


UMJETNE NEURONSKE MREŽE


LITERATURA: "MACHINE LEARNING", T. MITCHELL (1997) [ML]

"DEEP LEARNING", I. GOODFELLOW, Y. BENGIO, A. COURVILLE (2016) [DL]

PERCEPTRON [ML P.86]



$$r(x_1, \dots, x_m) = \begin{cases} 1 & \text{AKO } \sum_{i=0}^m w_i x_i > 0 \\ -1 & \text{AKO } \sum_{i=0}^m w_i x_i \leq 0 \end{cases}$$



$$r(\vec{w} \cdot \vec{x}) = \text{SGN}(\vec{w} \cdot \vec{x}) = \begin{cases} 1 & \text{AKO } \vec{w} \cdot \vec{x} > 0 \\ -1 & \text{AKO } \vec{w} \cdot \vec{x} \leq 0 \end{cases}$$

PROSTOR HIPOTEZA: $H = \{ \vec{w} \mid \vec{w} \in \mathbb{R}^{(m+1)} \}$

HIPERRAVNINE!

$t \in \{-1, 1\}$ CILJNA VARIJABLA
 $r \in \{-1, 1\}$ IZLAZ
 BINARYNI KLASIFIKACIJSKI PROBLEM

UČENJE PERCEPTRONA:

$$\vec{w}^{(i+1)} \leftarrow \vec{w}^{(i)} + \Delta \vec{w}^{(i)}$$

$$\Delta \vec{w}^{(i)} = \eta (t - r) \vec{x}^{(i)}$$

STOPA UČENJA

KONVERGENCIJA SAMO U SLUČAJU LINEARNE ODVOJIVOSTI!

UZORCI $(\vec{x}^{(i)}, t^{(i)})$ SE PREDSTAVLJAJU JEDAN PO JEDAN I NAKON SVAKOG

KRIVO KLASIFICIRANOG SE

RADI UPDATE TEŽIMA $\Delta \vec{w}^{(i)}$

VC DIMENZIJA PERCEPTRONA JE $m+1$


(NA VEĆI BROJ PRIMJERA KOJE MOŽEMO RAZDVOJITI S PERCEPTRONOM BEZ OBLIRA NA LABELU)

INTUITIVNI POKAZ:


AKO $r = -1$, $t = 1$ ONDA $t - r > 0$ I $\vec{w} \cdot \vec{x}$ SE TREBA POVEĆATI

AKO $r = 1$, $t = -1$ ONDA $t - r < 0$ I $\vec{w} \cdot \vec{x}$ SE TREBA SMANJITI

PRIMJER:



NE ZABORAVI
 $\vec{x}^{(i)} = (1, 1)$ MA $x_0 = 1$!
 $t^{(i)} = +1$
 $r^{(i)} = -1$
 $\vec{w}^{(i)} = (-3, 1, 1)$



GRADIJENTNI SPUST [ML P.89]

$\sigma(\vec{x}) = \vec{w} \vec{x}$ IZLAZ BEZ AKTIVACIJSKE FUNKCIJE!

$$E(\vec{w}) = \frac{1}{2} \sum_{i \in D} (t^{(i)} - \sigma^{(i)})^2$$

$$\nabla E(\vec{w}) = \left[\frac{\partial E}{\partial w_0}, \dots, \frac{\partial E}{\partial w_m} \right]$$

UČENJE:

$$\vec{w}^{(i+1)} \leftarrow \vec{w}^{(i)} + \Delta \vec{w}^{(i)}$$

$$\Delta \vec{w}^{(i)} = -\eta \nabla E(\vec{w})$$

DOKAZ:

$$\frac{\partial E}{\partial w_k} = \frac{\partial}{\partial w_k} \frac{1}{2} \sum_{i \in D} (t^{(i)} - \sigma^{(i)})^2 =$$


$$= \frac{1}{2} \sum_{i \in D} 2(t^{(i)} - \sigma^{(i)}) \frac{\partial}{\partial w_k} (t^{(i)} - \vec{w}^{(i)} \vec{x}^{(i)}) = \sum_{i \in D} (t^{(i)} - \sigma^{(i)}) (-x_k^{(i)})$$

KOMENTARI:

