

Identificarea sistemelor

Ingineria sistemelor, anul 3
Universitatea Tehnică din Cluj-Napoca

Lucian Buşoniu



Partea III

Baze matematice: Regresie liniară și statistică

Motivare

Până acum, am discutat analiza în domeniul timp a răspunsurilor la treaptă, folosind concepte cunoscute din teoria sistemelor liniare.

Majoritatea metodelor de identificare care urmează necesită elemente noi: **regresia liniară** și concepte de **teoria probabilităților și statistică**. Le vom discuta aici.

În această parte anumite notații (de ex. x , A) au o semnificație diferită de cea din restul materialului de curs.

Conținut

- 1 Regresia liniară
- 2 Concepte de teoria probabilităților și statistică
- 3 Analiza regresiei liniare

Conținut

- 1 Regresia liniară
 - Problema de regresie liniară și soluția sa
 - Exemple
- 2 Concepte de teoria probabilităților și statistică
- 3 Analiza regresiei liniare

Problema de regresie

Elementele problemei:

- Un șir de eșantioane cunoscute $y(k) \in \mathbb{R}$, indexate de $k = 1, \dots, N$: y este *variabila dependentă* (măsurătoarea).
- Pentru fiecare k , un vector cunoscut $\varphi(k) \in \mathbb{R}^n$: conține *regresorii* $\varphi_i(k)$, $i = 1, \dots, n$, $\varphi(k) = [\varphi_1(k), \varphi_2(k), \dots, \varphi_n(k)]^\top$.
- Un *vector de parametri* $\theta \in \mathbb{R}^n$ **necunoscut**.

Obiectiv: identificarea comportamentului variabilei dependente din date, folosind modelul liniar:


$$y(k) = \varphi^\top(k)\theta$$

Regresia liniară este o metodă clasică și des folosită, de ex. Gauss a folosit-o pentru a calcula orbitele planetelor în 1809.

Problema de regresie: Două utilizări importante

- 1 k este o variabilă de timp, și modelăm seria temporală $y(k)$.
- 2 k este doar un index de eșantion, și $\varphi(k) = \phi(x(k))$ unde x este intrarea unei funcții necunoscute g . În acest caz $y(k)$ este ieșirea corespunzătoare, posibil afectată de zgomot, iar obiectivul este identificarea unui model al funcției g din date. Această problemă se numește și *aproximarea unei funcții*, sau *învățarea supervizată*.

$g(x)$ necunoscut



$\hat{g}(x)$

?

Aproximare: Funcții de bază

Pentru aproximarea unei funcții, regresorii $\phi_i(k)$ din:

$$\phi(x(k)) = [\phi_1(x(k)), \phi_2(x(k)), \dots, \phi_n(x(k))]^\top$$

se numesc *funcții de bază*.

Aproximare: Exemplul 1

Studiem **venitul anual** y (în EUR) al unei persoane bazat pe **nivelul de educație** x_1 și **experiența profesională** x_2 (ambele măsurate în ani).

Se dă un set de date $(x_1(k), x_2(k), y(k))$ de la un grup reprezentativ de persoane. Obiectivul este **predicția** venitului oricărei alte persoane din nivelul său de educație (x_1) și experiență (x_2).

- Alegem funcțiile de bază $\phi(x) = [x_1, x_2, 1]^T$. Ne așteptăm ca venitul să evolueze conform cu $\theta_1 x_1 + \theta_2 x_2 + \theta_3 = \phi^T(x)\theta$, crescând liniar cu educația and experiența (de la un nivel minimal). Regresia implică găsirea parametrilor θ pentru care expresia este cel mai aproape de valorile reale ale venitului.
- În realitate, lucrurile sunt mai complicate... vom avea nevoie de variabile de intrare suplimentare, funcții de bază mai bune, etc.

Aproximare: Exemplul 2

Studiem **timpul de reacție** y (în ms) al unui șofer în funcție de **vârsta** sa x_1 (în ani) și **oboseala** x_2 (de ex. pe o scară de la 0 la 1).

Se dă un set de date $(x_1(k), x_2(k), y(k))$ de la un grup reprezentativ de șoferi de diferite vârste și nivele de oboseală. Obiectivul este **predicția** timpului de reacție al oricărui alt șofer folosind vârsta (x_1) și oboseala (x_2) sa.

