

# Adatmodellezés

## Lineáris függvényillesztés

Kormányos Andor

Komplex Rendszerek Fizikája Tanszék

2020. február 13.

# Elméleti modell

Fizikai törvény:

- Egy elmélet, valamilyen idea a világról
- *Matematikai összefüggéseket* adunk a mennyiségek között
- Az összefüggések *konstansokat*, *paramétereket* tartalmaznak

Példa: feldobott kő

$$F = m\ddot{x} = -g \cdot m$$

A differenciálegyenlet megoldása:

$$x(t) = -\frac{g}{2}t^2 + v_0t + x_0$$

# Elméleti modell

Fizikai törvény:

- Egy elmélet, valamilyen idea a világról
- *Matematikai összefüggéseket* adunk a mennyiségek között
- Az összefüggések *konstansokat*, *paramétereket* tartalmaznak

Példa: feldobott kő

$$F = m\ddot{x} = -g \cdot m$$

A differenciálegyenlet megoldása:

$$x(t) = -\frac{g}{2}t^2 + v_0t + x_0$$

Az elméleti modell bizonyos  $x_i$  *változók* és **a paramétervektor** függvényében *becslést ad* a mérhető fizikai mennyiségek értékeire.

Kísérlet:

- bizonyos *mennyiségeket mérünk*
- sokszor más mennyiségek függvényében, pl. az idő vagy hely

Problémák:

- a mért adatok sosem pontosan a valóságot adják vissza
- az adatokat torzítás, zaj és mérési hiba terheli

# Elméleti modell ellenőrzése

Kísérlet:

- bizonyos *mennyiségeket mérünk*
- sokszor más mennyiségek függvényében, pl. az idő vagy hely

Problémák:

- a mért adatok sosem pontosan a valóságot adják vissza
- az adatokat torzítás, zaj és mérési hiba terheli

Cél:

- ellenőrizni a fizikai törvény helyességét,
- megadni a konstansok és paraméterek értékét,
- továbbá megmondani, hogy a kísérlet alapján mennyire lehetünk abban bizonyosak, hogy a megalkotott törvény a valóságot írja le

# Melyik a legjobban illeszkedő modell?

A modell által adott  $y(x_i|\mathbf{a})$  becslések jól kell, hogy illeszkedjenek az  $y_i$  mért értékekre.

A mért  $y_i$  értékek:

- a mérésben mindig csak valamilyen  $P(y_i)$  valószínűséggel fordulnak elő
- a  $P(y_i)$  valószínűség eloszlása megismételt mérésekkel elvileg megbecsülhető
- a mérési hibáról magáról is felteszünk valamit, ez is a modell része
- ha  $P(y_i)$  normális eloszlásnak felel meg, akkor a mérési hibának a  $\sigma$  szórás vehető

# Melyik a legjobban illeszkedő modell?

A modell által adott  $y(x_i|\mathbf{a})$  becslések jól kell, hogy illeszkedjenek az  $y_i$  mért értékekre.

A mért  $y_i$  értékek:

- a mérésben mindig csak valamilyen  $P(y_i)$  valószínűséggel fordulnak elő
- a  $P(y_i)$  valószínűség eloszlása megismételt mérésekkel elvileg megbecsülhető
- a mérési hibáról magáról is felteszünk valamit, ez is a modell része
- ha  $P(y_i)$  normális eloszlásnak felel meg, akkor a mérési hibának a  $\sigma$  szórás vehető

Hogyan számszerűsíthető, hogy mennyire illeszkedik jól a modell a mérésekhez?

