



# Gépi tanulás a gyakorlatban

## Lineáris regresszió



# Lineáris Regresszió

- Legyen adott egy tanuló adatbázis:


Rendelkezésünkre áll egy olyan előfeldolgozott adathalmaz, aminek sorai az egyes ingatlanokat írják le. Az adathalmaznak két oszlopa van.

- Az első az *ingatlanok területét*,
- a második az *ingatlanok árait tartalmazza*.

*Felügyelt* módszer, *valós* segéd információval → regressziós feladat

Szeretnénk *előrejelezni ingatlanok árait*.

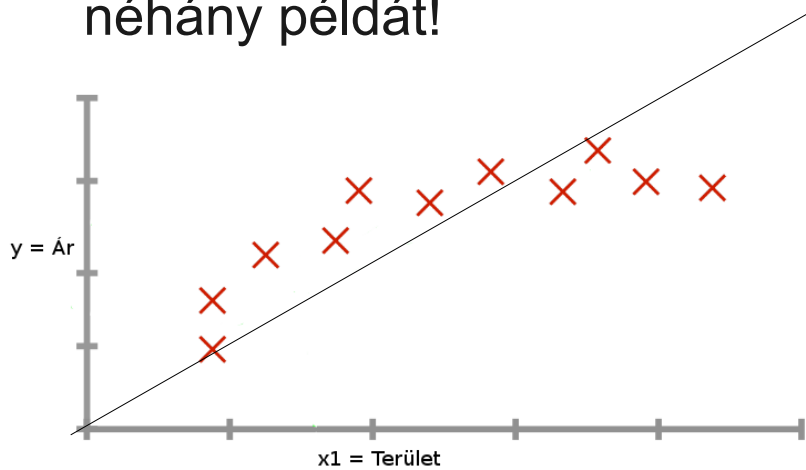
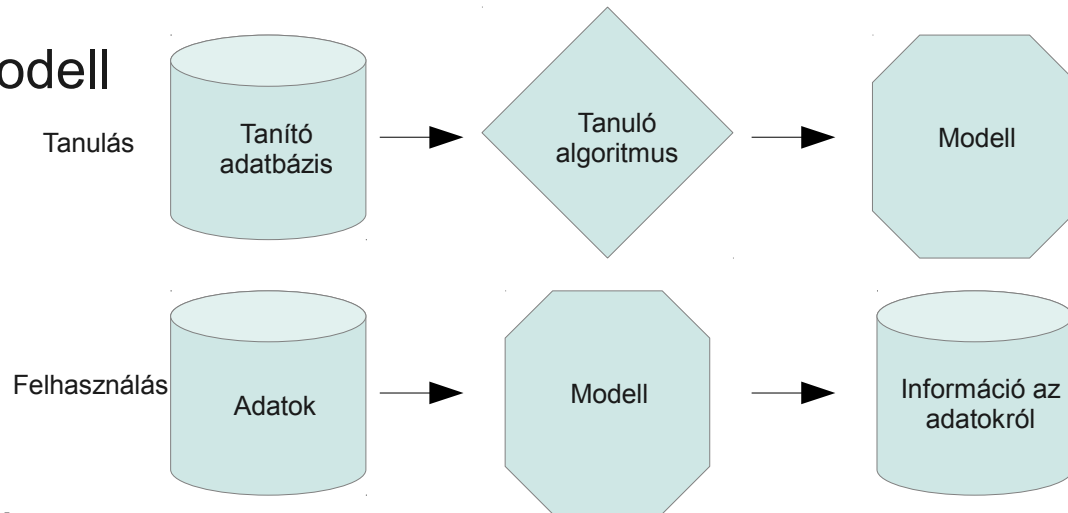
- Tanuló példák száma:  $m=11$
- Dimenzió:  $d=1$  (bemeneti pontok dimenziója)
- Jellemzők: 1 db, terület ( $x_1$ )
- Címkék: valós érték (ár) → valós érték → felügyelt regresszió ( $y$ )
- Modell: egyenes ( $h$ )



