

Univerzita Pardubice
Fakulta ekonomicko-správní

Modelování finančních toků obcí pomocí neuronových sítí

Bc. Kateřina Raková

Diplomová práce

2010

Univerzita Pardubice
Fakulta ekonomicko-správní
Ústav systémového inženýrství a informatiky
Akademický rok: 2009/2010

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Kateřina RAKOVÁ**
Studijní program: **N6209 Systémové inženýrství a informatika**
Studijní obor: **Informatika ve veřejné správě**

Název tématu: **Modelování finančních toků obcí pomocí neuronových sítí**

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

Charakterizujte rozpočty obcí a faktory rozpočtových příjmů a výdajů
Charakterizujte dopředné neuronové sítě a neuronové sítě typu RBF
Navrhňte model pro predikci finančních toků obcí
Analyzujte výsledky


Rozsah grafických prací:
Rozsah pracovní zprávy: cca 60 stran
Forma zpracování diplomové práce: tištěná/elektronická

Seznam odborné literatury:

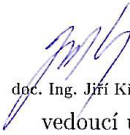
- [1] HAYKIN, S. Neural networks : a comprehensive foundation. 2nd edition. Upper Saddle River : Prentice Hall, 1999. 842 s. ISBN 0-13-273350-1.
- [2] KVASNIČKA, V. a kol. Úvod do teórie neurónových sietí. Bratislava: IRIS, 1997. 285 s. ISBN 80- 88778-30-1.
- [3] OLEJ, V. Modelovanie ekonomických procesov na báze výpočtovej inteligencie. Hradec Králové, Mileš Vognar - M&V, 2003. ISBN 80-90324-9-1.
- [4] PROVAZNÍKOVÁ, R. Financování měst, obcí a regionů. Praha : Grada, 2007. 280 s. ISBN 978-80-247-2097-5.
- [5] SCHNEIDEROVÁ, I. Rozpočtová skladba v roce 2008. 1. vyd. Rožďalovice : REVOS-L, c2008. 291 s. ISBN 978-80-903160-7-2.

Vedoucí diplomové práce: *Hájek*
Ing. Petr Hájek, Ph.D.
Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: 5. října 2009
Termín odevzdání diplomové práce: 30. dubna 2010


doc. Ing. Renáta Myšková, Ph.D.
děkanka

L.S.


doc. Ing. Jiří Krupka, Ph.D.
vedoucí ústavu

V Pardubicích dne 5. října 2009

Prohlašuji:

Tuto práci jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 20. 4. 2010

Kateřina Raková

Poděkování

Touto cestou bych chtěla poděkovat vedoucímu diplomové práce, panu Ing. Petru Hájkovi, Ph.D., za odbornou pomoc, vedení při vypracovávání a za poskytnutí cenných rad a připomínek.

Ráda bych dále poděkovala rodičům za jejich podporu, pochopení a trpělivost a také za to, že mi umožnili studovat.

ANOTACE

Diplomová práce se zabývá modelováním finančních toků obcí pomocí neuronových sítí. Jako vstupní data modelu slouží údaje o příjmech obcí Pardubického kraje. V diplomové práci jsou vymezeny základní pojmy týkající se rozpočtů obcí a definovány faktory ovlivňující finanční toky obcí. Je zde popsána dopředná neuronová síť a charakterizována všeobecná struktura a způsob učení neuronových sítí typu radiálně bazických funkcí (RBF). V závěru diplomové práce jsou analyzovány navržené modely neuronových sítí.

KLÍČOVÁ SLOVA

příjmy, rozpočty obcí, dopředná neuronová síť, RBF neuronová síť, predikce

TITLE

Modelling financial flows of municipalities by neural networks

ANNOTATION

This thesis deals with a suggestion of neural networks model for prediction of municipal financial flows. As the inputs data are used about the revenues of Pardubice Region municipalities. In this thesis basic terms for the budgets of municipalities are described and factors affecting municipal financial flows are defined. There is defined a feed-forward neural network, and there are discussed the description of basic structures and method for learning neural network of Radial Basis Function type in this thesis. In conclusion, the proposed models of neural networks are analyzed.

KEYWORDS

revenues, budgets of municipalities, feed-forward neural network, RBF neural network, prediction

Obsah

Úvod	9
1 Financování obcí.....	10
1.1 Charakteristika rozpočtu.....	10
1.1.1 Obsah rozpočtu	11
1.1.2 Peněžní fondy	11
1.1.3 Příjmy rozpočtu obce	11
1.1.4 Výdaje rozpočtu obce	12
1.2 Rozpočtový proces.....	13
1.3 Rozpočtová skladba	14
1.3.1 Rozpočtová skladba – třídění příjmů a výdajů veřejných rozpočtů	14
1.3.2 Druhé rozdělení příjmů.....	15
1.3.3 Druhé rozdělení výdajů.....	17
1.4 Majetek obcí	18
1.4.1 Členění majetku - aktiva	18
1.4.2 Členění majetku - pasiva	20
1.5 Faktory ovlivňující finanční toky obcí	21
1.5.1 Faktory ovlivňující příjmy	21
1.5.2 Faktory ovlivňující výdaje	22
1.6 Dílčí závěry.....	23
2 Dopředné neuronové sítě	24
2.1 Základní pojmy z neuronových sítí	24
2.2 Proces učení neuronové sítě.....	27
2.2.1 Učení s učitelem	27
2.2.2 Učení bez učitele.....	29
2.3 Dílčí závěry.....	30
3 Neuronové sítě typu RBF	31
3.1 Aktivační funkce.....	31
3.2 Topologie neuronové sítě typu RBF	32
3.3 Proces učení RBF neuronové sítě	33
3.3.1 Počet neuronů ve skryté vrstvě	34
3.3.2 Nalezení center RBF neuronů.....	36
3.4 Dílčí závěry.....	37
4 Návrh modelu pro predikci finančních toků obcí	39
4.1 Metody predikce	39
4.1.1 Kvalitativní metody predikce	40
4.1.2 Kvantitativní metody predikce	40
4.1.3 Metoda extrapolace.....	41
4.2 Chyby a metody pro hodnocení kvality predikce	41
4.3 Návrh modelu	42
4.4 Návrh vstupních parametrů.....	43
4.4.1 Návrh parametrů daňových příjmů	43
4.4.2 Návrh parametrů nedaňových příjmů	45
4.4.3 Návrh parametrů kapitálových příjmů.....	46
4.4.4 Návrh parametrů přijatých dotací	46
4.4.5 Vektor vstupních parametrů	47
4.5 Předzpracování dat.....	47
4.6 Analýza hlavních komponent	48
4.6.1 Zdrojová data	49

4.6.2	Výstupy analýzy hlavních komponent.....	49
4.6.3	Interpretace hlavních komponent	51
4.7	Dílčí závěry.....	52
5	Predikce finančních toků obcí pomocí neuronových sítí.....	53
5.1	Rozdělení dat	53
5.2	Návrh RBF neuronové sítě	54
5.2.1	Počet neuronů ve skryté vrstvě	55
5.2.2	Nastavení počtu cyklů.....	56
5.2.3	Nastavení momentu	57
5.2.4	Překryv radiálně bazických funkcí	58
5.3	Návrh struktury dopředné neuronové sítě.....	59
5.4	Analýza výsledků navržených struktur.....	61
5.4.1	Výsledné nastavení parametrů neuronové sítě typu RBF	62
5.4.2	Výsledné nastavení parametrů dopředné neuronové sítě.....	63
5.4.3	Výsledný model neuronové sítě pro predikci finančních toků obcí	63
5.5	Dílčí závěry.....	64
	Závěr	66
	Seznam použité literatury	67
	Seznam obrázků.....	70
	Seznam tabulek	70
	Seznam příloh	71
	Přílohy.....	72

Úvod

Veličiny, na nichž je vybudován finanční plán, jsou peněžní příjmy a peněžní výdaje. Tyto veličiny se označují jako veličiny finančního toku a tvoří je údaje o příjmech včetně jejich druhového členění, souhrnné údaje o výdajích v členění na běžné a kapitálové, údaje o dlouhodobých smluvních závazcích (splácení úvěrů), údaje o rozpočtovém čerpání výsledku hospodaření a o finančních zdrojích a potřebách (možné přijetí úvěru). Hlavními zdroji informací o finančních tocích jsou rozpočty obcí a finanční rozvaha aktiv a pasiv.

Cílem diplomové práce je návrh modelu pro predikci finančních toků obcí pomocí neuronových sítí, modelování a analýza výsledků. Predikce bude provedena pomocí neuronové sítě typu radiálně bazických funkcí (RBF) a dopředné neuronové sítě (typu perceptron). Pro modelování je použito programové prostředí Clementine 10.1. Jako vstupní data modelu budou sloužit údaje o příjmech obcí Pardubického kraje.

Diplomová práce se skládá z pěti hlavních kapitol. První kapitola je věnována rozpočtům obcí, třídění příjmů a výdajů a členění majetku. Dále jsou zde definovány faktory, které ovlivňují finanční toky obcí. Ve druhé kapitole jsou uvedeny základní pojmy z oblasti neuronových sítí a je zde popsána dopředná neuronová síť. Ve třetí kapitole je charakterizována všeobecná struktura a způsob učení neuronových sítí typu RBF.

Čtvrtá kapitola se zabývá návrhem modelu pro predikci finančních toků obcí pomocí neuronových sítí. Jsou zde navrženy vstupní parametry modelu a jejich předzpracování. V páté kapitole je navržena struktura neuronové sítě typu RBF a struktura dopředné neuronové sítě. V závěru diplomové práce jsou analyzovány navržené modely neuronových sítí a na základě výsledků stanovena nejvhodnější struktura pro predikci finančních toků obcí. Vliv navržených vstupů bude testován pomocí citlivostní analýzy.

1 Financování obcí

Převážná část této kapitoly je věnována charakteristice rozpočtů obcí. Jsou zde popsány fáze rozpočtového procesu, rozpočtová skladba a druhové třídění příjmů výdajů. Další část kapitoly se zabývá majetkem obcí a v poslední podkapitole jsou definovány faktory, které mohou mít vliv na finanční toky obcí.

1.1 Charakteristika rozpočtu

Klíčová práva i povinnosti obcí a krajů, které se dotýkají také financování, jsou vymezena Ústavou ČR. Územní samosprávné celky jsou veřejnoprávními korporacemi, které mohou mít **vlastní majetek a hospodařit podle vlastního rozpočtu**. Konkrétněji jsou definovány podmínky fungování municipálního (obecního) a regionálního (krajského) finančního systému v zákoně o obcích¹, v zákoně o krajích² a v zákoně o rozpočtovém určení daní³.

Rozpočet obce je pojímán jako [17]:

- a) decentralizovaný peněžní fond, v němž se soustředí různé druhy veřejných příjmů, které se rozdělují a používají na financování veřejných statků, zajišťovaných prostřednictvím municipálního veřejného sektoru nebo též nakupovaných u soukromého sektoru,
- b) bilance příjmů a výdajů za rozpočtové období (kalendářní rok), které je shodné s rozpočtovým obdobím v celé soustavě veřejných rozpočtů,
- c) finanční plán, podle kterého obce hospodaří v příslušném rozpočtovém období;
- d) právní dokument schválený místním zastupitelstvem,
- e) nástroj prosazování cílů obecní politiky,
- f) ekonomický vztah související se shromažďováním a rozdělováním peněžních prostředků.

Jestliže jsou některé příjmy daného roku určeny k využití až v následujícím roce, nebo jsou určeny k splácení jistiny úvěrů předchozích let, je možné sestavit rozpočet jako **přebytkový**. Rozpočet může být také schválen jako **schodkový**, a to v případech, kdy bude možné tento

¹ Zákon č. 128/2000 Sb., o obcích (obecní zřízení)

² Zákon č. 129/2000 Sb., o krajích (krajské zřízení)

³ Zákon č. 250/2000 Sb., o rozpočtovém určení výnosu některých daní územním samosprávným celkům a některým státním fondům (zákon o rozpočtovém určení daní)

schodek uhradit finančními prostředky z minulých let nebo smluvně zabezpečenou půjčkou, úvěrem, návratnou finanční výpomocí nebo výnosem z prodeje dluhopisů [23].

Kladný zůstatek z finančního rozpočtu se převádí k použití do dalšího roku ke krytí rozpočtových výdajů nebo je možné ho převést do peněžních fondů. Schodek hospodaření se uhrazuje z finančních prostředků z minulých let nebo se kryje z návratných zdrojů splatných v následujících letech.

1.1.1 Obsah rozpočtu

Obsahem rozpočtu jsou jeho příjmy a výdaje a ostatní peněžní operace, včetně tvorby a použití peněžních fondů, pokud není dále uvedeno, že probíhají mimo rozpočet.

Mimo rozpočet se uskutečňují peněžní operace týkající se [23]:

- a) cizích prostředků,
- b) sdružených prostředků.

Podnikatelské činnosti územního samosprávného celku se sledují účetně mimo rozpočtové příjmy a výdaje. Jejich hospodářské výsledky se promítají do rozpočtu vždy nejpozději ke konci kalendářního roku tak, aby byly součástí závěrečného účtu územního samosprávného celku.

1.1.2 Peněžní fondy

Územní samosprávný celek může zřizovat peněžní fondy, a to pro konkrétní účely anebo bez účelového určení.

Zdrojem peněžních fondů územního samosprávného celku mohou být zejména [23]:

- a) přebytky hospodaření z minulých let,
- b) příjmy běžného roku, které nejsou určeny k využití v běžném roce,
- c) převody prostředků z rozpočtu během roku do účelových peněžních fondů.

1.1.3 Příjmy rozpočtu obce

Příjmy rozpočtu obce tvoří především [17]:

- příjmy z vlastního majetku a majetkových práv,
- příjmy z výsledků vlastní hospodářské činnosti,

- příjmy z hospodářské činnosti právnických osob, pokud jsou příjmem obce, která organizaci zřídila nebo založila,
- příjmy z vlastní správní činnosti,
- výnosy z místních poplatků,
- výnosy daní nebo podíly z nich,
- dotace ze státního rozpočtu a ze státních fondů,
- dotace z rozpočtu kraje,
- prostředky získané správní činností ostatních orgánů státní správy,
- přijaté peněžní prostředky a dary,
- jiné příjmy.

Dále mohou být použity i prostředky poskytnuté prostřednictvím Národního fondu a návratných zdrojů. Ke krytí dočasného časového nesouladu mezi čerpáním výdajů a plněním příjmů lze použít návratnou finanční výpomoc z rozpočtu státu, kraje nebo jiné obce [23]. Tato výpomoc je bezúročná, její opožděné splácení se považuje za zadržení peněžních prostředků.

1.1.4 Výdaje rozpočtu obce

Výdaje z rozpočtu obce zahrnují následující položky [17]:

- závazky vyplývající pro obec z plnění povinností uložených jí zákony,
- výdaje na vlastní činnost obce v její samostatné působnosti,
- výdaje spojené s výkonem státní správy, ke které je obec pověřena zákonem,
- závazky vyplývající pro obec z uzavřených smluvních vztahů v jejím hospodaření a ze smluvních vztahů vlastních organizací, pokud k nim přistoupila,
- závazky přijaté v rámci spolupráce s jinými obcemi nebo dalšími subjekty,
- úhrada úroků z půjček a úvěrů,
- výdaje na emise vlastních dluhopisů a na úhradu výnosů z nich náležejících jejich vlastníkům,
- výdaje na podporu subjektů provádějících veřejně prospěšné činnosti a na podporu soukromého podnikání, které je prospěšné obci,
- jiné výdaje, včetně darů a příspěvků na sociální nebo jiné humanitární účely.

Dále obec hradí ze svého rozpočtu splátky půjček, úvěrů a návratných výpomocí a splátky jistin dluhopisů.

1.2 Rozpočtový proces

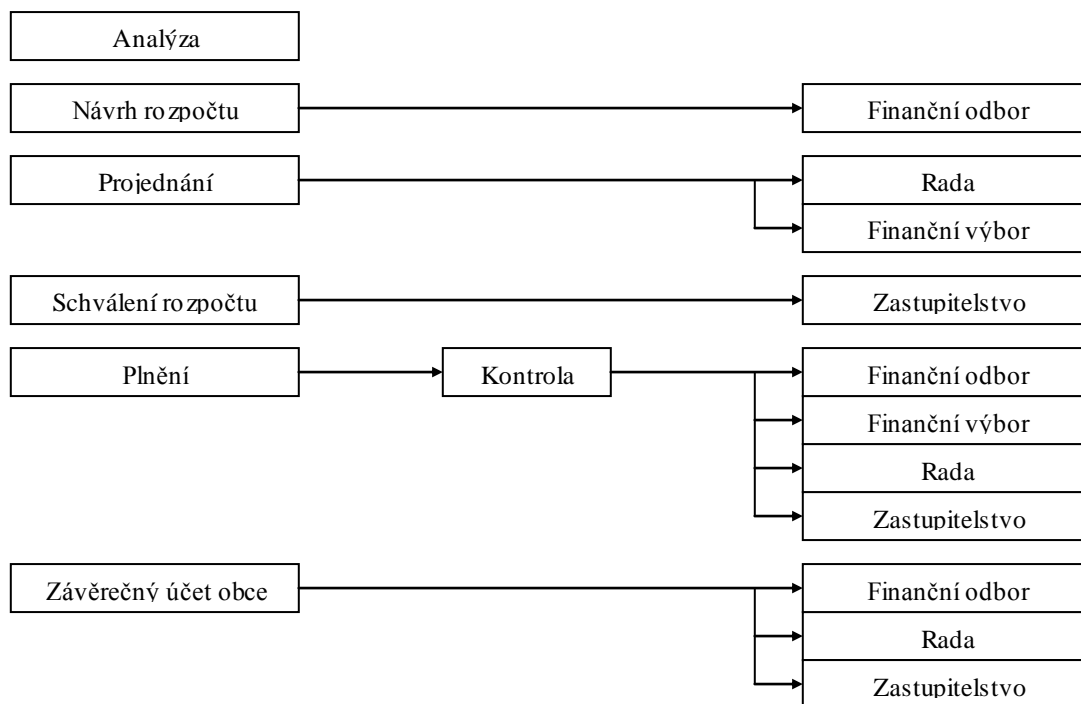
Pracovní postup pro sestavování, projednávání, schvalování, plnění a kontrolu realizace rozpočtu se nazývá **rozpočtovým procesem**. Rozpočtový proces [17] má kontinuální (nepřetržitý) charakter. Sestavování místního rozpočtu patří mezi nejdůležitější a etapy rozpočtového procesu, protože jde o co nejpřesnější předvídání a naplánování příjmové a výdajové stránky rozpočtu.

Jednotlivé fáze rozpočtového procesu lze rozdělit do těchto etap [15]:

- a) analýzy minulosti a stanovení priorit pro rozpočtové období,
- b) sestavení návrhu rozpočtu – zpravidla provádí výkonný orgán obce, většinou finanční odbor a podkladem pro návrh rozpočtu je rozpočtový výhled,
- c) projednávání a schválení – sestavený návrh rozpočtu se projednává ve finančním výboru a v radě obce (výkonnými orgány) a schvalování rozpočtu je ve výhradní pravomoci zastupitelstva (volený orgán),
- d) kontrola plnění rozpočtu,
- e) přehled o skutečném plnění rozpočtu, závěrečný účet - sestavují výkonné orgány (finanční odbor a rada),
- f) následná kontrola,
- g) aktualizace programu rozvoje a rozpočtového výhledu.