# A legkisebb négyzetek módszere

Definiáljuk az ún. *khi-négyzet költségfüggvényt*:

$$\chi^2 = \sum_i \frac{[y_i - y(x_i|\mathbf{a})]^2}{\sigma_i^2}$$

- ez fogja jellemezni az modell illeszkedésének jóságát
- általában a  $\sigma_i$  szórás (mérési hiba) minden mérési pontban különbözhet
- azok a mérési pontok, ahol  $\sigma_i$  nagy, kisebb súllyal szerepelnek



# A legkisebb négyzetek módszere

Definiáljuk az ún. *khi-négyzet költségfüggvényt*:

$$\chi^2 = \sum_i \frac{[y_i - y(x_i|\mathbf{a})]^2}{\sigma_i^2}$$

- ez fogja jellemezni az modell illeszkedésének jóságát
- általában a  $\sigma_i$  szórás (mérési hiba) minden mérési pontban különbözhet
- azok a mérési pontok, ahol  $\sigma_i$  nagy, kisebb súllyal szerepelnek

Miért pont a  $\chi^2$  költségfüggvényt használjuk?

- ha  $P(y_i)$  normális eloszlású  $\sigma_i$  szórással, akkor megmutatható, hogy a *maximum likelihood becslés* a  $\chi^2$  költségfüggvényhez vezet

Költségfüggvény:

$$\chi^2 = \sum_i \frac{[y_i - y(x_i|\mathbf{a})]^2}{\sigma_i^2}$$

*legkisebb négyzetek módszere*: a modell  $\mathbf{a}$  paramétereire úgy kaphatunk becslést, ha minimalizáljuk a  $\chi^2$ -t:

$$\arg \min_{\mathbf{a}} \sum_i \frac{[y_i - y(x_i|\mathbf{a})]^2}{\sigma_i^2} = ?$$

# A legkisebb négyzetek módszere

Megjegyzés: eddig a modellről nem tettünk fel semmit:

- lehet matematikai formula
- lehet algoritmus **a** bemenő paraméterekkel

# A legkisebb négyzetek módszere

Megjegyzés: eddig a modellről nem tettünk fel semmit:

- lehet matematikai formula
- lehet algoritmus  $\mathbf{a}$  bemenő paraméterekkel

Ha a model egy matematikai formula, akkor a minimumban:

$$\frac{\partial \chi^2(\mathbf{a})}{\partial a_k} = 0$$

vagyis a  $\chi^2$  minimalizációs feltétel:

$$0 = -2 \sum_i \frac{[y_i - y(x_i|\mathbf{a})]}{\sigma_i^2} \frac{\partial y(x_i|\dots a_k \dots)}{\partial a_k}$$

minden  $k$ -ra, ahol  $k$  a paraméterek számáig futó index.

# A legkisebb négyzetek módszere

Megjegyzés: eddig a modellről nem tettünk fel semmit:

- lehet matematikai formula
- lehet algoritmus  $\mathbf{a}$  bemenő paraméterekkel

Ha a model egy matematikai formula, akkor a minimumban:

$$\frac{\partial \chi^2(\mathbf{a})}{\partial a_k} = 0$$

vagyis a  $\chi^2$  minimalizációs feltétel:

$$0 = -2 \sum_i \frac{[y_i - y(x_i|\mathbf{a})]}{\sigma_i^2} \frac{\partial y(x_i|\dots a_k \dots)}{\partial a_k}$$

minden  $k$ -ra, ahol  $k$  a paraméterek számáig futó index.

Általános esetben a  $\chi^2$  bonyolult kifejezés.

- ha ismert is zárt alakban, analitikusan nehéz kezelni
- a parciális deriváltakat nem feltétlenül könnyű kiszámolni
- előfordulhat, hogy több lokális minimuma van, nehéz megtalálni az abszolút minimumot (ha létezik)

# A legkisebb négyzetek módszere

További megjegyzések:

- a számolás során  $x_i$ -ket végig ismertnek vettük, de általános esetben ezeknek is lehet hibájuk
- ha a modell egy algoritmus **a** bemenő paraméterekkel, akkor a minimum keresés is csak algoritmikusan kezelhető

# Példa: egyenes illesztése

Ismert:

- $x_1, x_2, \dots, x_i$  mérési pontok, ezeknek nincs hibájuk
- $y_1, y_2, \dots, y_i$  mért értékek
- $\sigma_1, \sigma_2, \dots, \sigma_i$  becsült hibák

Feladat: illesszünk a pontokra egyenest  $\chi^2$  módszerrel.