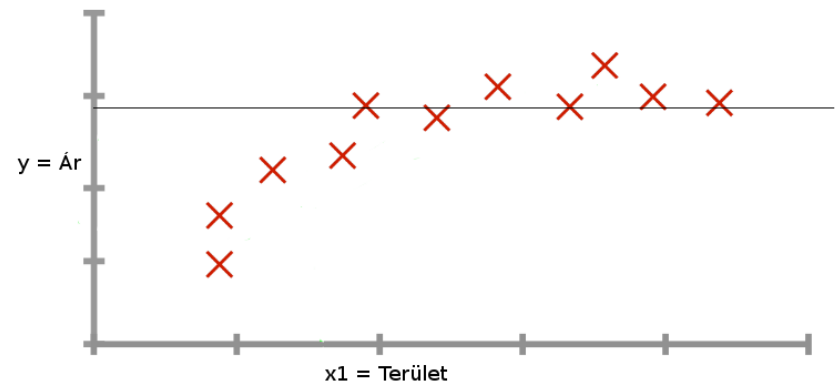


# Lineáris regresszió

- Tanulás során: tanuló adatbázis  $\rightarrow$  modell ( $h$ )
- Hogyan reprezentáljuk  $h$ -t?
- $h(x)=a*x+b$   $\leftarrow$   $a$  és  $b$  paraméterek
- Tanulás során:  $a$  és  $b$  paraméterek meghatározása
- Hogyan válasszuk  $a$ -t és  $b$ -t? Nézzünk néhány példát!



$$a=1, b=0$$



$$a=0, b=1.2m$$




# Lineáris regresszió

- Hogyan válasszuk  $a$ -t és  $b$ -t (h modell paramétereit)?
- Ötlet: válasszuk úgy  $a$ -t és  $b$ -t, hogy a tanuló példákon  $h(x)$  *közel kerüljön*  $y$ -hoz, minden  $(x,y)$  tanító példára

- Költség függvény:  $J(a, b) = \frac{1}{2m} \sum_{i=1}^m (h_{a,b}(x^{(i)}) - y^{(i)})^2$  , ahol

$$h_{a,b}(x^{(i)}) = h(x^{(i)}) = a \cdot x^{(i)} + b$$





Tanulás:  
*minimalizáljuk*  
 $J(a,b)$ -t a tanuló  
adatbázison és a  
tanult modell legyen  
a minimum hely



# Lineáris regresszió

- Értsük meg a költség függvényt!
  - a modell:  $h_{a,b}(x)$  a **példák** (nem csak tanító példák!) függvénye, adott paraméterek esetén  $\rightarrow$  területhez rendel becsült eladási árat
  - a költség függvény:  $J(a,b)$  a **paraméterek** függvénye, adott tanuló halmaz esetén  $\rightarrow$  megmondja, hogy az adott paraméterű modell mennyire jól illeszkedik a tanuló halmazra (hiba függvény)
- Egyszerűsítés: legyen  $h(x) = a \cdot x$   $\leftarrow$  (hagyjuk el a  $b$  paramétert egy időre)  $\rightarrow$  Origón átmenő egyeneseket tekintünk csak!





# Lineáris regresszió

- Értsük meg a költség függvényt!
- Előzőek alapján sejtés:  $J(a)$  parabolikus függvény
- Valóban:

$$J(a) = \frac{1}{2m} \sum_{i=1}^m (h_a(x^{(i)}) - y^{(i)})^2 = \frac{1}{2m} \sum_{i=1}^m (a \cdot x^{(i)} - y^{(i)})^2 =$$

$$= \frac{1}{2m} \sum_{i=1}^m ((x^{(i)})^2 \cdot a^2 - 2x^{(i)}y^{(i)} \cdot a + (y^{(i)})^2) =$$

