

Úvod do teorie neuronových sítí

Kamila Lepkova
Biomedicínské inženýrství (ČVUT),

[kamila.lepkova\(at\)cvut.cz](mailto:kamila.lepkova(at)cvut.cz)

Co je to AI ?

Definice AI podle EU ACT

*„System umělé inteligence“ (AI systém) znamená systém, který je navržen tak, aby fungoval s určitou úrovní autonomie a který **na základě dat a vstupů poskytnutých strojem a/nebo člověkem vyvozuje, jak dosáhnout daného lidmi definovaného cíle** využívající strojové učení a/nebo přístupy založené na logice a znalostech a vytváří systémově generované výstupy, jako je obsah (generativní systémy umělé inteligence), předpovědi, doporučení nebo rozhodnutí, které ovlivňují prostředí, se kterými systém umělé inteligence interaguje.*

Historie AI

Vytvořen první matematický model neuronu - Alan Turing

1943

1955

První použití termínu umělá
inteligence
John McCarthy

Chatbot ELIZA a robot Shakey

1966

První samořídící auto
Testlab 1

1989

Deep Blue poráží Garyho
Kasparova

1996

Historie AI

Dataset ImageNet

2006

2010

Watson vyhrává Riskuj!

SIRI a průlom ve
zpracování řeči

2011

AlphaGo poráží Lee
Sedola v Go

2017

GPT-3: Počítač píše
knihu

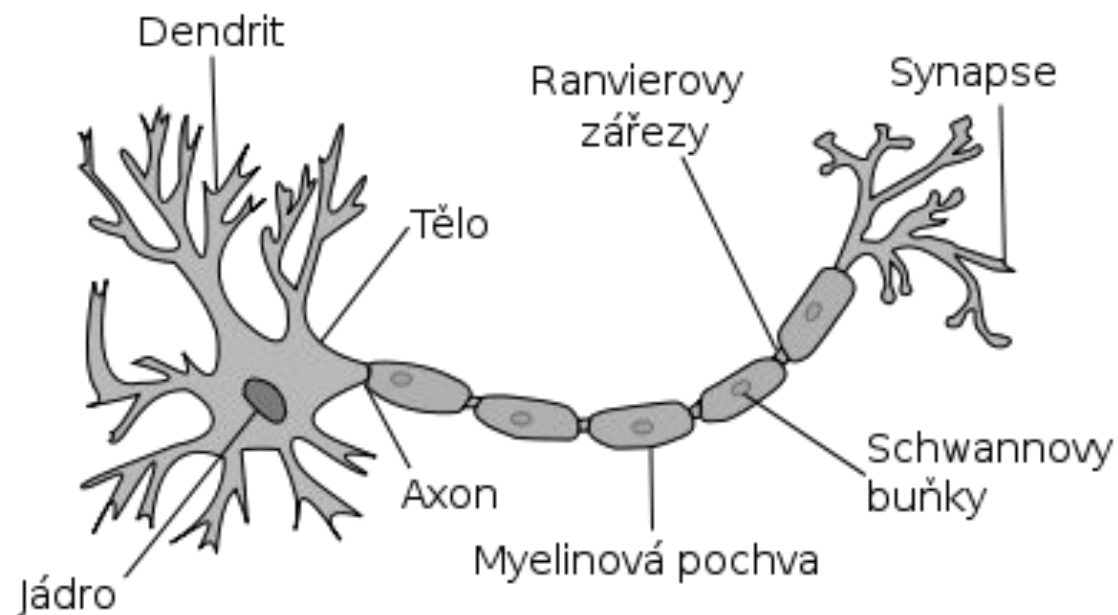
2020

Neuronová síť

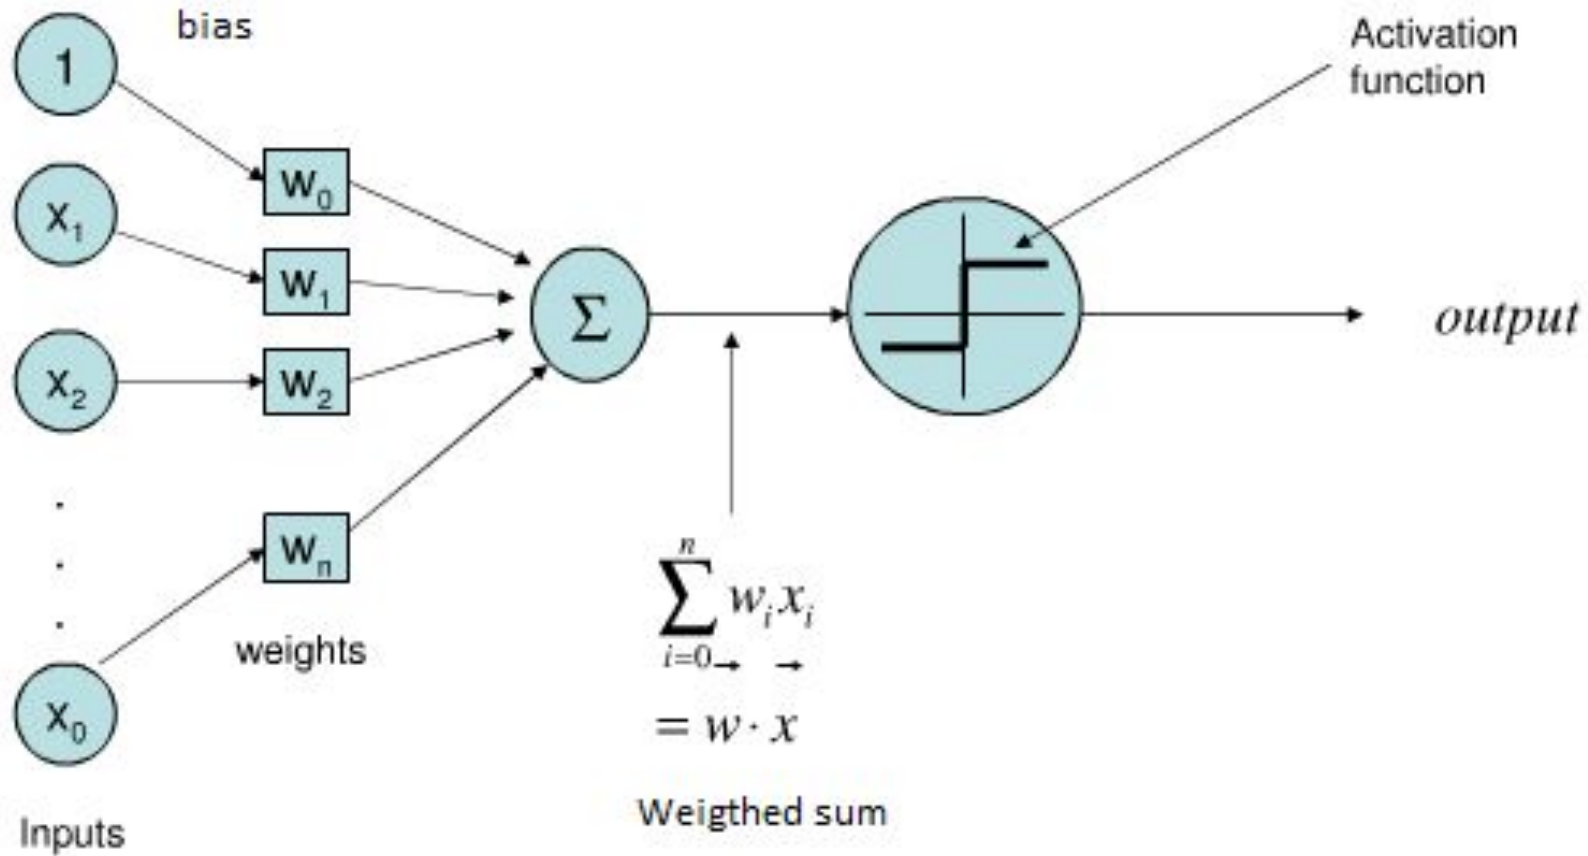
- Struktura / algoritmus / model určený pro paralelní zpracování dat, který se skládá z velkého počtu výkonných prvků - neuronů.
- Inspirován neurofyziologickými poznatky o struktuře a činnosti neuronů živých organismů.
- Schopnost extrahovat a reprezentovat závislost, učit se z předchozí zkušenosti, řešit nelineární úlohy, generalizovat znalosti.
- Aplikace: regrese, klasifikace, shluková analýza, optimalizace, predikce, filtrace, komprese dat
- Využití v reálném světě: lékařství (detekce, segmentace), radiologie, zpracování signálů, zpracování obrazů, modelování

Základní stavební jednotka – Perceptron / Neuron

- Biologický neuron: sběr, zpracování a přenos informací
- vstup (dendrity) / tělo (soma) / výstup (axon)



Perceptron - Neuron



Části perceptronu

- Vstup (Input): specifické informace (reálné číslo: velikost, barva,...)
- Váhy (Weights): důležitost informace (reálné hodnoty)
- Práhová hodnota (Bias): speciální váha s hodnotou 1
- Výstup (Output): třídy, shluky,...

- Aktivační funkce (Activation function)

Aktivační funkce (α)


- Skoková
(Step function)

- Po částech lineární
(Rectified Linear Unit function - ReLU)


- Sigmoidální
(Sigmoid function)



$$\sigma(\xi) = \begin{cases} 1 & \text{if } \xi \geq 0 \\ 0 & \text{if } \xi < 0 \end{cases}$$

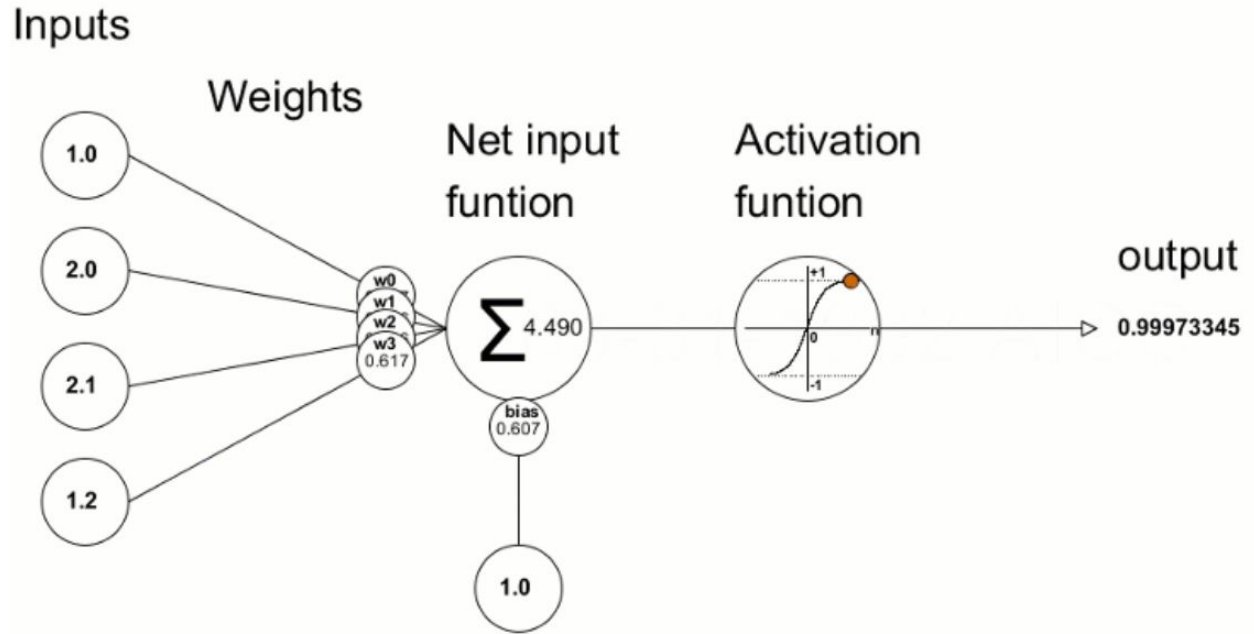
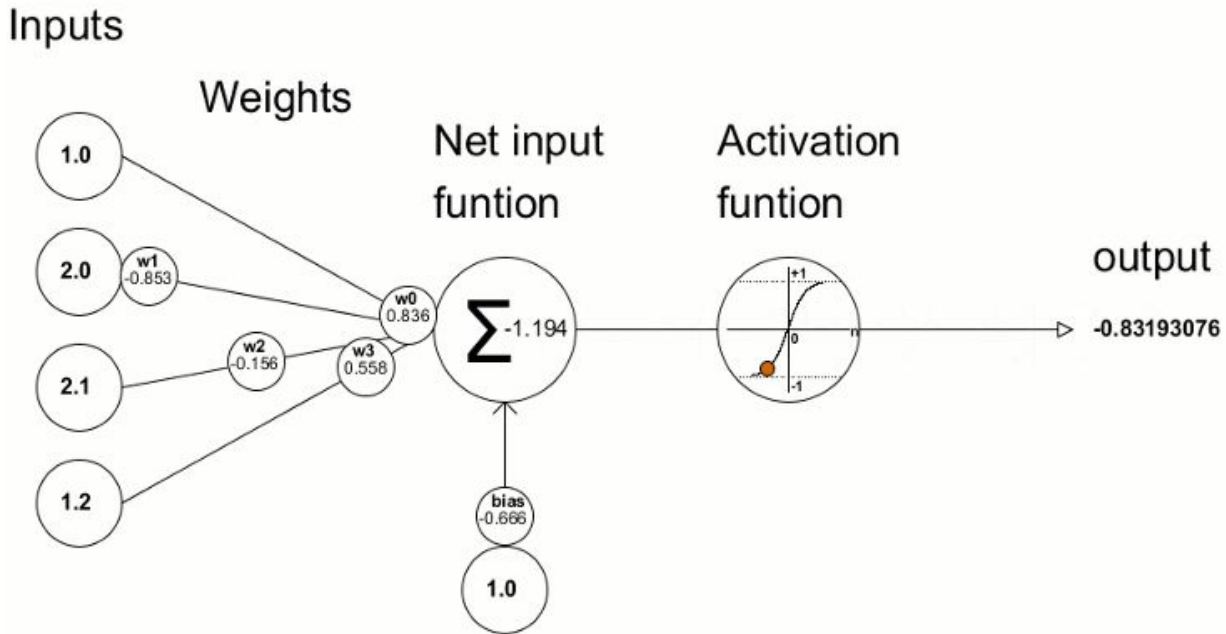


$$\sigma(\xi) = \begin{cases} 1 & \xi > 1 \\ \xi & 0 \leq \xi \leq 1 \\ 0 & \xi < 0 \end{cases}$$





$$\sigma(\xi) = \frac{1}{1 + e^{-\xi}}$$

Příklad fungování perceptronu (tan-sigmoid)



