



EVROPSKÁ UNIE  
Evropské strukturální a investiční fondy  
Operační program Výzkum, vývoj a vzdělávání



Název projektu	Rozvoj vzdělávání na Slezské univerzitě v Opavě
Registrační číslo projektu	CZ.02.2.69/0.0./0.0/16_015/0002400

## Dolování dat

## Neuronové sítě

Jan Górecki

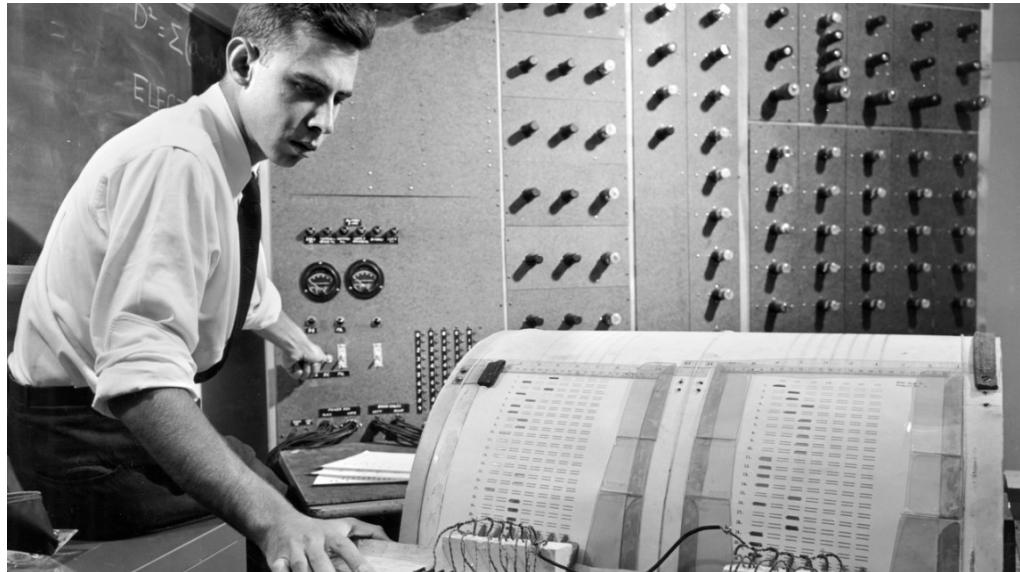


SLEZSKÁ  
UNIVERZITA  
OBCHODNÉ PODNIKATELSKÁ  
FAKULTA V KARVÍNÉ

# Obsah přednášky

---

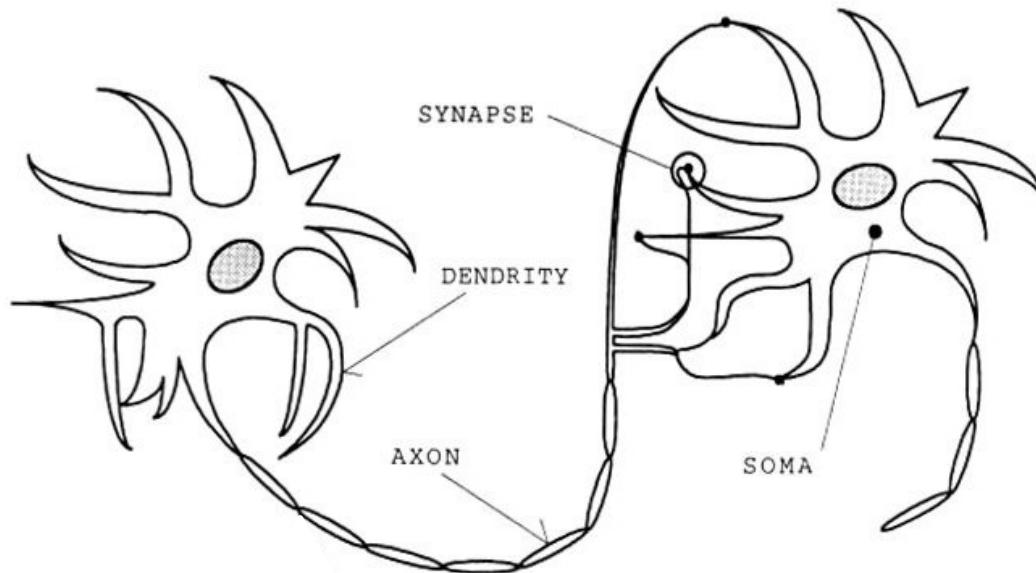
- Biologický neuron
- Modely neuronu
- Učení neuronu
- Vícevrstvý perceptron
- Backpropagation
- Příklady použití