Exemplu regresori 1: Polinom în k

Util pentru modelarea seriilor temporale.

$$\begin{aligned}y(k) &= \theta_1 + \theta_2 k + \theta_3 k^2 + \dots + \theta_n k^{n-1} \\ &= [1 \quad k \quad k^2 \quad \dots \quad k^{n-1}] \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \dots \\ \theta_n \end{bmatrix} \\ &= \varphi^\top(k) \theta\end{aligned}$$

Exemplu regresori 2: Polinom în x

Util pentru aproximarea funcțiilor. De exemplu, polinomul de gradul 2 cu două variabile de intrare $x = [x_1, x_2]^T$ este:

$$y(k) = \theta_1 + \theta_2 x_1(k) + \theta_3 x_2(k) + \theta_4 x_1^2(k) + \theta_5 x_2^2(k) + \theta_6 x_1(k)x_2(k)$$

$$= [1 \quad x_1(k) \quad x_2(k) \quad x_1^2(k) \quad x_2^2(k) \quad x_1(k)x_2(k)] \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \\ \theta_5 \\ \theta_6 \end{bmatrix}$$

$$= \phi^T(x(k))\theta = \varphi^T(k)\theta$$



 **Conexiune:** Proiect partea 1

Exemplu regresori 3: Funcții de bază Gaussiene

Utile pentru aproximarea funcțiilor:

$$\phi_i(x) = \exp \left[-\frac{(x - c_i)^2}{b_i^2} \right] \quad (1\text{-dim});$$



$$= \exp \left[-\sum_{j=1}^d \frac{(x_j - c_j)^2}{b_j^2} \right] \quad (d\text{-dim})$$



Exemplu regresori 4: Interpolare

Utilă pentru aproximarea funcțiilor.

- Grilă d -dimensională de puncte în spațiul intrărilor.
- Interpolare (multi)-liniară între aceste puncte.
- Echivalent cu funcții de bază *piramidale* (triunghiulare într-o singură dimensiune)



Sistem liniar

Scrind modelul pentru fiecare din cele N date, obținem un sistem de ecuații liniare:

$$y(1) = \varphi_1(1)\theta_1 + \varphi_2(1)\theta_2 + \dots + \varphi_n(1)\theta_n$$

$$y(2) = \varphi_1(2)\theta_1 + \varphi_2(2)\theta_2 + \dots + \varphi_n(2)\theta_n$$

...

$$y(N) = \varphi_1(N)\theta_1 + \varphi_2(N)\theta_2 + \dots + \varphi_n(N)\theta_n$$

Reamintim că în aproximarea funcțiilor, $\varphi_i(k) = \phi_i(x(k))$

Sistemul se poate scrie în *formă matriceală*:

$$\begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix} = \begin{bmatrix} \varphi_1(1) & \varphi_2(1) & \dots & \varphi_n(1) \\ \varphi_1(2) & \varphi_2(2) & \dots & \varphi_n(2) \\ \dots & \dots & \dots & \dots \\ \varphi_1(N) & \varphi_2(N) & \dots & \varphi_n(N) \end{bmatrix} \cdot \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \dots \\ \theta_n \end{bmatrix}$$

$$Y = \Phi\theta$$

cu noile variabile $Y \in \mathbb{R}^N$ și $\Phi \in \mathbb{R}^{N \times n}$.

Problema celor mai mici pătrate (CMMP)

Dacă $N = n$, sistemul se poate rezolva cu egalitate.

În practică, este mai bine să folosim $N > n$, de ex. datorită zgomotului. În acest caz, sistemul nu mai poate fi rezolvat cu egalitate, ci doar cu aproximare.

