
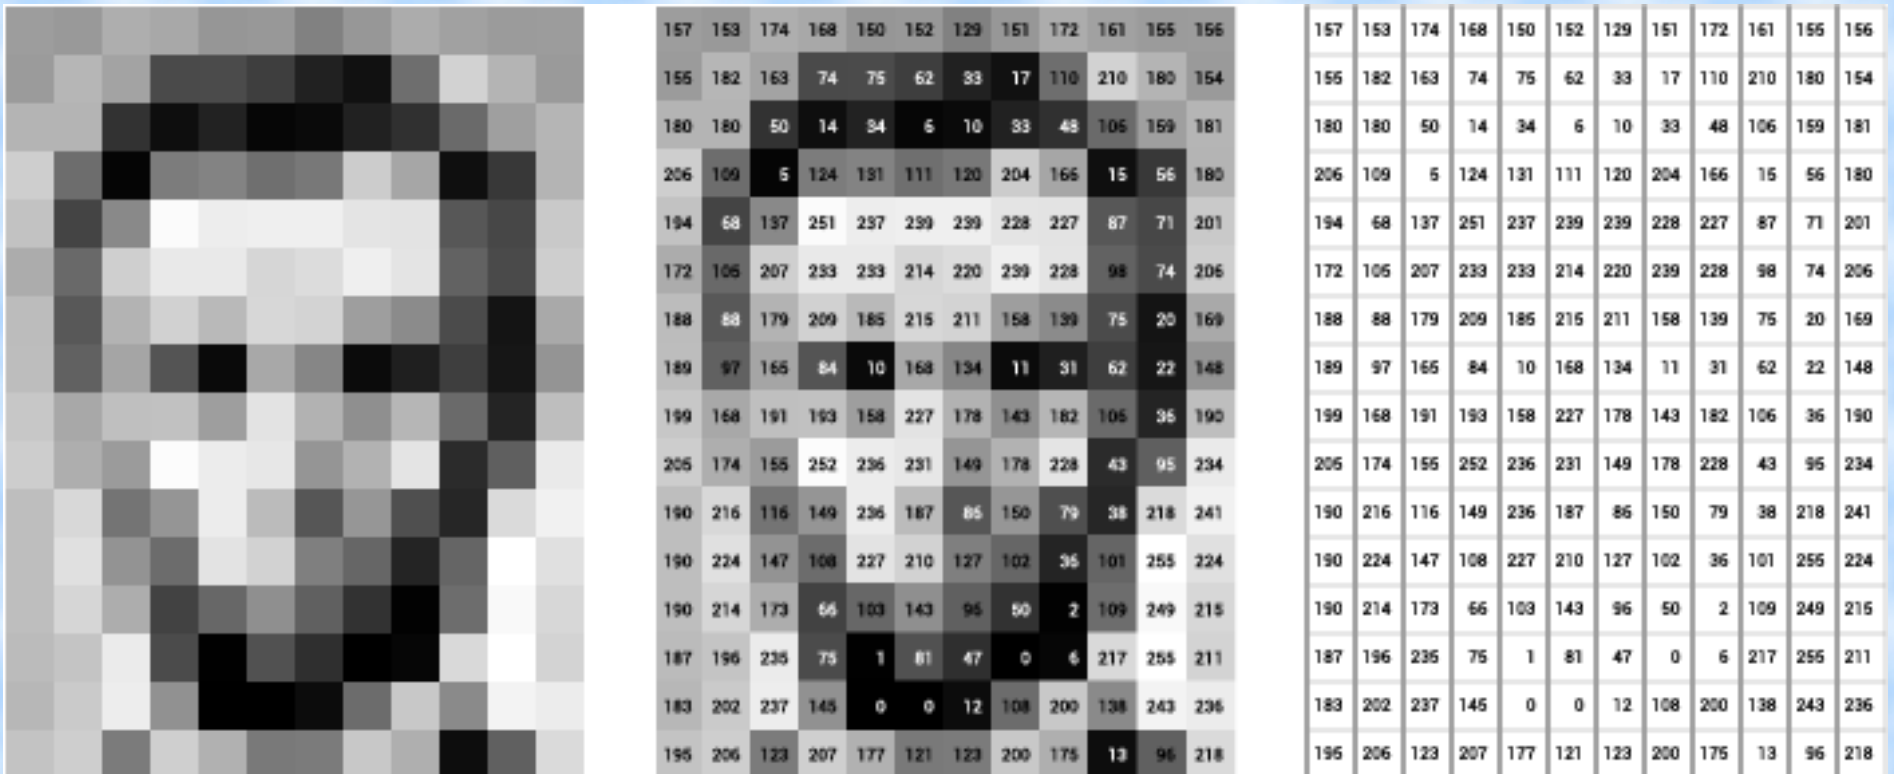


***Συμπύεση ψηφιακών εικόνων με ανάλυση κύριων  
συνιστωσών και χρήση νευρωνικού δικτύου.***



# Ψηφιακή εικόνα

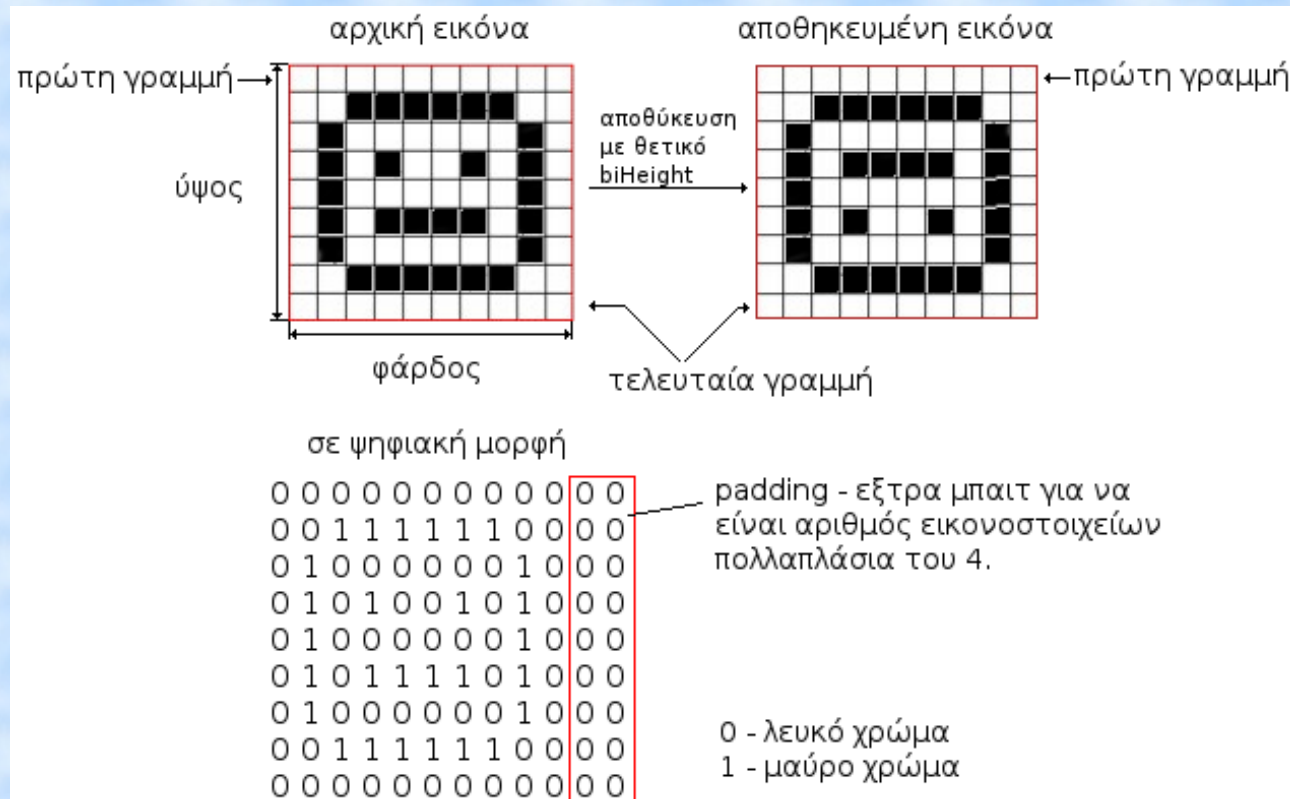
Η ψηφιακή εικόνα είναι ένα πεπερασμένο σύνολο περιοχών όπου κάθε περιοχή είναι χρωματισμένη με χρώμα που προέρχεται από ένα πεπερασμένο σύνολο χρωμάτων.



