

Univerzita Pardubice  
Fakulta ekonomicko – správní

Klasifikace ekonomických subjektů pomocí neuronových sítí  
Zuzana Kratochvílová

Bakalářská práce

2008

Univerzita Pardubice  
Fakulta ekonomicko-správní  
Ústav systémového inženýrství a informatiky  
Akademický rok: 2007/2008

## **ZADÁNÍ BAKALÁŘSKÉ PRÁCE**

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Zuzana KRATOCHVÍLOVÁ**  
Studijní program: **B6209 Systémové inženýrství a informatika**  
Studijní obor: **Informatika ve veřejné správě**

Název tématu: **Klasifikace ekonomických subjektů pomocí neuronových sítí**

Z á s a d y p r o v y p r a c o v á n í :

Klasifikační problém  
Neuronové sítě  
Klasifikace ekonomických subjektů pomocí dopředných neuronových sítí  
Analýza výsledků

Rozsah grafických prací:

Rozsah pracovní zprávy:

Forma zpracování bakalářské práce: **tištěná/elektronická**

Seznam odborné literatury:

**OLEJ, V. Modelovanie ekonomických procesov na báze výpočtovej inteligencie. Hradec Králové : M&V, 2003.**


**HAYKIN, S.S. Neural Networks: A Comprehensive Foundation. Upper Saddle River : Prentice Hall, 1999.**

**KVASNIČKA, V. a kol. Úvod do teórie neurónových sietí. Bratislava : IRIS, 1997.**

**MAŘÍK, V. a kol. Umělá inteligence (1). Praha : Academia, 1993.**

**MAŘÍK, V. a kol. Umělá inteligence (4). Praha : Academia, 2003.**

Vedoucí bakalářské práce:

  
**Ing. Petr Hájek, Ph.D.**  
Ústav systémového inženýrství a informatiky

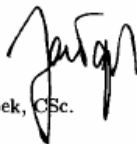
Datum zadání bakalářské práce:

**30. října 2007**

Termín odevzdání bakalářské práce:

**19. května 2008**

prof. Ing. Jan Čapek, CSc.  
děkan



L.S.



doc. Ing. Pavel Petr, Ph.D.  
vedoucí ústavu

V Pardubicích dne 30. října 2007

**Poděkování:**

Na tomto místě bych ráda poděkovala Ing. Petru Hájkovi, vedoucímu práce za vlídný přístup a cenné rady, které mi poskytl při konzultacích k této práci.

## SOUHRN

Ve své práci se zabývám klasifikací ekonomických subjektů pomocí neuronových sítí. Těmito ekonomickými subjekty jsou obce České republiky. V první části práce se zabývám popsáním základních použitých pojmů. Mezi tyto termíny patří klasifikace a neuronové sítě. V následující kapitole jsou zpracována data takovým způsobem, aby je bylo možno použít pro klasifikaci. Poslední a současně nejdůležitější částí práce je samotné zpracování dat pomocí zvoleného softwaru, zpracování výsledků a jejich vyhodnocení.

## KLÍČOVÁ SLOVA

neuronové sítě, klasifikace, perceptron

## TITLE

Classification economic entities with neural network

## ABSTRACT

This thesis deals with the classification of economic subjects by means of neural networks. These economic subjects are municipality within the Czech Republic. The first part this work deals with description of basic definitions used in the thesis. There belong the terms classification and neural network. In the following part there all the data processed in the way they can be consequently used for classification. Last and at the same time the most important part is the action of data processing by way of selected software. This last part is included in processing results and in their interpretation.

## KEYWORDS

neural network, classification, perceptron

## OBSAH:

1	Úvod.....	7
2	Data a jejich předzpracování.....	8
2.1	Návrh použitých parametrů na ohodnocování obcí .....	8
3	Klasifikace pomocí neuronových sítí .....	11
3.1	Všeobecný klasifikační problém.....	11
3.2	Neuronové sítě .....	12
3.2.1	Historický přehled vývoje neuronových sítí.....	12
3.2.2	Základní pojmy neuronových sítí .....	13
3.2.3	Umělé neuronové sítě .....	14
3.2.4	Dopředná neuronová síť typu perceptron .....	15
4	Klasifikace obcí do tříd pomocí neuronových sítí .....	19
4.1	Charakteristika dat a jejich předzpracování.....	19
4.2	Zpracovaná data.....	21
5	Závěr .....	34
6	Seznam literatury .....	35
7	Seznam grafů, tabulek a obrázků.....	36

# 1 Úvod

Při modelování ekonomických procesů [10] je velmi důležité rozhodnutí o složitosti procesu a při popisu těchto procesů vystupuje do popředí neurčitost způsobená nepřesným definováním základních pojmů. Jedním z možných přístupů řešení této problematiky je výpočetní inteligence (Soft Computing). Jejím obsahem je zkoumání fuzzy množiny, neuronové sítě a evolučních stochastických optimalizačních algoritmů (zvláště genetické algoritmy a evoluční postupy). Při modelování procesů je možné vytvořit model na klasifikaci ekonomických subjektů, dále je možné vytvořit model na predikci ekonomických časových řad, regresní modely na určení závislosti mezi ekonomickými jevy a optimalizační modely.

Neuronové sítě se používají v případech kdy požadujeme adaptivitu systému, rychlost výpočtu nebo odolnost vůči chybám. Mezi největší výhody umělých neuronových sítí [1] patří schopnost učit se. To znamená získávat znalosti učením pomocí množiny předkládaných vzorů bez nutnosti znalosti algoritmu řešení. U biologických neuronových sítí považujeme proces učení za schopnost organismu zhodnotit výsledky opakované adaptace v takovém smyslu, že organismus si zapamatuje stav nalezený při adaptaci a při změně prostředí se již obrací ke své paměti.

Pomocí schopností neuronových sítí, které jsou schopny samostatného rozhodování a přizpůsobení se novým situacím je možné klasifikovat obce do různých tříd. Klasifikace objektů do tříd patří mezi základní rozhodovací procesy. Cílem řešení rozhodovacího procesu je volba mezi různými verzemi činností. Volba verze činností je velice složitý proces, zvláště v případech kdy nelze předvídat důsledky jednotlivých rozhodnutí a informace nejsou úplné či nejisté.

Cílem této bakalářské práce je navržení takových struktur neuronových sítí, které jsou vhodné pro klasifikaci ekonomických subjektů. Cílem modelování bude návrh takového klasifikátoru, který bude dosahovat vysoké správnosti klasifikace a nízké chyby klasifikace na neznámých, testovacích datech. Tato klasifikace bude realizována v programovém prostředí Weka 3.4.11 pod operačním systémem Windows XP.

## 2 Data a jejich předzpracování

Tato kapitola je zaměřena na popsání základních pojmů, mezi které v této práci patří ekonomické subjekty - obce. Ty jsou v této práci klasifikovány do tříd podle jejich bonity. Jako vstupní parametry jsou vybrány parametry ekonomické, finanční a dluhové. Je uvedena jejich základní charakteristika a popisná statistika, včetně korelačních závislostí použitých parametrů.

### 2.1 Návrh použitých parametrů na ohodnocování obcí

Obec [14] je základní jednotkou veřejné správy a samosprávy a zpravidla, v různé míře podle typu obce, i státní správy. V některých zemích je obcí téměř každé město či vesnice, v jiných zemích je obvyklé, že obec je tvořena větším množstvím vesnic, nebo že některá sídla mohou být součástí města.

V literatuře jsou uvedeny společné kategorie parametrů na ohodnocování obcí. Jsou to parametry ekonomické, dluhové, finanční a administrativní. Nejdůležitější a nejvíce používané z těchto parametrů jsou parametry ekonomické, dluhové a finanční. Metody ohodnocování bonity obcí jsou rozdílné v parametrech a vahách, které jsou jim přisuzovány.

Ekonomické parametry ovlivňují dlouhodobé úvěrové riziko obcí. Obce s více různorodou ekonomikou a příznivějšími sociálně-ekonomickými podmínkami jsou lépe připraveny na ekonomickou recesi. Ekonomický růst však může zapříčinit rozšíření veřejných služeb a tím pak poroste zadluženost. Stabilní ekonomika obce zase může být příznakem ekonomické stagnace. Neexistuje syntetický parametr, který by kvantifikoval úroveň ekonomiky obce.

Dluhové parametry zahrnují velikost a strukturu dluhu. Poměrové parametry jsou často používanou metodou měření dluhu obce a schopnosti obce splácet dluhovou službu. Finanční parametry informují o rozpočtovém hospodaření obce. Jejich hodnoty jsou získávány z rozpočtu obce. Vstupní parametry na ohodnocování bonity obcí lze pak navrhnout tak, jak je to uvedeno v Tabulce 1 [2]. Parametry  $x_1$  až  $x_4$  jsou definovány za rok 2004 a parametry  $x_5$  až  $x_{12}$  jako průměrné hodnoty za roky 2003 a 2004.

