Praktikum zo strojového učenia a umelej inteligencie na vizuálnych dátach

Andrej Lúčny

Katedra aplikovanej informatiky FMFI UK

lucny@fmph.uniba.sk

http://dai.fmph.uniba.sk/w/Andrej_Lucny

www.agentspace.org/praktikum

12

Strojové učenie

- Hlboké učenie je špeciálny druh strojového učenia
- Strojové učenie je empirický prístup k programovaniu
- Zo vzorových vstupov a výstupov skonštruujeme model
- Pomocou modelu transformujeme ďalšie vstupy

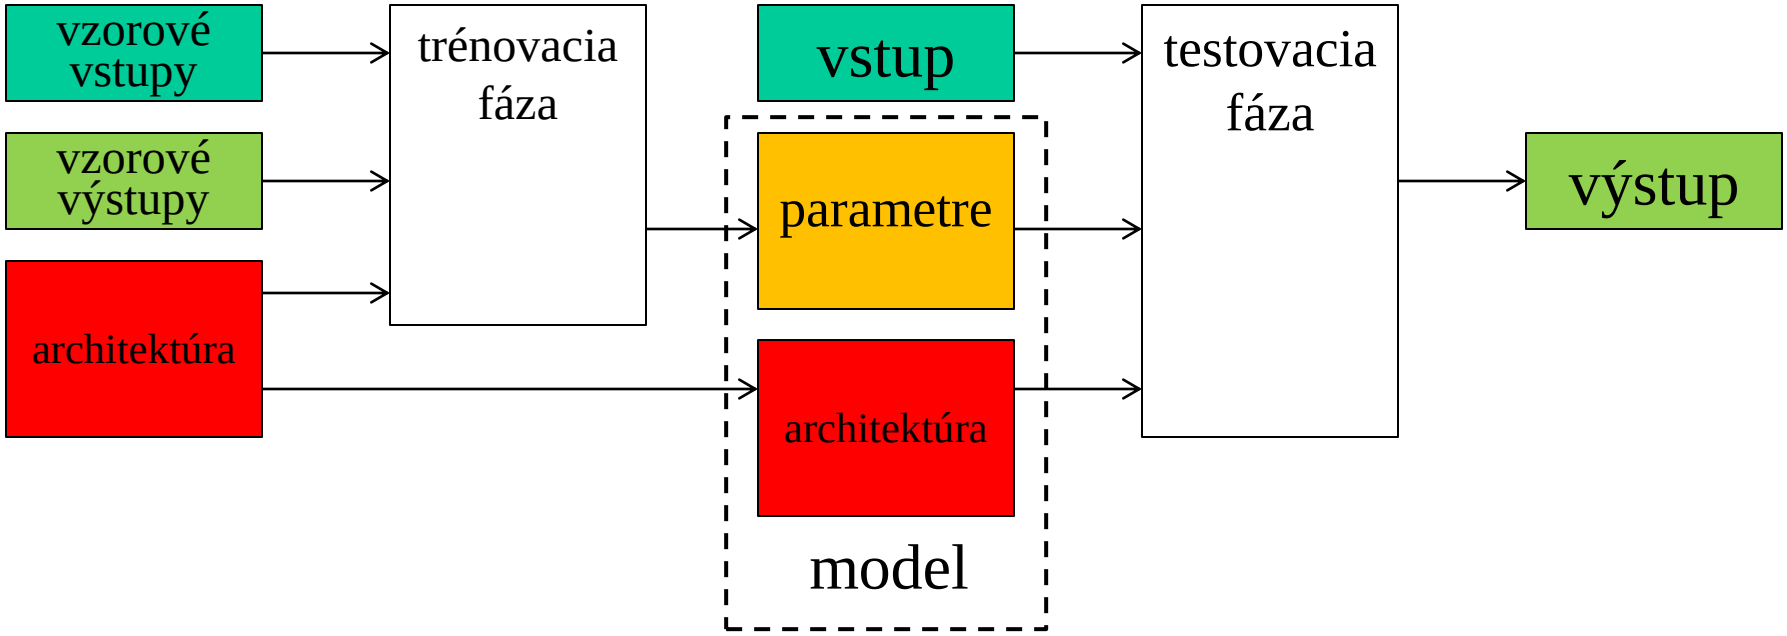

Dataset

Datasety majú stovky až desaťtisíce príkladov vstupu a želaného výstupu. Napr. dataset MNIST má 60000 vzoriek 28 x 28 x 1:

Univerzálny stroj

vzorový vstup

Predstavme si, že máme stroj, o ktorom vieme, že pri správnom nastavení kolečiek, realizuje našu úlohu, to správne nastavenie však nepoznáme...