- modell:  $y(x) = y(x|a, b) = a + bx$

Az optimalizálandó költségfüggvény:

$$\chi^2 = \sum_i \left( \frac{y_i - y(x_i|a, b)}{\sigma_i} \right)^2 = \sum_i \left( \frac{y_i - a - bx_i}{\sigma_i} \right)^2$$

Milyen  $a$  és  $b$  mellett lesz  $\chi^2$  minimális?

## Példa: egyenes illesztése

A minimumhelyen a parciális deriváltak eltűnnek:

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_i \frac{y_i - a - bx_i}{\sigma_i^2}$$

$$0 = \frac{\partial \chi^2}{\partial b} = -2 \sum_i \frac{x_i(y_i - a - bx_i)}{\sigma_i^2}$$

Megjegyzések:

- ez egy lineáris egyenletrendszer  $a$ -ra és  $b$ -re
- biztos, hogy minimumhelyet találunk, mert  $\chi^2$  kifejezése pozitív kvadratikus.



# Példa: egyenes illesztése

Jelölések:

$$S = \sum_i \frac{1}{\sigma_i^2} \quad S_x = \sum_i \frac{x_i}{\sigma_i^2} \quad S_y = \sum_i \frac{y_i}{\sigma_i^2}$$

$$S_{xx} = \sum_i \frac{x_i^2}{\sigma_i^2} \quad S_{xy} = \sum_i \frac{x_i y_i}{\sigma_i^2}$$

## Példa: egyenes illesztése

Jelölések:

$$S = \sum_i \frac{1}{\sigma_i^2} \quad S_x = \sum_i \frac{x_i}{\sigma_i^2} \quad S_y = \sum_i \frac{y_i}{\sigma_i^2}$$

$$S_{xx} = \sum_i \frac{x_i^2}{\sigma_i^2} \quad S_{xy} = \sum_i \frac{x_i y_i}{\sigma_i^2}$$

Az új jelölésekkel az egyenletrendszer  $a$ -ra és  $b$ -re:

$$\begin{aligned} S a + S_x b &= S_y \\ S_x a + S_{xx} b &= S_{xy} \end{aligned}$$

## Példa: egyenes illesztése

Az egyenletrendszer determinánsa:

$$\Delta = S \cdot S_{xx} - S_x^2$$

Az egyenletrendszer megoldása:

$$a = \frac{S_{xx} \cdot S_y - S_x \cdot S_{xy}}{\Delta}$$

$$b = \frac{S \cdot S_{xy} - S_x \cdot S_y}{\Delta}$$

Egy mérés során becsúszhatnak rossz mérések

- ezeket nem jellemzi a mérési hiba
- valamilyen ritka, nem várt esemény hatására

A modellillesztés során a kilógó pontoktól érdemes valamilyen módon megszabadulni.

# Kilógó pontok




Figure: Lineáris függés, kilógó ponttal

# Kilógó pontok kezelése

Léteznek kifinomult becslő módszerek, ezek pl akkor alkalmazhatóak, ha ismert, hogy mi a mérési hiba eloszlása:  $\Rightarrow$  “**Robust estimation**”

# Kilógó pontok kezelése

Léteznek kifinomult becslő módszerek, ezek pl akkor alkalmazhatóak, ha ismert, hogy mi a mérési hiba eloszlása:  $\Rightarrow$  **“Robust estimation”**


Helyette egy egyszerű iteratív módszer:

- illesszük a modellt a mérési pontokra
- számoljuk ki a mérési pontoktól vett eltérések szórását
- dobjuk ki azokat a pontokat, amik  $3\sigma$ -n kívül esnek
- ismételjük meg az illesztést

A módszer kevés kilógó ponttal elbánik

- arra számítunk, hogy egy idő után nem lesz  $3\sigma$ -n kívüli pont

# Kilógó pontok





# Általános lineáris függvényillesztés

Az  $(x_i, y_i)$  adathalmazra szeretnénk illeszteni egy modellt. Mint az előzőekben, most is a

$$\chi^2 = \sum_{i=1}^N \left[ \frac{y_i - f(x_i|\mathbf{a})}{\sigma_i} \right]^2$$

összeget kell minimalizálni.