Základní statistický popis dat je uveden v Tabulce 2. Všechny vybrané parametry  $p_1, p_2, \dots, p_{12}$  jsou kvantitativními proměnnými.



**Tabulka 1 - návrh parametrů bonity obcí**

Parametry	
Ekonomické	$x_1 = PO_r$ , $PO_r$ je počet obyvatel v r-tém roce.
	$x_2 = PO_r/PO_{r-s}$ , $PO_{r-s}$ je počet obyvatel v roce r-s, a s je zvolený časový interval.
	$x_3 = U$ , U je míra nezaměstnanosti v obci.
	$x_4 = \sum_{i=1}^e (PZO_i/PZ)^2$ , $PZO_i$ je počet obyvatel obce zaměstnaných v i-tém odvětví ekonomiky, $i = 1, 2, \dots, e$ , PZ je celkový počet zaměstnaných obyvatel, e je počet ekonomických odvětví.
Dluhové	$x_5 = DS/OP$ , $x_5 \in \langle 0, 1 \rangle$ , DS je dluhová služba, OP jsou opakujících se
	$x_6 = CD/PO$ , CD je celkový dluh.
	$x_7 = KD/CD$ , $x_7 \in \langle 0, 1 \rangle$ , KD je krátkodobý dluh.
Finanční	$x_8 = OP/BV$ , $x_8 \in R^+$ , BV jsou běžné výdaje.
	$x_9 = VP/CP$ , $x_9 \in \langle 0, 1 \rangle$ , VP jsou vlastní příjmy, CP jsou celkové příjmy.
	$x_{10} = KV/CV$ , $x_{10} \in \langle 0, 1 \rangle$ , KV jsou kapitálové výdaje, CV jsou celkové výdaje.
	$x_{11} = IP/CP$ , $x_{11} \in \langle 0, 1 \rangle$ , IP jsou investiční příjmy.
	$x_{12} = LM/PO$ , [Kč], LM je velikost likvidního majetku obce.

**Tabulka 2 - statistický popis dat**

Parametr	Průměr	Medián	Minimum	Maximum	Dolní kvartil	Horní kvartil	Směrodatná odchylka
$x_1$ [obyvatel]	1117.89	336.50	27.000	88181.0	191.00	751.50	4673.06
$x_2$ [-]	0.98	0.99	0.380	2.6	0.92	1.05	0.16
$x_3$ [%]	11.71	10.48	0.000	50.0	7.61	14.29	5.88
$x_4$ [-]	0.20	0.19	0.111	0.4	0.16	0.23	0.05
$x_5$ [-]	0.07	0.03	0.000	0.8	0.00	0.10	0.11
$x_6$ [Kč]	4174.69	1264.73	0.000	306480.8	155.28	4317.26	15810.11
$x_7$ [-]	0.51	0.50	0.000	1.0	0.06	1.00	0.42
$x_8$ [-]	1.21	1.19	0.257	2.6	1.05	1.36	0.36
$x_9$ [-]	0.08	0.06	0.002	0.6	0.03	0.10	0.08
$x_{10}$ [-]	0.22	0.19	0.000	0.8	0.09	0.34	0.18
$x_{11}$ [-]	0.15	0.08	0.000	0.8	0.02	0.22	0.18
$x_{12}$ [Kč]	69540.14	55165.25	5422.777	820591.8	37742.32	82393.14	65275.25

Závislosti mezi parametry lze vyčíst z koeficientů korelace uvedených v Tabulce 3. Z ní je patrné, že mezi parametry neexistují významné závislosti.

**Tabulka 3 - koeficienty korelace mezi parametry**

	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	x <sub>11</sub>	x <sub>12</sub>
x <sub>1</sub>	1.00	0.03	-0.08	-0.10	-0.03	0.01	-0.06	-0.31	-0.11	-0.08	0.36	0.05
x <sub>2</sub>	0.03	1.00	-0.21	-0.16	0.11	0.05	0.08	-0.02	-0.15	0.08	0.13	0.00
x <sub>3</sub>	-0.08	-0.21	1.00	0.20	-0.01	0.03	-0.01	-0.02	0.30	0.00	-0.04	0.31
x <sub>4</sub>	-0.10	-0.16	0.20	1.00	0.06	-0.03	0.02	-0.01	0.03	0.01	-0.02	-0.08
x <sub>5</sub>	-0.03	0.11	-0.01	0.06	1.00	0.15	-0.40	0.02	-0.04	0.11	0.19	0.06
x <sub>6</sub>	0.01	0.05	0.03	-0.03	0.15	1.00	-0.17	0.00	0.05	0.06	0.09	0.38
x <sub>7</sub>	-0.06	0.08	-0.01	0.02	-0.40	-0.17	1.00	0.06	0.07	-0.08	-0.17	0.02
x <sub>8</sub>	-0.31	-0.02	-0.02	-0.01	0.02	0.00	0.06	1.00	0.09	0.42	-0.42	-0.12
x <sub>9</sub>	-0.11	-0.15	0.30	0.03	-0.04	0.05	0.07	0.09	1.00	0.00	-0.17	0.34
x <sub>10</sub>	-0.08	0.08	0.00	0.01	0.11	0.06	-0.08	0.42	0.00	1.00	0.38	0.09
x <sub>11</sub>	0.36	0.13	-0.04	-0.02	0.19	0.09	-0.17	-0.42	-0.17	0.38	1.00	0.16
x <sub>12</sub>	0.05	0.00	0.31	-0.08	0.06	0.38	0.02	-0.12	0.34	0.09	0.16	1.00

Předzpracování dat je realizováno pomocí standardizace dat [8], čímž je odstraněna závislost na jednotkách. Vzhledem k řadovým rozdílům ve velikosti směrodatných odchylek jednotlivých proměnných (Tabulka 2), jsou standardizovány proměnné do svého z-skóre [5] podle vztahu

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, \quad (1)$$

- kde:
- $z_{ij}$  je normovaná hodnota pro  $i$ -tý objekt  $o_i$  a  $j$ -tou proměnnou  $x_j$ ,
  - $x_{ij}$  je původní hodnota pro  $i$ -tý objekt  $o_i$  a  $j$ -tou proměnnou  $x_j$ ,
  - $\bar{x}_j$  je průměr  $j$ -té proměnné  $x_j$ ,
  - $s_j$  je směrodatná odchylka  $j$ -té proměnné  $x_j$ .

Výhodou metody standardizace je především snadnější vzájemné porovnávání proměnných (mají průměrnou hodnotu  $\bar{x}_j=0$  a směrodatnou odchylku  $s_j=1$ ), kdy kladné hodnoty jsou nadprůměrné a záporné podprůměrné.

### 3 Klasifikace pomocí neuronových sítí

V kapitole je definována klasifikace a všeobecný klasifikační problém. Dále jsou popsány neuronové sítě a jejich vlastnosti. V práci bude použita dopředná neuronová síť typu perceptron, proto je níže popsána detailně.

#### 3.1 Všeobecný klasifikační problém

Cílem klasifikace ekonomických subjektů je klasifikovat obce do tříd  $\omega_j$  podle jejich hodnoty parametrů. Tuto klasifikaci je možné uskutečnit dvojím způsobem v závislosti na tom, zda je příslušnost obcí do tříd předem známá (neznámá). Pokud není bonita obce známá apriori, je možné klasifikaci realizovat metodami učení bez učitele. Tyto metody zahrnují redukci dat a shlukování [8, 5]. Ve druhém případě je předem známá příslušnost obcí do tříd. Tento problém se nazývá klasifikační a pro jeho realizaci jsou vhodné metody učení s učitelem. Metody učení s učitelem vhodné pro ohodnocování bonity obcí jsou např.:

- Diskriminační analýza [8, 5].
- Logistická regresní analýza [8, 5].
- Rozhodovací stromy (CHAID, C&RT, QUEST, C4.5, atd.) [11]
- Neuronové sítě (neuronová síť typu perceptron, neuronová síť typu radiální bázové funkce, pravděpodobnostní neuronová síť, učící vektorová kvantizace, atd. [6].