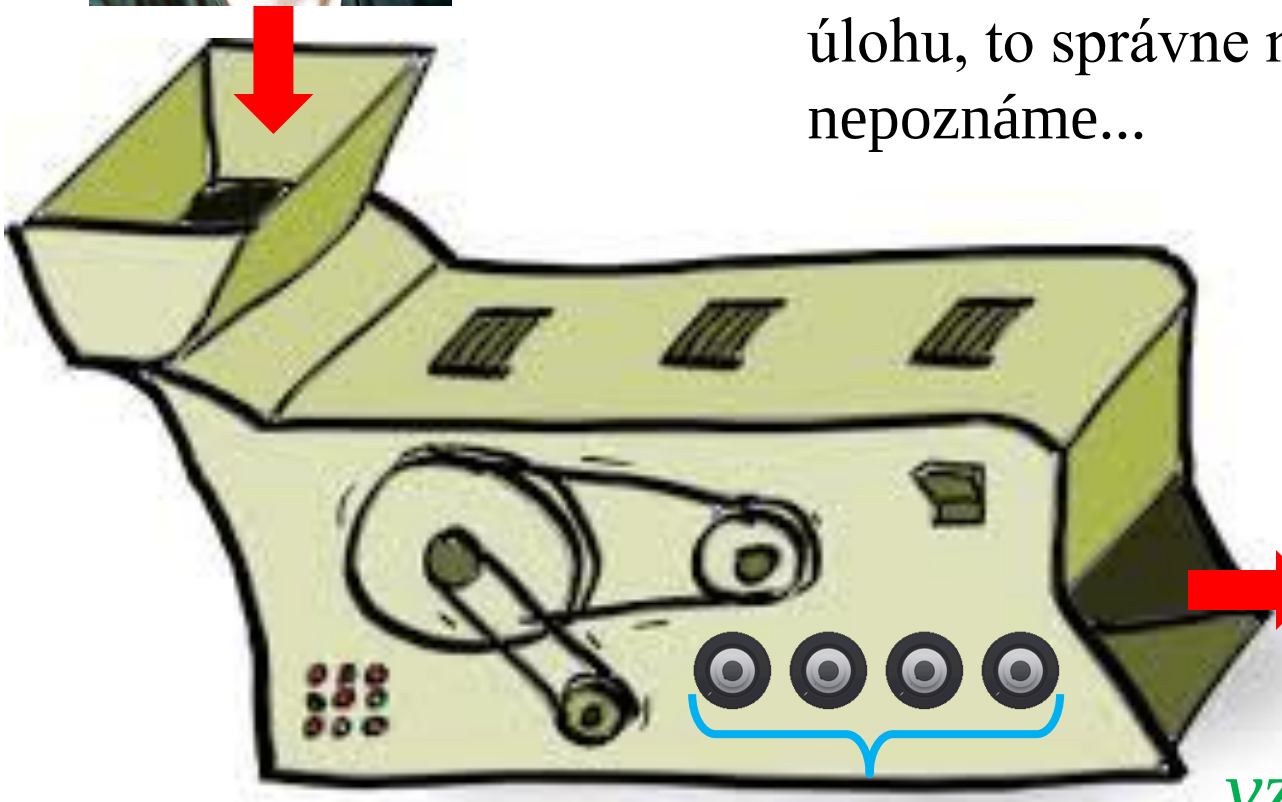

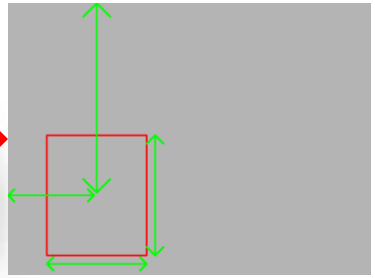

vzorový výstup

parametre

Univerzálny stroj

vzorový vstup

Niečo nastavíme, ale nedá nám to taký výstup aký chceme

vzorový výstup

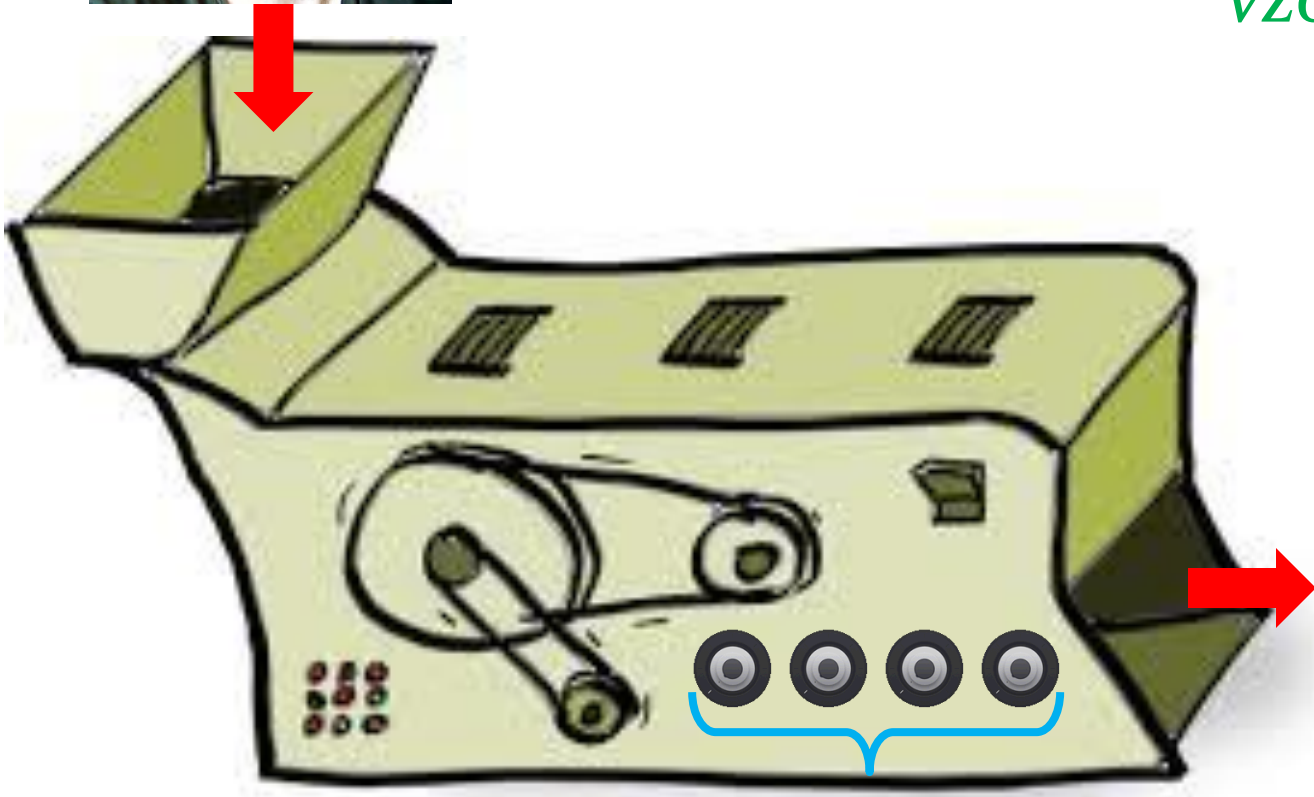

parametre

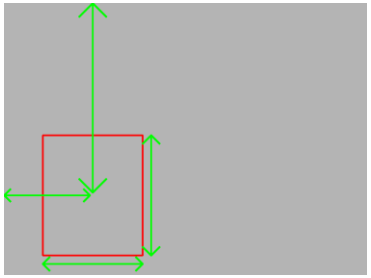

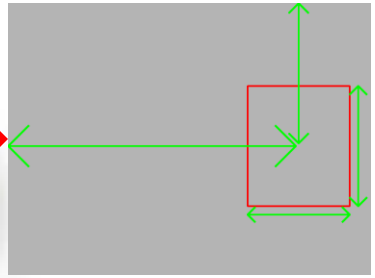

výstup

Univerzálny stroj

vzorový vstup

Určite by sme privítali, keby sme z porovnania vzorového výstupu a výstupu vedeli ako potočiť kolečkami, aby sa správanie stroja zlepšilo

