



České vysoké učení technické v Praze



Fakulta elektrotechnická



**Katedra kybernetiky
Katedra počítačů**



Vytěžování dat – přednáška 9

Umělé neuronové sítě v data miningu



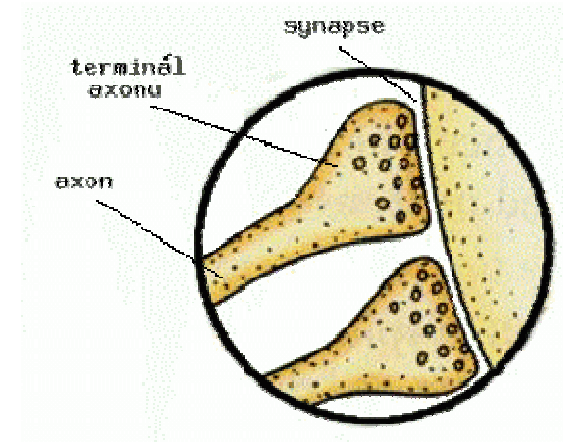
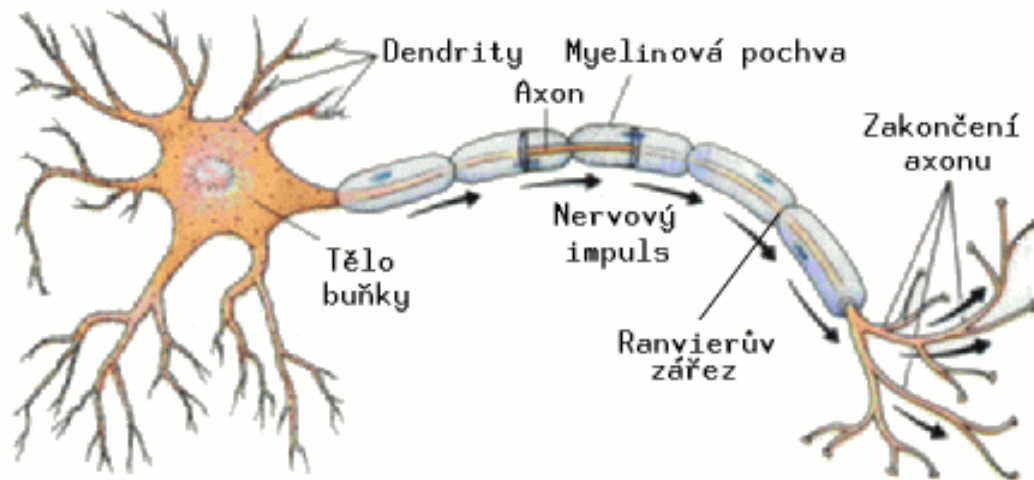
Osnova přednášky

Úvod do neuronových sítí

- Biologická inspirace
 - Historie
 - Perceptron
 - Minsky-Pappert omyl
 - Vícevrstvý perceptron
 - Příklady neuronových sítí – MLP, GMDH, RBFN, SOM
-
- Neuronové sítě a data mining
 - Použití neuronových sítí k řešení reálných problémů
 - Konkrétní příklady vytěžování dat pomocí NS

Úvod do neuronových sítí

Biologický neuron



<http://neuron.felk.cvut.cz/courseware/data/chapter/36nan026/s01index.html>

Co jsou to ty neuronové sítě?

- Umělé informační systémy, které jsou principiálně schopny napodobovat funkce nervových soustav a mozků živých organismů podstatně dokonalejším způsobem, než to činí dosavadní, tzv. konvenční výpočetní technika.
- Pozor! Od umělých neuronových sítí k mozku je ale ještě strašně daleko...

Umělá neuronová síť

- Distribuované, paralelní zpracování dat
- Vzájemně propojené výkonné prvky (neurony)
- Každý výkonný prvek transformuje vstupní data na výstupní podle jisté přenosové funkce.
- Přitom se též může uplatnit obsah jeho lokální paměti.
- Signál se šíří sítí tak, že výstupy neuronů jsou přivedeny na vstupy dalších neuronů.

Pracovní fáze umělé neuronové sítě

- Umělá neuronová síť pracuje v zásadě ve dvou fázích - adaptivní a aktivní.
- V adaptivní fázi se síť **učí** (learning phase),
- v aktivní vykonává naučenou činnost, **vybavuje** (evaluation phase).
- Paměť sítě reprezentují hodnoty synaptických vah na jednotlivých vstupech neuronů.

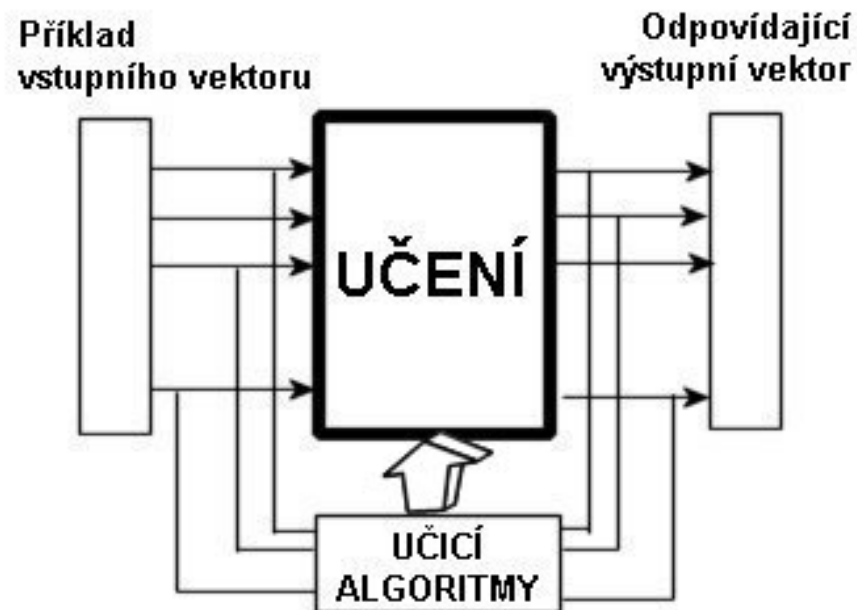
Učení a jeho typy

- Při **učení s učitelem** se umělá neuronová síť učí srovnáváním aktuálního výstupu s výstupem požadovaným a přestavováním synaptických vah tak, aby se propříště snížil rozdíl mezi skutečným a žádaným výstupem. Metodika snižování rozdílu je určena učicím algoritmem.
- Do **učení bez učitele** není zapojen žádný vnější arbitr a celé učení je založeno pouze na informacích, které samotná síť během celého procesu učení získala.


Možná se dostane i na Hebbovské učení, posilované učení, atd.

Učení umělé neuronové sítě

- Minule – kompetiční učení (bez učitele)
- Dnes – učení s učitelem:



Historie



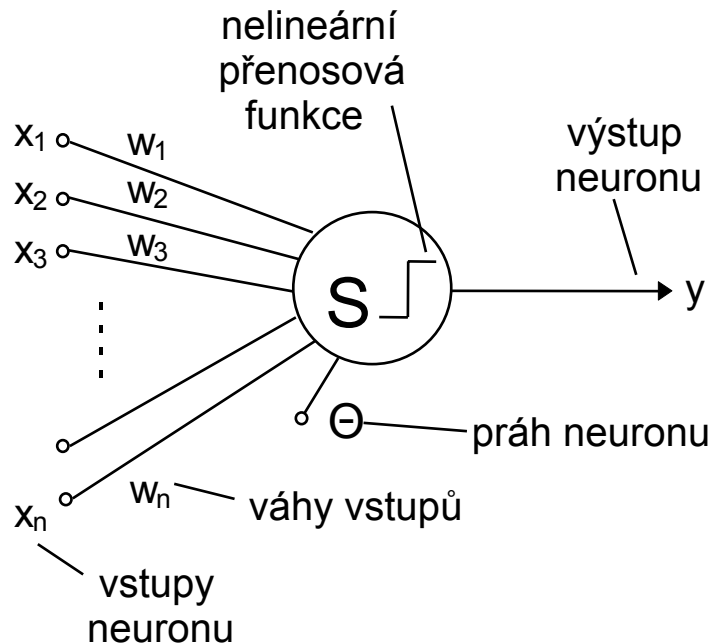
1899 - 1969




1923 - 1969

Warren McCulloch, Walter Pitts

McCulloch-Pittsův neuron (1943)



$$y = S\left(\sum_{i=1}^N w_i x_i + \Theta\right)$$



- y je výstup neboli aktivita neuronu,
- x_i je i -tý vstup neuronu, vstupů je celkem N ,
- w_i představuje hodnotu i -té synaptické váhy,
- S je (nelineární) přenosovou funkcí neuronu a
- Θ představuje prahovou hodnotu (vlastně posunutí).
- Výraz v závorce je vnitřní potenciál.