Všeobecný klasifikační problém lze definovat následujícím způsobem [6]. Nechť  $F(\mathbf{x})$  je funkce definovaná na množině  $O$ , která přiřadí každému prvku  $\mathbf{x} \in O$  obraz z množiny  $\Omega$ , kde  $\Omega = \{\omega_1, \omega_2, \dots, \omega_c\}$  je množina tříd. Klasifikátor (stroj, který provádí klasifikaci)  $\hat{\mathbf{x}} = F(\mathbf{x}) \in \Omega$  je pak zobrazení

$$F: O \rightarrow \Omega. \quad (2)$$

Nechť  $G(\mathbf{x}, \mathbf{w})$  je funkce, jejíž argumenty jsou z konečné množiny  $O_{\text{train}} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_r\} \subset O$  (nazývané trénovací množina) a  $\mathbf{w}$  je parametr (nebo parametry) zobrazení  $G$ . Pak platí  $\hat{\mathbf{x}} = G(\mathbf{x}, \mathbf{w}) \in \Omega_{\text{train}} \subset \Omega$ . Doplněk  $O_{\text{train}}$  vzhledem k množině  $O$  je testovací množina  $O_{\text{test}}$ . Nechť je znám pro každý  $\mathbf{x}_i \in O_{\text{train}}$  požadovaný obraz  $\hat{\mathbf{x}}_i$ . Cílem klasifikace je pak nalezení parametrů  $\mathbf{w}$  funkce  $G(\mathbf{x}, \mathbf{w})$ , aby funkční hodnoty argumentů z trénovací množiny  $O_{\text{train}}$  byly co nejbližší obrazům funkce  $F(\mathbf{x})$ . Dále, nechť je dána účelová funkce v následujícím tvaru

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^r (G(\mathbf{x}_i, \mathbf{w}) - \hat{\mathbf{x}}_i)^2. \quad (3)$$

Potom cílem je minimalizace této funkce. Globálního minima je dosaženo optimální hodnotou parametrů  $\mathbf{w}$ . Pak je funkce  $G(\mathbf{x}, \mathbf{w})$  adaptovaná.

Nechť optimální hodnota parametru  $\mathbf{w}$  je označena jako  $\bar{\mathbf{w}}$ . Pak se adaptovaná funkce  $G(\mathbf{x}, \bar{\mathbf{w}})$  používá pro klasifikaci trénovací i testovací množiny. Předpokládá se, že adaptovaná funkce dobře aproximuje původní funkci  $F(\mathbf{x})$  také mimo trénovací množiny. Jako metody vhodné pro ohodnocování bonity obcí jsou zvoleny neuronové sítě (Neural Networks) zejména vzhledem k jejich schopnosti učit se a zobecňovat a fuzzy inferenční systémy (Fuzzy Inference Systems), díky jejich schopnosti pracovat s neurčitostí a znalostmi experta.

## 3.2 Neuronové sítě

Teorie neuronových sítí vychází z chování nervového systému. Snaží se vysvětlit principy spravování informací v nervových buňkách. Modely neuronových sítí jsou označovány jako modely mozku bez mysli. Teorie umělých neuronových sítí je nejrychleji a nejintenzivněji se rozvíjející oblast počítačových věd.[6] Zájem o vývoj umělých neuronových sítí pramení z poznání, že lidský mozek pracuje jiným způsobem než běžné číslicové počítače. [12] Počítače přesně a rychle provádějí posloupnosti instrukcí, které pro ně byly formulovány. Lidský mozek je tvořen neurony, které pracují přibližně milionkrát pomaleji než obvody číslicové ho počítače, přesto člověk dokáže lépe řešit řadu výpočetně náročných úkolů (zpracování vizuální informace, porozumění řeči, hraní šachů, a podobně). Proto je snaha napodobit schopnosti mozku a vytvořit umělou neuronovou síť, která by uměla simulovat chování biologické neuronové sítě živých organismů.

### 3.2.1 Historický přehled vývoje neuronových sítí

V následující tabulce je znázorněn časový postup vývoje neuronových sítí.[12]

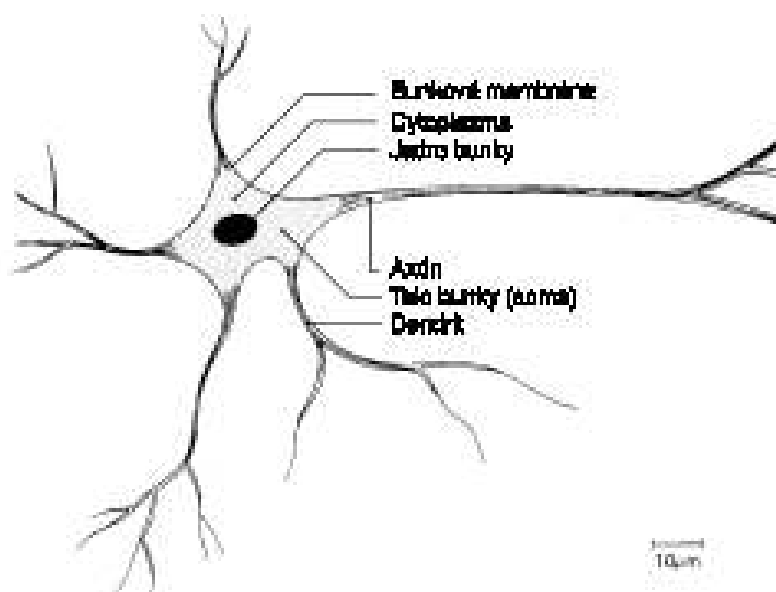
**Tabulka 4 - Historický vývoj neuronových sítí**

1943	považován za začátek vývoje umělých neuronových sítí, navržen McCullochů v-Pittsů v model neuronu
1949	Hebbův zákon učení (1. zákon učení neuronových sítí)
1958	navržen nejznámější model neuronu (perceptron), autorem Frank Rosenblatt

začátek 60. let 20. stol.	první model neuronových sítí (lineární sítě), navržena pravidla pro jejich učení
polovina 60. let až polovina 80. let 20. stol.	pokles zájmu o neuronové sítě, někteří nadšenci přesto pokračují ve výzkumu (např. T. Kohonen navrhuje tzv. samoorganizující se sítě a S. Grossberg zákony pro jejich učení)
od poloviny 80. let 20. stol. dosud	období renesance neuronových sítí, objevují se tzv. vícevrstvé nelineární sítě a pravidla pro jejich učení

### 3.2.2 Základní pojmy neuronových sítí

Nervový systém je složen z velkého množství buněk, které se dělí na centrální nervový systém a periferní nervový systém. Výhodou nervového systému je, že při výpadku funkčnosti jedné buňky celá funkčnost systému se nezmění. Hlavní činností nervového systému je řídit organismus. Základem této funkce je schopnost nervového systému zpracovávat informace. Informace se v nervovém systému přenášejí ve formě membránového potenciálu nervových buněk - neuronů. Neuron je elementární jednotka pro zpracování informace, Obrázek 1.

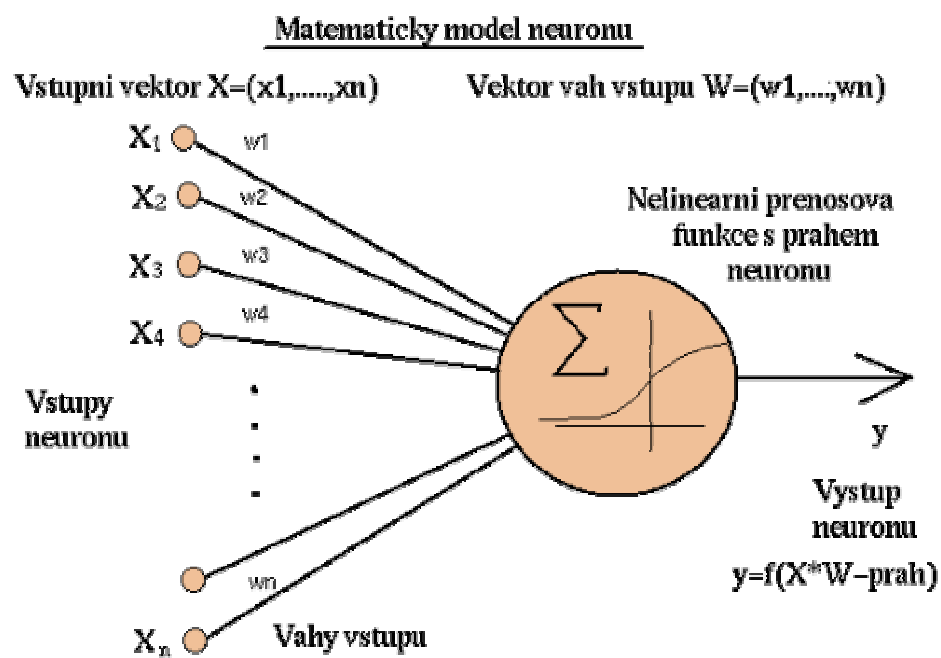


**Obrázek 1 – Neuron**

*Zdroj: KVASNIČKA, Vladimír, et al. Úvod do teorie neuronových sítí.*

Neuron se skládá z těla (lat. soma) a několika výběžků. Ty se můžou rozdělit do dvou skupin: dendrity, které představují z informačního hlediska vstupní část a axón, po kterém se informace šíří k ostatním buňkám (tzv. výstup). Neurony jsou ohraničeny membránou, která je polopropustná, což znamená že je propustná jen z jedné strany – signály se šíří pouze jedním

směrem. Neurony vytvářejí funkční spojení v místě přímého kontaktu axónu jedné buňky s membránou buňky jiné. Tyto spojení se nazývají synapse. Tělo neuronu má určitou prahovou hodnotu [9], pod kterou má na svém výstupu řekněme logickou nulu a nad tuto úroveň logickou jedničku. Stejně jako v elektronice existují obvody s různou převodní charakteristikou, mají je i výstupy neuronů. Nejde tedy čistě o binární obvod, spíše o jakýsi komparátor s nelineární převodní charakteristikou a sumátorem na vstupu. Obrázek 2 znázorňuje, že každý neuron má  $n$  vstupů označené jako  $x_1, x_2, \dots, x_n$ . Dále má váhy vstupu označené  $w_1, w_2, \dots, w_n$ , kterých je také  $n$  (stejný počet jako je počet vstupů). Další částí je výstup neuronu označený jako  $y$ .