# Ψηφιακή εικόνα

Μια τέτοια περιοχή ονομάζεται στοιχείο της εικόνας ή εικονοστοιχείο (pixel ή pel από το picture element).

Πίνακας εικονοστοιχείων της εικόνας bitmap.



# Βάθος χρώματος

## Παλέτα χρωμάτων

Βάθος χρώματος 2- 48 bit

2 bit – 2 χρώματα


8 bit - "ασπρόμαυρη"

16 bit – 65536 χρώματα

24 bit – true color

32 bit – 24bit + alpha channel


48 bit – image processing



# Ευκρίνεια

Ευκρίνεια της εικόνας είναι το πλήθος των εικονοστοιχείων ανά μονάδα επιφάνειας και καθορίζει πόσο λεπτομερής είναι η ψηφιακή αναπαράσταση της εικόνας. Η ευκρίνεια  $E$  μιας εικόνας διαστάσεων  $J \times K$  και εμβαδού  $A$  δίνεται από την σχέση:

$$E = \frac{J \times K}{A}$$



# Συμπίεση


- LZW – Lambel-Ziv-Welch
- RLE – Run Length encodign
- Deflation - LZ77+Huffman
- Transform coding
- Fractal
- Color space reducing



# PCA

Με τον όρο ανάλυση εννοούμε συνήθως την εύρεση των συστατικών ενός πράγματος ή την ύπαρξη συστατικών μέσα σ' αυτό. Παρόμοια χρήση έχει ο όρος αυτός και στα μαθηματικά. Έτσι ξέρουμε, ότι τα διανύσματα αναλύονται σε άλλα διανύσματα με τον κανόνα του παραλληλογράμμου π.χ.

$$\vec{x} = \lambda_1 \cdot \vec{u}_1 + \lambda_2 \cdot \vec{u}_2, \text{ όπου } \lambda_1, \lambda_2 \in \mathbb{R}$$



Δεδομένων των  $\vec{u}_1, \vec{u}_2$  ζητούνται τα  $\lambda_1, \lambda_2$ .

# PCA

Η παραπάνω διαδικασία απλοποιείται σημαντικά, αν τα  $\vec{u}_1, \vec{u}_2$  και γενικότερα  $\vec{u}_k, k=1,2,3\dots K$  είναι κάθετα μεταξύ τους και έχουν μέτρο(μήκος) την μονάδα (αποτελούν ορθοκανονική βάση). Η εύρεση των  $\lambda_1, \lambda_2, \lambda_3 \dots \lambda_k$  τότε είναι απλά υπολογισμός του εσωτερικού γινομένου  $\lambda_k = \langle \vec{x}, \vec{u}_k \rangle$

$$\lambda_1 = |\vec{\alpha}| |\vec{u}_1| \cdot \cos \theta = \langle \vec{\alpha}, \vec{u}_1 \rangle$$


$$\lambda_2 = |\vec{\alpha}| |\vec{u}_2| \cdot \cos \theta = \langle \vec{\alpha}, \vec{u}_2 \rangle$$