# Biologický neuron



SLEZSKÁ  
UNIVERZITA  
OBCHODNĚ PODNIKATELSKÁ  
FAKULTA V KARVÍNÉ



## 1. Logický neuron (McCulloch, Pitts, 1943)

$$w \in \mathbb{R}, x, y \in \{0, 1\}$$

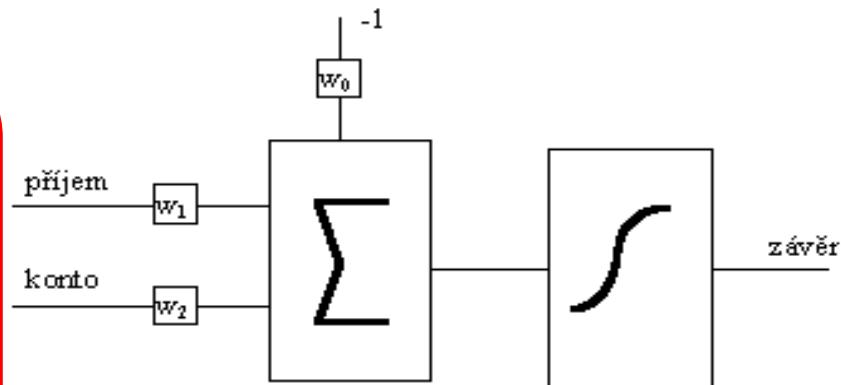
## 2. ADALINE (Widrow, 1960)

$$x, w \in \mathbb{R}, y \in \{0, 1\}$$

$$\hat{y} = 1 \text{ pro } \sum_{i=1}^d w_i x_i \geq w_0$$

$$\hat{y} = 0 \text{ pro } \sum_{i=1}^d w_i x_i < w_0,$$

kde  $d$  je počet vstupů



# Příklad ADALINE

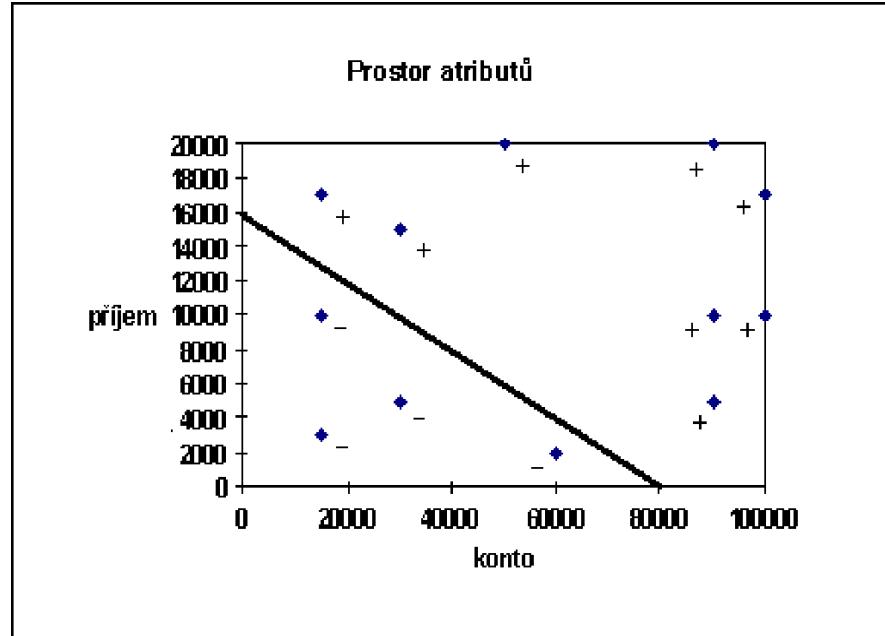


příjem	konto	úvěr	úvěr(bin)
3000	15000	ne	0
10000	15000	ne	0
17000	15000	ano	1
5000	30000	ne	0
15000	30000	ano	1
20000	50000	ano	1
2000	60000	ne	0
5000	90000	ano	1
10000	90000	ano	1
20000	90000	ano	1
10000	100000	ano	1
17000	100000	ano	0

$$\begin{aligned}x_1 &= \text{příjem}, \\x_2 &= \text{konto}, \\y &= \text{úvěr (bin)}, \\w_1 &= 1, \\w_2 &= 0.2, \\w_0 &= 16000\end{aligned}$$

