

DIAMOND SPONSORS



PLATINUM SPONSORS



GOLD SPONSORS



SILVER SPONSORS



ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ & ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

Διαφάνειες διαλέξεων

Υπολογιστική Νοημοσύνη
Βαθιά μάθηση



ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ &
ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ


ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

Στοιχεία Μηχανικής Μάθησης

Ανάλυση κυρίων συνιστωσών
(Principal Component Analysis)

Ανάλυση κυρίων συνιστωσών (Principal Component Analysis)

- Περιγραφή φυσικών δεδομένων (data) (p -διαστάσεων) από ένα υποσύνολο (k) νέων (συνθετικών) διαστάσεων.




Εισαγωγή

- Ανακαλύφθηκε από τον Karl Pearson (1857-1936) το 1901.



- Αναπτύχθηκε ανεξάρτητα από τον Harold Hotelling (1895-1973) το 1930.



Εισαγωγή

- Στην επεξεργασία σήματος ονομάζεται διακριτός Karhunen–Loève μετασχηματισμός (KLT).
 - **Kari Karhunen** (1915–1992)
 - **Michel Loève** (1907–1979)
- Άλλα ονόματα:
 - Singular value decomposition (SVD)
 - Eigendecomposition of a matrix
 - Factor Analysis
 - Και άλλα πολλά...




Τι είναι η PCA;

- Η ανάλυση κυρίων συνιστωσών Principal Component Analysis (PCA) είναι μια στατιστική διαδικασία με την οποία αναπαριστούμε ένα πίνακα συνδιακύμανσης ενός συνόλου «**αρχικών**» μεταβλητών μέσα από ένα διαφορετικό (και συνήθως μικρότερο) σύνολο «**νέων**» μεταβλητών οι οποίες προκύπτουν από τον **γραμμικό συνδυασμό** των «**αρχικών**» μεταβλητών.

Η PCA στο απλό...

- Για ένα γνωστό σύνολο δεδομένων $\{x,y\}$:
- Καθορίζουμε την διεύθυνση στην οποία έχω την μεγαλύτερη διασπορά (u).
- Μετά βρίσκω την επόμενη διεύθυνση στην οποία έχω την αμέσως μεγαλύτερη διασπορά (v).
- $PCA = \{u,v\}$
- Έτσι βρίσκουμε το νέο σύστημα συντεταγμένων που αναπαριστά με πιο συμπαγή τρόπο τα «αρχικά» δεδομένα



Η PCA στο απλό...

- **Αλγεβρικά:** η PCA αποτελείται από **ιδιαίτερους** γραμμικούς συνδυασμούς των «αρχικών» μεταβλητών
 - «**Ιδιαίτερος**» Σχηματίζουν μια προβολή των «**αρχικών**» μεταβλητών που αντιπροσωπεύει καλύτερα τα δεδομένα ως προς το μέσο τετραγωνικό σφάλμα.
- **Γεωμετρικά:** η PCA μέσα από τους γραμμικούς συνδυασμούς των «**αρχικών**» μεταβλητών δημιουργούν ένα **νέο** σύστημα συντεταγμένων που δημιουργείται μετατοπίζοντας και περιστρέφοντας το **παλαιό** σύστημα. Οι νέοι άξονες καθορίζουν τις κατευθύνσεις που παρουσιάζουν την/τις μέγιστη/ες μεταβολές των δεδομένων.

Η PCA στο απλό...

- **Υπολογιστικά:** Οι κύριες συνιστώσες της PCA βρίσκονται από τον υπολογισμό των ιδιοδιανυσμάτων και των αντιστοίχων ιδιοτιμών του πίνακα συνδιακύμανσης, όπως αυτός υπολογίζεται από τα δεδομένα που υπάρχουν.
 - Το ιδιοδιάνυσμα με την μεγαλύτερη ιδιοτιμή είναι η κατεύθυνση της μεγαλύτερης διασποράς.

Ιδιοδιανύσματα – Ιδιοτιμές (Eigenvectors, Eigenvalues)

- Δεδομένου ενός πίνακα: $\mathbf{M} \in \mathbb{R}^{d \times d}$ μία πολύ σημαντική κατηγορία γραμμικών εξισώσεων είναι της μορφής:

$$\mathbf{M} \cdot \mathbf{x} = \lambda \mathbf{x}, \text{ με } \lambda \in \mathbb{R}^1, \mathbf{x} \in \mathbb{R}^{d \times 1}$$

- Η παραπάνω εξίσωση γράφεται:

$$(\mathbf{M} - \lambda \mathbf{I})\mathbf{x} = \mathbf{0}, \text{ όπου } \{\mathbf{I}, \mathbf{0}\} \in \mathbb{R}^{d \times d}$$

- \mathbf{I} ο μοναδιαίος πίνακας
- $\mathbf{0}$ ο μηδενικός πίνακας
- $(\mathbf{M} - \lambda \mathbf{I})\mathbf{x} = \mathbf{0}$, χαρακτηριστικό πολυώνυμο

Ιδιοδιανύσματα – Ιδιοτιμές (Eigenvectors, Eigenvalues)

- Μια λύση $\mathbf{x} = \mathbf{e}_i \in \mathbb{R}^{d \times 1}$ της $(\mathbf{M} - \lambda_i \mathbf{I})\mathbf{e}_i = \mathbf{0}$ και η αντίστοιχη τιμή λ_i καλούνται ιδιοδιάνυσμα και ιδιοτιμή αντίστοιχα.
- Συνολικά υπάρχουν d - (πιθανώς μη διαφορετικά) ιδιοδιανύσματα λύσης $\{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_d\}$.
- Κάθε \mathbf{e}_i συνοδεύεται από την αντίστοιχη ιδιοτιμή τους $\{\lambda_1, \lambda_2, \dots, \lambda_d\}$
- Συνεπώς ισχύει: $\mathbf{M} \cdot \mathbf{e}_j = \lambda_j \mathbf{e}_j$
- **Ιδιότητα:** $\det(\mathbf{M}) = |\mathbf{M}| = \prod_{i=1}^d \lambda_i$
- **Ιδιότητα:** $\|\mathbf{e}_j\|^2 = 1, (\mathbf{e}_j)^T (\mathbf{e}_j) = 1$. Τα \mathbf{e}_j είναι μοναδιαία. Αν δεν προκύψουν τα κανονικοποιώ.