ή αλγεβρικά για

$$\alpha = \begin{bmatrix} \alpha_1 \\ \alpha_2 \end{bmatrix}, u_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, u_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

$$\langle \alpha, u_1 \rangle = \alpha_1 \cdot 1 + \alpha_2 \cdot 0 = \alpha_1 = \lambda_1$$

$$\langle \alpha, u_2 \rangle = \alpha_1 \cdot 0 + \alpha_2 \cdot 1 = \alpha_2 = \lambda_2$$





# PCA

Η ανάλυση κύριων συνιστωσών(ΑΚΣ). Είναι μία από τις βασικές μεθόδους μείωσης των διαστάσεων των δεδομένων, που βασίζεται στα στατιστικά χαρακτηριστικά τους.

Με την ΑΚΣ επιδιώκεται η περιγραφή των ανυσμάτων  $\mathbf{x}$  που περιγράφουν τα πρότυπα με άλλα ανύσματα  $\mathbf{y}$  ίσων ή λιγότερων διαστάσεων των οποίων οι γραμμές του  $\mathbf{y}$  θα έχουν μηδενική ετεροσυσχέτιση.

# PCA

## Η μέθοδος Karhunen–Loève

Έστω για ένα σύνολο  $K$  ανυσμάτων σε χώρο  $n$ -διαστάσεων διαφόρων χαρακτηριστικών και το  $\mathbf{x}_k$  είναι το διάνυσμα που δείχνεται από την σχέση:

$$\mathbf{x}_k = [x_{1k}, x_{2k}, \dots, x_{vk}, \dots, x_{Nk}]^T$$

Τότε, ο πίνακας συνδιασποράς  $\mathbf{C}_x$  όλων των ανυσμάτων του συνόλου εκπαίδευσης δίνεται από τη σχέση:

$$C_x = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T] = \frac{1}{K} \sum_{k=1}^K (\mathbf{x}_k - \boldsymbol{\mu}_x)(\mathbf{x}_k - \boldsymbol{\mu}_x)^T = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdot & \cdot & \sigma_{1v} & \cdot & \cdot & \sigma_{1N} \\ \sigma_{21} & \sigma_2^2 & \cdot & \cdot & \sigma_{2v} & \cdot & \cdot & \sigma_{2N} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \sigma_{v1} & \sigma_{v2} & \cdot & \cdot & \sigma_v^2 & \cdot & \cdot & \sigma_{vN} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \sigma_{N1} & \sigma_{N2} & \cdot & \cdot & \sigma_{Nv} & \cdot & \cdot & \sigma_N^2 \end{bmatrix}$$

όπου  $\boldsymbol{\mu}_x = E[\mathbf{x}]$

# PCA

## Η μέθοδος Karhunen–Loève

Για να επιτύχουμε αυτό, αναζητούμε ένα τέτοιο μετασχηματισμό  $W$  που θα εκφράζεται από ένα πίνακα  $N \times N$ , ώστε τα διανύσματα  $y = W^T \cdot x$  να έχουν πίνακα συνδιασποράς  $C_y$  με την ακόλουθη μορφή:  $\det(C_x - \lambda I)$

$$C_y = \begin{bmatrix} \lambda_1 & 0 & \cdot & \cdot & 0 & \cdot & \cdot & 0 \\ 0 & \lambda_2 & \cdot & \cdot & 0 & \cdot & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \lambda_v & \cdot & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & 0 & \cdot & \cdot & \lambda_N \end{bmatrix} = \Lambda, \lambda_1 > \lambda_2 > \dots > \lambda_v > \dots > \lambda_N$$

Ακόμη ισχύει ότι  $C_y = E[yy^T] = E[W^T x (W^T x)^T] = E[W^T x x^T W] = W^T E[x x^T] W = W^T C_x W$

# PCA

## Η μέθοδος Karhunen–Loève

Είναι φανερό ότι η τιμή  $\lambda_v = \sigma_v'^2$  είναι η διασπορά του  $y$  κατά τον  $v$  άξονα, ο οποίος εκφράζεται από την  $v$  στήλη του πίνακα  $W$ .