**Obrázek 2 - Matematický model neuronu**

Zdroj: <http://aldebaran.feld.cvut.cz/~xmyslik/www/neural.html>

### 3.2.3 Umělé neuronové sítě

Mezi největší výhody umělých neuronových sítí patří schopnost učit se. To znamená získávat znalosti učením pomocí množiny předkládaných vzorů bez nutnosti znalosti algoritmu řešení. Principem výstupní funkce neuronové sítě tedy je aproximovat nějakou funkci podle vstupních vektorů.[9] Klíčem k správné aproximaci zde ovšem je znát správně koeficienty, jež jsou vyjádřeny v matici a biologicky vlastně znamenají hodnoty propustností synapsí. Zde se objevuje fáze učení. Neuronovou síť lze naučit správně reagovat na vstupy. Jenže jak ony koeficienty zjistit? Při učení s učitelem se umělá neuronová síť učí tak, že srovnává svůj výstup s výstupem svého učitele nastavováním vah synapsí (hodnoty v matici) tak, aby se snížil rozdíl mezi

skutečným a požadovaným výstupem. Při učení bez učitele neuronová síť nemá žádný srovnávací signál k určení správnosti. Algoritmus je navržen tak, že hledá ve vstupních datech vzorky s určitými vlastnostmi tedy podle závislosti, korelace.

V aktivní vybavovací fázi se již neupravují koeficienty. Na vstup sítě se přivedou data a pak se (v matematické umělé reprezentaci) počítá odezva sítě na výstupu. Pokud má síť zpětné vazby, musí se počítat tak dlouho, dokud se signál na výstupu neustálí (zkonverguje).

Neuronové sítě lze realizovat softwarově, obvodově neboli hardwarově jako [9]

- analogové - realizace operačními zesilovači,
- digitální,
  - počítá se s maticemi a čísly, iterativně,
  - hardwarové (neuroprocesor),
  - softwarové (program).

Neuronové sítě jsou v ekonomické oblasti aplikovány především při řešení problémů predikce (předpověď) časových řad a případné následné rozhodování. Samozřejmě, že oblastí vhodných pro využití umělých neuronových sítí pro prognózu dalšího vývoje událostí je celá řada. Zde lze uvést oblasti jako je např. energetika, ekonomie, finančnictví, doprava, meteorologie, ekologie, lékařství, vojenství, chemie, strojírenství, ale i vodní hospodářství aj. Další aplikace spočívají např. v problémech

- Rozpoznávání a případná rekonstrukce obrazců. Příkladem může být rozpoznávání tištěných číslic a písmen, rozpoznávání ručně psaného textu.
- Problematika analýzy signálů.
- Komprese, expanze, kódování a dekódování signálů.
- Řízení složitých zařízení v dynamicky se měnících podmínkách.
- Transformace signálů.

### 3.2.4 Dopředná neuronová síť typu perceptron

Dopředná neuronová síť typu perceptron (NSP) je jeden z nejběžnějších typů umělých neuronových sítí (NS).[3] Byl navržený Rosenblattem v roce 1958. Tento model sestává z pevného počtu  $n$  prvků, ke kterým jsou prostřednictvím  $k$  vstupů přiváděny učící vzory. Každý učící vzor je popsán  $k$ -rozměrným vektorem příznaků (parametrů)  $x = (x_1, \dots, x_n) \in \mathfrak{R}^n$  a patří

do právě jedné z  $q$  daných tříd. Klasifikace učicích vzorů (objektů), počet příznaků a význam jednotlivých z nich závisí na konkrétní aplikaci uvažované sítě. Na základě učicích vzorů do tříd se perceptron má naučit správně klasifikovat vektory příznaků přicházejících na jeho vstupy. Klasifikace vektoru  $\mathbf{x}_i$  vstupních příznaků je prováděna na základě binárních hodnot  $y_j, j=1,2, \dots, q$ , které jsou určeny vztahem

$$y_r = \Theta\left(\sum_{i=1}^n w_{(i,j)} x_i\right) \quad (4)$$

kde  $w_{(i,j)}$  jsou váhy spojů z jednotlivých vstupů do výstupů  $y_j$  a určují chování tohoto výstupu.

Počty vrstev i počty perceptronů jsou parametrem NSP a závisí na povaze řešené úlohy. Pokud je počet perceptronů malý, NS nedokáže postihnout všechny závislosti v trénovacích datech. Pokud je naopak velký, zvyšuje se doba učení a vlivem nadměrného počtu trénovacích dat má síť špatnou schopnost generalizace způsobenou tzv. přeučení (Overfitting). Topologie třívrstvé NSP je uvedena na Obrázku 3.

### Vybavování v neuronové síti typu perceptron

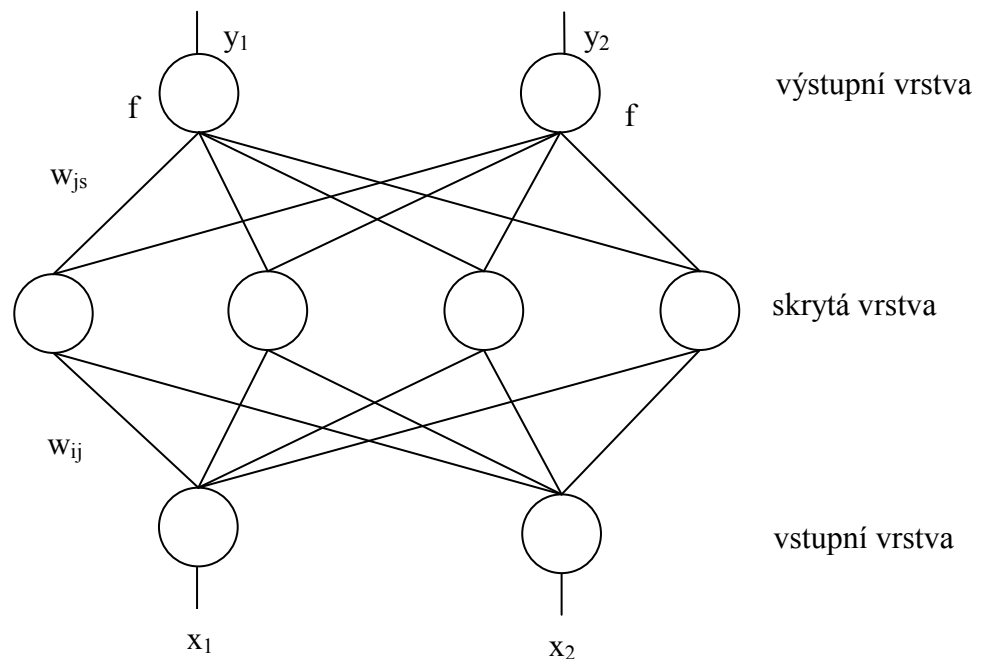
Ve fázi vybavování je na vstupy NSP přiložen vzor a postupně dopředně šířen (transformován) přes synaptické váhy perceptronů  $w_{ij}$  v jednotlivých vrstvách a využitím aktivačních funkcí  $f$  až k výstupům sítě. Postupně jsou počítány hodnoty potenciálů  $\xi$  od vstupní k výstupní vrstvě podle tohoto vztahu

$$\xi_j = \sum_i w_{ij} y_i, \quad (5)$$

kde:

- $w_{ij}$  jsou synaptické váhy mezi  $i$ -tým a  $j$ -tým perceptronem,
- $i$  a  $j$  jsou indexy probíhající přes perceptrony dvou sousedících vrstev,  $i$  probíhá přes perceptrony předcházející vrstvy,
- $y_i$  je výstup  $i$ -tého perceptronu.