Perceptron

- Schopný klasifikace do dvou tříd – třídy musí být lineárně separované



Proces výpočtu (Perceptron)

$$y(t) = \text{sgn} \left(\sum_{i=0}^n w_i(t)x_i(t) \right)$$

- 1. Inicializace vah $w_i(t)$
- 2. Výpočet sítě $y_i(t)$
- 3. Adaptace vah
 - Výstup je stejný:
 - Výstup je 0, měl by být 1:
 - Výstup je 1, měl by být 0:

$$w_i(t + 1) = w_i(t)$$

$$w_i(t + 1) = w_i(t) + \eta x_i(t)$$





$$w_i(t + 1) = w_i(t) - \eta x_i(t)$$

Adaptace vah, zobecnění:

$$\delta = z(t) - y(t)$$

$$w_i(t + 1) = w_i(t) - \eta \delta x_i(t)$$


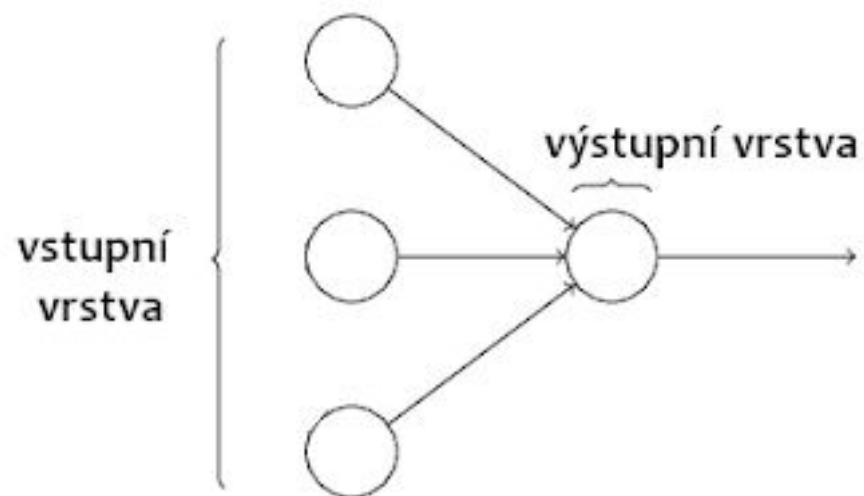
$z(t) =$ očekávaný výstup





Rozdělení neuronových sítí

- Podle počtu vrstev:
 - Jednovrstvé (Hopfieldova síť)
 - Vícevrstvé (MLP, Konvoluční síť)
- Podle směru trénování:
 - Dopředné (Feed-forward)
 - Rekurentní (Recurrent)
- Podle algoritmů učení:
 - S učitelem (Supervised)
 - Bez učitele (Unsupervised)
- Podle stylu učení:
 - Deterministické (Backpropagation)
 - Stochastické (Náhodné nastavování vah)

Jednovrstvé / Vícevrstvé




Dopředné / Rekurentní



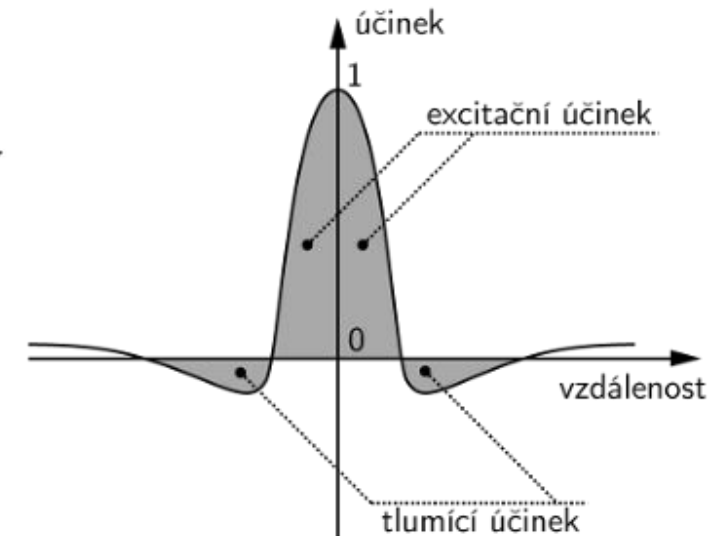
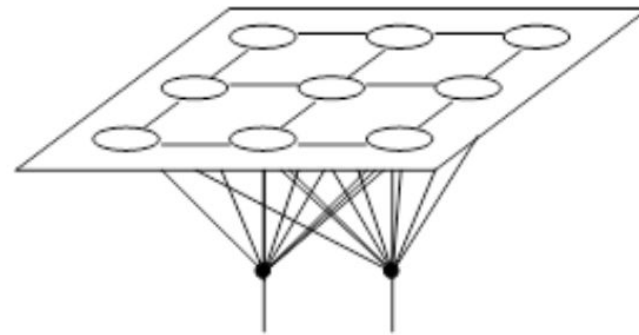

Hopfieldova síť



- Jednovrstvá, rekurentní (zpětnovazební) síť
- Zapamatování vstupních vzorů, vybavování
- Výstup neuronu je připojen na vstupy všech ostatních kromě jeho samotného.
- Použití: asociativní paměť, klasifikátor, optimalizace





Samooorganizující se neuronové síť / Kohonenova (SOM - Self Organizing Map)

- jednovrstvá síť s dopředným šířením,
- učící algoritmus ve variantě "učení bez učitele" provádí pouze analýzu vstupních dat (shlukovou analýzu)
- neuronová síť obsahuje jedinou vrstvu neuronů (mřížka)






Iteration 1



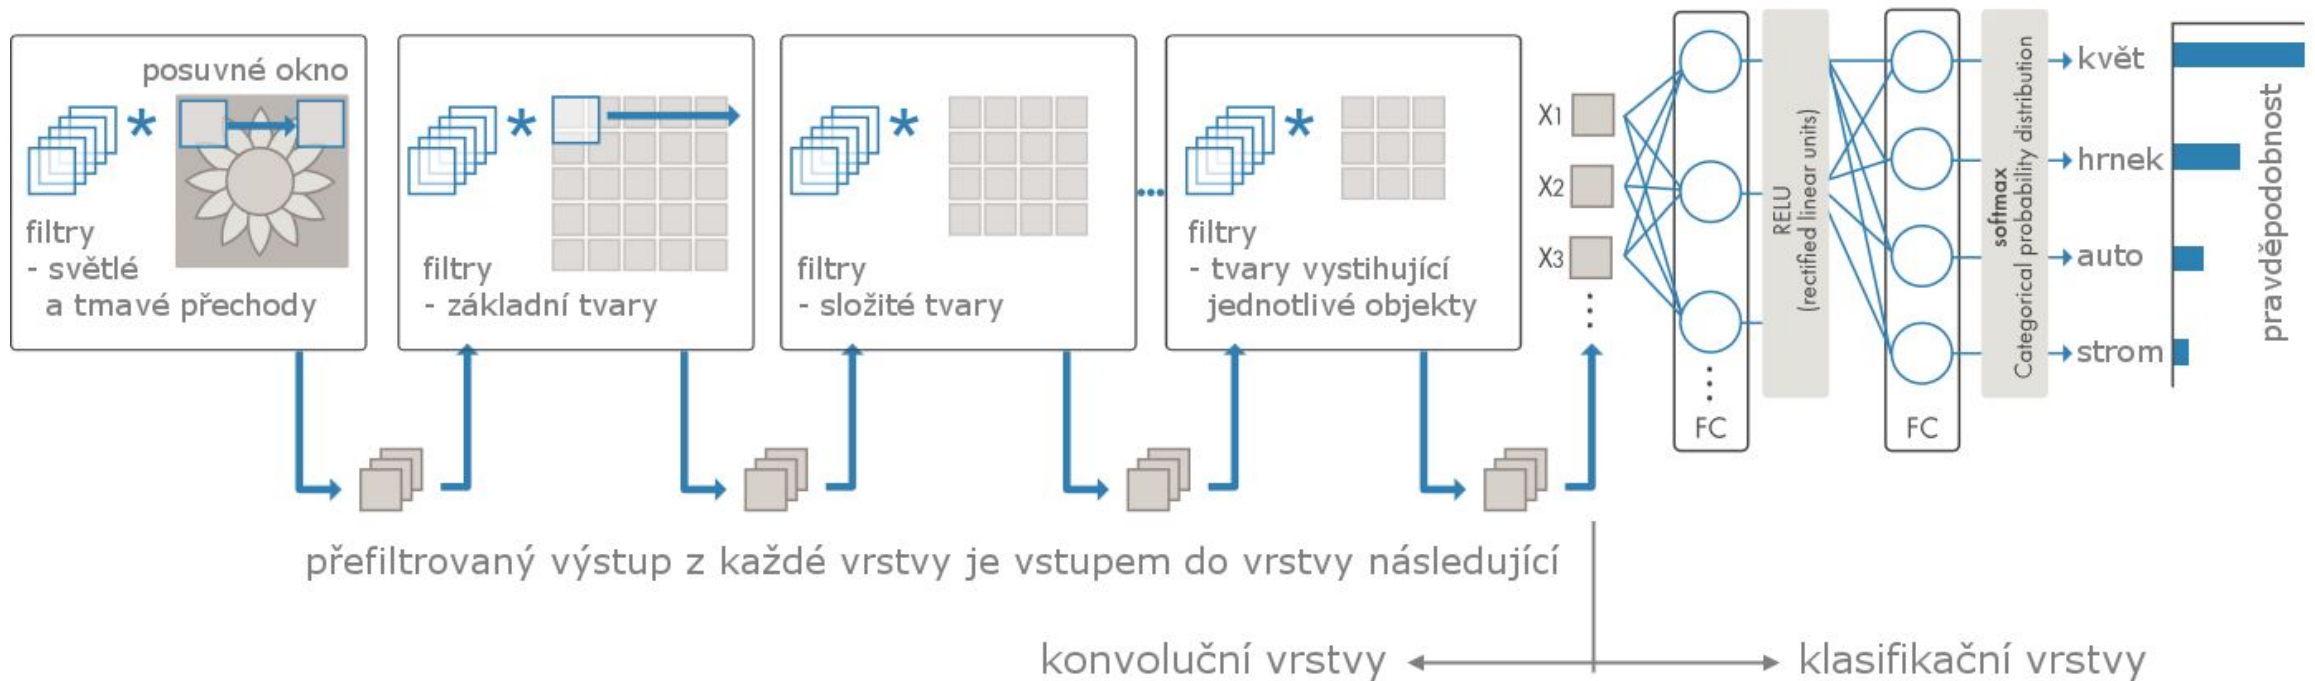
Vícevrstevná neuronová síť (MLP – Multi Layer Perceptron)

- Vstupní – Skrytá – Výstupní vrstva
- Nejpoužívanější neuronová síť
- Použití: predikce, klasifikace, aproximace



Konvoluční neuronová síť

- Vícevrstevná síť
- Vstupní – Skrytá – Výstupní vrstva
- Použití: klasifikace



Konvoluce

Obrázek 14.11. Zaostření

0	0	0	0	0
0	0	-1	0	0
0	-1	5	-1	0
0	0	-1	0	0
0	0	0	0	0



Konvoluce

Obrázek 14.12. Rozmazání


0	0	0	0	0
0	1	1	1	0
0	1	1	1	0
0	1	1	1	0
0	0	0	0	0



Konvoluce

Obrázek 14.14. Detekce hran

	0	1	0	
	1	-4	1	
	0	1	0	



Konvoluce

7	2	3	3	8
4	5	3	8	4
3	3	2	8	4
2	8	7	2	7
5	4	4	5	4

*

1	0	-1
1	0	-1
1	0	-1

=


6		

$$\begin{aligned} &7 \times 1 + 4 \times 1 + 3 \times 1 + \\ &2 \times 0 + 5 \times 0 + 3 \times 0 + \\ &3 \times -1 + 3 \times -1 + 2 \times -1 \\ &= 6 \end{aligned}$$

Vytváření neuronové sítě

1. Inicializace parametrů (váhy, bias)
2. Definování aktivační funkce (Sigmoid, ReLU)
3. Definování chybové funkce (MSE, CE)
4. Dopředné šíření (Forward Propagation)
5. Počítání chyby
6. Zpětné šíření chyby (Back Propagation)
7. Úprava vah
8. Nová iterace (zpět na krok č. 4)


Fungování neuronové sítě



28

$$28 \times 28 = 784$$

28




0.58

“Activation”



784



0.97

9



=



+



=



+




=



+





+






784





784



$$w_1 a_1 + w_2 a_2 + w_3 a_3 + w_4 a_4 + \dots + w_n a_n$$

$$w_1: 2.07$$

$$w_2: 2.31$$

$$w_3: 3.64$$

$$w_4: 1.87$$


$$w_5: -1.51$$

$$w_6: -0.43$$


$$w_7: 2.01$$

$$w_8: 1.07$$


⋮



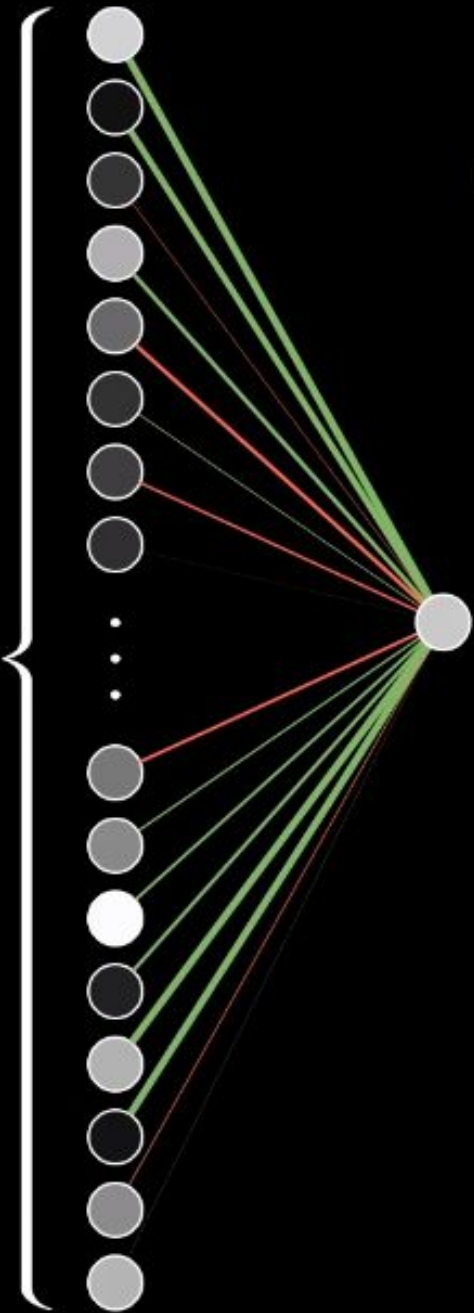
$$w_1 a_1 + w_2 a_2 + w_3 a_3 + w_4 a_4 + \dots + w_n a_n$$