Rosenblattův perceptron (1957)

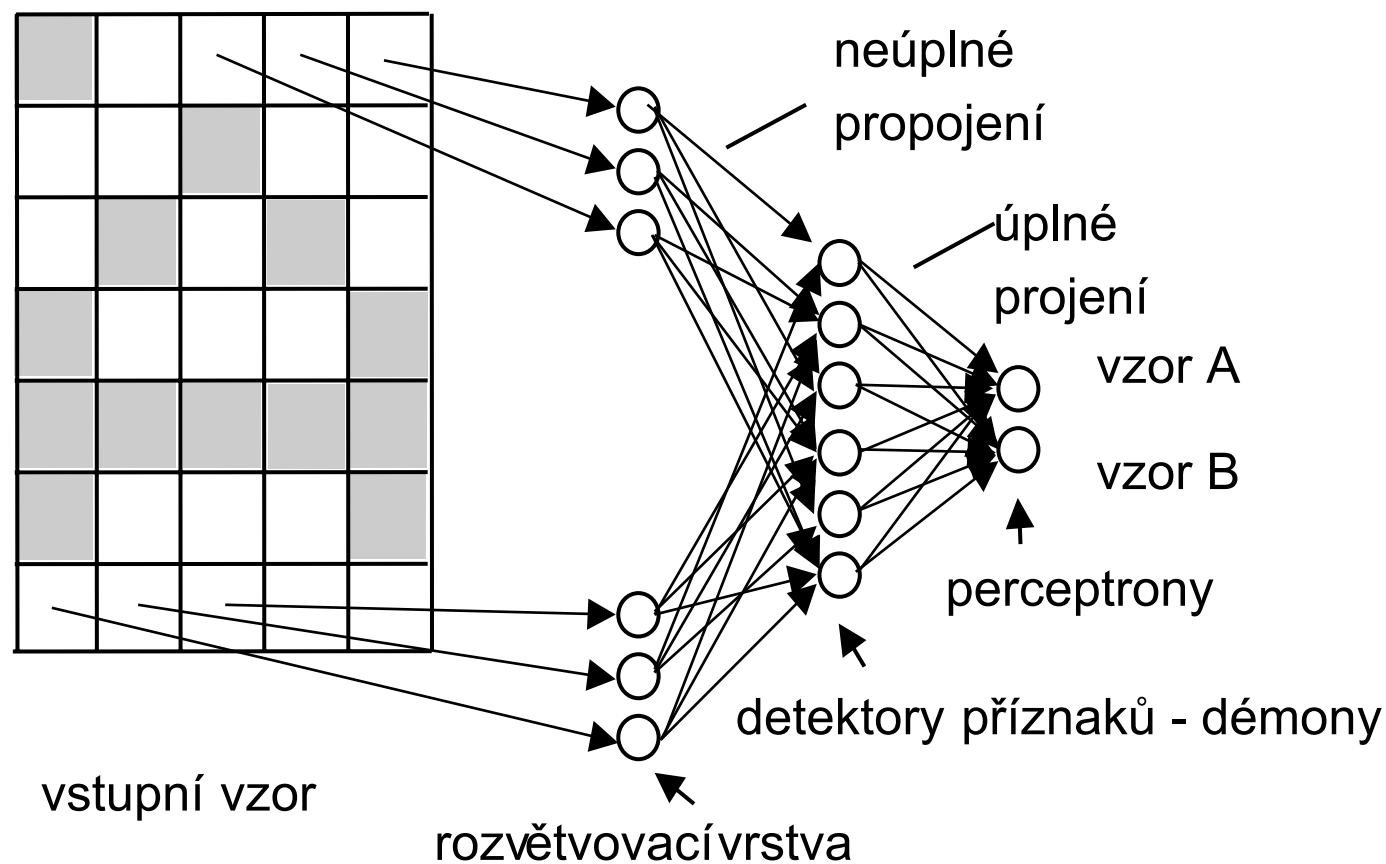


Frank Rosenblatt -


tvůrce prvního
neuropočítače Mark I, 1960

- Vymyslel pro MP-neuron algoritmus učení
- Nazývá neuron perceptronem (pattern recognizer)
- Použil ho pro klasifikaci písmen


Rosenblattova perceptronová síť



Neurony v Rosenblattově síti



neuron v perceptronové vrstvě



neuron v démonické vrstvě

Rosenblatt - učicí algoritmus


- Váhy se nastaví náhodně.
- Je-li výstup správný, váhy se nemění.
- Má-li být výstup roven 1, ale je 0/-1, inkrementuj váhy na aktivních vstupech.
- Má-li být výstup roven 0/-1, ale je 1, dekrementuj váhy na aktivních vstupech.
- Vstupy jsou přitom aktivní tehdy, když je jejich hodnota nad prahem, tedy nenulová. Velikost změny vah (inkrementace nebo dekrementace) závisí na konkrétně zvolené ze tří možných variant:
 - Při inkrementaci i dekrementaci se aplikují pevné přírůstky.
 - Přírůstky se mění v závislosti na velikosti chyby. Je výhodné, jsou-li při větší chybě větší a naopak. Takto dosažené zrychlení konvergence však může mít za následek nestabilitu učení.
 - Proměnné a pevné přírůstky se kombinují v závislosti na velikosti chyby.

Rosenblatt a spol.


- Velmi dobré výsledky
- Přitažlivý výzkum slibující velkou perspektivu.
- S dostatečně velkou sítí budu schopen rozpoznat cokoli!
- Na to grantové agentury slyší.
- Mnoho vědců se snaží výsledky napodobit a rozvinout.

MP-Perceptron

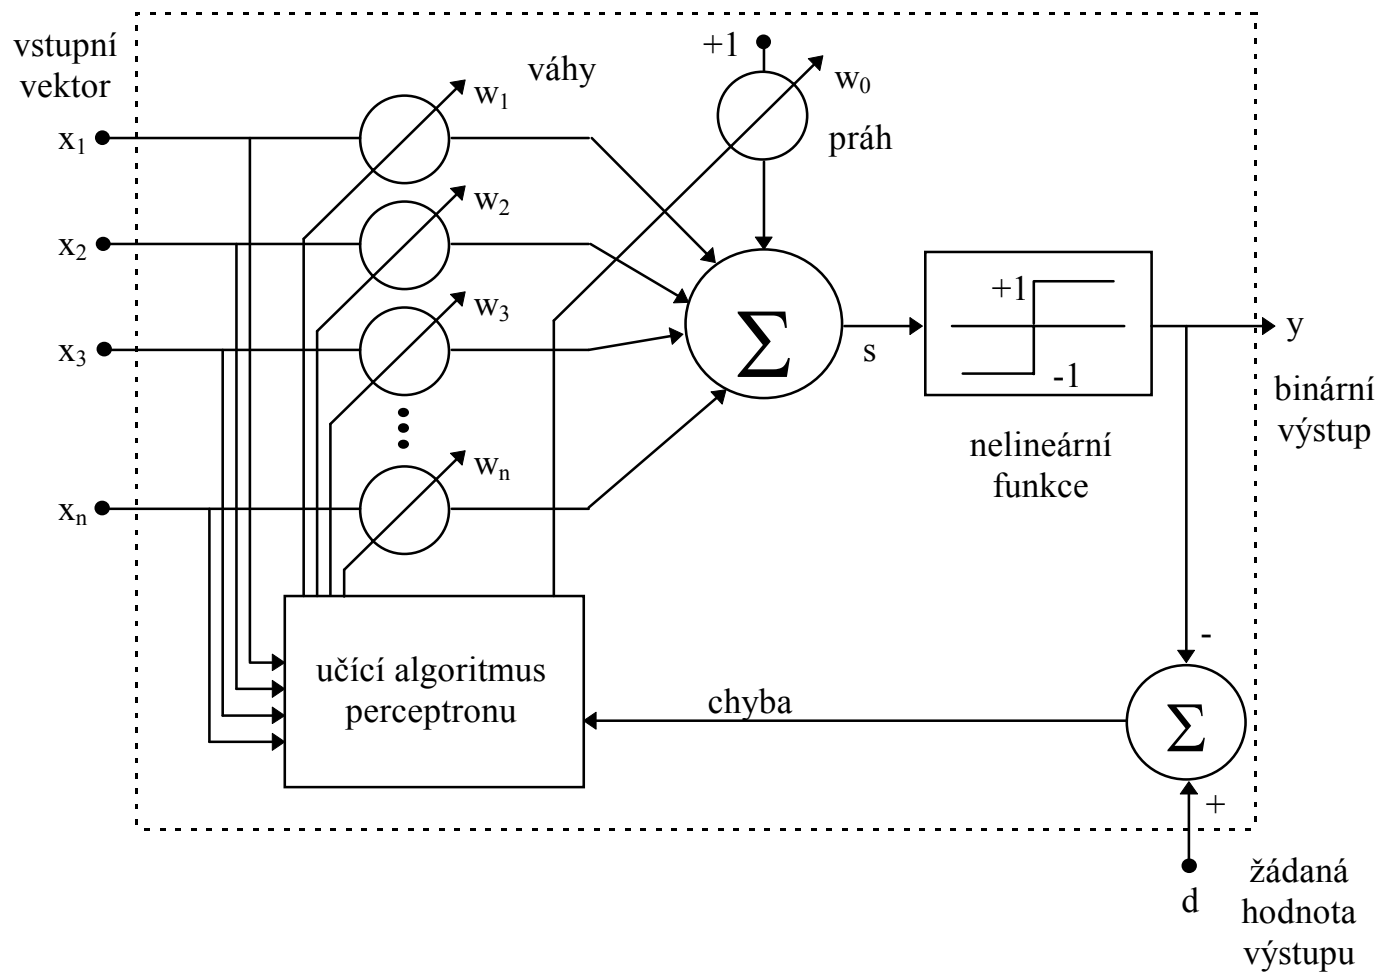
- MP = Marvin Minsky a Seymour Papert,
 - MIT Research Laboratory of Electronics,
 - V roce 1969 publikovali knihu:



Perceptrons



MP-perceptron



MP – algoritmus učení

Pro každý učicí vzor uprav váhy perceptronu:

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

$$e(t) = [d(t) - y(t)] ,$$

kde

Je to chyba? Jakých hodnot nabývají d a y ?

w_i je váha i tého vstupu

x_i je hodnota i tého vstupu

η je koeficient učení

y je výstup neuronu

d je požadovaný výstup

Geometrická interpretace neuronu

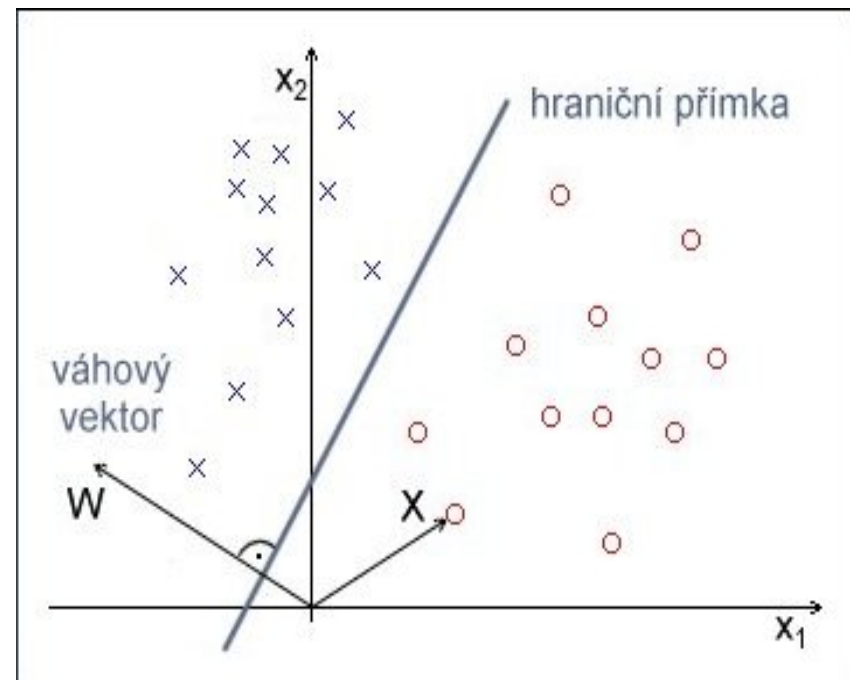
$f(\mathbf{X}) = \mathbf{W} \cdot \mathbf{X} - \theta = \sum_{i=1}^N w_i \cdot x_i - \theta$ je vnitřní potenciál neuronu

Položíme nule (ve 2D):

$$w_1 * x_1 + w_2 * x_2 - \theta = 0$$

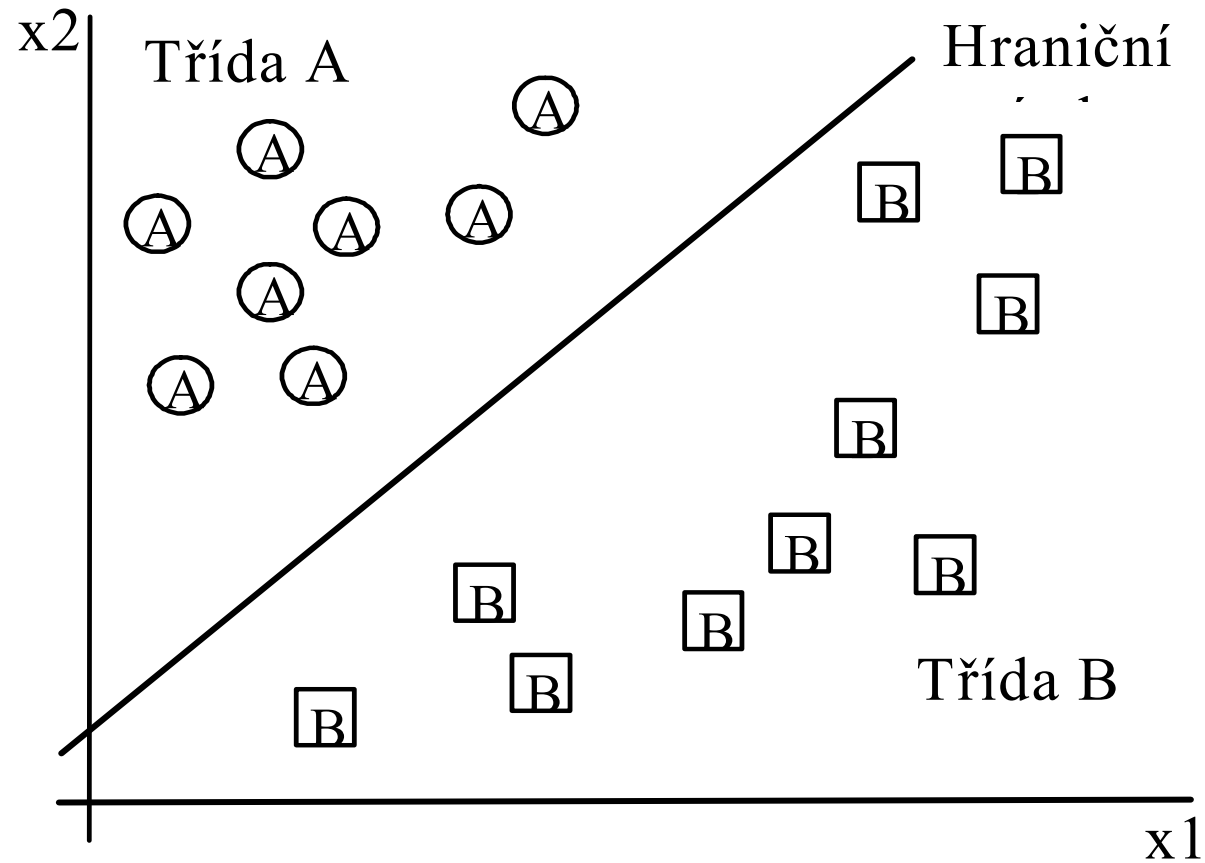
$$x_2 = -\frac{w_1}{w_2} * x_1 + \frac{\theta}{w_2}$$

Co s tím udělá nelinearita na výstupu?