Η στήλη  $w_v$  είναι “αποτελεσματικό” χαρακτηριστικό ενώ η τιμή  $\lambda_v$  αξιολογεί τη σπουδαιότητά του. Ο πίνακας  $C_x$  είναι συμμετρικός και ο πίνακας  $\Lambda$  διαγώνιος.

Η σχέση  $W^T C_x W = \Lambda$  ικανοποιείται αν  $w_1, \dots, w_N$  είναι τα ιδιοανύσματα του πίνακα  $C_x$ ,  $W = [w_1, \dots, w_N]$ . Οι ιδιοτιμές του  $C_x$  είναι οι τιμές  $\lambda_1, \dots, \lambda_N$ .


Σε περίπτωση που απαιτείται μείωση του πλήθους  $N$  των ιδιοδιανυσμάτων μπορούμε να επιλέξουμε τα  $M$  από αυτά ( $M < N$ ) με τις μεγαλύτερες αντίστοιχες ιδιοτιμές, αποδεχόμενοι ένα μέσο τετραγωνικό σφάλμα

$$\overline{\varepsilon^2}(m) = \sum_{v=M+1}^N \lambda_v$$

# PCA

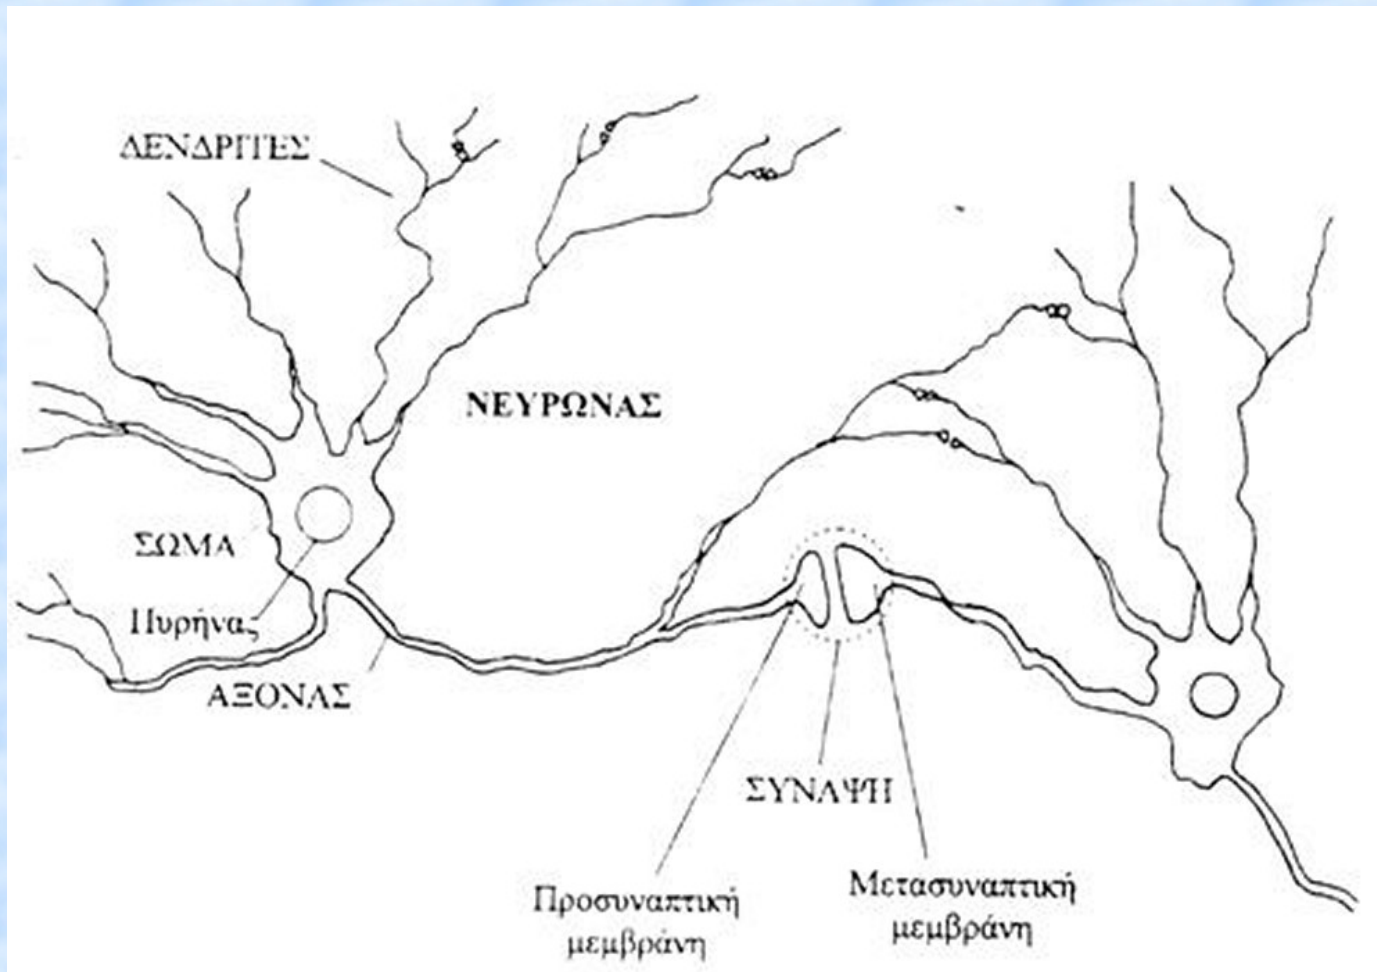
## Η μέθοδος Karhunen–Loève

Στην παρακάτω εικόνα φαίνονται προβολές των εισόδων πάνω στην κύρια συνιστώσα.



