

# NEURAL NETWORK IMPLEMENTATION INTO MICROCONTROLLER

**Justin Čermák**

Bachelor Degree Programme (3), FEEC BUT  
E-mail: xcerma01@stud.feec.vutbr.cz

Supervised by: Marek Bohrn  
E-mail: xbohrn00@stud.feec.vutbr.cz

## ABSTRACT

This article handles about implementation of multi layer neural networks for character recognition into the PC and microcontrollers. The practical part describes how to design and implement a simple program for pattern recognition of numbers using multi layer neural networks.

## 1. ÚVOD

Pro řízení různých systémů, se kromě jednoduché (dvouhodnotové) rozhodovací logiky, využívána i tzv. fuzzy (mlhavá, rozmazaná, neurčitá) logika. Fuzzy logika umožňuje pracovat s vícehodnotovou logikou, kdy výstup funkcí může nabývat hodnoty v intervalu  $\langle 0,1 \rangle$ , což umožní s určitou pravděpodobností matematicky popsat nejistotu v systému. Fuzzy logika i jednoduchá rozhodovací logika ale nemůže být použita v aplikacích, ve kterých neznáme matematický popis funkce řízeného systému.

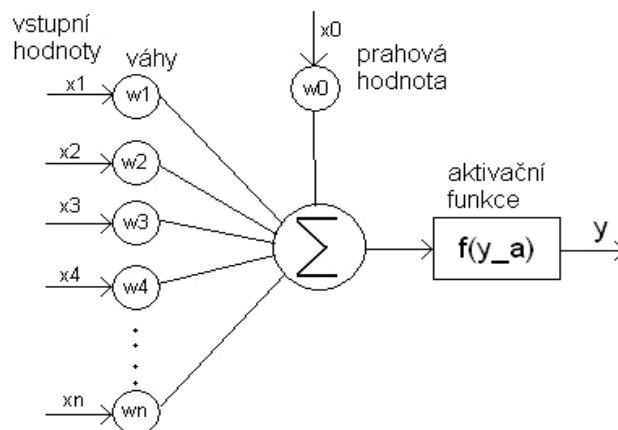
Výše popsany problém řeší umělé neuronové sítě (UNS), jež nacházejí uplatnění ve všech oborech lidské činnosti např. předpověď počasí, spotřební elektronika (detekce úsměvu nebo obličeje v digitálních fotoaparátech), řízení strojů a zařízení nebo detekce poruch. Jejich největší výhodou spočívá v možnosti učení podle příkladů, bez nutnosti znalosti matematického popisu řízeného systému.

## 2. ROZBOR

UNS si berou vzor v biologické neuronové síti, společné pro každý živý organismus. Při návrhu umělých neuronových sítí se vychází z neurofyzilogických poznatků, jako je struktura, stavební elementy, uspořádání a funkce biologických neuronových sítí. UNS modeluje činnost biologických neuronových sítí.

### 2.1. NEURON (PERCEPTRON)

Jedná se o základní stavební článek všech UNS, složitější struktury se vytvářejí spojováním neuronů.



**Obrázek 1:** Základní schéma neuronu

Neuron počítá svůj výstupní potenciál jako:

$$y\_a = \sum_{i=0}^N w_i \cdot x_i + w_0 \cdot x_0 \quad (1)$$

Z výstupního potenciálu se poté vytvoří příslušná aktivační funkce:

$$y = f(y\_a) \quad (2)$$

Dle průběhu rozeznáváme několik typů funkcí skokovou, lineární nebo sigmoidovou aktivační funkci.

## 2.2. SPOJOVÁNÍ NEURONŮ

Spojování neuronů do sítí, nám umožní řešit složitější úkoly, na které by samotný neuron nestačil. Při spojování neuronů platí, že výstup jednoho neuronu bývá připojen na vstup několika dalších neuronů. Neurony se v UNS rozdělují do vrstev. Rozlišujeme vstupní, skrytou a výstupní vrstvu.

Neurony ve vstupní vrstvě zajišťují vstup signálu z okolí a jeho rozdělení do vrstev následujících.