Rovnice přímky se směrnicí $-w_1/w_2$ a posuvem na ose x_2 rovným θ/w_2

Jak tedy klasifikuje Rosenblattův perceptron?



Příklad: AND

- Podívejme se na reprezentaci funkce AND
- Bílý čtvereček znamená 0, černý 1
- 0 je kódovaná jako -1, jednička jako +1



-1 AND -1 = false

-1 AND +1 = false


+1 AND -1 = false

+1 AND +1 = true

Použity slidy: Daniel A. Jiménez, Department of Computer Science, Rutgers University

Příklad: AND, pokračování


- Lineární řezná rovina - pro všechny kombinace vstupů je výstup buď $+1$, nebo -1 . Hranice, kde se výstup mění se nazývá *decision boundary*



Použity slidy: Daniel A. Jiménez, Department of Computer Science, Rutgers University

Příklad: AND, pokračování


- Dívejte se, jak se perceptron naučí funkci AND:



Použity slidy: Daniel A. Jiménez, Department of Computer Science, Rutgers University

Příklad: XOR

- Funkce XOR je reprezentována takto:



$$-1 \text{ XOR } -1 = \textit{false}$$

$$-1 \text{ XOR } +1 = \textit{true}$$

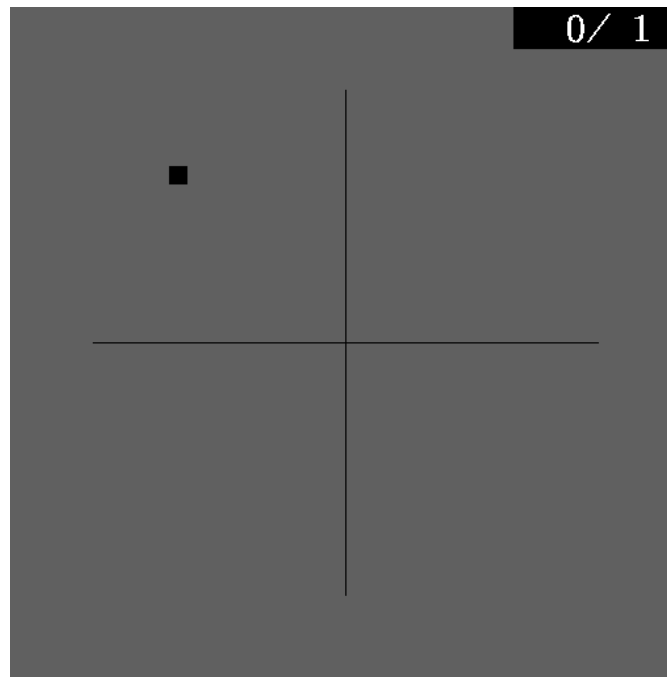
$$+1 \text{ XOR } -1 = \textit{true}$$

$$+1 \text{ XOR } +1 = \textit{false}$$

Použity slidy: Daniel A. Jiménez, Department of Computer Science, Rutgers University

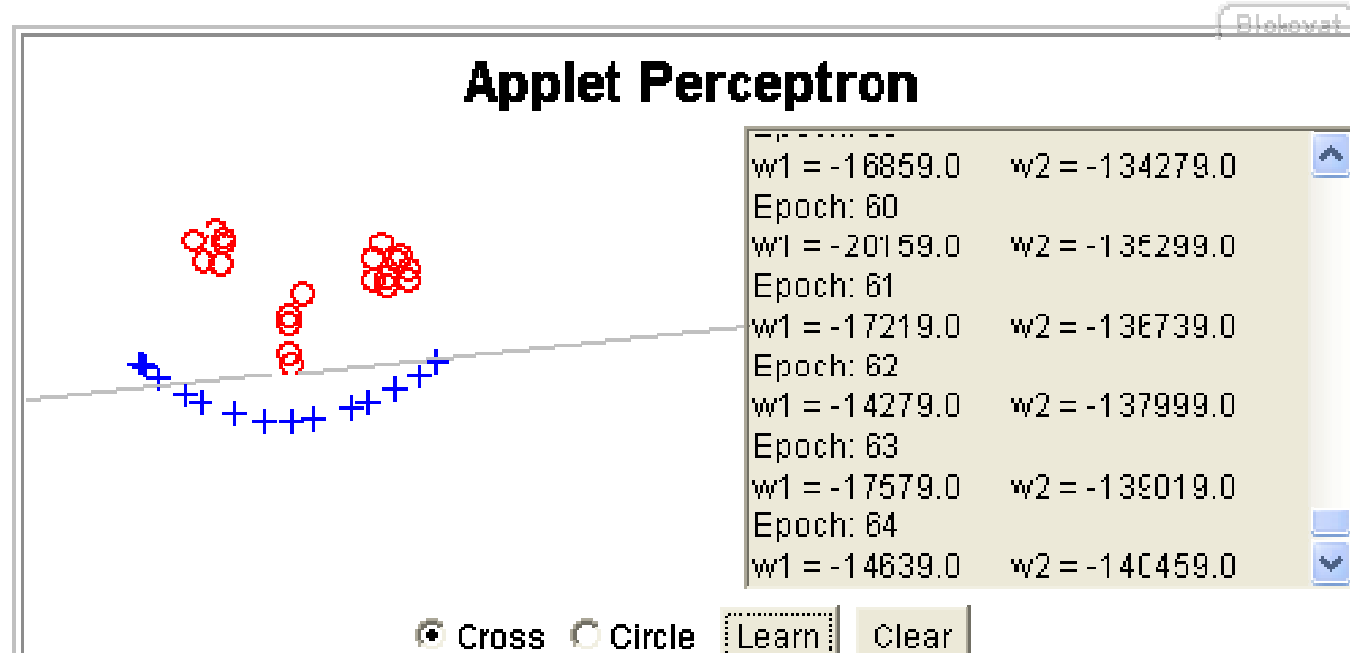
Příklad: XOR, pokračování

- Sledujte, jak se perceptron snaží naučit XOR:




Použity slidy: Daniel A. Jiménez, Department of Computer Science, Rutgers University

Applet perceptron



<http://neuron.felk.cvut.cz/courseware/data/chapter/36nan028/s04.html>




Kdy je perceptron naučen?

- Tehdy, když je pro všechny vzory **učicí** množiny (podmnožina množiny vstupních vzorů) splněno zadané kritérium naučenosti formulované např. tak, že
 - chyba perceptronu je menší než ...
- Jak vypočítám jeho chybu?
- Kdy mám ukončit učení?
 - chyba na validační množině začíná růst
 - stagnace po určitý počet epoch

