

# HY213. ΑΡΙΘΜΗΤΙΚΗ ΑΝΑΛΥΣΗ

## ΕΛΑΧΙΣΤΑ ΤΕΤΡΑΓΩΝΑ ΑΝΑΛΥΣΗ ΙΔΙΑΖΟΥΣΩΝ ΤΙΜΩΝ

Π. ΤΣΟΜΠΑΝΟΠΟΥΛΟΥ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ & ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

# Μέθοδος ελαχίστων τετραγώνων

---

- ▶ Τα σφάλματα στις πειραματικές μετρήσεις (από παρατηρήσεις και πειράματα) είναι αναπόφευκτα.
- ▶ Για να εξομαλύνουμε τα σφάλματα, λαμβάνουμε μέσο όρο από πολλές περιπτώσεις (π.χ., λαμβάνοντας περισσότερες μετρήσεις από ότι χρειαζόμαστε για να υπολογίσουμε κάποιες παραμέτρους).
- ▶ Το σύστημα στο οποίο καταλήγουμε είναι υπερπροσδιορισμένο.
- ▶ Προβολή των δεδομένων μεγαλύτερης διάστασης σε χώρους μικρότερης διάστασης, για να αφαιρέσουμε τις άσχετες λεπτομέρειες.
- ▶ Η προβολή στο χώρο μικρότερης διάστασης επιτυγχάνεται με τη μέθοδο των ελαχίστων τετραγώνων.

# Παράδειγμα: Data Fitting

---

- ▶ Με δοσμένα τα  $m$  σημεία  $(x_i, y_i)$ , υπολογίστε το  $n$ -διάστατο διάνυσμα  $c$  που καθορίζει τη συνάρτηση  $f(x, c)$  η οποία προσεγγίζει τα δεδομένα με τον καλύτερο δυνατό τρόπο:

$$\min_c \sum_{i=1}^m (y_i - f(x_i, c))$$

- ▶ Αν  $\varphi_1, \varphi_2, \dots, \varphi_n$ , η βάση του χώρου που ανήκει η  $f$  τότε:

$$f(x, c) = c_1\varphi_1(x) + c_2\varphi_2(x) + \dots + c_n\varphi_n(x)$$

- ▶ Σε μορφή πινάκων το σύστημα γράφεται  $A c \approx b$ , με  $a_{ij} = \varphi_j(x_i)$  και  $b_i = y_i$

# Παράδειγμα: Data Fitting

---

- ▶ Αν  $\varphi_1, \varphi_2, \dots, \varphi_n$ , είναι πολυώνυμα τότε:

$$f(x, \mathbf{c}) = c_1 + c_2x + \dots + c_n x^{n-1}$$

οπότε το  $\mathbf{c}$  περιέχει τους συντελεστές του πολυωνύμου και το πρόβλημα της προσέγγισης είναι γραμμικό.

- ▶ Αν  $\varphi_1, \varphi_2, \dots, \varphi_n$ , είναι εκθετικές συναρτήσεις τότε:

$$f(x, \mathbf{c}) = c_1 e^{c_2 x} + c_3 e^{c_4 x} + \dots + c_{n-1} e^{c_n x}$$

όπου το πρόβλημα είναι μη-γραμμικό (γιατί;;;).

- ▶ Θα μελετήσουμε μόνο γραμμικά προβλήματα ελαχίστων τετραγώνων.

# Παράδειγμα: Data Fitting

---

- ▶ Προσέγγιση (με τη μέθοδο ελαχίστων τετραγώνων) 5 σημείων με πολυώνυμο 2ου βαθμού:

$$Ac = \begin{bmatrix} 1 & x_1 & x_1^2 \\ 1 & x_2 & x_2^2 \\ 1 & x_3 & x_3^2 \\ 1 & x_4 & x_4^2 \\ 1 & x_5 & x_5^2 \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} \cong \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \end{bmatrix} = b$$

όπου ο πίνακας  $A$  είναι τύπου *Vandermonde*.

# Παράδειγμα: Data Fitting

---

- ▶ Με σημεία τα  $(-1, 1)$ ,  $(-0.5, 0.5)$ ,  $(0, 0)$ ,  $(0.5, 0.5)$ ,  $(1, 2)$ , τότε:

$$Ac = \begin{bmatrix} 1 & -1.0 & 1.0 \\ 1 & -0.5 & 0.25 \\ 1 & 0.0 & 0.0 \\ 1 & 0.5 & 0.25 \\ 1 & 1.0 & 1.0 \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} \cong \begin{bmatrix} 1.0 \\ 0.5 \\ 0.0 \\ 0.5 \\ 2.0 \end{bmatrix} = b$$


η μέθοδος ελαχίστων τετραγώνων δίνει λύση την  $[0.086 \ 0.4 \ 1.4]^T$ , οπότε το πολυώνυμο είναι:

$$p(x) = 0.086 + 0.4x + 1.4x^2$$

# Παράδειγμα: Data Fitting

---

Τα 5 σημεία και το πολυώνυμο που τα προσεγγίζει.