- *Eroarea la k* : $\varepsilon(k) = y(k) - \varphi^T(k)\theta$,
vectorul de eroare $\varepsilon = [\varepsilon(1), \varepsilon(2), \dots, \varepsilon(N)]^T$.
- **Funcția obiectiv** ce trebuie minimizată:

$$V(\theta) = \frac{1}{2} \sum_{k=1}^N \varepsilon(k)^2 = \frac{1}{2} \varepsilon^T \varepsilon$$

Problema CMMP

Găsește vectorul de parametri $\hat{\theta}$ care minimizează funcția obiectiv:



$$\hat{\theta} = \arg \min_{\theta} V(\theta)$$

Paranteză: Problema de optimizare

Dată fiind o funcție V de variabilele θ , care poate fi de ex. obiectivul nostru CMMP, sau în general oricare altă funcție:

găsește *valoarea optimă a funcției* $\min_{\theta} V(\theta)$ și valorile

$\theta^* = \arg \min_{\theta} V(\theta)$ ale variabilelor pentru care minimul este atins



De notat că în cazul regresiei liniare, folosim notația $\hat{\theta}$; vectorul $\hat{\theta}$ este soluția reală a problemei de optimizare dat fiind setul de date, dar rămâne totuși o estimare datorită zgomotului din date

Soluția formală a problemei de regresie

După câțiva pași de algebră liniară:

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y$$

Observații:

- Valoarea optimă a funcției obiectiv este $V(\hat{\theta}) = \frac{1}{2} [Y^T Y - Y^T \Phi (\Phi^T \Phi)^{-1} \Phi^T Y]$.
- Matricea $\Phi^T \Phi$ trebuie să fie inversabilă, ceea ce necesită o alegere bună a modelului (ordin n , regresori φ), și folosirea unui set informativ de date.

Expresie alternativă

$$\Phi^T \Phi = \sum_{k=1}^N \varphi(k) \varphi^T(k), \Phi^T Y = \sum_{k=1}^N \varphi(k) y(k)$$

Soluția poate fi scrisă:

$$\hat{\theta} = \left[\sum_{k=1}^N \varphi(k) \varphi^T(k) \right]^{-1} \left[\sum_{k=1}^N \varphi(k) y(k) \right]$$

Avantaj: matricea Φ cu dimensiunile $N \times n$ nu mai trebuie calculată; este nevoie doar de matrici și vectori mai mici, de dimensiuni $n \times n$ respectiv n .

Rezvolarea sistemului liniar

În practică, ambele metode bazate pe inversarea de matrici se comportă prost din punct de vedere numeric. Există algoritmi mai buni, cum ar fi triangularizarea ortogonală.

În majoritatea cazurilor, **MATLAB** alege automat un algoritm potrivit. Dacă Φ este stocată în variabila `PHI` și Y în `Y`, comanda care rezolvă sistemul de ecuații în sensul CMMP este împărțirea matriceală la stânga (backslash):

```
theta = PHI \ Y;
```

Dacă se dorește un control mai detaliat al algoritmului, se poate folosi funcția `linsolve` în loc de `\`.

Conținut

- 1 Regresia liniară
 - Problema de regresie liniară și soluția sa
 - Exemple
- 2 Concepte de teoria probabilităților și statistică
- 3 Analiza regresiei liniare

Exemplu analitic: Estimarea unui scalar

Model:

$$y(k) = b = 1 \cdot b = \varphi(k)\theta$$

unde $\varphi(k) = 1 \forall k$, $\theta = b$.

Pentru N date:

$$y(1) = \varphi(1)\theta = 1 \cdot b$$

...

$$y(N) = \varphi(N)\theta = 1 \cdot b$$

În formă matriceală:

$$\begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \theta$$


$$Y = \Phi\theta$$

Exemplu analitic: Estimarea unui scalar (continuare)

$$\begin{aligned}
 \hat{\theta} &= (\Phi^T \Phi)^{-1} \Phi^T Y \\
 &= \left([1 \ \dots \ 1] \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right)^{-1} [1 \ \dots \ 1] \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix} \\
 &= N^{-1} [1 \ \dots \ 1] \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix} \\
 &= \frac{1}{N} (y(1) + \dots + y(N))
 \end{aligned}$$

Intuiție: Estimarea este media tuturor măsurătorilor, filtrând zgomotul.

Exemplu: Aproximarea funcției lui Rosenbrock




- Funcția Rosenbrock: $g(x_1, x_2) = (1 - x_1)^2 + 100[(x_2 + 1.5) - x_1^2]^2$ (necunoscută de algoritm).
- **Date de identificare:** 200 puncte de intrare (x_1, x_2) , distribuite aleator în spațiul $[-2, 2] \times [-2, 2]$; și ieșirile corespunzătoare $y = g(x_1, x_2)$, **afectate de zgomot**.
- **Date de validare:** grilă uniformă cu 31×31 puncte în $[-2, 2] \times [-2, 2]$ cu ieșirile corespunzătoare (afectate de zgomot).