vzorový výstup

parametre

výstup

Neurónová sieť

vzorový vstup

Presne túto vlastnosť má neurónová sieť

vzorový výstup

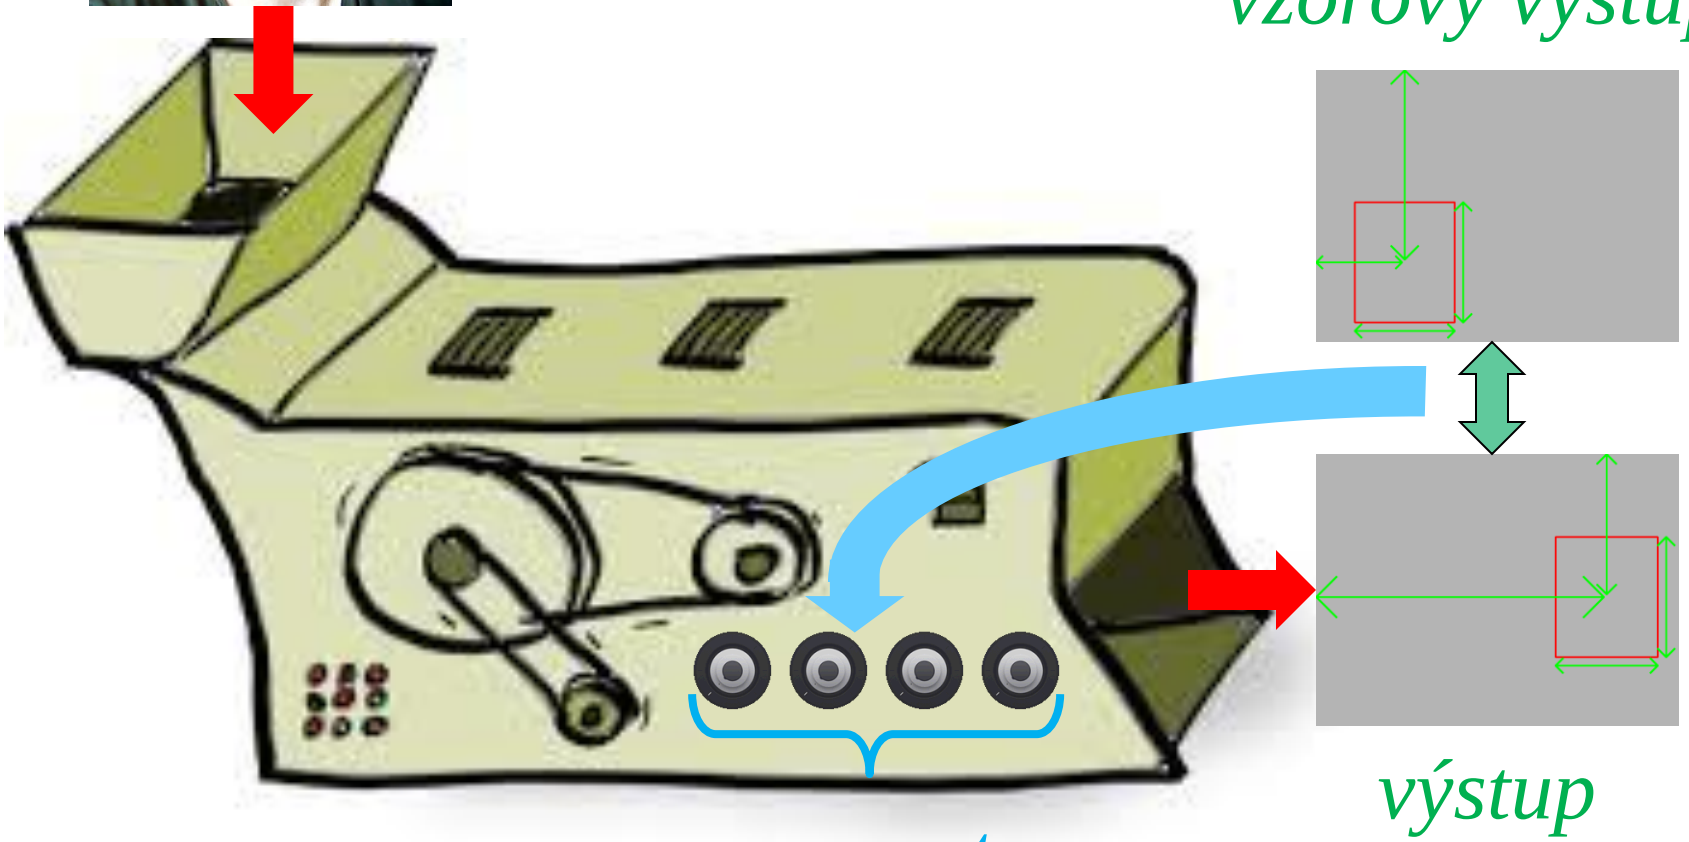

výstup

parametre

Trénovanie

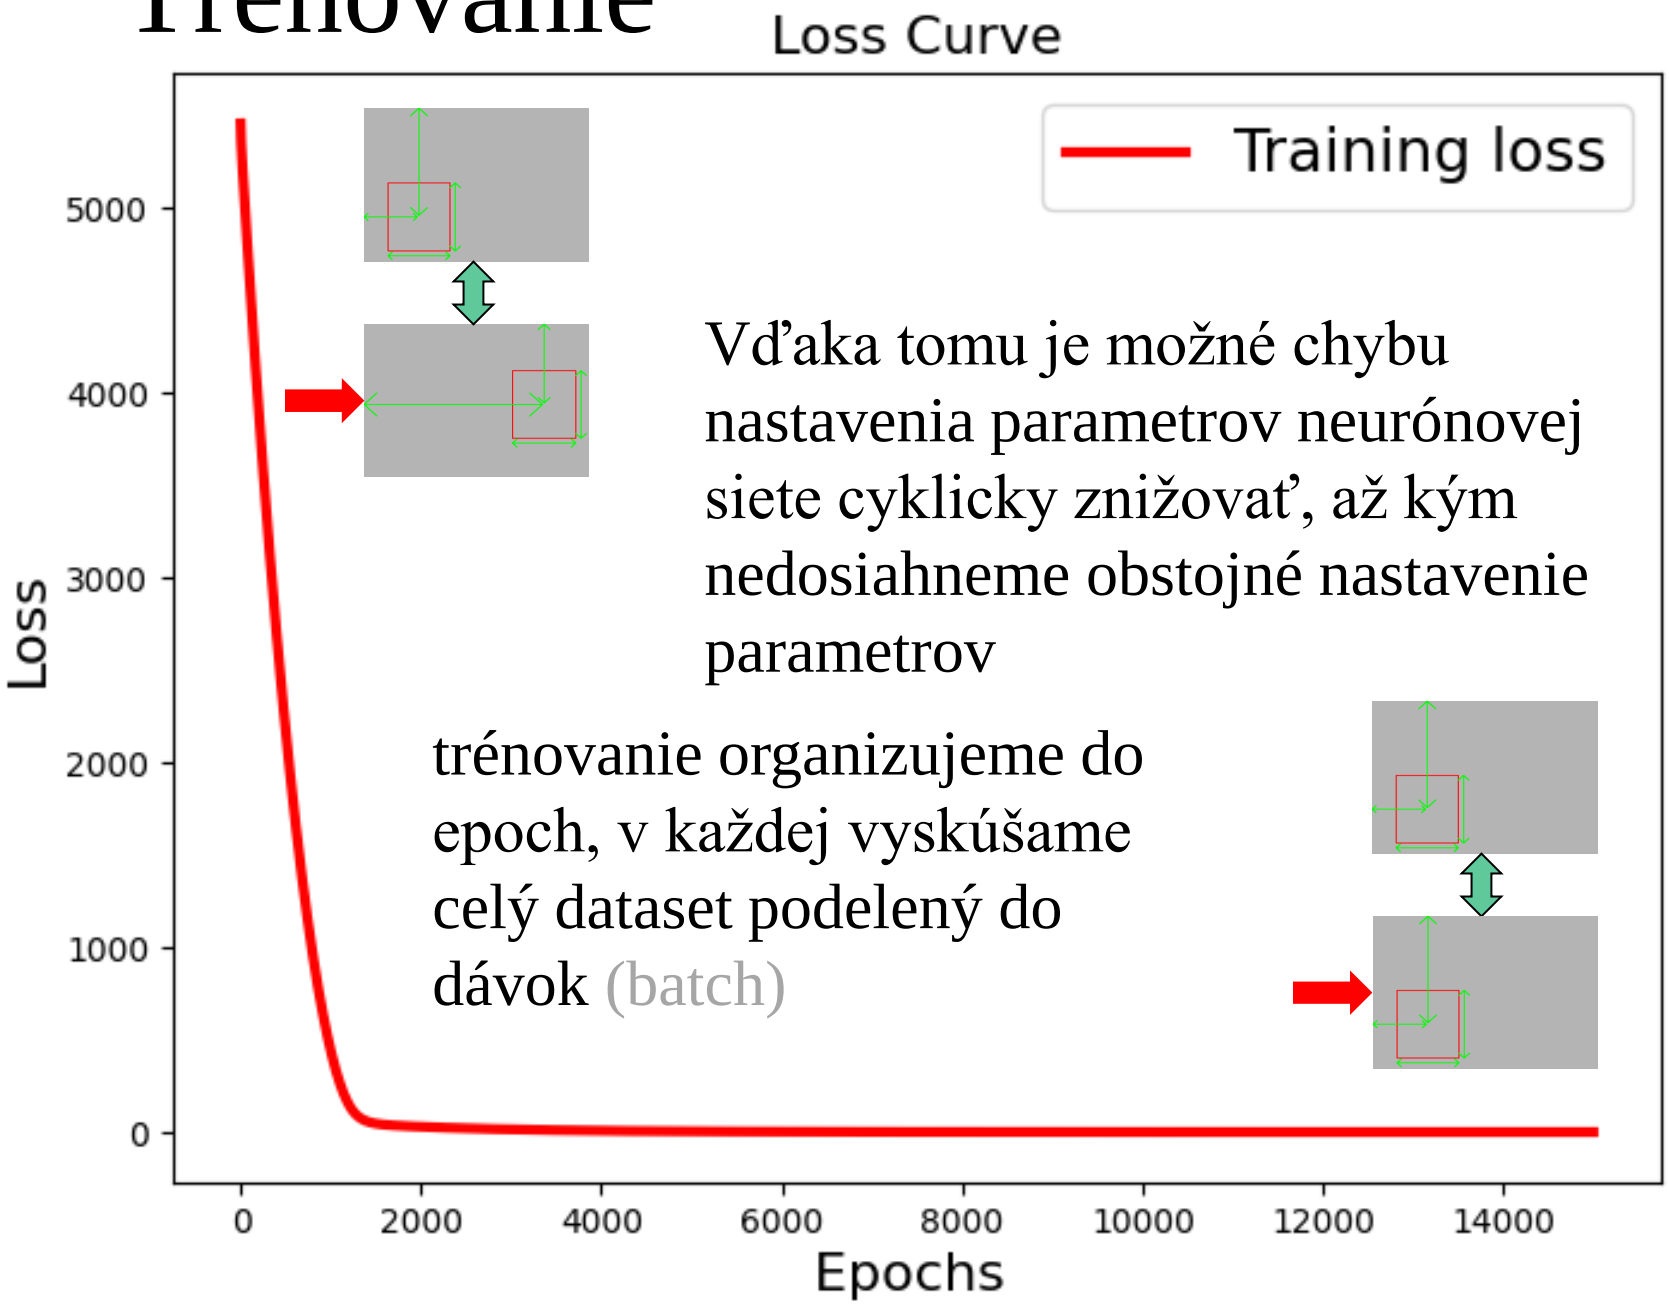

Vďaka tomu je možné chybu nastavenia parametrov neurónovej siete cyklicky znižovať, až kým nedosiahneme obstojné nastavenie parametrov

trénovanie organizujeme do epoch, v každej vyskúšame celý dataset podelený do dávok (batch)

Preučenie

vstup

Dúfame potom, že toto nastavenie bude fungovať aj pre vstupy, ktoré nemáme v datasete. Fungovať to nemusí. Najlepšie nastavenie nemusí byť to, ktoré dáva najmenšiu chybu na vzorkách