Ιδιοδιανύσματα – Ιδιοτιμές

- Παράδειγμα:

$$M \equiv \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix}$$

$$e_1 = \begin{bmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{bmatrix} \quad \text{και} \quad \lambda_1 = 7$$

όντως: $M \cdot e_1 = \lambda_1 \cdot e_1$

$$\begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \cdot \begin{bmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{bmatrix} = 7 \begin{bmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{bmatrix}$$

επίσης: $(1/\sqrt{5})^2 + (2/\sqrt{5})^2 = 1$ (ΜΟΝΑΔΙΑΙΑ).

Εύρεση ιδιοτιμών και ιδιοδιανυσμάτων

- Υπάρχουν 2 κύριες μέθοδοι:
 - $O(n^3)$ running time method (with pivotal condensation)
 - Υποστηρίζει την εύρεση λύσης για συμμετρικούς πίνακες, όπως ο πίνακας της συνδιακύμανσης Σ .
 - Η λύση είναι ακριβής χωρίς σφάλματα.
 - *Power iteration method*

$O(n^3)$ running time method

- $(\mathbf{M} - \lambda\mathbf{I})\mathbf{e} = \mathbf{0}$
 - Θα πρέπει να ισχύει: $\det(\mathbf{M} - \lambda\mathbf{I}) = 0$
 - Η ανωτέρω **ορίζουσα** είναι ένα πολυώνυμο d- τάξης ως προς λ και **έχει υπολογιστική πολυπλοκότητα $O(n^3)$** .
 - Λαμβάνουμε d- τιμές για το λ .
 - Για κάθε τιμή λύνουμε την $\mathbf{M}\mathbf{e} = \lambda\mathbf{e}$ και υπολογίζουμε το \mathbf{e} .
 - Κανονικοποιούμε το \mathbf{e} ώστε να έχει μέτρο 1.

$O(n^3)$ running time method

- Παράδειγμα:

Έστω ο πίνακας $M \in \mathbb{R}^{2 \times 2}$ $M = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix}$
(ο πίνακας είναι συμμετρικός)

Τότε $M - \lambda I = \begin{bmatrix} 3-\lambda & 2 \\ 2 & 6-\lambda \end{bmatrix}$ και η ορίζουσα:
 $\frac{(3-\lambda) \cdot (6-\lambda) - 4}{}$

$$\text{έχω } \det(M - \lambda I) = 0 \Rightarrow \lambda^2 - 9\lambda + 14 = 0$$

$$\Delta = 81 - 4 \cdot 14 = 81 - 56 = 25, \quad \sqrt{\Delta} = \sqrt{25} = 5.$$

$$\lambda_{1,2} = \frac{-(1-9) \pm 5}{2} \quad \begin{array}{l} \lambda_1 = 7 \leftarrow 1^{\text{η}} \text{ κύρια} \\ \lambda_2 = 2 \leftarrow 2^{\text{η}} \text{ κύρια} \end{array}$$

Θεωρώ $e = \begin{bmatrix} x \\ y \end{bmatrix}$, έτσι πρέπει να λύνω:

$$\begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 7 \begin{bmatrix} x \\ y \end{bmatrix} \Rightarrow$$

$$\begin{array}{l} 3x + 2y = 7x \quad \textcircled{1} \Rightarrow 2y = 4x \Rightarrow y = 2x \quad \nabla \\ 2x + 6y = 7y \quad \textcircled{2} \Rightarrow 2x = y \Rightarrow y = 2x \quad \nabla \end{array}$$

ορθάνο ιδιοδιάνυσμα $e = \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} x \\ 2x \end{bmatrix} \sim \begin{bmatrix} 1 \\ 2 \end{bmatrix}$

κανονικοποιώ το $e \rightsquigarrow e_1$ ή (e)

$$\|e\| = \sqrt{1^2 + 2^2} = \sqrt{5} \quad \text{και τιμή:}$$

$$e_1 = \begin{bmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{bmatrix} \quad \text{και } \lambda_1 = 7$$

ΥΠΟΝΟΜΙΣΜΟΣ $\lambda_2 = 2$ ιδιοτιμής / ιδιοδιανύσματος.

$$\lambda_2 = 2, \quad e = \begin{bmatrix} x \\ y \end{bmatrix} \quad \text{όρα:} \quad \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} = 2 \begin{bmatrix} x \\ y \end{bmatrix}$$

$$\Rightarrow \left. \begin{array}{l} 3x + 2y = 2x \Rightarrow 2y = -x \\ 2x + 6y = 2y \Rightarrow 4y = -2x \end{array} \right\} \boxed{x = -2y}$$

$$\text{όρα:} \quad e = \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} -2y \\ y \end{bmatrix} \hat{=} \begin{bmatrix} \text{⊗} \\ -x/2 \end{bmatrix} \quad \text{έτσι ώστε να είναι θετικό}$$

$$\text{όρα:} \quad e = \begin{bmatrix} 2 \\ -1 \end{bmatrix} \quad \text{και} \quad \|e\| = \sqrt{2^2 + 1^2} = \sqrt{5} = 1$$

Τελικά

$$e_2 = \begin{bmatrix} 2/\sqrt{5} \\ -1/\sqrt{5} \end{bmatrix} \quad \mu_2 = 2$$

