



# Gépi tanulás a gyakorlatban

Logisztikus regresszió,  
túltanulás



# Osztályozás – Logisztikus Regresszió

- Legyen adott egy osztályozási adatbázis:

- $x$  – tumor mérete,
- $y$  – rosszindulatú-e a daganat (Igen/Nem).

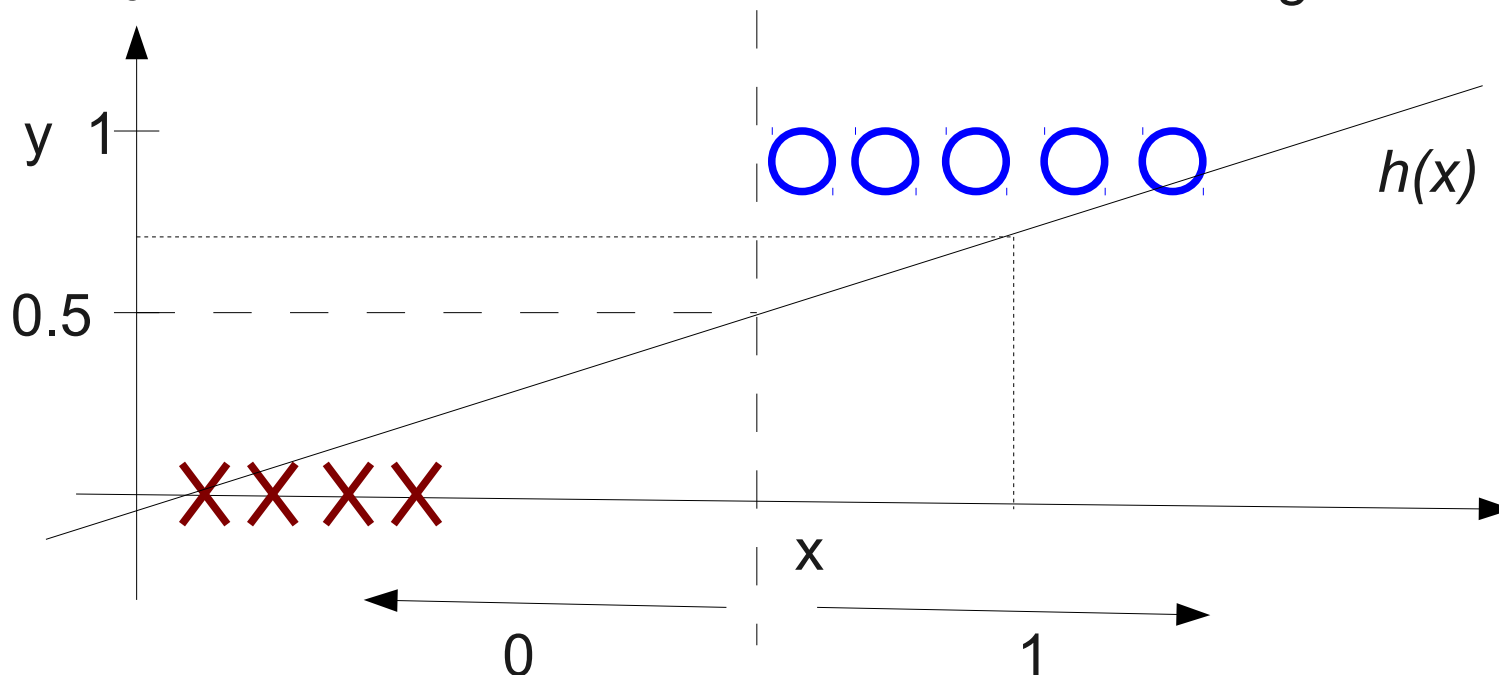
Szeretnénk a rosszindulatúságot előrejelezni.

## Ötlet:

- Tanuljunk lineáris modell-t a szeperációra
- Alkalmazzuk a  $0.5 < h(x) \rightarrow 1$ , különben 0 szabályt

## Probléma:

- Ebben az esetben  $h(x)$  tetszőleges lehet...