Separující přímka:

$$\sum_{i=1}^d w_i x_i = w_0$$



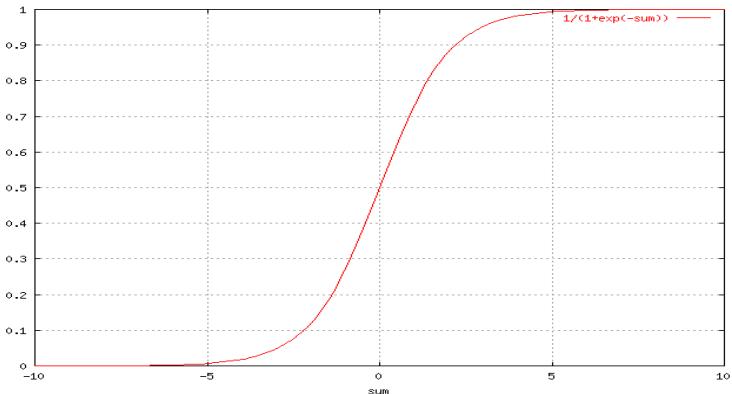
$$\text{příjem} + 0.2 \text{ konto} - 16000 = 0$$

# Modely neuronu

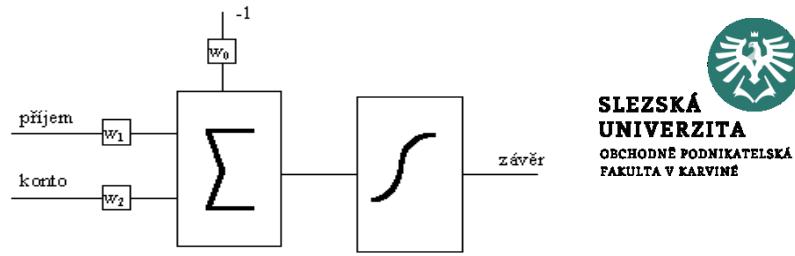
## 3. Současné modely

$$x, w \in \mathbb{R}, y \in [0, 1] \text{ (nebo } [-1, 1])$$

Nelinearity v podobě skokové funkce, tak jak je použita v případě *Adaline* (dávající pouze dvě výstupní hodnoty neuronu), je ve složitějších modelech neuronu nahrazena hladkými funkcemi, které nabývají hodnot z celého intervalu (sigmoide, tang, ale taky identita).

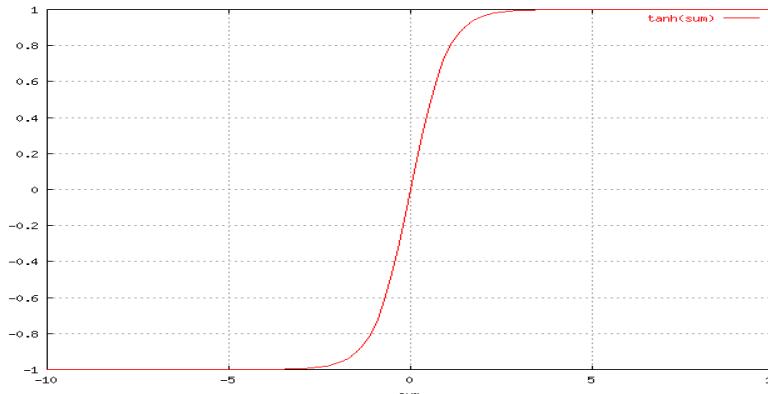


$$\text{Sigmoid } f(\text{SUM}) = \frac{1}{1+e^{-\text{SUM}}}$$



$$SUM = \sum_{i=0}^d w_i x_i = \mathbf{w} \cdot \mathbf{x},$$

$$\text{kde } \mathbf{x} = (-1, x_1, \dots, x_d) \text{ a } \mathbf{w} = (w_0, w_1, \dots, w_d)$$



$$\text{hyperbolický tangens } f(\text{SUM}) = \tanh(\text{SUM})$$



- Modifikace vah  $w$  na základě dat  $[x_i, y_i], i = 1, \dots, n$
- Učení jako aproximace – hledáme parametry dané funkce  $f(x)$