Activations should be in this range




784




$$\sigma(w_1 a_1 + w_2 a_2 + w_3 a_3 + \dots + w_n a_n \boxed{-10})$$

“bias”

Only activate meaningfully
when **weighted sum** > 10





$$784 \times 16 + 16 \times 16 + 16 \times 10$$


weights

$$16 + 16 + 10$$

biases

13,002

Learning \rightarrow Finding the right weights and biases




Sigmoid

$$a_0^{(1)} = \sigma \left(w_{0,0} a_0^{(0)} + w_{0,1} a_1^{(0)} + \dots + w_{0,n} a_n^{(0)} + b_0 \right)$$

↑
Bias


$$\sigma \left(\begin{bmatrix} w_{0,0} & w_{0,1} & \dots & w_{0,n} \\ w_{1,0} & w_{1,1} & \dots & w_{1,n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{k,0} & w_{k,1} & \dots & w_{k,n} \end{bmatrix} \begin{bmatrix} a_0^{(0)} \\ a_1^{(0)} \\ \vdots \\ a_n^{(0)} \end{bmatrix} + \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_n \end{bmatrix} \right)$$

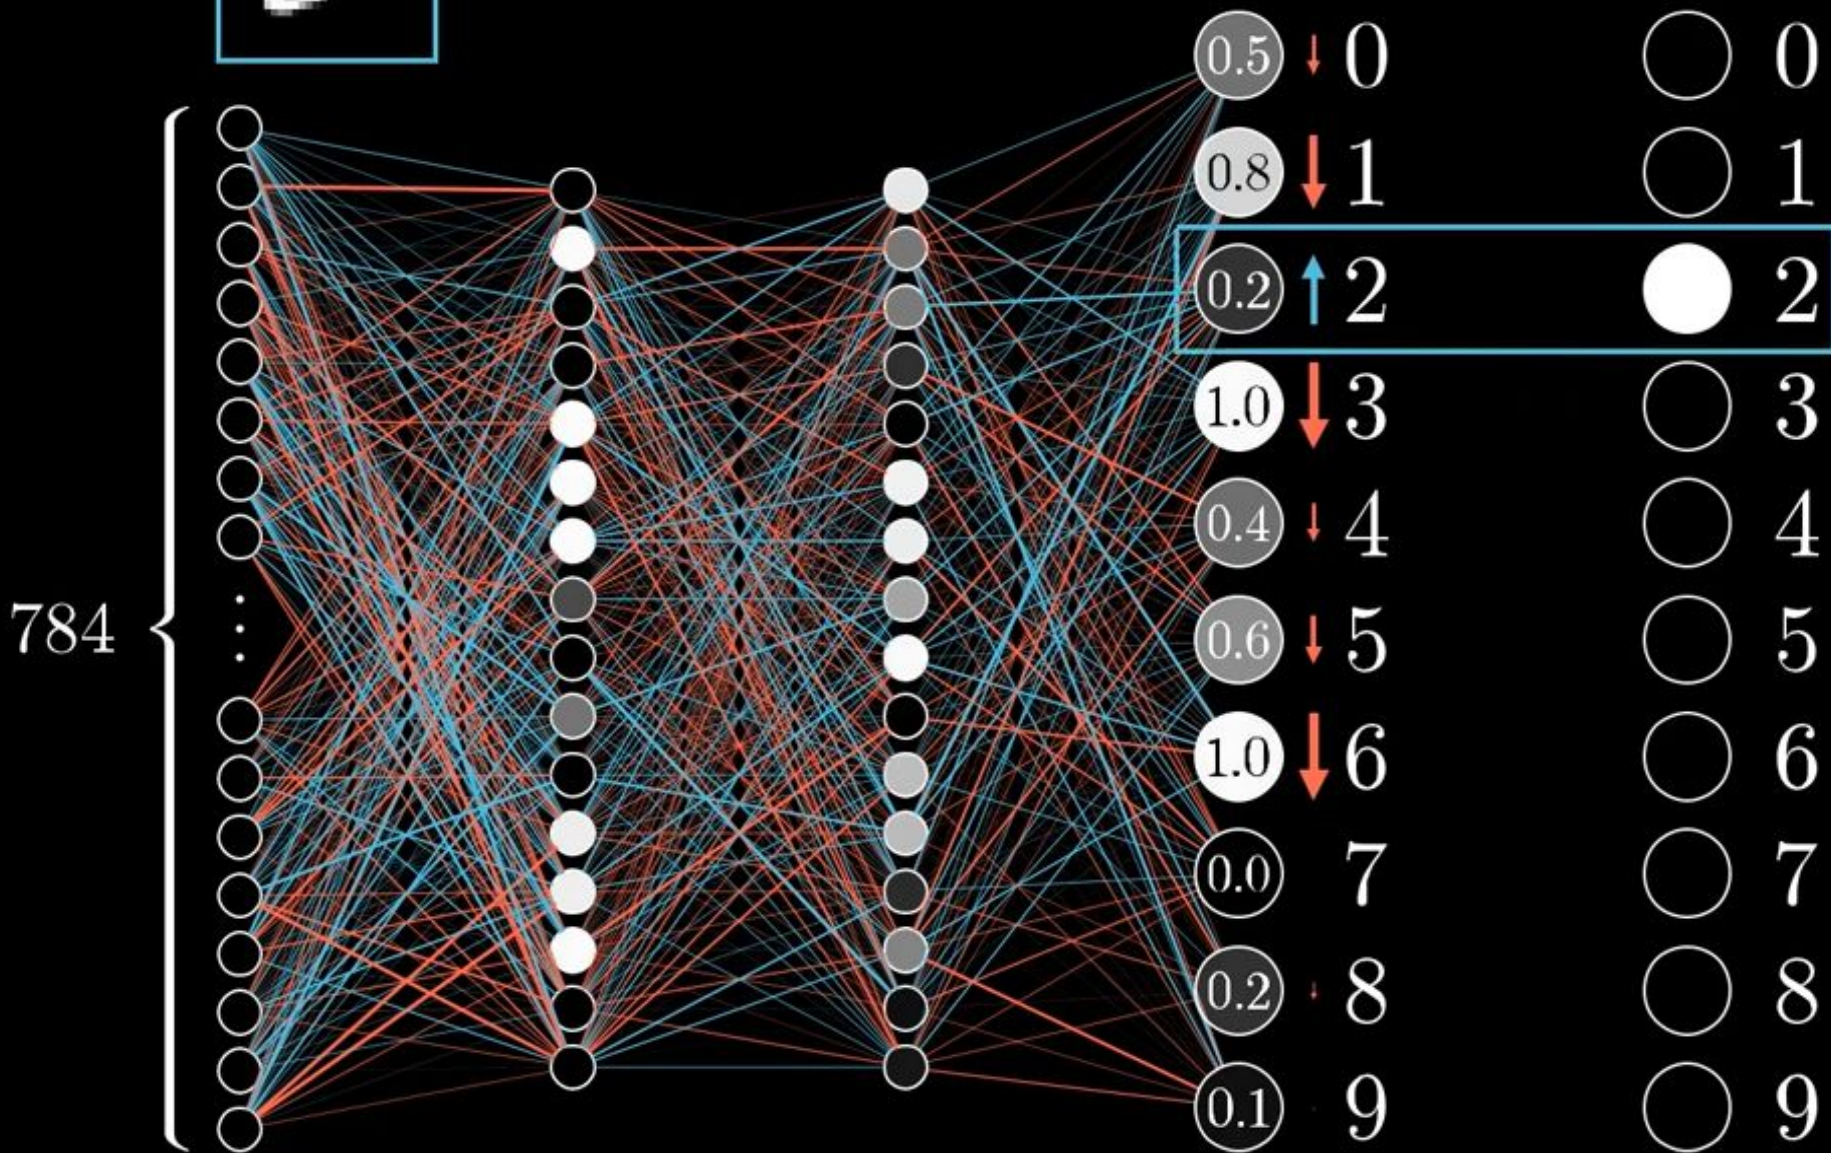
Učení Neuronové sítě





You can only adjust weights and biases








$$\textcircled{0.2} = \sigma(w_0 a_0 + w_1 a_1 + \dots + w_{n-1} a_{n-1} + b)$$

Increase b

Increase w_i

Change a_i






Increase b

Increase w_i
in proportion to a_i

Change a_i
in proportion to w_i




Cost of **3**

3.37

0.1863	←	$(0.43 - 0.00)^2 +$
0.0809	←	$(0.28 - 0.00)^2 +$
0.0357	←	$(0.19 - 0.00)^2 +$
0.0138	←	$(0.88 - 1.00)^2 +$
0.5242	←	$(0.72 - 0.00)^2 +$
0.0001	←	$(0.01 - 0.00)^2 +$
0.4079	←	$(0.64 - 0.00)^2 +$
0.7388	←	$(0.86 - 0.00)^2 +$
0.9817	←	$(0.99 - 0.00)^2 +$
0.3998	←	$(0.63 - 0.00)^2$

What's the "cost" of this difference?





Cost of **3**


0.03

0.0006 ← $(0.02 - 0.00)^2 +$
0.0007 ← $(0.03 - 0.00)^2 +$
0.0039 ← $(0.06 - 0.00)^2 +$
0.0009 ← $(0.97 - 1.00)^2 +$
0.0055 ← $(0.07 - 0.00)^2 +$
0.0004 ← $(0.02 - 0.00)^2 +$
0.0022 ← $(0.05 - 0.00)^2 +$
0.0033 ← $(0.06 - 0.00)^2 +$
0.0072 ← $(0.08 - 0.00)^2 +$
0.0018 ← $(0.04 - 0.00)^2$

What's the "cost" of this difference?








Compute ∇C

Small step in $-\nabla C$ direction

Repeat.



$$\vec{W} = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \\ \vdots \\ w_{13,000} \\ w_{13,001} \\ w_{13,002} \end{bmatrix}$$

$$-\nabla C(\vec{W}) = \begin{bmatrix} 0.31 \\ 0.03 \\ -1.25 \\ \vdots \\ 0.78 \\ -0.37 \\ 0.16 \end{bmatrix}$$

w_0 should increase somewhat
 w_1 should increase a little
 w_2 should decrease a lot

$w_{13,000}$ should increase a lot
 $w_{13,001}$ should decrease somewhat
 $w_{13,002}$ should increase a little


Minimize cost ...

Cost of




$$\left\{ \begin{array}{l} (0.05 - 0.00)^2 + \\ (0.02 - 0.00)^2 + \\ (0.07 - 0.00)^2 + \\ (0.88 - 1.00)^2 + \\ (0.11 - 0.00)^2 + \\ (0.63 - 0.00)^2 + \\ (0.14 - 0.00)^2 + \\ (0.73 - 0.00)^2 + \\ (0.57 - 0.00)^2 + \\ (0.13 - 0.00)^2 \end{array} \right.$$

What's the “cost”
of this difference?



Gradient descent




Testing data




Guess \rightarrow 4

$$\frac{\text{Number correct}}{\text{total}} = \frac{238}{249} = 0.956$$



Algoritmus zpětného šíření (Back propagation)



Vstup – Skryté
vrstvy – Výstup



Výpočet chyby



Zpětné šíření
chyby



Úprava vah

Řetězové pravidlo (Chain rule)

- Pravidlo o derivaci složené funkce – zjednodušení výpočtu derivace
- Úprav vah: $w_{i+1} = w_i - \eta \nabla G(w_i)$

Back Propagation

$$C(w_1, b_1, w_2, b_2, w_3, b_3)$$

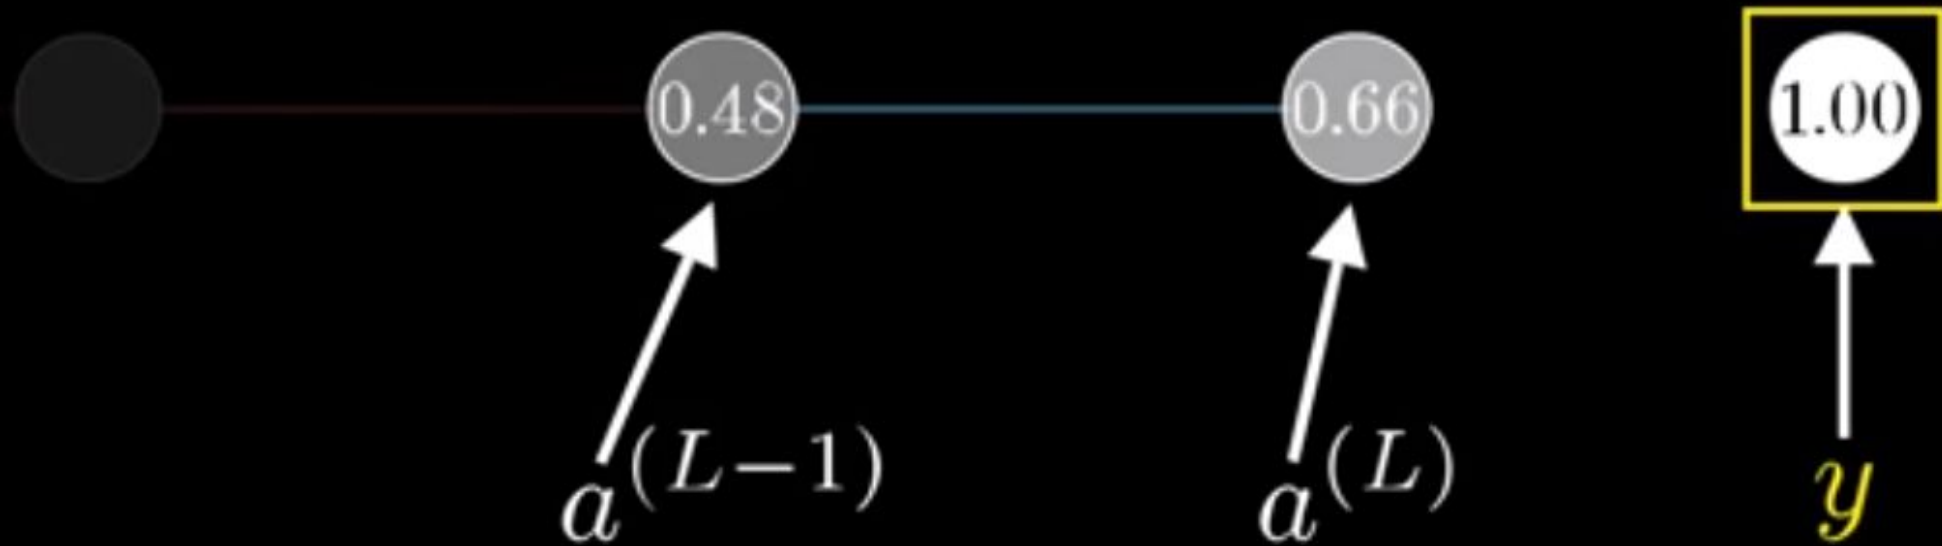


$$\text{Cost} \longrightarrow C_0(\dots) = (a^{(L)} - y)^2$$

$$z^{(L)} = w^{(L)} a^{(L-1)} + b^{(L)}$$

$$a^{(L)} = \sigma(z^{(L)})$$

Desired
output





Cost $\longrightarrow C_0(\dots) = (a^{(L)} - y)^2$

$$z^{(L)} = w^{(L)} a^{(L-1)} + b^{(L)}$$

$$a^{(L)} = \sigma(z^{(L)})$$

Desired
output



$$\frac{\partial C_0}{\partial w^{(L)}} = \frac{\partial z^{(L)}}{\partial w^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}} \frac{\partial C_0}{\partial a^{(L)}}$$