Power iteration method – 1^ο ζεύγος τιμών

- Έστω M ο πίνακας του οποίου τις ιδιοτιμές και τα ιδιοδιανύσματα αναζητάμε:
- Υπολογισμός της πρώτης ιδιοτιμής και του αντιστοίχου ιδιοδιανύσματος:
 - Για ένα οποιοδήποτε \mathbf{x}_0 υπολογίσατε επαναληπτικά:
$$\mathbf{x}_{k+1} = \frac{M\mathbf{x}_k}{\|M\mathbf{x}_k\|}, \text{ με } \|M\mathbf{x}_k\| = \|N\| \text{ η νόρμα Frobenius:}$$

$$- \|N\| = \sqrt{\sum_{i=1}^{\# \text{στοιχειων} N} (N_i)^2}$$

- Τερματισμός όταν: $\|\mathbf{x}_k - \mathbf{x}_{k+1}\| < \varepsilon$.
- Ανέθεσε στο αναζητούμενο ιδιοδιάνυσμα το $\mathbf{x} = \mathbf{x}_k$
- Εφόσον ισχύει $\mathbf{x}^T \mathbf{x} = \mathbf{1}$, έχουμε: $M\mathbf{x} = \lambda\mathbf{x}$ και:

$$\mathbf{x}^T M\mathbf{x} = \mathbf{x}^T \lambda\mathbf{x} = \lambda\mathbf{x}^T \mathbf{x} = \lambda$$

Power iteration method – 1^ο ζεύγος τιμών

- Παράδειγμα:

έστω $M = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix}$ και επιλέγω για $x_0 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

τότε: $x_1 = M \cdot x_0 = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 5 \\ 8 \end{bmatrix}$

η νόρμα Frobenius: $\sqrt{5^2 + 8^2} = \sqrt{89} = 9.434$, και x_1 :

$x_1 = \begin{bmatrix} 5/\sqrt{89} \\ 8/\sqrt{89} \end{bmatrix} = \begin{bmatrix} 0.530 \\ 0.848 \end{bmatrix}$. Ομοίως $x_2 = M \cdot x_1 =$

$\begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \cdot \begin{bmatrix} 0.530 \\ 0.848 \end{bmatrix} = \begin{bmatrix} 3.286 \\ 6.148 \end{bmatrix}$. η νόρμα $F = 6.971$

$\Rightarrow x_2 = \begin{bmatrix} 0.471 \\ 0.889 \end{bmatrix}$

συνεχίζουμε προς ένα διάνυσμα του οποίου ο 2^{ος} συντελεστής είναι ο διπλάσιος του πρώτου.

και μετα στο μερικες γραφες: $x = \begin{bmatrix} 0.447 \\ 0.894 \end{bmatrix}$

και η αντιστοιχη \mathcal{J} :

$$\mathcal{J} = x^T M x = \begin{bmatrix} 0.447 & 0.894 \end{bmatrix} \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \begin{bmatrix} 0.447 \\ 0.894 \end{bmatrix}$$

$$= 6.993$$

} κανονικά είναι 7.
η μεθοδος Balm είναι
σφάλμα...

Power iteration method

Επόμενο ζεύγος τιμών

- Δημιουργία του νέου πίνακα:

$$M^* = M - \lambda \mathbf{x} \mathbf{x}^T$$

- Επανάληψη της προηγούμενης διαδικασίας για τον υπολογισμό του επόμενου ζεύγους ιδιοδιανύσματος – ιδιοτιμής με βάση τον πίνακα M^* .
- **Ιδιότητες:** το ιδιοδιάνυσμα \mathbf{x} είναι ιδιοδιάνυσμα του M^* με ιδιοτιμή 0.

$$M^* \mathbf{x} = (M - \lambda \mathbf{x} \mathbf{x}^T) \mathbf{x} = M \mathbf{x} - \lambda \mathbf{x} \mathbf{x}^T \mathbf{x} = M \mathbf{x} - \lambda \mathbf{x} = \mathbf{0}$$

Power iteration method

Επόμενο ζεύγος τιμών

- **Ιδιότητες:** Ομοίως αν \mathbf{v} , λ_v είναι ένα eigenpair του συμμετρικού πίνακα M (εκτός του πρώτου ζεύγους), τότε είναι eigenpairs του M^* .

$$\begin{aligned} M^* \mathbf{v} &= (M^*)^T \mathbf{v} = (M - \lambda \mathbf{x} \mathbf{x}^T)^T \mathbf{v} \\ &= M^T \mathbf{v} - \lambda \mathbf{x} (\mathbf{x}^T \mathbf{v}) = M^T \mathbf{v} = \lambda_v \mathbf{v} \end{aligned}$$

Power iteration method

Επόμενο ζεύγος τιμών

- Συνέχεια:

$$\begin{aligned} M^* &= M - \lambda \mathbf{x}\mathbf{x}^T = \\ & \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} - 6.993 \begin{bmatrix} 0.447 \\ 0.894 \end{bmatrix} \begin{bmatrix} 0.447 & 0.894 \end{bmatrix} = \\ & = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} - \begin{bmatrix} 1.397 & 2.795 \\ 2.795 & 5.589 \end{bmatrix} = \begin{bmatrix} 1.603 & -0.795 \\ -0.795 & 0.411 \end{bmatrix} \end{aligned}$$

Επανάληψη της προηγούμενης διαδικασίας για τον υπολογισμό του επόμενου ζεύγους ιδιοδιανύσματος – ιδιοτιμής με βάση τον πίνακα M^* .

Ο πίνακας των ιδιοδιανυσμάτων

- Δεδομένου ενός πίνακα: $\mathbf{M} \in \mathbb{R}^{d \times d}$
υπολογίζουμε τα ιδιοδιανύσματα του:

$$\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_d$$

- Έστω \mathbf{E} ο πίνακας, η i -στήλη του οποίου είναι το \mathbf{e}_i ιδιοδιάνυσμα:

$$\mathbf{E} = \begin{pmatrix} \cdots & \uparrow & \cdots \\ \vdots & \mathbf{e}_i & \vdots \\ \cdots & \downarrow & \cdots \end{pmatrix}$$

- Τότε: $\mathbf{E}\mathbf{E}^T = \mathbf{E}^T\mathbf{E} = \mathbf{I}$ (τα ιδιοδιανύσματα είναι ορθοκανονικά)

