

# KLASIFIKAČNÍ MOŽNOSTI NEURONŮ

Václav Žáček

*Ostravská Univerzita v Ostravě, 30. dubna 22  
701 03 Moravská Ostrava, +420777 809 948, R09276@student.osu.cz*

## Úvod

V současné době vznikly nové druhy neuronových sítí, které mají velice slibné výsledky z hlediska možností klasifikace [1][2]. Úkolem tohoto příspěvku je porovnat tyto možnosti na jasně definovaných logických funkcích. Je kladen důraz na zjištění klasifikačních možností sítí typu: Perceptron, Adaline, RBF a SVM na lineárně a nelineárně separabilních funkcích. V příspěvku jsou zmíněny konkrétní nastavení modelů, pro které je možné vybrané funkce bezchybně klasifikovat. Jako výsledek tohoto měření je očekáváno rozdělení neuronů podle schopnosti klasifikovat lineárně a nelineárně separabilní funkce.

## Použité funkce

Pro demonstraci byly použity tři funkce. Dvě z nich jsou lineárně separabilní (funkce AND, OR). Třetí funkce (XOR) je nelineárně separabilní. Všechny 3 funkce byly realizovány pomocí čtveřice bodů a rozděleny skupinami tak, aby jejich logický význam byl dodržen. Jednalo se o tyto body:  $\{[1,1];[1,0];[0,1];[0,0]\}$ . Pro funkci AND bylo nastavení:  $[1,1]$  – kladná odezva a  $[1,0];[0,1];[0,0]$  – nulová odezva. Pro funkci OR bylo nastavení:  $[1,1];[1,0];[0,1]$  – kladná odezva a  $[0,0]$  – nulová odezva. Pro funkci XOR bylo nastavení:  $[1,0];[0,1]$  – kladná odezva a  $[0,0];[1,1]$  – nulová odezva.

## Nastavení modelů

Všechny modely pracovaly s bipolární prezentací dat (0 a 1). U modelu Perceptronu a Adaline se postupně nastavovaly hodnoty na vstupních vahách tak, aby bylo dosaženo bezchybné a co nejrychlejší adaptace při daných funkcích. Model RBF vyžadoval nastavení většího množství parametrů při počátečním nastavení počtu a středů RBF neuronů, jejich rozsahů a zvolení vhodné transformační funkce. Na počátku adaptace se upravovaly pouze lineární vazby skryté vrstvy na výstupní neuron. SVM požadují nastavení vhodné transformační funkce stejně jako RBF neurony. Po tomto nastavení se vyberou podpůrné vektory (body ležící nejbližší optimální dělicí přímce) a z jejich lineárních kombinací a vyřešení problému kvadratického programování („Quadratic programming“) je získána směrnice a posun dané přímky.

## Výsledky měření

Nad každou funkcí bylo postupně provedeno dvacet měření pro každý model. Modely byly v učení omezeny na sto kroků. V závislosti na nastavení počátečních vah probíhalo učení v některých případech rychleji (potřeba 2 cyklů pro Perceptron) případně pomaleji (potřeba 5 cyklů). V případě funkcí AND a OR byly všechny modely schopny správně klasifikovat, dříve než se dostaly k omezujícímu počtu cyklů. RBF model používal Gaussovu transformační funkci:

$$e^{-\left(\frac{\|x_j - c_i\|}{b_i}\right)^2}$$

kde  $x_j$  jsou jednotlivé vstupní vektory,  $c_i$  jsou souřadnice středů RBF neuronů a  $b_i$  je rozsah neuronu, který byl nastaven na jedna. Model SVM používal v tomto případě lineární transformační funkci. U funkce XOR však při různých nastaveních vstupních vah nebyly modely

Perceptron a Adaline schopné správné klasifikace ani po dosažení omezení počtu kroků. U RBF modelu byla stejně jako u funkcí AND a OR použita Gaussova transformační funkce. Model SVM využíval v tomto případě také Gaussovu transformační funkci. Jak RBF model tak SVM model byly schopny danou funkci bezchybně klasifikovat.

## **Závěr**

Měřením bylo zjištěno, že neurony typu Perceptron a Adaline jsou schopny řešit pouze lineárně separabilní problémy. Pokud bychom chtěli, aby tyto neurony byly schopny řešit nějaké složitější problémy, museli bychom využít jejich spojení ve složitější struktuře, to jest vícevrstvé síti. Neurony typu RBF a SVM jsou také schopny řešit bez větších obtíží problémy, které jsou lineárně separabilní. Navíc jsou oproti neuronům Perceptron a Adaline schopny řešit problémy nelineárně separabilní. Tato schopnost je ale vykoupena zvýšením složitosti daného algoritmu adaptace. Příkladem může být u sítě RBF třífázové[1] učení a u sítě SVM vytvoření lineárních kombinací podpůrných vektorů.

***Klíčová slova: Perceptron; Adaline; RBF; SVM***

## **Literatura**

1. HLAVÁČKOVÁ, Kateřina a Roman NERUDA. Radial basis function network. In: Neural network world: international journal on neural and mass-parallel computing and information systems. Prague 8: Institute of Computer Science AS, 1993, s. 93-101. ISBN 1210-0552ISSN 1210-0552.
2. CORTES, Corinna a Vladimír VAPNIK. Support-vector networks. In: PURELIS, Eileen. Machine learning. New York, NY 10013-1578: Springer, 1995, s. 25. 20, 3. ISSN 1573-0565. DOI: 10.1007/BF00994018. Dostupné z: <http://www.springerlink.com/content/k238jx04hm87j80g/>