**Obrázek 3 – Topologie NSP**

**Legenda:**  $x_1, x_2$  jsou vstupy NSP,  $w_{ij}, w_{js}$  jsou synaptické váhy,  $y_1, y_2$  jsou výstupy NSP

Hodnoty výstupů (stavů) perceptronů  $y_j$  jsou vypočteny podle vztahu

$$y_j = f(\xi_j), \text{ kde aktivační funkce } f \text{ je např. sigmoidální funkce.} \quad (6)$$

Hodnoty výstupů perceptronů výstupní vrstvy jsou hodnotami výstupů NSP, které jsou všeobecně reprezentovány reálnými čísly. Pokud mají výstupy NSP představovat třídy v klasifikační úloze, aktivační funkce  $f$  má charakter ostré nelinearity ve výstupních neuronech NS.

### Učení v neuronové síti typu perceptron

Cílem učení NSP je dosáhnout takového nastavení synaptických vah  $w_{ij}$ , aby odchylka (chyba)  $E_r$  mezi skutečnými a požadovanými výstupy NSP byla minimální vzhledem k odpovídajícím předloženým trénovacím vzorům. Chyba NSP je definována takto

$$E_r = \sum_k E_{r_k}, \quad (7)$$

- kde:
- $k$  je index probíhající přes všechny trénovací vzory,
  - $E_{r_k}$  je chyba odpovídající  $k$ -tému trénovacímu vzoru,
  - $E_r$  je chyba NS.

Chyba  $E_{r_k}$  odpovídající konkrétnímu trénovacímu vzoru je definována takto

$$E_{r_k} = \frac{1}{2} \sum_j (y_j - d_{kj}), \quad (8)$$

- kde:
- $j$  probíhá přes perceptrony výstupní vrstvy,
  - $d_{kj}$  je  $j$ -tý prvek požadovaného výstupu  $k$ -tého trénovacího vzoru.

Neuronové síti jsou předkládány jednotlivé trénovací vzory. Pro každý je spočítána chyba  $E_{r_k}$  podle (8) a po vyčerpání všech trénovacích vzorů je spočítána výsledná chyba  $E_r$  podle (7). Pomocí chyby  $E_r$  jsou upraveny hodnoty synaptických vah  $w_{ij}$  takto

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}, \text{ kde } t \text{ je čas a změny vah jsou získány podle} \quad (9)$$

$$\Delta w_{ij} = -\eta \frac{\partial E_r}{\partial w_{ij}}, \text{ kde } \eta \text{ je rychlost učení, } 0 \leq \eta \leq 1. \quad (10)$$

Parciální derivace chyby podle synaptických vah NS typu perceptron, podle (10), představuje minimalizaci chyby  $E_r$  pomocí synaptických vah gradientní metodou. Uvedený algoritmus učení představuje tzv. akumulované učení, protože synaptické váhy  $w_{ij}$  jsou aktualizovány teprve po vyhodnocení všech trénovacích vzorů. Nezáleží tedy na pořadí, v jakém jsou vzory předkládány na vstupy NS. Variantou tohoto učení je okamžitá aktualizace synaptických vah po každém předloženém vzoru. Celý proces je opakován, dokud chyba  $E_r$  není menší než předem stanovená hodnota. Učícím pravidlem NSP je metoda zpětného šíření chyby (Backpropagation). Odvození této metody je uvedeno např. v [4]. Vzhledem k tomu, že NSP využívá při učení gradientní metodu, je možné, že NSP při pohybu po chybové funkci uvízne v lokálním minimu. To je způsobeno tím, že není možné pokračovat ve směru minimalizace chybové funkce. Byla nalezena řada způsobů, jak tento problém řešit [4]. Patří mezi ně přidání šumu do rovnice pro adaptaci synaptických vah, přidání perceptronů, nastavení rychlosti učení  $\eta$  nebo přidání momentu do rovnice pro adaptaci synaptických vah. Při malé rychlosti učení  $\eta$  klesá chyba pomalu, při velké může NSP divergovat.

## 4 Klasifikace obcí do tříd pomocí neuronových sítí

V kapitole budou navrženy vhodné struktury dopředných neuronových sítí pro klasifikaci ekonomických subjektů. Výsledky budou porovnány pro různé hodnoty parametrů rychlosti učení a momentu. Cílem klasifikace bude dosažení minimální chyby a maximální správnosti klasifikace.


### 4.1 Charakteristika dat a jejich předzpracování

V této práci jsou zpracovávána data o obcích. Data obsahují 12 parametrů podle ukazatelů o bonitě obcí. Tyto parametry se dělí na ekonomické, finanční a dluhové parametry. Pro tuto práci jsem použila programové prostředí Weka 3.1 pod operačním systémem Windows XP.

Výsledek klasifikace je znázorněn chybami (odchylkami) původních výstupů od očekávaných výstupů. Jedná se o střední absolutní odchylku, střední čtvercovou odchylku a relativní čtvercovou odchylku. Pro klasifikaci je potřeba nastavit parametry učení. Těmi jsou rychlost učení, momentum a počet neuronů ve skryté vrstvě. Proto jsou realizovány experimenty pro různé hodnoty těchto parametrů a zaznamenány výsledky.


Hodnoty parametrů byly zvoleny na momentum 0,1 0,2 a 0,3. Rychlost učení byla zkoumaná při hodnotách 0,05 0,1 0,15 0,2 0,25 a 0,3. Počet neuronů ve skryté vrstvě byl zvolen 7, 11, 15 a počítalo se i z automatickou hodnotou („a“) počtu neuronů ve skryté vrstvě, která se vypočítá pomocí vzorce: počet parametrů –  $\frac{1}{2}$  parametrů / 2 což v tomto případě vychází 9 neuronů ve skryté vrstvě.

Na následujícím obrázku lze vidět jednu z možných struktur neuronových sítí se 7 neurony ve skryté vrstvě.




Obrázek 4 - Neuronová síť se 7 neurony ve skryté vrstvě

Obrázek 5 znázorňuje neuronovou síť s 11 neurony ve skryté vrstvě.



**Obrázek 5 - Neuronová síť s 11 neurony ve skryté vrstvě**

Na obrázku 6 je poslední z použitých struktur neuronových sítí s 15 neurony ve skryté vrstvě.



**Obrázek 6 - Neuronová síť s 15 neurony ve skryté vrstvě**

Rozdělení dat na trénovací a testovací je v prvním příkladě podle procentuálního rozdělení 2:1. Další rozdělení dat na trénovací a testovací bylo provedeno pomocí křížové validace [13], kde K-násobná křížová-validace postupuje takto

1. Vstupní data jsou rozdělena na  $k$  stejně velkých podmnožin.
2. Každá z těchto podmnožin je jednou použita pro testování hypotézy vytvořené trénováním na zbytku dat.

## 4.2 Zpracovaná data

Získané výsledky jsou zpracované v následujících tabulkách. První jsou data zpracovaná křížovou validací s 10 podmnožinami. Střední absolutní chyba pro různé struktury dopředných neuronových sítí a různé parametry rychlosti učení a momentum jsou uvedeny v Tabulce 5, Tabulce 6, Tabulce 7 a Tabulce 8.

**Tabulka 5 - Střední absolutní chyba -  $a = 9$  neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0656	0.0638	0.0622
	0,1	0.0562	0.0548	0.0546
	0,15	0.0518	0.0512	0.0501
	0,2	0.05	0.0505	0.0466
	0,25	0.0478	0.049	0.0511
	0,3	0.05	0.0497	0.0505

**Tabulka 6 - Střední absolutní chyba - 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0674	0.0656	0.0636
	0,1	0.0579	0.0558	0.0557
	0,15	0.0547	0.0536	0.053
	0,2	0.0528	0.0539	0.0544
	0,25	0.0531	0.0534	0.0514
	0,3	0.0534	0.0498	0.0488

