbf{F}_e(\mathbf{x}) = [h_1 \ h_2 \ \dots \ h_l]^T$ ,  $l \ll m$  (*code, latent variables*)

### Decoder:

Input  $\mathbf{h} = [h_1 \ h_2 \ \dots \ h_l]^T$

Output  $\mathbf{x}' = \mathbf{F}_d(\mathbf{h}) = [x_1' \ x_2' \ \dots \ x_m']^T$  (*reconstruction* του  $\mathbf{x}$ )


### Bottleneck:

Ενδιάμεσα Στρώματα Κρυφών Νευρώνων που επεξεργάζονται τις  $l$  *latent variables*

### Αλγόριθμος Μάθησης (*Unsupervised Learning*):

Ελαχιστοποίηση απόκλισης  $\|\mathbf{x} - \mathbf{x}'\|^2$  με επαναλήψεις *backpropagation* σε εισόδους στοιχείων *unlabeled* δείγματος μάθησης

encoder                      bottleneck                      decoder



Ο *decoder* δεν είναι απαραίτητος **μετά** τη διαδικασία μάθησης – ρύθμισης των παραμέτρων του *encoder* για κωδικοποίηση μέσω τροποποιημένων σημαντικών χαρακτηριστικών του δείγματος (*latent variables*)

- Οι *latent variables* αποκαλύπτουν *reduced feature maps*. Αν τα νευρωνικά δίκτυα είναι γραμμικά με μηδενικά *bias* αποτελούν τις  $l$  κύριες συνιστώσες *unlabeled* δείγματος
- Μπορούν να χρησιμοποιηθούν για *image compression, pattern recognition, διόρθωση & συμπλήρωση ατελών δειγματικών στοιχείων, ανίχνευση ανωμαλιών* κλπ. όταν δεν είναι διαθέσιμο *labeled training dataset*