Chain rule

$$C_0(\dots) = (a^{(L)} - y)^2$$

$$z^{(L)} = w^{(L)} a^{(L-1)} + b^{(L)}$$

$$a^{(L)} = \sigma(z^{(L)})$$

Desired output



$$\frac{\partial C_0}{\partial w^{(L)}} = \frac{\partial z^{(L)}}{\partial w^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}} \frac{\partial C_0}{\partial a^{(L)}}$$

$$C_0 = (a^{(L)} - y)^2$$


$$z^{(L)} = w^{(L)} a^{(L-1)} + b^{(L)}$$

$$\frac{\partial C_0}{\partial a^{(L)}} = 2(a^{(L)} - y)$$

$$a^{(L)} = \sigma(z^{(L)})$$

$$\frac{\partial a^{(L)}}{\partial z^{(L)}} = \sigma'(z^{(L)})$$

$$\frac{\partial z^{(L)}}{\partial w^{(L)}} = a^{(L-1)}$$




$$\frac{\partial C_0}{\partial w^{(L)}} = \frac{\partial z^{(L)}}{\partial w^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}} \frac{\partial C_0}{\partial a^{(L)}} = a^{(L-1)} \sigma'(z^{(L)}) 2(a^{(L)} - y)$$

$$\nabla C = \begin{bmatrix} \frac{\partial C}{\partial w^{(1)}} \\ \frac{\partial C}{\partial b^{(1)}} \\ \vdots \\ \frac{\partial C}{\partial w^{(L)}} \\ \frac{\partial C}{\partial b^{(L)}} \end{bmatrix}$$

$$C_0 = (a^{(L)} - y)^2$$

$$z^{(L)} = w^{(L)} a^{(L-1)} + b^{(L)}$$

$$a^{(L)} = \sigma(z^{(L)})$$



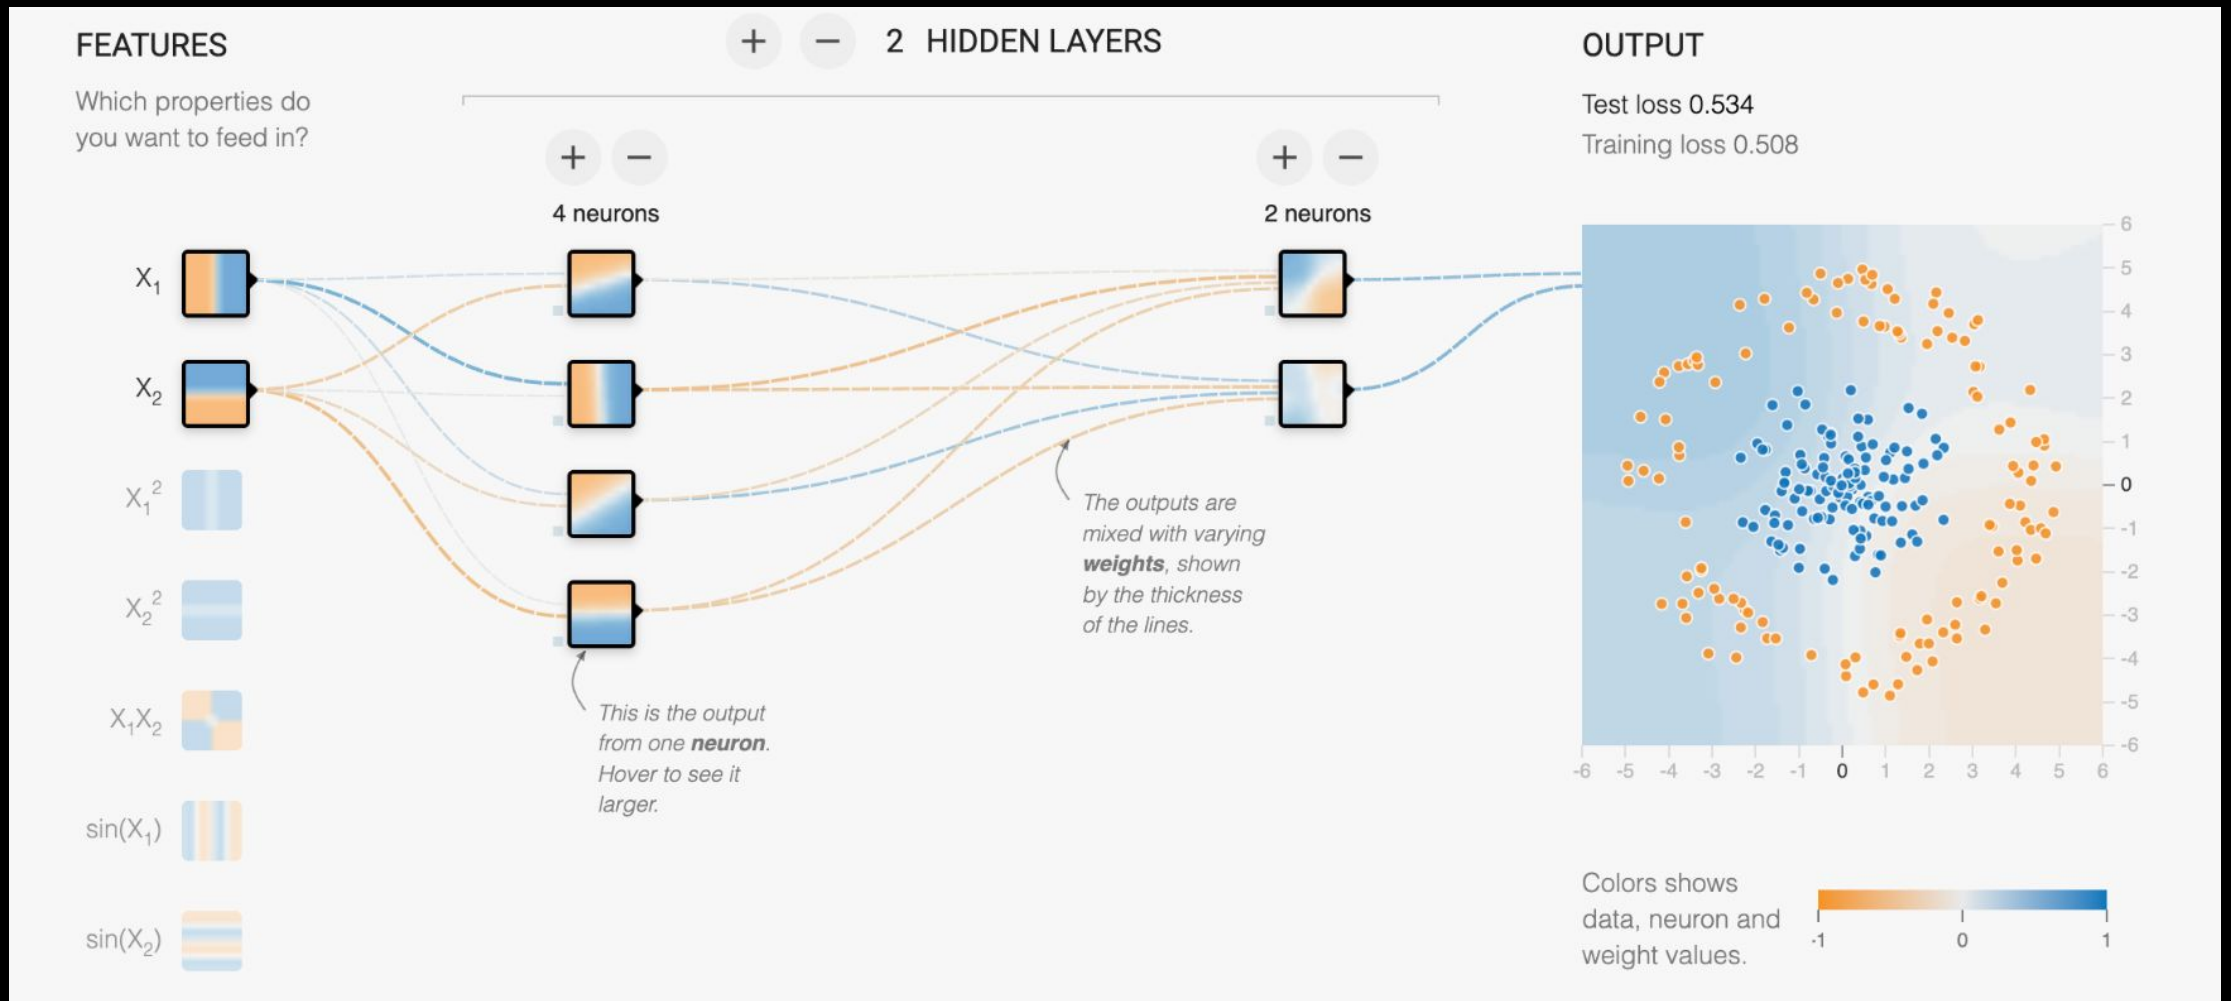
Chybové funkce

- Čtvercová chyba (MSE - Mean Squared Error)
- Křížová entropie (CE - Cross-Entropy)

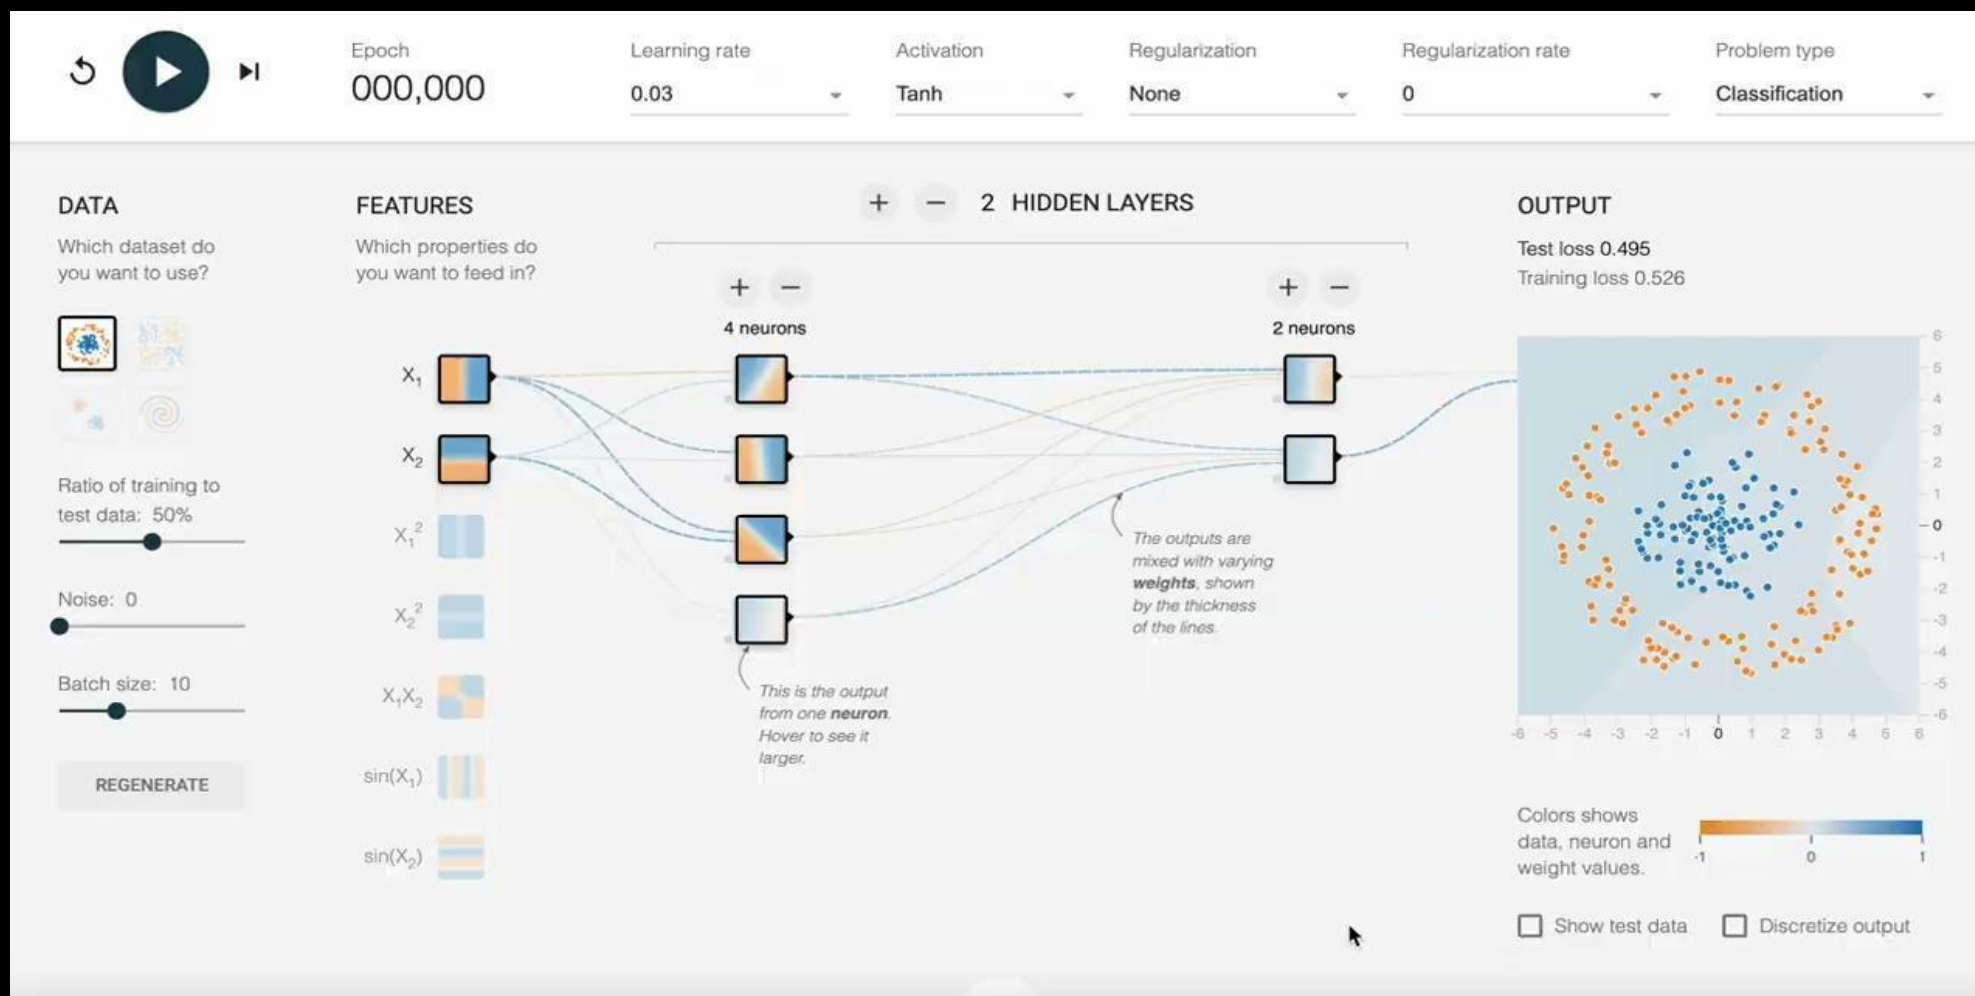
$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

