

# Modell választás

Kormányos Andor

Komplex Rendszerek Fizikája Tanszék

2021. március 1.

# Mennyire jó a modell?<sup>1</sup>

Mikor jó egy modell?

- nem elég, hogy jól illeszkedik az adatokhoz (a  $J(\mathbf{a}_{fit}; x^{(i)}, y^{(i)})$  költségfüggvény értéke kicsi)
- emellett még az **általánosítási hibája** is kicsi
- vagyis új adatok esetén is prediktív

Mit jelent ez?

- detektálni akarjuk, hogy underfittinghez vagy overfittinghez vezet-e a modell
- sokszor a kettő között nem nyilvánvaló a határ
- egyszerű esetben a modell és az adatok ábrázolása segíthet
- többváltozós modell esetén az ábrázolás nem feltétlenül segít

---

<sup>1</sup>Andrew Ng, Coursera alapján

Első lépés:

- előfeltétel, hogy ne csak néhány adatpont legyen
- osszuk az adatokat kétfelé:
  - **training halmaz**  $\{(\mathbf{x}_{tr}^{(i)}, y_{tr}^{(i)})\}$ , pl eredeti adathalmaz 70%
  - **validációs halmaz**  $\{(\mathbf{x}_v^{(i)}, y_v^{(i)})\}$ , pl eredeti adathalmaz 30%
- az eredeti adathalmazból egyetlenes valószínűséggel válasszunk a training és a validációs halmazba!

# Modell kiértékelése

Első lépés:

- előfeltétel, hogy ne csak néhány adatpont legyen
- osszuk az adatokat kétfelé:
  - **training halmaz**  $\{(\mathbf{x}_{tr}^{(i)}, y_{tr}^{(i)})\}$ , pl eredeti adathalmaz 70%
  - **validációs halmaz**  $\{(\mathbf{x}_v^{(i)}, y_v^{(i)})\}$ , pl eredeti adathalmaz 30%
- az eredeti adathalmazból egyetlenes valószínűséggel válasszunk a training és a validációs halmazba!

Második lépés:

- a  $\{(\mathbf{x}_{tr}^{(i)}, y_{tr}^{(i)})\}$  segítségével kiszámolt  $J(\mathbf{a}; \mathbf{x}^{(i)}, y^{(i)})$  minimalizáljuk
- így kapjuk az  $\mathbf{a}_{fit}$  paramétereket

# Modell kiértékelése

Első lépés:

- előfeltétel, hogy ne csak néhány adatpont legyen
- osszuk az adatokat kétfelé:
  - **training halmaz**  $\{(\mathbf{x}_{tr}^{(i)}, y_{tr}^{(i)})\}$ , pl eredeti adathalmaz 70%
  - **validációs halmaz**  $\{(\mathbf{x}_v^{(i)}, y_v^{(i)})\}$ , pl eredeti adathalmaz 30%
- az eredeti adathalmazból egyetlenes valószínűséggel válasszunk a training és a validációs halmazba!

Második lépés:

- a  $\{(\mathbf{x}_{tr}^{(i)}, y_{tr}^{(i)})\}$  segítségével kiszámolt  $J(\mathbf{a}; \mathbf{x}^{(i)}, y^{(i)})$  minimalizáljuk
- így kapjuk az  $\mathbf{a}_{fit}$  paramétereket

Harmadik lépés:

- a  $\{(\mathbf{x}_v^{(i)}, y_v^{(i)})\}$  és az előző lépésben kapott  $\mathbf{a}_{fit}$  felhasználásával számoljuk ki a  $J(\mathbf{a}_{fit}; \mathbf{x}_v^{(i)}, y_v^{(i)})$
- ez az ún **validációs hiba**

# Hogyan válasszunk modellt?

- olyan modellt szeretnénk, amely prediktív lehet új adatokra is
- vagyis kicsi az általánosítási hibája
- kvantifikáljuk az általánosítási hibát

Egy egyszerű példa: hányad fokú polinomot tartalmazó modellt válasszunk?

$$h_1(\mathbf{a}^{(1)}; x) = a_{10} + a_{11}x$$

$$h_2(\mathbf{a}^{(2)}; x) = a_{20} + a_{21}x + a_{22}x^2$$

$$h_3(\mathbf{a}^{(3)}; x) = a_{30} + a_{31}x + a_{32}x^2 + a_{33}x^3$$

$$h_4(\mathbf{a}^{(4)}; x) = a_{40} + a_{41}x + a_{42}x^2 + a_{43}x^3 + a_{44}x^4$$