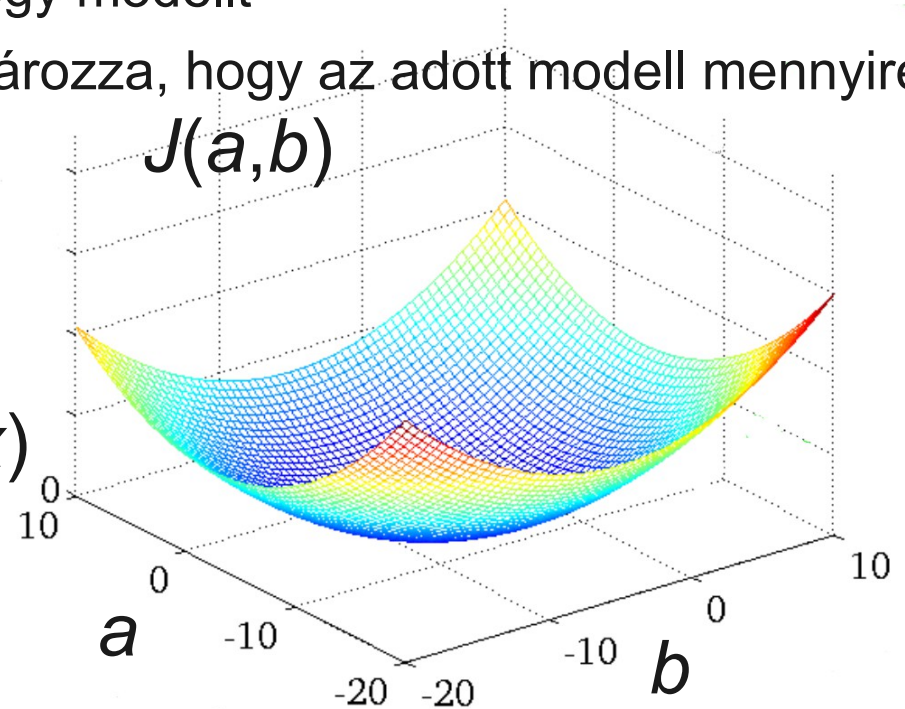
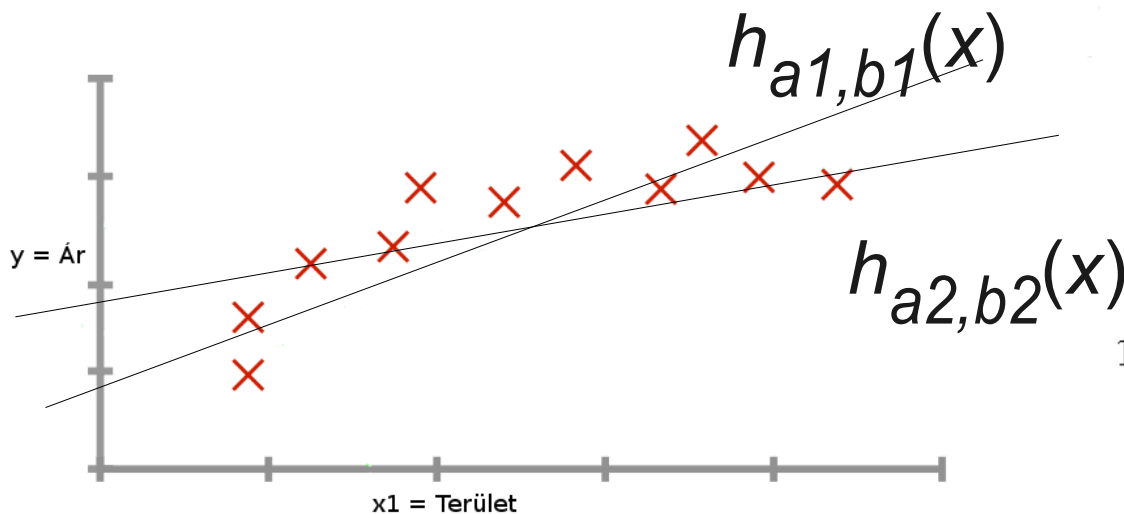
$$= \underbrace{\frac{1}{2m} \sum_{i=1}^m (x^{(i)})^2 \cdot a^2}_A - \underbrace{\frac{1}{m} \sum_{i=1}^m x^{(i)}y^{(i)} \cdot a}_B + \underbrace{\frac{1}{2m} \sum_{i=1}^m (y^{(i)})^2}_C =$$