$$L = -\frac{1}{m} \sum_{i=1}^m y_i \cdot \log(\hat{y}_i)$$

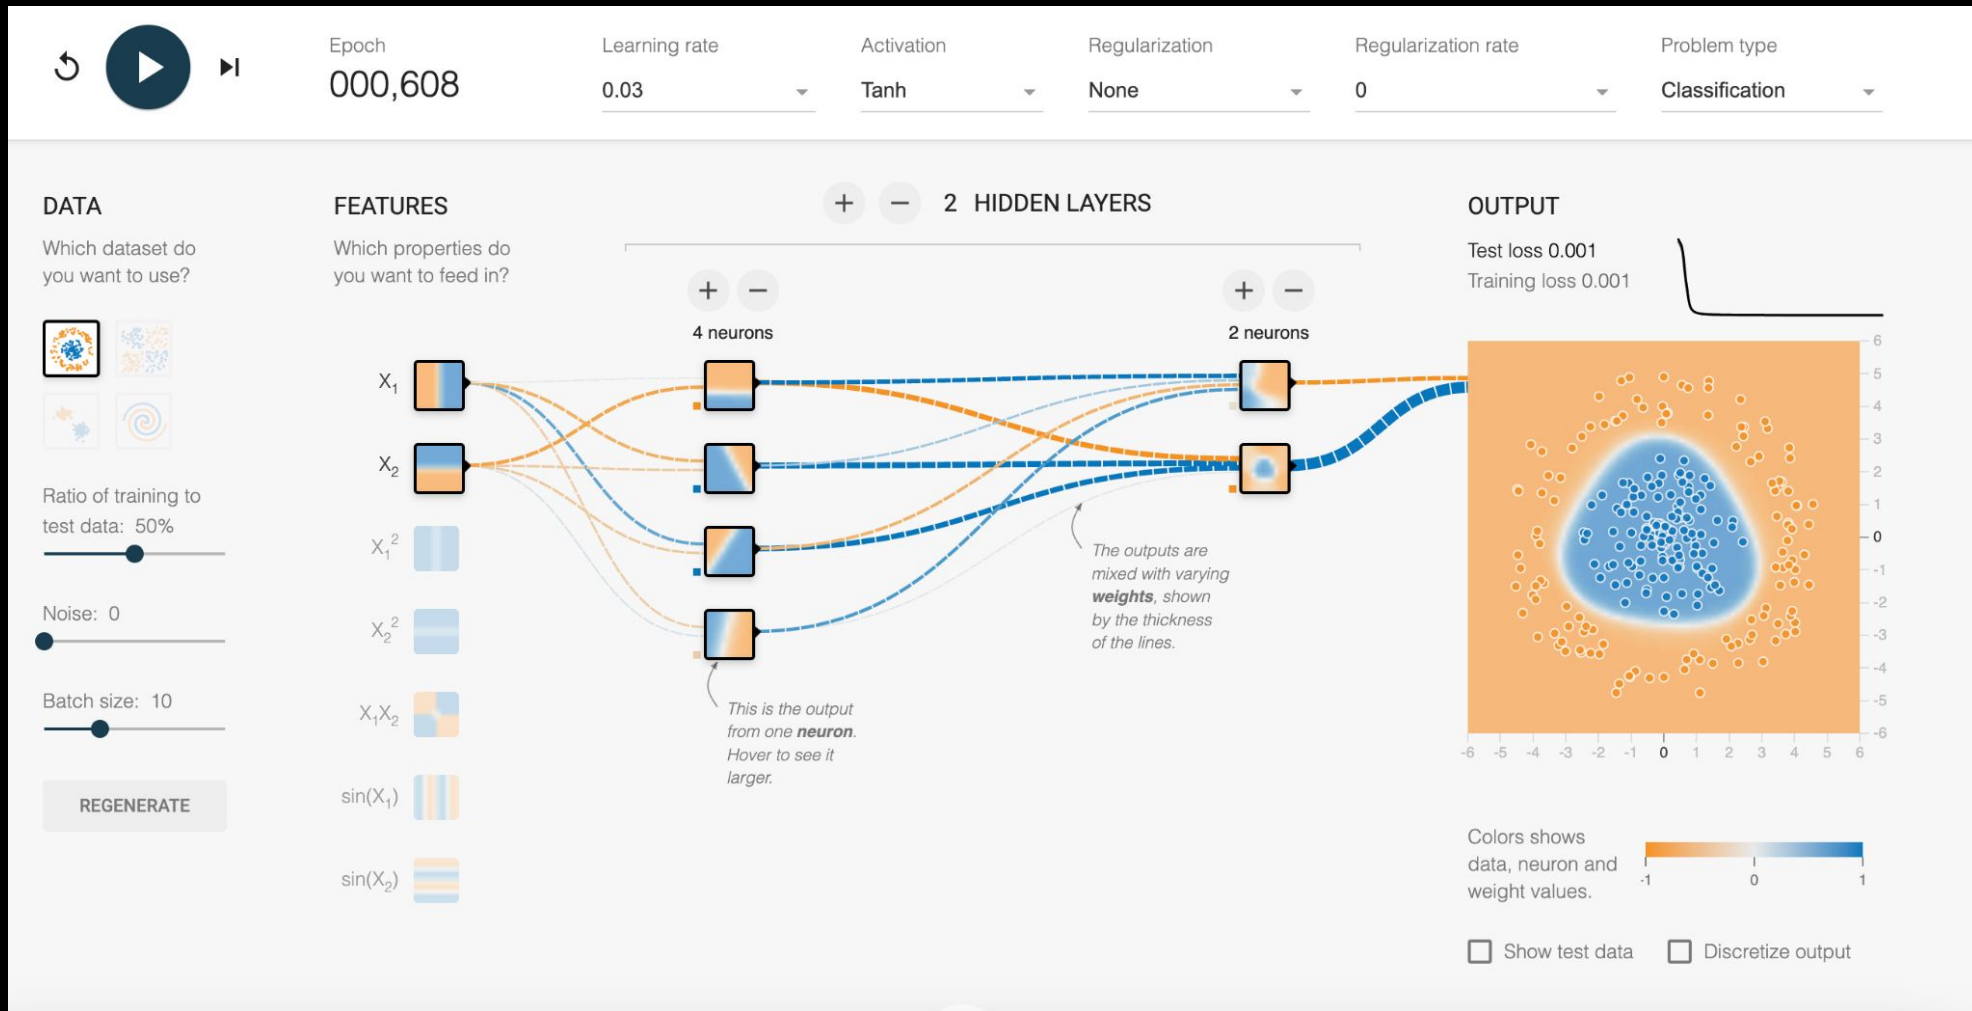
Jak se neuronová síť učí?



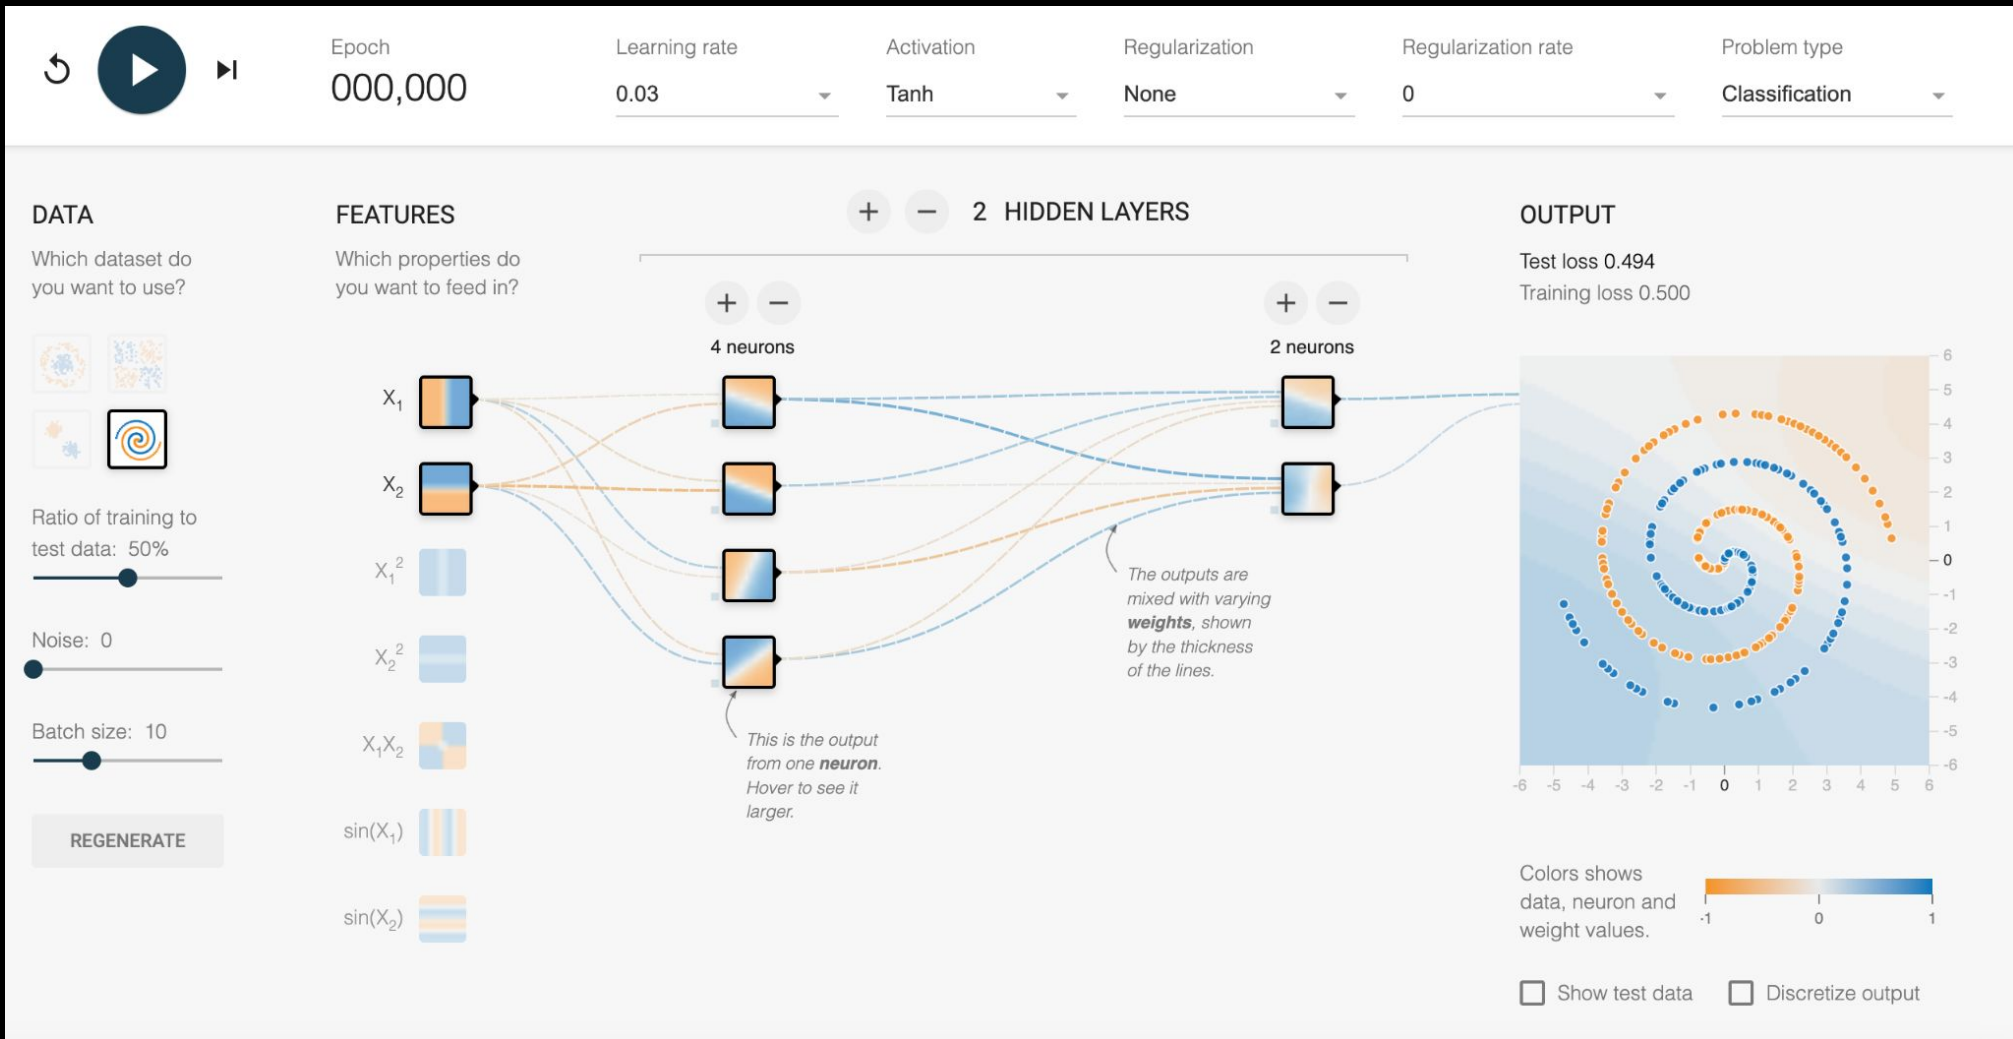
Jak se neuronová síť učí?



