

# 5. Linearni diskriminativni modeli

Strojno učenje 1, UNIZG FER, ak. god. 2021./2022.

Jan Šnajder, natuknice s predavanja, v1.9

## 1 Linearni diskriminativni modeli

- Linearni diskriminativni modeli – granica je linearna  $\Rightarrow$  **hiperravnina**:

$$h(\mathbf{x}; \mathbf{w}) = \mathbf{w}^T \mathbf{x}$$

- Granica između klasa je na  $h(\mathbf{x}) = 0$  (ponekad:  $h(\mathbf{x}) = 0.5$ )
- **Diskriminativan model** – izravno modelira granicu između klasa
- Generativni vs. diskriminativni modeli


## 2 Geometrija linearnog modela

- BSO, razmatramo sljedeći model:

$$h(\mathbf{x}; \mathbf{w}) = w_1 x_1 + w_2 x_2 + w_0$$

- Granica je pravac:

$$w_1 x_1 + w_2 x_2 + w_0 = 0$$



- $\mathbf{w}$  je **normala** hiperravnine:

$$\begin{aligned} h(\mathbf{x}_1) &= h(\mathbf{x}_2) \\ \mathbf{w}^T \mathbf{x}_1 + w_0 &= \mathbf{w}^T \mathbf{x}_2 + w_0 \\ \mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) + w_0 - w_0 &= 0 \\ \mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) &= 0 \end{aligned}$$

- Udaljenost primjera  $\mathbf{x}$  od hiperravnine:

$$\begin{aligned} \mathbf{x} &= \mathbf{x}_\perp + d \frac{\mathbf{w}}{\|\mathbf{w}\|} \\ &= \underbrace{\mathbf{w}^T \mathbf{x} + w_0}_{h(\mathbf{x})} = \underbrace{\mathbf{w}^T \mathbf{x}_\perp + w_0}_{=h(\mathbf{x}_\perp)=0} + d \frac{\mathbf{w}^T \mathbf{w}}{\|\mathbf{w}\|} \\ h(\mathbf{x}) &= d \|\mathbf{w}\| \quad \Rightarrow \quad d = \frac{h(\mathbf{x})}{\|\mathbf{w}\|} \end{aligned}$$

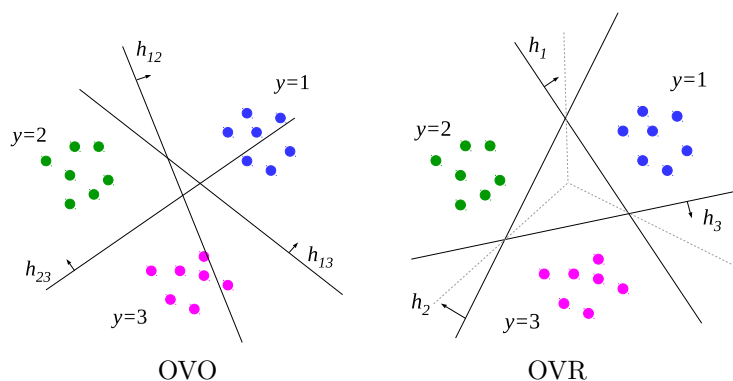
### 3 Višeklasna klasifikacija

- Shema **jedan-naspram-jedan** (**one-vs-one, OVO**) –  $\binom{K}{2}$  binarnih modela:

$$h(\mathbf{x}) = \operatorname{argmax}_i \sum_{i \neq j} \operatorname{sgn}(h_{ij}(\mathbf{x})), \quad h_{ji}(\mathbf{x}) = -h_{ij}(\mathbf{x})$$

- Shema **jedan-naspram-ostali** (**one-vs-rest, OVR**) –  $K$  binarnih modela:

$$h(\mathbf{x}) = \operatorname{argmax}_j h_j(\mathbf{x})$$



- OVR ima manje modela od OVO, ali potencira neuravnotežnost klasa

### 4 Klasifikacija regresijom


- Funkcija pogreške:

$$E(\mathbf{w}|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (\mathbf{w}^T \phi(\mathbf{x}^{(i)}) - y^{(i)})^2 = \frac{1}{2} (\Phi \mathbf{w} - \mathbf{y})^T (\Phi \mathbf{w} - \mathbf{y})$$

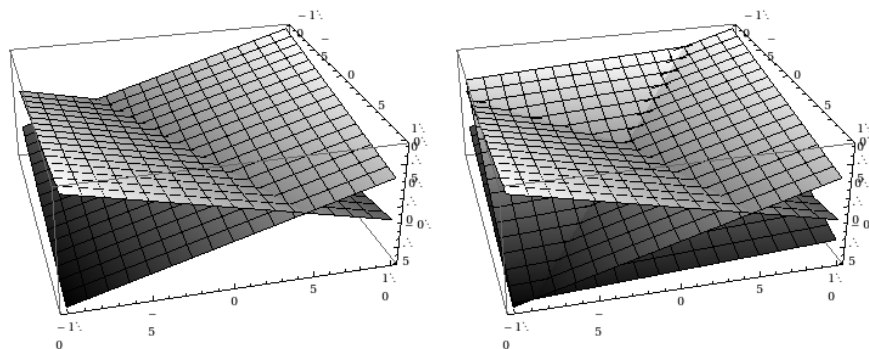
- Minimizador:

$$\mathbf{w}^* = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{y} = \Phi^+ \mathbf{y}$$