Jako skrytá vrstva jsou označovány všechny vrstvy ležící mezi vstupní a výstupní vrstvou. Úkolem těchto vrstev je zvýšit aproximační schopnosti celé sítě. Těchto vrstev může být neomezené množství.

Výstupní vrstva je poslední vrstvou umělé neuronové sítě, slouží k předávání výstupního signálu do okolí. Výstupní signál je vlastně odezva sítě na vstupní signál.

## 2.3. UČENÍ UMĚLÉ NEURONOVÉ SÍTĚ

Toto patří mezi nejdůležitější schopnosti UNS. Při učení dochází k modifikaci vah (případně i prahů), cílem je dosažení správné odezvy neuronové sítě na vstupní hodnoty, tzn. dosažení shody mezi aktuálním a požadovaným výstupem neuronové sítě. Způsob, jakým bude docházet k modifikaci vah, určuje učící algoritmus.

V tomto projektu je pro učení využíván algoritmus Error Back Propagatio. Tento algoritmus pracuje na principu postupného přikládání trénovacích hodnot na vstupy sítě a následné modifikace jednotlivých spojení dle rozdílu aktuálního a požadovaného výstupu.

### 3. REALIZACE UMĚLÉ NEURONOVÉ SÍTĚ

Vytvořil jsem počítačový program, umožňující testování zvolené konfigurace UNS a použitého algoritmu učení. V programu lze vytvářet a upravovat trénovací řady, v případě potřeby je možné zobrazit výpis jednotlivých vah a prahových hodnot.

Jako trénovací hodnoty se využívají nakreslené vzory čísel 0-9. Každé z čísel je nakresleno v poli 8x11 prvků a poté je rozděleno na 88 samostatných segmentů. Každý segment může nabývat hodnoty 0 (bílá) nebo 1 (černá). Číselná řada tvořená čísly 0-9 se nazývá trénovací řada. Pro větší úspěšnost rozpoznání čísla používám pro učení umělé neuronové sítě 10 různých trénovacích řad.



Obrázek 2: Trénovací řada

000011000001101100110001011000010100001101000010010000100100011000111100001100000000000

Obrázek 3: Příklad číselného zápisu pro „0“

V projektu využívám UNS obsahující 88 vstupních, 40 skrytých a 10 výstupních neuronů.

Každému výstupnímu neuronu odpovídá jedno z čísel. Pokud je obraz úspěšně rozpoznán, je příslušný výstupní neuron aktivní (výstup má hodnotu 1), zatímco ostatní výstupní neurony jsou neaktivní (výstupy mají hodnotu 0).

### 4. ZÁVĚR

Umělé neuronové sítě představují jednoduchý nástroj pro řízení různých druhů systémů.

Nevýhodou umělých neuronových sítí je doba učení, jež vzrůstá s velikostí sítě a složitostí řízeného systému.

V současnosti pracuji implementaci umělé neuronové sítě do 16bit mikrokontroléru.

### LITERATURA

- [1] ŠÍMA, Jiří, NERUDA, Roman. *Teoretické otázky neuronových sítí*. Praha : MATFYZPRESS 1996. 390 s. Dostupný z WWW: <<http://www2.cs.cas.cz/~sima/kniha.pdf>>.
- [2] DRÁBEK, O., SEIDL, P., TAUFER, I. Umělé neuronové sítě – základy teorie a aplikace (3). CHEMagazín : Časopis pro chemicko-technickou a laboratorní praxi [online]. 2006, roč. XVI, č. 3 [cit. 2008-11-06]. Dostupný z WWW: <[http://www.chemagazin.cz/Texty/CHXVI\\_1\\_cl3.pdf](http://www.chemagazin.cz/Texty/CHXVI_1_cl3.pdf)>.
- [3] DRÁBEK, O., SEIDL, P., TAUFER, I. Umělé neuronové sítě – základy teorie a aplikace (5). CHEMagazín : Časopis pro chemicko-technickou a laboratorní praxi [online]. 2006, roč. XVI, č. 5 [cit. 2008-11-06]. Dostupný z WWW: <[http://www.chemagazin.cz/Texty/CHXVI\\_5\\_cl6.pdf](http://www.chemagazin.cz/Texty/CHXVI_5_cl6.pdf)>