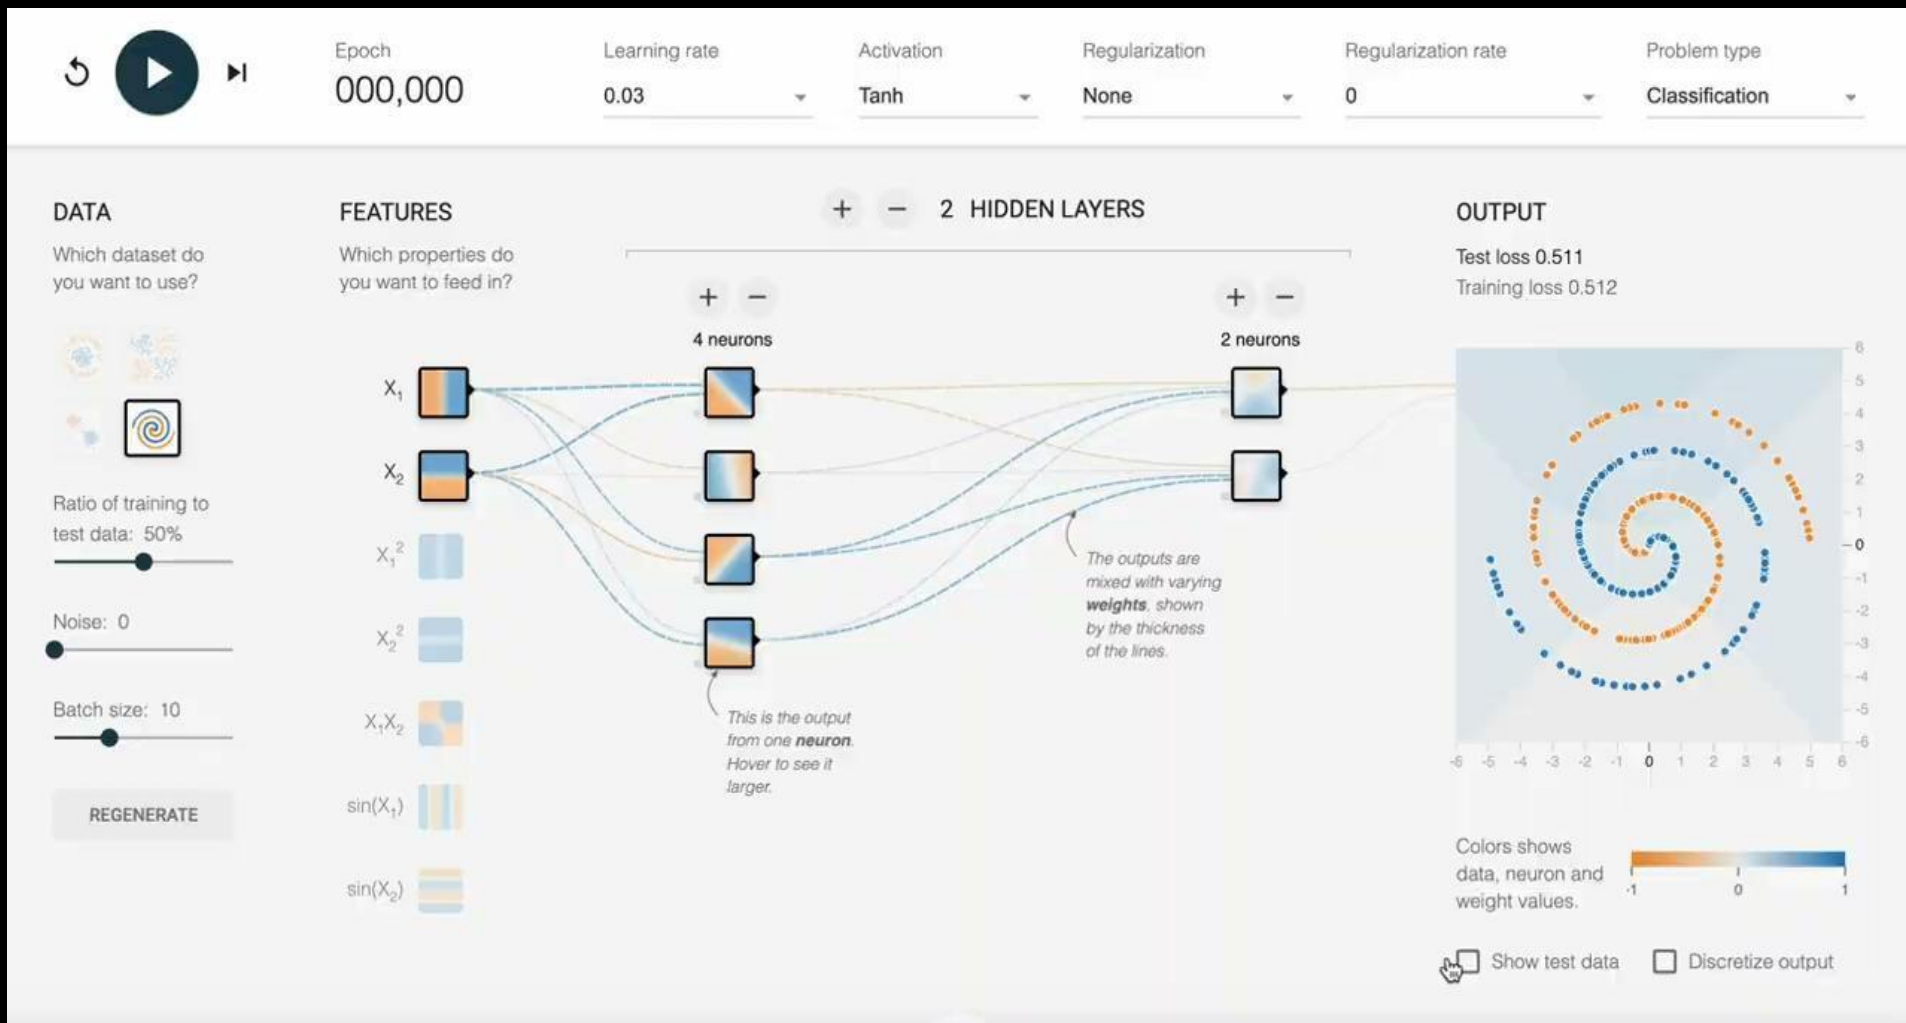
Jak se neuronová síť učí?



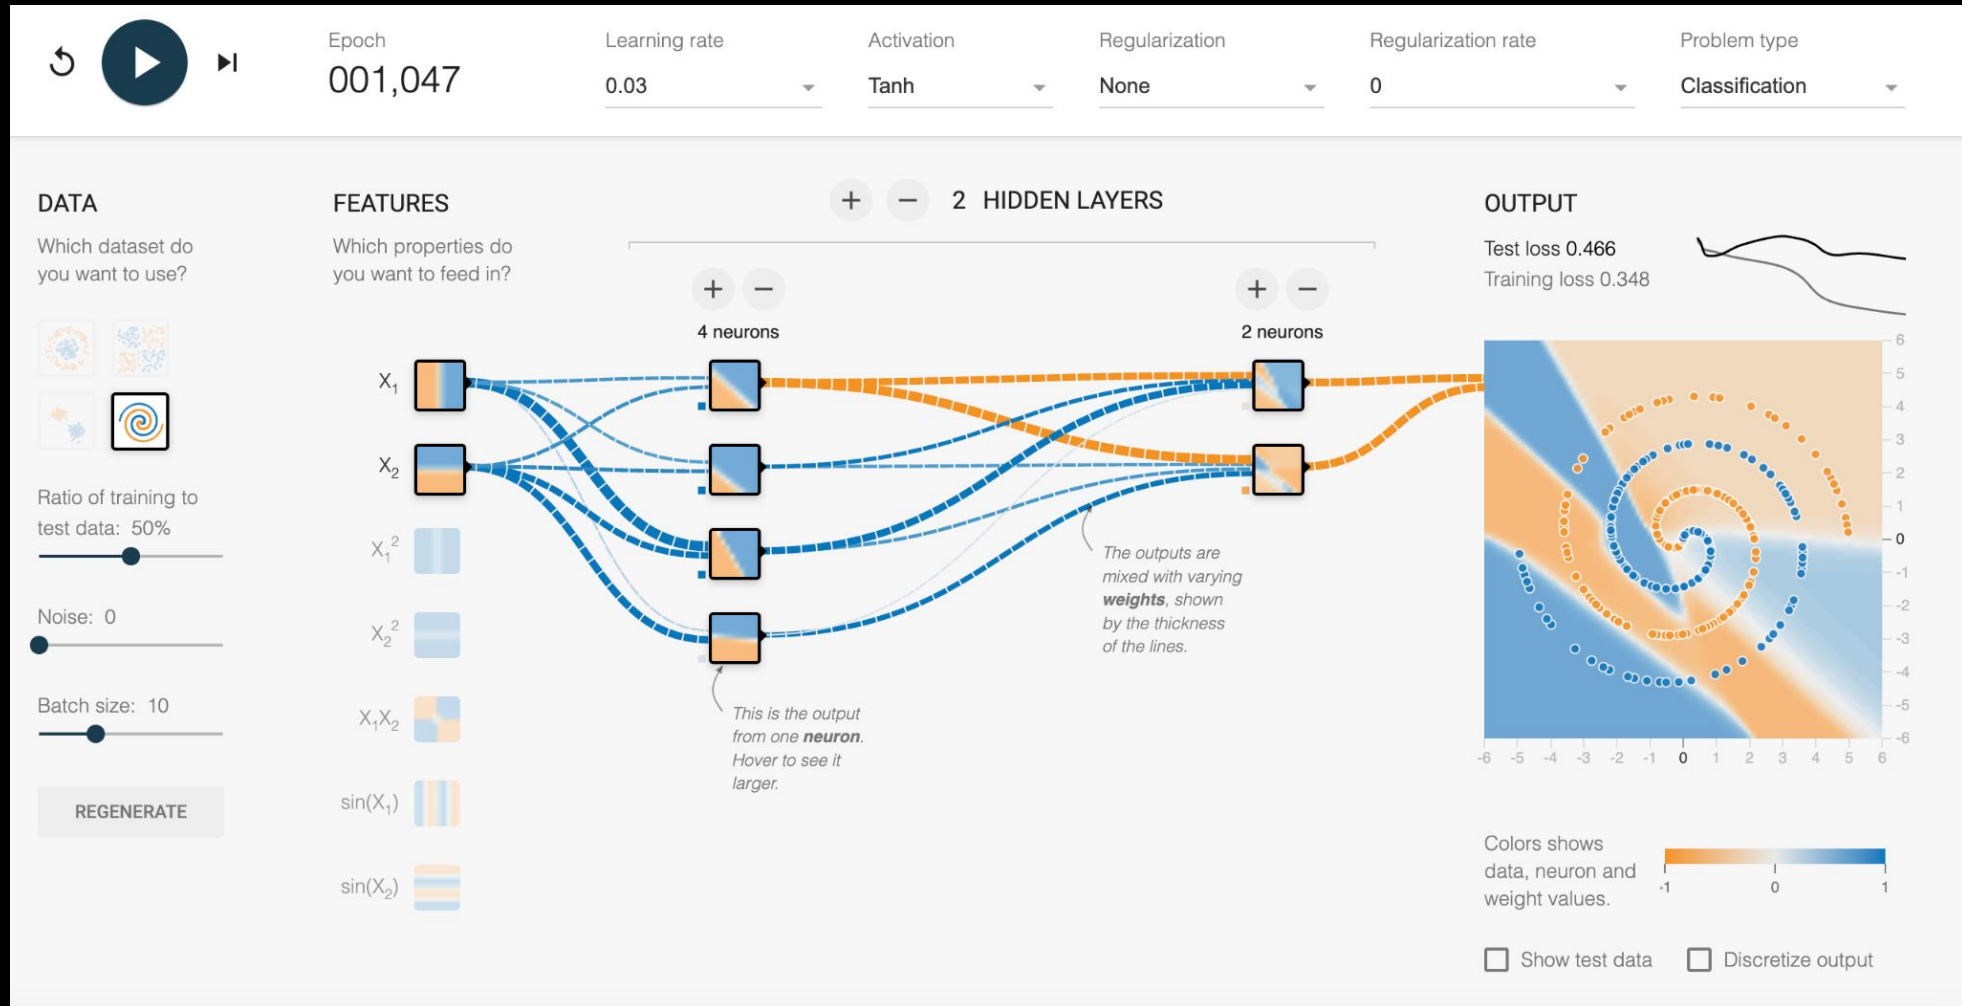
Jak se neuronová síť učí?