Funcția Rosenbrock: Aproximare polinomială


Polinom de gradul 4 în cele două intrări (15 parametri):

polynomial; MSE=110




Funcția Rosenbrock: Funcții de bază radiale

Reamintim funcțiile de bază radiale:




Rezultate cu 6×6 RBF-uri, cu centre pe o grilă echidistantă și lățimea egală cu distanța între centre:




Funcția Rosenbrock: Interpolare

Reamintim funcțiile de bază
piramidale, pentru interpolare:



Rezultate cu grilă de interpolare
 6×6 (corespunzând la 6×6
funcții de bază):



Conținut

- 1 Regresia liniară
- 2 **Concepte de teoria probabilităților și statistică**
 - Baze matematice
 - Utilizarea practică în identificarea sistemelor
- 3 Analiza regresiei liniare

Probabilitate: Definiție formală

Concepte preliminare:

- *Rezultat* ω , luând valori în *universul* Ω , $\omega \in \Omega$
- *Eveniment* A , definit ca un subset al Ω , $A \subseteq \Omega$ (cu anumite condiții tehnice de validitate)

Definiție

O **măsură de probabilitate** P este o funcție ce se aplică evenimentelor posibile și produce probabilități în $[0, 1]$, cu satisfacerea condițiilor:

- 1 $0 \leq P(A) \leq 1$ (probabilități valide)
- 2 $P(\Omega) = 1$ (universul complet trebuie să aibă probabilitatea 1)
- 3 Dacă evenimentele A_1, \dots, A_m sunt disjuncte, atunci $P(A_1 \cup A_2 \cup \dots \cup A_m) = P(A_1) + P(A_2) + \dots + P(A_m)$. Această condiție este necesară chiar dacă $m \rightarrow \infty$.

În această secțiune urmărim Capitolul 5 al suportului de curs pentru identificarea sistemelor de la Uppsala University, dezvoltate de K. Pelckmans.

Probabilitate: Exemplu

Considerăm precipitația într-o anumită zi, notată cu h și măsurată în mm.

- *Univers*: de ex. $\Omega = \{\text{senin } (h = 0), \text{burniță } (0 < h \leq 2), \text{ploaie } (2 < h \leq 10), \text{furtună } (h > 10)\}$, cu *rezultatele* ω putând lua oricare dintre aceste valori.
- *Eveniment A*: orice rezultat individual, de ex. $A = \{\text{burniță}\}$, și în plus orice reuniune de rezultate, cum ar fi $A = \{\text{burniță}\} \cup \{\text{ploaie}\} \cup \{\text{furtună}\}$; cu numele posibil $A = \text{umed}$.

Un exemplu de *măsură de probabilitate* este $P(\{\text{senin}\}) = 0.5$, $P(\{\text{burniță}\}) = 0.2$, $P(\{\text{ploaie}\}) = 0.2$, $P(\{\text{furtună}\}) = 0.1$, și folosim condiția 3 pentru a genera evenimente combinate, de ex. $P(\text{umed}) = 0.2 + 0.2 + 0.1 = 0.5$. De notat că ambele condiții, 1 și 2, sunt satisfăcute.

Probabilitate: Independență

Probabilitatea comună a două evenimente A și B este $P(A, B) := P(A \cap B)$.

Definiție

Două evenimente A și B se numesc **independente** dacă $P(A, B) = P(A)P(B)$.

Exemple:

- Evenimentul de a arunca 6 cu un zar este independent de evenimentul 6 la aruncarea anterioară (de fapt, de oricare altă valoare la orice aruncare anterioară).
- Evenimentul de a arunca două valori 6 *consecutive* nu este independent de aruncarea anterioară!

(Primul fapt este contra-intuitiv și multă lume nu îl înțelege, ducând la așa-numita *gambler's fallacy*. O secvență mai lungă de jocuri norocoase sau proaste nu are nici absolut nici o influență asupra jocului următor!)