Fáze rozpočtového procesu zobrazuje obrázek 1.

Obce i kraje mají povinnost sestavovat kromě ročního rozpočtu i rozpočtový výhled. Rozpočtový výhled [23] je pomocný nástroj, který slouží pro střednědobé finanční plánování rozvoje hospodářství města. Sestavuje se na základě uzavřených smluvních vztahů a přijatých závazků většinou na období 2 až 5 let, které následují po roce, ve kterém byl sestaven rozpočet.



Obrázek 1 Fáze rozpočtového procesu. Zdroj: [15]

1.3 Rozpočtová skladba

Při sestavování rozpočtu je nezbytná znalost nejen celkového objemu příjmů, jež budou k dispozici, ale také jejich přesné členění. Systematické, jednotné a závazné třídění příjmů a výdajů, které se uplatňuje v oblasti veřejných rozpočtů se, označuje jako tzv. **rozpočtová skladba** [15] neboli **rozpočtová klasifikace**. V současné době je rozpočtová skladba upravována vyhláškou MF ČR o rozpočtové skladbě¹, která zahrnuje poměrně rozsáhlé změny v rozpočtové skladbě oproti vyhlášce předchozí z roku 2002.

1.3.1 Rozpočtová skladba – třídění příjmů a výdajů veřejných rozpočtů

Platná rozpočtová skladba využívá čtyři základní druhy třídění příjmů a výdajů [15], [22]:

- **Kapitolní (organizační, nebo odpovědnostní)** je v ČR povinné pouze u státního rozpočtu. V současné době je 40 kapitol státního rozpočtu. Pro územní samosprávu je toto třídění nepovinné.
- **Druhé třídění** je základní třídění. Týká se všech peněžních operací, které třídí peněžní operace do tří základních okruhů: příjmů, výdajů a tzv. financování.

¹ Vyhláška MF ČR č. 440/2006 Sb., o rozpočtové skladbě

Používá se čtyřmístný číselný kód, který dovoluje odlišit třídy, seskupení položek, podseskupení položek a položky. Druhé třídění dělí peněžní operace takto:

a) příjmové operace na třídy:

1. třída: Daňové příjmy
2. třída: Nedaňové příjmy
3. třída: Kapitálové příjmy
4. třída: Přijaté dotace,

b) výdajové operace na třídy:

6. třída: Běžné výdaje
7. třída: Kapitálové výdaje,

c) třída 8: Financování.

- **Z hlediska odvětvového** se třídí příjmy a výdaje podle odvětví. Využívá čtyřmístný klasifikační klíč třídění na skupiny, oddíly, pododdíly a paragrafy. Skupiny se člení na:
 1. zemědělství a lesní hospodářství,
 2. průmyslová a ostatní odvětví hospodářství,
 3. služby pro obyvatelstvo,
 4. sociální věci a politika zaměstnanosti,
 5. bezpečnost státu a právní ochrana,
 6. všeobecná veřejná správa a služby.
- **Konsolidační třídění**, kdy prvkem jsou tzv. záznamové položky. Konsolidace umožňuje vyloučit duplicitu na základě interních transferů mezi fondy a korekci příjmů na straně jedné a korekci výdajů na straně druhé při započítávání příjmů a výdajů.

1.3.2 Druhé rozdělení příjmů

Příjmové operace se třídí do čtyř tříd [15]:

Třída 1 – Daňové příjmy – povinné, neopětované příjmy plynoucí z daní, pojistného sociálního a zdravotního pojištění, doplatků včetně daní a sankcí za pozdní či nesprávné placení.

Třída 2 – Nedaňové příjmy – veškeré opětované příjmy, jako příjmy z prodeje neinvestičního majetku, příjmy z prodeje zboží a služeb, příjmy sankční povahy, které nemají vztah k daním a přijaté splátky půjček za účelem rozpočtové politiky.

Třída 3 – Kapitálové příjmy – příjmy z prodeje investičního majetku a finančních aktiv majících povahu majetkových podílů za účelem rozpočtové politiky a přijaté dary pro investiční účely s výjimkou darů od zahraničních vlád a transferů z jiných úrovní vlády.

Třída 4 – Přijaté dotace s podrobnějším tříděním na běžné a kapitálové dotace neopětované a nenávratně inkasované dotace a dary od jiných úrovní vlády a od zahraničních vlád a institucí.

Podrobné schéma druhového rozdělení příjmů zobrazuje tabulka 1.

Tabulka 1 Druhové rozdělení příjmů. Zdroj: [15]

PŘÍJMY		
Daňové příjmy	<ul style="list-style-type: none"> - daně z příjmů, zisku a kapitálových výnosů - daně ze zboží a služeb v tuze msku - daně a poplatky z vybraných činností a služeb - daně a cla za zboží a služby ze zahraničí - majetkové daně - pojistné na SZ a veřejné zdravotní pojištění - ostatní daňové příjmy 	
Nedaňové příjmy	<ul style="list-style-type: none"> - příjmy z vlastní hospodářské činnosti - odvody příspěvkových organizací (např. vodné, stočné, odvoz odpadu, poplatky za školní stravování, služby knihoven apod.) - příjmy z pronájmu majetku - úroky, dividendy, kursové zisky - přijaté sankční platby a vratky transferů - příjmy z prodeje nekapitálového majetku - přijaté splátky půjčených prostředků 	
Kapitálové příjmy	<ul style="list-style-type: none"> - příjmy z prodeje dlouhodobého majetku - příjmy z prodeje akcií a majetkových podílů 	
Přijaté dotace	běžné	<ul style="list-style-type: none"> - od veřejných rozpočtů ústřední úrovně - od veřejných rozpočtů územní úrovně - převody z vlastních fondů - ze zahraničí
	kapitálové	<ul style="list-style-type: none"> - od veřejných rozpočtů ústřední úrovně - od veřejných rozpočtů územní úrovně - z vlastních fondů - ze zahraničí

1.3.3 Druhové rozdělení výdajů

Výdajové operace se třídí do 5. a 6. třídy [15]:

Třída 5 – Běžné výdaje – neinvestiční nákupy – tj. opětované výdaje na zboží a služby neinvestiční povahy a náklady související s pracovní silou (mzdy, pojistné atd.). Neinvestiční transfery – neopětované výdaje na neinvestiční účely charakteru dotací a příspěvků mimo rozpočtovou jednotku. Neinvestiční půjčky – návratně poskytované prostředky jiným subjektům na neinvestiční účely.

Třída 6 – Kapitálové výdaje – investiční nákupy – tj. opětované výdaje na pořízení hmotného a nehmotného investičního majetku a akcií a majetkových účastí, investiční transfery – neopětované výdaje charakteru dotací a příspěvků na investiční účely poskytované mimo rozpočtovou jednotku.

Podrobné schéma druhového rozdělení výdajů zobrazuje tabulka 2.

Tabulka 2 Druhové rozdělení výdajů. Zdroj: [15]

VÝDAJE		
Běžné výdaje	neinvestiční nákupy	<ul style="list-style-type: none"> - platby za provedenou práci (mzdy, OOV další) - povinné pojistné placené za městnavatelem - nákup zboží a služeb - úroky, kursové ztráty - poskytované zálohy a výdaje související s neinvestičními nákupy
	neinvestiční transfery	<ul style="list-style-type: none"> - neinvestiční transfery podnikatelským subjektům a neziskovým organizacím - neinvestiční transfery a některé další platby veřejným rozpočtům - neinvestiční transfery vlastním fondům - neinvestiční transfery obyvatelstvu - neinvestiční transfery do zahraničí
	neinvestiční půjčky	<ul style="list-style-type: none"> - (ve stejném členění jako neinv. transfery)
Kapitálové výdaje	investiční výdaje	<ul style="list-style-type: none"> - investiční nákupy - nákup akcií a majetkových podílů
	investiční transfery	<ul style="list-style-type: none"> - (ve stejném členění jako neinv. transfery)
	investiční půjčky	<ul style="list-style-type: none"> - (ve stejném členění jako neinv. transfery)

1.4 Majetek obcí

Rozvaha (bilance) [14] je jedním ze základních výkazů účetní závěrky. Tento finanční výkaz podává přehled o majetku organizace (aktivech) a zdrojů jeho krytí (pasivech) v peněžním vyjádření k určitému datu (rozvahovému dni) a umožňuje tak posoudit finanční pozici organizace.

Na rozdíl od jiných účetní výkazů (například výkazu zisku a ztráty), které zobrazují hodnoty platné za určité období (tokové veličiny), zobrazuje rozvaha hodnoty platné k určitému okamžiku (stavové veličiny).

Formálně správně sestavená rozvaha musí splňovat základní bilanční rovnici - tzn. součet aktiv se musí rovnat součtu pasiv. Obsah, rozsah a formu rozvahy určují účetní standardy, podle kterých se výkaz sestavuje (a podle kterého se také většinou vede i celé účetnictví).

1.4.1 Členění majetku - aktiva

Aktiva [14] jsou vložený majetek do účetní jednotky a pořízený majetek v průběhu činnosti, který slouží k zajištění činnosti účetní jednotky, pro niž byla zřízena, tzn. plnému poskytování služeb nebo provozní činnosti k zajištění stanovených cílů.

Z hlediska funkce majetku lze majetek rozčlenit na dvě kategorie:

- a) Dlouhodobý majetek (DM) je majetek, který se používá delší dobu a postupně se opotřebovává a jehož vstupní cena přesahuje určitou hranici = stálá aktiva. Zařazení majetku do DM má zásadní význam, protože významně ovlivňuje výše daní.
- b) Majetek, který se při činnosti organizace spotřebovává jednorázově, popřípadě přeměna majetku v peníze nepřesáhne délku jednoho roku = oběžná aktiva.

Členění majetku je zobrazeno na obrázku 2.

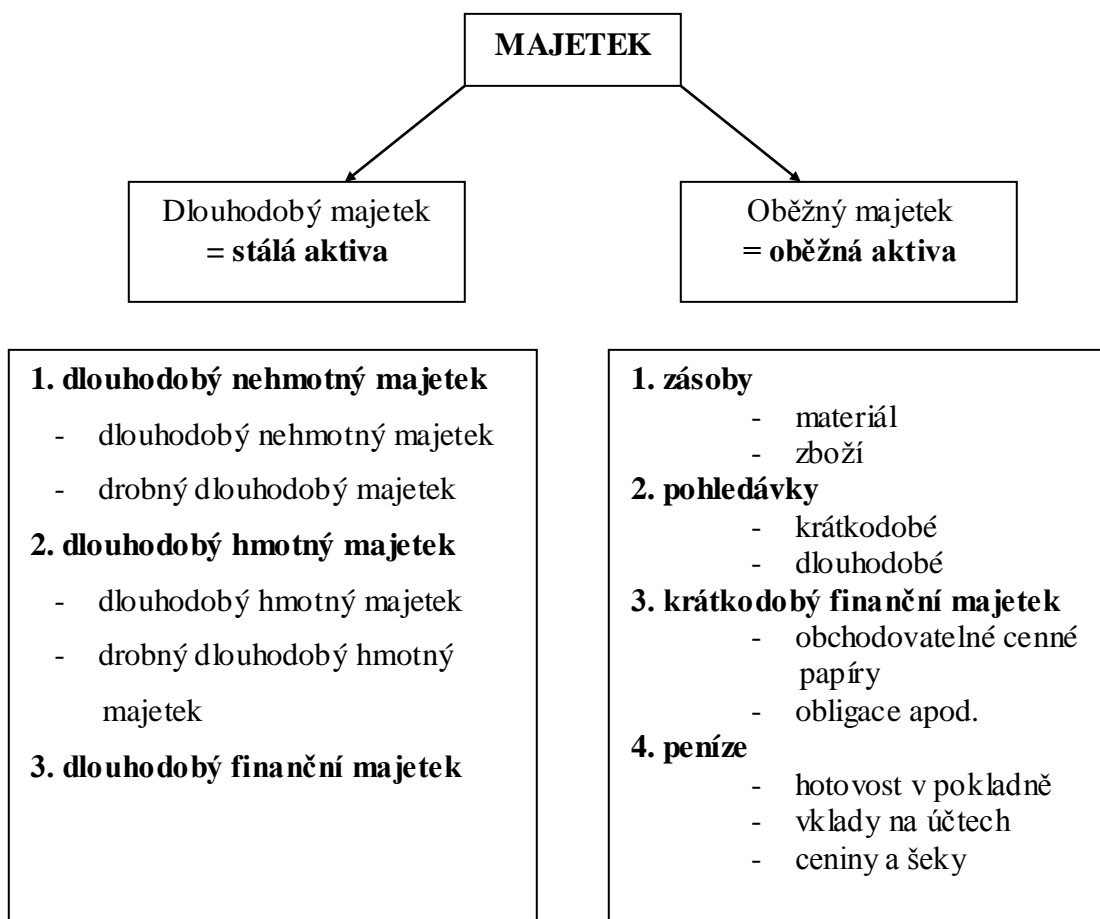
Stálá aktiva tvoří:

1. **Hmotný DM** - např. budovy, stavby, stroje, dopravní prostředky, atd.

- cena je vyšší než 40.000,- Kč (daňové hledisko);
- doba používání delší než 1 rok;
- odepisuje se (kromě půdy a uměleckých předmětů) – účetní a daňové odpisy;
- člení se na movitý a nemovitý .

2. **Nehmotný DM** - např. licence, software, firemní značka apod.
 - cena je vyšší než 60.000,- Kč (daňové hledisko);
 - doba používání delší než 1 rok;
 - odepisuje se (účetní i daňové odpisy).

3. **Finanční DM** - např. dlouhodobé cenné papíry, dlouhodobé půjčky, termínované vklady s výpovědní lhůtou delší než 1 rok, nemovitosti, umělecká díla apod.
 - doba používání více než jeden rok;
 - minimální cena není stanovena;
 - neodepisuje se.



Obrázek 2 Členění majetku. Zdroj: [17]

Oběžná aktiva tvoří:

1. **Zásoby** – jejichž součástí je např. materiál na skladě, pořízení materiálu, nedokončená výroba, výrobky, zboží na skladě, pořízení zboží.

2. **Pohledávky** – tvoří zejména pohledávky odběratelů, směnky k inkasu, pohledávky za eskontované cenné papíry, poskytnuté provozní zálohy, pohledávky za rozpočtové příjmy, daně z příjmů, daně z přidané hodnoty, ostatní daně a poplatky.
3. **Finanční majetek** krátkodobé povahy – jedná se zejména o peněžní prostředky v hotovosti (pokladna), ceniny (poštovní známky, kolky, šeky apod.), bankovní účty, majetkové a dlužné cenné papíry k obchodování, ostatní cenné papíry a pořízení krátkodobého finančního majetku.
4. **Prostředky rozpočtového hospodaření** a další účty mající vztah k rozpočtovému hospodaření a účty mimorozpočtových prostředků, a to příslušné bankovní účty, poskytnuté dotace a příspěvky, poskytnuté návratné a přechodné výpomoci, limity výdajů.
5. **Přechodné účty aktivní** (náklady a příjmy příštích období, kurzové rozdíly a dohadné účty aktivní).

1.4.2 Členění majetku - pasiva

Z hlediska vlastnictví se pasiva člení [14]:

- a) na vlastní zdroje krytí stálých a oběžných aktiv,
- b) na cizí zdroje.

Vlastní zdroje tvoří:

- majetkové fondy (fond dlouhodobého majetku, fond oběžných aktiv, fond hospodářské činnosti a oceňovací rozdíly z přecenění majetku a závazků),
- finanční fondy (fond odměn, fond rezervní, fond kulturních a sociálních potřeb, fond reprodukce majetku, peněžní fondy a jiné finanční fondy),
- zdroje krytí prostředků rozpočtového hospodaření,
- hospodářský výsledek.

Cizí zdroje tvoří:

- rezervy (zásoby a hmotné zdroje určené pro mimořádné účely),
- dlouhodobé závazky (vydané dluhopisy, závazky z pronájmu, dlouhodobé přijaté zálohy, dlouhodobé směnky k úhradě a ostatní dlouhodobé závazky),
- krátkodobé závazky (dodavatelé, směnky k úhradě, přijaté zálohy, ostatní závazky),
- bankovní výpomoci a půjčky (dlouhodobé a krátkodobé bankovní úvěry, směnky, finanční výpomoci),

- přechodné účty pasivní (výdaje a výnosy příštích období, kurzové rozdíly pasivní a dohadné účty pasivní).

1.5 Faktory ovlivňující finanční toky obcí

Příjmy a výdaje obcí se neustále mění a jejich strukturu ovlivňuje celá řada faktorů. Tyto faktory mohou být různého druhu (např. ekonomické, demografické, sociální, politické). Velikost příjmů a výdajů mohou ovlivnit pozitivním nebo negativním způsobem.

1.5.1 Faktory ovlivňující příjmy

Výše příjmů obce nebo města závisí především na následujících faktorech:

- **Počet obyvatel obce** - platí pravidlo čím více obyvatel, tím vyšší příjmy.
- **Počet živnostníků bydlících v obci** - obci zůstává 30 % výnosu z daně, kterou platí osoby samostatně výdělečně činné (živnostníci) mající v obci bydliště. (Právnícké osoby platí daně podle sídla firmy, které se může lišit od místa podnikání).
- **Koeficient, který obec uplatňuje u daně z nemovitosti** - Obec jej může zvýšit nebo snížit v zákonem daném limitu obecně závaznou vyhláškou.
- **Rozloha katastrálního území** - čím větší území obec má, tím vyšší má příjem.
- **Počet zaměstnanců majících v obci místo výkonu práce** - to se zjišťuje z ročních zúčtování daně z příjmů. Jde však o téměř bezvýznamné objemy peněz.

Daňové příjmy jsou ovlivňovány zejména těmito faktory [18]:

- **Rozpočtové určení daní**, které zvyšuje procentní podíl obcí na celostátním výnosu daní.
- **Výnosy z daní** - Daně z přidané hodnoty, Daně z příjmů fyzických osob, Daně z příjmů právnických osob.
- **Daň z nemovitosti** – Celý výnos daně jde do rozpočtu obce, na jejímž území se nemovitost nachází. Daň z nemovitosti má dvě součásti: Daň ze staveb a daň z pozemků. Je ovlivňována nejen počtem a velikostí nemovitostí na území obce, ale i velikostí obce (danou počtem obyvatel) a bonitou zemědělské půdy.
- **Správní a místní poplatky** - např. poplatek ze psů, za lázeňský a rekreační pobyt, ze vstupného, z ubytovací kapacity, za ukládání odpadů, za užívání veřejného prostranství,

za provozovaný výherní hrací přístroj, za povolení k vjezdu s motorovým vozidlem do vybraných míst a částí měst.

Vývoj **nedaňových příjmů** je málo citlivý na změny legislativy. Závisí např. na cenách nájemného, cenách služeb, množství aktivit v oblasti cestovního ruchu, aj.

Výše **kapitálových příjmů** souvisí s prodejem pozemků, proplácením směnek, výstavbou, rozvojem podnikání, apod.

Přijaté dotace souvisí např. s činností, kterou jednotlivé obce pro stát vykonávají, realizací různých projektů, finanční situace obce, zadluženost obce, finanční možnosti státu.

