

# Modell illeszkedés I.

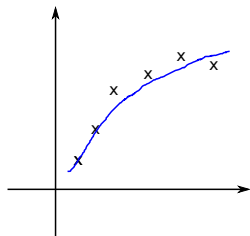
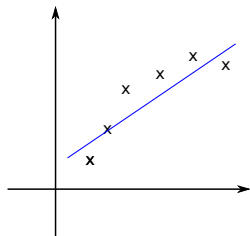
Kormányos Andor

Komplex Rendszerek Fizikája Tanszék

2022. február 7.

# Mennyire illeszkedik jól a modell?<sup>1</sup>

Van egy adathalmazunk, amelyre illesztünk egy modellt

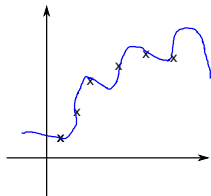


- lineáris illesztés:  $h(x; \mathbf{a}) = a_0 + a_1x$
- a modell érezhetően túl egyszerű
- a  $J(\mathbf{a}_{fit}; x^{(i)}, y^{(i)})$  költségfüggvény értéke viszonylag nagy marad a minimalizálás után is
- **underfitting (high bias)**
  
- e.g.: kvadratikus illesztés:  
 $h(x; \mathbf{a}) = a_0 + a_1x + a_2x^2$
- jobb, mint a lineáris modell
- a  $J(\mathbf{a}_{fit}; x^{(i)}, y^{(i)})$  költségfüggvény értéke lecsökkent

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

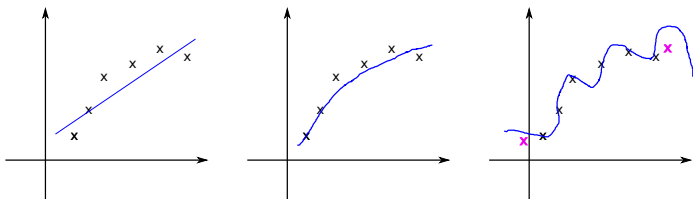
# Mennyire illeszkedik jól a modell?

Van egy adathalmazunk, amelyre illesztünk egy modellt



- e.g. magasrendű polinom:  
 $a_0 + a_1x + a_2x^2 + a_3x^3 + a_4x^4 + a_5x^5$
- a modell átmegy szinte minden mérési ponton
- a  $J(\mathbf{a}_{fit}; x^{(i)}, y^{(i)})$  költségfüggvény értéke nagyon kicsi
- viszont a modell nagy oszcillációkat mutat
- elképzelhető, hogy olyan mintázatot próbálunk fittelni, ami valójában nincs jelen az adatokban
- **overfitting (high variance)**

# Mennyire illeszkedik jól a modell?



- $J(\mathbf{a}_{fit}; x^{(i)}, y^{(i)})$  költségfüggvény alacsony értéke nem az egyedüli fokmérője annak, hogy egy modell mennyire jó
- **általánosítási hiba (generalization error)** mekkora a modell várható hibája egy olyan adat esetén, amely nem szerepelt az eredeti, illesztésre használt adatsorban

Az illesztést befolyásolhatja:

- zajos mérési adatok:
  - $y^{(i)}$ -k  $\sigma_i$  hibája nagy
  - nagy lesz a modellben szereplő illesztett paraméterek hibája
- modell választás
  - underfitting, overfitting
  - nagy lehet az általánosítási hiba

Cél: olyan a modell választása, amelynek

- kicsi az általánosítási hibája
- és minél pontosabban meghatározni a modell paramétereit