Variabilă aleatoare

Definiție

O **variabilă aleatoare** este o funcție $X : \Omega \rightarrow \mathcal{X}$ definită pe universul Ω , și care ia valori într-un spațiu arbitrar \mathcal{X} .

Intuitiv, variabilele aleatoare asociază valori interesante rezultatelor ω . O valoare specifică (deterministă) a variabilei X este notată cu x . O astfel de valoare se numește *realizare* a X .

Probabilitatea cu care X ia valoarea x este probabilitatea tuturor rezultatelor asociate cu valoarea x :

$$P(X = x) = P(\{\omega \mid X(\omega) = x\})$$

Vom folosi prima notație, mai simplă.

Variabilă aleatoare: Exemplu

O urnă conține 10 bile colorate, numerotate de la 1 la 10. Primele 2 bile sunt albe, celelalte sunt negre. Universul este $\Omega = \{1, \dots, 10\}$. Bilele sunt extrase urmărind o distribuție uniformă, corespunzând la $P(\{i\}) = 1/10, \forall i$.

- *Variabila aleatoare* este culoarea bilei, $X : \Omega \rightarrow \{\text{alb}, \text{negru}\}$, definită prin $X(1) = X(2) = \text{alb}, X(3) = \dots = X(10) = \text{negru}$.
- Probabilitatea de a extrage o bilă albă este $P(X = \text{alb}) = P(\{1, 2\}) = 1/5$.

Variabilă aleatoare discretă

Dacă setul \mathcal{X} este discret, variabila aleatoare este și ea discretă.
Există două posibilități:

- \mathcal{X} conține un număr finit n de elemente
- \mathcal{X} conține un număr infinit de elemente ce pot fi indexate folosind numerele naturale $0, 1, 2, \dots$ (concept matematic: “numărabil”).

În acest caz, o reprezentare suficientă a distribuției de probabilitate este funcția de frecvență:

Definiție

Funcția de frecvență a variabilei X este lista probabilităților tuturor valorilor individuale $p(x_0), p(x_1), \dots$

Exemplu: Culoarea bilei este o variabilă aleatoare discretă, cu număr finit de valori (două), și funcția sa de frecvență este $p(\text{alb}) = 1/5$, $p(\text{negru}) = 4/5$.

Variabilă aleatoare continuă: Motivare

În exemplul legat de vreme, dorim să caracterizăm cantitatea precisă de precipitații $h \in [0, h_{\max}]$ unde h_{\max} este un maxim rezonabil. Presupunem că toate valorile h au probabilități egale. (Putem lua universul $\Omega = [0, h_{\max}]$ și variabila H egală cu funcția identitate, $H(\omega) = \omega$).

Dar există o infinitate continuă de valori în intervalul $[0, h_{\max}]$, așadar $P(h)$ trebuie să fie 0 pentru orice h ! (Altfel, cum probabilitățile sunt egale, $P([0, h_{\max}]) \rightarrow \infty$ și condiția 1 din definiția probabilității este invalidată.) Așadar, nu se poate defini o funcție de frecvență care să aibă sens.

Variabilă aleatoare continuă: Repartiție și densitate

Se pot defini probabilități utile doar pentru subseturi “continue”.

Definiții

Funcția de repartiție a unei variabile aleatoare continue $X : \Omega \rightarrow \mathbb{R}$ este:

$$F(x) := P(X \leq x) = P(\{\omega \mid X(\omega) \leq x\})$$

Din funcția de repartiție, definim **densitatea de probabilitate**:


$$f(x) := \frac{dF(x)}{dx}$$

Observații:


- Densitatea corespunde funcției de frecvență discrete.
- Pentru orice set $Z \subseteq \mathcal{X}$, $P(X \in Z) = \int_{x \in Z} f(x)$ (în cazul discret, $P(X \in Z) = \sum_{x \in Z} P(x)$).

Exemplu: Distribuția Gaussiană

Are formă similară cu funcțiile de bază Gaussiene, dar semnificație diferită.



Normal (Gaussian) pdf Distribution



Cumulative Distribution Function

$$f_G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

Parametri: media μ și varianța σ^2 (vor fi explicați mai târziu)

Distribuția Gaussiană intervine adeseori în natură: de ex., distribuția IQ-urilor într-o populație umană. Este numită de aceea și distribuția normală, și se notează $\mathcal{N}(\mu, \sigma^2)$.