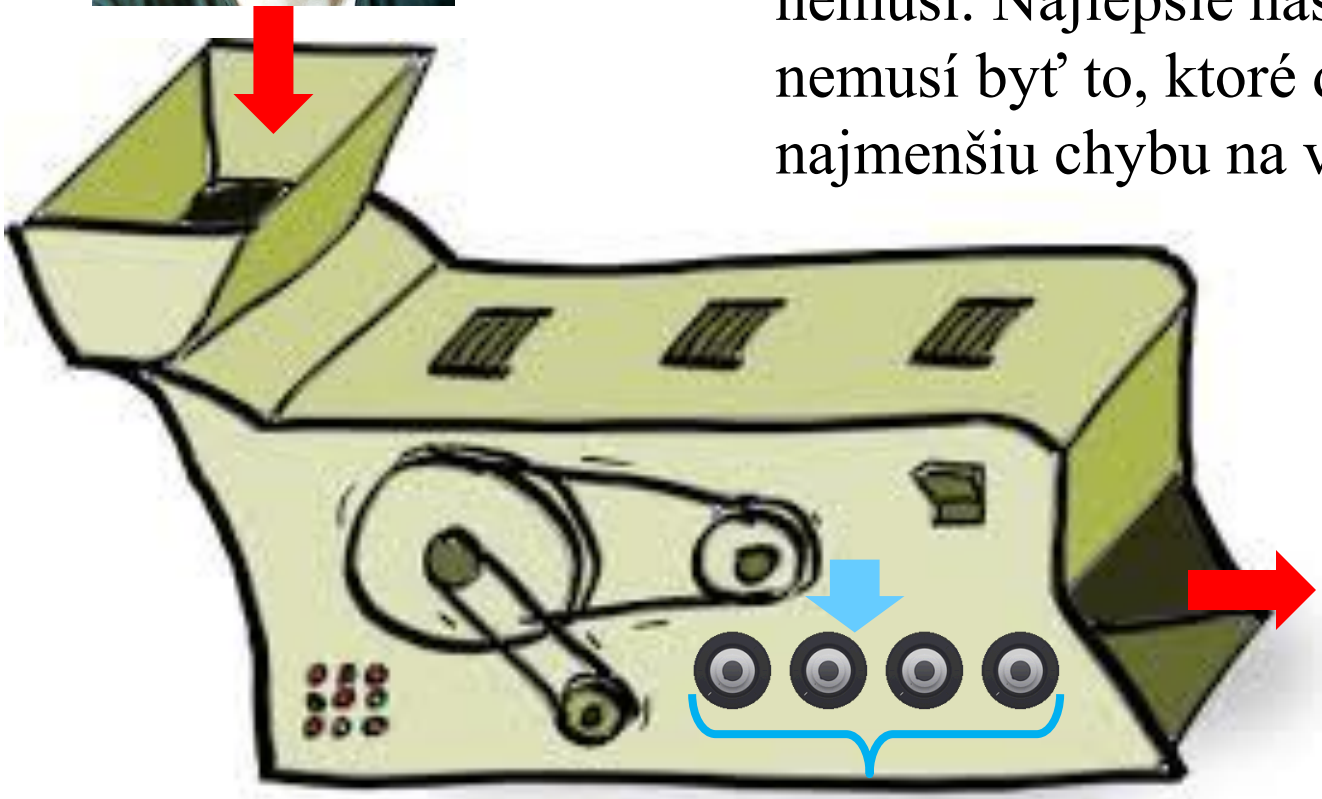

parametre

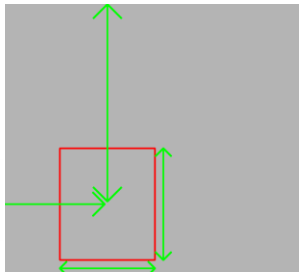

výstup

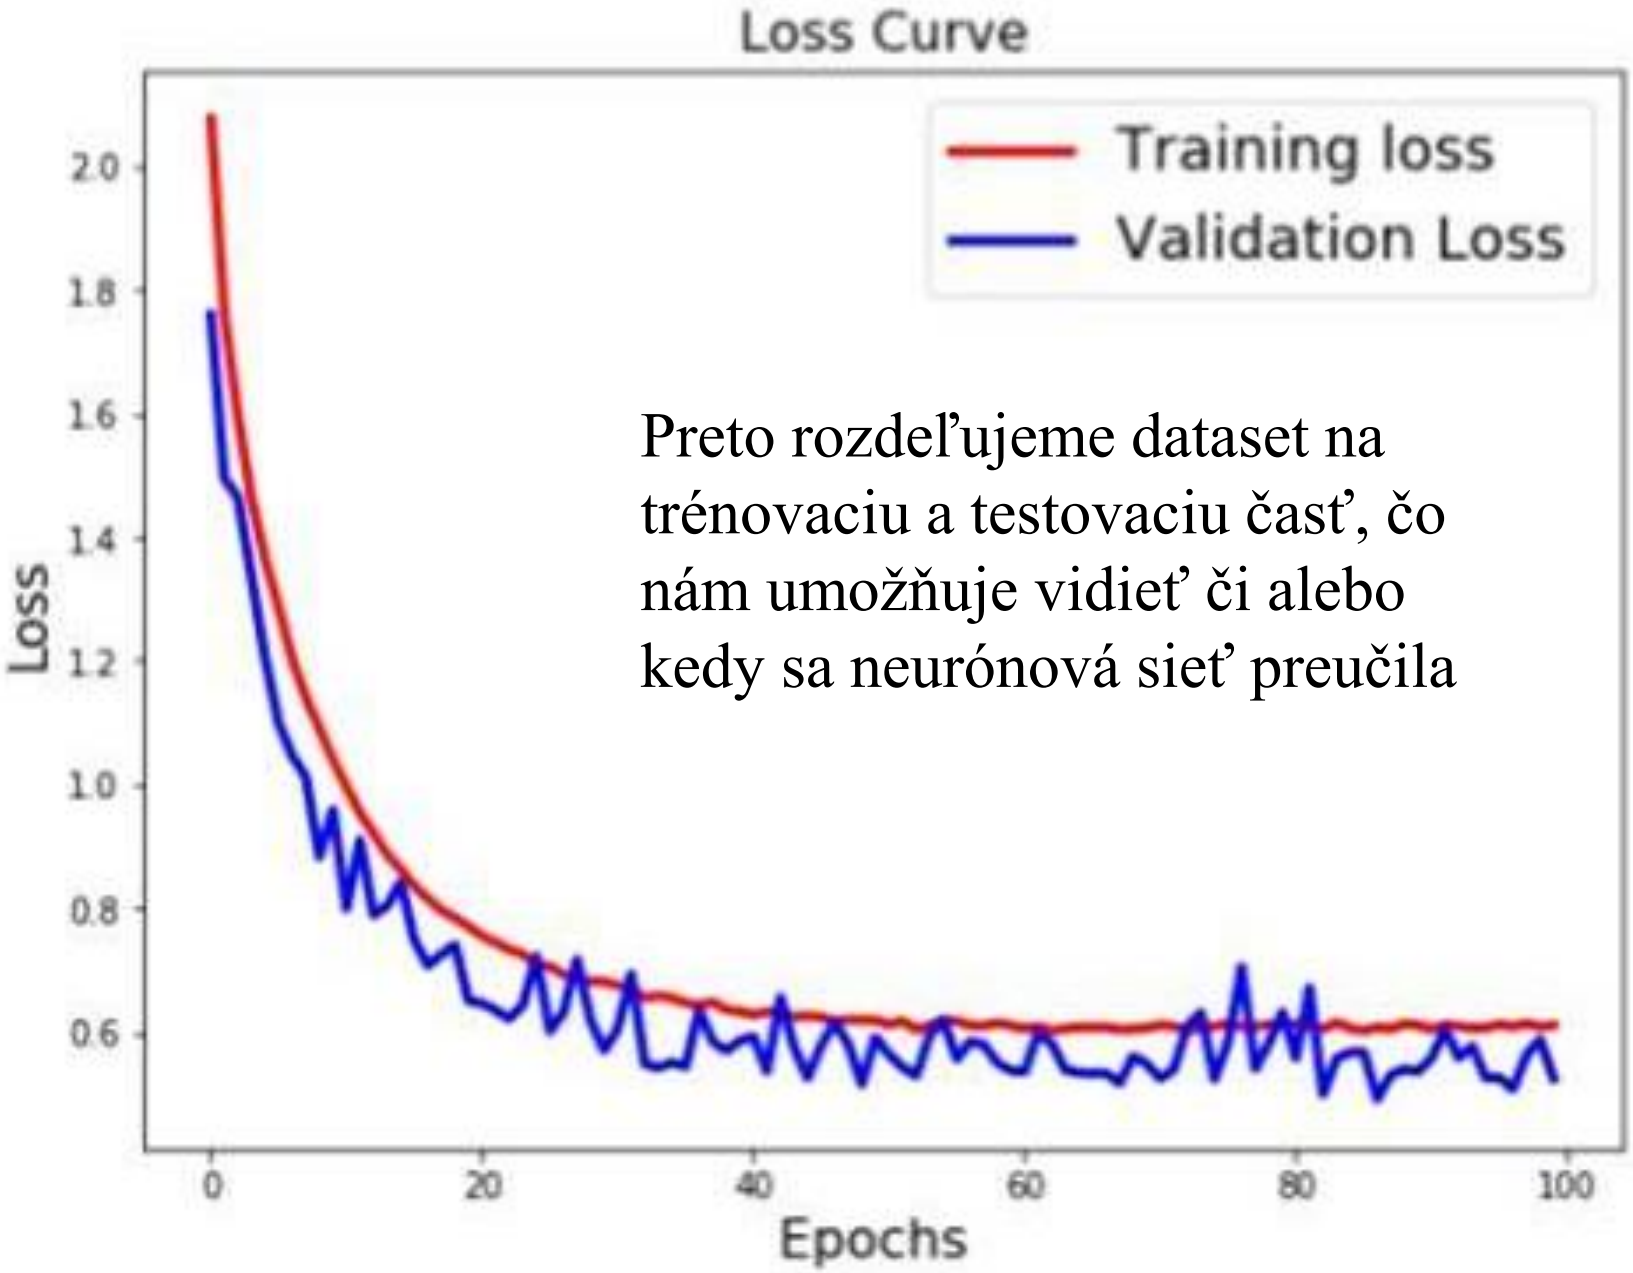

Preto rozdeľujeme dataset na trénovaciu a testovaciu časť, čo nám umožňuje vidieť či alebo kedy sa neurónová sieť preučila

Ako vyzerá taká neurónová sieť zvnútra?