# Μέθοδος ελαχίστων τετραγώνων

---

- ▶ Για γραμμικά προβλήματα που καταλήγουν σε υπερπροσδιορισμένα γραμμικά συστήματα  $Ax=b$ , με τον  $A$  να είναι διάστασης  $m \times n$  και  $m > n$ .
- ▶ Επειδή το σύστημα δεν λύνεται ακριβώς όταν  $m > n$ , συνήθως γράφουμε  $Ax \approx b$ .
- ▶ Η μέθοδος των ελαχίστων τετραγώνων υπολογίζει το  $x$  έτσι ώστε να ελαχιστοποιεί την Ευκλείδεια νόρμα του υπολοίπου:

$$\min_x \|r\|_2^2 = \min_x \|b - Ax\|_2^2$$



# Ύπαρξη και μοναδικότητα της λύσης.

---

- ▶ Το πρόβλημα των ελαχίστων τετραγώνων  $Ax \approx b$ , έχει πάντα λύση.
- ▶ Η λύση είναι μοναδική αν και μόνο αν οι στήλες του  $A$  είναι γραμμικά ανεξάρτητες, δηλ.  $\text{rank}(A) = n$ , αφού  $m > n$ .
- ▶ Αν  $\text{rank}(A) < n$ , τότε η λύση δεν είναι μοναδική.
- ▶ Στα προβλήματα που θα λύσουμε θα ισχύει  $\text{rank}(A) = n$ .

# Αναγκαίες μαθηματικές έννοιες.

---

- ▶ Γραμμικοί χώροι.
- ▶ Εσωτερικό γινόμενο.
- ▶ Νόρμα.
- ▶ Βέλτιστη προσέγγιση.
- ▶ Βάσεις.
- ▶ Ορθογώνιες βάσεις.

# Γραμμικοί χώροι - Εσωτερικό γινόμενο.

---

Ορισμός: **Γραμμικός χώρος**  $X$ , είναι ένας χώρος εφοδιασμένος με πρόσθεση και με πολλαπλασιασμό με πραγματικό αριθμό.

Ορισμός: Μία απεικόνιση  $(\cdot, \cdot): X \times X \rightarrow \mathbb{R}$  λέγεται **εσωτερικό γινόμενο**, αν ικανοποιεί τις ιδιότητες:

$$(x + y, z) = (x, z) + (y, z), \quad \forall x, y, z \in X$$

$$(\lambda x, y) = \lambda(x, y), \quad \forall x, y \in X$$

$$(x, y) = (y, x), \quad \forall x, y \in X$$

$$(x, x) > 0, \quad \forall x \in X - \{0\}$$

# Παραδείγματα.

---

- ▶ Εσωτερικό γινόμενο στον  $\mathbb{R}^2$  :

$$x = (a, b), y = (c, d) \in \mathbb{R}^2, (x, y) = ac + bd$$

- ▶ Εσωτερικά γινόμενα στον  $C([a, b])$  :

$$f, g \in C([a, b]), (f, g) = \int_a^b f(x)g(x)dx,$$

ή

$$f, g \in C([a, b]), (f, g) = \int_a^b w(x)f(x)g(x)dx.$$

# Νόρμα (ή στάθμη ή απόσταση).

---

Ορισμός: Μία απεικόνιση  $(\cdot, \cdot): X \times X \rightarrow \mathbb{R}$  λέγεται **νόρμα**, αν ικανοποιεί τις ιδιότητες:

$$x \in X \quad \|x\| = 0 \Leftrightarrow x = 0$$

$$\forall \lambda \in \mathbb{R}, \forall x \in X \quad \|\lambda x\| = |\lambda| \|x\|$$

$$\forall x, y \in X \quad \|x + y\| \leq \|x\| + \|y\|$$

# Παραδείγματα.

---

- ▶ Νόρμα στον  $\mathbb{R}^2$  :

$$x = (a, b) \in \mathbb{R}^2, \|x\| = \sqrt{a^2 + b^2}$$

- ▶ Νόρμες στον  $C([a, b])$ :

$$f \in C([a, b]), \|f\|_2 = \sqrt{\int_a^b f^2(x) dx}, \quad f \in C([a, b]), \|f\|_1 = \int_a^b |f(x)| dx,$$

$$f \in C([a, b]), \|f\|_{w,2} = \sqrt{\int_a^b w(x) f^2(x) dx}, \quad f \in C([a, b]), \|f\|_\infty = \max_{a \leq x \leq b} |f(x)|.$$

# Βάσεις - Ορθογώνιες Βάσεις.

---

Ορισμός: Έστω  $(X, (\cdot, \cdot))$  ένας γραμμικός χώρος με εσωτερικό γινόμενο, ένα υποσύνολο σύνολο του  $\{x_1, x_2, \dots, x_n\}$ , λέγεται **βάση**, ανν :

$$\forall x \in X, \exists a_1, a_2, \dots, a_n \in \mathbb{R}, x = \sum_{i=1}^n a_i x_i$$