Conținut

- 1 Regresia liniară
- 2 **Concepte de teoria probabilităților și statistică**
 - Baze matematice
 - Utilizarea practică în identificarea sistemelor
- 3 Analiza regresiei liniare

Probabilități în practică

În inginerie, se folosesc de obicei variabile aleatoare *numerice* și se lucrează direct cu funcțiile de frecvență $p(x)$ sau de densitate $f(x)$.

Universul Ω , rezultatele ω , și evenimentele A sunt rareori definite sau folosite explicit.

Valoarea medie

Definiție

$$E\{X\} = \begin{cases} \sum_{x \in \mathcal{X}} p(x)x & \text{pentru variabile aleatoare discrete} \\ \int_{\mathcal{X}} f(x)x & \text{pentru variabile aleatoare continue} \end{cases}$$

Intuiție: media tuturor valorilor, ponderate de probabilitatea lor; valoarea “așteptată” în avans, dată fiind distribuția de probabilitate.

Valoarea medie se mai numește și *valoare așteptată* sau *speranță*.

Exemple:

- Pentru un zar unde X este numărul fiecărei fețe,
 $E\{X\} = \frac{1}{6}1 + \frac{1}{6}2 + \dots + \frac{1}{6}6 = 7/2.$
- Dacă X are distribuție Gaussiană, $f(x) = f_G(x)$, atunci
 $E\{X\} = \mu.$

Valoarea medie a unei funcții

Considerăm o funcție $g : \mathcal{X} \rightarrow \mathbb{R}$ care depinde de variabila aleatoare X . Atunci, $g(X)$ este o și ea o variabilă aleatoare, cu valoarea medie:

$$E \{g(X)\} = \begin{cases} \sum_{x \in \mathcal{X}} p(x)g(x) & \text{discret} \\ \int_{\mathcal{X}} f(x)g(x) & \text{continuu} \end{cases}$$

Varianța

Definiție

$$\text{Var} \{X\} = \boxed{E \{(X - E \{X\})^2\}} = E \{X^2\} - (E \{X\})^2$$

Intuiție: cât de “răspândite” sunt valorile aleatoare în jurul valorii medii.

$$\begin{aligned} \text{Var} \{X\} &= \begin{cases} \sum_{x \in \mathcal{X}} p(x)(x - E \{X\})^2 & \text{discret} \\ \int_{x \in \mathcal{X}} f(x)(x - E \{X\})^2 & \text{continuu} \end{cases} \\ &= \begin{cases} \sum_{x \in \mathcal{X}} p(x)x^2 - (E \{X\})^2 & \text{discret} \\ \int_{x \in \mathcal{X}} f(x)x^2 - (E \{X\})^2 & \text{continuu} \end{cases} \end{aligned}$$

Exemple:

- Pentru un zar, $\text{Var} \{X\} = \frac{1}{6}1^2 + \frac{1}{6}2^2 + \dots + \frac{1}{6}6^2 - (7/2)^2 = 35/12$.
- Dacă X este distribuită cu densitatea $f(x) = f_G(x)$, Gaussiană, atunci $\text{Var} \{X\} = \sigma^2$.

Notăție

Vom nota generic $E\{X\} = \mu$ și $\text{Var}\{X\} = \sigma^2$.

Cantitatea $\sigma = \sqrt{\text{Var}\{X\}}$ se numește *abaterea standard*.

Covarianța

Definiție

$$\text{Cov} \{X, Y\} = \mathbb{E} \{(X - \mathbb{E} \{X\})(Y - \mathbb{E} \{Y\})\} = \mathbb{E} \{(X - \mu_X)(Y - \mu_Y)\}$$

unde μ_X, μ_Y sunt valorile medii ale celor două variabile.

Intuiție: cât de “aliniată” sunt schimbările celor două variabile (covarianța pozitivă dacă variabilele se schimbă în direcții similare, negativă dacă se schimbă în direcții opuse).

Observație: $\text{Var} \{X\} = \text{Cov} \{X, X\}$.

Variabile necorelate

Definiție

Variabilele aleatoare X și Y sunt **necorelate** dacă $\text{Cov} \{X, Y\} = 0$. Altfel, ele se numesc **corelate**.