# Νευρωνικά δίκτυα


## Βιολογικά νευρωνικά δίκτυα



# Νευρωνικά δίκτυα



Τεχνητά μαθηματικά μοντέλα νευρωνικών δικτύων

- Εκπαίδευση με επόπτη
- Εκπαίδευση χωρίς επόπτη
- Ενισχυτική μάθηση



# Νευρωνικά δίκτυα

Ενός και πολλών επιπέδων





# GHΑ

## Αλγόριθμος του Χεμπ

Το πιο απλό μοντέλο του νευρώνα του Hebb περιγράφεται με μια γραμμική συνάρτηση με πολλαπλούς εισόδους  $x_1, x_2, \dots, x_m$  μέσω των συναπτικών βαρών  $w_1, w_2, \dots, w_m$ . Η έξοδος εκφράζεται με τον τυπο:

$$y = \sum_{i=1}^m w_i x_i$$

Τα βάρη μεταβάλλονται στο χρόνο συνεχώς, καθώς αυξάνονται δραματικά εάν η είσοδος  $x_i$  συμπίπτει με τη έξοδο  $y$ .

$$w_{ij}(n+1) = w_{ij}(n) + \gamma x_j(n) y_i(n)$$

Όπου  $\gamma$  είναι ένας συντελεστής που καθορίζει το ρυθμό μάθησης και το  $n$  είναι διακριτή χρονική στιγμή.