# Osztályozás – Logisztikus Regresszió

- Képezzük le a  $h(x)$  kimenetet a  $[0;1]$  intervallumba egy  $g(x)$  függvény segítségével, ami:
  - 0.5-öt ad, ha az „egyenesen vagyunk” (decision boundary),
  - $h(x) < 0.5$ -nél ha „alatta”,
  - $h(x) > 0.5$ -nél pedig „felette”.
  - Monoton és (parciálisan) deriválható (Azért, hogy egy alkalmas költségfüggvény választása esetén tudjuk alkalmazni a gradiens módszert.)
- Jelölt  $g(x)$  szerepére: Sigmoid vagy Logisztikus függvény:

$$g(z) = \frac{1}{1 + e^{-z}}$$

$$h_{\Theta}^{\text{logreg}}(x) = g(h_{\Theta}^{\text{linreg}}(x)) = \frac{1}{1 + e^{-h_{\Theta}(x)}} = \frac{1}{1 + e^{-\Theta^T x}}$$

- Tanulás: Paraméter illesztés a tanító halmazra
- Interpretáció:  $P(y=1|\Theta;x)$  Osztályozás:  
 $y^* = \operatorname{argmax}_y P(y|\Theta;x)$





# Osztályozás – Logisztikus Regresszió



1. Kvíz: Tegyük fel, hogy egy *bináris osztályozási probléma* esetén betanított logreg kimenete egy  $x$  példára  $h(x)=P(y=1|\Theta;x)=0.7$ . Mi a  $P(y=0|\Theta;x)$  becslése:

- 1.  $P(y=0|\Theta;x) = 0.7$
- 2.  $P(y=0|\Theta;x) = 0.7 * 0.7$
- 3.  $P(y=0|\Theta;x) = 0.3$
- 4.  $P(y=0|\Theta;x) = 0.3 * 0.7$



# Osztályozás – Logisztikus Regresszió

- Predikció:
  - $y=1$ , ha  $h(x) \geq 0.5$  azaz  $z \geq 0$
  - $y=0$ , ha  $h(x) < 0.5$  azaz  $z < 0$
- Döntési felület: sík
  - Két térrész
  - Folytonos átmenet







$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2)$$

Theta :=  $[-3, 1, 1]'$  ← tegyük fel, ezt tanultuk



# Oszályozás – Logisztikus Regresszió

2. Kvíz: Legyen adott egy két dimenziós ( $x_1, x_2$ ) bementi tér, ezen egy tanuló algoritmussal a  $\Theta_0=5$ ,  $\Theta_1=-1$ ,  $\Theta_2=0$  paramétereket tanultuk (Azaz  $h(x)=g(5-x_1)$ ). Melyik a helyes döntési felület?



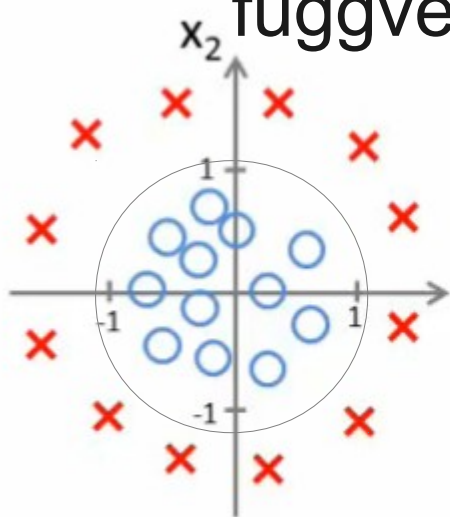


# Osztályozás – Logisztikus Regresszió

- Nemlineáris döntési felület:
  - Lineáris regresszió helyett, polinomiális regresszió  
→ nagyobb fokú tagok bevétele + gradiens módszer
    - Több paraméter (Theta nagyobb dimenziós)
    - Nagyobb reprezentációs erő (Változatosabb a felületek)
  - Logisztikus regresszió esetén: Erre polinomiális regresszió kimenetére alkalmazzuk a sigmoid függvényt → ábrán kör alakú döntési felület

Túl nagy komplexitás: túltanulás → probléma!!! (lásd később)

Általában radial basis function alapú megközelítés



$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2)$$

$\theta = [-1, 0, 0, 1, 1]'$  ← tegyük fel, ezt tanultuk

Predict “ $y = 1$ ” if  $-1 + x_1^2 + x_2^2 \geq 0$



# Logisztikus Regresszió - Tanítás

Legyen adott egy  $m$  elemű tanulótöbbség:

$$\mathcal{S} = \{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\} \subseteq \mathbb{R}^{d+1} \times \{0, 1\}, \forall i : x_0^{(i)} = 1$$

$$h_{\theta}(x) = \frac{1}{1 + e^{-\theta^T x}}$$

Lineáris regresszió költségfüggvénye:

