

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Μη Επιβλεπόμενη Μάθηση - Unsupervised Learning**

***K*-Means Clustering**

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

καθ. Βασίλης Μάγκλαρης

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

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

(μέσω Webex)

Πέμπτη 11/3/2021

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

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

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

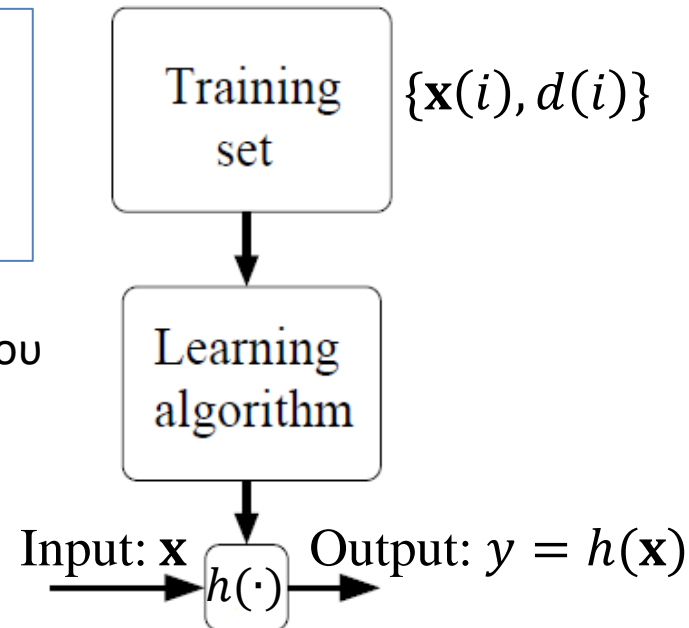
- Στόχος του συστήματος είναι η αντιστοίχιση ενός δειγματικού στοιχείου εισόδου (**input sample point, example**)  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  σε τιμές εξόδου  $y$  που εκτιμούν επιθυμητές (**desired**) τιμές  $d$  (π.χ. πρόβλεψη ή ταξινόμηση). Τα στοιχεία  $x_i$  είναι αριθμητικές τιμές 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  $\{\mathbf{x}(i), d(i)\}, i = 1, 2, \dots, N$  γνωστών σε εξωτερικό εκπαιδευτή (**supervisor**)

- Η σχεδίαση της  $h(\cdot)$  βασίζεται σε αλγόριθμο μάθησης, με προσαρμογή της μορφής και των παραμέτρων ενός μοντέλου ώστε να προσεγγίζεται ο στόχος της υπόθεσης

$$d(i) \cong y(i) = h(\mathbf{x}(i))$$

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



# 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  $m$  *features*  $x_i$  π.χ. *K-Means Clustering* - επιλογή  $K$  Κέντρων Βάρους Συστοιχιών (*cluster centroids*) και κατανομή σε *clusters* δυσδιάστατων σημείων  $\mathbf{x} = [x_1 \ x_2]^T$
- Δεν υπάρχει εκ των προτέρων κατηγοροποίηση (*labelling*) δεδομένων. Το σύστημα με βάση *features* δειγματικών στοιχείων  $\mathbf{x}$  (π.χ. συντεταγμένες σημείων σε δύο διαστάσεις) ορίζει επιθυμητή έξοδο  $d$  και χειρίζεται νέα στοιχεία ως προς αυτή (π.χ. συμμετοχή στο πλησιέστερο *cluster centroid*) μέσω μετασχηματισμού (συνάρτησης)  $y = h_w(\mathbf{x}) \rightarrow d$  με στατιστικά κριτήρια
- Τα συστήματα με μη επιβλεπόμενη μάθηση βασίζονται σε αυτο-οργάνωση (π.χ. *Self-Organizing Maps - SOM*) και μαθηματικά εργαλεία ανίχνευσης κοινών χαρακτηριστικών (*features, patterns*) για την αποτελεσματική επεξεργασία – αποθήκευση – ταξινόμηση δεδομένων χωρίς εξωτερική βοήθεια, π.χ. για επεξεργασία σήματος (*speech – image processing*) και αναγνώριση προτύπων (*pattern recognition*)