$$= A \cdot a^2 - B \cdot a + C$$



# Lineáris regresszió

- Az egyszerűsítés elvetésével is hasonló a helyzet:
  - a modell:  $h_{a,b}(x) = a \cdot x + b$  → nem csak az origón átmenő egyenesek → két paraméter →
  - a költség függvény:  $J(a,b)$  két **változós** függvény → szintén parabolikus
- A költség függvény:
  - minden egyes alappontja meghatároz egy modellt
  - a hozzá tartozó függvény érték meghatározza, hogy az adott modell mennyire „jó” a tanuló halmazon







# Lineáris regresszió

- A költség függvény:

- minden egyes alappontja meghatároz egy modellt
- a hozzá tartozó függvény érték meghatározza, hogy az adott modell mennyire „jó” a tanuló halmazon

- Tanulás-Modell felhasználás:

- Adott egy tanuló adatbázis:  $\mathcal{S} = \{(x_1, y_1), \dots, (x_m, y_m)\} \subseteq \mathbb{R} \times \mathbb{R}$

- és néhány paraméter:  $\theta = (a, b)$

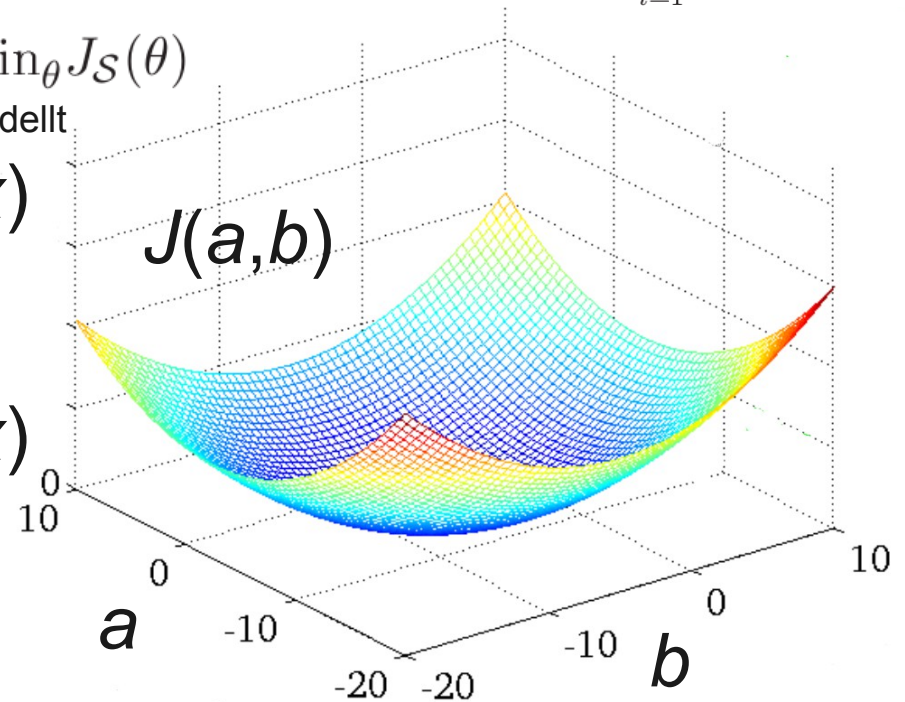

- a modell a példák függvénye:  $h_\theta(x) = h_{a,b}(x) = a \cdot x + b$

- definiáljunk egy költség függvényt a paraméterek függvényében:  $J_S(\theta) = J_S(a, b) = J(a, b) = \frac{1}{2m} \sum_{i=1}^m (h_{a,b}(x^{(i)}) - y^{(i)})^2$