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \underbrace{\frac{1}{2}(\theta^T x^{(i)} - y^{(i)})^2}_{\text{Modell } h_{\theta}(x^{(i)}) \text{ és az elvárt érték } y^{(i)} \text{ hibája}} = \frac{1}{m} \sum_{i=1}^m \text{cost}(h_{\theta}(x^{(i)}), y^{(i)})$$

Ahol  $\text{cost}(h_{\theta}(x), y) = \frac{1}{2}(h_{\theta}(x), y)^2$ . Ez a lineáris regresszió esetén parabólikus (kvadratikus)  $\rightarrow \theta$ -ban konvex!  
 A Logisztikus regresszió esetén, ahol  $h_{\theta}(x) = \frac{1}{1+e^{-h_{\theta}(x)}} = \frac{1}{1+e^{-\theta^T x}}$  a  $\text{cost}$  nem konvex és így  $J(\theta)$  sem az  $\rightarrow$   
 Gradiens módszer lokális optimumban maradhat!


Ötlet olyan  $\text{cost}$  megvalósítás használjuk, ami mellett  $J(\theta)$  konvex!

Legyen:

$$\text{cost}(h_{\theta}(x), y) = \begin{cases} -\log(h_{\theta}(x)) & \text{ha } y = 1 \\ -\log(1 - h_{\theta}(x)) & \text{ha } y = 0 \end{cases}$$

ekkor  $J(\theta)$ -t felírhatjuk a következő módon:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m (y^{(i)} \log(h_{\theta}(x)) + (1 - y^{(i)}) \log(1 - h_{\theta}(x)))$$








# Osztályozás – Logisztikus Regresszió

Könnyen látható, hogy:

$$cost(h_{\theta}(x), y) \begin{cases} = 0 & \text{ha } y = 1 \text{ és } h_{\theta}(x) = 1 \\ \rightarrow \infty & \text{ha } y = 1 \text{ és } h_{\theta}(x) \rightarrow 0 \\ = 0 & \text{ha } y = 0 \text{ és } h_{\theta}(x) = 0 \\ \rightarrow \infty & \text{ha } y = 0 \text{ és } h_{\theta}(x) \rightarrow 1 \end{cases}$$



Ahhoz, hogy Gradiens módszer használatával tanuljuk a paramétereket, szükség lesz a  $J(\theta)$  parciális deriváltjára.

Számoljuk ki:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m (y^{(i)} \log(h_{\theta}(x)) + (1 - y^{(i)}) \log(1 - h_{\theta}(x))), \text{ ahol } h_{\theta}(x) = \frac{1}{1 + e^{-\theta^T x}} \text{ és}$$

$$\frac{\partial}{\partial \theta} h_{\theta}(x) = \frac{e^{-\theta^T x} x}{(1 + e^{-\theta^T x})^2} = \frac{1}{1 + e^{-\theta^T x}} \cdot \frac{1 + e^{-\theta^T x} - 1}{1 + e^{-\theta^T x}} \cdot x = h_{\theta}(x)(1 - h_{\theta}(x))x$$

$$\frac{\partial}{\partial \theta} J(\theta^{(t)}) = \frac{\partial}{\partial \theta} J(\theta^{(t)}) = -\frac{1}{m} \sum_{i=1}^m \left( \frac{y^{(i)}}{h_{\theta^{(t)}}(x^{(i)})} \frac{\partial}{\partial \theta} h_{\theta^{(t)}}(x^{(i)}) + \frac{(1 - y^{(i)})}{1 - h_{\theta^{(t)}}(x^{(i)})} \left( -\frac{\partial}{\partial \theta} h_{\theta^{(t)}}(x^{(i)}) \right) \right) =$$

$$= -\frac{1}{m} \sum_{i=1}^m (y^{(i)}(1 - h_{\theta^{(t)}}(x^{(i)}))x^{(i)} - (1 - y^{(i)})h_{\theta^{(t)}}(x^{(i)})x^{(i)}) = -\frac{1}{m} \sum_{i=1}^m (y^{(i)} - h_{\theta^{(t)}}(x^{(i)}))x^{(i)} = \frac{1}{m} \sum_{i=1}^m (h_{\theta^{(t)}}(x^{(i)}) - y^{(i)})x^{(i)}$$




# Több osztályos osztályozás

- Több osztályos problémák:
  - Email-ek mappákba sorolása: barátok, család, ...
  - Orvosi diagnózis: megfázás, tüdőgyulladás, ...