- Hoci silnou motiváciou pri vymyslení vhodnej architektúry neurónovej siete bola snaha napodobniť ľudský mozog, podobá sa naň pramálo
- Kvôli tejto motivácii však nazývame základné stavebné prvky neurónmi
- Neuróny sú organizované do vrstiev
- Vrstvy sú organizované do blokov
- Každý blok spracúva jeden tenzor na druhý
- Tenzor je viacrozmerné pole dát, napríklad našich 10 obrázkov predstavuje vstupný tenzor s rozmermi
  10 x 416 x 416 x 3 (dávka, výška, šírka, počet kanálov)
  počet pixelov

Neurón

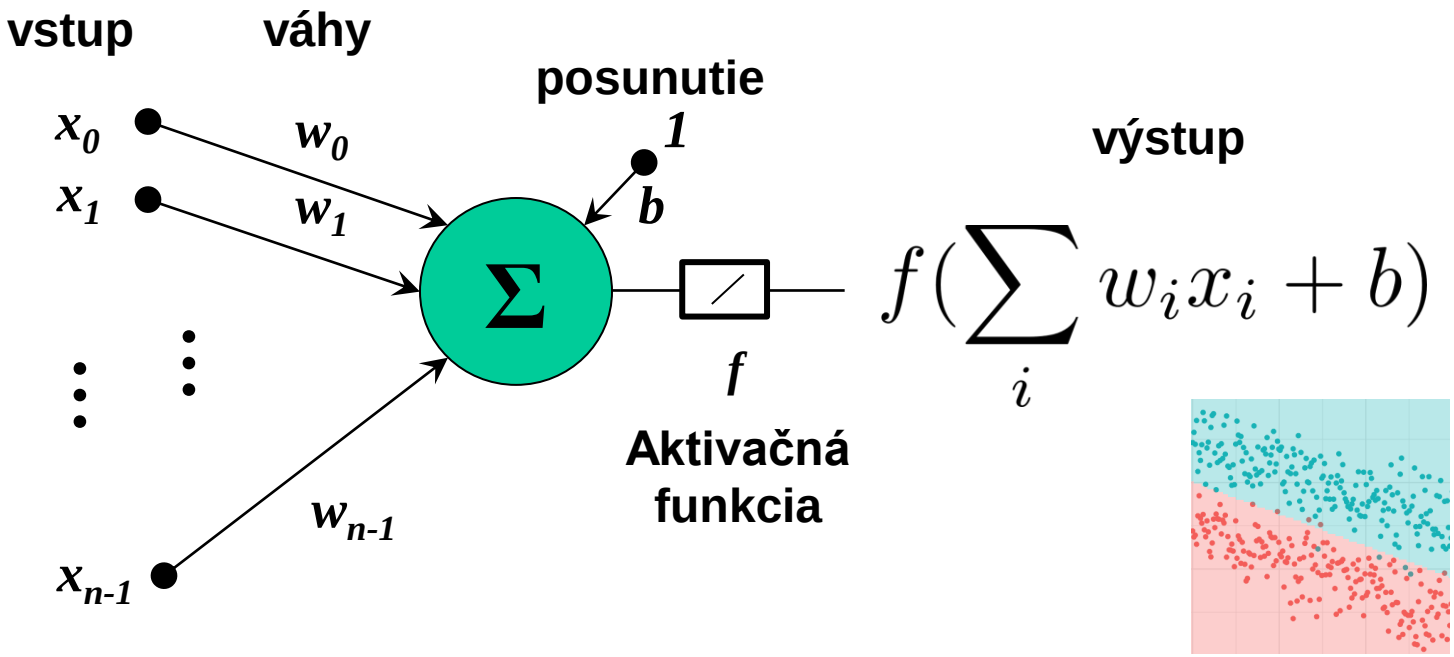

- Neurón počíta skalárny súčin vstupu s váhami, pripočíta posunutie a aplikuje aktivačnú funkciu
- Aktivačná funkcia môže byť: lineárna, sigmoida, hyperbolický tangens, …