## Gradientní metoda

Střední kvadratická chyba

$$\text{Err}(w) = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

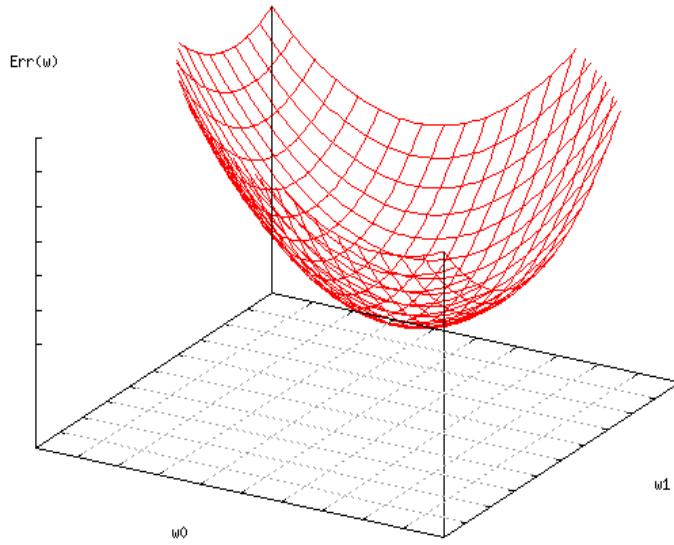
Minimalizace probíhá iterativně modifikací vah

$$w \leftarrow w + \Delta w,$$

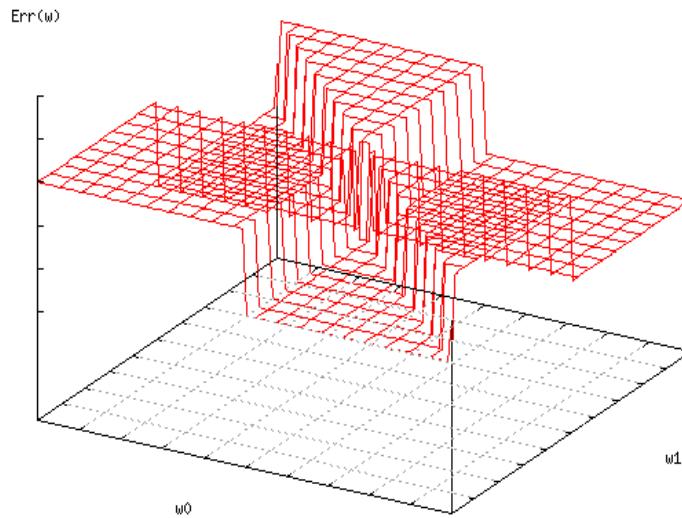
kde

$$\Delta w = -\eta \frac{\partial \text{Err}}{\partial w}$$

# Příklady chybových funkcí



pro lineární aktivaci:  
 $f(SUM) = SUM$



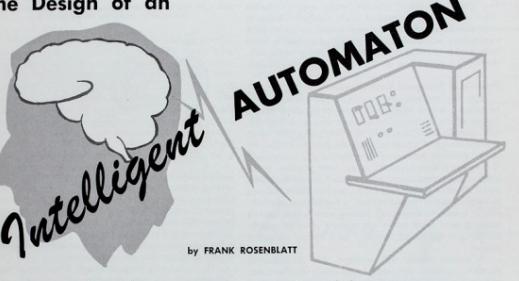
pro skokovou aktivaci (ADALINE):  
 $f(SUM) = 1 \text{ pro } SUM \geq 0,$   
jinak  $f(SUM) = 0$

# Perceptron

Vol. VI, No. 2, Summer 1958

**research trends**  
CORNELL AERONAUTICAL LABORATORY, INC., BUFFALO 21, NEW YORK

**The Design of an Intelligent AUTOMATON**



by FRANK ROSENBLATT

Introducing the perceptron — A machine which senses, recognizes, remembers, and responds like the human mind.