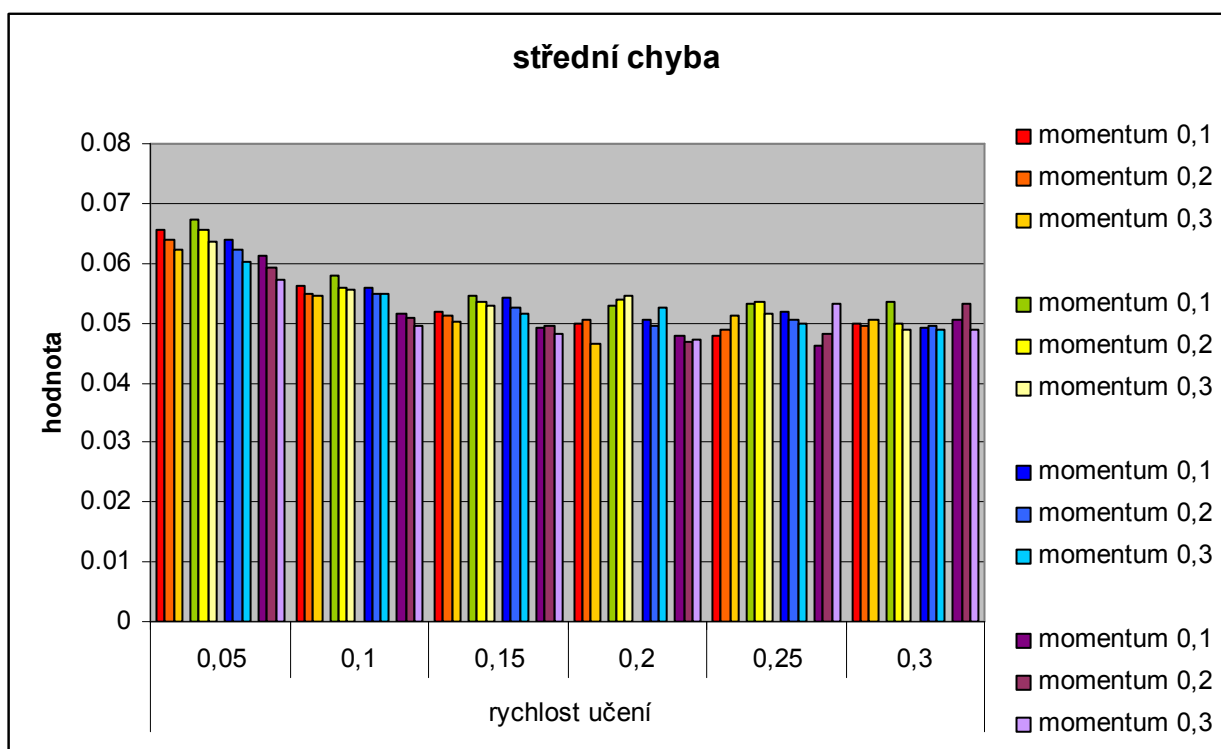
**Tabulka 7 - Střední absolutní chyba - 11 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0639	0.0621	0.0603
	0,1	0.0559	0.0549	0.055
	0,15	0.0543	0.0526	0.0517
	0,2	0.0507	0.0496	0.0526
	0,25	0.0519	0.0504	0.0499
	0,3	0.0492	0.0497	0.0488

**Tabulka 8 - Střední absolutní chyba - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0611	0.0593	0.0573
	0,1	0.0517	0.051	0.0497
	0,15	0.0491	0.0494	0.0483
	0,2	0.0477	0.0467	0.0471
	0,25	0.0463	0.0483	0.0532
	0,3	0.0506	0.0533	0.0488

Z tabulek lze vidět, jak jsou hodnoty rozdílné. Nejlepších výsledků bylo dosaženo pro 15 neuronů ve skryté vrstvě, pro rychlost učení od 0,15 do 0,3. Vliv momentu je nejednoznačný, u neuronových sítí s méně neurony ve skryté vrstvě vyšší hodnota momentu snižuje střední absolutní chybu. V převážné většině se hodnoty pohybují od 0,04 – 0,06. Lepší srovnání poskytuje Graf 1.



**Graf 1 – střední absolutní chyba při křížové validaci**

**Legenda 1 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

Výsledky pro střední kvadratickou chybu jsou uvedeny v Tabulce 9, Tabulce 10, Tabulce 11 a Tabulce 12.

**Tabulka 9 - Střední kvadratická chyba - a = 9 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1685	0.168	0.1677
	0,1	0.1682	0.1686	0.1738
	0,15	0.173	0.1725	0.1745
	0,2	0.1728	0.1774	0.1711
	0,25	0.1724	0.1757	0.1832
	0,3	0.1803	0.1813	0.1865

**Tabulka 10 - Střední kvadratická chyba - 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1707	0.1707	0.1706
	0,1	0.1715	0.1697	0.1736
	0,15	0.1745	0.1753	0.177
	0,2	0.177	0.1814	0.1853
	0,25	0.1799	0.1851	0.1845
	0,3	0.1849	0.1819	0.1824

**Tabulka 11 - Střední kvadratická chyba - 11 neuronů ve skryté vrstvě**


		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.171	0.1711	0.1705
	0,1	0.1702	0.172	0.1764
	0,15	0.1796	0.1783	0.1782
	0,2	0.1756	0.1764	0.1807
	0,25	0.18	0.1839	0.1831
	0,3	0.1838	0.1829	0.1861

**Tabulka 12 – Střední kvadratická chyba - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1661	0.1656	0.1655
	0,1	0.168	0.1696	0.1711
	0,15	0.1732	0.1745	0.1732
	0,2	0.1725	0.1715	0.1769
	0,25	0.1743	0.1817	0.1959
	0,3	0.1872	0.1968	0.183

Z uvedených tabulek můžeme vidět, že hodnota kvadratické chyby se pohybuje mezi 0,16 – 0,18. Grafické porovnání umožňuje Graf 2, kde lze výsledky prohlásit za srovnatelné pro všechny navržené struktury NSP a různé hodnoty vstupních parametrů. Nejnižší hodnoty střední kvadratické chyby jsou při nízkých rychlostech učení. Hodnoty kvadratické chyby s rostoucí hodnotou rychlosti učení rostou.





**Graf 2 – Střední kvadratická chyba při křížové validaci**

**Legenda 2 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

Posledním kritériem hodnocení klasifikace byla zvolena správnost klasifikace. Výsledky pro navržené struktury NSP a měnící se hodnoty vstupních parametrů jsou uvedeny v Tabulce 13, Tabulce 14, Tabulce 15 a Tabulce 16.

**Tabulka 13 - Správnost klasifikace - a = 9 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	86.95%	86.95%	86.28%
	0,1	86.28%	86.50%	86.50%
	0,15	86.06%	84.73%	85.62%
	0,2	85.40%	84.29%	86.50%
	0,25	85.18%	85.84%	84.29%
	0,3	85.84%	85.40%	84.29%

**Tabulka 14 - Správnost klasifikace - 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	85.40%	85.62%	85.84%
	0,1	85.84%	86.28%	86.06%
	0,15	86.50%	86.06%	86.06%
	0,2	85.84%	85.18%	84.51%
	0,25	85.84%	84.96%	85.62%
	0,3	84.96%	86.06%	85.62%

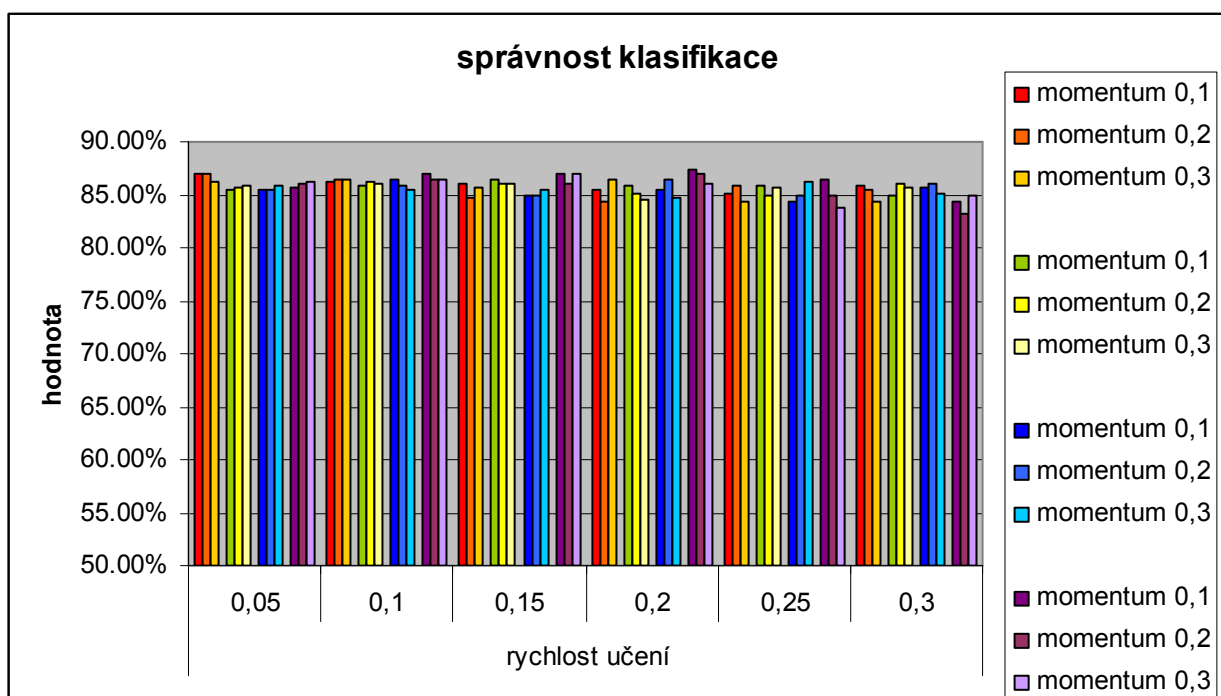
**Tabulka 15 - Správnost klasifikace - 11 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	85.40%	85.40%	85.84%
	0,1	86.50%	85.84%	85.40%
	0,15	84.96%	84.96%	85.40%
	0,2	85.40%	86.50%	84.73%
	0,25	84.29%	84.96%	86.28%
	0,3	85.62%	86.06%	85.18%

**Tabulka 16 - Správnost klasifikace - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	85.62%	86.06%	86.28%
	0,1	86.95%	86.50%	86.50%
	0,15	86.95%	86.06%	86.95%
	0,2	87.39%	86.95%	86.06%
	0,25	86.50%	84.96%	83.85%
	0,3	84.29%	83.19%	84.96%

Tyto tabulky jsou zpracované v Grafu 3, kde hodnoty jsou lépe srozumitelné a viditelné. Hodnoty správnosti klasifikace při křížové validaci se pohybují okolo 85%. Rozdíly pro různé hodnoty vstupních parametrů nejsou nijak výrazné, horších výsledků se dosáhlo s rychlostí učení nad 0,1.



