


A perceptron

Neuron



- ▶ absztrakt neuron modell: $a = f\left(\sum_i x_i w_i + b\right)$
- ▶ x_i : a neuron bemenetei
- ▶ w_i : súlyzók
- ▶ b : bias
- ▶ f : aktivációs függvény
- ▶ a : a neuron kimenete



A perceptron

- ▶ a perceptron egy olyan neuron, amely **hardlim** aktivációs függvényt* használ

$$f: \mathbb{R} \rightarrow \{0,1\}, \quad f(x) = \begin{cases} 1, & \text{ha } x \geq 0 \\ 0 & \text{különben} \end{cases}$$


- ▶ $a = \text{hardlim}(\mathbf{w}^T \mathbf{x} + b)$
- ▶ a perceptron egy **lineáris és bináris** osztályozó
- ▶ döntési felület: azon bemenetek halmaza, amelyre $\mathbf{w}^T \mathbf{x} + b = 0$
- ▶ bináris osztályozási problémák: spam?, rák?, hitel?, stb

*vagy valamilyen más lépcsőfüggvényt



- ▶ tanítsunk meg egy perceptronnak a következő leképzéseket:

$$\left\{ \mathbf{p}_1 = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, t_1 = 1 \right\}, \left\{ \mathbf{p}_2 = \begin{bmatrix} -1 \\ 2 \end{bmatrix}, t_1 = 0 \right\}, \left\{ \mathbf{p}_3 = \begin{bmatrix} 0 \\ -1 \end{bmatrix}, t_1 = 0 \right\}$$



- ▶ tanítás: a súlyzóvektor értékeinek beállítása



Perceptron tanítási szabály (perceptron learning rule)

Jelölés:

- ▶ a jelölés egyszerűsítéséért: $w_0 \leftarrow b$ és $x_0 \leftarrow 1$
- ▶ \mathbf{x} egy bemenet és d a hozzátartozó helyes osztályozás
- ▶ $y = f(\mathbf{w}^T \mathbf{x})$ a perceptron kimenete
- ▶ $e = (d - y)$ a perceptron hibája az \mathbf{x} bemenetre

Tanítási szabály:

- ▶ ha $e = 0$, akkor \mathbf{w} változatlan
- ▶ ha $e = 1$, akkor $\mathbf{w} \leftarrow \mathbf{w} + \mathbf{x}$
- ▶ ha $e = -1$, akkor $\mathbf{w} \leftarrow \mathbf{w} - \mathbf{x}$



- ▶ tanítás: a w iteratív módon történő beállítása
- ▶ tanítási halmaz: $T = \{(x^1, d^1), (x^2, d^2), \dots, (x^N, d^N)\}$
- ▶ bizonyítottan konvergál, ha T lineárisan szétválasztható

```
1 function w = PerceptronLearning(x, d)
2   [N, n] = size(x);
3   lr = 0.01;
4   w = randn(n,1);
5   E = 1;
6   while E ~= 0
7     E = 0;
8     for i = 1:N
9       yi = hardlim(x(i,:)*w);
10      ei = d(i)-yi;
11      w = w + lr*ei*x(i,:);
12      E = E + ei^2;
13    end
14  end
15 end
```



(a) lineárisan szétválasztható



(b) lineárisan nem szétválasztható

- ▶ hány megoldás van? melyiket preferáljuk?
- ▶ mi az a legegyszerűbb logikai függvény, amit a perceptron nem tud megtanulni?
- ▶ több osztály? puha margó (soft margin)?

- ▶ WIN32 hívások alapján döntsük el, hogy egy processz rosszindulatú-e
- ▶ nyers tanítási halmaz:

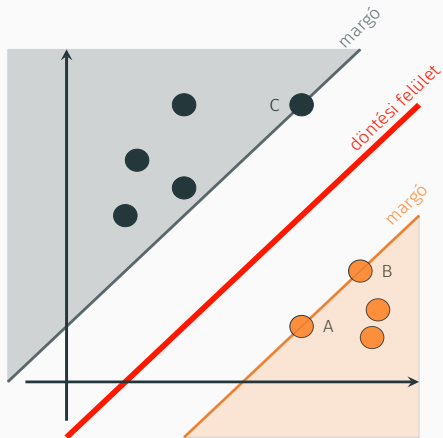
```
CoCreateInstance,CoInitializeEx,CreatePipe,CreateProcess,Crea,...,malicious
CoInitializeEx,Connect,CreateRemoteThread,CreateService,Crea,...,benign
AdjustTokenPrivileges,CoCreateInstance,CoInitializeEx,Connec,...,malicious
Bind,CoInitializeEx,CreateMutex,CreateRemoteThread,CreateThr,...,benign
AdjustTokenPrivileges,Bind,CoInitializeEx,CreateMutex,Create,...,benign
AdjustTokenPrivileges,Connect,CreatePipe,CreateProcess,Creat,...,benign
AdjustTokenPrivileges,CoCreateInstance,Connect,CreatePipe,Cr,...,malicious
AdjustTokenPrivileges,CoCreateInstance,CreateService,CryptAc,...,malicious
...
```

- ▶ összesen $n = 167$ különböző függvény, $\{f_1, f_2, \dots, f_n\}$
- ▶ kimenet kódolása: malicious – 1, benign – 0
- ▶ $F = \{f_k\}$ bemenet kódolása: 1, ha $f_i \in F$, 0 különben
- ▶ **tesztelési halmaz**
- ▶ a perceptron viselkedését egy **konfúziós mátrixban** összesítjük:


		actual class	
		benign	malicious
pred class	benign	#true positives	#false positives
	malicious	#false negatives	#true negatives

Support vector machine (SVM)

- ▶ maximális margó (maximal margin)



A margó méretének kiszámítása



$$\triangleright \|\vec{p}\| = \frac{2}{\|\vec{w}\|}$$

- ▶ $\{\mathbf{x}_i, y_i\}_{i=1..N}$ tanítási halmaz, $y_i = \pm 1$
- ▶ $\mathbf{w}^T \mathbf{x}_i + b \geq 1$, ha $y_i = 1$
- ▶ $\mathbf{w}^T \mathbf{x}_i + b \leq -1$, ha $y_i = -1$
- ▶ $\frac{2}{\|\mathbf{w}\|} \rightarrow \max \Leftrightarrow \|\mathbf{w}\| \rightarrow \min$
- ▶ optimalizációs probléma: $\underset{\mathbf{w}}{\operatorname{argmin}} \|\mathbf{w}\|$, úgy hogy $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1$
- ▶ implementációk: `quadprog` (Matlab), `qp` (Octave)

- ▶ Christopher Bishop: Pattern Recognition and Machine Learning, 2006
- ▶ Simon Haykin: Neural Networks and Learning Machines, 2009
- ▶ Alexandre Kowalczyk: Support Vector Machines Succintly
- ▶ Martin Hagan: Neural Network Design 2nd ed, 2014