Ορισμός: Έστω  $(X, (\cdot, \cdot))$  ένας γραμμικός χώρος με εσωτερικό γινόμενο, ένα υποσύνολο σύνολο του  $\{x_1, x_2, \dots, x_n\}$ , λέγεται **ορθογώνια βάση**, ανν είναι βάση και ισχύει:

$$(x_i, x_j) = 0, \quad i \neq j$$

# Βάσεις (συνέχεια).

---

Έστω  $(X, (\cdot, \cdot))$  γραμμικός χώρος με εσωτερικό γινόμενο, τότε από το εσωτερικό γινόμενο ορίζεται η νόρμα:

$$\forall x \in X, \quad \|x\| = \sqrt{(x, x)}$$

Έστω  $(X, (\cdot, \cdot))$  γραμμικός χώρος με εσωτερικό γινόμενο,  $Y$  υποσύνολο του  $X$ ,  $x$  στοιχείο του  $X$ ,  $y$  η βέλτιστη προσέγγιση του  $x$  μέσα στο  $Y$  (με βάση τη νόρμα που παράγεται από το εσ. γιν.) και  $\{z_i\}, i=1, \dots, n$  βάση του  $Y$ , τότε ισχύει:

$$(x, z_i) = (y, z_i), \quad i = 1, \dots, n$$



# Ορθογωνιότητα.

---


- ▶ Δύο διανύσματα  $v_1, v_2$  λέγονται ορθογώνια αν το εσωτερικό τους γινόμενο είναι 0,  $v_1^T v_2 = 0$ .
- ▶ Ο χώρος που παράγεται από τον  $A$ ,  $\text{span}(A) = \{Ax: x \in \mathbb{R}^n\}$  είναι διάστασης το πολύ  $n$ .
- ▶ Αν  $m > n$  τότε το  $b$  δεν ανήκει γενικά στον  $\text{span}(A) \rightarrow$  το σύστημα  $Ax=b$  δεν έχει λύση.
- ▶ Το διάνυσμα  $y=Ax$  στον  $\text{span}(A)$ , είναι η βέλτιστη προσέγγιση του  $b$  (ως προς την  $\|\cdot\|_2$  νόρμα), όταν το υπόλοιπο είναι κάθετο στο χώρο  $\text{span}(A)$ :

$$0 = A^T r = A^T (b - Ax) \Rightarrow A^T Ax = A^T b$$

# Βέλτιστη προσέγγιση.

Ορισμός: Έστω  $(X, \|\cdot\|)$  ένας γραμμικός χώρος με νόρμα,  $Y$  ένα υποσύνολο του  $X$  και  $x$  στοιχείο του  $X$ . Ένα στοιχείο  $y$  του  $Y$  είναι λέγεται **βέλτιστη προσέγγιση** (ή **προβολή του  $x$  στον  $Y$** ) του  $x$  ανν ισχύει:

$$\forall z \in Y \quad \|x - y\| \leq \|x - z\|$$




ο  $Y$  λέγεται **χώρος προσέγγισης**.

# Ορθογωνιότητα - Ιδιότητα της Βέλτιστης προσέγγισης.

---

Το διάνυσμα  $y=Ax$  στον  $\text{span}(A)$ , είναι η βέλτιστη προσέγγιση του  $b$  (ως προς την  $\|\cdot\|_2$  νόρμα), εμφανίζεται όταν το υπόλοιπο είναι κάθετο στο χώρο  $\text{span}(A)$ :



$$0 = A^T r = A^T (b - Ax) \Rightarrow A^T Ax = A^T b$$

# Ψευδοαντίστροφος και δείκτης κατάστασης.

---

Για ένα πίνακα  $A$ ,  $m \times n$ , δεν υπάρχει αντίστροφος με τη γνωστή έννοια.

Αν  $\text{rank}(A)=n$ , ο ψευδοαντίστροφος ορίζεται ως:

$$A^+ = (A^T A)^{-1} A^T \quad \text{και} \quad \text{cond}(A) = \|A\|_2 \|A^+\|_2$$

Αν  $\text{rank}(A) < n$  τότε  $\text{cond}(A) = \infty$

Η λύση των ελαχίστων τετραγώνων για το σύστημα  $Ax \approx b$ , είναι

$$x = A^+ b$$

# Ευαισθησία και συνθήκες

---

Η μέθοδος των ελαχίστων τετραγώνων επηρεάζεται τόσο από τον πίνακα  $A$  όσο και από το διάνυσμα  $b$ .

Η γωνία  $\theta$  μεταξύ του  $y=Ax$  και του  $b$  σαν:

$$\cos(\theta) = \frac{\|y\|_2}{\|b\|_2} = \frac{\|Ax\|_2}{\|b\|_2}$$

Το σχετικό σφάλμα φράσσεται:

$$\frac{\|\Delta x\|_2}{\|x\|_2} \leq \text{cond}(A) \frac{1}{\cos(\theta)} \frac{\|\Delta b\|_2}{\|b\|_2}$$

ή

$$\frac{\|\Delta x\|_2}{\|x\|_2} \leq \left( \text{cond}^2(A) \tan(\theta) + \text{cond}(A) \right) \frac{\|\Delta A\|_2}{\|A\|_2}$$

# Κανονικές εξισώσεις.

---

Τα ελάχιστα τετράγωνα ελαχιστοποιούν το τετράγωνο της Ευκλείδειας νόρμας του υπολοίπου:

$$\|r\|_2^2 = r^T r, \quad r = b - Ax$$

Για να ελαχιστοποιήσουμε το υπόλοιπο:

$$\|r\|_2^2 = r^T r = (b - Ax)^T (b - Ax)$$

$$= b^T b - 2x^T A^T b + x^T A^T Ax,$$

παραγωγίζουμε ως προς  $x$ , την θέτουμε ίση με 0 και λύνουμε ως προς  $x$ :

$$2A^T Ax - 2A^T b = 0 \Leftrightarrow A^T Ax = A^T b$$

όπου το τελευταίο σύστημα είναι  $n \times n$  και ονομάζεται σύστημα **κανονικών εξισώσεων**.