**Graf 3 - Správnost klasifikace při křížové validaci**

**Legenda 3 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

Následující výsledky jsou vypočítány pomocí náhodného procentuálního rozdělení dat 2:1. Tím je dosaženo porovnání s rozdělením dat na trénovací a testovací pomocí metody křížové validace. Předpokladem je, že metoda křížové validace poskytne lepší výsledky, protože je vždy část dat v průběhu učení použita jako kontrolní data, tj. data, na kterých se ověřuje schopnost NSP klasifikovat neznámá data. Opět následují výsledky pro střední absolutní chybu v Tabulce 17, Tabulce 18, Tabulce 19 a Tabulce 20.

**Tabulka 17 - Střední absolutní chyba - a = 9 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0649	0.063	0.0611
	0,1	0.0567	0.0548	0.0527
	0,15	0.0528	0.0526	0.0543
	0,2	0.0505	0.0469	0.0444
	0,25	0.0435	0.0436	0.0426
	0,3	0.0413	0.0406	0.0422

**Tabulka 18 - Střední absolutní chyba - 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0658	0.0637	0.0618
	0,1	0.0554	0.0542	0.0534
	0,15	0.0512	0.0507	0.0486
	0,2	0.0498	0.051	0.0482
	0,25	0.0463	0.0485	0.0483
	0,3	0.0484	0.0484	0.0489


**Tabulka 19 - Střední absolutní chyba - 11 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0598	0.0579	0.0559
	0,1	0.0508	0.0495	0.0478
	0,15	0.046	0.0445	0.0435
	0,2	0.0417	0.0395	0.0421
	0,25	0.0414	0.0447	0.0411
	0,3	0.0418	0.0404	0.0396

**Tabulka 20 - Střední absolutní chyba - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.0582	0.0559	0.0535
	0,1	0.0474	0.0464	0.0457
	0,15	0.0459	0.0465	0.0454
	0,2	0.0456	0.0462	0.0465
	0,25	0.0468	0.0434	0.0379
	0,3	0.0413	0.0415	0.0389

Zpracované hodnoty z předchozích tabulek jsou zřetelnější v Grafu 4, ze kterého je názorněji vidět jak si jsou hodnoty podobné. Hodnoty střední chyby s rostoucí rychlostí učení klesají. Je zde také vidět, že se zvyšující hodnotou momentu se střední chyba snižuje. Nejčastěji vysoké hodnoty jsou při 7 neuronech ve skryté vrstvě.



**Graf 4 - graf střední absolutní chyby při procentuálním rozdělení**

**Legenda 4 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

Hodnoty kvadratické chyby při procentuálním rozdělení jsou znázorněny v následujících tabulkách Tabulka 21, Tabulka 22, Tabulka 23 a Tabulka 24

**Tabulka 21 - kvadratická chyba - a = 9 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1551	0.1542	0.1538
	0,1	0.1575	0.1571	0.1556
	0,15	0.1585	0.1604	0.1664
	0,2	0.1621	0.1603	0.1557
	0,25	0.1547	0.1561	0.165
	0,3	0.1577	0.1522	0.1559

**Tabulka 22 - kvadratická chyba – 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1623	0.1618	0.1615
	0,1	0.1581	0.1593	0.159
	0,15	0.1567	0.1584	0.1605
	0,2	0.1622	0.1689	0.1579
	0,25	0.1567	0.1593	0.1625
	0,3	0.1613	0.1642	0.1668


**Tabulka 23 - kvadratická chyba – 11 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1558	0.1553	0.1544
	0,1	0.1531	0.1495	0.1503
	0,15	0.1506	0.152	0.1509
	0,2	0.1453	0.1392	0.1402
	0,25	0.1356	0.1451	0.1467
	0,3	0.1436	0.15	0.1491

**Tabulka 24 - kvadratická chyba - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	0.1484	0.1477	0.1474
	0,1	0.1465	0.1467	0.1479
	0,15	0.1545	0.1605	0.1607
	0,2	0.1605	0.164	0.1625
	0,25	0.1642	0.1603	0.1512
	0,3	0.1585	0.1623	0.1611

Uvedené tabulky nám ukazují, že hodnoty kvadratické chyby se pohybují převážně od 0,14 do 0,16. Tyto hodnoty jsou lépe zřetelné v Grafu 5, kde je názorně vidět nejčastějších nízkých hodnot při 11 neuronech ve skryté vrstvě. Ostatní struktury mají ve většině případů vyšší hodnotu.



**Graf 5 - graf kvadratické chyby při procentuálním rozdělení**

**Legenda 5 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

Vypočítané výsledky správnosti klasifikace při procentuálním rozdělení jsou znázorněny v následujících tabulkách Tabulka 25, Tabulka 26, Tabulka 27 a Tabulka 28

**Tabulka 25 - správnost klasifikace - a = 9 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	88.96%	88.96%	89.61%
	0,1	88.96%	88.31%	88.96%
	0,15	90.26%	89.61%	88.31%
	0,2	88.31%	87.66%	88.31%
	0,25	88.31%	87.66%	87.01%
	0,3	88.31%	88.31%	87.01%

**Tabulka 26 - správnost klasifikace - 7 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	85.71%	86.36%	86.36%
	0,1	88.31%	87.66%	87.66%
	0,15	89.61%	87.66%	86.36%
	0,2	88.31%	87.01%	88.96%
	0,25	88.31%	88.31%	87.66%
	0,3	87.66%	88.31%	88.31%

**Tabulka 27 - správnost klasifikace - 11 neuronů ve skryté vrstvě**


		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	87.66%	87.66%	87.66%
	0,1	87.66%	88.96%	88.96%
	0,15	88.96%	88.96%	89.61%
	0,2	90.26%	90.91%	89.61%
	0,25	90.26%	90.26%	90.91%
	0,3	90.26%	90.91%	89.61%

**Tabulka 28 - správnost klasifikace - 15 neuronů ve skryté vrstvě**

		momentum		
		0,1	0,2	0,3
rychlost učení	0,05	89.61%	89.61%	89.61%
	0,1	90.26%	88.31%	88.96%
	0,15	88.96%	87.66%	88.31%
	0,2	87.66%	87.66%	87.01%
	0,25	86.36%	88.31%	89.61%
	0,3	88.31%	88.31%	88.96%

Znázornění hodnot z předešlých tabulek je lépe zřetelné z Grafu 6. Hodnoty správnosti klasifikace jsou přibližně okolo 85%. Nejnižší hodnoty správnosti klasifikace jsme dosáhli při 7 neuronech ve skryté vrstvě. V převážné většině případů se správnost moc neliší.





**Graf 6 - správnost klasifikace při procentuálním rozdělení**

**Legenda 6 – červené odstíny barvy = a=9 neuronů ve skryté vrstvě**

**žluté odstíny barvy = 7 neuronů ve skryté vrstvě**

**modré odstíny barev = 11 neuronů ve skryté vrstvě**

**fialové odstíny barvy = 15 neuronů ve skryté vrstvě**

V Grafu 6 můžete vidět že nejvyšší hodnoty správnosti klasifikace při procentuálním rozdělení jsou hodnoty při 11 skrytých vrstvách. Dosahují dokonce i hodnot o málo vyšších než 90%. Tyto hodnoty jsou ve srovnání s křížovou validací vyšší, což ukazuje na správné procentuální rozdělení dat na trénovací a testovací. Dostatek dat umožňuje využití tohoto rozdělení dat při dosažení vysoké správnosti klasifikace na testovacích datech. Metodu křížové validace lze tedy doporučit zejména v případech, kdy je dat nedostatek.

## 5 Závěr

V práci jsem se zabývala klasifikací ekonomických subjektů pomocí neuronových sítí. V první části jsou popsány základní pojmy z oblasti neuronových sítí. Jedná se o neuron, topologii a učení neuronových sítí a dopředné neuronové sítě typu perceptron.