Exemple:

- Nivelul de educație al unei persoane este corelat cu venitul său.
- Culoarea părului este necorelată cu venitul (sau ar trebui să fie, în cazul ideal).

Observații:

- Dacă X și Y sunt independente, atunci sunt și necorelate.
- Dar nu și invers! Putem avea variabile necorelate care sunt totuși dependente.

Vectori de variabile aleatoare

Considerăm vectorul $\mathbf{X} = [X_1, \dots, X_N]^\top$ unde fiecare X_i este o variabilă aleatoare cu valori reale continue. Acest vector are o *funcție de densitate comună* $f(\mathbf{x})$, cu $\mathbf{x} \in \mathbb{R}^N$.

Definiții

Valoarea medie și matricea de covarianță a lui \mathbf{X} :



$$E\{\mathbf{X}\} := [E\{X_1\}, \dots, E\{X_N\}]^\top = [\mu_1, \dots, \mu_N]^\top, \text{ notată } \boldsymbol{\mu} \in \mathbb{R}^N$$

$$\text{Cov}\{\mathbf{X}\} := \begin{bmatrix} \text{Cov}\{X_1, X_1\} & \text{Cov}\{X_1, X_2\} & \dots & \text{Cov}\{X_1, X_N\} \\ \text{Cov}\{X_2, X_1\} & \text{Cov}\{X_2, X_2\} & \dots & \text{Cov}\{X_2, X_N\} \\ \dots & \dots & \dots & \dots \\ \text{Cov}\{X_N, X_1\} & \text{Cov}\{X_N, X_2\} & \dots & \text{Cov}\{X_N, X_N\} \end{bmatrix}$$

$$= E\left\{(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^\top\right\}, \text{ notată } \Sigma \in \mathbb{R}^{N,N}$$

Observații: $\text{Cov}\{X_i, X_j\} = \text{Var}\{X_j\}$. De asemenea, $\text{Cov}\{X_i, X_j\} = \text{Cov}\{X_j, X_i\}$, deci matricea Σ este simetrică.

Exemplu: vector Gaussian



Densitatea comună Gaussiană a unui vector \mathbf{X} se poate scrie:

$$f(\mathbf{x}) = \frac{1}{(2\pi)^N \sqrt{\det(\Sigma)}} \exp\left(-(\mathbf{x} - \boldsymbol{\mu})\Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})^\top\right)$$

unde $\boldsymbol{\mu}$ este vectorul de valori medii și Σ matricea de covarianță (care trebuie să fie pozitiv definită, pentru ca $\det(\Sigma) > 0$ și Σ^{-1} să existe).


Proces stohastic

Definiție

Un **proces stohastic** \mathbf{X} este o secvență de variabile aleatoare $\mathbf{X} = (X_1, \dots, X_k, \dots, X_N)$.

Avem așadar de-a face tot cu un vector de variabile aleatoare, cu o structură specifică: fiecare index din vector este asociat unui pas discret de timp k .

În identificarea sistemelor, semnalele (intrări, ieșiri, perturbații etc.) vor fi adesea procese stohastice.



Zgomot alb de medie zero

Definiție

Un proces stohastic \mathbf{X} este **zgomot alb de medie zero** dacă:
 $\forall k, E\{X_k\} = 0$ (medie zero), și $\forall k, k' \neq k, \text{Cov}\{X_k, X_{k'}\} = 0$ (valorile la pași diferiți de timp sunt necorelate). În plus, varianța $\text{Var}\{X_k\}$ trebuie să fie finită $\forall k$.

Cu notație vectorială, aceste proprietăți se pot scrie compact: media $\boldsymbol{\mu} = E\{\mathbf{X}\} = \mathbf{0} \in \mathbb{R}^N$ și matricea de covarianță $\boldsymbol{\Sigma} = \text{Cov}\{\mathbf{X}\}$ este diagonală (cu diagonala formată din numere finite și pozitive).

În identificarea sistemelor, măsurătorile sunt adesea afectate de zgomote, și vom presupune câteodată că aceste zgomote sunt albe și de medie zero.