- GRAD. SPUST MOŽEMO KORISTITI KAD IMAMO $\vec{w} \in \mathbb{R}^m$ I AKO $\nabla E(\vec{w})$ POSTOJI
- KONVERGENCIJA I KAD UZORCI NISU LINEARNO ODVOJIVI!
- MINIMIZACIJA KVADRATNE GREŠKE ($E(\vec{w})$), NE I UKUPNOG BROJA KRIVO KLASIFICIRAN
- POTENCIJALNO SPORA KONVERGENCIJA (DODAVANJE MOMENTA I HESSIJANA)
- PROBLEMI AKO JE $E(\vec{w})$ NEKONVERSNJA (MINIMUM NIJE JEDINSTVEN)

NELINEARNE AKTIVACIJSKE FUNKCIJE:


SIGMOIDA: $\sigma(\vec{w} \vec{x}) = \frac{1}{1 + e^{-\vec{w} \vec{x}}}$




$$\frac{d \sigma(y)}{dy} = \sigma(y)(1 - \sigma(y))$$

TANGENS

HIPERBOLNI: $\tanh(\vec{w} \vec{x}) = \frac{e^{-\vec{w} \vec{x}} - e^{\vec{w} \vec{x}}}{e^{-\vec{w} \vec{x}} + e^{\vec{w} \vec{x}}}$



$$\frac{d \tanh(y)}{dy} = 1 - \tanh^2(y)$$



1. KONVERSNOST!

2. BAYES-OPTIMALNA UZ PRETPOSTAVKU GAUSSOVOG ŠUMA

$\sigma(\vec{x}) = \vec{w} \vec{x}$ LINEARNA FUNKCIJA } KONVERSNOST!


$\sigma(\vec{x}) = f(\vec{w} \vec{x})$ POTENCIJALNO NELINEARNA FUNKCIJA } NEKONVERSNOST!

$$w_k^{(i+1)} \leftarrow w_k^{(i)} + \Delta w_k^{(i)}$$

$$\Delta w_k^{(i)} = -\eta \frac{\partial E}{\partial w_k^{(i)}} = \eta \sum_{i \in D} \underbrace{(t^{(i)} - \sigma^{(i)}) x_k^{(i)}}_{\text{STOHAISTIČKI GRAD. SPUST}} \underbrace{(-1)}_{\text{GRADIJENTNI SPUST}}$$

VIŠESLOJNE NEURONSKE MREŽE [MLP.95, DL P.168]

MOTIVACIJSKI PROBLEM (XOR PROBLEM): [DL P.171]




LINEARNO NESEPARABILAN,
ALI MOGUĆE ODVOJITI S
(RECIMO) ELIPSON:


$$\tilde{w}_5 x_1^2 + \tilde{w}_4 x_1 x_2 + \tilde{w}_3 x_2^2 + \tilde{w}_2 x_1 + \tilde{w}_1 x_2 + \tilde{w}_0 = 0$$

I DALJE LINEARAN PROBLEM
(U PARAMETRIMA \tilde{w}) ALI
S EKSPlicitnim Nelinearnim
Mapiranjem!

S VIŠESLOJNIM Nelinearnim NEUR. MR. MOŽEMO NAUČITI Mapiranje:



$$\text{ReLU}(x) = \max\{0, x\}$$



RECTIFIED LINEAR UNIT



$$f(\vec{x}; W, \vec{z}, \tilde{w}, h) = \tilde{w}^T \max\{0, W^T \vec{x} + \vec{z}\} + h$$

$$W = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \quad \vec{z} = \begin{bmatrix} 0 \\ -1 \end{bmatrix} \quad \tilde{w} = \begin{bmatrix} 1 \\ -2 \end{bmatrix} \quad X = \begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 1 & 0 \\ 1 & 1 \end{bmatrix} \begin{matrix} + \\ 0 \\ 0 \\ + \end{matrix}$$

Mapiranje u skrivenom sloju:

$$\max\{0, XW + \vec{z}\} = \max\left\{0, \begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 1 & 0 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} + \begin{bmatrix} 0 \\ -1 \end{bmatrix}\right\} = \max\left\{0, \begin{bmatrix} 0 & -1 \\ 1 & 0 \\ 1 & 0 \\ 2 & 1 \end{bmatrix}\right\} = \begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 1 & 0 \\ 2 & 1 \end{bmatrix} \begin{matrix} + \\ 0 \\ 0 \\ + \end{matrix}$$