# Μέθοδος Κανονικών Εξισώσεων

---

Αν ο  $m \times n$  πίνακας  $A$  έχει τάξη  $n$ , τότε ο συμμετρικός  $n \times n$  πίνακας  $A^T A$  είναι θετικά ορισμένος, οπότε η παραγοντοποίηση Cholesky:

$$A^T A = LL^T$$

μπορεί να χρησιμοποιηθεί για τη λύση του συστήματος:

$$A^T A x = A^T b$$

που έχει την ίδια λύση με αυτή του προβλήματος των γραμμικών ελαχίστων τετραγώνων  $Ax \cong b$  .

# Παράδειγμα: Μέθοδος Κανονικών Εξισώσεων

Με σημεία τα  $(-1, 1)$ ,  $(-0.5, 0.5)$ ,  $(0, 0)$ ,  $(0.5, 0.5)$ ,  $(1, 2)$ ,  
τότε:

$$A^T A = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ -1.0 & -0.5 & 0.0 & 0.5 & 1.0 \\ 1.0 & 0.25 & 0.0 & 0.25 & 1.0 \end{bmatrix} \begin{bmatrix} 1 & -1.0 & 1.0 \\ 1 & -0.5 & 0.25 \\ 1 & 0.0 & 0.0 \\ 1 & 0.5 & 0.25 \\ 1 & 1.0 & 1.0 \end{bmatrix} = \begin{bmatrix} 5.0 & 0.0 & 2.5 \\ 0.0 & 2.5 & 0.0 \\ 2.5 & 0.0 & 2.125 \end{bmatrix},$$

$$A^T b = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ -1.0 & -0.5 & 0.0 & 0.5 & 1.0 \\ 1.0 & 0.25 & 0.0 & 0.25 & 1.0 \end{bmatrix} \begin{bmatrix} 1.0 \\ 0.5 \\ 0.0 \\ 0.5 \\ 2.0 \end{bmatrix} = \begin{bmatrix} 4.0 \\ 1.0 \\ 3.25 \end{bmatrix}$$



# Παράδειγμα: Μέθοδος Κανονικών Εξισώσεων

---

Η παραγοντοποίηση Cholesky για τον  $A^T A$  δίνει:

$$A^T A = \begin{bmatrix} 5.0 & 0.0 & 2.5 \\ 0.0 & 2.5 & 0.0 \\ 2.5 & 0.0 & 2.125 \end{bmatrix} =$$
$$\begin{bmatrix} 2.236 & 0 & 0 \\ 0 & 1.581 & 0 \\ 1.118 & 0 & 0.935 \end{bmatrix} \begin{bmatrix} 2.236 & 0 & 1.118 \\ 0 & 1.581 & 0 \\ 0 & 0 & 0.935 \end{bmatrix}$$
$$= LL^T$$

# Παράδειγμα: Μέθοδος Κανονικών Εξισώσεων

---


Λύνοντας το κάτω τριγωνικό σύστημα  $Lz=A^Tb$  με προς τα εμπρός αντικατάσταση έχουμε:

$$z = \begin{bmatrix} 1.789 \\ 0.632 \\ 1.336 \end{bmatrix}$$

Λύνοντας το άνω τριγωνικό σύστημα  $L^T x=z$ , με προς τα πίσω αντικατάσταση έχουμε την λύση των ελαχίστων τετραγώνων:


$$x = \begin{bmatrix} 0.086 \\ 0.400 \\ 1.429 \end{bmatrix}$$

# Προσέγγιση συναρτήσεων.




- Υψηλή ακρίβεια (6-30 δεκαδ. ψηφία).
- Ανυπαρξία αβεβαιότητας στη συνάρτηση.
- Χρήση όλων των ιδιοτήτων της συνάρτησης για μείωση πολυπλοκότητας.

# Αναπαράσταση δεδομένων.



- Μεσαία ακρίβεια (2-5 δεκαδ. ψηφία).
- Μικρή αβεβαιότητα στα δεδομένα.
- Μικρή αλλά ικανή πληροφορία για τα δεδομένα (π.χ. μεταβάλλονται εκθετικά).
- Δύσκολο να εμπλουτίσουμε το δείγμα μας.

# Ανάλυση δεδομένων.



- ▶ Χαμηλή ακρίβεια (0.5-3 δεκαδ. ψηφία).
- ▶ Μεγάλη αβεβαιότητα στα δεδομένα.
- ▶ Καμία πληροφορία για τα δεδομένα.
- ▶ Δύσκολο να εμπλουτίσουμε το δείγμα μας.

# Διακριτά ελάχιστα τετράγωνα - Προσέγγιση δεδομένων.

---

Έστω  $\mathbf{x}=(x_1,x_2,\dots,x_m)$ ,  $\mathbf{y}=(y_1,y_2,\dots,y_m)$  διανύσματα του  $\mathbb{R}^m$  που περιέχουν τις τετμημένες και τεταγμένες των δεδομένων.