# Hogyan válasszunk modellt?

Egy egyszerű eljárás, amely


- nem csak lineáris illesztés esetén alkalmazható
- nem függ a költségfüggvény konkrét alakjától (nem csak legkisebb négyzetek esetén)

Lépések:

- a training set  $\{(x_{tr}^{(i)}, y_{tr}^{(i)})\}$  segítségével meghatározzuk az illesztett paramétervektorokat minden modellre:  $\mathbf{a}_{fit}^{(1)}, \mathbf{a}_{fit}^{(2)}, \mathbf{a}_{fit}^{(3)}, \mathbf{a}_{fit}^{(4)}$
- kiszámoljuk a költségfüggvényt minden modellre a validációs halmaz  $\{(x_v^{(i)}, y_v^{(i)})\}$  segítségével:  $J(\mathbf{a}_{fit}^{(j)}; x_v^{(i)}, y_v^{(i)})$
- azt a modellt választjuk, amelyre a  $J(\mathbf{a}_{fit}^{(j)}; x_v^{(i)}, y_v^{(i)})$  a legkisebb

# Hogyan válasszunk modellt?

Ha a különböző modellek az illesztett polinom fokában különböznek:



**Figure:** A költségfüggvény viselkedése különböző modellek esetén. Jelölés:

$$J_{tr}(\mathbf{a}_{fit}) = J(\mathbf{a}_{fit}^{(j)}; \mathbf{x}_{test}^{(i)}, y_{test}^{(i)}), \quad J_v(\mathbf{a}_{fit}) = J(\mathbf{a}_{fit}^{(j)}; \mathbf{x}_v^{(i)}, y_v^{(i)})$$



# Mekkora a választott modell általánosítási hibája?

- ha a  $k$ -ik modellt választottuk, akkor azt gondolhatjuk, hogy a  $J(\mathbf{a}_{fit}^{(k)}; \mathbf{x}_v^{(i)}, y_v^{(i)})$  jellemzi a hibát
- szigorúan véve ez nem egy jó mértéke az általánosítási hibának
- mivel a  $\{(x_v^{(i)}, y_v^{(i)})\}$ -t használtuk a modell kiválasztására, ezért ezen az adathalmazon számolt  $J(\mathbf{a}_{fit}^{(k)}; x_v^{(i)}, y_v^{(i)})$  valószínűleg alulbecsüli az általánosítási hibát

# Mekkora a választott modell általánosítási hibája?

- ha a  $k$ -ik modellt választottuk, akkor azt gondolhatjuk, hogy a  $J(\mathbf{a}_{fit}^{(k)}; \mathbf{x}_v^{(i)}, y_v^{(i)})$  jellemzi a hibát
- szigorúan véve ez nem egy jó mértéke az általánosítási hibának
- mivel a  $\{(x_v^{(i)}, y_v^{(i)})\}$ -t használtuk a modell kiválasztására, ezért ezen az adathalmazon számolt  $J(\mathbf{a}_{fit}^{(k)}; x_v^{(i)}, y_v^{(i)})$  valószínűleg alulbecsüli az általánosítási hibát

## Korrekt eljárás:

- három adathalmaz képzése az eredeti adatokból:
  - training adatok  $\{(x_{tr}^{(i)}, y_{tr}^{(i)})\}$  (60%)
  - validációs adatok  $\{(x_v^{(i)}, y_v^{(i)})\}$  (20%)
  - teszt adatok  $\{(x_{test}^{(i)}, y_{test}^{(i)})\}$  (20%)
- $\{(x_{tr}^{(i)}, y_{tr}^{(i)})\}$ :  $\mathbf{a}_{fit}^{(j)}$  fit meghatározása minden modellre
- $\{(x_v^{(i)}, y_v^{(i)})\}$ : modell kiválasztása  $J(\mathbf{a}_{fit}^{(j)}; x_v^{(i)}, y_v^{(i)})$  számolásával
- $\{(x_{test}^{(i)}, y_{test}^{(i)})\}$ : a kiválasztott modell  $\mathbf{a}_{fit}^{(k)}$  paramétereivel kiszámoljuk a  $J(\mathbf{a}_{fit}^{(k)}; x_{test}^{(i)}, y_{test}^{(i)})$  **általánosítási hibát**