- Ideja: hipoteza koja predviđa  $y = 1$  i  $y = 0$  za primjere prve odnosno druge klase
- Model:  $h(\mathbf{x}; \mathbf{w}) = \mathbf{1}\{\mathbf{w}^T \phi(\mathbf{x}) \geq 0.5\}$
- Skica za  $n = 1$ :




- Proširivo na  $K > 2$  klasa shemom OVR ili OVO



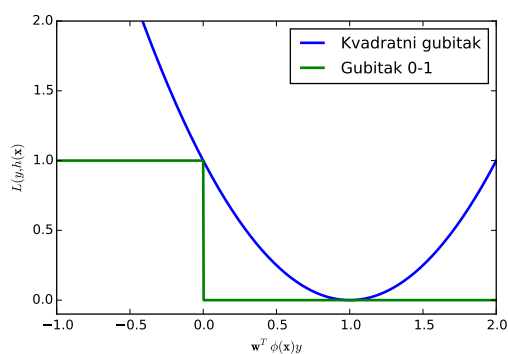
- Nedostatci: izlazi nisu vjerojatnosti, nerobusnost na vrijednosti koje odskaču
- Skica: nerobusnost na vrijednosti koje odskaču ( $n = 1$ ):



- Nerobusnost na vrijednosti koje odskaču ( $n = 2$ ):



- Uzrok: funkcija gubitka  $L$  kažnjava i dobro klasificirane primjere
- Za  $y \in \{-1, +1\}$ : ispravna klasifikacija  $\Leftrightarrow \mathbf{w}^T \phi(\mathbf{x})y > 0$
- Skica:  $L$  kao funkcija od  $\mathbf{w}^T \phi(\mathbf{x})y$



- Idealan gubitak je gubitak 0-1, ali nije konveksan, pa nije pogodan za optimizaciju

## 5 Perceptron

- Model:

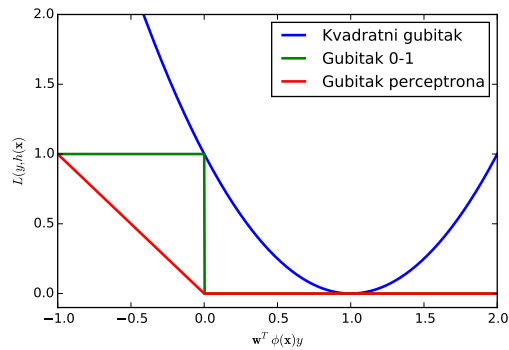
$$h(\mathbf{x}) = f(\mathbf{w}^T \phi(\mathbf{x}))$$

- **Funkcija praga** kao aktivacijska funkcija:

$$f(\alpha) = \begin{cases} +1 & \text{ako } \alpha \geq 0 \\ -1 & \text{inače} \end{cases}$$

- Perceptron – umjetni neuron (McCulloch & Pitts, 1943.)
- Funkcija gubitka:

$$L(y, h(\mathbf{x})) = \max(0, -\mathbf{w}^T \phi(\mathbf{x})y)$$




- Funkcija pogreške:


$$E(\mathbf{w}|\mathcal{D}) = - \sum_{i : f(\mathbf{w}^T \phi(\mathbf{x}^{(i)})) \neq y^{(i)}} \mathbf{w}^T \phi(\mathbf{x}^{(i)}) y^{(i)} = \sum_{i=1}^N \max(0, -\mathbf{w}^T \phi(\mathbf{x}^{(i)}) y^{(i)})$$

⇒ kažnjava samo netočno klasificirane primjere (za razliku od regresije)

- Površina pogreške u prostoru parametara:



udio pogrešnih klasifikacija



pogreška perceptrona

- Ne postoji minimizator u zatvorenoj formi ⇒ primjenjujemo **gradijentni spust**
- Gradijentni spust: težine ažuriramo u smjeru suprotnome od gradijenta
- Gradijent funkcije gubitka za netočno klasificirane primjere:

$$\nabla_{\mathbf{w}} L = \nabla_{\mathbf{w}} (-\mathbf{w}^T \phi(\mathbf{x}) y) = -\phi(\mathbf{x}) y$$

- Ažuriranja težina – **Widrow-Hoffovo pravilo**:

$$\mathbf{w} \leftarrow \mathbf{w} - \eta \nabla L(\mathbf{w}|\mathcal{D})$$

tj.

$$\mathbf{w} \leftarrow \mathbf{w} + \eta \phi(\mathbf{x}) y$$

gdje je  $\eta$  stopa učenja

## Algoritam perceptrona

```
1: inicijaliziraj  $\mathbf{w} \leftarrow (0, \dots, 0)$ 
2: ponavljaj do konvergencije
3:   za  $i = 1, \dots, N$ 
4:     ako  $f(\mathbf{w}^T \phi(\mathbf{x}^{(i)})) \neq y^{(i)}$  onda  $\mathbf{w} \leftarrow \mathbf{w} + \eta \phi(\mathbf{x}^{(i)}) y^{(i)}$ 
```

- Nedostatci:

- Izlazi modela nisu vjerojatnosti
- Konvergira samo ako su primjeri linearno odvojivi (Rosenblatt, 1962)
- Rezultat ovisi o početnim težinama