LINEARNO RAZDVOJIVI!



$$\begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 1 & 0 \\ 2 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ -2 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 1 \\ 0 \end{bmatrix} \begin{matrix} + \\ 0 \\ 0 \\ + \end{matrix}$$

KOMENTARI:

- KOMPozICIJA LIN. FUN. JE I DALJE LIN. FUN., ZATO JE VIŠESLOJNA N.M. S LIN. AKT. FUN. EKVIvalENTNA JEDNOM PERCEPTRONU!
- RELU NIJE DERIVABILNA, ZA RAZLIKU OD SIGMOIDE I TANH
- KORIŠTENJE RELU JE EKVIvalENTNO KAO ODABIR PODSKUPA NEURONA I KORIŠTENJA LIN. AKT. FUN (ZA SVAKI UZORAK JE TAKI PODSKUP DRUGAČIJI!)



NEMA NESTAJUĆEG
GRADIJENTA I
RAČUNANJE JE
EFIKASNIJE!

BACKPROPAGATION [ML P.97, DL P.204]

$$E_d(\vec{w}) = \frac{1}{2} \sum_{k \in \text{out}} (t_k - a_k)^2$$

FUNKCIJA GREŠKE ZA VZORAK
 d JE DEFINIRANA SA TO ZA
IZLAZNI SLOJ!

$$\Delta w_{ji} = -\eta \frac{\partial E_d}{\partial w_{ji}}$$

UPDATE KOJI RADIMO ZA TEŽINU w_{ji}
NAKON VZORKA d

↑ ↑
NEURON ULAZ U
NEURON

$$\frac{\partial E_d}{\partial w_{ji}} = \frac{\partial E_d}{\partial (\sum_i w_{ji} x_{ji})} \cdot \frac{\partial (\sum_i w_{ji} x_{ji})}{\partial w_{ji}} = \underbrace{\frac{\partial E_d}{\partial (\sum_i w_{ji} x_{ji})}}_{\delta_j} x_{ji}$$

CHAIN RULE

(DERIVACIJA KOMPOZICIJE FUNKCIJA)

IZLAZNI NEURONI : $\delta_j \leftarrow \sigma_j(1-\sigma_j)(t_j - a_j)$

SKRIVENI NEURONI : $\delta_j \leftarrow \sigma_j(1-\sigma_j) \sum_{k \in \text{out}} w_{kj} \delta_k$

DERIVACIJA
SIGMOIDE

KOLIKO JE NEURON j
ODGOVORAN ZA GREŠKU
U IZLAZNOJ NEURONU k

ZA SIGMOIDALNU
AKTIVACIJSKU FUN.!

$$\sigma(\vec{w} \cdot \vec{x}) = \frac{1}{1 + e^{-\vec{w} \cdot \vec{x}}}$$

KOMENTARI:



- GRADIJENT SE DISIPIRA ŠTO JE MREŽA DUBLJA, POČETNE TEŽINE SE MALO MIJENJAJU (VANISHING GRADIENT) - RELU NEMA TAJ PROBLEM!

REGULARIZACIJA U NEURONSKIM MREŽAMA [ML P. 108, DL P. 228]

PRISTRANOST I VARIJANCA: [SCOT.FORTMANN-ROE.COM/DOCS/BIASVARIANCE.HTML]

$$Y = f(x) + \epsilon \quad \text{ERR}(x) = E[(Y - \hat{f}(x))^2] =$$

$$= \underbrace{(E[\hat{f}(x)] - f(x))^2}_{\text{PRISTRANOST}^2} + \underbrace{E[(\hat{f}(x) - E[\hat{f}(x)])^2]}_{\text{VARIJANCA}} + \underbrace{\epsilon^2}_{\text{IREDUKIBILNA GREŠKA}}$$



REGULARIZACIJA U N.M.:

- PENALIZIRANJE TEŽINA \vec{w}

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} \sum_{k \in OUT} (t_k^{(d)} - w_k^{(d)})^2 + \gamma \sum_{i,j} w_{ij}^2$$

KVADRATNA, L_2 , TIKHONOVA
REGULARIZACIJA

NAMEĆE GLATKOST U \vec{w} !

$$\gamma \sum_{i,j} |w_{ij}|$$

APSOLUTNA, L_1 REGULARIZACIJA

NAMEĆE RIJETKOST U \vec{w} !