**S**TORIES about the creation of machines having human qualities have long been a fascinating province in the realm of science fiction. Yet we are now about to witness the birth of the first machine capable of perceiving, recognizing, and identifying its surroundings without any human training or control.

Development of that machine has stemmed from a search for an understanding of the physical mechanisms which underlie human experience and intelligence. The earliest man-made nervous process is at least as ancient as any other question in western science and philosophy, and, indeed, ranks as one of the greatest scientific challenges of our time.

Our understanding of this problem has gone perhaps far as had the development of physics since Newton. We have made some definite progress in the physical sciences, explained a number of interesting hypotheses, and a little detailed knowledge about events in the nervous system. But we lack agreement on any integrated set of principles by which the functioning of the nervous system can be understood.

We believe now that this ancient problem is about to yield to our theoretical investigation for three reasons:

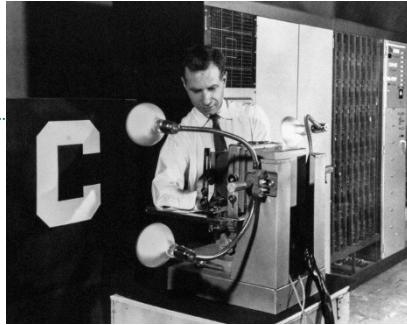
First, in recent years our knowledge of the functioning of individual cells in the central nervous system has vastly increased.

Second, large numbers of engineers and mathematicians are, for the first time, undertaking serious study of the mathematical basis for thinking, perception, and the handling of information by the central nervous system, thus providing the hope that these problems may be solved outside the field of medicine.

Third, recent developments in probability theory and in the mathematics of random processes provide new tools for the study of events in the nervous system, where only the gross statistical organization is known and the precise cell-by-cell "wiring diagram" may never be obtained.

**Receives Navy Support**

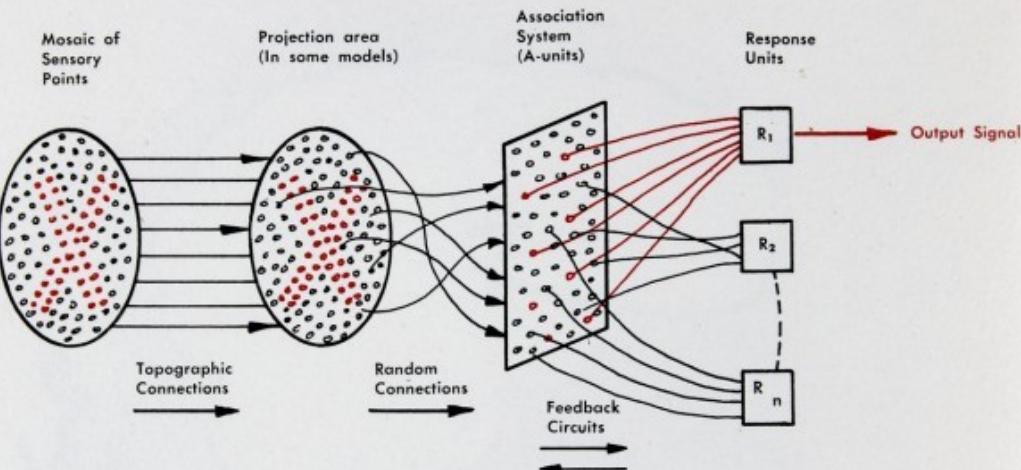
In July, 1957, Project PARA (Perceiving and Recognizing Automaton), an internal research program which had been in progress for over a year at Cornell Aeronautical Laboratory, received the support of the Office of Naval Research. The program had been concerned primarily with the application of probability theory



SLEZSKÁ  
UNIVERZITA  
OBCHODNÉ PODNIKATELSKÁ  
FAKULTA V KARVÍNĚ



**FIG. 1 — Organization of a biological brain. (Red areas indicate active cells, responding to the letter X.)**



**FIG. 2 — Organization of a perceptron.**

# Perceptron



SLEZSKÁ  
UNIVERZITA  
OBCHODNĚ PODNIKATELSKÁ  
FAKULTA V KARVÍNÉ

## Umí:

- Rozpozнат písmena z abecedy
- Rozpozнат tvary (pattern recognition)

## Neumí:

- XOR problem
- Nelineárně separabilní problémy

## Problém:

- Jak ho učit?