Proces staționar

Valorile unui semnal la diferite momente de timp pot fi corelate (de ex. când semnalul depinde de ieșirea unui sistem dinamic). Vom presupune însă câteodată că semnalele sunt staționare:

Definiție


Procesul stohastic \mathbf{X} este **staționar** dacă $\forall k, E\{X_k\} = \mu$, și $\forall k, k', \tau$, $Cov\{X_k, X_{k+\tau}\} = Cov\{X_{k'}, X_{k'+\tau}\}$.

Media este aceeași la fiecare pas, iar covarianța depinde doar de pozițiile relative ale pașilor de timp (și nu de pozițiile lor absolute).

Conținut

- 1 Regresia liniară
- 2 Concepte de teoria probabilităților și statistică
- 3 Analiza regresiei liniare**

Interpretare geometrică



- Spațiul tuturor vectorilor posibili de măsurători Y este un spațiu vectorial N -dimensional.
- Notăm coloana i a matricii Φ cu ψ_i , $i = 1, \dots, n$. Observație:

$$\psi_i = [\varphi_i(1), \dots, \varphi_i(N)]^T.$$
- Atunci, spațiul soluțiilor reprezentabile de către regresori este un subspațiu vectorial n -dimensional generat de către vectorii ψ_1, \dots, ψ_n . Fiecare soluție se obține alegând valori pentru parametrii $\theta_1, \dots, \theta_n$ și calculând combinația liniară $\sum_{i=1}^n \theta_i \psi_i$.
- Soluția în sensul celor mai mici pătrate \hat{Y} este proiecția vectorului măsurat Y pe acest subspațiu.

Analiză: Ipoteze

- 1 Există un vector ideal de parametri θ_0 pentru care datele satisfac

$$y(k) = \varphi^\top(k)\theta_0 + e(k)$$

- 2 Procesul stohastic $e(k)$ este *zgomot alb de medie zero*, cu varianța σ^2 la fiecare pas.

Intuiție: Ipotezele presupun că datele reale sunt reprezentabile de către modelul ales, admitând erori care se comportă bine din punct de vedere statistic.

Observație: Noile erori $e(k)$ au un întâeles diferit de valorile $\varepsilon(k)$ dinainte ($e(k)$ sunt erorile ideale date de parametrii ideali θ_0 , iar $\varepsilon(k)$ sunt erorile reale generate de parametrii θ găsiți în practică).

Analiză: Garanții

Teoremă

- 1 Soluția $\hat{\theta}$ a problemei de tip CMMP este un *estimator nedepășat* al lui θ_0 . Acest lucru înseamnă că: $E\{\hat{\theta}\} = \theta_0$ unde valoarea medie este calculată peste distribuția de probabilitate a datelor.
- 2 Matricea de covarianță a soluției este:


$$\text{Cov}\{\hat{\theta}\} = \sigma^2(\Phi^T \Phi)^{-1}$$

Intuiție: Prima parte spune că soluția are sens din punct de vedere statistic, iar partea a doua se poate interpreta ca un nivel de încredere în soluție. De exemplu, erori ideale mai mici $e(k)$ au o varianță σ^2 mai mică, ceea ce duce la covarianțe ale soluției mai mici – încredere mai mare că $\hat{\theta}$ este aproape de valoarea ideală θ_0 .

Observație: σ^2 este necunoscută, dar se poate estima cu formula $\frac{2V(\hat{\theta})}{N-n}$ (reamintim că $V(\hat{\theta}) = \frac{1}{2}[Y^T Y - Y^T \Phi(\Phi^T \Phi)^{-1} \Phi^T Y]$).

Alegerea modelului

Considerăm că dată fiind o complexitate a modelului (număr de parametri) n , putem genera regresori $\varphi(k)$ care fac modelul mai expresiv (de ex., funcții de bază pe o grilă mai fină). Ne așteptăm ca funcția obiectiv (CMMP) să se comporte în următorul fel:



Putem așadar crește treptat valoarea lui n până când eroarea V nu mai scade, sau eroarea V_{val} pe datele de validare începe să crească.

Observație: Dacă datele sunt afectate de zgomot, creșterea exagerată a lui n va duce la **supraantrenare**: performanțe bune pe datele de identificare, dar proaste pe date diferite. **Validarea pe un set separat de date** este esențială în practică!