Παράδειγμα

$$\mathbf{E} = \begin{bmatrix} 2/\sqrt{5} & 1/\sqrt{5} \\ -1/\sqrt{5} & 2/\sqrt{5} \end{bmatrix}$$

$$\mathbf{E}^T = \begin{bmatrix} 2/\sqrt{5} & -1/\sqrt{5} \\ 1/\sqrt{5} & 2/\sqrt{5} \end{bmatrix}$$

$$\mathbf{E}\mathbf{E}^T = \begin{bmatrix} 2/\sqrt{5} & 1/\sqrt{5} \\ -1/\sqrt{5} & 2/\sqrt{5} \end{bmatrix} \begin{bmatrix} 2/\sqrt{5} & -1/\sqrt{5} \\ 1/\sqrt{5} & 2/\sqrt{5} \end{bmatrix}$$

$$\begin{bmatrix} 4/5 + 1/5 & -2/5 + 2/5 \\ -2/5 + 2/5 & 1/5 + 4/5 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

Ο πίνακας των ιδιοδιανυσμάτων

- Δεδομένου του πίνακα των ιδιοδιανυσμάτων \mathbf{E} , ενός συμμετρικού πίνακα $\mathbf{A} \in \mathbb{R}^{3 \times 3}$:

$$\mathbf{A}\mathbf{e}_1 = \lambda_1\mathbf{e}_1, \mathbf{A}\mathbf{e}_2 = \lambda_2\mathbf{e}_2, \mathbf{A}\mathbf{e}_3 = \lambda_3\mathbf{e}_3$$

$$\mathbf{A} \cdot [\mathbf{e}_1 \ \mathbf{e}_2 \ \mathbf{e}_3] = [\mathbf{e}_1 \ \mathbf{e}_2 \ \mathbf{e}_3] \cdot \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix}$$

ή

$$\mathbf{A} \cdot \mathbf{E} = \mathbf{E} \cdot \mathbf{\Lambda}$$

και:

$$\mathbf{A} = \mathbf{E} \cdot \mathbf{\Lambda} \cdot \mathbf{E}^T$$

Ο πίνακας των ιδιοδιανυσμάτων

- Αντί για οποιοδήποτε \mathbf{A} , ας θεωρήσουμε τον συμμετρικό πίνακα συνδιακύμανσης $\mathbf{\Sigma} \in \mathbb{R}^{d \times d}$ ενός πληθυσμού. Τότε υπάρχει α) ένας πίνακας \mathbf{E} (των ιδιοδιανυσμάτων του) και β) ένας διαγώνιος πίνακας $\mathbf{\Lambda}$ των ιδιοτιμών του έτσι ώστε:


$$\mathbf{E}^T \cdot \mathbf{\Sigma} \cdot \mathbf{E} = \mathbf{\Lambda}$$

- Πρακτικά ο πίνακας \mathbf{E} μετασχηματίζει γραμμικά (περιστρέφει και μετατοπίζει) τον πίνακα $\mathbf{\Sigma}$.
- Οι νέες συντεταγμένες είναι **ασυσχέτιστες** (decorrelated).

Η PCA στην πράξη

- Έστω ένα σύνολο δεδομένων στο αρχικό σύστημα συντεταγμένων: $X = [x_1, x_2, \dots, x_d]$.
 - Υπολογίσατε τις μέσες τιμές: $\mu_x = [\mu_{x1}, \mu_{x2}, \dots, \mu_{xd}]$
 - Υπολογίσατε τον πίνακα συνδιακύμανσης Σ .
 - Υπολογίσατε τα ιδιοδιανύσματα $E = [e_1, \dots, e_d]$
- Κάθε σημείο p_x στο αρχικό σύστημα συντεταγμένων μετασχηματίζεται στο νέο σύστημα συντεταγμένων $[e_1, \dots, e_d]$ ως:
$$p_e = (p_x - \mu_x)E$$

Η PCA στην πράξη



Η PCA πιο μαθηματικά...

- Έστω ότι θέλουμε να αναπαραστήσουμε ένα πληθυσμό από n το πλήθος δεδομένα – διανύσματα που βρίσκονται σε ένα χώρο d -διαστάσεων με ένα μόνο διάνυσμα.
- Δλδ, ψάχνουμε την καλύτερη αναπαράσταση των $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n \in \mathbb{R}^d$ με το διάνυσμα $\mathbf{x}_0 \in \mathbb{R}^d$.
- Ένας κλασικός τρόπος είναι να ελαχιστοποιήσουμε το άθροισμα των τετραγωνικών αποστάσεων μεταξύ του \mathbf{x}_0 και των $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$.
- Ορίζω την συνάρτηση:
$$J_0(\mathbf{x}_0) = \sum_{k=1}^n \|\mathbf{x}_0 - \mathbf{x}_k\|^2,$$

Η PCA πιο μαθηματικά...

- Ισχυριζόμαστε ότι αυτό γίνεται αν $\mathbf{x}_0 = \mathbf{m}$, όπου \mathbf{m} είναι το διάνυσμα της μέσης τιμής του πληθυσμού:

$$\mathbf{m} = \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k.$$

- Ακολουθεί απόδειξη:

$$J_0(\mathbf{x}_0) = \sum_{k=1}^n \|(\mathbf{x}_0 - \mathbf{m}) - (\mathbf{x}_k - \mathbf{m})\|^2$$

$$= \sum_{k=1}^n \|\mathbf{x}_0 - \mathbf{m}\|^2 - 2 \sum_{k=1}^n (\mathbf{x}_0 - \mathbf{m})^t (\mathbf{x}_k - \mathbf{m}) + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2$$

$$= \sum_{k=1}^n \|\mathbf{x}_0 - \mathbf{m}\|^2 - 2(\mathbf{x}_0 - \mathbf{m})^t \sum_{k=1}^n (\mathbf{x}_k - \mathbf{m}) + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2$$

Ο όρος: $\sum_{k=1}^n (\mathbf{x}_k - \mathbf{m}) = \sum_{k=1}^n \mathbf{x}_k - \sum_{k=1}^n \mathbf{m} = n\mathbf{m} - n\mathbf{m} = 0$

$$= \sum_{k=1}^n \|\mathbf{x}_0 - \mathbf{m}\|^2 + \underbrace{\sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2}_{\text{Ανεξάρτητο του } \mathbf{x}_0}$$

Η παραπάνω έκφραση ελαχιστοποιείται αν $\mathbf{x}_0 = \mathbf{m}$

Η PCA πιο μαθηματικά...