$f(x|\mathbf{a})$ -t a következő alakban keressük:

$$f(x|\mathbf{a}) = \sum_{j=1}^M a_j f_j(x),$$

ahol  $f_j(x)$  tetszőleges ún. **bázisfüggvény**, ami már nem függ az  $a_j$ -ktől.

A probléma lineáris, mert a teljes  $f(x|\mathbf{a})$  a különböző  $f_j(x)$ -ek lineárkombinációja.

# Általános lineáris függvényillesztés

A minimumot a

$$\frac{\partial \chi^2(a_j)}{\partial a_j} = 0$$

feltétel adja.

# Általános lineáris függvényillesztés

A minimumot a

$$\frac{\partial \chi^2(a_j)}{\partial a_j} = 0$$

feltétel adja.

Behelyettesítve  $f(x|\mathbf{a})$ -t:

$$\frac{\partial \chi^2(a_j)}{\partial a_j} = 2 \cdot \sum_{i=1}^N \left[ \frac{1}{\sigma_i^2} \cdot \left( \sum_{k=1}^M a_k f_k(x_i) - y_i \right) \cdot f_j(x_i) \right] = 0$$

Ez egy lineáris egyenletrendszer az  $a_k$  együtthatókra!

# A tervmátrix<sup>1</sup>

Az átláthatóság kedvéért vezessük be a következőket:

$$X_{ij} = \frac{f_j(x_i)}{\sigma_i} \qquad b_i = \frac{y_i}{\sigma_i}$$

$X_{ij}$  az úgynevezett *tervmátrix*:

- az  $M$  oszlopa a bázisfüggvényeknek felel meg
- az  $N$  sora a mérési pontoknak
- a mátrixelemek a  $j$ . bázisfüggvény  $x_i$  helyeken vett értékei

---

<sup>1</sup>design matrix

# A tervmátrix és a $b_i$ vektor felépítése

$$X_{ij} = \begin{pmatrix} \frac{f_1(x_1)}{\sigma_1} & \frac{f_2(x_1)}{\sigma_1} & \dots & \frac{f_M(x_1)}{\sigma_1} \\ \frac{f_1(x_2)}{\sigma_2} & \frac{f_2(x_2)}{\sigma_2} & \dots & \frac{f_M(x_2)}{\sigma_2} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \frac{f_1(x_N)}{\sigma_N} & \frac{f_2(x_N)}{\sigma_N} & \dots & \frac{f_M(x_N)}{\sigma_N} \end{pmatrix} \quad b_i = \begin{pmatrix} \frac{y_1}{\sigma_1} \\ \frac{y_2}{\sigma_2} \\ \vdots \\ \vdots \\ \frac{y_N}{\sigma_N} \end{pmatrix}$$

# A lineáris illesztés normálegyenletei

A parciális deriváltakra felírt egyenletek ezzel:

$$\sum_{i=1}^N \left[ \left( \sum_{k=1}^M a_k X_{ik} - b_i \right) \cdot X_{ij} \right] = 0,$$

ami indexes írásmóddal:

$$X_{ik} a_k X_{ij} = X_{ij} b_i$$

# A lineáris illesztés normálegyenletei

A parciális deriváltakra felírt egyenletek ezzel:

$$\sum_{i=1}^N \left[ \left( \sum_{k=1}^M a_k X_{ik} - b_i \right) \cdot X_{ij} \right] = 0,$$

ami indexes írásmóddal:

$$X_{ik} a_k X_{ij} = X_{ij} b_i$$

Mátrixos írásmódban:

$$\mathbf{X}^T \mathbf{X} \mathbf{a} = \mathbf{X}^T \mathbf{b},$$

ahol  $\mathbf{X}$  egy  $N \times M$ -es mátrix és  $\mathbf{a}$  tartalmazza az ismeretleneket.