Epocha = předložení všech vzorů trénovací množiny na vstup

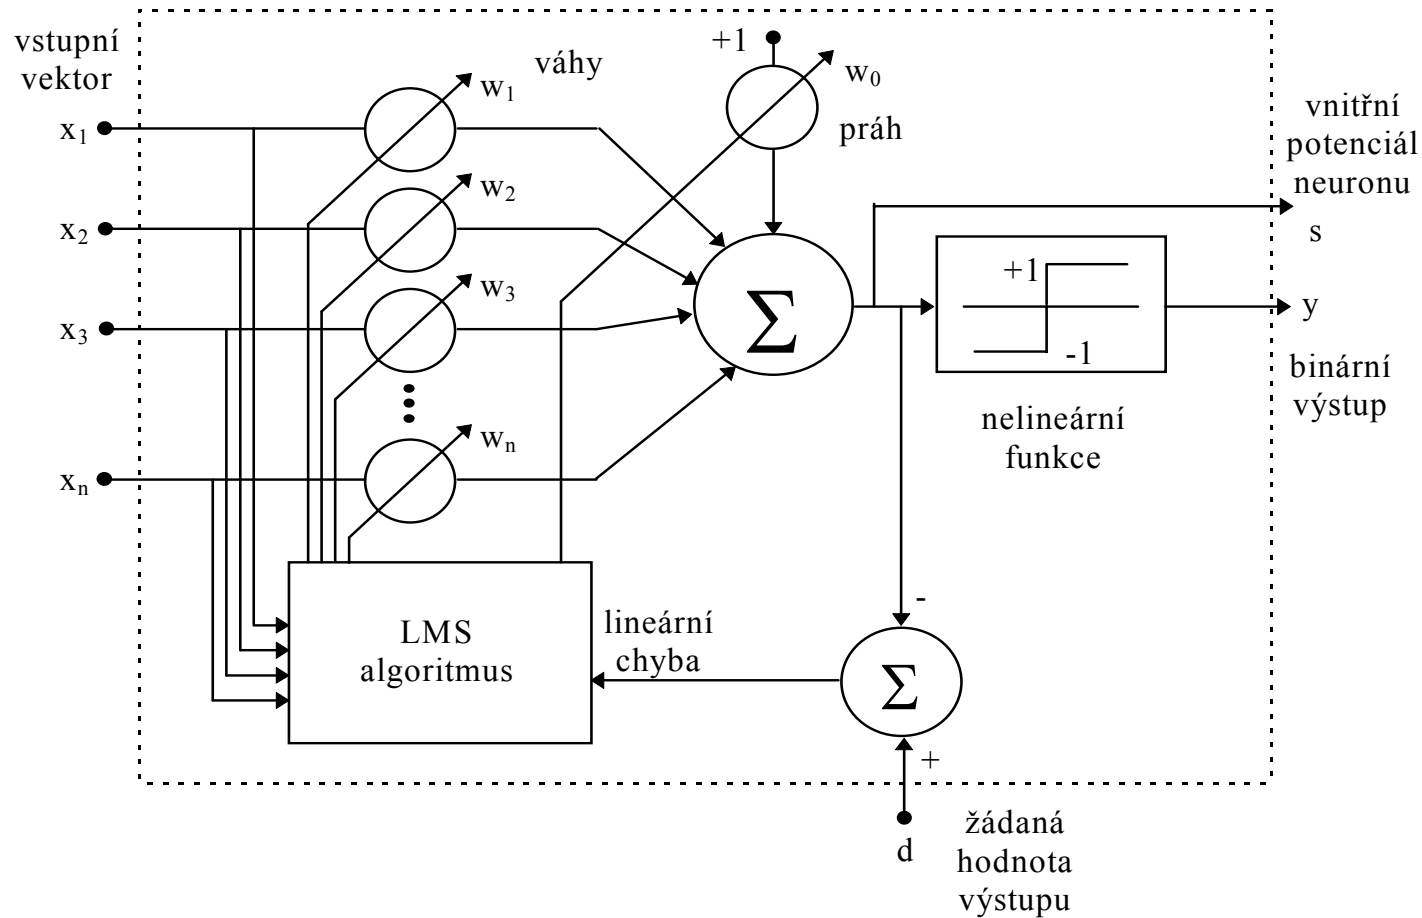
ADALINE

B. Widrow, Stanfordská universita, 1960



Y336VD Vytěžování dat

ADALINE - AdAptive Linear Neuron



Učicí algoritmus ADALINE (tzv. delta rule)

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

$$e(t) = d(t) - s(t).$$

kde

w_i je váha itého vstupu

x_i je hodnota itého vstupu

η je koeficient učení

s je vnitřní potenciál neuronu

d je požadovaný výstup

ADALINE Uceni Pocet vstupu: 5 Rychlost animace: < | | >

Tabulka stavu

```

-1,-1,-1,-1,-1;-1
1,1,1,1,1;1
-1,1,-1,1,-1;1
1,-1,1,-1,1;-1
  
```

<< Pridaj
Odstran
Smaz vse
Vloz >>
Nauc vse
Stop

Vstupy: Vahy Vystup

Prah: 0.12850223

-1 +1

0.22630563

-1 +1

0.5896984

Vnitri p.: 0.0

-1 +1

Odchylka: 0.06926345

0.23594072

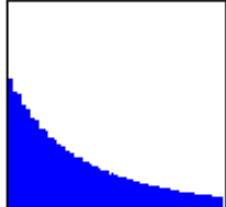
Odchylka 1.3178664

-1 +1

0.38672927

-1 +1


-0.0060936445



Perceptron/ADALINE 1 krok uceni Vahy nahodne

Simulace uceni a vybavovani
Libor Martinek & Petr Miska

Prirustek: 0.01



<http://neuron.felk.cvut.cz/courseware/data/chapter/36nan009/example/s03Applet.html>

Poznáte, v čem se liší MP-perceptron a ADALINE?

- Perceptron: $\Delta w_{ij} = n(d_i - y_i)x_j$
- Delta rule: $\Delta w_{ij} = n(d_i - s_i)x_j$

y_i -vs- s_i (výstup nebo vnitřní potenciál):

- Delta rule se může asymptoticky přiblížit k minimu chyby pro lineárně **n**eseparabilní problémy; perceptron NE.
- Perceptron vždy konverguje k bezchybnému klasifikátoru lineárně separabilních problémů; delta rule se to podařit nemusí!

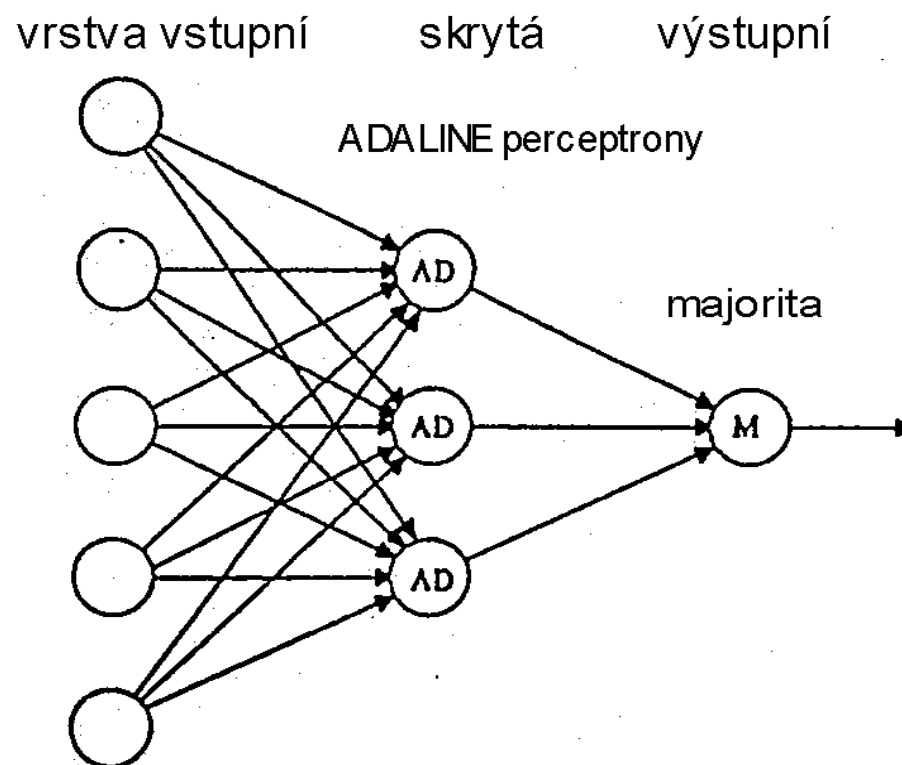
↙
Kdy by perceptron zkonvergovat nemusel?

MADALINE (**M**ultiple **A**daptive **L**inear **E**lement)

- Zpracovává binární signály,
- pracuje s bipolárním kódováním,
- jedna skrytá, jedna výstupní vrstva,
- učí se s učitelem,
- autorem je opět B. Widrow.



MADALINE - architektura sítě




Pozn.: učí se pouze synapse na vstupech ADALINE perceptronů.

MADALINE možnosti použití

- První neuronová síť reálně nasazená pro řešení problému z praxe.
- Použita jako adaptivní filtr pro potlačení ozvěn na telefonních linkách (dodnes se někde používá).
- Zvládne vyřešit nelineárně separabilní problém s nulovou chybou?

MADALINE




MADALINE omezení

- MADALINE není použitelná na složitější problémy.
- Proč?
- Kvůli algoritmu učení – ADALINE se učí nezávisle, nejsou schopny si nějakým způsobem rozdělit vstupní prostor aby společně vytvořily složitou rozhodovací hranici ...