1.5.2 Faktory ovlivňující výdaje

Veřejné výdaje nepřetržitě rostou a mění se jejich struktura způsobená celou řadou faktorů [13], [15]. Jsou jimi např.:

- **Technická vybavenost** - důležitou charakteristikou výdajů obcí jsou výrazné rozdíly mezi jednotlivými obcemi. Rozdíly obcí jsou především v technické vybavenosti, v rozvoji infrastruktury, v bytové výstavbě. Rozhodující je i poloha daného místa ve vztahu k nosné ekonomické a obchodní sféře v zemi, napojení na dopravní infrastrukturu a stav krajiny a životního prostředí vůbec.
- **Velikost obce** - podle průzkumů i velikost obce ovlivňuje složení a efektivnost obecních výdajů. Struktura výdajů malých a větších obcí je rozdílná. Menší obce nemohou využívat úspor z rozsahu při produkci a poskytování služeb. Projevuje se to zejména v podílech běžných a kapitálových výdajů na celkových a v administrativních nákladech. Úroveň kapitálových výdajů u malých obcí se výrazně zvyšuje a jsou to právě malé obce, které jsou nuceny přijímat rizikové úvěry, aby zabezpečily nutné investiční potřeby.
- **Problém externalit** - kdy některé obce financují výdaje i pro jiné obce a neexistuje kompenzační mechanismus.
- **Demografické faktory** a míra změny těchto faktorů společně s přírodními a fyzickými podmínkami obce mají podstatný vliv na strukturu, úroveň výdajů a jejich změny. Obec s klesající populací má jiné priority než obec s rostoucí populací.
- **Celková ekonomická situace** má také významné dopady na výdaje, zejména na míru růstu výdajů. Vzhledem k tomu, že obce nejsou tržně orientované organizace, ekonomický vliv je patrný zejména ve vztahu ústřední a místní vlády. V období

hospodářské konjunktury je činěn na územní samosprávě mnohem menší tlak než v opačných podmínkách.

- **Urbanizace** způsobená stěhováním obyvatel do měst nebo naopak návrat obyvatel na venkov, vyžaduje zvýšit veřejné výdaje na budování municipální infrastruktury. Výsledkem velkých migračních vln do měst může být stav následného přetížení v uspokojování veřejných statků pro občany (nedostatek komunálních i soukromých bytů, nedostatek škol, atd.).

Faktory výdajů obcí, které se liší v čase, závisí i na spolupráci s krajskými samosprávami. Stejně tak je třeba vzít v úvahu, že stupeň autonomie v rozhodování o výdajích je rozdílný v různých obcích (např. podle rozsahu přenesené působnosti) a může se měnit.

1.6 Dílčí závěry

V kapitole byl shrnut současný stav místních rozpočtů v České republice. Byly charakterizovány základní pojmy – rozpočet obce, jeho členění a fáze rozpočtového procesu. Dále byly charakterizovány základní faktory příjmů a výdajů místních rozpočtů reprezentující finanční toky obcí. Faktory ovlivňující příjmy obcí budou dále použity jako vstupy modelu pro predikci finančních toků obcí. Jsou to zejména determinanty daňových příjmů, např. socioekonomické ukazatele obcí.

2 Dopředné neuronové sítě

Existuje mnoho metod pro predikci časových řad, mohou to být algebraické metody, fyzikální modely, statistické metody či metody využívající umělé neuronové sítě (dále jen neuronové sítě), kterými se tato práce zabývá. Neuronové sítě poskytují oproti ostatním metodám výhodu kvalitativního zpracování nelineárních závislostí, která může přispět k zvýšení přesnosti predikce. V této kapitole jsou uvedeny základní pojmy z teorie neuronových sítí. Je zde popsána struktura neuronové sítě a definován algoritmus učení zpětného šíření chyby (back-propagation).


2.1 Základní pojmy z neuronových sítí

Neuronovou sítí [8], [9], [21] lze definovat jako orientovaný graf $G = (V, E)$ sestávající se z N vrcholů $V = \{v_1, v_2, \dots, v_n\}$, které představují jednotlivé neurony a M ohodnocených spojů $E = \{e_1, e_2, \dots, e_m\}$, jež představují jednotlivé synapse. Každý spoj se interpretuje jako uspořádaná dvojice dvou neuronů z množiny V , $e = (v, v')$. Spoj e začíná v neuronu v a končí v neuronu v' . Množina V je rozložena na disjunktní podmnožiny následujícím způsobem [8]:

$$V = V_I \cup V_H \cup V_O \quad (2.1)$$

kde V_I obsahuje N_I vstupních neuronů, které sousedí jen s vycházejícími hranami V_H , obsahuje N_H skrytých neuronů, které sousedí současně s vycházejícími jako s vcházejícími hranami a V_O obsahuje N_O výstupních neuronů, které sousedí jen s vcházejícími hranami. V následujících úvahách se bude vždy předpokládat, že množiny V_I a V_O jsou neprázdné, tj. neuronová síť obsahuje vždy alespoň jeden vstupní a jeden výstupní neuron.

Jedná se tedy o síť výpočetních jednotek - neuronů, které jsou mezi sebou propojeny spoji (synapsemi) ohodnocenými váhami. Výpočetní jednotka zobrazena na obrázku 4, se skládá z x_1, x_2, \dots, x_n vstupů a w_1, w_2, \dots, w_n vah synapsí. Práh je označen jako θ , vnitřní potenciál ξ . Výstup neuronu $y = f(\xi)$ je získán aplikací aktivační funkce na potenciál [9].



Obrázek 3 Formální neuron. Zdroj: [9]

Mezi nejznámější a nejpoužívanější dopředné neuronové sítě patří vícevrstvá perceptronová síť (dále jen dopředná neuronová síť). Tato síť obsahuje z hlediska struktury neurony – perceptrony, které jsou mezi sebou propojeny tak, že vytváří vrstevnatou síť. Perceptron je speciálním případem formálního neuronu představující obecný výpočetní prvek všech neuronových sítí, u něhož je vnitřní potenciál počítán jako vážený součet vstupů [9]

$$\xi = \sum_{i=0}^n w_i x_i - \theta = \sum_{i=0}^n w_i x_i \quad (2.2)$$

a aktivační funkcí je sigmoida

$$f(\xi) = \frac{1}{1 + e^{-\lambda \xi}}, \quad (2.3)$$

kde λ je parametr strmosti (gain).

Tato síť se skládá z několika vrstev perceptronů. Perceptrony jednotlivých sousedících vrstev jsou mezi sebou vzájemně propojeny tak, že tvoří úplný bipartitní graf, tj. výstup jednoho neuronu vrstvy je distribuován do vstupů všech perceptronů následující vrstvy [9]. Podle polohy vrstvy v neuronové síti se rozeznává [2]:

- vrstva vstupní, v ní umístěné neurony zajišťují vstup signálu z okolí;
- vrstva nebo vrstvy skryté;
- vrstva výstupní, jejíž neurony předávají signál do okolí.


Vstupní vrstva je tvořena tzv. zdrojovými uzly a slouží ke vstupu určitého signálu z okolí a jeho následnému rozdělení do neuronů následující vrstvy. Potom vstupní vrstva přechází ve vektor vstupů a číslování vrstev začíná od první skryté vrstvy až po vrstvu výstupní. Poslední vrstvou uvažované neuronové sítě je výstupní vrstva. Tato vrstva je určena k přenosu

výstupních signálů z neuronové sítě do okolí. Tyto výstupní signály jsou pak odezvou neuronové sítě na signály vstupní. Všechny případné mezilehlé vrstvy se označují jako vrstvy skryté. Úkolem skrytých vrstev je zvýšení aproximačních vlastností neuronové sítě jako celku.

Podle toku signálu neuronovou sítí se pak neuronové sítě dělí na [19]:


- acyklické (resp. dopředné), v nichž se signál šíří po orientovaných synapsích jenom jedním směrem;
- cyklické (resp. rekurentní), u nichž existují mezi neurony, nebo vrstvami zpětné vazby.

Příklad acyklické a cyklické sítě je uveden na následujícím obrázku 4.



Obrázek 4 Příklad acyklické (vlevo) a cyklické (vpravo) architektury. Zdroj: [19]

Obecné uspořádání – topologie dopředné neuronové sítě je uvedeno na obrázku 5. Neurony jsou seřazeny do několika vrstev, řazených za sebou. Základní charakteristikou dopředných neuronových sítí je to, že propojení neuronů existuje jenom mezi neurony přilehlých vrstev a je jednosměrné. To znamená, že ve vlastní vrstvě mezi sebou a mezi dalšími vrstvami neurony propojeny nejsou a mezi neurony neexistují ani žádné zpětné vazby [3].



Obrázek 5 Dopředná neuronová síť. Zdroj: [19]

2.2 Proces učení neuronové sítě

Základní a velmi podstatnou vlastností neuronové sítě je její schopnost učení. Proces učení neuronové sítě představuje dynamický proces, při kterém dochází k modifikaci vhodných, tzv. nastavitelných, parametrů příslušné neuronové sítě za účelem dosažení požadované shody mezi výstupy z modelované soustavy a výstupy z neuronové sítě. Ve většině případů se proces učení soustřeďuje na adaptaci vah synapsí mezi neurony. Někdy mohou být nastavitelnými parametry také strmosti aktivačních funkcí nebo postupná změna struktury neuronové sítě.

2.2.1 Učení s učitelem

Učení s učitelem představuje v praxi nejběžnější způsob učení. Hledaná transformační funkce umělé neuronové sítě je vždy dána dvojicí hodnot. A to hodnotou vstupní proměnné x_i na straně jedné, a k ní požadovaným výstupem y_i daný učitelem na straně druhé. Tyto požadované výstupní hodnoty se během učícího procesu porovnávají se skutečným výstupem sítě \hat{y}_i (skutečný výstup vznikne jako odezva neuronové sítě na daný vstupní signál). Přitom během procesu učení dochází k modifikaci vah synapsí za účelem dosažení co možná největší shody mezi skutečným a požadovaným výstupem. Tzn. že v procesu učení hledáme minimum chybové funkce E , která někdy bývá nazývána také funkcí energetickou [2].

Pro učení dopředné neuronové sítě byl vyvinut algoritmus zpětného šíření chyby E známý pod pojmem BP algoritmus (z anglického Back Propagation Algorithm) [8]. Snahou učení je dosáhnout takového nastavení vah, aby odchylka (chyba) mezi aktuálními a požadovanými výstupy sítě byla minimální vzhledem k odpovídajícím předloženým trénovacím vzorům. Chyba je definována jako [9]:

$$E = \sum_k E_k \quad (2.4)$$

kde index k probíhá přes všechny trénovací vzory a E_k je chyba odpovídající k -tému trénovacímu vzoru definovaná vztahem [9]:

$$E_k = \frac{1}{2} \sum_j (y_j - d_{kj}), \quad (2.5)$$

v němž index j probíhá přes neurony výstupní vrstvy a d_{kj} je j -tý element požadovaného výstupu k -tého trénovacího vzoru.

Pro optimalizaci chyby se v základním modelu sítě používá gradientní metoda [9]. Na začátku učení se všechny váhy nastaví na malé náhodné hodnoty se střední hodnotou okolo nuly. Poté se předkládají jednotlivé trénovací vzory, pro každý se spočítá pomocí vybavovací fáze chyba podle vztahu (2.5) a tato chyba se akumuluje. Po vyčerpání všech trénovacích vzorů je dosaženo výsledné chyby ze vztahu (2.4) a na jejím základě jsou upraveny hodnoty vah sítě podle vztahu [9]:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}, \quad (2.6)$$

kde změny vah se získají ze vztahu

$$\Delta w_{ij} = -\mu \frac{\partial E}{\partial w_{ij}}, \quad (2.7)$$

kde η je parametr učení, $0 \leq \eta \leq 1$. Parciální derivace chyby podle vah sítě v tomto vztahu představuje minimalizaci chyby pomocí vah gradientní metody. Vzhledem k lineárnosti operátoru derivace a vztahu (2.4) platí, že [9]:

$$\frac{\partial E}{\partial w_{ij}} = \sum_k \frac{\partial E_k}{\partial w_{ij}}. \quad (2.8)$$

Využitím pravidel o derivaci složené funkce se získá vztah [9]:

$$\frac{\partial E_k}{\partial w_{ij}} = \frac{\partial E_k}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}}. \quad (2.9)$$

Parciální derivace $\frac{\partial y_j}{\partial \xi_j}$ je získána derivací vztahu

$$\frac{\partial \xi_j}{\partial w_{ij}} = y_i. \quad (2.10)$$

Parciální derivace $\frac{\partial y_j}{\partial \xi_j}$ je získána derivací aktivační funkce (sigmoidy) a využitím její vlastní

funkční hodnoty $\frac{\partial y_j}{\partial \xi_j} = \frac{\lambda e^{-\lambda \xi_j}}{(1 + e^{-\lambda \xi_j})^2} = \lambda y_j (1 - y_j)$ [9]. (2.11)

Poslední parciální derivace $\frac{\partial E_k}{\partial y_j}$ je vypočítána metodou zpětného šíření, tj. postupným

procházením sítě od výstupní vrstvy ke vstupní vrstvě. Procházení sítě odzadu je dáno tím, že primární informace o chybě se nachází pouze ve výstupní vrstvě a do ostatních vrstev se musí teprve postupně přenášet. Dosazením příslušných parciálních derivací do vztahů (2.9) a (2.10) se získá výsledná hodnota gradientu chybové funkce. Pomocí této hodnoty je pak vypočítána změna vah podle vztahu (2.8) pro úpravu vah sítě.

2.2.2 Učení bez učitele

Tento typ učení je založen na schopnosti neuronových sítí rozeznat ve svých vstupech stejné nebo podobné vlastnosti a třídit tak předkládané vektory podle těchto vlastností. Neuronové sítě jsou poskytovány pouze hodnoty vstupních proměnných. Principem učení je výpočet vzdálenosti mezi vzory a aktuálními hodnotami. Jsou hledány minimální vzdálenosti vzoru. Procesu samoorganizace se používá v případech, kdy není známá učící množina [2]. Jako příklady neuronových sítí, ve kterých je používán tento typ učení, lze uvést např. asociativní paměti, Kohonenovy sítě, apod.

2.3 Dílčí závěry

V kapitole byly uvedeny základní pojmy z oblasti neuronových sítí a popsána dopředná neuronová síť. Dále byl definován algoritmus učení dopředné neuronové sítě, tj. algoritmus zpětného šíření chyby. Tento algoritmus umožňuje takové nastavení vah synapsí, že je minimalizována chyba učení. Existuje však možnost uvíznutí v lokálním minimu. Takto definovaná neuronová síť bude dále použita při predikci finančních toků obcí.

3 Neuronové sítě typu RBF

Sítě typu RBF, představují vícevrstvé neuronové sítě s jednotkami odlišného typu, než jsou například dříve popsané perceptrony. Také motivace jejich zavedení je jiná. Začátkem osmdesátých let se v části numerické matematiky zabývajících se interpolací a aproximací dat začaly studovat tzv. radiální bazické funkce (Radial Basis Functions) jako jeden z nových způsobů řešení aproximačních problémů.

Pod RBF neuronovou sítí se rozumí jakýkoliv druh dopředné neuronové sítě, který jako přechodovou funkci používá radiální bazickou funkci. Takto vymezené neuronové sítě jsou z aproximačního hlediska přirozené, protože se aproximuje funkcemi, které ovlivňují výslednou funkci jen v okolí centra příslušného RBF neuronu a ne v celém rozsahu funkce.

3.1 Aktivační funkce

Hledá-li se funkce, která bude nejlépe (v nějakém smyslu, například dle kritéria nejmenších čtverců) aproximovat daná data, omezujeme se většinou na funkce vyjádřené v nějakém konkrétním tvaru. Často jde o lineární kombinaci tzv. bazických funkcí, což mohou být například polynomy, nebo v tomto případě radiální funkce. Radiální funkci si lze představit jako funkci určenou nějakým významným bodem – středem – která pro argumenty se stejnou vzdáleností od tohoto středu dává stejné funkční hodnoty. Všeobecně má tvar [4]:

$$h(x) = \varphi\left(\frac{\sqrt{(\mathbf{x} - \mathbf{c})^T (\mathbf{x} - \mathbf{c})}}{r}\right), \quad (3.1)$$

kde výraz $\sqrt{(\mathbf{x} - \mathbf{c})^T (\mathbf{x} - \mathbf{c})}$ vyjadřuje vzdálenost mezi vstupním vektorem \mathbf{x} a centrem RBF \mathbf{c} v Euklidovském vektorovém prostoru a r určuje poloměr funkce. V případě použití jednorozměrného vektoru vstupních dat, dojde ke zjednodušení funkce na [4]:

$$h(x) = \varphi\left(\left|\frac{\mathbf{x} - \mathbf{c}}{r}\right|\right). \quad (3.2)$$

Radiální funkce jsou zvláštní třídou matematických funkcí, jejichž základní vlastností je, že monotónně klesají nebo stoupají se zvětšující se vzdáleností od centra.

Neurony skryté vrstvy mohou jako aktivační funkci obsahovat libovolnou radiálně bazickou funkci. Nejčastěji používanou je Gaussova funkce (jako jednorozměrná radiálně bazická

funkce) a rotační Gaussova funkce (dvourozměrná radiálně bázická funkce). Je možno zavést např. následující typy radiálních funkcí [4]:

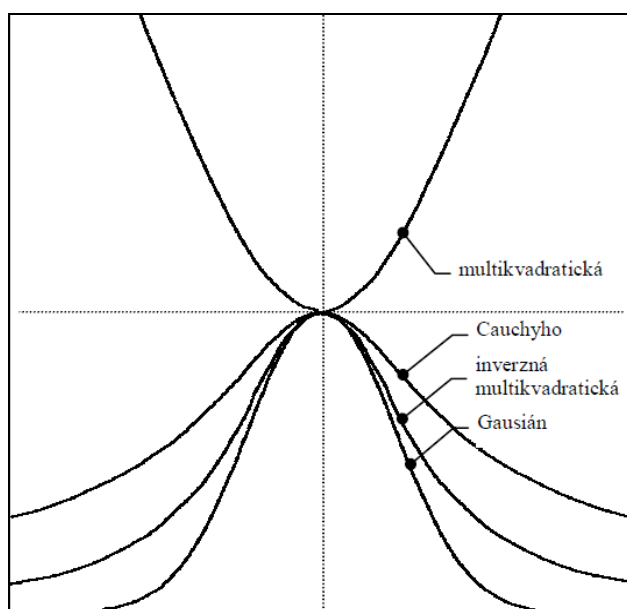
- Gaussova funkce $\varphi(x) = e^{-x^2}$ (3.3)

- multikvadratická $\varphi(x) = \sqrt{(x^2 + c^2)}$, $c > 0, x \in R$, (3.4)

- inverzní multikvadratická $\varphi(x) = \frac{1}{\sqrt{(x^2 + c^2)}}$, $c > 0, x \in R$, (3.5)

- Cauchyho $\varphi(x) = \frac{1}{1+x}$. (3.6)

Průběh jednotlivých aktivačních funkcí je zobrazen na obrázku 6.