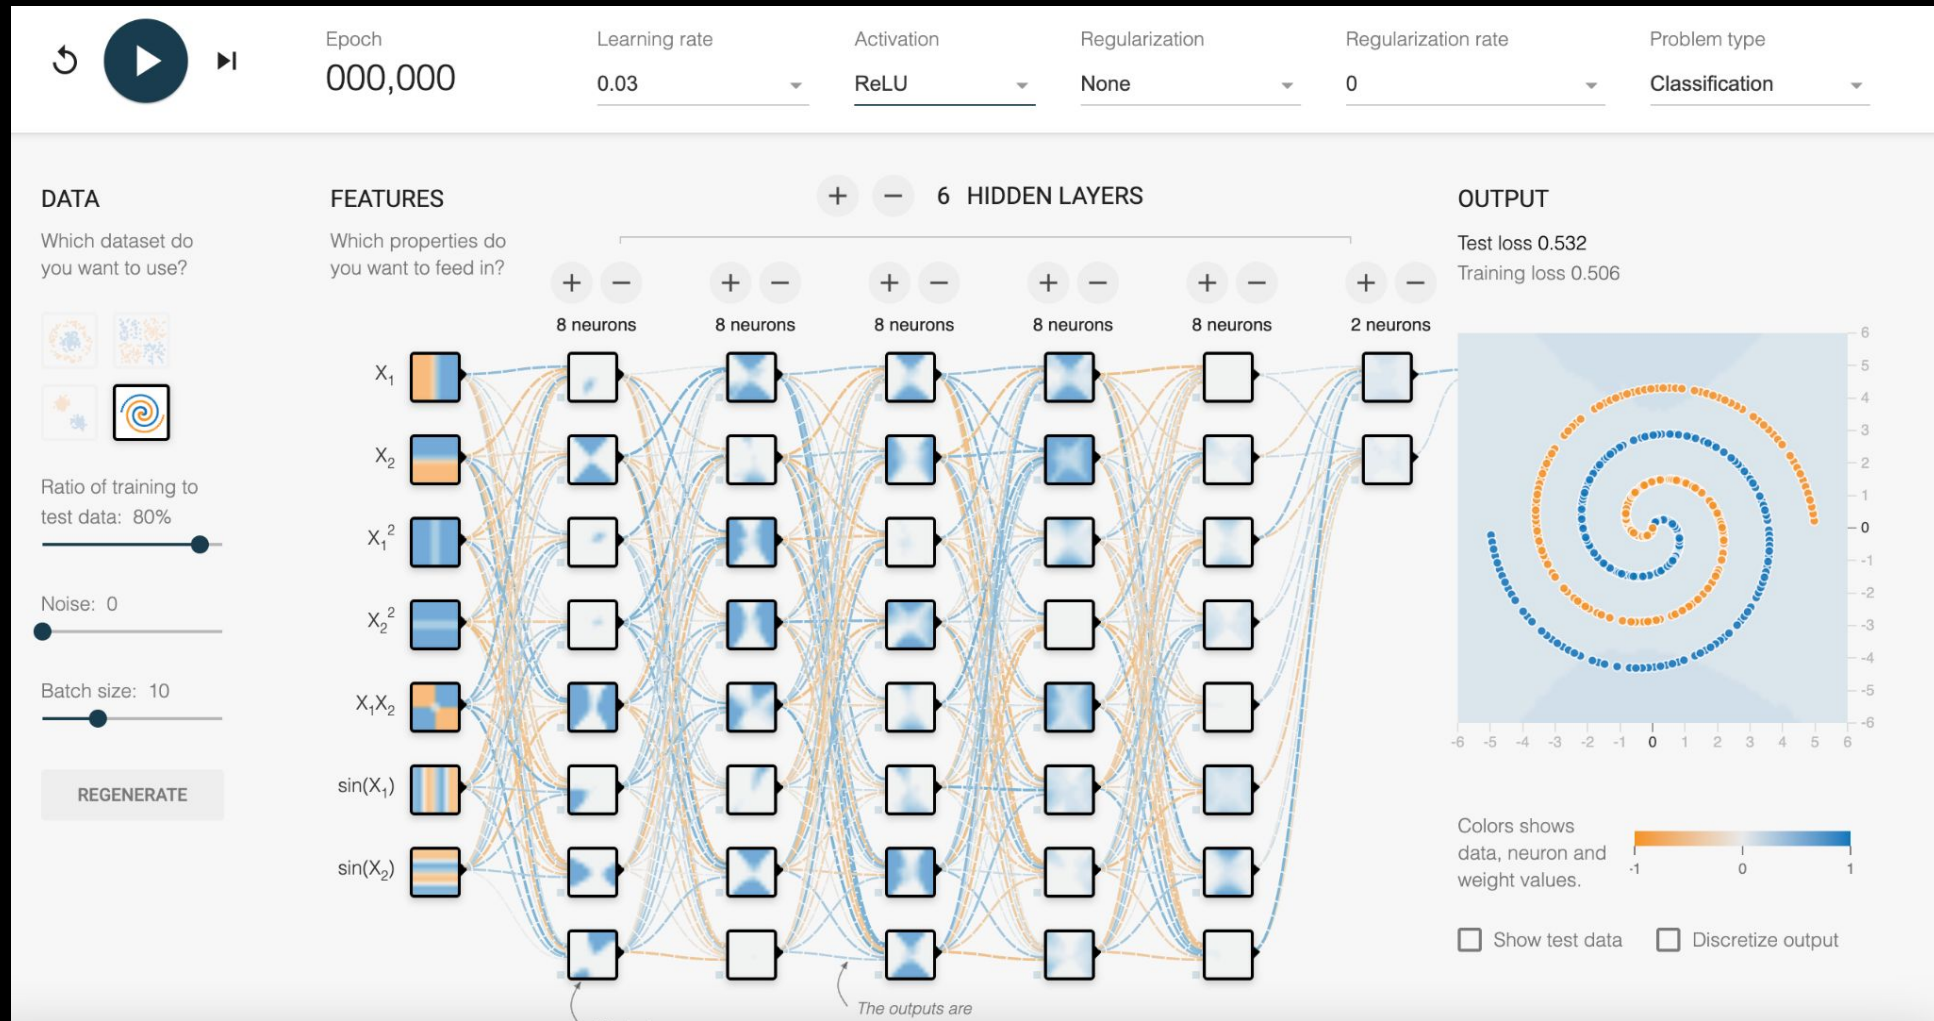
Jak se neuronová síť učí?



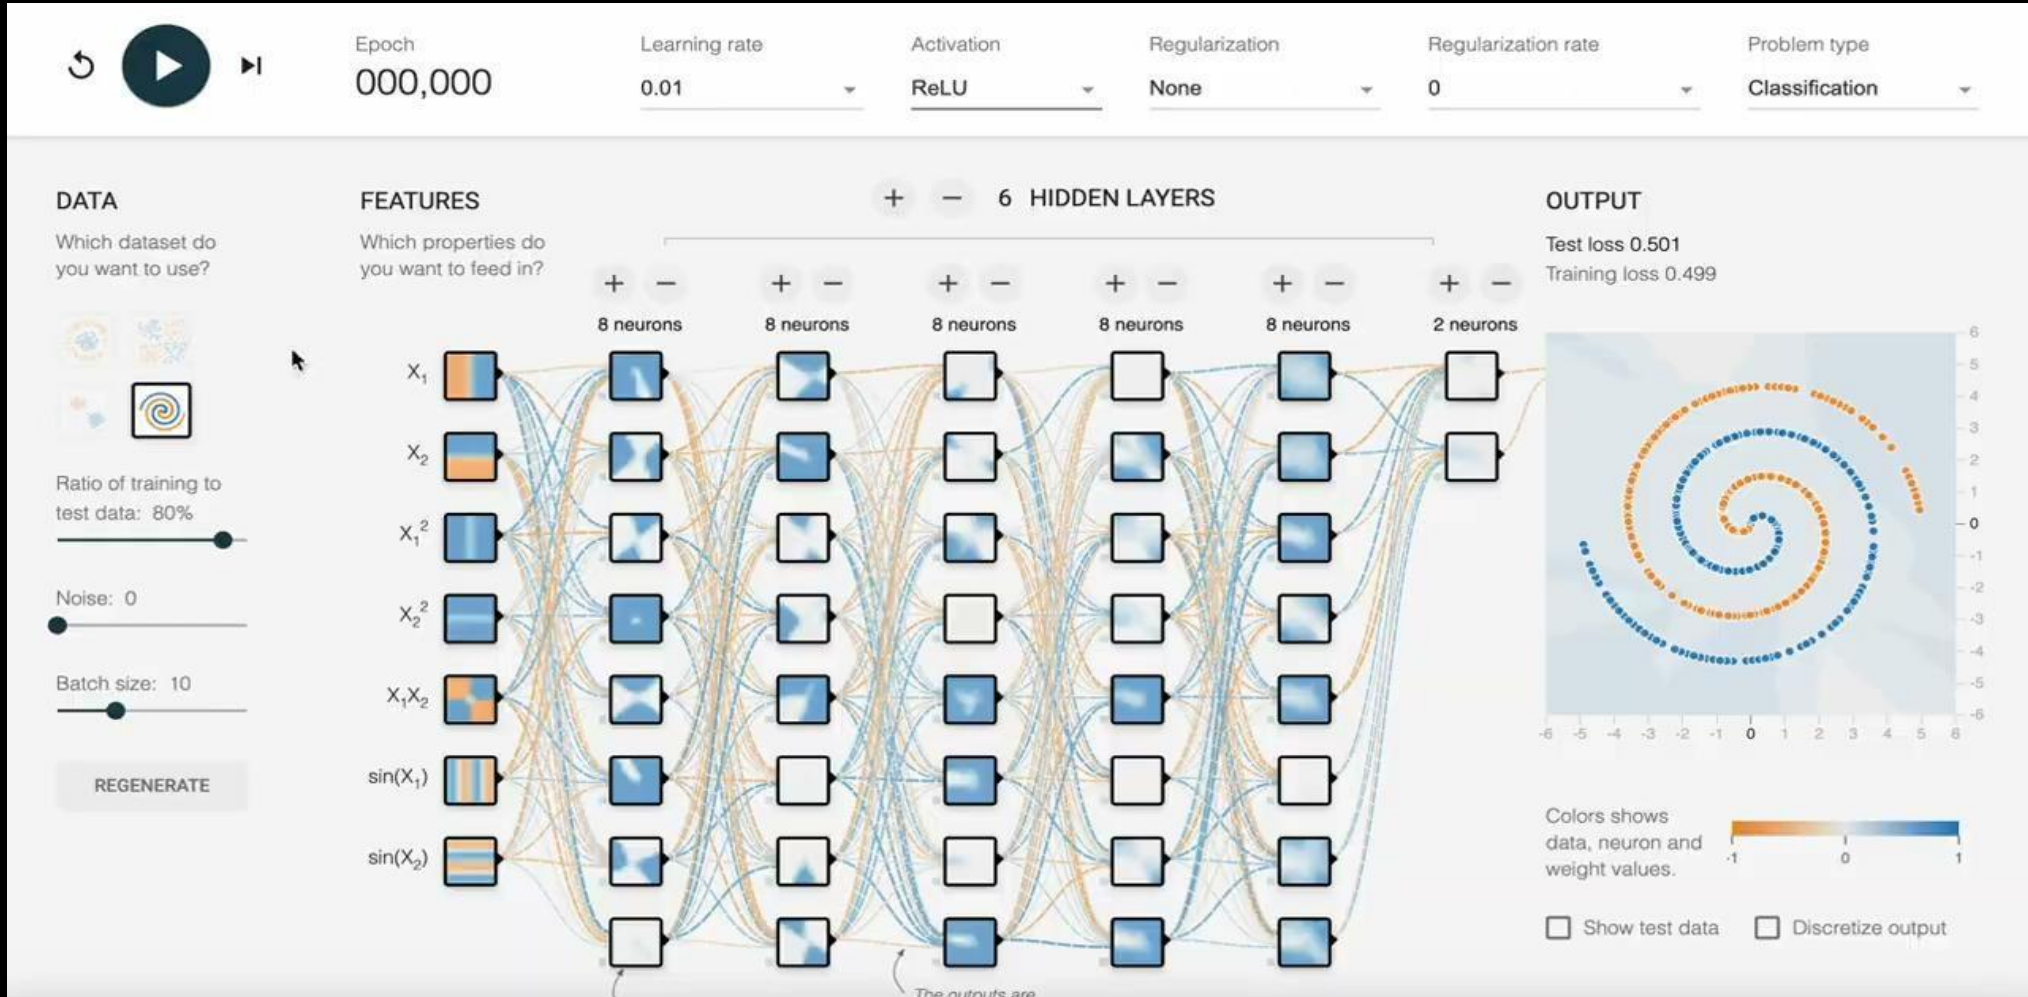
Jak se neuronová síť učí?