- RANO PREKIDANJE UČENJA

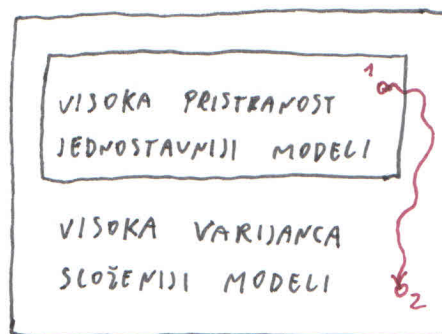
- NAMETANJE INVARIJANCI (GENERIRANJE MODIFICIRANIH PRIMJERA, TRANS. ZNAČAKI)

- LOKALNO POVEZIVANJE NEURONA I DIJELJENJE TEŽINA

- DROPOUT (NASUMIČNO "GAŠENJE" TEŽINA ILI NEURONA - IMPLICITNO STVARA ANSAMBL)

INICIJALIZACIJA TEŽINA:

PREPORUČA SE POČETI S MALIM
TEŽINAMA JER TO ODGOVARA
JEDNOSTAVNIJIM MODELIMA



REPREZENTACIJSKA MOĆ NEURONSKIH MREŽA [ML P.105, DL P.198]

UNIVERZALNI APROKSIMACIJSKI TEOREM (HORNIK, CYBENKO 1989.)

NEURONSKA MREŽA S BAREM JEDNIM SKRIVENIM SLOJEM SA „SQUASHING“ AKT. FUNK. (SIGMOIDA, TANH) I LINEARNIM VANJSKIM SLOJEM MOŽE PROIZVOLJNO TOČNO APROKSIMIRATI BILO KOJU BOREL-MJERLJIVU FUNKCIJU (SVAKA KONTINUIRANA FUNK. NA ZATVORENOM PODSKUPU OD \mathbb{R}^n JE BOREL-MJERLJIVA).

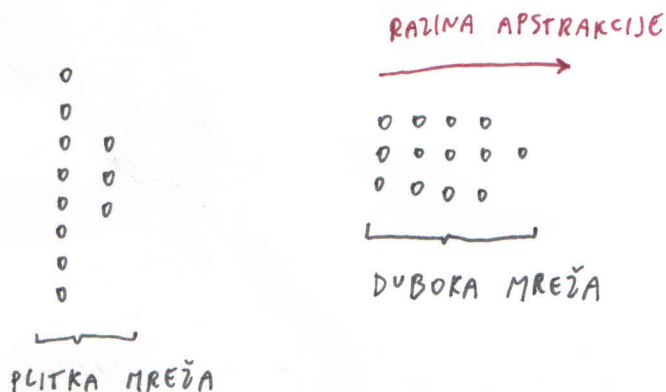
(LESHNO 1993.) EKSTENZIJA NA RELU AKTIVACIJSKE FUNKCIJE

PROBLEMI:

- NE POSTOJI GARANCIJA DA JE MOGUĆE NAVČITI TEŽINE TAKVE MREŽE
- NE KAŽE SE KOLIKO JE NEURONA POTREBNO, U NAJGOREM SLUČAJU JE POTREBNO EKSPONENCIJALNI BROJ SKRIVENIH NEURONA


(BROJ MOGUĆIH BINARNIH FUNKCIJA NA VEKTORIMA $\mathcal{N} \in \{0,1\}^n$ JE 2^{2^n} , I POTREBNO JE 2^n BITOVA ZA SELEKCIJU JEDNE OD NJIH)

IPAK, INTUICIJA I PRAKSA POKAZUJU DA SU DUBOKE MREŽE PUNO EFIKAJMIJE U UČENJU I REPREZENTACIJI:




NEURAL NETWORK PLAYGROUND:
[PLAYGROUND.TENSORFLOW.ORG](https://playground.tensorflow.org)

UČENJE S PODRŠKOM



INTERAKCIJA S OKOLIŠEM: [ML P.368]



KUMULATIVNA NAGRADA:

$$r_0 + \gamma r_1 + \dots + \gamma^m r_m \quad 0 \leq \gamma \leq 1 \quad 0 \leq \gamma < 1$$