# A lineáris illesztés normálegyenletei

A parciális deriváltakra felírt egyenletek ezzel:

$$\sum_{i=1}^N \left[ \left( \sum_{k=1}^M a_k X_{ik} - b_i \right) \cdot X_{ij} \right] = 0,$$

ami indexes írásmóddal:

$$X_{ik} a_k X_{ij} = X_{ij} b_i$$

Mátrixos írásmódban:

$$\mathbf{X}^T \mathbf{X} \mathbf{a} = \mathbf{X}^T \mathbf{b},$$

ahol  $\mathbf{X}$  egy  $N \times M$ -es mátrix és  $\mathbf{a}$  tartalmazza az ismeretleneket.

Ez egy  $M \times M$  lineáris egyenletrendszer: a legkisebb négyzetes illesztés **normálegyenletei**

Megoldás: pl Gauss-Jordan elimináció



# Többváltozós polinomillesztés

Ha az  $y_i$  mérési pontokat nem egyetlen  $x_i$  változó függvényében mérjük, hanem az  $x_i$  mérési pontok maguk is  $x_i^{(k)}$   $K$ -dimenziós vektorok

Ekkor definiáljuk a következő polinomot

$$f(\mathbf{x}|\mathbf{a}) = \sum_{k=1}^K \sum_{j=1}^M a_j^{(k)} [x^{(k)}]^{j-1},$$

- a probléma immár összesen  $M \cdot K$  ismeretlent fog tartalmazni
- ebben nincsenek vegyes tagok!
- a probléma ugyanúgy oldható meg, mint az előző

# 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

# Az illesztett paraméterek hibája

Elvégeztünk egy optimalizációs eljárást, ami a mérési adatok alapján megadott bizonyos  $\mathbf{a}$  modellparamétereket. Mennyire tekinthetők ezek a paraméterértékek pontosnak?

Két különböző dolgot vizsgálhatunk:

- *hibaterjedés*:  
a mérési hibából következően mekkora az illesztett paraméterek bizonytalansága
- *konfidencia intervallumok*:  
mennyire lehetünk biztosak abban, hogy a mérés alapján a “valódi” paramétereket sikerült megilleszteni?

# A paraméterek hibája egyenes illesztés esetén

Az  $y_i$  mért értékek hibája mennyire befolyásolja a kapott  $a$  és  $b$  paraméterek bizonytalanságát?

A hibaterjedés törvénye szerint egy függvény értékének hibája:

$$\sigma_f^2 = \sum_i \sigma_i^2 \left( \frac{\partial f}{\partial y_i} \right)^2$$

# A paraméterek hibája egyenes illesztés esetén

Az  $y_i$  mért értékek hibája mennyire befolyásolja a kapott  $a$  és  $b$  paraméterek bizonytalanságát?

A hibaterjedés törvénye szerint egy függvény értékének hibája:

$$\sigma_f^2 = \sum_i \sigma_i^2 \left( \frac{\partial f}{\partial y_i} \right)^2$$

A fentiekben explicit kifejezéseket kaptunk  $a$ -ra és  $b$ -re. Ezt felhasználva:

$$\frac{\partial a}{\partial y_i} = \frac{S_{xx} - S_x x_i}{\sigma_i^2 \Delta} \qquad \frac{\partial b}{\partial y_i} = \frac{S x_i - S_x}{\sigma_i^2 \Delta}$$

Behelyettesítve:

$$\sigma_a^2 = \frac{S_{xx}}{\Delta} \qquad \sigma_b^2 = \frac{S}{\Delta}$$

Kiszámolható a kovariancia is:  $\text{Cov}(a, b) = -S_x / \Delta$

# Asszimptotikus hiba

Általánosabb esetben, ha a modell analitikus alakja ismert, egy egyszerű módszer a paraméterek bizonytalanságára.