Obrázek 6 Grafy jednorozměrných radiálních funkcí. Zdroj: [4]

3.2 Topologie neuronové sítě typu RBF

RBF síť si lze představit jako třívrstvou neuronovou síť, kde vstupní vrstva neuronů slouží pouze k přenosu vstupních hodnot. Druhá (skrytá) vrstva sestává z tzv. RBF jednotek, které realizují jednotlivé radiální funkce. Třetí, výstupní vrstva je lineární. Formálně lze RBF síť vyjádřit následujícím vztahem [4]:

$$f(x) = w_0 + \sum_{i=1}^m w_i h_i(\mathbf{x}). \quad (3.7)$$

Dále bude RBF neuronová síť chápána jako síť s jednou skrytou vrstvou tak, jak byla definována Broomheadem a Lowem. Grafické znázornění této sítě je zobrazeno na obrázku 7.



Obrázek 7 Graf RBF neuronové sítě. Zdroj: [4]

Vstupní vrstva neuronové sítě zprostředkovává načítání jednotlivých vektorů dat. Anomálií je použití vstupní vrstvy pouze pro načítání dat. U RBF neuronové sítě nejsou použity váhy synapsí mezi vstupní a skrytou vrstvou. Další rozdíl nastává ve skryté vrstvě, kde RBF neuronová síť, obsahuje právě jednu skrytou vrstvou. Není tedy možno konstruovat RBF neuronovou síť s více než jednou skrytou vrstvou. Důvodem omezení počtu skrytých vrstev je skutečnost, že každá z n vstupních hodnot vektoru x slouží jako parametr aktivační funkce h_i , $\forall i \in N : 0 < i \leq m$. Výstup sítě je potom lineární kombinací radiálně bazických funkcí a vah w_1, w_2, \dots, w_m [7], [4].

3.3 Proces učení RBF neuronové sítě

Proces učení RBF neuronové sítě se skládá z několika základních kroků. V prvním kroku musí být určen počet RBF center a nalezení jejich nejvhodnějších pozic. Druhým krokem je určení poloměrů center, nastavení vah mezi skrytou a výstupní vrstvou a určení strmosti RBF.

3.3.1 Počet neuronů ve skryté vrstvě

Návrh vhodného počtu RBF neuronů ve skryté vrstvě neuronové sítě je velmi důležitým bodem, protože má výrazný vliv na výsledné vlastnosti neuronové sítě. A to zejména na rychlost učení, přesnost navrženého modelu nebo schopnost zevšeobecnování dat.

První pokusy s RBF neuronovou sítí se zabývaly interpolací hodnot časové řady. Každé známé hodnotě vstupních dat byl přiřazen jeden neuron ve skryté vrstvě a výstupem poté byly neznámé hodnoty nacházející se mezi danými vstupy. Takto koncipovaná neuronová síť je zcela nevhodná pro jakoukoli aproximaci funkcí [6], [7]. Vysoký počet neuronů vede k rychlému přeučení neuronové sítě a ke ztrátě schopnosti zevšeobecnování navrženého modelu. Výsledkem je pak neuronová síť, která velmi přesně postihuje historická data přivedená na vstup během procesu učení, avšak jakákoli nová data není model schopen postihnout.

Problémem počtu neuronů a jejich vlivu na přesnost navrhovaného modelu se v devadesátých letech dvacátého století zabývali Partha Niyogi a Federico Girosi [5]. Ve své práci se zabývali matematických definováním optimálního počtu RBF neuronů ve skryté vrstvě neuronové sítě. Výsledky jejich práce jsou přínosné, jelikož usnadňují návrh topologie neuronové sítě.


Věta 1 [6]: Necht' je dána RBF neuronová síť používající Gaussovu funkci s m_0 vstupními jednotkami a m_1 skrytými jednotkami. Dále, necht' $f(x)$ představuje regresní funkci, jež patří do Sobolevova prostoru. Potom, neuronová síť převezme trénovací data $\Psi = \{(x_i, d_i)\}_{i=1}^l$ jako náhodný výběr z regresní funkce $f(x)$. Pro jakýkoli parametr $\delta \in (0,1)$ je trénovací chyba O RBF neuronové sítě ohraničená shora

$$\|f_0 - \hat{f}_{m,l}\|^2 \leq O\left(\frac{1}{m_1}\right) + O\left(\frac{m_0 m_1}{l} \log(m_1 l) + \frac{1}{l} \log\left(\frac{1}{\delta}\right)^{1/2}\right), \quad (3.8)$$

s pravděpodobností vyšší než $1-\delta$, l je rozsah náhodného výběru (množiny vstupních dat).


Z věty 1 a jiných poznatků Niyogi a Girosiho lze vyvodit závěry týkající se počtu RBF neuronů ve skryté vrstvě [5]:

- Celková chyba pro trénovací množinu dat konverguje k nule s růstem počtu RBF neuronů m_1 ve skryté vrstvě, viz obrázek 8.



Obrázek 8 Vliv množství vstupních dat a počtu RBF neuronů na trénovací chybu. Zdroj: [5]

- Zevšeobecnující chyba (testovací a validační) klesá pouze za předpokladu, že počet RBF neuronů m_l roste výrazně pomaleji než množství dat l ve vstupní množině, což zobrazuje obrázek 9.



Obrázek 9 Vliv počtu RBF neuronů na zevšeobecnující (testovací a validační) chybu. Zdroj: [5]

- Na průběh trénování a zevšeobecňující chyby má vliv množství dat v trénovací množině a počet RBF neuronů ve skryté vrstvě.
- Pro danou velikost trénování množiny dat l je optimální množství neuronů ve skryté vrstvě m_1^* přibližně $\sqrt[3]{l}$. Zvýšení i snížení množství RBF neuronů má za následek zvýšení zevšeobecňující chyby.
- Neuronové sítě typu RBF se stávají neefektivní pro řešení klasifikačního problému, pokud se jednotlivé RBF neurony překrývají.

3.3.2 Nalezení center RBF neuronů

Dalším krokem procesu učení je nalezení center RBF oblastí. Nalezení vhodných center RBF neuronů je jednou z nejdůležitějších částí procesu učení neuronové sítě. Přesná volba center, vhodně postihujících vstupní data, umožňuje použití nižšího množství neuronů ve skryté vrstvě při zachování stejné přesnosti.

Existuje více přístupů k určení center RBF neuronů v první fázi inicializace neuronové sítě. Jednou z možností je metoda náhodné volby, která byla použita Broomheadem a Lowem při definování RBF neuronové sítě. Další způsob pro nalezení center je použití segmentace, což je nejpoužívanější metoda.

Náhodná volba – Tato nejjednodušší metoda používá fixní sklon radiálně bazických funkcí. Jejich poloha je zvolena náhodně z množiny trénovacích dat. Tento přístup předpokládá, že náhodně vybraná centra budou vhodně reprezentovat data vstupující do neuronové sítě. Jako radiálně bazická funkce je zde použita Gaussova funkce s centry v \mathbf{c}_i definována jako [6]:

$$G(\|\mathbf{x} - \mathbf{c}_i\|^2) = e^{-\frac{m_i}{d_{\max}^2} \|\mathbf{x} - \mathbf{c}_i\|^2}, \quad i = 1, 2, \dots, m_1, \quad (3.9)$$

kde m_1 je počet center a d_{\max} vyjadřuje maximální vzdálenost mezi zvolenými centry. Sklon radiálně bazických funkcí je fixní a definován jako [6]:

$$\sigma = \frac{d_{\max}}{\sqrt{2m_1}}. \quad (3.10)$$

Tento vztah zajišťuje skutečnost, že radiálně bazické funkce nebudou příliš strmé ani příliš ploché. Použití této metody není však příliš efektivní. Tato metoda je vhodná pouze pro malé množiny vstupních dat. Při jejím použití na větší množiny dochází k rychlému a často

zbytečnému nárůstu množství RBF neuronů ve skryté vrstvě a tím i k neopodstatněnému růstu složitosti výsledné neuronové sítě [6], [7].

Segmentace dat – Vzhledem k tomu, že data, která vstupují do neuronové sítě, jsou předem známa, je možno použít informace v nich obsažené k vyhledání vhodných míst jako center RBF oblastí.

Segmentace dat je metodou učení bez učitele a lze zde opět použít několik algoritmů. Jednou z velmi známých nehierarchických metod shlukové analýzy je metoda K-means. Tato metoda spočívá v rozdělení l bodů vstupní množiny do k shluků pomocí minimalizace jistého kritéria. Algoritmus K-means minimalizuje funkci [6]:

$$K = \sum_{j=1}^k \sum_{i=1}^l (\mathbf{x}_i - \boldsymbol{\mu}_j)^2, \quad (3.11)$$

kde vstupem algoritmu je množina dat \mathbf{x}_i , $i = 1, \dots, l$ a číslo K udávající počet vektorů $\boldsymbol{\mu}_j$, $j = 1, \dots, k$.

Obecně lze algoritmus K-means popsat těmito kroky:

1. Na začátku se inicializují vektory $\boldsymbol{\mu}_j$ na náhodně zvolenou hodnotu.
2. Všechna data \mathbf{x}_i jsou přiřazena do tříd určenými vektory $\boldsymbol{\mu}_j$, podle minima Euklidovské vzdálenosti.
3. Přepočítání vektorů $\boldsymbol{\mu}_j$: Vypočítají se nové hodnoty vektorů $\boldsymbol{\mu}_j$ jako střední hodnoty dat \mathbf{x}_i .
4. Opakování kroků 2 a 3 do okamžiku, dokud se alespoň jeden vektor \mathbf{x}_i klasifikuje do jiné třídy než byl klasifikován v předcházejícím kroku.

Každá takto vytvořená množina má svého reprezentativního zástupce, jenž je zároveň zvolen centrem radiální báze funkce. Výběr center radiálně bazických funkcí použitím tohoto postupu zajišťuje optimální přiřazení neuronů skryté vrstvy k daným skupinám dat vstupujících do neuronové sítě.

3.4 Dílčí závěry

V této kapitole byla definována neuronová síť typu RBF, její topologie a proces učení. Oproti dopředné neuronové síti jsou jako aktivační funkce skryté vrstvy používány radiální bazické

funkce. To umožňuje rychlejší naučení sítě a konvergenci sítě ke globálnímu minimu v průběhu učení. Tento typ neuronové sítě bude použit pro predikci finančních toků obcí a výsledky budou porovnány s dopřednou neuronovou sítí.

4 Návrh modelu pro predikci finančních toků obcí

V této části práce je navržen model pro predikci finančních toků obcí pomocí neuronových sítí. Predikce časové řady pomocí neuronové sítě spočívá v naučení sítě na průběh veličiny v nějakém omezeném čase a následném použití do budoucnosti. Síť jsou předkládána na vstup data z minulosti a jako výstup se očekávají data z budoucnosti. Jedná se tedy o učení s učitelem.

V první části této kapitoly jsou uvedeny příklady metod predikce, které je možné využít pro modelování finančních toků obcí. Druhá část této kapitoly popisuje metody, kterými lze měřit přesnost predikce. V další části je navržen algoritmus řešení a poté jsou definovány vstupní parametry a jejich následné předzpracování.

4.1 Metody predikce

Konstrukce předpovědí (jinak také predikce) je jedním z nejdůležitějších úkolů analýzy časových řad. Výběr příslušné metody predikce závisí na dané situaci a řadě dalších okolností. Hrají zde roli zejména následující faktory [1]:

- Horizont předpovědi, což je časová vzdálenost předpovídané hodnoty od okamžiku provádění předpovědi.
- Požadovaná forma předpovědi. Například bodová předpověď, nebo předpovědní interval.
- Náklady spojené s konstrukcí předpovědi, tzn. časové i finanční prostředky spojené s vyvinutím metody, či s vlastní předpovědí.
- Požadovaná přesnost předpovědi.
- Druh dat, která jsou k dispozici. Výchozími daty může být např. pouze jednoduchá časová řada, řada s doplňujícími informacemi (průběh derivace, interferenční proměnné), či několik časových řad, které jsou spolu nějakým způsobem příbuzné.
- Dostupnost dat, jejich kvalita (např. chybějící údaje), či objem.

Pro predikci finančních toků obcí, kterými se zabývá tato práce, je možno využít následující metody predikce.

4.1.1 Kvalitativní metody predikce

Též nazývané expertní metody, jsou obvykle založeny na názoru odborníků a mají proto dosti subjektivní charakter. Tyto metody nacházejí uplatnění v případě, když není k dispozici dostatečné množství historických dat, pro předpovědi za pomoci analýzy. To může nastat například při plánování výrobního procesu v podniku při zavádění nových výrobních technologií.

Výhody a nevýhody kvalitativních metod [16]:

- Za hlavní přednost metod lze považovat využití velkého množství informací.
- Nevýhodou metody je její nesystematičnost v měření a vyhodnocení přesnosti předpovědi a možná předpojatost expertů.
- Jsou vhodné pro dlouhodobé předpovědi.

4.1.2 Kvantitativní metody predikce

Snaží se předpovídat na základě statistické analýzy naměřených dat. Kvantitativní metody jsou tedy konstruovány na základě objektivních metod, ale na druhou stranu jejich úspěch silně závisí na předpokladu, že se v budoucím vývoji nemění charakter řady (tzn. že zůstává v platnosti model zkonstruovaný na základě předchozích hodnot). Kvantitativní metody se člení do dvou skupin [16]:

1. Vycházející z časových řad (Time-series) – vychází z předpokladu, že studiem minulých hodnot a jejich pohybu v čase, lze předpovědět budoucí hodnoty analyzované proměnné.
2. Ekonometrické nebo příčinné (Econometric or causal) – příčinné (deterministické) modely odvozují hodnoty předpovídané proměnné (závislé) z chování jiných proměnných (nezávislých).

Výhody a nevýhody kvantitativních metod:

- Po vhodném výběru nezávislé proměnné (proměnných), spočívá předpověď pouze na hodnotách této proměnné a je tudíž objektivní.
- Existují způsoby měření přesnosti předpovědi.
- Pokud je jednou model sestaven, je generování předpovědi závislé pouze na čase.
- Jsou vhodné pro krátkodobé a střednědobé předpovědi.

4.1.3 Metoda extrapolace

Je založena na prodlužování sledovaných vývojových řad. Vychází z předpokladu, že sledovaný proces se bude v budoucnu vyvíjet stejným směrem nebo i stejnou intenzitou.

Postup uplatnění metod extrapolace zahrnuje etapy:

1. Určení parametrů trendu.
2. Výběr dat charakterizujících minulý vývoj.
3. Volba délky extrapolovaného období.
4. Určení funkce (křivky) vyjadřující budoucí trend.

4.2 Chyby a metody pro hodnocení kvality predikce

Vyšetřování chyb predikce je nezbytný úkol pro zhodnocení kvality použitých metod. Hlavním zdrojem chyby predikce je přítomnost reziduální složky v časové řadě, jelikož tato složka představuje nepředpověditelné chování řady. Je-li v datech velký podíl této složky, pak je možnost podat přesnou předpověď značně omezena.

Chyba predikce je definována jako:

$$e_i = y_i - \hat{y}_i, \quad (4.1)$$

kde y_i je skutečná hodnota a \hat{y}_i je predikovaná hodnota. Velikost chyby se samozřejmě zjistí až tehdy, když je známá skutečná hodnota y_i , která nebyla při konstrukci predikce známá.

Často se však pro posouzení kvality navržené metody predikce konstruují předpovědi známých hodnot časové řady (tzv. testovací množina dat) a provádí se porovnání těchto předpovědí s daty z testovací množiny.

Přesnost predikce [20] dat za pomoci neuronové sítě je možno vyjádřit například pomocí sumy kvadratických odchylek

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (4.2)$$

střední kvadratické odchylky

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (4.3)$$

odmocniny ze střední kvadratické odchylky

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.4)$$

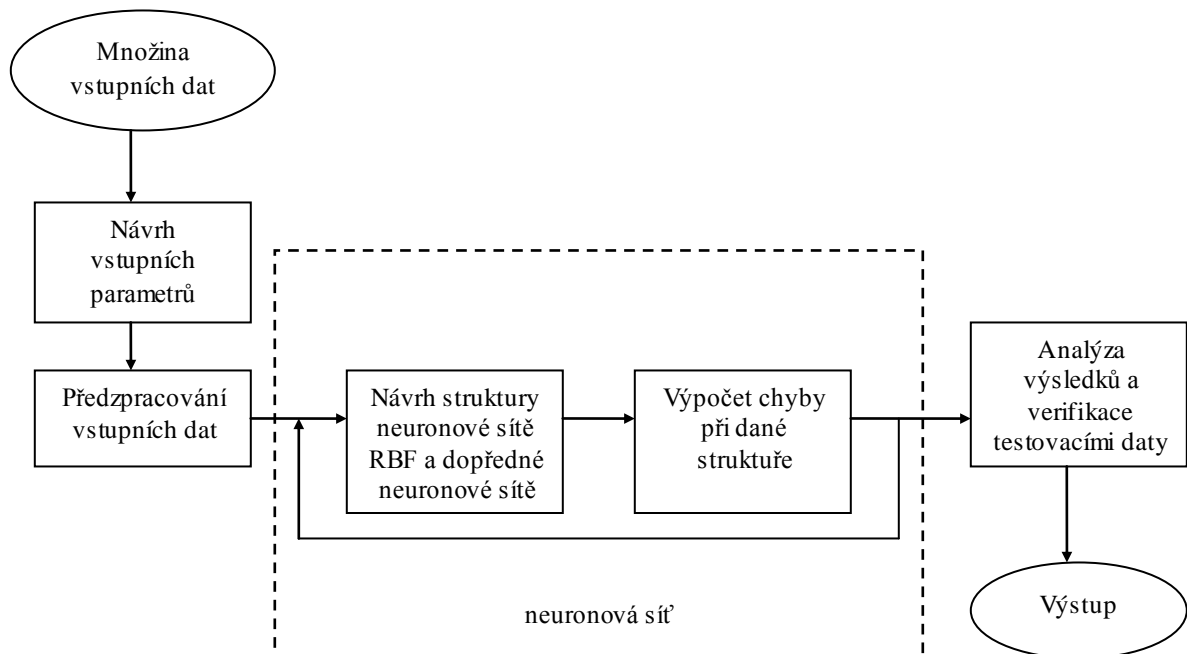
nebo absolutní odchylky

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (4.5)$$

Během procesu učení se hledá takové řešení, kdy je chyba výstupu co možná nejnižší. A to jak pro trénovací, tak pro testovací množinu dat. Je preferováno takové řešení, kdy jsou si chyby pro obě množiny dat blízké, před řešením, kdy je jedna chyba minimalizována na úkor druhé [1], [20].

4.3 Návrh modelu

Modelování finančních toků obcí pomocí neuronových sítí se skládá z několika dílčích kroků zobrazených na obrázku 10. Chyba jednoho kroku může negativně ovlivnit kroky následující a výsledný model by nesplňoval požadavky na přesnost. Proto je zapotřebí přiřadit každému kroku dostatečnou důležitost.



Obrázek 10 Návrh modelu pro predikci finančních toků obcí. Zdroj: [Vlastní]

Základem modelu je vlastní sběr požadovaných dat z daného okolí, která budou následně využita pro predikci. Na kvalitě vstupních dat závisí výsledek navržené neuronové sítě. Následuje předzpracování dat a jejich rozdělení na trénovací a testovací množinu. Dalším krokem je volba struktury a parametrů RBF neuronové sítě a dopředné neuronové sítě. Na základě analýzy výsledků je vybrána struktura s příslušnými parametry, která poskytuje nejlepší výsledky predikce (nejnižší chybu na testovacích datech). Výstupem navrženého modelu jsou predikované hodnoty finančních toků (příjmů) obcí s požadovanou přesností.