- Tanulás: optimalizáljuk a költség függvényt:  $\theta^* = \operatorname{argmin}_\theta J_S(\theta)$

- Felhasználás: használjuk az optimális paraméterekkel a modellt

$$h_{\theta^*}(x) = h_{a^*,b^*}(x) = a^* \cdot x + b^*$$







# Lineáris regresszió

1. Kvíz: Lehet-e negatív a lineáris regresszió költségfüggvényének az értéke?

1. Igen, ha a tanító halmaz minden  $(x,y)$  elemére  $h(x) < y$
2. Igen, ha feltesszük, hogy felügyelt tanulásról van szó
3. Nem

2. Kvíz: Lehet-e olyan paraméter párt mondani, amely mellett az egy dimenziós lineáris regresszió költségfüggvény értéke 0 (adott tanító halmazon)?

1. Igen,  $(a=1, b=1)$
2. Nem
3. Igen,  $(a=1, b=0)$
4. Igen,  $(a=0, b=0)$



# Lineáris regresszió

- Tanulás: opt. a költség függvényt:  $\theta^* = \operatorname{argmin}_{\theta} J_{\mathcal{S}}(\theta)$
- Hogyan határozzuk meg a költség függvény minimumát?
  - Kimerítő keresés → nagy műveletigény főleg nagyobb dimenzióban
  - Hegymászó algoritmus → a lineáris regresszió esetén túl általános
    - Algoritmus:
      - $\theta_0 =$  véletlen,  $i=0$
      - Amíg nem konvergált
        - $\theta_{i+1} := \theta_i$  környezetéből egy olyan véletlen pont
        - Ha  $J(\theta_{i+1}) \geq J(\theta_i)$  akkor  $\theta_{i+1} = \theta_i$
  - Gradiens módszer (Gradient descent) → jó választás, hiszen a költség függvény parabolikus → Nézzük meg részletesebben!



# Gradiens módszer

- Hasonlít a Hegymászó algoritmushoz, csak a szomszéd választás irányított.
- Algoritmus:  
 $\theta_0 := \text{véletlen}, i = 0$   
**repeat** until convergence {  
     $\theta_{i+1} = \theta_i - \alpha \frac{\partial}{\partial \theta_i} J(\theta_i)$   
}
- Azaz a gradiens irányával ellentétes irányba (kivonás) lépünk el
- A lépés hosszát Alpha határozza meg

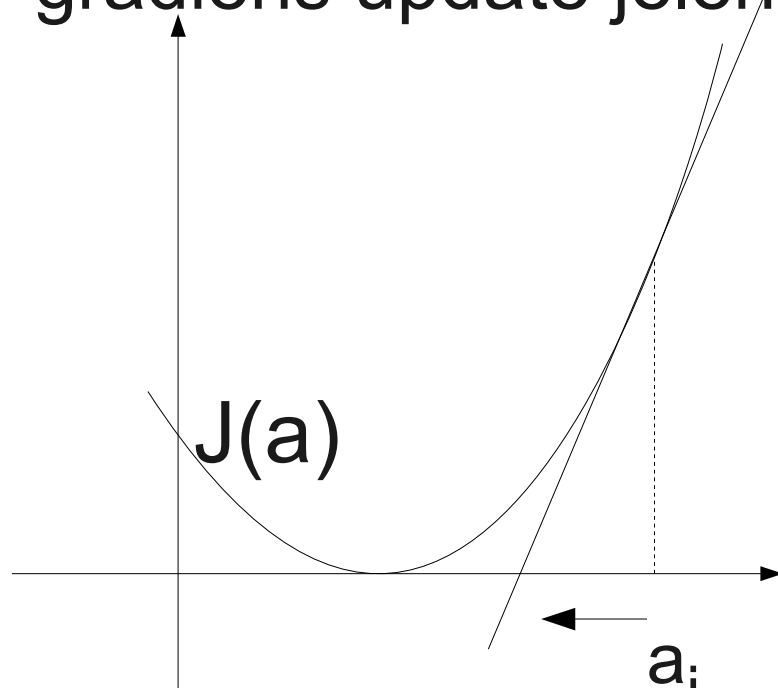


# Gradiens módszer

- Interpretáció: Tegyük fel ismét, hogy  $h(x)=a \cdot x$ , és így

$$J(a) = \frac{1}{2m} \sum_{i=1}^m (a \cdot x^{(i)} - y^{(i)})^2$$
 egy dimenziós parabola