Για να προσεγγίσουμε τα σημεία με μια **συνάρτηση** με το βέλτιστο τρόπο στον  $\mathbb{R}^n$ , ως προς την Ευκλείδεια νόρμα  $\|\cdot\|_2$  η οποία ορίζεται ως:

$$\mathbf{z} \in \mathbb{R}^m, \quad \|\mathbf{z}\|_2 = \sqrt{\sum_{i=1}^m z_i^2}$$

αρκεί να υπολογίσουμε τους συντελεστές της  $f$  ως προς το σύστημα βάσης συναρτήσεων που επιθυμούμε να χρησιμοποιήσουμε.

Αν  $\{\varphi_i, i=1,\dots,n\}$  είναι οι συναρτήσεις βάσης, τότε  $f = \sum_{i=1}^n c_i \varphi_i$ ,

Επιθυμούμε να ελαχιστοποιήσουμε:

$$\tilde{\mathbf{y}} = (f(x_1) \quad \dots \quad f(x_m)), \quad \|\mathbf{y} - \tilde{\mathbf{y}}\|_2 = \left\| \mathbf{y} - \sum_{i=1}^n c_i \varphi_i(x) \right\|_2$$

# Ελαχιστοποιούμε την ποσότητα:

---

$$r = \|y - \tilde{y}\|_2^2 = \sum_{i=1}^m \left( \sum_{j=1}^n c_j \varphi_j(x_i) - y_i \right)^2$$

$$\frac{\partial r}{\partial c_k} = 0, \quad k = 1, \dots, n$$

σε μορφή πίνακα (κανονικές εξισώσεις):


$$Pc = b,$$

$$p_{ij} = \sum_{k=1}^m \varphi_i(x_k) \varphi_j(x_k), \quad i, j = 1, \dots, n$$

$$b_i = \sum_{k=1}^m \varphi_i(x_k) y_k, \quad i = 1, \dots, n$$


Ερώτηση: Ποια η διαφορά μεταξύ των πινάκων από τις κανονικές εξισώσεις στην προσέγγιση συναρτήσεων και διακριτών δεδομένων;

# Εκτίμηση σφάλματος προσέγγισης δεδομένων (a-posteriori).





# Εκτίμηση σφάλματος προσέγγισης δεδομένων (a-posteriori).



$$\|\mathbf{y} - \tilde{\mathbf{y}}\|_2$$

# Διακριτά ελάχιστα τετράγωνα - Προσέγγιση δεδομένων με ευθεία.

---

Έστω  $\mathbf{x}=(x_1,x_2,\dots,x_m)$ ,  $\mathbf{y}=(y_1,y_2,\dots,y_m)$  διανύσματα του  $\mathbb{R}^m$  που περιέχουν τις τετμημένες και τεταγμένες των δεδομένων.

Για να προσεγγίσουμε τα σημεία με μια **ευθεία** με το βέλτιστο τρόπο στον  $\mathbb{R}^m$ , ως προς την Ευκλείδεια νόρμα  $\|\cdot\|_2$  η οποία ορίζεται ως:

$$\mathbf{z} \in \mathbb{R}^m, \quad \|\mathbf{z}\|_2 = \sqrt{\sum_{i=1}^m z_i^2}$$

αρκεί να υπολογίσουμε τα  $a_0$  και  $a_1$ , (αν η ευθεία είναι η  $y=a_0+a_1x$ )

ώστε η ποσότητα να είναι η ελάχιστη δυνατή:

$$\|\mathbf{y} - \tilde{\mathbf{y}}\|_2 = \|\mathbf{y} - (a_0 + a_1\mathbf{x})\|_2$$

- ▶ *Ανάλογα δουλεύουμε αν προσεγγίζουμε με παραβολή ή με πολυώνυμο μεγαλύτερου βαθμού.*

# Παράδειγμα:

---

$$n = 2, \varphi_i(\mathbf{x}) = x^{i-1}, i = 1, 2$$

σε μορφή πίνακα (κανονικές εξισώσεις):

$$Pc = b$$

$$P = \begin{bmatrix} m & \sum_{i=1}^m x_i \\ \sum_{i=1}^m x_i & \sum_{i=1}^m x_i^2 \end{bmatrix}, \quad b = \begin{bmatrix} \sum_{i=1}^m y_i \\ \sum_{i=1}^m x_i y_i \end{bmatrix}$$

# Προσέγγιση συναρτήσεων.

Αν  $X$  είναι ο χώρος των ομαλών συναρτήσεων με πεδίο ορισμού το  $[a, b]$  και  $Y$  ο χώρος προσέγγισης με βάση  $\{B_i\}, i=1, \dots, n$ , τότε αν  $f \in X$  τότε η βέλτιστη προσέγγιση  $\varphi \in Y$  έχει τη μορφή

$$\varphi(x) = \sum_{i=1}^n a_i B_i(x)$$

και ισχύει  $(f, B_j) = (\varphi, B_j) \Leftrightarrow (f, B_j) = \sum_{i=1}^n a_i (B_i, B_j), \quad \forall j = 1, \dots, n$

(κανονικές εξισώσεις).