4.4 Návrh vstupních parametrů

Vstupní množina dat obsahuje informace o 452 obcích Pardubického kraje v letech 2003 až 2008. Tyto data byla získána z rozpočtů a z finanční rozvahy obcí, která poskytl Krajský úřad Pardubického kraje. Dalším zdrojem dat (socio-ekonomických) byly stránky Českého statistického úřadu (ČSÚ).

Jednotlivé obce jsou popsány 23 vstupními parametry (za roky 2003-2007) a jedním výstupním parametrem (za roky 2004-2008). Vstupní parametry P1, P2, ..., P23 lze rozdělit na daňové příjmy, nedaňové příjmy, kapitálové příjmy a přijaté dotace. Výstupním parametrem V je velikost příjmů obcí. Délka predikce je stanovena na jeden rok. Podrobný popis parametrů obsahuje datový slovník, který zobrazuje tabulka 3.

4.4.1 Návrh parametrů daňových příjmů

Daňové příjmy jsou nejvýznamnějším zdrojem financování obcí. Jak již bylo uvedeno v první kapitole, příjmy daňového charakteru patří mezi nenávratné a jsou tvořeny daněmi, místními a správními poplatky. Parametry daňových příjmů byly pro tuto práci navrženy takto:

Počet obyvatel obce (P1) – udává počet obyvatel obce v daném roce. Vyšší hodnota tohoto parametru znamená pro obec vyšší daňové příjmy a naopak.

Velikostní koeficient obce (P2) – je stanoven obcím podle počtu obyvatel v obci, dle kterého je určena výše daňového příjmu na sdílených daních.

Hrubý domácí produkt (P3) - je hrubý domácí produkt (HDP) v daném roce.

Počet podnikatelských subjektů v obci (P4) – udává počet ekonomických subjektů v obci za příslušný rok.

Daň z příjmů fyzických osob ze závislé činnosti (P5) - zahrnuje daň odvedenou plátcem - zaměstnavatelem - za vlastní zaměstnance. Výnos plynoucí obci daně z příjmů fyzických osob činí 20,59% z celkového výnosu daně.

Tabulka 3 Datový slovník. Zdroj: [Vlastní]

Parametr	Popis parametru	Datový typ	Rozsah
P1	Počet obyvatel obce	Celočíselný	23 - 89245
P2	Velikostní koeficient obce	Desetiný	0,4213 – 0,8487
P3	Hrubý domácí produkt (HDP)	Procenta	3,6% - 6,8%
P4	Počet podnikatelských subjektů v obci	Celočíselný	5 – 22481
P5	Daň z příjmů fyzických osob ze závislé činnosti	Měna [Kč]	17801 – 213,4*10 ⁶
P6	Daň z příjmů fyzických osob ze samostatné činnosti	Měna [Kč]	-34876 – 83,49*10 ⁶
P7	Daň z příjmů fyzických osob z kapitálových výnosů	Měna [Kč]	0 – 12,84*10 ⁶
P8	Daň z příjmů právnických osob	Měna [Kč]	4226 – 233,14*10 ⁶
P9	Daň z příjmů právnických osob za obce	Měna [Kč]	0 – 56,85*10 ⁶
P10	Daň z přidané hodnoty	Měna [Kč]	0 - 334,12*10 ⁶
P11	Poplatky a daně z vybraných činností a služeb	Měna [Kč]	0 – 113,4*10 ⁶
P12	Daň z nemovitostí	Měna [Kč]	0 – 43,38*10 ⁶
P13	Dlouhodobý nehmotný majetek	Měna [Kč]	0 – 79,03*10 ⁶
P14	Dlouhodobý hmotný majetek	Měna [Kč]	844029 – 9,78*10 ⁹
P15	Dlouhodobý finanční majetek	Měna [Kč]	0 – 1,45*10 ⁹
P16	Příjmy z vlastní činnosti	Měna [Kč]	0 – 26,52*10 ⁶
P17	Příjmy z pronájmu majetku	Měna [Kč]	0 – 38,48*10 ⁶
P18	Příjmy z úroků a realizace finančního majetku	Měna [Kč]	0 – 7,46*10 ⁶
P19	Příjmy z prodeje neinvestičního majetku	Měna [Kč]	0 – 2,77*10 ⁶
P20	Příjmy z prodeje investičního majetku	Měna [Kč]	0 – 176,91*10 ⁶
P21	Počet dětí 0-14 let	Celočíselný	1 – 11814
P22	Běžné přijaté dotace	Měna [Kč]	549 – 3,55*10 ⁹
P23	Kapitálové přijaté dotace	Měna [Kč]	0 – 102,64*10 ⁶
V	Celkové příjmy - výstupní proměnná určená k predikci	Měna [Kč]	283943 – 1,86*10 ⁹

Daň z příjmů fyzických osob ze samostatné činnosti (P6) - zahrnuje veškerou daň "z daňových priznání", tj. získanou z výdělečné činnosti jiné než je závislá práce, především pak z podnikání, jiné samostatné výdělečné činnosti a pronájmu. Výnos plynoucí obci činí 30% z celkového výnosu daně.

Daň z příjmů fyzických osob z kapitálových výnosů (P7) - zahrnuje daně z úroků, dividend a jiných kapitálových výnosů.

Daň z příjmů právnických osob (P8) - zahrnuje daň ze zisku a kapitálových výnosů ve smyslu zákona o daních z příjmů¹. Výnos plynoucí obci činí 20,59% z celkového výnosu daně.

Daň z příjmů právnických osob za obce (P9) - zahrnuje daň v případech, kdy je poplatníkem obec, s výjimkou daně vybírané srážkou podle zvláštní sazby.

Daň z přidané hodnoty (P10) - zahrnuje daň z přidané hodnoty (DPH) podle zákona o dani z přidané hodnoty². Výnos plynoucí obci činí 20,59% z celkového výnosu daně.

Poplatky a daně z vybraných činností a služeb (P11) - jsou tvořeny zejména poplatky za ukládání odpadů, poplatky za komunální odpad, místními poplatky (tj. poplatek ze psů, poplatek za užívání veřejného prostranství, poplatek za provozovaný výherní hrací stroj atd.). Obci připadá celá část vybraných poplatků tj. 100%.

Daň z nemovitostí (P12) – zahrnuje daň podle zákona o dani z nemovitostí³, která se dělí na daň z pozemků a daň ze staveb. Příjmem obcí je celý výnos z této daně.

4.4.2 Návrh parametrů nedaňových příjmů

Nedaňové příjmy – zejména příjmy z vlastní hospodářské činnosti představují další významný zdroj do rozpočtu obcí. Tvoří je příjmy z užitelských poplatků, příjmy od různých organizací zřízených obcemi – odvody příspěvkových organizací, dále je tvoří příjmy z pronájmu majetku, z realizace finančního majetku, úroky z poskytnutých úvěrů a ostatní nedaňové příjmy.

Pro tuto práci byly navrženy následující parametry týkající se nedaňových příjmů:

Dlouhodobý nehmotný majetek (P13) – udává velikost nehmotného majetku obce v daném roce, (viz. kapitola 1).

Dlouhodobý hmotný majetek (P14) – udává velikost hmotného majetku obce v daném roce, (viz. kapitola 1).

Dlouhodobý finanční majetek (P15) – udává velikost finančního majetku obce v daném roce, (viz. kapitola 1).

¹ Zákon č. 586/1992 Sb., o daních z příjmů

² Zákon č. 235/2004 Sb., o dani z přidané hodnoty

³ Zákon č. 338/1992 Sb., o dani z nemovitostí

Příjmy z vlastní činnosti (P16) – jsou tvořeny příjmy za poskytování služeb a výrobků, příjmy z prodeje zboží, odvody příspěvkových organizací (tj. vodné, stočné, odvoz domovního odpadu, poplatky za školní stravování, služby knihoven apod.).

Příjmy z pronájmu majetku (P17) – tj. příjmy z pronájmu pozemků, z pronájmu nemovitostí nebo jejich částí a příjmy z pronájmu movitých věcí.

Příjmy z úroků a realizace finančního majetku (P18) – zahrnují příjmy z úroků, příjmy z podílů na zisku a dividend a realizované kurzové zisky.

Příjmy z prodeje neinvestičního majetku (P19) – zahrnuje příjmy z prodeje neinvestičního (nekapitálového) majetku.

4.4.3 Návrh parametrů kapitálových příjmů

Kapitálové příjmy představují příjmy z prodeje majetku územních celků, výnosy z vlastnictví cenných papírů – z prodeje akcií a majetkových podílů.

Mezi parametry kapitálových příjmů lze zařadit i parametry majetku obce (P13, P14, P15), které byly již popsány výše a které s kapitálovými příjmy souvisí. A dále jsou to:

Příjmy z prodeje investičního majetku (P20) – tento parametr zahrnuje příjmy z prodeje pozemků, příjmy z prodeje nemovitostí a příjmy z prodeje hmotného a nehmotného investičního majetku.

4.4.4 Návrh parametrů přijatých dotací

Obcím v ČR jsou vypláceny převážně účelové dotace. Jedná se o dotace **běžné**, které slouží k financování provozních (každoročně se opakujících) neinvestičních potřeb, a **kapitálové**, které jsou určeny na financování investičních potřeb a mají dlouhodobý charakter. Obce získávají dotace z nejrůznějších zdrojů jako je státní rozpočet, státní fondy, kraje, obce a rozpočtu Evropské unie. Navrženými parametry jsou:

Počet dětí 0 -14 let (P21) – určuje počet dětí ve věku 0 až 14 let. Tento parametr byl zvolen proto, že nejvyšší položku dotací tvoří dotace do školství, která je závislá na počtu dětí/žáků navštěvující základní školy. Údaje o počtech žáků základních škol však nejsou k dispozici, proto byl zvolen parametr počet dětí 0 až 14 let.

Běžné přijaté dotace (P22) – celkový součet neinvestičních přijatých dotací v daném roce. Tvoří je: neinvestiční přijaté dotace ze státního rozpočtu, neinvestiční přijaté dotace ze státních fondů, dotace přijaté od orgánů státní správy, neinvestiční přijaté dotace od obcí, neinvestiční přijaté dotace od krajů, převody z vlastních fondů a neinvestiční přijaté dotace ze zahraničí.

Kapitálové přijaté dotace (P23) – celkový součet investičních přijatých dotací v daném roce. Mají stejné členění jako neinvestiční přijaté dotace.

4.4.5 Vektor vstupních parametrů

Výsledkem zjištěných a zpracovaných dat vznikla matice dat o velikosti $m \times n$, kde m je počet řádků a n je počet sloupců. Sloupce jsou tvořeny navrženými parametry a řádky tvoří obce, ve kterých je daný parametr sledován. Jelikož jsou parametry sledovány v letech 2003 – 2008, obsahuje matice celkem 2255 řádků a 23 sloupců.

Parametry p_1 až p_{23} představují vektor p parametrů charakterizujících finanční toky obcí. Vektor p má tvar:

$$p = (p_1, p_2, \dots, p_{23})$$

Navržený model je tedy popsán maticí P o velikosti 2255×23 a zápis lze vyjádřit takto:

$$P = \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,n} \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ x_{m,1} & x_{m,2} & \dots & x_{m,n} \end{bmatrix},$$

kde m je počet objektů (obcí), n je počet parametrů, x_{ij} je hodnota j -tého parametru p_j pro i -tou obec o_i , $j \in \{2, \dots, 23\}$.

4.5 Předzpracování dat

Data byla nejprve předzpracována v prostředí MS Excel, kde byly vypočteny také základní statistiky, jako je maximum, minimum, směrodatná odchylka, horní kvantil, průměr a rozptyl. Popisné statistiky dat se nacházejí v příloze A.

Dále byla provedena analýza závislostí pomocí korelační matice, která znázorňuje závislost mezi prvky vektoru. Prvky na hlavní diagonále jsou rovny jedné a prvky mimo diagonálu leží

v intervalu $[-1;1]$. Když je koeficient korelace roven nule, znamená to, že složky vektoru jsou nekorelované. Čím více se koeficient korelace v absolutní hodnotě blíží 1, tím více jsou složky vektoru vzájemně korelované a lineárně závislé.

V tabulce 4 je na ukázkou uvedena korelační matice pro prvních 12 parametrů, které charakterizují daňové příjmy.

Tabulka 4 Korelační matice pro parametry P1 až P12. Zdroj: [Vlastní]

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12
P1	1	0,4686	0,0006	0,9965	0,9921	0,9563	0,9816	0,9896	0,8702	0,9890	0,9437	0,9844
P2	0,4686	1	0,0071	0,4424	0,4354	0,4394	0,4267	0,4342	0,4274	0,4353	0,4302	0,4488
P3	0,0006	0,0071	1	0,0031	0,0131	-0,0125	0,0096	0,0176	0,0121	0,0180	0,0174	0,0016
P4	0,9965	0,4424	0,0031	1	0,9954	0,9538	0,9882	0,9933	0,8570	0,9916	0,9452	0,9884
P5	0,9921	0,4354	0,0131	0,9954	1	0,9386	0,9910	0,9996	0,8558	0,9911	0,9448	0,9860
P6	0,9563	0,4394	-0,0125	0,9538	0,9386	1	0,9229	0,9317	0,8269	0,9440	0,8918	0,9466
P7	0,9816	0,4267	0,0096	0,9882	0,9910	0,9229	1	0,9904	0,8419	0,9774	0,9370	0,9813
P8	0,9896	0,4342	0,0176	0,9933	0,9996	0,9317	0,9904	1	0,8539	0,9904	0,9442	0,9842
P9	0,8702	0,4274	0,0121	0,8570	0,8558	0,8269	0,8419	0,8539	1	0,8629	0,8262	0,8638
P10	0,9890	0,4353	0,0180	0,9916	0,9911	0,9440	0,9774	0,9904	0,8629	1	0,9389	0,9827
P11	0,9437	0,4302	0,0174	0,9452	0,9448	0,8918	0,9370	0,9442	0,8262	0,9389	1	0,9293
P12	0,9844	0,4488	0,0016	0,9884	0,9860	0,9466	0,9813	0,9842	0,8638	0,9827	0,9293	1

Z výše uvedené tabulky je zřejmé, že mezi daty existují statisticky významné závislosti. Vzhledem k vysokým korelacím mezi daty bude provedena analýza hlavních komponent, pomocí které budou závislosti mezi parametry analyzovány a původní parametry (proměnné) budou nahrazeny hlavními komponentami.

4.6 Analýza hlavních komponent

Metoda hlavních komponent [10], neboli PCA (Principal Component Analysis) je jednou z nejvíce používaných metod vícerozměrné analýzy. Poprvé byla zavedena v roce 1901 Pearsonem a nezávisle na tom v roce 1933 Hotellingem. Je to popisná statistická metoda, která je využívána zejména k redukci vícerozměrných dat.

Cílem analýzy hlavních komponent je redukce původního počtu popisovaných proměnných novými veličinami (umělými), označenými jako komponenty, které shrnují informaci o původních proměnných za cenu minimální ztráty informace. Tyto komponenty jsou vzájemně nezávislé a jsou seřazeny podle svého příspěvku k vysvětlení celkového rozptylu pozorovaných proměnných.

4.6.1 Zdrojová data

Základním předpokladem metody hlavních komponent jsou statisticky významné závislosti mezi vstupními proměnnými. Z korelační matice dat, která je uvedena v příloze B, je zřejmé, že data jsou vhodná pro předzpracování metodou PCA (tj. existují mezi nimi statisticky významné závislosti). Metoda je citlivá na změny měřítka. V případě, že jsou hodnoty jednotlivých veličin vyjádřeny v podstatně odlišných jednotkách, doporučuje se převést proměnné na normovaný tvar. Proto je provedena **standardizace** dat. Nyní jsou data připravena pro nalezení hlavních komponent.

4.6.2 Výstupy analýzy hlavních komponent

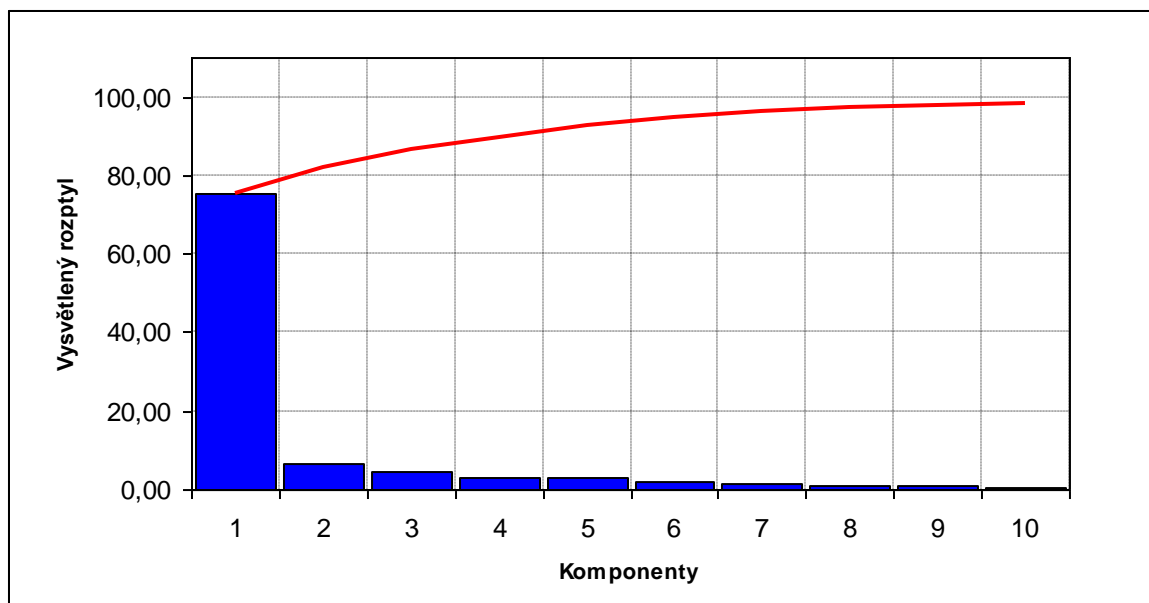
Jednotlivé komponenty lze charakterizovat pomocí vlastních čísel (Eigenvalue), kdy hodnota vlastního čísla větší než jedna slouží jako rozhodovací kritérium pro významnost hlavní komponenty. Dalším parametrem hlavních komponent je jejich podíl na celkovém rozptylu dat. Cílem je vysvětlit pomocí zvolených hlavních komponent maximální velikost celkového rozptylu.

Hodnoty vlastních čísel a vysvětlených rozptylů jsou uvedeny v příloze C. Z analýzy je vidět, že významné jsou první tři hlavní komponenty, jejichž vlastní čísla mají hodnotu větší než 1. Pro tuto práci byly zvoleny ty proměnné, které vysvětlují alespoň 90% rozptylu. Proto bylo vybráno prvních pět hlavních komponent, pomocí nichž lze vysvětlit 92,54 % celkového rozptylu v datech. V následující tabulce 5 jsou uvedeny charakteristiky těchto pěti hlavních komponent.