### Διευκρίνιση: Στατιστική Θεώρηση Δειγματικών Δεδομένων

Ένα δείγμα (*sample*) δεδομένων είναι σύνολο  $N$  διανυσματικών στοιχείων  $\mathbf{x}$  που επιλέγονται με πιθανότητα  $p(\mathbf{x})$  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 σε  $K$  συστάδες (*clusters*)  $N$  δειγματικών στοιχείων  $\mathbf{x}(i) = [x_1(i) \ x_2(i) \ \dots \ x_m(i)]^T$  με βάση κοινά χαρακτηριστικά από *unlabeled* δείγμα χωρίς δάσκαλο (*unsupervised learning*)

### Ορισμοί:

- **Encoder  $C$**   $C(i) = j$ : Το στοιχείο  $\mathbf{x}(i)$ ,  $i = 1, 2, \dots, N$  ανήκει στο *cluster*  $j = 1, 2, \dots, K$
- **Measure of Similarity**  $d(\mathbf{x}(i), \mathbf{x}(i'))$  π.χ. **Τετραγωνική Ευκλείδεια Απόσταση**  $\|\mathbf{x}(i) - \mathbf{x}(i')\|^2$
- **Εκτιμώμενο κέντρο βάρους  $\hat{\mu}_j$  (*centroid*)** του *cluster*  $j = 1, 2, \dots, K$  (μέσες Ευκλείδειες αποστάσεις των  $\mathbf{x}(i)$  από  $\hat{\mu}_j$  για τις επιλογές του encoder  $C(i) = j$ )

### • Συνάρτηση Κόστους


$$J(C) = \frac{1}{2} \sum_{j=1}^K \sum_{C(i)=j} \sum_{C(i')=j} \|\mathbf{x}(i) - \mathbf{x}(i')\|^2 = \sum_{j=1}^K \sum_{C(i)=j} \|\mathbf{x}(i) - \hat{\mu}_j\|^2$$

- **Κριτήριο Ελαχιστοποίησης:** Διαφορά  $\hat{\sigma}_j^2 \triangleq \sum_{C(i)=j} \|\mathbf{x}(i) - \hat{\mu}_j\|^2$ ,  $\min_C J(C) = \min_C \sum_{j=1}^K \hat{\sigma}_j^2$


### Σύνοψη αλγορίθμου:

- Ο αλγόριθμος τοποθετεί τα δειγματικά στοιχεία στο πλησιέστερο *centroid*, ανανεώνει τις επιλογές κέντρων βάρους (*centroids*) και συνεχίζει μέχρι τη τελική διαμόρφωση  $K$  *clusters*
- Αρχική επιλογή *centroids*: Αυθαίρετες (τυχαίες) τοποθετήσεις  $K$  σημείων
- Η εκτέλεση του αλγορίθμου είναι αποτελεσματική αλλά χωρίς εγγύηση βέλτιστης λύσης


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 εφαρμογή *Unsupervised Learning* σε γραμμικό σύστημα με είσοδο  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$  μπορεί να μειωθεί ο αριθμός των χαρακτηριστικών (αριθμός συντεταγμένων  $m$ ) μέσω μετασχηματισμού σε **Ασυσχέτιστες 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

Αναλογία με ιδιοτιμές (*eigenvalues*) και ιδιοδιανύσματα (*eigenvectors*) στη γραμμική άλγεβρα και σχετικούς αλγόριθμους μετασχηματισμού συνιστωσών σε ορθοκανονικό (*orthonormal*) σύστημα συντεταγμένων

## Orthonormal Transformation σε Principal Components

### Ορισμοί Στατιστικής Προσέγγισης της Principal Component Analysis (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 ιδιοτιμών  $\lambda_j$

$$\mathbf{q}_j^T \mathbf{q}_k = \begin{cases} 1, & k = j \\ 0, & k \neq j \end{cases} \quad \text{και} \quad \mathbf{q}_j^T \mathbf{R} \mathbf{q}_k = \begin{cases} \lambda_j, & k = j \\ 0, & k \neq j \end{cases}$$