- Ο μέσος όρος είναι μια αναπαράσταση μηδενικής διάστασης των δεδομένων μας.
- Μπορούμε να λάβουμε μια πιο ενδιαφέρουσα μονοδιάστατη αναπαράσταση αν προβάλλουμε τα δεδομένα σε μια γραμμή που περνάει από την μέση τιμή.
 - Έστω \mathbf{e} ένα μοναδιαίο διάνυσμα στην επιθυμητή κατεύθυνση.
 - Τότε η εξίσωση της ευθείας θα είναι:

$$\mathbf{x} = \mathbf{m} + a\mathbf{e},$$

- Η τιμή a αντιστοιχεί στην **απόσταση** κάθε σημείου \mathbf{x} από το κέντρο των δεδομένων \mathbf{m} .
- Συνεπώς αναπαριστούμε το σημείο \mathbf{x}_k με το $\mathbf{m} + a_k \mathbf{e}$
 - Η διαφορά τους: $(\mathbf{m} + a_k \mathbf{e}) - \mathbf{x}_k$
 - Το τετράγωνο του μέτρου της διαφοράς τους:
 $\|(\mathbf{m} + a_k \mathbf{e}) - \mathbf{x}_k\|^2$
- Για να βρούμε την νέα αναπαράσταση ελαχιστοποιούμε την:

$$\begin{aligned}
 J_1(a_1, \dots, a_n, \mathbf{e}) &= \sum_{k=1}^n \|(\mathbf{m} + a_k \mathbf{e}) - \mathbf{x}_k\|^2 = \sum_{k=1}^n \|a_k \mathbf{e} - (\mathbf{x}_k - \mathbf{m})\|^2 \\
 &= \sum_{k=1}^n a_k^2 \|\mathbf{e}\|^2 - 2 \sum_{k=1}^n a_k \mathbf{e}^t (\mathbf{x}_k - \mathbf{m}) + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2.
 \end{aligned}$$

- Αν θεωρήσουμε ότι $\|e\| = 1$ τότε λαμβάνοντας την μερική παράγωγο σε σχέση με το a_k και μηδενίζοντας, έχω:

$$a_k = e^t (x_k - m).$$

- **Γεωμετρική ερμηνεία:** λαμβάνουμε μια λύση τύπου ελαχίστων τετραγώνων αν προβάλουμε το διάνυσμα x_k σε μια γραμμή με κατεύθυνση το e και η οποία περνάει από το σημείο της μέσης τιμής m .

Ένα πολύ πιο ενδιαφέρον ερώτημα

- Ποια είναι η βέλτιστη κατεύθυνση \mathbf{e} ;
 - Θεωρώ τον πίνακα διασποράς (scatter matrix):

$$\mathbf{S} = \sum_{k=1}^n (\mathbf{x}_k - \mathbf{m})(\mathbf{x}_k - \mathbf{m})^t$$

- Ισχύει: $\mathbf{S} = (n-1)\mathbf{\Sigma}$ όπου $\mathbf{\Sigma}$ ο πίνακας συνδιακύμανσης

$$\begin{aligned} J_1(a_1, \dots, a_n, \mathbf{e}) &= \sum_{k=1}^n \|(\mathbf{m} + a_k \mathbf{e}) - \mathbf{x}_k\|^2 = \sum_{k=1}^n \|a_k \mathbf{e} - (\mathbf{x}_k - \mathbf{m})\|^2 \\ &= \sum_{k=1}^n a_k^2 \|\mathbf{e}\|^2 - 2 \sum_{k=1}^n a_k \mathbf{e}^t (\mathbf{x}_k - \mathbf{m}) + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2. \\ &\quad a_k = \mathbf{e}^t (\mathbf{x}_k - \mathbf{m}). \end{aligned}$$

Ένα πολύ πιο ενδιαφέρον ερώτημα

$$J_1(\mathbf{e}) = \sum_{k=1}^n a_k^2 - 2 \sum_{k=1}^n a_k^2 + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2$$

$$= - \sum_{k=1}^n [\mathbf{e}^t (\mathbf{x}_k - \mathbf{m})]^2 + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2$$

$$a_k = \mathbf{e}^t (\mathbf{x}_k - \mathbf{m})$$

$$= - \sum_{k=1}^n \mathbf{e}^t (\mathbf{x}_k - \mathbf{m}) (\mathbf{x}_k - \mathbf{m})^t \mathbf{e} + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2$$

$$= -\mathbf{e}^t \mathbf{S} \mathbf{e} + \sum_{k=1}^n \|\mathbf{x}_k - \mathbf{m}\|^2.$$

- Φαίνεται ότι το διάνυσμα \mathbf{e} το οποίο ελαχιστοποιεί το $J_1(\mathbf{e})$ μεγιστοποιεί τον όρο:

$$\mathbf{e}^t \mathbf{S} \mathbf{e}$$

Μεγιστοποίηση του $\mathbf{e}^t \mathbf{S} \mathbf{e}$

- Υπό τον περιορισμό ότι: $\|\mathbf{e}\| = 1$
- Χρήση πολλαπλασιαστών Lagrange,
 - Έστω λ ο πολλαπλασιαστής
 - Θέτουμε: $u = \mathbf{e}^t \mathbf{S} \mathbf{e} - \lambda(\mathbf{e}^t \mathbf{e} - 1)$
 - Παραγωγίζουμε ως προς \mathbf{e} :
$$\frac{\partial u}{\partial \mathbf{e}} = 2\mathbf{S}\mathbf{e} - 2\lambda\mathbf{e}$$
 - Και μηδενίζουμε: $\mathbf{S}\mathbf{e} = \lambda\mathbf{e}$.
 - Από ότι φαίνεται για να μεγιστοποιήσουμε το $\mathbf{e}^t \mathbf{S} \mathbf{e}$ **πρέπει να επιλέξουμε το ιδιοδιάνυσμα που αντιστοιχεί στην μεγαλύτερη ιδιοτιμή του \mathbf{S} .**

Μεγιστοποίηση του $e^t S e$

- Επειδή: $S e = \lambda e$. έχω: $e^t S e = \lambda e^t e = \lambda$,
- Με άλλα λόγια: για να βρούμε την **καλύτερη** (*καλύτερη ως προς το μέσο τετραγωνικό σφάλμα*) προβολή σε μια διάσταση των δεδομένων μας x_k πρέπει να προβάλλουμε σε μια γραμμή που περνάει από το μέσο m των δεδομένων και **προς την κατεύθυνση του ιδιοδιανύσματος του πίνακα διασποράς (scatter) με την μεγαλύτερη ιδιοτιμή.**

Ανάλυση κύριων συνιστωσών


- Αν πάμε σε περισσότερες προβολές:

$$\mathbf{x} = \mathbf{m} + \sum_{i=1}^{d'} a_i \mathbf{e}_i$$

Με: $d' \leq d$ και \mathbf{e}_i τα ιδιοδιανύσματα που αντιστοιχούν σε φθίνουσα σειρά των ιδιοτιμών λ_i .