Tabulka 5 Podíl jednotlivých komponent na celkovém rozptylu. Zdroj: [Vlastní]

Komponenta	Hodnota vlastního čísla	Podíl na vysvětlení rozptylu v %	Rozptyl %
1	17,38	75,58	75,58
2	1,47	6,37	81,95
3	1,01	4,41	86,35
4	0,72	3,12	89,47
5	0,71	3,07	92,54

Graficky lze výsledky prezentovat na obrázku 11. Pro znázornění podílu jednotlivých komponent na celkovém rozptylu bylo zvoleno prvních deset komponent. První hlavní komponenta vysvětluje 75,58 % celkového rozptylu, další hlavní komponenta 6,37 %, atd.



Obrázek 11 Podíl komponent na celkovém rozptylu. Zdroj: [Vlastní]

Výstupem realizované analýzy hlavních komponent jsou koeficienty pro 5 hlavních komponent. Jejich ukázka je uvedena v tabulce 6.

Tabulka 6 Váhy jednotlivých komponent. Zdroj: [Vlastní]

Parametry	Komponenty				
	1	2	3	4	5
P1	0,99	-0,09	0,00	0,02	0,00
P2	0,49	0,35	0,00	0,75	0,24
P3	0,01	0,02	0,99	-0,06	0,15
P4	0,99	-0,13	0,00	0,01	-0,01
P5	0,98	-0,14	0,02	0,03	-0,06
P6	0,96	-0,07	-0,03	-0,03	0,05
P7	0,97	-0,15	0,01	0,02	-0,04
P8	0,98	-0,14	0,03	0,03	-0,08
P9	0,90	0,16	0,01	-0,10	-0,07
P10	0,98	-0,15	0,03	0,03	-0,06
P11	0,95	-0,08	0,02	0,02	-0,06
P12	0,98	-0,12	0,00	0,02	-0,03
P13	0,97	-0,05	0,03	-0,01	-0,09
P14	0,99	-0,01	0,02	-0,02	-0,06
P15	0,94	-0,15	0,03	0,04	-0,06
P16	0,68	0,56	-0,04	-0,22	-0,03
P17	0,65	0,65	-0,02	-0,16	-0,01
P18	0,86	0,04	0,00	0,01	0,00
P19	0,56	-0,12	-0,18	-0,23	0,76
P20	0,90	-0,08	0,01	-0,06	0,05
P21	0,99	-0,05	-0,01	0,03	0,01
P22	0,99	-0,05	-0,02	-0,04	0,00
P23	0,52	0,62	0,00	-0,04	-0,02

4.6.3 Interpretace hlavních komponent

I . Komponenta – obsahuje několik vysvětlujících proměnných s podobnými koeficienty korelace:

1. Počet obyvatel (P1)
2. Počet podnikatel. subjektů (P4)
3. Daň z příjmů fyzických osob ze závislé činnosti (P5)
4. Daň z příjmů fyzických osob ze samostatné činnosti (P6)
5. Daň z příjmů fyzických osob z kapitálových výnosů (P7)
6. Daň z příjmů právnických osob (P8)
7. Daň z příjmů právnických osob za obce (P9)
8. Daň z přidané hodnoty (P10)
9. Poplatky a daně (P11)
10. Daň z nemovitostí (P12)
11. Dlouhodobý nehmotný majetek (P13)
12. Dlouhodobý hmotný majetek (P14)
13. Dlouhodobý finanční majetek (P15)
14. Příjmy z úroků a realizace finančního majetku (P18)
15. Příjmy z prodeje investičního majetku (P20)
16. Počet dětí 0-14 let (P21)
17. Běžné přijaté dotace (P2)

Tato komponenta je tvořena zejména daněmi a majetkem obcí, proto bude nazvána komponentou „*Daně a majetek*“ a označena jako K1.

II. Komponenta – nejvíce s ní koreluje:

- Příjmy z vlastní činnosti (P16)
- Příjmy z pronájmu majetku (P17)
- Kapitálové přijaté dotace (P23)

Tato komponenta je tvořena převážně nedaňovými příjmy, proto bude nazvána jako „*Nedaňová*“ a označena K2.

III. Komponenta – největší koeficient korelace s komponentou vykazuje: Hrubý domácí produkt (P3). Lze ji tedy nazvat komponentou „*HDP*“ a označena jako K3.

IV. Komponenta – nejvíce s ní koreluje: Velikostní koeficient obce (P2). Bude tedy nazvána komponentou „*Velikostní*“ a označena K4.

V. Komponenta – největší koeficient korelace vykazuje: Příjmy z prodeje neinvestičního majetku (P19). Bude tedy nazvána komponentou: „*Prodej neinvestičního majetku*“ a označena K5.

4.7 Dílčí závěry

V kapitole byly navrženy vstupní parametry pro predikci finančních toků (příjmů obcí). Vzhledem k vysokým korelačním závislostem mezi parametry byla provedena analýza hlavních komponent. Po provedení analýzy hlavních komponent bude nyní množina vstupních dat tvořena 2255 záznamy o obcích Pardubického kraje v letech 2003-2007. Každá z obcí je popsána pěti vstupními a jedním výstupním parametrem. Vstupní parametry představuje pět komponent (K1, K2, K3, K4, K5), které jsou výsledkem analýzy hlavních komponent a jsou to data standardizovaná za roky 2003-2007. Výstupem jsou celkové příjmy v původní nestandardizované podobě v následujícím roce (tj. za roky 2004-2008), jak je uvedeno v datovém slovníku tabulka 3. Výstup bude předmětem predikce.

5 Predikce finančních toků obcí pomocí neuronových sítí

Topologie a učení neuronové sítě výrazně ovlivňuje velikost chyby výsledného modelu predikce finančních toků obcí. Pro predikci pomocí neuronových sítí bylo využito prostředí SPSS Clementine 10.1. Zpracování výsledků, výpočet chyb a grafické výstupy byly provedeny v programovém prostředí MS Excel.

V první části této kapitoly jsou nejprve vstupní data rozdělena na trénovací a testovací množinu. Ve druhé části je navržena RBF neuronová síť a dopředná neuronová síť (typu perceptron) pro predikci finančních toků obcí. Nakonec je provedena analýza výsledků obou navržených sítí a na jejím základě je vybrána optimální topologie a parametry učení neuronové sítě pro predikci finančních toků obcí.

5.1 Rozdělení dat

Pro úspěšný proces učení neuronové sítě jsou vyžadovány alespoň dvě skupiny dat, trénovací a testovací. Rozdělení vstupní množiny dat na množinu trénovací a testovací je možno provést několika způsoby:

- rozdělení náhodným výběrem,
- výběr každého n-tého prvku,
- výběr na základě shlukové analýzy,
- výběr na základě oblastí, určených Kohonenovou samoorganizující se mapou.

Při dělení vstupních dat na množinu trénovací a množinu testovací je požadováno, aby testovací množina reprezentovala veškerá data umístěná v množině trénovací. Důvodem je proces učení neuronové sítě.

V případě této práce jsou data rozdělena pomocí náhodného výběru. Rozdělení náhodným výběrem je realizováno pomocí uzlu „Partition“ v poměru 70% trénovací množina a 30% testovací množina. Ověření správnosti rozdělení vstupních dat je provedeno pomocí popisných charakteristik, které zobrazují tabulka 7 a tabulka 8. V případě, že by popisné statistiky trénovacího a testovacího souboru dat vykazovaly výrazné rozdíly, došlo by k nerovnoměrnému rozdělení základního souboru dat.

Tabulka 7 Popisné statistiky pro trénovací množinu dat. Zdroj: [Vlastní]


	K1	K2	K3	K4	K5
Rozsah souboru	1606	1606	1606	1606	1606
Minimum	-0.304	-12.186	-5.863	-6.875	-12.056
Maximum	18.566	10.951	2.990	5.013	25.971
Průměr	0.016	0.002	-0.024	-0.018	0.020
Medián	-0.156	-0.120	0.531	0.236	-0.028
Směrodatná odchylka	1.052	1.036	1.014	1.026	1.115
Součet	25.722	3.539	-37.935	-29.397	32.870
Chyba střední hodnoty	0.026	0.026	0.025	0.026	0.028
Rozptyl	1.106	1.074	1.029	1.053	1.243
Variační rozpětí	18.870	23.137	8.853	11.888	38.027
Dolní kvartil	-0.200	-0.263	-0.770	-0.378	-0.231
Horní kvartil	-0.092	-0.004	0.695	0.591	0.234

Tabulka 8 Popisné statistiky pro testovací množinu dat. Zdroj: [Vlastní]

	K1	K2	K3	K4	K5
Rozsah souboru	649	649	649	649	649
Minimum	-0.304	-5.855	-1.768	-3.602	-11.358
Maximum	18.157	10.268	2.338	2.230	2.401
Průměr	-0.040	-0.005	0.058	0.045	-0.051
Medián	-0.158	-0.119	0.533	0.361	0.039
Směrodatná odchylka	0.858	0.905	0.962	0.931	0.630
Součet	-25.722	-3.539	37.935	29.397	-32.870
Chyba střední hodnoty	0.034	0.036	0.038	0.037	0.025
Rozptyl	0.737	0.819	0.925	0.866	0.396
Variační rozpětí	18.462	16.123	4.107	5.832	13.759
Dolní kvartil	-0.197	-0.220	-0.762	-0.319	-0.207
Horní kvartil	-0.100	-0.019	0.695	0.599	0.242

5.2 Návrh RBF neuronové sítě

Jelikož RBF neuronové sítě sestávají z jedné skryté a jedné výstupní vrstvy, jsou navrhovány jen počty neuronů ve skryté vrstvě. Topologie neuronové sítě RBF s 5 vstupy a 140 neurony ve skryté vrstvě je zobrazena na obrázku 12. Dále je třeba nastavit parametry učení RBF neuronové sítě ovlivňujících přesnost predikce, kterými jsou: počet cyklů učení, moment alfa a překrytí vrstev.



Obrázek 12 Návrh struktury neuronové sítě RBF. Zdroj: [Vlastní]


5.2.1 Počet neuronů ve skryté vrstvě

Určení počtu neuronů ve skryté vrstvě patří mezi nejobtížnější části návrhu struktury RBF neuronové sítě. Výsledný počet RBF neuronů je dán experimentálně a byl prováděn za shodných podmínek všech zbývajících parametrů. Přesnost predikce je vyjádřena pomocí střední absolutní odchylky MAE.

Průběh chyby v závislosti na počtu neuronů ve skryté vrstvě zobrazuje tabulka 9. Grafické znázornění průběhu chyby je na obrázku 13.

Tabulka 9 Průběh chyby v závislosti na počtu neuronů ve skryté vrstvě. Zdroj: [Vlastní]

Počet neuronů	Počet cyklů	Alpha	Překrytí	MAE - trénovací	MAE - testovací	MAE - celková
50	500	0,95	1	6 688 260	6 714 284	6 695 750
100	500	0,95	1	6 050 322	7 045 606	6 336 769
130	500	0,95	1	5 511 518	6 698 427	5 853 116
140	500	0,95	1	5 331 287	6 603 668	5 697 484
150	500	0,95	1	5 221 962	6 648 399	5 632 498
200	500	0,95	1	4 977 476	6 930 000	5 539 422
300	500	0,95	1	4 189 010	7 052 360	5 013 096
500	500	0,95	1	3 819 286	9 474 254	5 446 813
750	500	0,95	1	3 269 558	10 637 470	5 390 079
900	500	0,95	1	3 020 199	11 592 758	5 487 423
1000	500	0,95	1	2 891 704	11 862 495	5 473 542
1200	500	0,95	1	2 468 926	12 295 636	5 297 101



Obrázek 13 Vliv počtu neuronů ve skryté vrstvě na výslednou chybu. Zdroj: [Vlastní]


Z grafu i tabulky je patrné, že s růstem počtu RBF neuronů klesá chyba na trénovací množině dat. Chyba na testovací množině dat klesá až do počtu 140 neuronů a poté dochází k růstu chyby. Na základě těchto výsledků bylo zvoleno pro další postup 140 neuronů ve skryté vrstvě.

5.2.2 Nastavení počtu cyklů

S rostoucím počtem cyklů učení neuronové sítě vzrůstá přesnost modelu. Zvyšováním počtu cyklů dochází k přetrénování a přesnost modelu klesá. Naopak v případě, že je počet cyklů učení příliš malý, neuronová síť není dobře natrénovaná a přesnost je opět malá. Průběh chyby při nastavení tohoto parametru zobrazuje tabulka 10 a obrázek 14. Chyba neuronové sítě pro trénovací množinu s rostoucím počtem cyklů klesá. Chyba pro testovací množinu dat klesá až ke svému minimu. Tohoto minima je dosaženo při 5600 cyklech.

Tabulka 10 Průběh chyby v závislosti na počtu cyklů. Zdroj: [Vlastní]

Počet neuronů	Počet cyklů	Alpha	Překrytí	MAE - trénovací	MAE - testovací	MAE - celková
140	100	0,95	1	8 354 174	9 220 950	8 603 636
140	300	0,95	1	6 165 654	7 308 991	6 494 712
140	500	0,95	1	5 331 287	6 603 668	5 697 484
140	700	0,95	1	4 771 166	6 120 509	5 159 514
140	1000	0,95	1	4 175 627	5 577 747	4 579 164
140	3000	0,95	1	2 691 629	4 413 746	3 187 263
140	5000	0,95	1	2 395 676	4 321 425	2 949 916
140	5500	0,95	1	2 368 921	4 320 155	2 930 495
140	5600	0,95	1	2 364 611	4 320 068	2 927 401
140	5700	0,95	1	2 360 630	4 320 088	2 924 571
140	7000	0,95	1	2 326 068	4 325 968	2 901 649
140	10000	0,95	1	2 302 907	4 339 987	2 889 188




Obrázek 14 Vliv počtu cyklů na výslednou chybu. Zdroj: [Vlastní]

5.2.3 Nastavení momentu

Během procesu učení neuronové sítě dochází k poklesu chyby až do okamžiku dosažení lokálního minima. V tomto lokálním extrému je proces učení zastaven. Vložení momentu do algoritmu učení dojde k překročení lokálního extrému a proces učení pokračuje dále. Výhodou může být dosažení nižší chyby. V programovém prostředí Clementine je tento parametr označován jako „Alpha“. Průběh chyby při měnícím se nastavení tohoto parametru zobrazuje obrázek 15 a hodnoty jsou zaznamenány v tabulce 11. Se zvyšující hodnotou tohoto parametru chyba tohoto modelu klesá.

Tabulka 11 Vliv momentu na výslednou chybu. Zdroj: [Vlastní]

Počet neuronů	Počet cyklů	Alpha	Překrytí	MAE - trénovací	MAE - testovací	MAE - celková
140	5600	0,30	1	5 693 513	6 908 670	6 043 241
140	5600	0,50	1	5 140 451	6 442 599	5 515 215
140	5600	0,70	1	4 288 400	5 681 387	4 689 309
140	5600	0,90	1	2 755 679	4 442 629	3 241 192
140	5600	0,95	1	2 364 611	4 320 068	2 927 401
140	5600	0,99	1	2 297 556	4 347 219	2 887 459



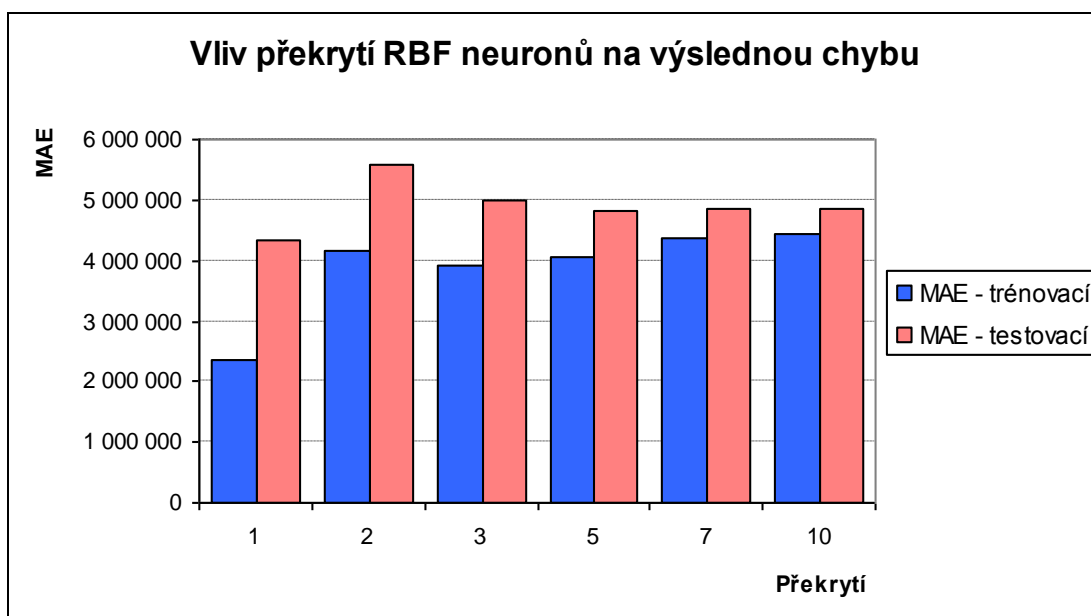
Obrázek 15 Vliv momentu na výslednou chybu. Zdroj: [Vlastní]

5.2.4 Překryv radiálně bazických funkcí

Tento parametr umožňuje nastavení, kolik oblastí či shluků se má překrývat. Vliv tohoto parametru na absolutní odchylku zobrazuje obrázek 16 a hodnoty jsou zaznamenány v tabulce 12. Se zvyšující se hodnotou tohoto parametru dochází ke zvyšování chyby navrženého modelu. V případě této struktury RBF sítě dochází k nejnižší chybě v případě, kdy je nastaveno překrytí na 1, což zároveň znamená, že se shluky nepřekrývají.

Tabulka 12 Vliv překrytí RBF neuronů na průběh chyby. Zdroj: [Vlastní]

Počet neuronů	Počet cyklů	Alpha	Překrytí	MAE - trénovací	MAE - testovací	MAE - celková
140	5600	0,95	1	2 364 611	4 320 068	2 927 401
140	5600	0,95	2	4 157 096	5 584 800	4 567 996
140	5600	0,95	3	3 929 847	4 977 707	4 231 426
140	5600	0,95	5	4 045 450	4 823 823	4 269 469
140	5600	0,95	7	4 352 653	4 867 211	4 500 745
140	5600	0,95	10	4 448 157	4 842 746	4 561 721




Obrázek 16 Vliv překrytí RBF neuronů na výslednou chybu. Zdroj: [Vlastní]

5.3 Návrh struktury dopředné neuronové sítě


Počet neuronů ve vstupní a výstupní vrstvě odpovídá počtu vstupních a výstupních parametrů. Proto má tato dopředná neuronová síť ve vstupní vrstvě pět neuronů a na výstupu je jeden neuron. Návrh topologie tedy spočívá v návrhu počtu skrytých vrstev a počtu neuronů ve skrytých vrstvách. Navrhnutá topologie dopředné neuronové sítě má jednu skrytou vrstvu a počet neuronů ve skryté vrstvě N_H je zvolen na $N_I - 1$, tj. $N_H = 4$. Topologie dopředné neuronové sítě s jednou skrytou vrstvou, kde N_I jsou vstupní neurony a N_O je výstup, je zobrazena na obrázku 17.