Tekintsük  $\chi^2$  viselkedését a minimum körül:

- $\chi^2(\mathbf{a})$  az  $\mathbf{a}_0$  minimum körül Taylor-sorba fejthető

$$\chi^2(\mathbf{a}) = \chi_0^2 + \left. \frac{\partial \chi^2}{\partial \mathbf{a}_k} \right|_{\mathbf{a}_0} (\mathbf{a} - \mathbf{a}_0) + (\mathbf{a} - \mathbf{a}_0)^T \left. \frac{1}{2} \frac{\partial^2 \chi^2}{\partial \mathbf{a}_k \partial \mathbf{a}_l} \right|_{\mathbf{a}_0} (\mathbf{a} - \mathbf{a}_0) + \dots$$

- a minimumhelyen az első derivált definíció szerint 0
- a második derivált pozitív definit, az *irányonkénti* nagysága jellemzi, hogy “mennyire stabil” a minimum
- bízunk benne, hogy a magasabb rendű tagok kicsik

$M$  változó esetén parciális második deriváltakat kell nézni: *Hesse-mátrix*

# A Hesse-mátrix

Egy többváltozós függvény “görbületét” jellemzi. Írjuk fel a  $\chi^2$ -re:

$$2 \cdot \alpha_{kl} = \frac{\partial^2 \chi^2}{\partial a_k \partial a_l}$$

Állítás:

- az  $\alpha_{kl}$  mátrix **inverze** jellemzi az illesztett paraméter standard hibáját
- az átlós elemekben  $\sigma_k^2$  jelenik meg
- a nem diagonális elemekben a  $k$ . és  $l$ . paraméterek kovarianciája

Normál eloszlású mérési hibák és lineáris illesztés esetén ez egzaktul belátható, nem lineáris függvényillesztés esetén csak (jó) közelítés.

# Egyenesillesztés hibája a Hesse-mátrix inverzével

A  $\chi^2$  parciális deriváltjait  $a$  és  $b$  szerint már kiszámoltuk a minimum keresésekor:

$$\frac{\partial \chi^2}{\partial a} = -2 \sum_i \frac{y_i - a - bx_i}{\sigma_i^2} \qquad \frac{\partial \chi^2}{\partial b} = -2 \sum_i \frac{x_i(y_i - a - bx_i)}{\sigma_i^2}$$

A második parciális deriváltakból alkotott Hesse-mátrix a korábbi jelölésekkel:

$$2 \cdot \alpha = \begin{pmatrix} \frac{\partial^2 \chi^2}{\partial a^2} & \frac{\partial^2 \chi^2}{\partial a \partial b} \\ \frac{\partial^2 \chi^2}{\partial b \partial a} & \frac{\partial^2 \chi^2}{\partial b^2} \end{pmatrix} = 2 \cdot \begin{pmatrix} S & S_x \\ S_x & S_{xx} \end{pmatrix}$$

Az  $\alpha$  mátrixot invertálva kapjuk a hibákat és a kovarianciákat:

$$\alpha^{-1} = \begin{pmatrix} \sigma_a^2 & \text{Cov}(a, b) \\ \text{Cov}(a, b) & \sigma_b^2 \end{pmatrix} = \frac{1}{\Delta} \begin{pmatrix} S_{xx} & -S_x \\ -S_x & S \end{pmatrix} \checkmark$$



# A Hesse-mátrix általános lineáris függvényillesztés esetén

Az egyszerűség kedvéért tegyük fel, hogy a mérés hibája állandó:  $\sigma_i = \sigma$

Az  $\mathbf{X}$  tervmátrix segítségével:  $(\mathbf{X}\mathbf{a} - \mathbf{y}/\sigma)_i = \sum_j X_{ij}a_j - y_i/\sigma$

# A Hesse-mátrix általános lineáris függvényillesztés esetén

Az egyszerűség kedvéért tegyük fel, hogy a mérés hibája állandó:  $\sigma_i = \sigma$

Az  $\mathbf{X}$  tervmátrix segítségével:  $(\mathbf{Xa} - \mathbf{y}/\sigma)_i = \sum_j X_{ij}a_j - y_i/\sigma$