Úvod: Aktivačné funkcie

Lineárna

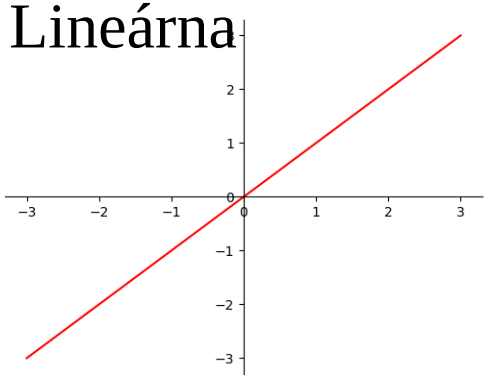

ReLU

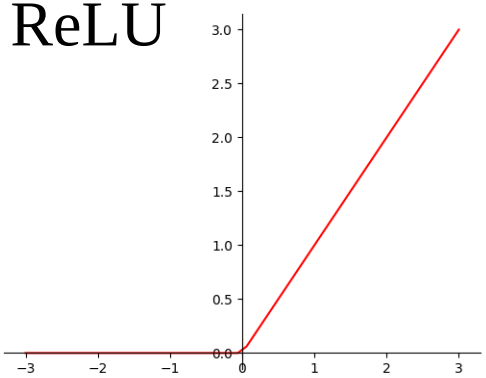

Leaky ReLU

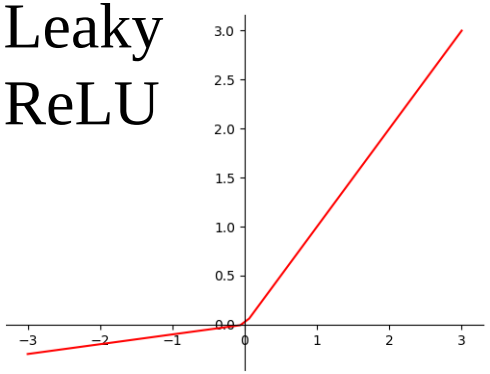

sigmoida

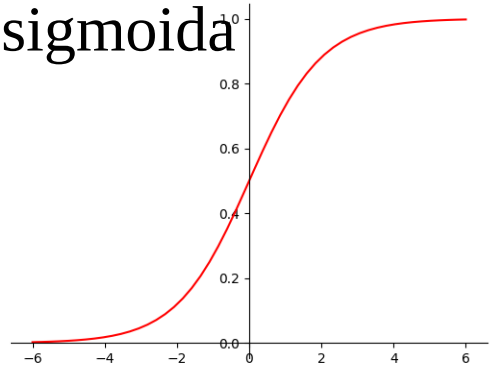

exp

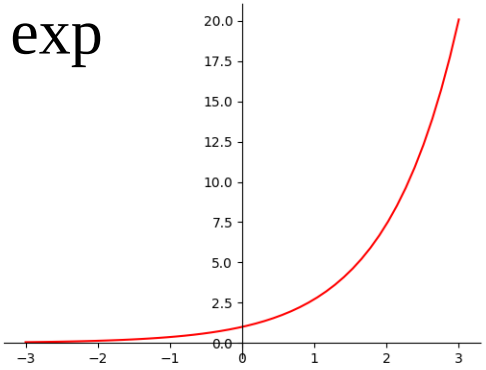

softmax

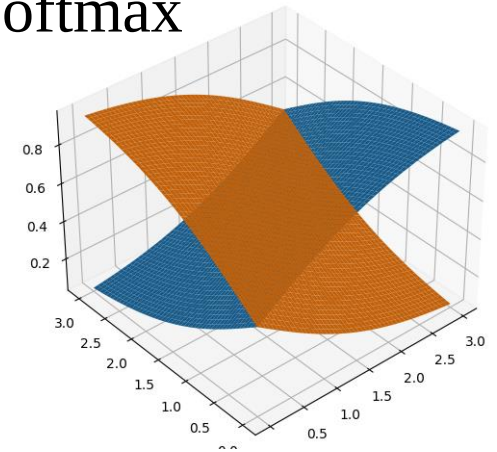

Perceptron

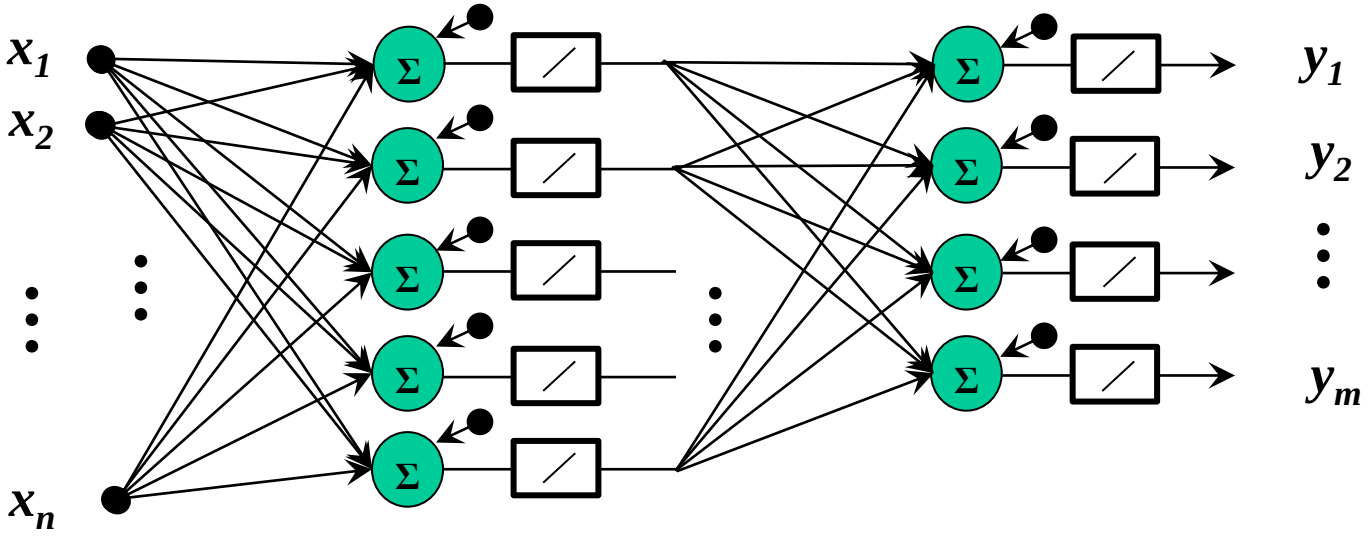

- jedna skrytá a jedna výstupná vrstva
- iba lineárna aktivácia
- možnosť trénovať len váhy výstupnej vrstvy

[1958 Rosenblatt]

Perceptron

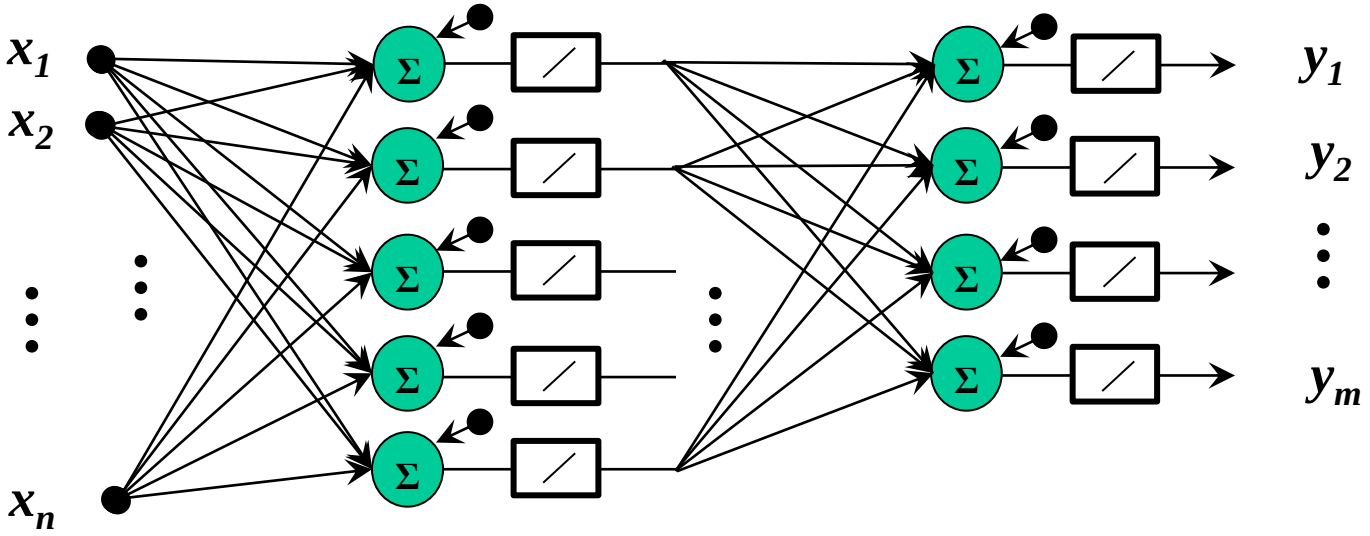

- analýza schopností perceptronu dokázala, že toho vie dosť málo
- neskôr sa však ukázalo, že jeho neveľká úprava situáciu dramaticky zmení

[1968 Minsky]