=> Celá oblast neuronových sítí utichla na téměř 20 let!

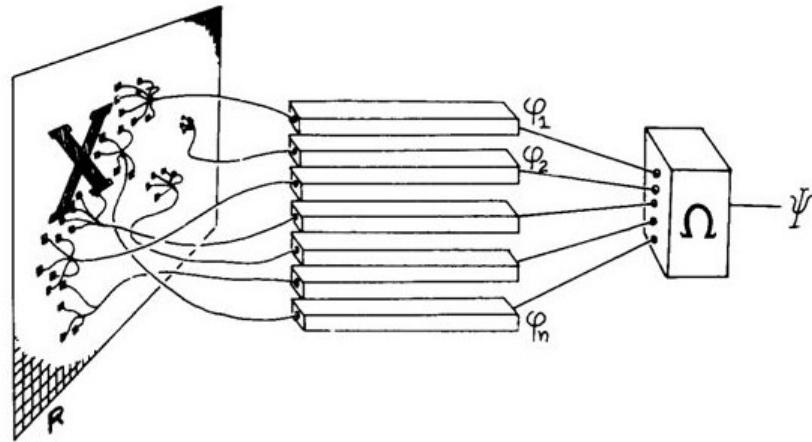


FIGURE 1. The one-layer perceptron analyzed by Minsky and Papert. (From *Perceptrons* by M. L. Minsky and S. Papert, 1969, Cambridge, MA: MIT Press. Copyright 1969 by MIT Press. Reprinted by permission.)

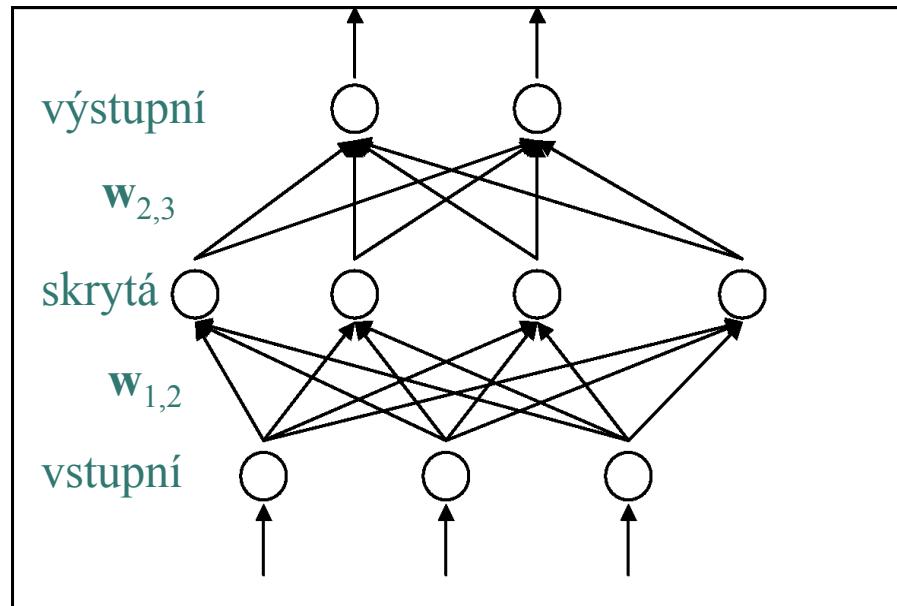
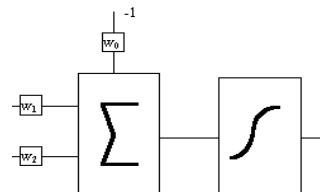
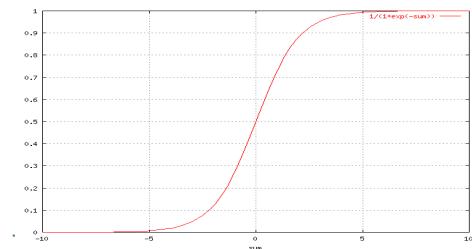
# Vícevrstvý perceptron (MLP)

Sít' používaná pro klasifikaci resp. predikci

3 vrstvy:

1. vstupní – přenáší vstupní data dál
2. skrytá
3. výstupní – ukazuje výsledek klasifikace resp. predikce

sigmoidální aktivační funkce pro neurony ve **skryté** a **výstupní** vrstvě

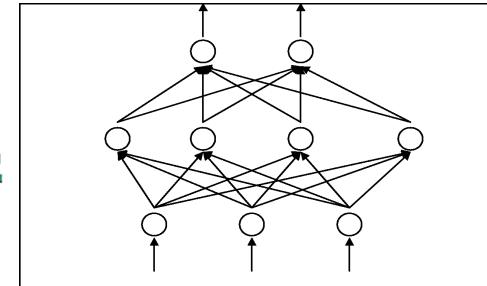


Vícevrstvý perceptron s jednou skrytou vrstvou

# Backpropagation - algoritmus učení s učitelem

- cílem je minimalizovat chybu založenou na druhé mocnině rozdílu mezi skutečným ( $y_{i,v}$ ) a očekávaným ( $\hat{y}_{i,v}$ ) výstupem sítě pro příklad  $x_i$

$$\text{Err}(\mathbf{w}^{(i)}) = \frac{1}{2} \sum_{v \in \text{výstupy}} (y_{i,v} - \hat{y}_{i,v})^2$$



Změna váhy vazby vedoucí od neuronu  $j$  k neuronu  $k$  se bude řídit gradientem funkce  $\text{Err}$

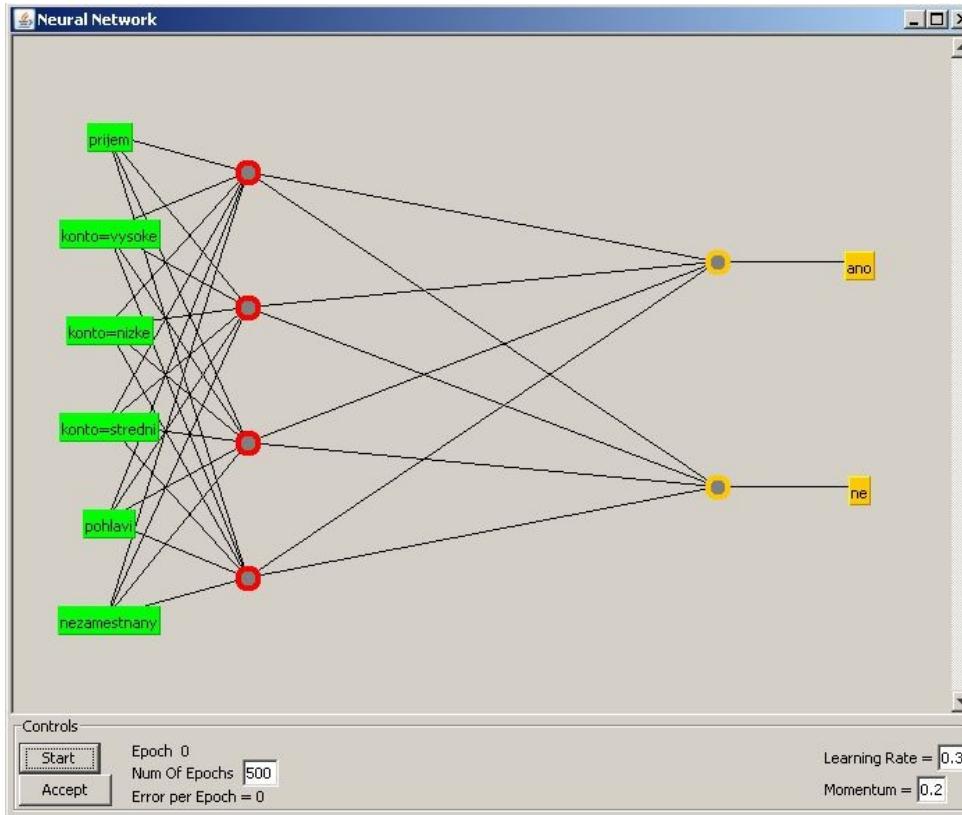
$$\Delta w_{jk} = -\eta \frac{\partial \text{Err}}{\partial w_{jk}}$$