- 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  $m$  συντεταγμένες  $x_i$  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  $m$  συντεταγμένες  $a_i$  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 συντεταγμένες 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


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 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  $m$  τυχαίων μεταβλητών  $X_j$  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

## Προσδιορισμός 1<sup>ης</sup> Κύριας Συνιστώσας από Γραμμικό Νευρώνα με Μάθηση Hebbian (1/2) (First Principal Component via Hebbian-based Maximum Eigenfilter)

**Αξίωμα του Hebb's:** Αν τα σήματα στα άκρα μιας νευρωνικής σύναψης  $i$  ενεργοποιούνται ταυτόχρονα σε μια χρονική στιγμή που ορίζεται από το 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

**Αυτοοργανωμένη (Self-organized) Προσέγγιση Principal Component Analysis (PCA):**  
**Νευρωνικό Δίκτυο Υπολογισμού *First Principal Component* Δεδομένων με  $m$  Features**

$$y(n) = \sum_{i=1}^m w_i(n)x_i(n) \text{ στην επανάληψη } n$$

Τα βάρη αυξάνονται στην επανάληψη  $n \rightarrow n + 1$  αν  $y(n)x_i(n) > 0$  (*αξίωμα Hebb's*)



$$w_i(n + 1) = w_i(n) + \eta y(n)x_i(n), \quad i = 1, 2, \dots, m \quad \text{όπου } \eta \text{ learning parameter}$$

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 θετική ανάδραση  $y(n)x_i(n)$  που προκαλεί αστάθεια αντισταθμίζεται από την  $-y(n)w_i(n)$ :

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





# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

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

### (First Principal Component via Hebbian-based Maximum Eigenfilter)

#### 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 μια στιγμιαία υλοποίηση της μήτρας συσχέτισης  $\mathbf{R} = E[\mathbf{X}\mathbf{X}^T]$  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 λόγω της μη επιβλεπόμενης (αυτό-οργανωμένης, self-organized) φύσης του πλην του a-priori καθορισμού της παραμέτρου μάθησης  $\eta$

# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ



## Προσδιορισμός $l$ Κυρίων Συνιστωσών από Μονοστρωματικό Νευρώνα Hebbian (1/3) (Hebbian-based Principal-Component Analysis)

Γενίκευση του Hebbian-based maximum Eigenfilter: Γραμμικό Feedforward Νευρωνικό Δίκτυο ενός επιπέδου με  $l$  νευρώνες για προσδιορισμό των  $l$  σημαντικών Principal Components από Δεδομένα Διαστάσεων  $m$ ,  $l < m$ :

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

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

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



# ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

## Προσδιορισμός $l$ Κυρίων Συνιστωσών από Μονοστρωματικό Νευρώνα Hebbian (2/3) (Hebbian-based Principal-Component Analysis)

### Γενικευμένος Αλγόριθμος του Hebb's – 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 Μονοστρωματικό Νευρώνα 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)

- Αρχική Εικόνα (Δείγμα) **Lena**:  $256 \times 256$  pixels, 256 gray levels στην **1<sup>η</sup> εικόνα**
- Μάθηση μέσω  $N = 2000$  σκαναρισμένων εικόνων, χωρισμένων 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) κωδικοποιημένων σε 256 gray levels:

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

- Το δείγμα τροφοδοτεί **Μονοστρωματικό 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 ανασύσταση της αρχικής με τη συμμετοχή μόνο των  $l = 8$  κυριότερων συνιστωσών της (**l Principal Components**) χωρίς κβαντισμό


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

- Η **4<sup>η</sup> εικόνα** αποτελεί συμπίεση 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**):  $256 \times 256$  pixels, 256 gray levels στην *πάνω εικόνα*

Original Image



Weights




Using First 8 Components



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



Weights



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