- One-vs-all

One-vs-all (one-vs-rest):

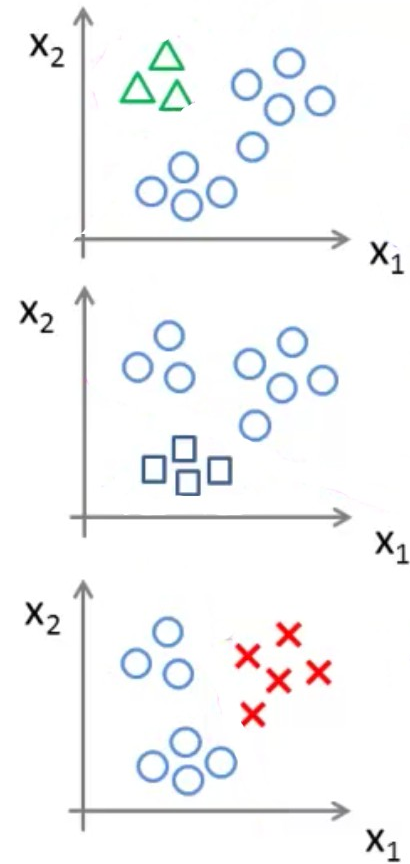



Class 1: 

Class 2: 

Class 3: 

$$h_{\theta}^{(i)}(x) = P(y = i|x; \theta) \quad (i = 1, 2, 3)$$







# Radial basis function

Radial basis function model

Egy a tanító példák  $x^{(i)}$ -k helyett használjuk a tanítás és a kiértékelés során a  $\phi(x^{(i)})$ -ket, ahol  $\phi: \mathbb{R}^d \rightarrow \mathbb{R}^n$  nemlineáris leképezés.

- Előny:
  - Nem lineáris döntési felület érhető el
- Hátrány:
  - Nagyobb dimenzióban csökken a példa sűrűség  $\rightarrow$  több példa kell
  - Komplexebb hipotézis  $\rightarrow$  túltanulás veszélye




$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2)$$

Predict “ $y = 1$ ” if  $-1 + x_1^2 + x_2^2 \geq 0$



# Osztályozás – Logisztikus Regresszió

3. Kvíz: Milyen jellemző leképezést (radial basis function-t) használtunk az előző példában:




$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2)$$

Predict “ $y = 1$ ” if  $-1 + x_1^2 + x_2^2 \geq 0$


1.  $\Phi(x) = [0, x_1, x_2, x_1^2, x_2^2]^T$
2.  $\Phi(x) = [1, x_1, x_2, x_1^2, x_2^2]^T$
3.  $\Phi(x) = [1, x_1, x_2, x_1 x_2, x_1^2, x_2^2]^T$
4. Nincs jellemző leképezés



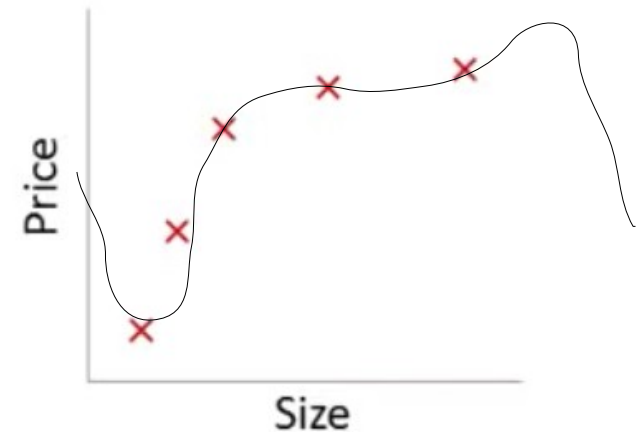
# Túltanulás



$$\theta_0 + \theta_1 x$$



$$\theta_0 + \theta_1 x + \theta_2 x^2$$



$$\theta_0 + \theta_1 x + \theta_2 x^2 + \theta_3 x^3 + \theta_4 x^4$$

- Alultanulás (Underfit):

- A modell reprezentációs ereje túl kicsi, nem tud jól ráilleszkedni a tanuló példákra

- Túltanulás (Overfit):

- A modell reprezentációs ereje túl nagy, túl jól illeszkedik a tanuló példákra → nem tud jól általánosítani, azaz új, a tanítás során nem látott példákra nem működik jól a modell.