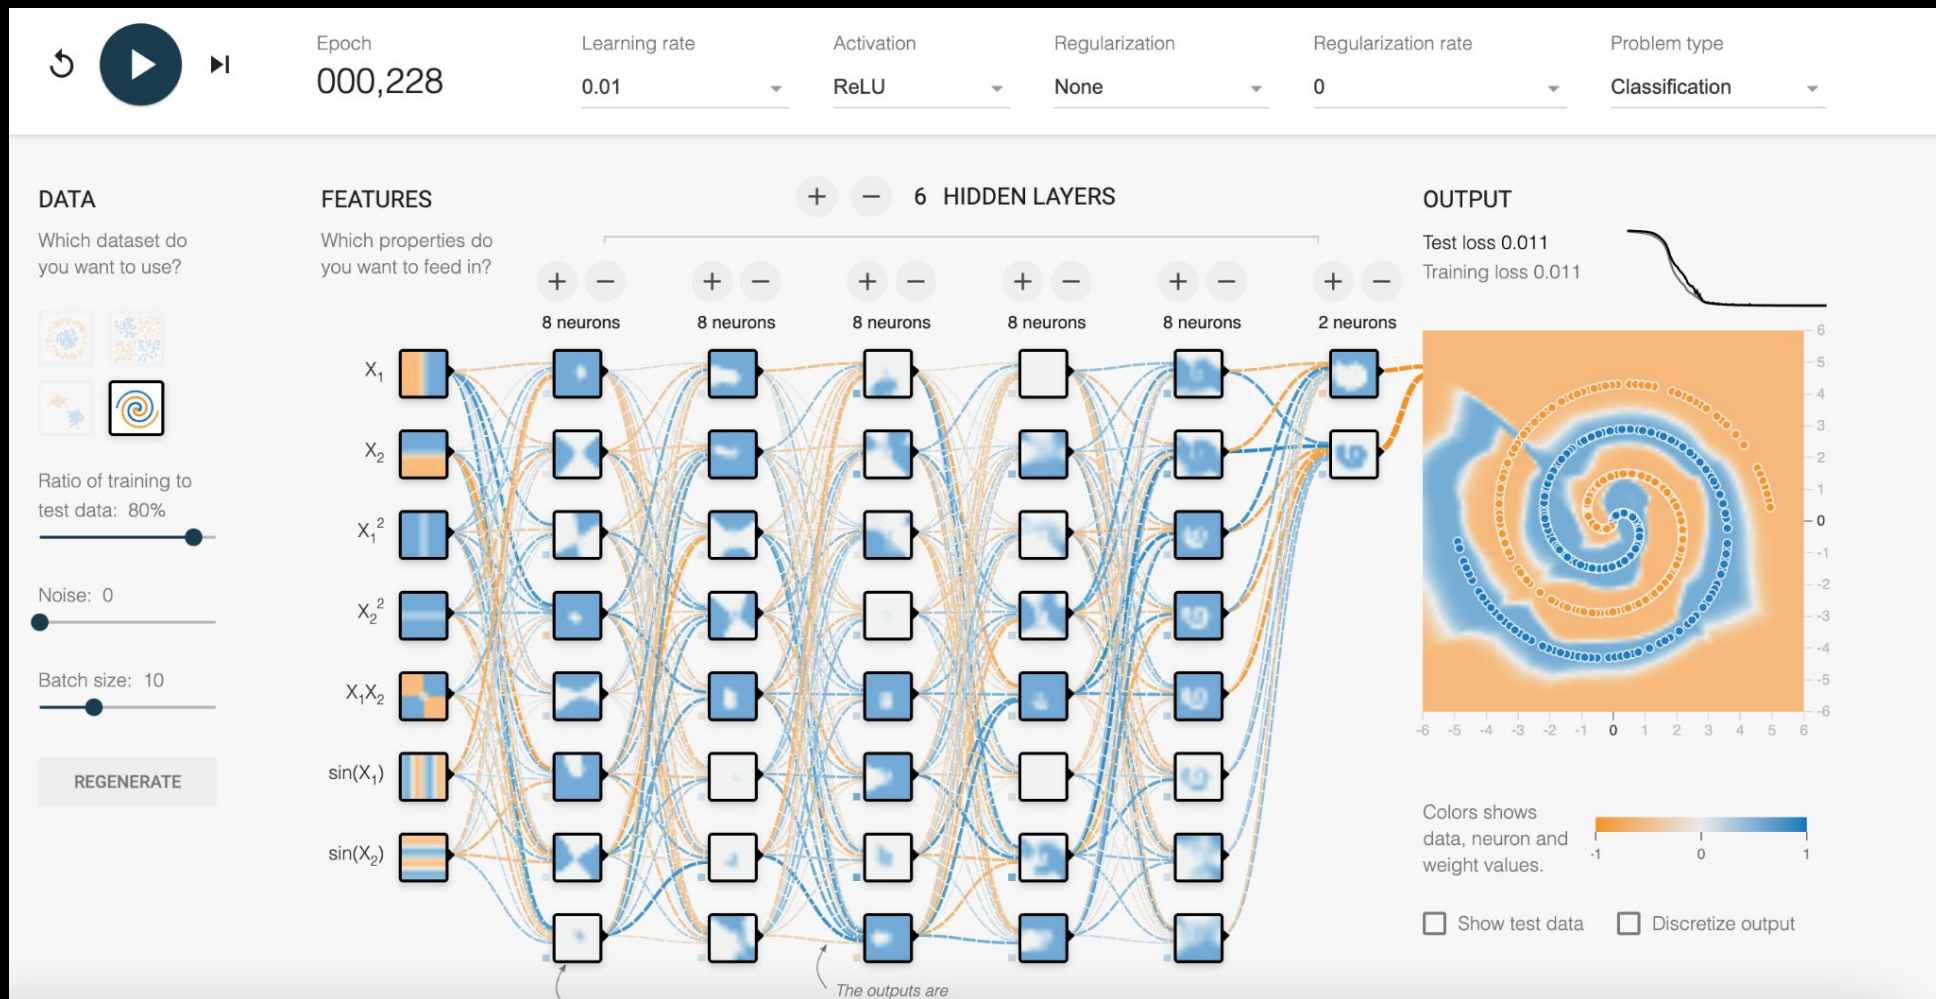
Jak se neuronová síť učí?



Jak se neuronová síť učí?




Jak se neuronová síť učí?




Problémy neuronových sítích

- Málo dat
- Špatně označená data
- Přeučení neuronové sítě (Overfitting)
- Nenaučení neuronové sítě (Underfitting)
- Dlouhé učení


Overfitting, Underfitting



Underfitting



Overfitting







Balanced

Regularizace Neuronové sítě

- Počet skrytých vrstev a neuronů
- Rozšiřování a normalizace dat
- L2 regularizace
- Míra učení (Learning rate)
- Včasné zastavení (Early stopping)
- Dropout regularizace

Poččet skrytých vrstev a neuronů




Rozšiřování dat

- Otáčení
- Ořezávání
- Distorze



Normalizace dat




L2 regularizace

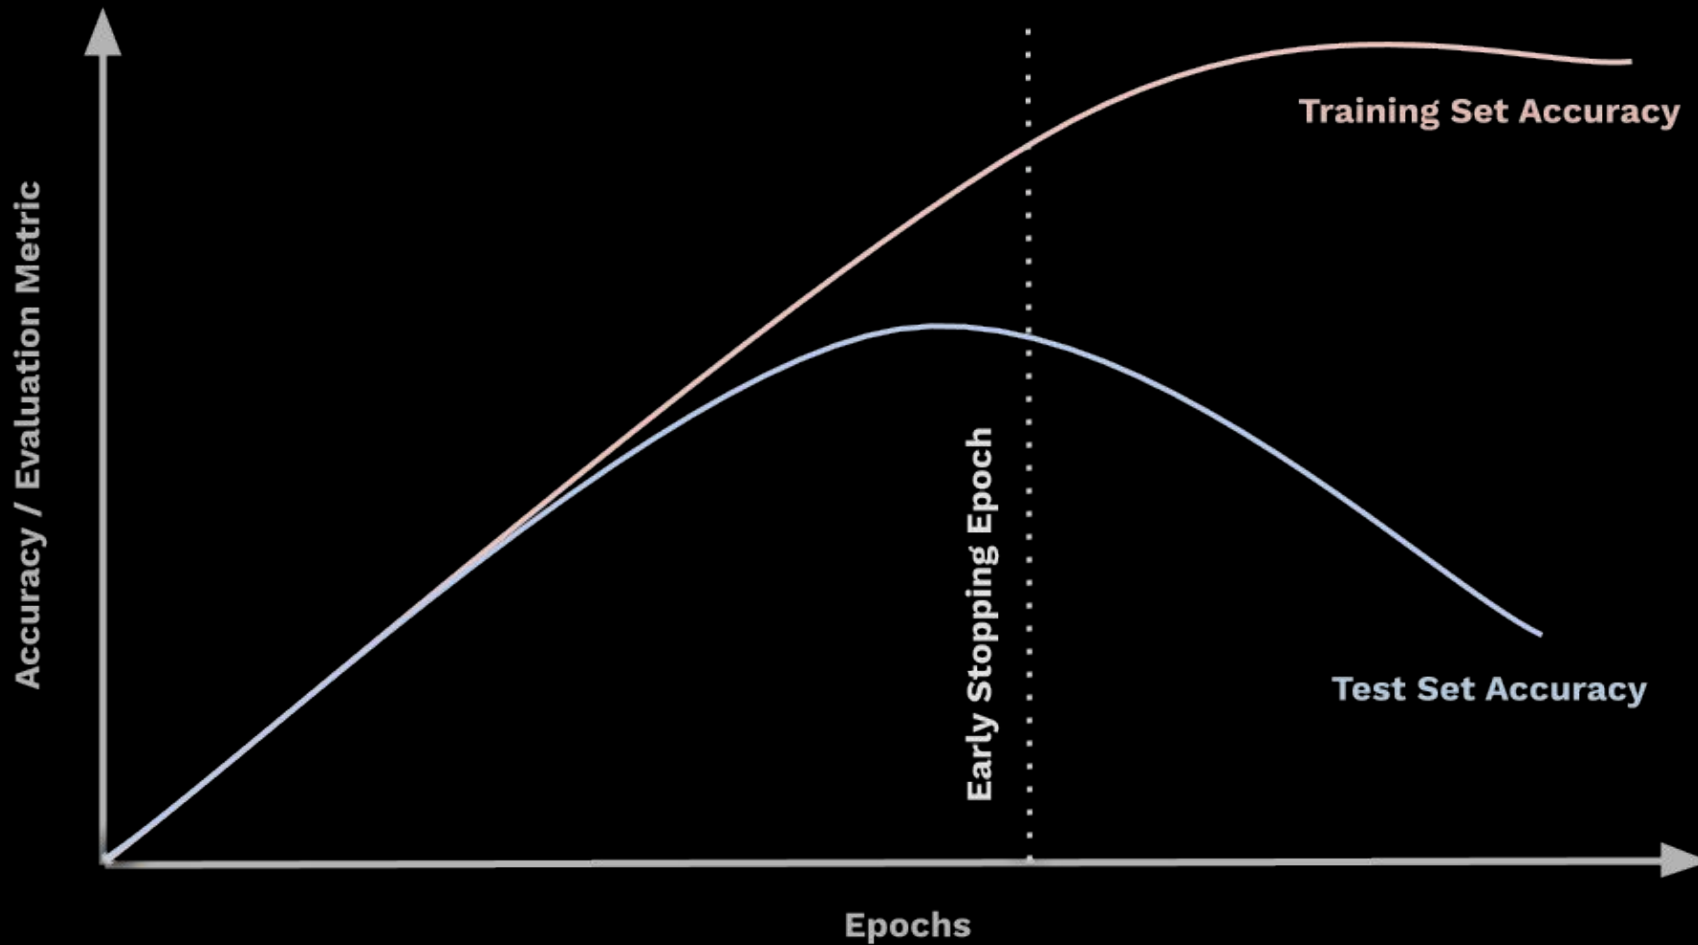
L2 Regularization

$$\text{Cost} = \underbrace{\sum_{i=0}^N (y_i - \sum_{j=0}^M x_{ij} W_j)^2}_{\text{Loss function}} + \lambda \underbrace{\sum_{j=0}^M W_j^2}_{\text{Regularization Term}}$$

Míra učení (Learning rate)




Včasné zastavení (Early stopping)




Dropout regularizace

Original Network




Connections = 16

Dropout-ratio = 30%



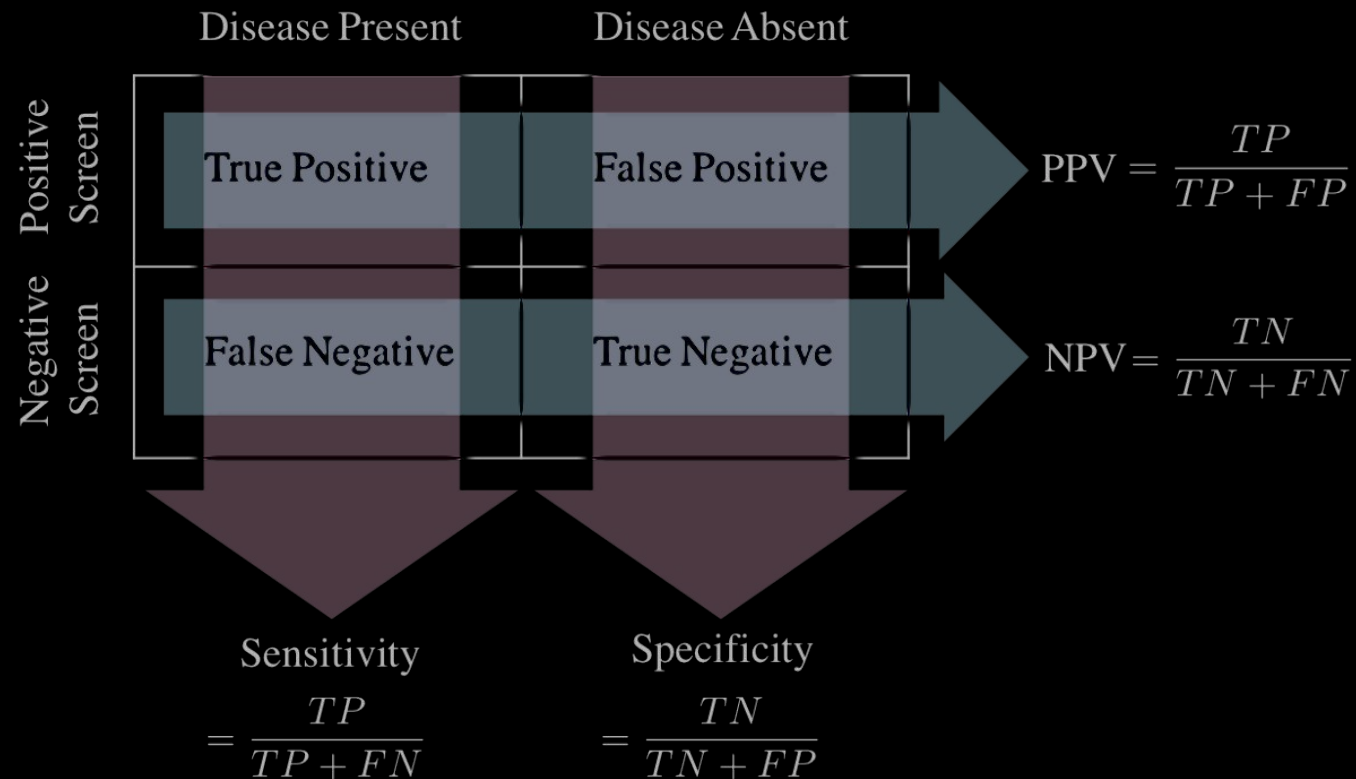
Active = 11 (70%)



Active = 11 (70%)

Testování neuronové sítě

- Senzitivita (Recall)
- Specificita
- F1 scóre
 - Precision = PPV



$$F1 \text{ Score} = 2 * \frac{Precision * Recall}{Precision + Recall}$$