V procesu učení dopředné neuronové sítě se využívá učící algoritmus zpětného šíření chyby, který byl podrobně definován v kapitole 2. Tento algoritmus se skládá ze tří hlavních fází. V první fázi se vstupní signál učícího vzoru dopředně šíří přes všechny vrstvy neuronové sítě. Výstup z neuronové sítě, tj. predikovaná hodnota, se porovnává se skutečnou hodnotou. Ve druhé fázi se chyba, tj. rozdíl mezi těmito hodnotami, zpětně šíří. V poslední fázi se upravují hodnoty vah synapsí tak, aby došlo k minimalizaci chyby neuronové sítě.

Zobrazení absolutní chyby během trénování a testování dopředné neuronové sítě je uvedeno na obrázku 18.



Obrázek 17 Návrh topologie dopředné neuronové sítě. Zdroj: [Vlastní]



Obrázek 18 Průběh chyby během trénování a testování dopředné neuronové sítě. Zdroj: [Vlastní]

V následující tabulce 13 je zobrazen průběh chyby a nastavení dalších parametrů ovlivňujících výslednou chybu dopředné neuronové sítě. Nejprve je zvolen moment „Alpha“, jehož hodnota je nastavena na 0,95. Při tomto nastavení momentu vychází chyba testovacích dat nejnižší.

Rychlost učení dopředné neuronové sítě určuje parametr eta, který byl u neuronové sítě typu RBF zvolen automaticky. Nyní je však vyžadováno nastavení tzv. počátečního „Initial Eta“, které se mění na hodnotu tzv. „Low Eta“, z ní pak dále na hodnotu tzv. „High Eta“ a znovu klesá na hodnotu „Low Eta“. Tyto dva poslední kroky se opakují dokud není trénování sítě ukončeno.

Tabulka 13 Průběh chyby a nastavení parametrů dopředné neuronové sítě. Zdroj: [Vlastní]

Topologie	Počet cyklů	Alpha	Initial Eta	High Eta	Low Eta	MAE - trénovací	MAE - testovací	MAE - celková
(5 - 4 - 1)	100	0,95	0,25	0,9	0,51	9 731 417	9 995 651	9 807 465
(5 - 4 - 1)	300	0,95	0,25	0,9	0,51	8 060 473	8 728 465	8 252 724
(5 - 4 - 1)	500	0,95	0,25	0,9	0,51	6 403 952	7 009 416	6 578 207
(5 - 4 - 1)	700	0,95	0,25	0,9	0,51	6 079 731	6 698 159	6 257 717
(5 - 4 - 1)	1000	0,95	0,25	0,9	0,51	5 441 124	6 120 440	5 636 635
(5 - 4 - 1)	1500	0,95	0,25	0,9	0,51	5 017 916	5 719 623	5 219 871
(5 - 4 - 1)	3000	0,95	0,25	0,9	0,51	4 576 907	5 296 975	4 784 146
(5 - 4 - 1)	5000	0,95	0,25	0,9	0,51	4 307 614	4 995 749	4 505 663
(5 - 4 - 1)	5200	0,95	0,25	0,9	0,51	3 927 540	4 657 377	4 137 591
(5 - 4 - 1)	5300	0,95	0,25	0,9	0,51	4 098 255	4 826 222	4 307 768
(5 - 4 - 1)	5400	0,95	0,25	0,9	0,51	4 284 186	5 005 823	4 491 877
(5 - 4 - 1)	5500	0,95	0,25	0,9	0,51	4 264 835	5 024 793	4 483 555

5.4 Analýza výsledků navržených struktur

Oba navržené modely neuronových sítí byly trénovány a testovány na stejných datech. Tyto typy neuronových sítí se v mnohém liší. Jiné typy neuronů ve skryté vrstvě, uspořádání vrstev i jejich počet vyžadují využití odlišných postupů při návrhu těchto neuronových sítí.

RBF neuronové sítě a dopředné neuronové sítě jsou nejčastěji používanými modely neuronových sítí. V literatuře [12] bylo prokázáno, že oba tyto modely neuronových sítí pracují jako univerzální aproximátory, tj. s dostatečným počtem neuronů ve skryté vrstvě jsou schopné aproximovat jakoukoliv spojitou funkci. Rozdíl mezi nimi je založen na použití radiální báze funkce jako aktivační funkce neuronů ve skryté vrstvě. To umožňuje jednak rychlejší naučení RBF neuronové sítě [11] a také konvergenci sítě ke globálnímu minimu v průběhu učení. Oproti tomu, algoritmus učení (zpětné šíření chyby [6]) dopředné neuronové

sítě je potřeba doplnit např. momentem právě z toho důvodu, že u této neuronové sítě hrozí uvíznutí v lokálním minimu.

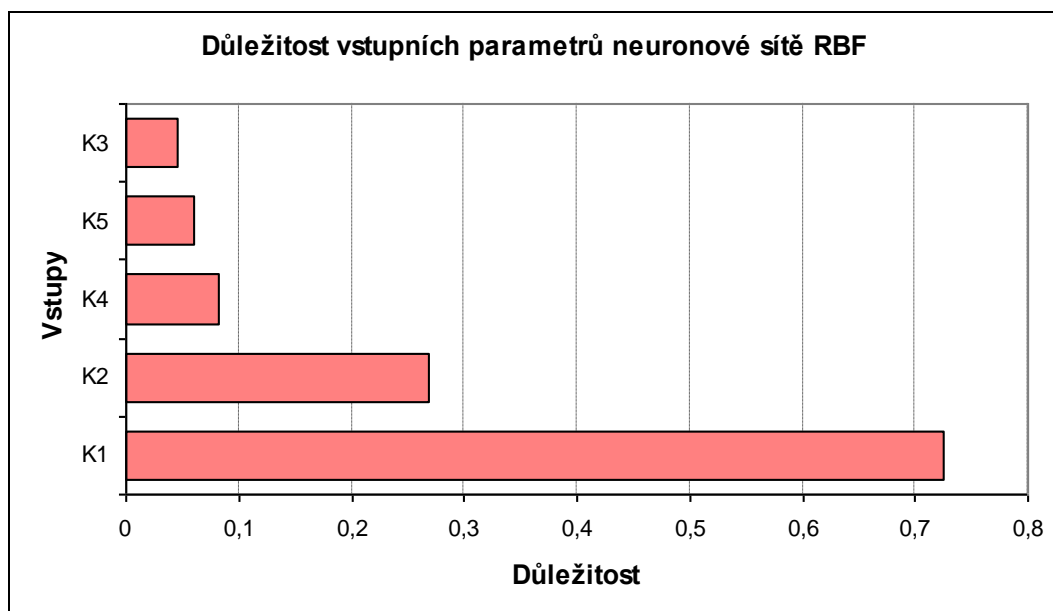
5.4.1 Výsledné nastavení parametrů neuronové sítě typu RBF

Optimální nastavení parametrů sítě typu RBF je uvedeno v tabulce 14. Nejnižší absolutní chyba byla dosažena při nastavení počtu 140 neuronů ve skryté vrstvě, počtu 5600 cyklů, momentu alpha na 0,95 a překrytí 1 (tzn. žádné vrstvy se nepřekrývají).

Tabulka 14 Výsledné nastavení parametrů neuronové sítě typu RBF. Zdroj: [Vlastní]

Počet neuronů	Počet cyklů	Alpha	Překrytí	MAE - trénovací	MAE - testovací	MAE - celková
140	5600	0,95	1	2 364 611	4 320 068	2 927 401

Na obrázku 19 je graficky zobrazena relativní důležitost vstupních proměnných, která je určena analýzou citlivosti. Vstupní proměnné jsou uvedeny v pořadí od nejméně důležitých k nejvýznamnějším. Hodnota uvedená pro každý vstup je míra jeho relativní významnosti, která se pohybuje mezi 0 (vstupní parametr, který nemá žádný vliv na predikci) a 1 (vstupní parametr, který zcela určuje predikci). Tedy největší vliv na predikci má parametr K1 a nejméně se na celkovém výstupu podílí parametr K3.



Obrázek 19 Relativní důležitost vstupních proměnných neuronové sítě typu RBF. Zdroj: [Vlastní]


5.4.2 Výsledné nastavení parametrů dopředné neuronové sítě

Výsledné nastavení parametrů dopředné neuronové sítě zobrazuje tabulka 15. Optimální nastavení této sítě obsahuje 4 neurony ve skryté vrstvě; 5200 cyklů; moment alpha je roven 0,95; počáteční rychlost (Initial Eta) je 0,25 a rychlost High Eta je 0,9. Při tomto nastavení parametrů je dosaženo nejnižší chyby u tohoto typu sítě.

Tabulka 15 Výsledné nastavení parametrů dopředné neuronové sítě. Zdroj: [Vlastní]

Topologie	Počet cyklů	Alpha	Initial Eta	High Eta	MAE - trénovací	MAE - testovací	MAE - celková
(5 - 4 - 1)	5200	0,95	0,25	0,9	3 927 540	4 657 377	4 137 591

Následující obrázek 20 zobrazuje relativní důležitost vstupních proměnných na celkový výstup. Stejně jako u neuronové sítě RBF má největší vliv na predikci parametr K1 a nejmenší důležitost má parametr K3. Na rozdíl od RBF neuronové sítě je parametr K1 důležitějším prediktorem a ostatní parametry jsou méně významné.



Obrázek 20 Relativní důležitost vstupních proměnných dopředné neuronové sítě. Zdroj: [Vlastní]

5.4.3 Výsledný model neuronové sítě pro predikci finančních toků obcí

Na základě analýz a poznatků navržených struktur sítě typu RBF a MLP bylo dosaženo výsledného nastavení. Jako nejvhodnější model pro predikci finančních toků obcí byla

vybrána navržená struktura neuronové sítě typu RBF, jelikož dosahuje nižší chyby predikce na testovacích datech oproti dopředné neuronové síti. Minimální chyba vyjádřená střední absolutní odchylkou má hodnotu 2 364 611 pro trénovací množinu dat a 4 320 068 pro testovací množinu dat. Výsledky obou modelů neuronových sítí zobrazuje tabulka 16.

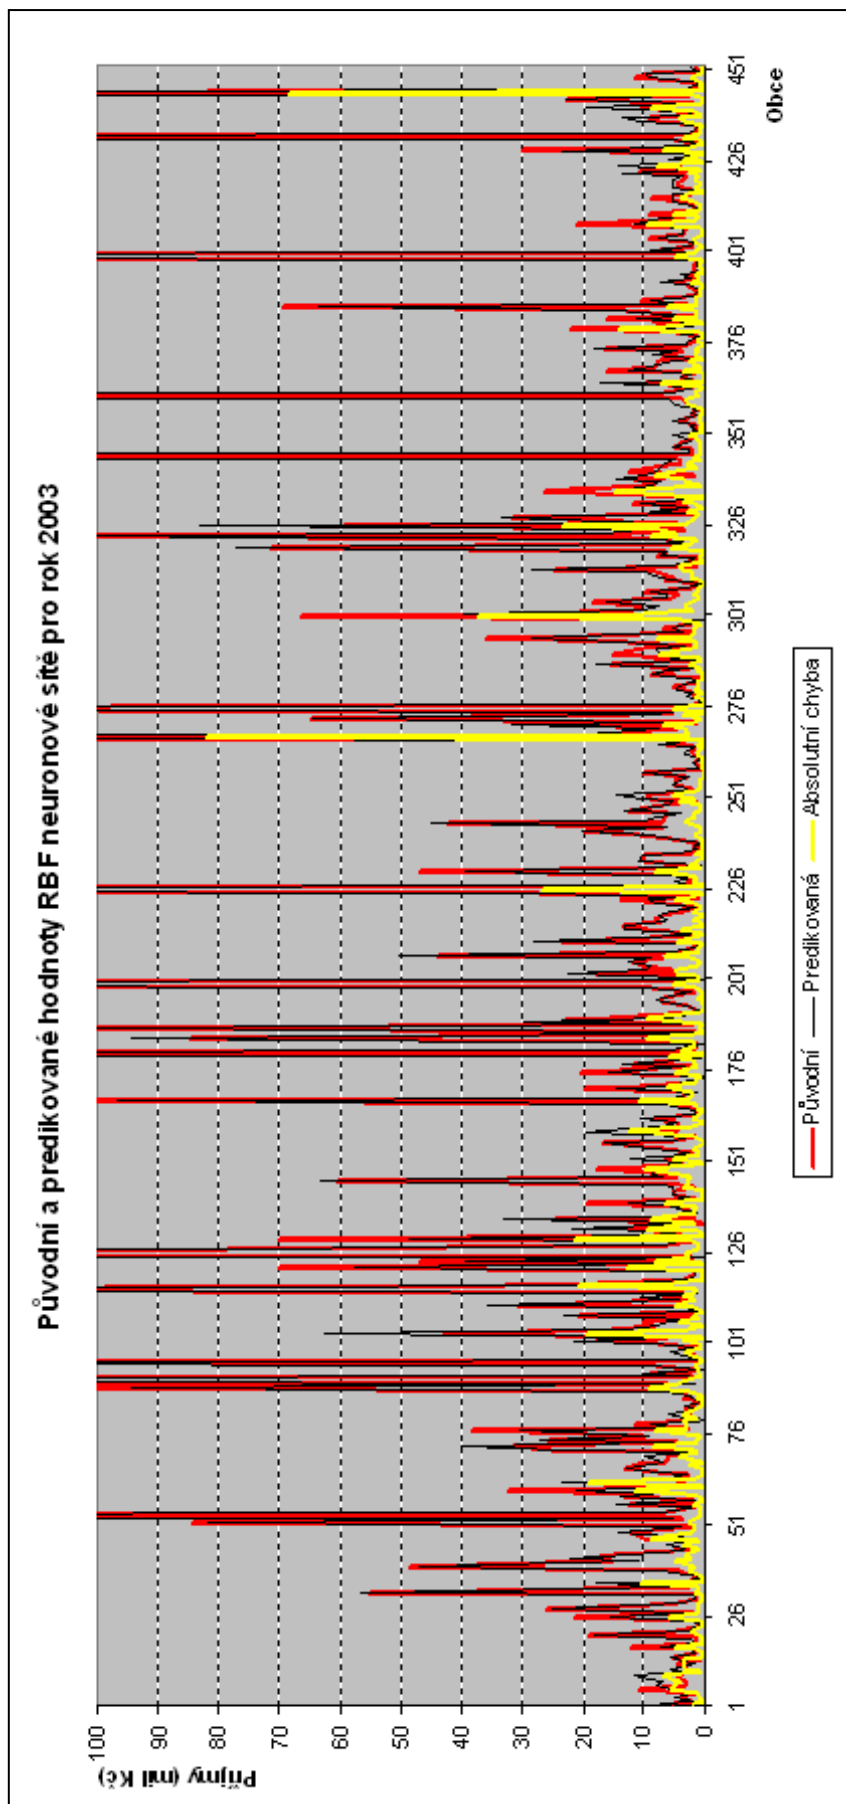
Tabulka 16 Výsledky predikce navržených struktur dopředných neuronových sítí. Zdroj: [Vlastní]

Typ neuronové sítě	MAE - trénovací	MAE - testovací	MAE - celková
RBF	2 364 611	4 320 068	2 927 401
Dopředná neuronová síť	3 927 540	4 657 377	4 137 591

Průběh původních a predikovaných hodnot pro jednotlivé obce v roce 2003 zobrazuje obrázek 20. Graf navíc zobrazuje průběh absolutní odchylky MAE. Grafické ilustrace průběhu původních a predikovaných hodnot pomocí RBF neuronové sítě pro další roky jsou obsaženy v příloze D, E, F, G.

5.5 Dílčí závěry

V kapitole byly navrženy různé topologie a parametry učení pro RBF neuronové sítě a dopředné neuronové sítě. Výsledky ukázaly, že pro predikci finančních toků obcí (celkových příjmů) jsou vhodnější RBF neuronové sítě. Kvalita predikce byla měřena pomocí střední absolutní odchylky MAE na trénovacích a testovacích datech. Dále byla provedena citlivostní analýza výsledků. Takto byla určena relativní důležitost vstupních parametrů (proměnných) na predikovaný výstup.



Obrázek 21 Průběh původních a predikovaných hodnot RBF neuronové sítě pro rok 2003. Zdroj: [Vlastní]

Závěr

Cílem diplomové práce bylo navrhnout vhodný model pro predikci finančních toků obcí založený na neuronových sítích. Pro proces učení neuronové sítě byla použita data o příjmech obcí Pardubického kraje v letech 2003-2008. Tato data slouží jako vstup do navrhovaných struktur neuronové sítě typu RBF a dopředné neuronové sítě. Data bylo nutné nejprve předzpracovat a rozdělit na trénovací a testovací množinu. Z důvodu vysokých korelací mezi sledovanými parametry byla provedena analýza hlavních komponent. Testování a analýza navržených modelů byla provedena v programovém prostředí SPSS Clementine 10.1.

Úvodní část práce je věnována problematice rozpočtů obcí, členění příjmů a výdajů a jsou zde definovány faktory ovlivňující finanční toky obcí. Dále jsou uvedeny základní pojmy z teorie dopředných neuronových sítí a charakterizována neuronová síť typu RBF. Další část práce se zabývá návrhem modelu pro predikci finančních toků obcí.

Návrh modelu se skládá z několika dílčích kroků, tj. návrhu vstupních parametrů a návrhu neuronových sítí. Návrh a testování modelu neuronové sítě spočíval ve zvolení vhodné topologie a parametrů učení neuronových sítí, ovlivňujících kvalitu jejich predikce. Kvalita navržených modelů byla hodnocena pomocí průměrné absolutní odchylky. Na základě analýzy výsledků byla stanovena nejvhodnější struktura neuronové sítě pro predikci finančních toků obcí.

Nejlépeším analyzovaným modelem pro predikci finančních toků obcí se stal model neuronové sítě typu RBF, v jehož výsledném nastavení parametrů bylo dosaženo nejnižší absolutní chyby. Výsledný model obsahoval 5 neuronů ve vstupní vrstvě, 140 neuronů ve vrstvě skryté a 1 výstupní neuron.

V práci byl navržen model pro predikci finančních toků obcí. Na základě modelování a analýzy dosažených výsledků byla navržena RBF neuronová síť s optimální topologií a nastavením parametrů učení. Z analýzy výsledků dále vyplynulo, že klíčovými parametry pro predikci příjmů obcí jsou parametry obsažené v komponentě, která byla označena jako „daně a majetek“. Tím byly cíle práce stanovené v úvodu práce splněny.