# GHA

## Γενικευμένος αλγόριθμος του Χεμπ

Έστω ένα μονού επιπέδου δίκτυο με εισόδους ένα  $N$ -διάστατο διάνυσμα με στήλη  $x$  και έναν πίνακα βαρών  $W$  με διάσταση  $M \times N$  και εξόδους ένα διάνυσμα στήλη  $y=Wx$  με διάσταση  $M$  όπου  $M < N$ . Έστω επίσης οι τιμές του  $x$  που παράγονται από ένα στατικό τυχαίο διάνυσμα μιας στοχαστικής διεργασίας με πίνακα συσχέτισης  $C_x = E[xx^T]$ . Κατά συνέπεια θεωρείται πως τα  $x$  και  $y$  είναι συναρτήσεις του χρόνου και ο  $W$  θα είναι επίσης χρονικά εξαρτώμενος. Η σχέση που περιγράφει το GHA είναι:

$$W_{ji}(t+1) = w_{ji}(t) + \gamma(t) [y_i(t)x_j(t) - \sum_{k=1}^j w_{kj}(t)y_k(t)]$$

για  $i=1,2,\dots, m$  και για  $j=1,2,\dots, k$

# GHA

## Γενικευμένος αλγόριθμος του Χεμπ

Ο GHA μπορεί να γραφτεί με τη μορφή:

$$\Delta W_{ji} = \gamma(n) y_j(n) [x_i(n) - \sum_{k=1}^{j-1} W_{ki}(n) y_k(n)] + \gamma(n) y_j^2(n) W_{ji}(n)$$

Η διαμορφωμένη μορφή της εισόδου δίνεται από τη σχέση:

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

Το κύριο στοιχείο στη διαμορφωμένη είσοδο είναι το  $i$  ιδιοδιάνυσμα της αρχικής εισόδου. Όταν εφαρμόζεται ο αλγόριθμος Oja στη διαμορφωμένη είσοδο έχει ως αποτέλεσμα η  $i$  έξοδος να μαθαίνει το  $i$  ιδιοδιάνυσμα.

# DCT-2

Ο δισδιάστατος μετασχηματισμός συνημιτόνου (2D-DCT: Discrete Cosine Transform) αποτελεί την βάση για συμπίεση μη δυαδικών εικόνων με αποδεκτή απώλεια πληροφορίας. Η τυποποίηση JPEG βασίζεται στις πρώτες εκδόσεις της στον 2D-DCT.

Για ένα δισδιάστατο διακριτό σήμα  $x(n_1, n_2)$  με μήκη  $N_1, N_2$ , οι προβολές του στα παραπάνω ορθοκανονικά ανύσματα βάσης είναι:

$$c_{k_1 k_2} = \frac{2}{\sqrt{N_1 N_2}} \sum_{n_2=0}^{N_2-1} \sum_{n_1=0}^{N_1-1} x[n_1, n_2] \cdot \cos\left(\frac{\pi k_1 (2n_1 + 1)}{2} N_1\right) \cdot \cos\left(\frac{\pi k_2 (2n_2 + 1)}{2} N_2\right)$$

Το σήμα  $x[n_1, n_2]$  ανακτάται σύμφωνα με τη σχέση:

$$x(n_1, n_2) = \sum_{n_2=0}^{N_2-1} \sum_{n_1=0}^{N_1-1} c_{k_1 k_2} \cdot g_{k_1 k_2}(n_1, n_2)$$

# PCA vs DCT-2

Εφαρμόζουμε τις δύο τεχνικές για υπολογισμό του μέσου τετραγωνικού σφάλματος mse ( $e^2$ ) σε μια εικόνα [Lenna](#), που χρησιμοποιείται για δοκιμές αλγορίθμων σε πολλά επιστημονικά έργα και έχει διαστάσεις 512x512.

Samples	64(8X8)	16(4X4)	4(2X2)
PCA	27.08	9.84	22.497
DCT-2	11.826	22.90	62.24

Για την περίπτωση PCA επιλέχθηκαν μισές κύριες συνιστώσες και για DCT-2 μισές συχνότητες.

# PCA vs DCT-2

## PCA

1 – αρχική εικόνα, 2 - συμπιεσμένη εικόνα, 3 – κύριες συνιστώσες(προβολή)



## DCT-2

1 – αρχική εικόνα, 2 - συμπιεσμένη εικόνα, 3 – κύριες συνιστώσες(προβολή)