Útlum výzkumu neuronových sítí

- Respektovaná kniha Minskyho-Paperta „Perceptron“ (1969) uvádí, že neuronové sítě nezvládnou uspokojivě řešit lineárně neseparabilní problémy.
- Grantové agentury usoudili, že financování výzkumu neuronových sítí není perspektivní – 20 let živoření

Lineární neseparabilita - Minsky-Papertův omyl



funkce OR



funkce XOR

\circ výstup = 0 \bullet výstup = 1

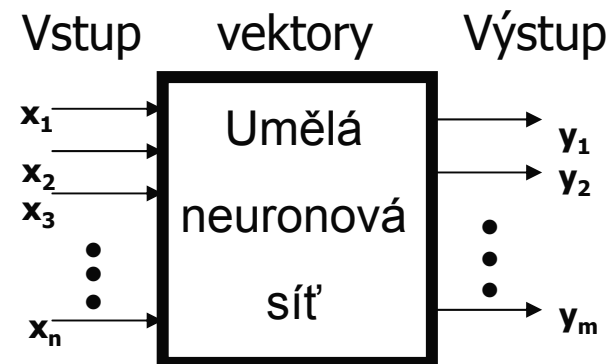
Neuronová síť to zvládne (viz. MADALINE), ale je třeba vymyslet, jak ji to naučit!

Zajímavé Intermezzo

Funkci ANN můžeme chápat jako transformaci T
vstupního vektoru X

na výstupní vektor Y


$$Y = T(X)$$




Jaké všechny transformace T může ANN realizovat?

Toto byla vědecká výzva od počátku existence disciplíny.


Průlom I: diferencovatelné aktivační funkce




a) lineární




b) dvouhodnotová funkce
pro $|\beta|=|\delta|=1$ -signum




c) sigmoida



d) Heavisideova funkce



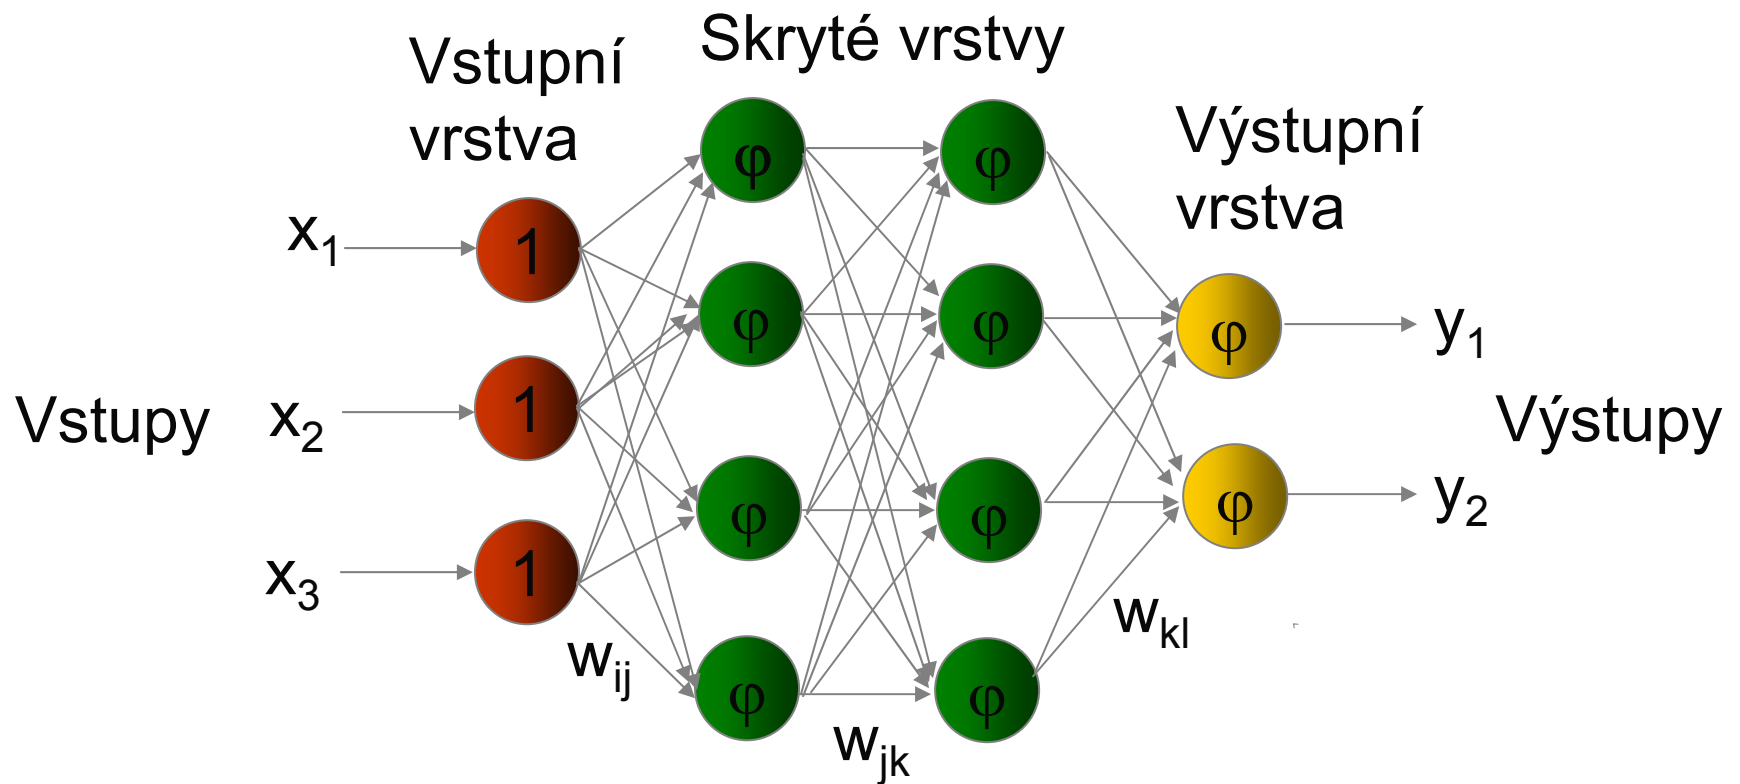
e) s omezením




f) hyperbolická tangenta

Průlom II: vícevrstvé sítě s dopředným šířením

■ MLP (MultiLayered Perceptron)



Nelineární přenosová funkce MultiLayered Perceptronu



$$S(\varphi) = \frac{1}{1 + e^{-\gamma\varphi}}$$

Co je tam to φ ?