# Kritéria zastavení

- počet iterací
- velikost chyby
- změna chyby mezi iteracemi



# Implementace (Weka)

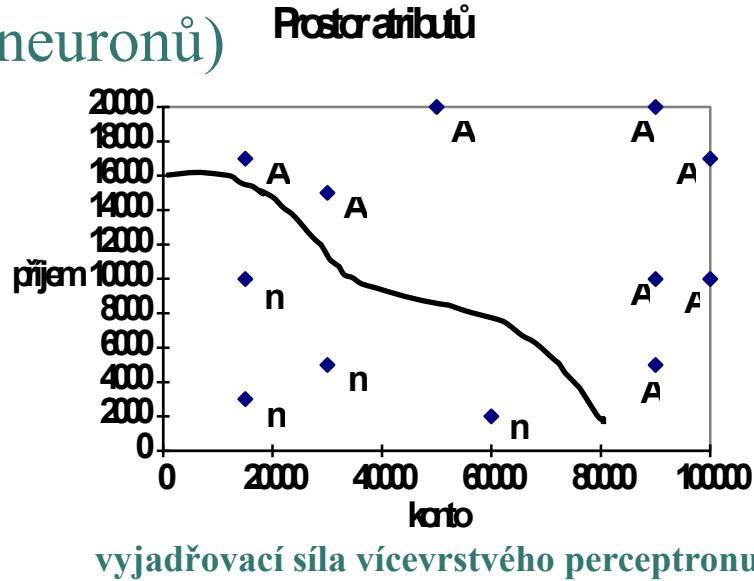


# Způsob aplikace neuronové sítě

- volba vhodné sítě (topologie, počet neuronů)
- výběr trénovacích příkladů
- učení sítě

Typy úloh:

- klasifikace
- predikce



- neuronové sítě jsou vhodnější pro numerické atributy
- lze „popsat“ složité shluky v prostoru atributů
- nalezené znalosti jen obtížně interpretovatelné

# Klasifikace

---



**Úloha:** vyhodnocování bonity klienta banky

**Vstupy:** údaje o žadateli

**Výstupy:** doporučení „poskytnout/neposkytnout úvěr“

**Řešení:**

**Typ sítě:** MLP

**Vstupní vrstva:** jeden neuron pro každý údaj o žadateli

**Výstupní vrstva:** jeden neuron

**Skrytá vrstva:** ??

**Učení:** informace o dřívějších klientech + závěr banky

---

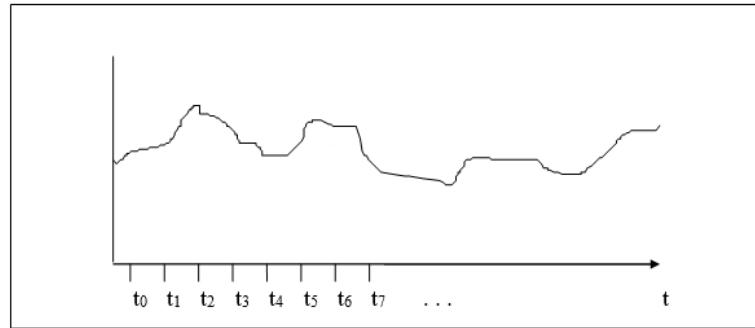
# Predikce

Na základě historických dat předpověď dalšího vývoje

**Úloha:** predikce vývoje směnných kursů

**Vstupy:** předchozí hodnoty kurzu

**Výstupy:** budoucí hodnota kurzu



**Řešení:**

**Typ sítě:** MLP

**Vstupní vrstva:** jeden neuron pro každou hodnotu

**Výstupní vrstva:** jeden neuron pro každou hodnotu

**Skrytá vrstva:** ??

**Učení:** historické + aktuální údaje

vstupy	výstup
$y(t_0)$ $y(t_1)$ $y(t_2)$ $y(t_3)$	$y(t_4)$ $[sign(y(t_4) - y(t_3))]$
$y(t_1)$ $y(t_2)$ $y(t_3)$ $y(t_4)$	$y(t_5)$ $[sign(y(t_5) - y(t_4))]$
$y(t_2)$ $y(t_3)$ $y(t_4)$ $y(t_5)$	$y(t_6)$ $[sign(y(t_6) - y(t_5))]$
...	

# Děkuji za pozornost

Některé snímky převzaty od:

prof. Ing. Petr Berka, CSc. [berka@vse.cz](mailto:berka@vse.cz)