CIL: NAVČI KONTROLNU STRATEGIJU $\pi: S \rightarrow A$

U NADZIRANOM UČENJU OČEKUJEMO PODATKE $(s, \pi(s))$

ZADATAK UČENJA: [ML P.370]

$$V^\pi(s_t) = r_t + \gamma r_{t+1} + \dots = \sum_{i=0}^{\infty} \gamma^i r_{t+i}$$

DISCOUNTED CUMULATIVE REWARD

$$\pi^* \equiv \underset{\pi}{\text{ARB MAX}} V^\pi(s), \forall s$$

OPTIMALNA STRATEGIJA

$$\pi^*(s) = \underset{a}{\text{ARB MAX}} [r(s, a) + \gamma V^*(\delta(s, a))]$$

FUNKCIJA NAGRADE


MAKSIMALNA KUMULATIVNA NAGRADA

FUNKCIJA PRIJELAZA


$\delta: S \times A \rightarrow S$ DETERMINISTIČKA

$\delta: S \times A \rightarrow \text{PROB}(S)$ NEDETERMINISTIČKA

PRIMER:



$$\gamma = 0.9$$



G - GRANIČNO STANJE

$r(s, a)$ - FUNKCIJA NAGRADE

$V^*(s)$ MAKSIMALNA KUMULATIVNA NAGRADA

$\pi^*(s)$ OPTIMALNA STRATEGIJA

Q LEARNING [ML P.373]

$$\pi^*(s) = \underset{a}{\operatorname{ARGMAX}} [r(s,a) + \gamma V^*(\delta(s,a))]$$

KADA BI $r(s,a)$ I $\delta(s,a)$ BILE U POTPUNOSTI POZNATE GORNJA BI SE JEDNAĐBA MOGLA ISKORISTITI ZA UČENJE $\pi^*(s)$ (ONDA SE TO ZOVE DINAMIČKO PROGRAMIRANJE!). UMJESTO TOGA, UČIMO Q-FUNKCIJU:

$$Q(s,a) = r(s,a) + \gamma \max_{a'} Q(\delta(s,a), a')$$

AKCIJA DOSTUPNA IZ
SLJEDEĆEG STANJA $\delta(s,a)$

$$V^*(s) = \max_{a'} Q(s, a')$$

↑
FUNKCIJA STANJA

↑
FUNKCIJA STANJA
I AKCIJE (PRAKTIČNIJE)

UČENJE Q-FUNKCIJE:

$$\hat{Q}(s,a) \leftarrow r(s,a) + \gamma \max_{a'} \hat{Q}(s', a') \quad 0 \leq \gamma < 1$$

KAKO ODABIRATI AKCIJE?

$$P(a_i | s) = \frac{k^{\hat{Q}(s, a_i)}}{\sum_j k^{\hat{Q}(s, a_j)}}$$

$k > 0$, REGULIRA KOLIKO SE PREFERIRAJU AKCIJE
S VELIKIM $Q(s,a)$ VRIJEDNOSTIMA (EXPLORATION
VS
EXPLOITATION)

UVJETI ZA KONVERGENCIJU Q UČENJA:

1. DETERMINISTIČKI MARKOVLEV PROCES ODLUČIVANJA
2. NAGRADE SU OGRANIČENE
3. BESKONAČNO POSJEĆIVANJE SVAKOG PARA STANJE/AKCIJA


PRIMJERI IZ PRAKSE:

- "HUMAN-LEVEL CONTROL THROUGH DEEP R.L." (2015)

- "MASTERING THE GAME OF GO WITH DEEP M.N. AND TREE SEARCH" (2016)

UVJET 3. JE NEREALISTIČAN,
ZATO SE U PRAKSI Q-FUNKCIJA
APROKSIMIRA NEURALNOM MREŽOM!

PRIMJER ZA Q-VČENJE [ML P.376]




$r(s, a)$

$$\gamma = 0.9$$


90	100	0
81	90	100

$V^*(s)$




$Q(s, a)$

JEDNA ITERACIJA Q-VČENJA:



$a \rightarrow$



$$\hat{Q}(s_1, a_{\rightarrow}) \leftarrow \underbrace{r(s_1, a_{\rightarrow})}_0 + \underbrace{\gamma}_{0.9} \underbrace{\max_{a'} \hat{Q}(s_2, a')}_{\max\{66, 81, 100\}} = 90$$