- Tegyük fel továbbá, hogy eljutottunk  $a_i$  pontba, ekkor a gradiens update jelentése a következő




$$a_{i+1} = a_i - \alpha \frac{\partial}{\partial \theta_i} J(a_i)$$

- A derivált függvény értéke (gradiens) az  $a_i$  helyen megadja az  $a_i$  pontba húzott érintő meredekségét
- A gradiens update ebben az esetben a minimum felé tolja  $a_{i+1}$ -et (Alpha > 0)



# Gradiens módszer

- Gradiens módszer tulajdonságai:
  - Általánosságban – megfelelő Alpha választásával – lokális optimum megtalálását biztosítja
  - Parabolikus (több dimenzióban kvadratikus függvények esetén) egy optimum van → lokális = globális
- Tanuló konstans (learning rate, Alpha szerepe)
  - Lépés méretét határozza meg
    - Túl kicsi → lassú konvergencia
    - Túl nagy → túl léphet a az optimumon (akár divergálhat is)





# Gradiens módszer

3. Kvíz: Parabolikus (kvadratikus) költségfüggvény esetén az gradiens módszer megtalálja a globális optimumot

1. Igen, feltéve, hogy a lépésköz (Alpha) paraméter megfelelően van beállítva
2. Nem, divergál
3. Igen, mindig
4. Igen, feltéve, hogy a költségfüggvény folytonosan differenciálható



# Gradiens módszer – Lineáris regresszió esetén

- Tegyük fel ismét, hogy a  $J(a, b) = \frac{1}{2m} \sum_{i=1}^m (a \cdot x^{(i)} + b - y^{(i)})^2$  a két változós optimalizálendő költségfüggvényünk
- Ahhoz, hogy a Gradiens módszer alkalmazható legyen le kell azt deriválnunk minden változója szerint (parciális deriválás)

$\theta_0 :=$  véletlen,  $i = 0$   
**repeat** until convergence {  
     $\theta_{i+1} = \theta_i - \alpha \frac{\partial}{\partial \theta_i} J(\theta_i)$   
}

$(a_0, b_0) :=$  véletlen,  $i = 0$   
**repeat** until convergence {  
     $a_{i+1} = a_i - \alpha \frac{1}{m} \sum_{i=1}^m (a \cdot x^{(i)} + b - y^{(i)}) \cdot x^{(i)}$   
     $b_{i+1} = b_i - \alpha \frac{1}{m} \sum_{i=1}^m (a \cdot x^{(i)} + b - y^{(i)})$   
}





# Gradiens módszer

- Annak függvényében, hogy milyen költség függvényt alkalmazunk eltérő módszerekről beszélhetünk:
  - Eddig a teljes tanító halmazt használtuk hiba (költség mérésére) → batch mód  $J_S(a, b) = \frac{1}{2m} \sum_{i=1}^m (h_{a,b}(x^{(i)}) - y^{(i)})^2$
  - Tanító halmaz egy véletlen részhalmazán történő mérés → mini batch mód  $\mathcal{Q} \subseteq \mathcal{S} \quad J_{\mathcal{Q}}(a, b) = \frac{1}{2|\mathcal{Q}|} \sum_{(x^{(i)}, y^{(i)}) \in \mathcal{Q}} (h_{a,b}(x^{(i)}) - y^{(i)})^2$
  - Egy példán történő mérés → stochastic mód

$$(x^{(i)}, y^{(i)}) \in \mathcal{S} \quad J_{(x^{(i)}, y^{(i)})}(a, b) = \frac{1}{2} (h_{a,b}(x^{(i)}) - y^{(i)})^2$$