Seznam použité literatury

- [1] BOUŠKA, J. *Neuronové sítě pro predikci časových řad* [online]. [s.l.], 2008. 83 s. Diplomová práce. České vysoké učení technické v Praze Fakulta elektrotechnická. Dostupné z WWW: <https://dip.felk.cvut.cz/browse/pdfcache/bouskj1_2008dipl.pdf>.
- [2] DRÁBEK, O., SEIDEL, P., TAUFER, I. *Umělé neuronové sítě - Základy teorie a aplikace (4)* [online]. Chemagazín: 2006, č.2, [cit. 2010-04-11]. Dostupný z WWW: <http://www.chemagazin.cz/Texty/CHXVI_2_cl9.pdf>.
- [3] DRÁBEK, O., SEIDEL, P., TAUFER, I. *Umělé neuronové sítě - Základy teorie a aplikace (5)* [online]. Chemagazín: 2006, č.5, [cit. 2010-04-11]. Dostupný z WWW: <http://www.chemagazin.cz/Texty/CHXVI_5_cl6.pdf>.
- [4] FABUŠ, M. *RBF neuronové sítě a genetické algoritmy* [online]. 1998. 52 s. Diplomová práce. Univerzita Komenského v Bratislavě, Fakulta matematiky, fyziky a informatiky. Dostupné z WWW: <<http://diplomovka.sme.sk/zdroj/2522.pdf>>.
- [5] GIROSI, F., NIYOGLI, P. *On the Relationship Between Generalization Error, Hypothesis Complexity, and Sample Complexity for Radial Basis Functions* [online]. 1994 [cit. 2010-04-11]. Dostupný z WWW: <<ftp://publications.ai.mit.edu/ai-publications/pdf/AIM-1467.pdf>>.
- [6] HAYKIN, S. *Neural networks : a comprehensive foundation*. 2nd edition. Upper Saddle River : Prentice Hall, 1999. 842 s. ISBN 0-13-273350-1.
- [7] KOKEŠ, R. *Modelování bonity obcí pomocí RBF neuronových sítí (predikční modely)*. [s.l.], 2008. 63 s. Diplomová práce. Univerzita Pardubice, Fakulta ekonomicko správní.
- [8] KVASNICKA, V. a kol. *Úvod do teórie neuronových sietí*. Bratislava: IRIS, 1997. 285 s. ISBN 80- 88778-30-1.
- [9] MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. *Umělá inteligence (4)*. Praha : Academia, 1993. 475 s. ISBN 978-80-200-1470-2.
- [10] MELOUN, M., MILITKÝ, J. *Statistická analýza experimentálních dat*. Praha : Academia, 2004. 953 s. ISBN 80-200-1254-0.
- [11] MOODY, J., DARKEN, C.J. *Fast learning in networks of locally-tuned processing units*. [online]. *Neural Computation* 1(2): 1989, [cit. 2010-04-15]. Dostupný z WWW: <<http://www.mitpressjournals.org/doi/abs/10.1162/neco.1989.1.2.281>>.

- [12] PARK, J., SANDBERG, I.W. *Universal Approximation Using Radial-Basis-Function Networks* [online]. *Neural Computation* 3(2): 1991, [cit. 2010-04-15]. Dostupný z WWW: <<http://www.mitpressjournals.org/doi/abs/10.1162/neco.1991.3.2.246>>.
- [13] PEKOVÁ, J. *Veřejné finance: úvod do problematiky*. Praha: ASPI, 2005. 527 s. ISBN 80-7357-049-1.
- [14] PODHORSKÝ, J. *Účtování a vedení účetnictví v organizačních složkách státu, územních samosprávných celcích a příspěvkových organizacích: metodika účetnictví, vzorové příklady, účetní závěrka, kontrola účetnictví*. [s.l.] : POLYGON, 2005. 363 s. ISBN 80-7273-119-X.
- [15] PROVAZNÍKOVÁ, R. *Financování měst, obcí a regionů*. Praha : Grada, 2007. 280 s. ISBN 978-80-247-2097-5.
- [16] REDDICK, C. G. *Assessing Local Government Revenue Forecasting Techniques* [online]. *INTERNATIONAL JOURNAL OF PUBLIC ADMINISTRATION* : 2004 [cit. 2010-02-15]. Dostupný z WWW: <<http://direct.bl.uk/bld/PlaceOrder.do?UIN=156217360&ETOC=RN&from=searchengine>>. ISSN 0190-0692.
- [17] REKTOŘÍK, J., ŠELEŠOVSKÝ, J. a kol. *Jak řídit kraj, město, obec*. Masarykova univerzita v Brně, 2002. ISBN 80-210-2966-5.
- [18] SWANSON, CHRISTOPHER, J. *Long-term financial forecasting for local governments*. *Government Finance Review* [online]. 2008 [cit. 2010-02-15]. Dostupný z WWW: <<http://www.thefreelibrary.com/Long+term+financial+forecasting+for+local+governments.-a0188999557>>.
- [19] ŠÍMA, J., NERUDA, R. *Teoretické otázky neuronových sítí* [online]. 1996 [cit. 2010-02-12]. Dostupný z WWW: <<http://www2.cs.cas.cz/~sima/kniha.pdf>>.
- [20] TOPUZ, T. *Quality assessment of data-based metamodels for multi-objective aeronautic design optimisation* [online]. 2007 [cit. 2010-04-11]. Dostupný z WWW: <http://www.few.vu.nl/en/Images/stageverslag-topuz_tcm39-90709.pdf>.
- [21] VOMOČIL, M., HÁJEK, P., OLEJ, V. *Modelování bonity obcí pomocí dopředných neuronových sítí*. [online]. [cit. 2010-04-19]. Dostupný z WWW: <<http://library.upce.cz/Sources/CL659.pdf>>. ISSN 1211-555X.
- [22] Vyhláška Ministerstva financí č. 323/2002 Sb. o rozpočtové skladbě ve znění pozdějších předpisů

[23] Zákon č. 250/2000 Sb. o rozpočtových pravidlech územních rozpočtů ve znění pozdějších předpisů

[24] Zákon č. 128/2000 Sb., o obcích (obecních zřízeních), ve znění pozdějších předpisů

Seznam obrázků

Obrázek 1 Fáze rozpočtového procesu	14
Obrázek 2 Členění majetku	19
Obrázek 3 Formální neuron	25
Obrázek 4 Příklad acyklické (vlevo) a cyklické (vpravo) architektury	26
Obrázek 5 Dopředná neuronová síť	27
Obrázek 6 Grafy jednorozměrných radiálních funkcí	32
Obrázek 7 Graf RBF neuronové sítě	33
Obrázek 8 Vliv množství vstupních dat a počtu RBF neuronů na trénovací chybu	35
Obrázek 9 Vliv počtu RBF neuronů na zevšeobecnující (testovací a validační) chybu	35
Obrázek 10 Návrh modelu pro predikci finančních toků obcí	42
Obrázek 11 Podíl komponent na celkovém rozptylu	50
Obrázek 12 Návrh struktury neuronové sítě RBF	55
Obrázek 13 Vliv počtu neuronů ve skryté vrstvě na výslednou chybu	56
Obrázek 14 Vliv počtu cyklů na výslednou chybu	57
Obrázek 15 Vliv momentu na výslednou chybu	58
Obrázek 16 Vliv překrytí RBF neuronů na výslednou chybu	59
Obrázek 17 Návrh topologie dopředné neuronové sítě	60
Obrázek 18 Průběh chyby během trénování a testování dopředné neuronové sítě	60
Obrázek 19 Relativní důležitost vstupních proměnných neuronové sítě typu RBF	62
Obrázek 20 Relativní důležitost vstupních proměnných dopředné neuronové sítě	63
Obrázek 21 Průběh původních a predikovaných hodnot RBF neuronové sítě pro rok 2003 ..	64

Seznam tabulek

Tabulka 1 Druhové rozdělení příjmů	16
Tabulka 2 Druhové rozdělení výdajů	17
Tabulka 3 Datový slovník	44
Tabulka 4 Korelační matice pro parametry P1 až P12	48
Tabulka 5 Podíl jednotlivých komponent na celkovém rozptylu	49
Tabulka 6 Váhy jednotlivých komponent	50
Tabulka 7 Popisné statistiky pro trénování množinu dat	54
Tabulka 8 Popisné statistiky pro testovací množinu dat	54
Tabulka 9 Průběh chyby v závislosti na počtu neuronů ve skryté vrstvě	55
Tabulka 10 Průběh chyby v závislosti na počtu cyklů	57
Tabulka 11 Vliv momentu na výslednou chybu	58
Tabulka 12 Vliv překrytí RBF neuronů na průběh chyby	58
Tabulka 13 Průběh chyby a nastavení parametrů dopředné neuronové sítě	61
Tabulka 14 Výsledné nastavení parametrů neuronové sítě typu RBF	62
Tabulka 15 Výsledné nastavení parametrů dopředné neuronové sítě	63
Tabulka 16 Výsledky predikce navržených struktur dopředných neuronových sítí	64

Seznam příloh

Příloha A - Popisné statistiky vstupní množiny dat

Příloha B - Koeficienty korelace vstupní množiny dat

Příloha C - Podíl jednotlivých komponent na celkovém rozptylu

Příloha D - Původní a predikované hodnoty RBF neuronové sítě pro rok 2004

Příloha E - Původní a predikované hodnoty RBF neuronové sítě pro rok 2005

Příloha F - Původní a predikované hodnoty RBF neuronové sítě pro rok 2006

Příloha G - Původní a predikované hodnoty RBF neuronové sítě pro rok 2007

Přílohy

Příloha A Popisné statistiky vstupní množiny dat. Zdroj: [Vlastní]

	Maximum	Minimum	Průměr	Medián	Směrodatná odchylka	Úhrn	Chyba střední hodnoty	Rozptyl	Variační rozpětí	Dolní kvartil	Horní kvartil
P1	89245,00	23,00	1124,17	340,00	4686,80	2534996,00	98,70	21966066,16	89222,00	195,00	748,50
P2	0,85	0,42	0,57	0,59	0,05	1277,98	0,00	0,00	0,43	0,54	0,59
P3	0,07	0,04	0,05	0,06	0,01	123,12	0,00	0,00	0,03	0,05	0,06
P4	22481,00	5,00	230,63	65,00	1128,51	520078,00	23,76	1273524,98	22476,00	35,00	132,00
P5	213400977,7	17800,60	1813481,47	469598,00	9530746,55	4089400710	200702,90	9,08351E+13	213383177,1	244301,35	1005904,00
P6	83489499,30	-34876,38	712947,00	128444,40	3731031,03	1606982534	78587,22	1,39206E+13	83524375,68	48919,00	328920,61
P7	12840889,81	0,00	106266,35	28386,00	562725,62	239630613,78	11850,14	3,1666E+11	12840889,81	13462,00	62609,29
P8	233139006,7	4226,00	1947483,26	513428,00	10156084,56	4391574752	213871,56	1,03146E+14	233134780,7	275052,07	1127938,90
P9	56850980,00	0,00	422947,10	0,00	2430280,35	953745707,00	51177,98	5,90626E+12	56850980,00	0,00	28044,00
P10	334119224	0,00	2824631,25	757773,00	14631053,80	6369543471	308107,55	2,14068E+14	334119224	401635,00	1635502,00
P11	113395407,4	0,00	1127603,59	139425,00	5776354,64	2542746106	121641,17	3,33663E+13	113395407,4	64455,00	319577,00
P12	43376407,00	0,00	590741,46	252608,00	2140670,64	1332121982	45079,24	4,58247E+12	43376407,00	145059,50	449374,64
P13	79033546,95	0,00	691051,40	143839,00	3561061,60	1558320901	74990,49	1,26812E+13	79033546,95	38578,80	360853,00
P14	9767215125	844029,30	97479805,86	22139144,75	451168466,5	2,19817E+11	9500915,70	2,03553E+17	9766371096	9899748,87	49935148,53
P15	1451128122	0,00	11177475,48	626000,00	72913010,65	25205207215	1535436,14	5,31631E+15	1451128122	52000,00	2688000,00
P16	26517841,95	0,00	624876,30	113282,00	2084368,70	1409096063	43893,61	4,34459E+12	26517841,95	23596,89	401549,00
P17	38481731,53	0,00	727486,04	66652,00	2838834,92	1640481015	59781,51	8,05898E+12	38481731,53	17694,50	243079,15
P18	7464716,91	0,00	97028,52	19330,57	415742,29	218799306,87	8754,89	1,72842E+11	7464716,91	6512,98	51375,76
P19	2766637,66	0,00	11119,79	0,00	82139,40	25075133,34	1729,73	6746881818	2766637,66	0,00	445,00
P20	176909121,5	0,00	1192924,53	26331,00	7013373,99	2690044821	147690,90	4,91874E+13	176909121,5	0,00	256225,00
P21	11814,00	1,00	171,18	55,00	637,17	386005,00	13,42	405991,70	11813,00	29,00	124,00
P22	3552742792	549,00	26019190,00	318965,00	179611942,8	58673273445	3782351,95	3,22604E+16	3552742243	118063,50	1635889,00
P23	102636926,6	0,00	2047989,28	50000,00	6968154,50	4618215833	146738,64	4,85552E+13	102636926,6	0,00	390000,00
V	1864708728	283943,01	20940600,88	4234475,50	93139725,06	47221054983	1961379,71	8,67501E+15	1864424785	2030283,23	9959805,17


Příloha B Koeficienty korelace vstupní množiny dat. Zdroj: [Vlastní]


	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15	P16	P17	P18	P19	P20	P21	P22	P23
P1	1	0,469	0,001	0,997	0,992	0,956	0,982	0,990	0,870	0,989	0,944	0,984	0,959	0,982	0,947	0,613	0,579	0,836	0,561	0,885	0,997	0,984	0,467
P2	0,469	1	0,007	0,442	0,435	0,439	0,427	0,434	0,427	0,435	0,430	0,449	0,437	0,456	0,417	0,397	0,437	0,428	0,239	0,393	0,489	0,437	0,374
P3	0,001	0,007	1	0,003	0,013	-0,012	0,010	0,018	0,012	0,018	0,017	0,002	0,026	0,015	0,016	-0,007	0,014	0,007	-0,048	0,019	-0,004	-0,011	0,014
P4	0,997	0,442	0,003	1	0,995	0,954	0,988	0,993	0,857	0,992	0,945	0,988	0,955	0,982	0,943	0,597	0,546	0,825	0,559	0,880	0,989	0,982	0,434
P5	0,992	0,435	0,013	0,995	1	0,939	0,991	1,000	0,856	0,991	0,945	0,986	0,961	0,983	0,947	0,586	0,536	0,818	0,516	0,873	0,982	0,973	0,434
P6	0,956	0,439	-0,012	0,954	0,939	1	0,923	0,932	0,827	0,944	0,892	0,947	0,935	0,928	0,910	0,622	0,601	0,802	0,583	0,895	0,957	0,957	0,428
P7	0,982	0,427	0,010	0,988	0,991	0,923	1	0,990	0,842	0,977	0,937	0,981	0,950	0,976	0,927	0,586	0,526	0,803	0,534	0,844	0,970	0,967	0,419
P8	0,990	0,434	0,018	0,993	1,000	0,932	0,990	1	0,854	0,990	0,944	0,984	0,960	0,983	0,946	0,583	0,533	0,815	0,502	0,868	0,978	0,970	0,432
P9	0,870	0,427	0,012	0,857	0,856	0,827	0,842	0,854	1	0,863	0,826	0,864	0,869	0,899	0,813	0,735	0,679	0,797	0,457	0,824	0,877	0,882	0,529
P10	0,989	0,435	0,018	0,992	0,991	0,944	0,977	0,990	0,863	1	0,939	0,983	0,960	0,975	0,946	0,571	0,532	0,822	0,512	0,882	0,980	0,970	0,427
P11	0,944	0,430	0,017	0,945	0,945	0,892	0,937	0,944	0,826	0,939	1	0,929	0,914	0,941	0,896	0,592	0,560	0,800	0,492	0,822	0,939	0,934	0,448
P12	0,984	0,449	0,002	0,988	0,986	0,947	0,981	0,984	0,864	0,983	0,929	1	0,952	0,976	0,923	0,610	0,558	0,811	0,540	0,880	0,975	0,971	0,420
P13	0,959	0,437	0,026	0,955	0,961	0,935	0,950	0,960	0,869	0,960	0,914	0,952	1	0,951	0,934	0,636	0,613	0,809	0,475	0,892	0,954	0,958	0,455
P14	0,982	0,456	0,015	0,982	0,983	0,928	0,976	0,983	0,899	0,975	0,941	0,976	0,951	1	0,910	0,684	0,625	0,813	0,513	0,864	0,977	0,972	0,501
P15	0,947	0,417	0,016	0,943	0,947	0,910	0,927	0,946	0,813	0,946	0,896	0,923	0,934	0,910	1	0,528	0,503	0,843	0,489	0,864	0,941	0,926	0,425
P16	0,613	0,397	-0,007	0,597	0,586	0,622	0,586	0,583	0,735	0,571	0,592	0,610	0,636	0,684	0,528	1	0,825	0,572	0,338	0,562	0,631	0,656	0,538
P17	0,579	0,437	0,014	0,546	0,536	0,601	0,526	0,533	0,679	0,532	0,560	0,558	0,613	0,625	0,503	0,825	1	0,559	0,307	0,545	0,610	0,615	0,630
P18	0,836	0,428	0,007	0,825	0,818	0,802	0,803	0,815	0,797	0,822	0,800	0,811	0,809	0,813	0,843	0,572	0,559	1	0,470	0,760	0,843	0,834	0,474
P19	0,561	0,239	-0,048	0,559	0,516	0,583	0,534	0,502	0,457	0,512	0,492	0,540	0,475	0,513	0,489	0,338	0,307	0,470	1	0,543	0,564	0,569	0,231
P20	0,885	0,393	0,019	0,880	0,873	0,895	0,844	0,868	0,824	0,882	0,822	0,880	0,892	0,864	0,864	0,562	0,545	0,760	0,543	1	0,882	0,882	0,405
P21	0,997	0,489	-0,004	0,989	0,982	0,957	0,970	0,978	0,877	0,980	0,939	0,975	0,954	0,977	0,941	0,631	0,610	0,843	0,564	0,882	1	0,982	0,495
P22	0,984	0,437	-0,011	0,982	0,973	0,957	0,967	0,970	0,882	0,970	0,934	0,971	0,958	0,972	0,926	0,656	0,615	0,834	0,569	0,882	0,982	1	0,461
P23	0,467	0,374	0,014	0,434	0,434	0,428	0,419	0,432	0,529	0,427	0,448	0,420	0,455	0,501	0,425	0,538	0,630	0,474	0,231	0,405	0,495	0,461	1

Příloha C Podíl jednotlivých komponent na celkovém rozptylu. Zdroj: [Vlastní]


Komponenta	Hodnota vlastního čísla	Podíl na vysvětlení rozptylu v %	Rozptyl %
1	17,383	75,577	75,577
2	1,465	6,37	81,947
3	1,013	4,405	86,353
4	0,717	3,116	89,469
5	0,707	3,072	92,541
6	0,507	2,203	94,744
7	0,299	1,301	96,045
8	0,233	1,012	97,057
9	0,19	0,826	97,882
10	0,13	0,566	98,448
11	9,35E-02	0,406	98,855
12	7,72E-02	0,336	99,19
13	6,15E-02	0,267	99,458
14	4,41E-02	0,192	99,649
15	2,47E-02	0,107	99,757
16	1,75E-02	7,62E-02	99,833
17	1,41E-02	6,15E-02	99,894
18	1,10E-02	4,79E-02	99,942
19	6,94E-03	3,02E-02	99,972
20	4,42E-03	1,92E-02	99,991
21	1,35E-03	5,87E-03	99,997
22	4,85E-04	2,11E-03	99,999
23	1,34E-04	5,83E-04	100

Příloha D Původní a predikované hodnoty RBF neuronové sítě pro rok 2004. Zdroj: [Vlastní]





Příloha F Původní a predikované hodnoty RBF neuronové sítě pro rok 2006. Zdroj: [Vlastní]



Příloha G Původní a predikované hodnoty RBF neuronové sítě pro rok 2007. Zdroj: [Vlastní]