Sigmoida zobrazená
pro různé argumenty γ

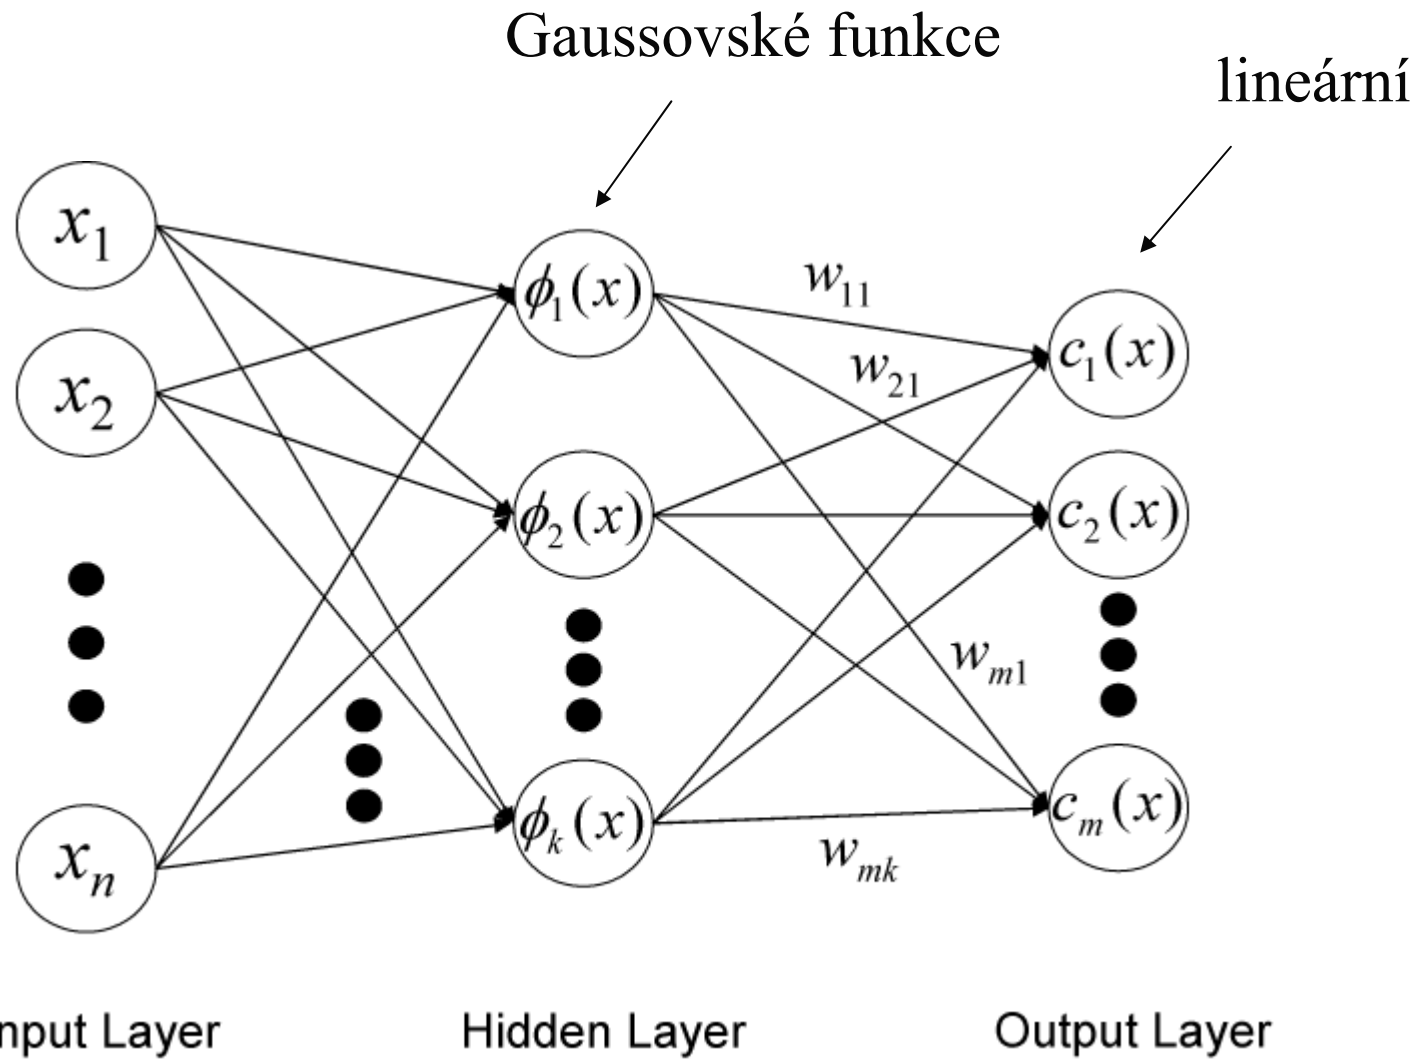
Průlom III: Algoritmus učení

- K natrénování MLP sítě lze použít algoritmus zpětného šíření chyby – Back propagation of error (zkráceně Backpropagation).
- MLP síť trénovaná Backpropagation algoritmem je dodnes nejpoužívanější neuronová síť.
- Více příští přednášku ...

Další dopředné neuronové sítě

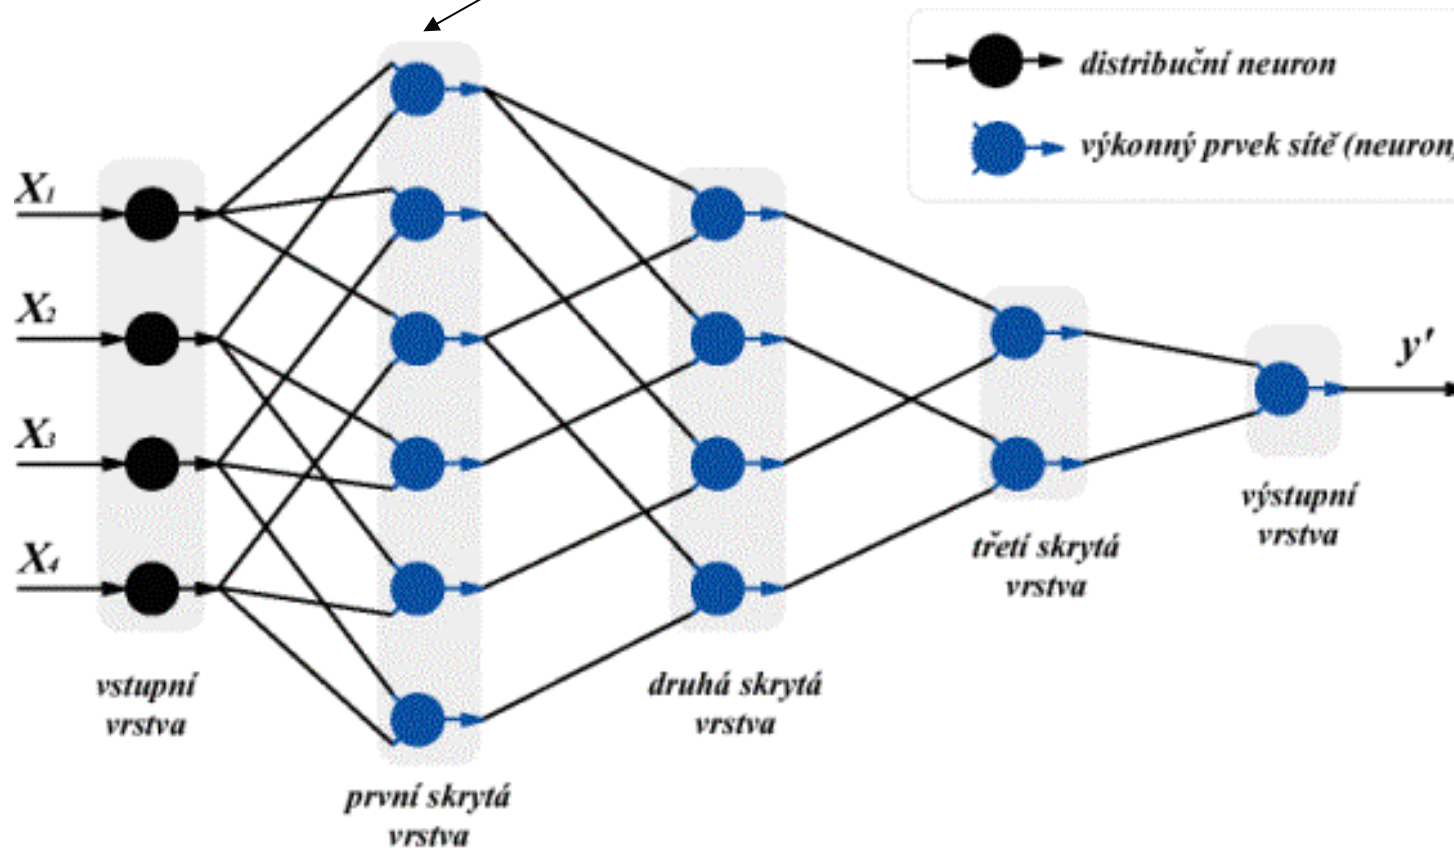
- Radial Basis Function Network
- MIA GMDH Network
- Cascade Correlation Network
- Neocognitron
- ...

