

# Paraméterek hibájának becslése II.

Kormányos Andor

Komplex Rendszerek Fizikája Tanszék

2023. március 2.

# A paraméterek hibájának becslése más módon

A paraméterek hibájának becslése:

- ha a modell analitikusan ismer: Hesse-mátrix
- Egy jellegében más módszer: Monte Carlo módszerek
  - új “mérési eredményeket” szimulálunk és vizsgáljuk az illetett paraméterek stabilitását
  - Jackknife módszer
  - Bootstrapping

# Jackknife<sup>1</sup> módszer

Tekintsük a mérési pontokat, de minden lépésben hagyjunk ki egyet az illesztésből

- hagyjuk ki az  $i$ . pontot
- illesszük a modellt  $N - 1$  pontra
- legyen az illesztett paraméterek vektora  $\mathbf{a}_{(i)}$

Minden egyes mérési pontra megismételve összesen  $N$  különböző paramétervektort kapunk

- ezek átlaga lesz a becsült paramétervektor

$$\mathbf{a}_{\text{jack}} = \frac{1}{N} \sum_i \mathbf{a}_{(i)}$$

- az  $k$ -ik illesztett paraméter szórásnégyzete pedig

$$\sigma_{\text{jack},k}^2 = \frac{N-1}{N} \sum_i (a_{(i),k} - a_{\text{jack},k})^2$$

---

<sup>1</sup>jackknife = bicska

# Bootstrapping

Főbb lépések:

- jelöljük az eredeti,  $N$  db adatot tartalmazó adathalmazt  $\mathcal{D}_0$ -val
- a  $\mathcal{D}_0$  segítségével meghatározzuk a  $\mathbf{a}_{(0)}$  paramétereket
- $\mathcal{D}_0$  segítségével új, szintetikus adathalmazokat generálunk:  $\mathcal{D}_1^{(S)}, \mathcal{D}_2^{(S)}, \dots$  ("S": synthetic).
- minden  $\mathcal{D}_i^{(S)}$  segítségével kiszámoljuk az  $\mathbf{a}_{(i)}^{(s)}$  illetett paramétervektort
- $\mathbf{a}_{(i)}^{(s)}$  segítségével kapunk egy eloszlást az illetett paraméterekre
- az  $\mathbf{a}_{(i)}^{(s)}$  eloszlása  $\mathbf{a}_{(0)}$  körül jelzi, hogy mekkora hibával tudjuk  $\mathbf{a}_{(0)}$ -t meghatározni
- pl ha  $\mathbf{a}_{(i)}^{(s)}$  eloszlása  $\mathbf{a}_{(0)}$  körül nagyon keskeny, akkor kicsi  $\mathbf{a}_{(0)}$  hibája

Hogyan kapjuk meg  $\mathcal{D}_1^{(S)}, \mathcal{D}_2^{(S)}, \dots$ -t ?

- véletlenszerűen kiválasztunk  $N$  adatot  $\mathcal{D}_0$ -ból, úgy, hogy minden választás után “visszahelyezzük” a kiválasztott adatot  $\mathcal{D}_0$ -ba
- $\Rightarrow \mathcal{D}_1^{(S)}, \mathcal{D}_2^{(S)}, \dots$ -ben egyes adatok esetleg többször is szerepelhetnek

További részletek: *Numerical Recipes*

# Konfidencia tartomány


A bootstrapping-gal kapunk egy  $M$ -dimenziós eloszlást az  $\mathbf{a}$  paramétervektorra

- pl kétdimenziós  $\mathbf{a} = (a_0, a_1)$  esetén  $\mathbf{a}_{(i)}^{(s)} = (a_{(i)0}^{(s)}, a_{(i)1}^{(s)})$
- ezzel ki tudjuk számolni a  $\mathbf{a}_{(i)}^{(s)} - \mathbf{a}_{(0)}$  értékeket  $\Rightarrow$  egy-egy pont a síkban
- ezek után meghatározhatunk egy tartományt, amelyben bizonyos valószínűséggel található:
  - az egyik paraméter, pl  $a_{(0)0}$ , függetlenül a másiktól ( $a_{(0)1}$ )
  - a két paraméter együttesen ( $a_{(0)0}, a_{(0)1}$ )

**konfidencia tartomány:** az a tartomány, amely adott valószínűséggel (pl 95%) tartalmazza a paramétervektort vagy annak egy elemét

# Konfidencia tartomány

Kétdimenziós példa:



**Figure:** A szimulált paraméterértékek 68% van a függőleges illetve vízszintes vonalakkal jelzett intervallumban.  $a_{(0)0}$ ,  $a_{(0)1}$ : az eredeti adathalmaz segítségével kapott értékek . ábra: Numerical Recipes.

# További fontos kérdések

A paraméterek meghatározásával még nem ért véget a feladat:

- mekkora a meghatározott paraméterek hibája? ✓
- egyáltalán mennyire jó a modell? Hiába kicsi a meghatározott paraméterek hibája, ha rossz a modell, amit használunk