# Προσέγγιση συναρτήσεων (συνέχεια).

Το σύστημα που προκύπτει έχει τη μορφή:

$$\begin{bmatrix} (B_1, B_1) & \cdots & (B_n, B_1) \\ \vdots & \ddots & \vdots \\ (B_n, B_n) & \cdots & (B_n, B_n) \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} (f, B_1) \\ \vdots \\ (f, B_n) \end{bmatrix}$$

όπου αν η βάση είναι ορθογώνια ισχύει:

$$(B_i, B_j) = 0, i \neq j \quad \Rightarrow$$

$$\begin{bmatrix} (B_1, B_1) & 0 & \cdots & 0 \\ 0 & (B_2, B_2) & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & (B_n, B_n) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} (f, B_1) \\ (f, B_2) \\ \vdots \\ (f, B_n) \end{bmatrix} \quad \Rightarrow \quad a_j = \frac{(f, B_j)}{(B_j, B_j)}, \quad j = 1, \dots, n$$

# Προσέγγιση συναρτήσεων (συνέχεια).

Αν  $X$  είναι ο χώρος των ομαλών συναρτήσεων με πεδίο ορισμού το  $[a, b]$  και χώρος προσέγγισης είναι ο χώρος των πολυωνύμων βαθμού  $n$ ,  $\mathbf{P}_n([a, b])$ , και αν  $f \in X$  τότε η βέλτιστη προσέγγιση  $p_n^* \in \mathbf{P}_n([a, b])$  έχει τη μορφή

$$p_n^*(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0$$

και ισχύει  $\|f - p_n^*\| \leq \|f - p\|, \forall p \in \mathbf{P}_n([a, b])$

ως προς τη συγκεκριμένη νόρμα.

# Προσέγγιση συναρτήσεων (συνέχεια).

Τα μονώνυμα δεν αποτελούν ορθογώνια βάση.

Ορθοκανονικοποίηση Gram-Schmidt: Αν  $x_1, \dots, x_n$  βάση του χώρου  $X$ , τότε μπορούμε να κατασκευάσουμε μια ορθοκανονική βάση  $e_1, \dots, e_n$  του χώρου  $X$ .

Απόδειξη: Ορίζουμε

$$e'_1 = x_1, \quad e'_2 = x_2 - \frac{(x_2, e'_1)}{(e'_1, e'_1)} e'_1, \quad \dots$$

$$e'_n = x_n - \frac{(x_n, e'_{n-1})}{(e'_{n-1}, e'_{n-1})} e'_{n-1} - \dots - \frac{(x_n, e'_1)}{(e'_1, e'_1)} e'_1$$

Θέτουμε:

$$e_i = \frac{e'_i}{\|e'_i\|}, \quad i = 1, \dots, n$$

# Προσέγγιση συναρτήσεων (συνέχεια).

Ανισότητα Bessel: Αν  $x_n \in X_n$  βέλτιστη προσέγγιση του  $x \in X$ , τότε

$\|x_n\| \leq \|x\|$  , και αν  $e_1, \dots, e_n$  ορθοκανονική βάση του  $X_n$  τότε ισχύει:

$$\sum_{i=1}^n |(x, e_i)|^2 \leq \|x\|^2$$

Απόδειξη: Γνωρίζουμε ότι  $(x - x_n, x_n) = 0$ , άρα

$$\|x\|^2 = \|(x - x_n) + x_n\|^2 = \|x - x_n\|^2 + \|x_n\|^2 \Rightarrow \|x\|^2 \geq \|x_n\|^2$$

Επίσης:

$$x_n = \sum_{i=1}^n (x, e_i) e_i \Rightarrow \|x_n\|^2 = \left\| \sum_{i=1}^n (x, e_i) e_i \right\|^2 = \sum_{i=1}^n \|(x, e_i) e_i\|^2 = \sum_{i=1}^n |(x, e_i)|^2 \cdot \|e_i\|^2 \Rightarrow$$

$$\left. \begin{array}{l} \|x_n\|^2 = \sum_{i=1}^n |(x, e_i)|^2 \\ \|x\|^2 \geq \|x_n\|^2 \end{array} \right\} \Rightarrow \|x\|^2 \geq \sum_{i=1}^n |(x, e_i)|^2$$



# Ορθογώνια πολυώνυμα.

Θεώρημα: Έστω  $w$  μια συνάρτηση βάρους (εσωτερικό γινόμενο), τότε υπάρχουν μοναδικά πολυώνυμα  $p_n \in P_n$  τα οποία είναι ορθογώνια ως προς το  $(\cdot, \cdot)_w$  και ισχύει:

$$\begin{cases} p_{-1}(x) = 0, \\ p_0(x) = 1, \\ p_{n+1}(x) = (x - a_{n+1})p_n(x) - \beta_n p_{n-1}(x), \quad n \geq 0 \end{cases}$$

και 
$$\begin{cases} a_{n+1} = \frac{(\hat{x}p_n, p_n)_w}{(p_n, p_n)_w}, \quad n \geq 0 \\ \beta_{n+1}(x) = \begin{cases} 0, & n = 0 \\ \frac{(p_n, p_n)_w}{(p_{n-1}, p_{n-1})_w}, & n \geq 1 \end{cases} \end{cases}, \text{ όπου } \hat{x} \text{ η ταυτοτική}$$

συνάρτηση.