RBFN



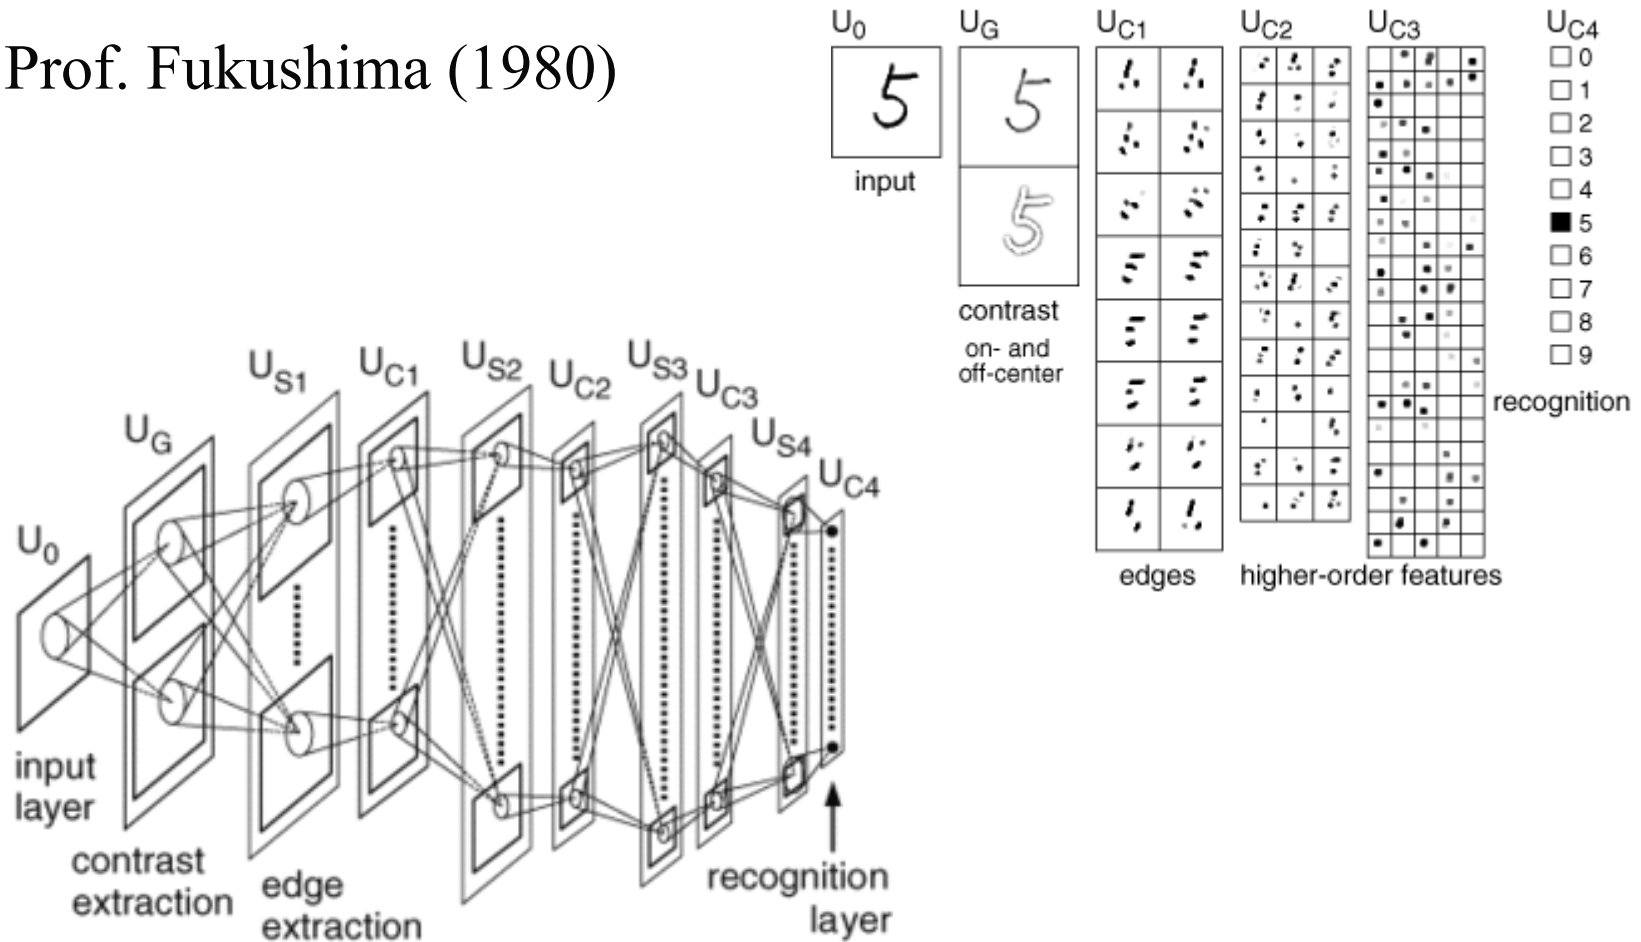
MIA GMDH

Neurony s polynomiální
přenosovou funkcí



Neocognitron

Prof. Fukushima (1980)



Feedforward NN for rapid vision

- Serre, Thomas (2007)
- Hodně podobné
- U nás GOLOKO (Brunner 1987)


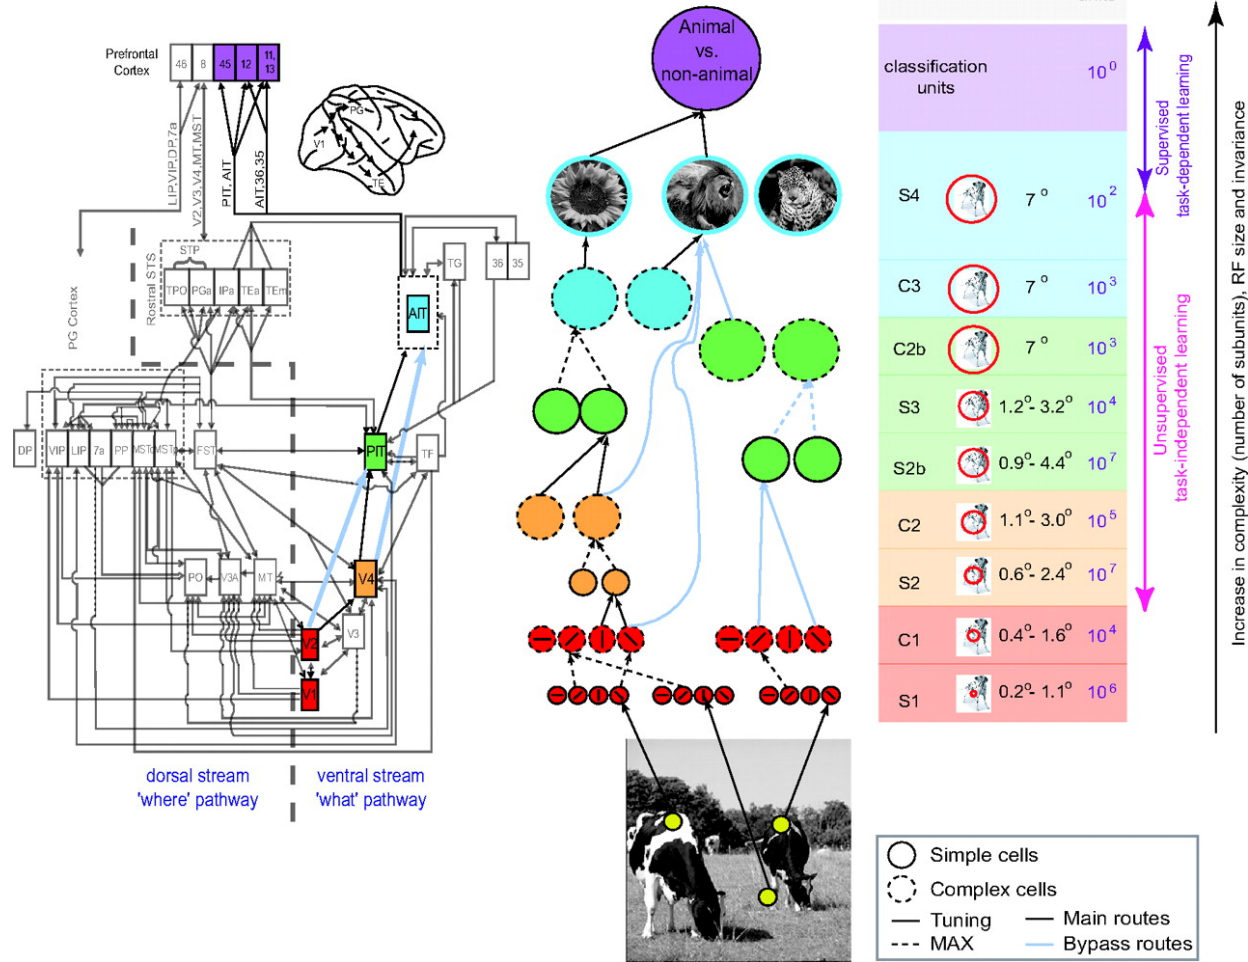


Fig. 1. Sketch of the model



Serre, Thomas et al. (2007) Proc. Natl. Acad. Sci. USA 104, 6424-6429

Neuronové sítě v data miningu

- Viz např. Industrial Conference on Data Mining 2007

<http://www.informatik.uni-trier.de/~ley/db/conf/incdm/incdm2007.html>
nebo

www.cs.uml.edu/~ckrieger/user/Neural_Networks.pdf

- Klasifikace
- Predikce
- Shlukování
- Identifikace
- Filtrování
- Asociace
- ...