- Túl sok jellemző




# Túltanulás elkerülése


- Plot :) (← csak kis dimenzióban működik)
- Csökkentsük a jellemzők számát és nézzük meg, hogy tanulható marad-e az probléma.
- Modell szelekciós algoritmusok használata
- Regularizáció:
  - Tartsuk meg a jellemzőket, viszont *büntessük* a tanulás során azt, ha túl nagy értékeket vesznek fel a jellemzőkhöz rendelt paraméterek




# Regularizáció



Size  
 $\theta_0 + \theta_1 x$



Size  
 $\theta_0 + \theta_1 x + \theta_2 x^2$



Size  
 $\theta_0 + \theta_1 x + \theta_2 x^2 + \theta_3 x^3 + \theta_4 x^4$

- **Ötlet büntessük a nagy fokú tagokat!**

Egy a tanító példák  $x^{(i)}$ -k helyett használjuk a tanítás és a kiértékelés során a  $\phi(x^{(i)})$ -ket, ahol  $\phi : \mathbb{R}^d \rightarrow \mathbb{R}^n$  nemlineáris leképezés.

Regularizáció alkalmazása során büntetjük a hipotézistér nagy reprezentációs erejét elősegítő tagokat.

$$\min_{\theta} \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + \underbrace{100 \cdot \theta_3^2 + 100 \cdot \theta_4^2}_{\text{Regularizációs tag}}$$



# Regularizáció

Működés: kis értékű paraméterek → egyszerűbb hipotézis → kisebb esély a túlillesztésre

Túl sok jellemző esetén nem tudjuk, hogy melyik nem fontos → regularizáljuk mindet (kivéve a 0-dikat (bias))

Általában (Lineáris regresszió)

$$J(\theta) = \frac{1}{2m} \left[ \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + \lambda \sum_{j=1}^d \theta_j^2 \right]$$

(Logisztikus regresszió)

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m (y^{(i)} \log(h_{\theta}(x)) + (1 - y^{(i)}) \log(1 - h_{\theta}(x))) + \frac{\lambda}{2m} \sum_{j=1}^d \theta_j^2$$

$\lambda$  regularizációs paraméter, trade-off a hiba minimalizálás és a modell egyszerűn tartása között.

Túl nagy → csak a bias tag marad → csak egy horizontális egyenes marad

Túl kicsi → nincs regularizáció → túlillesztés veszélye

Gradiensek (Lineáris regresszió)

$$\frac{1}{m} \sum_{i=1}^m (h_{\theta^{(t)}}(x^{(i)}) - y^{(i)}) x^{(i)} + \frac{\lambda}{m} \theta^{(t)}, \text{ ahol } \theta_0^{(t)} = 0!!!$$

Gradiens update változása (Lineáris regresszió és Logisztikus regresszió)

$$\theta_0^{(t+1)} = \theta_0^{(t)} - \alpha \frac{\partial}{\partial \theta} J(\theta^{(t)})_0 = \theta_0^{(t)} - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta^{(t)}}(x^{(i)}) - y^{(i)}) x_0^{(i)}$$

$$\forall 1 \leq j \leq d$$

$$\theta_j^{(t+1)} = \theta_j^{(t)} - \alpha \frac{\partial}{\partial \theta} J(\theta^{(t)})_j = (1 - \alpha \frac{\lambda}{m}) \theta_j^{(t)} - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta^{(t)}}(x^{(i)}) - y^{(i)}) x_j^{(i)}$$





# Lineáris regresszió – Weka megvalósítás

- Classifier osztály kiterjesztése
- `void buildClassifier(Instances)` ← tanulás megvalósítása
- `double classify(instance)` ← predikció megvalósítása