Ennek segítségével a  $\chi^2$  és a szükséges deriváltak:

$$\begin{aligned}\chi^2 &= \sum_i \left[ \sum_j (X_{ij}a_j) - y_i/\sigma \right]^2 \\ \frac{\partial \chi^2}{\partial a_k} &= 2 \cdot \sum_i \left[ \sum_j X_{ik}X_{ij}a_j - X_{ik}y_i/\sigma \right] \\ \frac{\partial^2 \chi^2}{\partial a_k \partial a_l} &= 2 \cdot \sum_i [X_{ik}X_{il}]\end{aligned}$$

# Az illesztett paraméterek hibája

A második parciális deriváltakból álló Hesse-mátrix:

$$\alpha = \mathbf{X}^T \mathbf{X}$$

Ennek az inverze adja a kovarianciamátrixot:

$$\mathbf{C} = \alpha^{-1}$$

- az átlós elemek a varianciákat tartalmazzák:  $\sigma_k^2 = C_{kk}$
- a többi a kovarianciákat:  $\text{Cov}(k, l) = C_{kl}$

## Példa: parabola illesztése 5 pontra

Mivel öt megadott pont esetében a parabolaillesztés túlhatározott, a legkisebb négyzetek módszerét használjuk. Legyenek a mérési adatok a következők (valójában oszlopvektorok):

$$\mathbf{x} = \{ -2, -1, 0, 1, 2 \}$$
$$\mathbf{y} = \{ 5.1, 1.9, 1.1, 2.1, 4.9 \}$$

A mérési hiba az egyszerűség kedvéért  $\sigma_i = \sigma = 0.1$

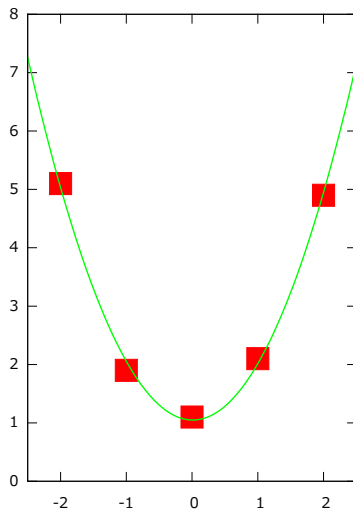
A modell három ismeretlenes:  $f(x) = a_0 + a_1x + a_2x^2$ , azaz  $f_1(x) = 1$ ,  $f_2(x) = x$  és  $f_3(x) = x^2$ . Ezzel:

$$\mathbf{X} = 10 \begin{bmatrix} 1 & -2 & 4 \\ 1 & -1 & 1 \\ 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{bmatrix} \quad \mathbf{X}^T \mathbf{X} = 10^2 \begin{bmatrix} 5 & 0 & 10 \\ 0 & 10 & 0 \\ 10 & 0 & 34 \end{bmatrix} \quad \mathbf{X}^T \frac{\mathbf{y}}{\sigma} = 10^2 \begin{bmatrix} 15.1 \\ -0.2 \\ 44.0 \end{bmatrix}$$

# A függvényillesztés eredménye

Az  $\mathbf{X}^T \mathbf{X} \mathbf{a} = \mathbf{X}^T \mathbf{y}$  egyenletet  $\mathbf{a}$ -ra megoldva:

$$\mathbf{a} = \begin{bmatrix} 1.049 \\ -0.020 \\ 0.986 \end{bmatrix}$$



# A konkrét példában

Az illesztett modell:

$$f(x) = 1.049 - 0.020x + 0.986x^2$$

A kovarianciamátrix:

$$(\mathbf{X}^T \mathbf{X})^{-1} = 10^{-2} \begin{bmatrix} 5 & 0 & 10 \\ 0 & 10 & 0 \\ 10 & 0 & 34 \end{bmatrix}^{-1} = 10^{-2} \begin{bmatrix} 0.49 & 0 & -0.14 \\ 0 & 0.10 & 0 \\ -0.14 & 0 & 0.07 \end{bmatrix}$$

Vagyis az egyes paraméterek szórása  
és kovarianciája:

$$\sigma(a_0) = 0.070$$

$$\sigma(a_1) = 0.032$$

$$\sigma(a_2) = 0.027$$

$$\text{cov}(a_0, a_2) = -0.014$$