Zpracovaná data se týkají obcí. Jsou zde uvedeny ekonomické, finanční a dluhové parametry pro ohodnocování bonity obcí. Obce jsou rozděleny do tříd podle bonity. Cílem práce byl návrh takových struktur neuronových sítí, pomocí kterých by bylo možno správně klasifikovat tyto obce, zejména s ohledem na neznámá data, tj. dosáhnout vysoké schopnosti generalizace neuronové sítě.

Z procesu klasifikace byla získána střední chyba, kvadratická chyba a správnost klasifikace pomocí rozdělení dat křížovou validací a náhodným rozdělení na trénovací a testovací data. Původní data byla klasifikována do 7 tříd.

Výsledky znázorňují správnost klasifikace testovacích dat. Po porovnání výsledků křížové validace a náhodným rozdělení na trénovací a testovací data byly zjištěny správnější výsledky při náhodném rozdělení na trénování a testovací data. Hodnota střední chyby se s rychlostí učení snižovala a nejlepších výsledků bylo získáno u modelu s 11 neurony ve skryté vrstvě. Nejlepších výsledků u střední kvadratické chyby bylo dosaženo také při 11 neuronech ve skryté vrstvě. Správnost klasifikace při náhodném rozdělení na trénování a testovací data dosahovala hodnot téměř 90% a nejvyšších hodnot správnosti klasifikace bylo získáno u modelu s 11 neurony ve skryté vrstvě. Nejlepších hodnot klasifikace bylo dosaženo při náhodném rozdělení na trénovací a testovací data u struktury dopředné neuronové sítě typu perceptron s 11 neurony ve skryté vrstvě.

Neuronové sítě se ukázaly jako vhodná metoda pro klasifikaci ekonomických subjektů. Jsou schopny se učit znalosti z vstupních dat a naučené znalosti použít při klasifikaci neznámých objektů. Mezi ekonomickými daty existují nelineární závislosti, které lze pomocí dopředných neuronových sítí typu perceptron vhodně modelovat. Ukázalo se, že nejlepších výsledků klasifikace lze dosáhnout s jednou skrytou vrstvou s  $n-1$  neurony. Další parametry učení měly na výsledky klasifikace menší vliv. To prokázaly experimenty pro různé rozdělení dat na trénování a testovací data.

Na základě uvedených skutečností lze tvrdit, že cíle práce vytyčené v úvodu práce byly splněny.

## 6 Seznam literatury

- [1] DRÁBEK, O., SEIDL, P., TAUFER, I. UMĚLÉ NEURONOVÉ SÍTĚ : Základy teorie a aplikace. *Chemagazin* [online]. 2005, č. XV. [cit. 2008-03-03]. Dostupný z WWW: <[http://www.chemagazin.cz/Texty/CHXV\\_4\\_cl6.pdf](http://www.chemagazin.cz/Texty/CHXV_4_cl6.pdf)>.
- [2] HÁJEK, P. Modelování bonity obcí pomocí metod výpočetní inteligence. Disertační práce. Univerzita Pardubice : Pardubice, 2006.
- [3] HAKL, František, HOLEŇA, Martin. *Úvod do teorie neuronových sítí*. [s.l.] : [s.n.], 1998. 210 s. ISBN 80-01-01716-8.
- [4] HAYKIN, S. S. *Neural Network : A Comprehensive Foundation*. Upper Saddle River : Prentice-Hall, 1999.
- [5] HEBÁK, P. *Vícerozměrné statistické metody*. Praha : Informatorium, 2004. ISBN 80-7333 025-3.
- [6] KVASNIČKA, Vladimír, et al. *Úvod do teórie neuronových sietí*. 1997. vyd. Bratislava : IRIS, 1997. 264 s.
- [7] MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. *Umělá inteligence (4)*. Praha : ACADEMIA, 2003. 475 s. ISBN 80-200-1044-0.
- [8] MELOUN, M., MILITKÝ, J. *Statistická analýza experimentálních dat*. Praha : Academia, 2004. 449 s. ISBN 80-200-1254-0.
- [9] MYSLÍK, Vladimír. *Neuronové sítě* [online]. 1996 [cit. 2008-03-03]. Dostupný z WWW: <<http://aldebaran.feld.cvut.cz/~xmyslik/www/neural.html>>.
- [10] OLEJ, Vladimír. *Modelovanie ekonomických procesov na báze výpočtovej inteligencie*. [s.l.] : [s.n.], 2003. 160 s. ISBN 80-90324-9-1.
- [11] PETR, Pavel. *Data Mining*. [s.l.] : [s.n.], 2006. 144 s. ISBN 80-7194-886-1.
- [12] RADOVÁ, Vlasta. *Neuronové sítě pro humanitní studia* [online]. 2003 [cit. 2008-03-03]. Dostupný z WWW: <<http://artin.zcu.cz/people/radova/teaching/neuh/prednasky.pdf>>.
- [13] Důvěryhodnost naučených modelů. *Umělá inteligence* [online]. 2008 [cit. 2008-03-17]. Dostupný z WWW: <[datel.felk.cvut.cz/xui1/2006ZS/X06.ppt](http://datel.felk.cvut.cz/xui1/2006ZS/X06.ppt)>.
- [14] *Wikipedie - otevřená encyklopedie* [online]. 2008 [cit. 2008-03-31]. Dostupný z WWW: <[http://cs.wikipedia.org/wiki/Hlavn%C3%AD\\_strana](http://cs.wikipedia.org/wiki/Hlavn%C3%AD_strana)>.

## 7 Seznam grafů, tabulek a obrázků

Graf 1 – střední absolutní chyba při křížové validaci.....	23
Graf 2 - kvadratická chyba při křížové validaci .....	25
Graf 3 - graf střední absolutní chyby při procentuálním rozdělení.....	29
Graf 4 - graf kvadratické chyby při procentuálním rozdělení .....	31
Tabulka 1 - návrh parametrů bonity obcí.....	9
Tabulka 2 - statistický popis dat .....	9
Tabulka 3 - koeficienty korelace mezi parametry .....	10
Tabulka 4 - Historický vývoj neuronových sítí .....	12
Tabulka 5 - Střední absolutní chyba - a = 9 neuronů ve skryté vrstvě .....	21
Tabulka 6 - Střední absolutní chyba - 7 neuronů ve skryté vrstvě .....	21
Tabulka 7 - Střední absolutní chyba - 11 neuronů ve skryté vrstvě .....	22
Tabulka 8 - Střední absolutní chyba - 15 neuronů ve skryté vrstvě .....	22
Tabulka 9 - Střední kvadratická chyba - a = 9 neuronů ve skryté vrstvě .....	23
Tabulka 10 - Střední kvadratická chyba - 7 neuronů ve skryté vrstvě .....	24
Tabulka 11 - Střední kvadratická chyba - 11 neuronů ve skryté vrstvě .....	24
Tabulka 12 – Střední kvadratická chyba - 15 neuronů ve skryté vrstvě.....	24
Tabulka 13 - Správnost klasifikace - a = 9 neuronů ve skryté vrstvě.....	25
Tabulka 14 - Správnost klasifikace - 7 neuronů ve skryté vrstvě.....	26
Tabulka 15 - Správnost klasifikace - 11 neuronů ve skryté vrstvě.....	26
Tabulka 16 - Správnost klasifikace - 15 neuronů ve skryté vrstvě.....	26
Tabulka 17 - Střední absolutní chyba - a = 9 neuronů ve skryté vrstvě .....	27
Tabulka 18 - Střední absolutní chyba - 7 neuronů ve skryté vrstvě .....	28
Tabulka 19 - Střední absolutní chyba - 11 neuronů ve skryté vrstvě .....	28
Tabulka 20 - Střední absolutní chyba - 15 neuronů ve skryté vrstvě .....	28
Tabulka 21 - kvadratická chyba - a = 9 neuronů ve skryté vrstvě.....	29
Tabulka 22 - kvadratická chyba – 7 neuronů ve skryté vrstvě .....	30
Tabulka 23 - kvadratická chyba – 11 neuronů ve skryté vrstvě .....	30
Tabulka 24 - kvadratická chyba - 15 neuronů ve skryté vrstvě .....	30
Tabulka 25 - správnost klasifikace - a = 9 neuronů ve skryté vrstvě.....	31
Tabulka 26 - správnost klasifikace - 7 neuronů ve skryté vrstvě.....	32
Tabulka 27 - správnost klasifikace - 11 neuronů ve skryté vrstvě.....	32

Tabulka 28 - správnost klasifikace - 15 neuronů ve skryté vrstvě.....	32
Obrázek 1 – Neuron.....	13
Obrázek 2 - Matematický model neuronu .....	14
Obrázek 3 - Topologie NSP.....	17
Obrázek 4 - neuronová síť se 7 neurony ve skryté vrstvě.....	19
Obrázek 5 - neuronová síť s 11 neurony ve skryté vrstvě .....	20
Obrázek 6 - neuronová síť s 15 neurony ve skryté vrstvě .....	20