- Οι συντελεστές a_i που αντιστοιχούν στις προβολές στους νέους άξονες \mathbf{e}_i ονομάζονται **κύριοι συντελεστές (principal component)**.

Παράδειγμα



$$M = \begin{bmatrix} 1 & 2 \\ 2 & 1 \\ 3 & 4 \\ 4 & 3 \end{bmatrix}$$

Four points in a two-dimensional space

$$M^T M = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 2 & 1 & 4 & 3 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 2 & 1 \\ 3 & 4 \\ 4 & 3 \end{bmatrix} = \begin{bmatrix} 30 & 28 \\ 28 & 30 \end{bmatrix}$$

$$(30 - \lambda)(30 - \lambda) - 28 \times 28 = 0$$

Παράδειγμα

$$\lambda = 58 \longrightarrow \begin{bmatrix} 30 & 28 \\ 28 & 30 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 58 \begin{bmatrix} x \\ y \end{bmatrix} \longrightarrow \begin{array}{l} 30x+28y = 58x \\ 28x+30y = 58y \end{array} \quad x = y.$$

$$\lambda = 58 \longrightarrow \mathbf{e}_1 = \begin{bmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix}$$


$$\lambda = 2. \longrightarrow \begin{bmatrix} 30 & 28 \\ 28 & 30 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = 2 \begin{bmatrix} x \\ y \end{bmatrix} \longrightarrow \begin{array}{l} 30x+28y = 2x \\ 28x+30y = 2y \end{array} \quad x = -y.$$

$$\lambda = 2. \longrightarrow \mathbf{e}_2 = \begin{bmatrix} -1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix}$$

$$E = \begin{bmatrix} 1/\sqrt{2} & -1/\sqrt{2} \\ 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix}$$

Παράδειγμα

$$ME = \begin{bmatrix} 1 & 2 \\ 2 & 1 \\ 3 & 4 \\ 4 & 3 \end{bmatrix} \begin{bmatrix} 1/\sqrt{2} & -1/\sqrt{2} \\ 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix} = \begin{bmatrix} 3/\sqrt{2} & 1/\sqrt{2} \\ 3/\sqrt{2} & -1/\sqrt{2} \\ 7/\sqrt{2} & 1/\sqrt{2} \\ 7/\sqrt{2} & -1/\sqrt{2} \end{bmatrix}$$



The points of Fig. 11.1 in the new coordinate system

Εφαρμογή: Αναγνώριση προσώπου (face recognition)

- Οι στόχοι της χρήσης PCA στην αναγνώριση προσώπου είναι οι εξής:
 - Ελάττωση των δεδομένων (Data Reduction)
 - Επιλογή Χαρακτηριστικών (Feature Selection)



Εφαρμογή: Αναγνώριση προσώπου (face recognition)

- Στην αναγνώριση προσώπου μία εικόνα εισόδου με n pixels μπορεί να θεωρηθεί ως **ένα** σημείο σε ένα n -διάστατο χώρο που ονομάζεται χώρος εικόνας.
 - Οι συντεταγμένες εκείνου του σημείου είναι οι τιμές κάθε pixel της εικόνας:
$$\mathbf{p}_x = (i_1, i_2, \dots, i_n)$$
 - Οι τιμές αυτές λαμβάνονται διατρέχοντας την εικόνα είτε γραμμή-γραμμή είτε στήλη-στήλη.

Εφαρμογή: Αναγνώριση προσώπου (face recognition)

- Π.χ: Εικόνα 128×128 pixels.




$$= \begin{bmatrix} 150 & 152 & \cdot & 151 \\ 131 & 133 & \cdot & 72 \\ \cdot & \cdot & \cdot & \cdot \\ 144 & 171 & \cdot & 67 \end{bmatrix}_{128 \times 128}$$

16384 vector

$[150, 152, \dots, 151, 131, 133, \dots, 72, \dots, 144, 171, \dots, 67]_{16K}$

Εφαρμογή: Αναγνώριση προσώπου (face recognition)

- Οι εικόνες προσώπου γενικά παρουσιάζουν μια αρκετά πλεονάζουσα (redundant) πληροφορία:
 - Όλα τα pixels παρασκηνίου είναι ίδια
 - Κάθε υποκείμενο (άνθρωπος) έχει τα ίδια χαρακτηριστικά προσώπου.



- Στον χώρο των δεδομένων κάθε pixel είναι μια μεταβλητή
 - Έτσι η διάσταση του χώρου είναι πολύ υψηλή.
 - Η ελάττωση της διάστασης γίνεται με την PCA.
- Έστω $D \in \mathbb{R}^{N \times n}$ ο πίνακας που αποτελείται από N πρόσωπα των n -pixels.
 - Κάθε γραμμή είναι και μια εικόνα.

$$D = \begin{bmatrix} 150 & 152 & \dots & 254 & 255 & \dots & 252 \\ 131 & 133 & \dots & 221 & 223 & \dots & 241 \\ \cdot & \cdot & & \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot & \cdot & & \cdot \\ 144 & 171 & \dots & 244 & 245 & \dots & 223 \end{bmatrix} N \times n$$

- Έστω ότι η μέση τιμή των στηλών είναι:

$$[120 \ 140 \ \dots \ 230 \ 230 \ \dots \ 240]$$

- Δημιουργούμε τον κεντραρισμένο (centered) πίνακα \mathbf{U} αφαιρώντας την μέση τιμή από τον πίνακα \mathbf{D} .