# Ορθογώνια πολυώνυμα (συνέχεια).

---

- ▶ Πολυώνυμα Legendre: Αν  $w(x)=1$  και το πεδίο ορισμού των συναρτήσεων είναι το  $[-1,1]$  τότε τα ορθογώνια πολυώνυμα  $p_n$  ονομάζονται πολυώνυμα Legendre και ισχύει :

$$\gamma_n P_n(1) = 1, \quad P_n = \gamma_n P_n$$

και

$$P_0(x) = 1, \quad P_1(x) = x,$$

$$(n+1)P_{n+1}(x) = (2n+1)xP_n(x) - nP_{n-1}(x), \quad n > 1$$

# Ορθογώνια πολυώνυμα (συνέχεια).

---


- ▶ Πολυώνυμα Chebyshev: Αν  $w(x)=(1-x)^\alpha(1+x)^\beta$ ,  $\alpha=\beta=1/2$  και το πεδίο ορισμού των συναρτήσεων είναι το  $[-1,1]$  τότε τα ορθογώνια πολυώνυμα  $T_n$  ονομάζονται πολυώνυμα Chebyshev και ισχύει :

$$T_n(x) = \cos(n \arccos(x)), \quad x \in [-1,1], \quad n = 0,1,\dots,$$

ή

$$T_0(x)=1, \quad T_1(x)=x, \quad T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x), \quad x \in [-1,1], \quad n = 1,\dots,$$

# Εκτίμηση σφάλματος προσέγγισης συνάρτησης (a-posteriori).



# Κανονικές Εξισώσεις.

---

## ☹️ Σοβαρά μειονεκτήματα:


- ▶ Ο δείκτης κατάστασης του  $P$  είναι μεγάλος.
- ▶ Αν οι συναρτήσεις βάσεις δεν είναι ορθογώνιες, τότε ο  $P$  μπορεί είναι «σχεδόν μη αντιστρέψιμος».

## 😊 Αντιμετώπιση με μετασχηματισμούς Householder.

- ▶ Ορισμός: Ένας τετραγωνικός πίνακας  $U$  λέγεται ορθοκανονικός αν  $U^T U = I$ , δηλαδή ο ανάστροφος του είναι και ο αντίστροφος του.

SVD:

$$U^T A V = \begin{bmatrix} \Sigma & 0 \\ 0 & 0 \end{bmatrix}$$




$$A = U \begin{bmatrix} \Sigma & 0 \\ 0 & 0 \end{bmatrix} V^T$$

Συστολι

$\varphi : [a, b] \rightarrow [a, b]$ , συνεχής  
 συστολή

$x_0 \rightsquigarrow x_{n+1} = \varphi(x_n)$

$x_n \rightarrow x^*$   
 ↑ σταθερό σημείο του  $\varphi$



$$x_n - x^* = \underbrace{\varphi(x_{n-1})}_{\text{οριζώνιο της απόστασης}} - x^* = \varphi(x_{n-1}) - \underbrace{\varphi(x^*)}_{\text{σταθερό σημείο του } \varphi}$$

$$|x_n - x^*| = |\varphi(x_{n-1}) - \varphi(x^*)| \stackrel{\text{Lipschitz}}{\leq} L |x_{n-1} - x^*|$$

$$\begin{aligned} &\leq L \cdot L \cdot |x_{n-2} - x^*| = L^2 |x_{n-2} - x^*| \leq \\ &\leq \dots \leq L^n |x_0 - x^*| \leq \\ &\leq L^n \max\{x_0 - a, b - x_0\} \end{aligned}$$

---


$$|x_n - x^*| \leq L^n \max\{x_0 - a, b - x_0\}$$

Π. 1.

$$a = 0, b = 2, x_0 = 1$$


$$L = 1/10$$

Πόσες ενδιάμεσες επαλήθευσεις είναι


απαραίτητες για να ελεγχθεί ότι το σφάλμα είναι το πολύ  $10^{-6}$

$$|x_n - x^*| \leq 10^{-6} \leq L^n \max\{1-0, 2-1\} = 10^{-n}$$

$$\Rightarrow \boxed{n \geq 6}$$



$$|x_n - x^*| < \frac{L}{1-L} |x_n - x_{n-1}|$$




## Splines:

2) κυβικά splines  $s$

- Παρεμβολή

- κατά τη διάρκεια κυβικά πολυώνυμα

$$\underline{S(x_i) = y_i}$$



-  $s \in C^2([x_0, x_n])$ , συνέχεια μέχρι  $2^n$  παράγωγο.

$$s_-(x_i) = s_+(x_i)$$

$$s'_-(x_i) = s'_+(x_i)$$

$$s''_-(x_i) = s''_+(x_i)$$

B) Hermite splines  $s$ :  
- Παρεμβολή



- κάθε τμήμα κυρίως ποσότητα.
- συνεχές μέχρι  $1^m$  παράγωγο
- $S(x_i) = y_i$
- $S'(x_i) = z_i$

- Νόρμες διανυσμάτων

$$x \in \mathbb{R}^n \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$\|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2}$$

$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

Νόρμα:  $\|\cdot\| : X \rightarrow \mathbb{R}_+$

$$\|x\| = 0 \Leftrightarrow x = 0$$

$$\|\lambda x\| = |\lambda| \cdot \|x\|$$

$$\|x+y\| \leq \|x\| + \|y\|$$

$\forall x$ :

$$\|\cdot\|_a : X \rightarrow \mathbb{R} \quad X = \mathbb{R}^n \quad a \in \mathbb{R}$$

$$\|x\|_a = |ax_1 + ax_2 + \dots + ax_n|$$

$\|\cdot\|_a$  νόρμα??