Logistický regresor

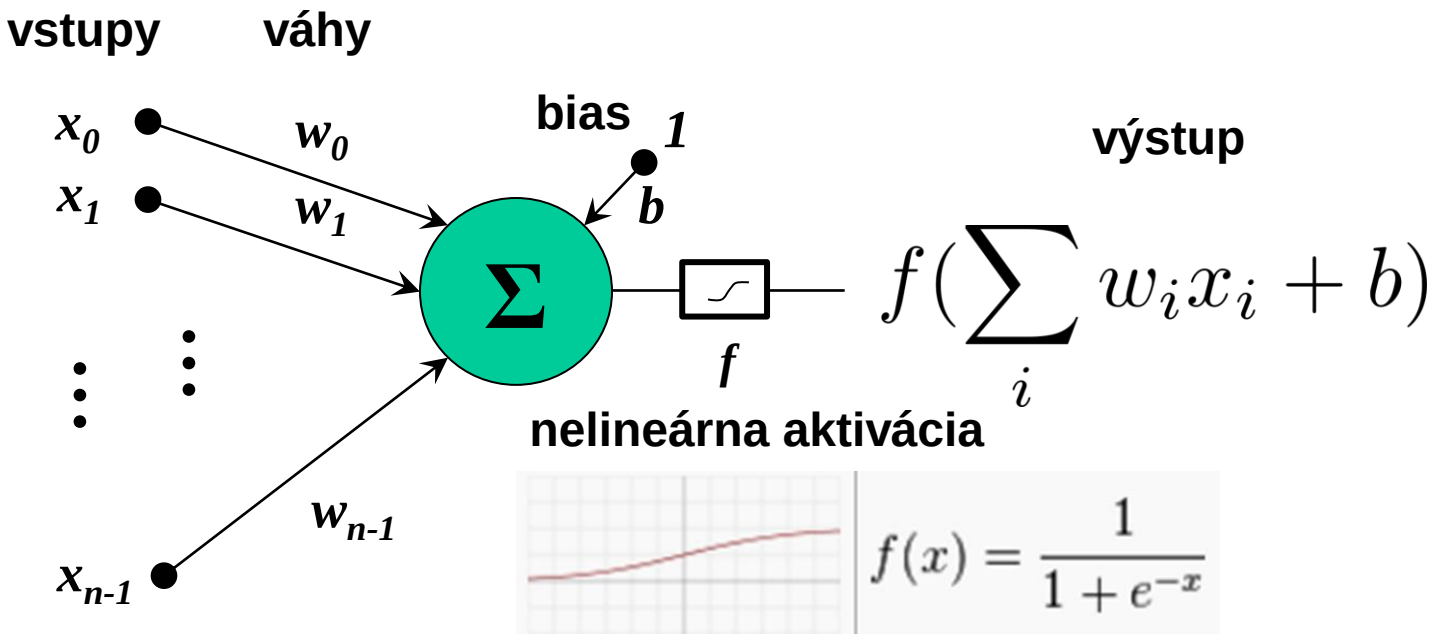

- keď miesto lineárnej aktivácie použijeme logistickú funkciu (sigmoidu) alebo hyperbolický tangens, trénovanie jedného takéhoto neurónu zodpovedá logistickej regresii a potenciál neurónu byť stavebnou jednotkou siete sa dramaticky zlepší

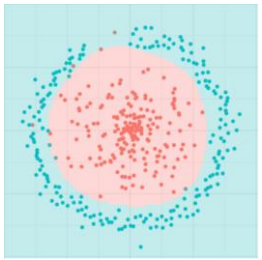

Perceptron + nelinearita + BP

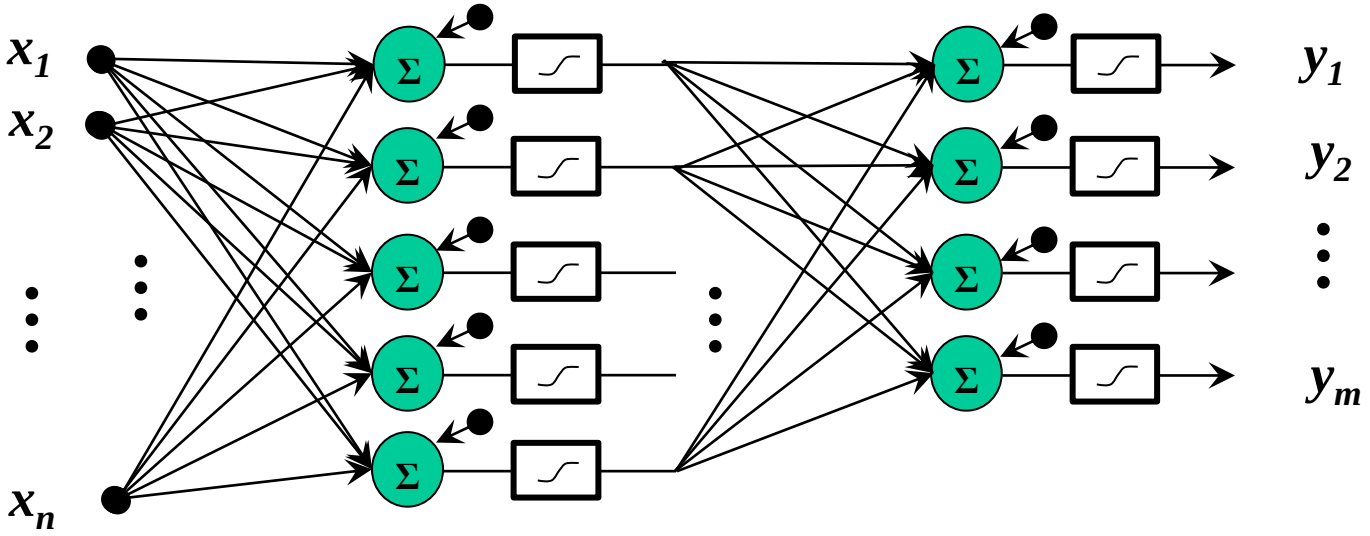

- Algoritmus spätného šírenia (Back propagation) – pomocou pravidla derivácie zloženej funkcie [Leibnitz 1676] na trénovanie algoritmom spätnej propagácie (back propagation)

[1986 Rumelhart, Hinton & Williams]

Univerzálny aproximátor

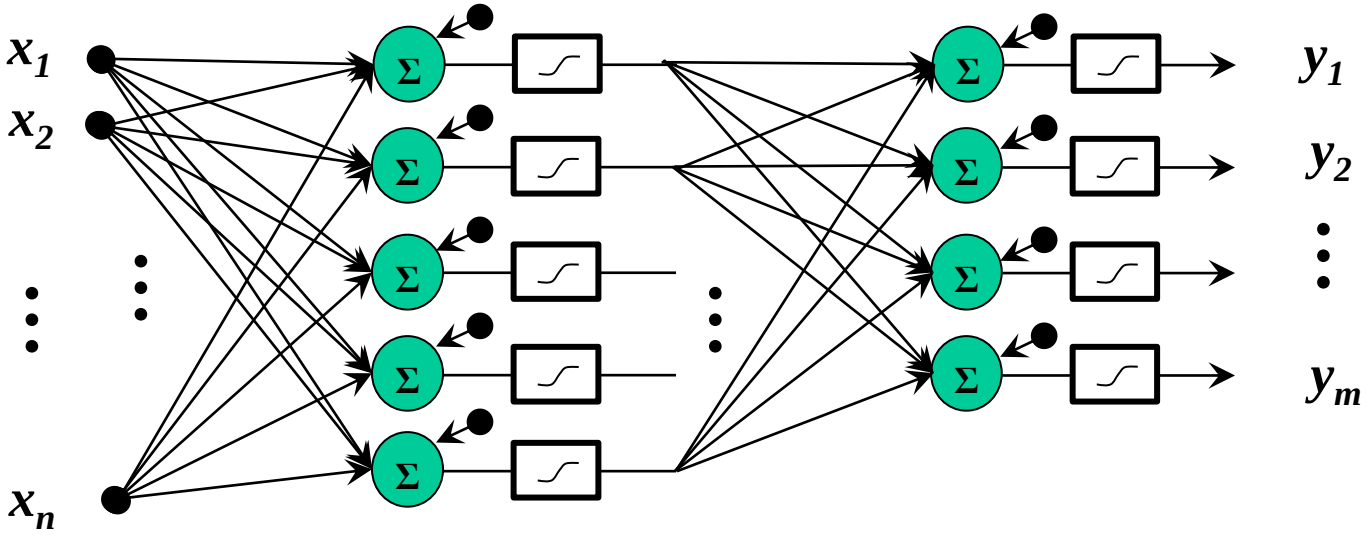

- matematicky bolo dokázané, že perceptron sa teoreticky dokáže s ľubovoľnou presnosťou naučiť akúkoľvek rovnomerne spojitú funkciu [1989 Cybenko] [1989 Hornik]
- prakticky sa to však podarilo uskutočniť len pre vstupy pomerne malej dimenzie, pre naše obrazové dáta s dimenziou 519168 = 416 x 416 x 3 je to nepoužiteľné