$$\mathbf{U} = \begin{bmatrix} 30 & 12 & \dots & 24 & 25 & \dots & 12 \\ 11 & -7 & \dots & -9 & -7 & \dots & 1 \\ \cdot & \cdot & & \cdot & \cdot & & \cdot \\ 24 & 31 & \dots & 14 & 15 & \dots & -17 \end{bmatrix} N \times n$$

- Υπολογίζω τον πίνακα συνδιακύμανσης $\mathbf{\Sigma} \in \mathbb{R}^{n \times n}$ από τον \mathbf{U} .

$$\mathbf{\Sigma} = \mathbf{U}^T \mathbf{U} / (N - 1)$$

- Βρίσκω τον πίνακα ιδιοδιανυσμάτων \mathbf{E} και τον αντίστοιχο πίνακα ιδιοτιμών $\mathbf{\Lambda}$ του πίνακα $\mathbf{\Sigma}$ που ικανοποιούν την:


$$\mathbf{\Sigma} = \mathbf{E} \cdot \mathbf{\Lambda} \cdot \mathbf{E}^T$$

- Κανονικοποιούμε (αν χρειάζεται) τα \mathbf{e}_i ιδιοδιανύσματα έτσι ώστε να αποτελούν μια ορθοκανονική βάση:

$$\forall \mathbf{e}_i, \mathbf{e}_j \in \mathbf{E}, \langle \mathbf{e}_i, \mathbf{e}_j \rangle = \delta_{ij} = \begin{cases} 1, & \text{αν } i = j \\ 0, & \text{αν } i \neq j \end{cases}$$

- *Ιδιοδιανύσματα με μικρές ιδιοτιμές συμβάλλουν με μικρή πληροφορία στην αναπαράσταση των δεδομένων.*
- *Συνεπώς μείωση των διαστάσεων των δεδομένων επιτυγχάνεται αγνοώντας τα ιδιοδιανύσματα με μικρές ιδιοτιμές.*

- Το σύνολο των ιδιοδιανυσμάτων m (με $m < n$) του Σ που έχουν τις m -μεγαλύτερες ιδιοτιμές, ελαχιστοποιεί το μέσο τετραγωνικό σφάλμα ανακατασκευής.
- Αν και τυπικά απαιτούνται n -μεταβλητές για την αναπαράσταση ενός αρχικού δείγματος εικόνας \mathbf{X} , μεγάλο μέρος της μεταβλητότητας των δεδομένων μπορεί να οφείλεται σε μικρότερο αριθμό m **κυριών συνιστωσών**.



EigenFaces

- Έτσι, τα αρχικά δεδομένα που αποτελούνται από N εικόνες των n -μεταβλητών μπορούν να ελαττωθούν σε N εικόνες των m -μεταβλητών (ιδιοδιανύσματα).
- Στην αναγνώριση προσώπου τα ιδιοδιανύσματα καλούνται «**ιδιόφασες**» - **eigenfaces**.

Δεδομένα εκπαίδευσης

- **D: Training Set: 14 Εικόνες 384×256 pixels**



EigenFaces

- Μέση τιμή:



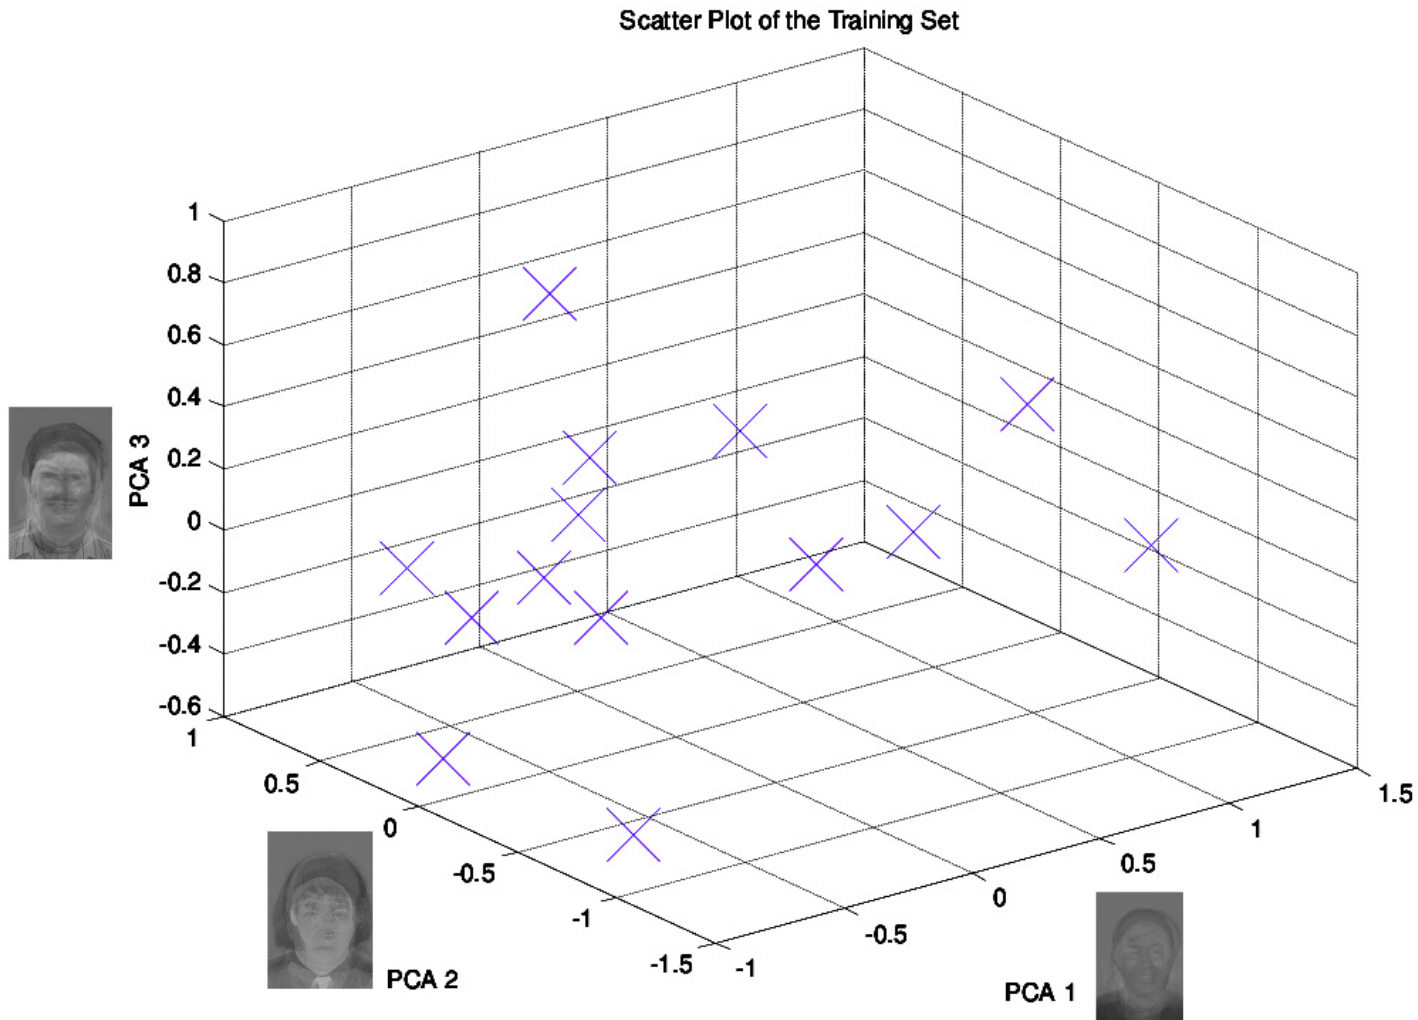
EigenFaces

- Τα 4 ιδιοδιανύσματα με τις πιο ισχυρές ιδιοτιμές.



EigenFaces

- Η προβολή τους στα 3 πρώτα ιδιοδιανύσματα:



Ανακατασκευή προσώπων

- Αρχική:





3

5

8

11

13



Ανακατασκευή προσώπων

- Αρχική:





3



5



8



11



13



Πόσες κύριες συνιστώσες χρειαζόμαστε;;

- Δεν υπάρχει απόλυτη απάντηση
- Μια προσέγγιση είναι να δούμε πόση διασπορά αντιπροσωπεύει η κάθε μια κύρια συνιστώσα.
 - Για το i -ιδιοδιάνυσμα:

$$r_i = 100 \times \frac{\lambda_i}{\sum_{j=1}^n \lambda_j}$$

- Μια ευριστική (heuristic) μέθοδος δεν λαμβάνει υπόψη μια κύρια συνιστώσα όταν $r_i < 1\%$.

Η κατάρα της διαστατικότητας.

- Η αναγνώριση προσώπου αποτελεί ένα χαρακτηριστικό παράδειγμα της κατάρας της διαστατικότητας.
 - small sample size problem.
- Το πλήθος των μεταβλητών (pixels) n είναι πολύ μεγάλο αλλά το πλήθος των δειγμάτων – εικόνων στο σύνολο εκπαίδευσης N είναι πολύ μικρότερο.
- Καθώς ο πίνακας συνδιακύμανσης Σ είναι πολύ μεγάλος ($n \times n$) ο υπολογισμός των ιδιοδιανυσμάτων είναι μια δύσκολη υπόθεση.
 - Δεδομένου ότι υπάρχουν μόνο N εικόνες εκπαίδευσης ο βαθμός (rank) του Σ είναι το πολύ $N-1$ και ως εκ τούτου υπάρχουν το πολύ $N-1$ ιδιοδιανύσματα με μη μηδενικές ιδιοτιμές.

Μετασχηματισμός ΚΛ

Karhunen Lowe Transform

- Οι Karhunen και Lowe βρήκαν μια πολύ ωραία ιδέα για τον αποδοτικό υπολογισμό των κυρίων συνιστωσών.
 - $\mathbf{U}^T \mathbf{U} \in \mathbb{R}^{n \times n}$
 - Ενώ $\mathbf{U} \mathbf{U}^T \in \mathbb{R}^{N \times N}$
- Δεδομένου $N \ll n$ υπολογίζουμε τις ιδιοτιμές του $\mathbf{U} \mathbf{U}^T$ με μεγαλύτερη ευκολία.

$$\mathbf{U} \mathbf{U}^T \mathbf{E}' = \mathbf{E}' \mathbf{\Lambda}$$

- Πολλαπλασιάζοντας από δεξιά με \mathbf{U}^T έχουμε:

$$\mathbf{U}^T \mathbf{U} \mathbf{U}^T \mathbf{E}' = \mathbf{U}^T \mathbf{E}' \mathbf{\Lambda}$$

$$U^T U U^T E' = U^T E' \Lambda$$

- Με μια αναδιοργάνωση...

$$U^T U (U^T E') = (U^T E') \Lambda$$

- Άρα τα $(U^T E')$ είναι τα ιδιοδιανύσματα των $U^T U$.
- Άρα:
 - Βρίσκουμε τα ιδιοδιανύσματα E' του «μικρού» πίνακα $U U^T$
 - Στην συνέχεια πολ/μος με U^t για να βρώ τα ιδιοδιανύσματα του $U^T U$.
- Τα προκύπτοντα ιδιοδιανύσματα δεν είναι ορθοκανονικά. Αυτό επιτυγχάνεται με την διαίρεση κάθε στήλης του πίνακα ιδιοδιανυσμάτων $(U^T E')$ με το μέτρο:
 - $\sqrt{(N - 1)\lambda_i}$ αν έχουμε τον scatter πίνακα S .
 - $\sqrt{\lambda_i}$ αν έχουμε τον πίνακα συνδιακυμανσης σ .

$$U^T U U^T E' = U^T E' \Lambda$$

- Υπάρχουν το πολύ $N-1$ μη μηδενικές ιδιοτιμές στον πίνακα $U U^T$
- Αυτό δεν αποτελεί περιορισμό, καθώς όπως γνωρίζουμε ο βαθμός (rank) του $U^T U$ είναι το πολύ $N-1$.