ΟΧΙ γιατί για το  $x = \begin{bmatrix} 1 \\ -1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \neq 0$

$$\|x\|_a = |a - a + 0 \dots d| = 0$$

Π. X.:

$$\|\cdot\|_B : \mathbb{R}^n \rightarrow \mathbb{R} \quad B \in \mathbb{R}_+$$

$$\|x\|_B = B(|x_1| + \dots + |x_n|)$$

properties:

$$- \|x\|_B \geq 0 \quad \forall x \in \mathbb{R}^n$$

$$- \|x\|_B = 0 \stackrel{?}{\Leftrightarrow} x = 0$$

$$\cdot x = 0 \Rightarrow x_i = 0 \quad \forall i = 1..n \Rightarrow \|x\|_B = 0$$

$$\cdot \|x\|_B = 0 \Rightarrow B(|x_1| + |x_2| + \dots + |x_n|) = 0 \Rightarrow$$

$$\stackrel{B \neq 0}{\Rightarrow} \sum |x_i| = 0 \Rightarrow \forall x_i = 0 \Rightarrow \underline{\underline{x=0}}$$

$$- \|\lambda x\|_B \stackrel{?}{=} |\lambda| \cdot \|x\|_B$$

$$\|\lambda x\|_B = B(|\lambda x_1| + |\lambda x_2| + \dots + |\lambda x_n|) =$$

$$= B(|\lambda| \cdot (|x_1| + |x_2| + \dots + |x_n|)) =$$

$$= |\lambda| \left( B(|x_1| + |x_2| + \dots + |x_n|) \right) =$$

$$= |\lambda| \cdot \|x\|_B$$

$$- \|x+y\|_p \leq \|x\|_p + \|y\|_p$$

$$\begin{aligned} \|x+y\|_p &= p (|x_1+y_1| + |x_2+y_2| + \dots + |x_n+y_n|) \\ &\leq p (|x_1| + |y_1| + |x_2| + |y_2| + \dots + |x_n| + |y_n|) \\ &= p (\sum |x_i| + \sum |y_i|) = \\ &= p \sum |x_i| + p \sum |y_i| = \|x\|_p + \|y\|_p \end{aligned}$$

Νόρμες συναρτήσεων:

$$f \in C([a, b])$$


$$\|f\|_1 = \int_a^b |f(x)| dx$$

$$\|f\|_2 = \sqrt{\int_a^b f^2(x) dx}$$

$$\|f\|_\infty = \max_{a \leq x \leq b} |f(x)|$$

1

$$\rightarrow y = ax + b$$



$$ax_0 + B = y_0$$

$$ax_1 + B = y_1$$

$$ax_n + B = y_n$$

$$M \begin{bmatrix} a \\ B \end{bmatrix} = Y$$

$$M = \begin{bmatrix} x_0 & 1 \\ x_1 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{bmatrix}$$

$$r = Y - M \begin{bmatrix} a \\ B \end{bmatrix} \neq 0 \Rightarrow r_i = y_i - ax_i - B, \quad i = 0, \dots, n$$

Θέλω να υπολογίσω  $\begin{bmatrix} a \\ B \end{bmatrix}$  τ.ω.

το  $r$  να είναι το ελάχιστο δυνατό.

$$\begin{array}{l} \min_{a, B} \|r\| \\ \parallel \\ g(a, B) \end{array} \begin{array}{l} \xrightarrow{\|\cdot\|_1} \min_{a, B} \left( \sum_{i=0}^n |y_i - ax_i - B| \right) \\ \xrightarrow{\|\cdot\|_\infty} \min_{a, B} \left( \max_{i=0, \dots, n} |y_i - ax_i - B| \right) \\ \xrightarrow{\|\cdot\|_2} \min_{a, B} \left( \sqrt{\sum_{i=0}^n (y_i - ax_i - B)^2} \right) \end{array}$$

Αρα υπολογίζω να δουλέψω το

$$\min_{a, B} \left( \sum_{i=0}^n (y_i - ax_i - B)^2 \right)$$

$$\min_{\alpha, \beta} \underbrace{\left( \sum_{i=0}^n (y_i - \alpha x_i - \beta)^2 \right)}_{g(\alpha, \beta)}$$

$$\begin{aligned} \frac{\partial g}{\partial \alpha} = 0 &\Leftrightarrow \frac{\partial}{\partial \alpha} \left( \sum (\ )^2 \right) = \sum_{i=0}^n \frac{\partial}{\partial \alpha} (y_i - \alpha x_i - \beta)^2 = \sum_{i=0}^n 2(y_i - \alpha x_i - \beta)(-x_i) \\ &= \sum (2y_i x_i + 2\alpha x_i^2 + 2\beta x_i) \\ &= -2 \sum y_i x_i + 2\alpha \sum x_i^2 + 2\beta \sum x_i = 0 \end{aligned}$$

$$\text{Όρα } \alpha \sum_{i=0}^n x_i^2 + \beta \sum_{i=0}^n x_i = \sum_{i=0}^n x_i y_i$$

0 ∈ ℝ

Όπως

$$\frac{\partial g}{\partial \beta} = 0 \Rightarrow \alpha \sum_{i=0}^n x_i + (n+1)\beta = \sum_{i=0}^n y_i$$

$$\Downarrow \begin{bmatrix} \sum x_i^2 & \sum x_i \\ \sum x_i & n+1 \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \begin{bmatrix} \sum x_i y_i \\ \sum y_i \end{bmatrix}$$


---