UNIVERZITA PARDUBICE
FAKULTA EKONOMICKO-SPRÁVNÍ
ÚSTAV SYSTÉMOVÉHO INŽENÝRSTVÍ A INFORMATIKY

MODELOVÁNÍ VÝVOJE INFLACE POMOCÍ FRONTÁLNÍCH NEURONOVÝCH SÍTÍ

DIPLOMOVÁ PRÁCE

AUTOR: **Klára TRPIŠOVSKÁ**
VEDOUCÍ PRÁCE: **prof. Ing. Vladimír OLEJ, CSc.**
KONZULTANT: **Ing. Ivan ŠEDA**

2007

UNIVERSITY OF PARDUBICE
FACULTY OF ECONOMICS AND ADMINISTRATION
INSTITUTE OF SYSTEM ENGINEERING AND INFORMATICS

MODELLING OF INFLATION EVOLUTION BY FRONTAL NEURAL NETWORKS

THESIS

AUTHOR: **Klára TRPIŠOVSKÁ**
SUPERVISOR: **prof. Ing. Vladimír OLEJ, CSc.**
CONSULTANT: **Ing. Ivan ŠEDA**

2007

Vyhrazeno pro zadávací list (strana 1)

Vyhrazeno pro zadávací list (strana 2)

Prohlašuji:

Tuto práci jsem vypracovala samostatně. Veškeré 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 Univerzity Pardubice.

V Pardubicích dne

Klára Trpišovská

PODĚKOVÁNÍ

Touto cestou bych chtěla poděkovat vedoucímu diplomové práce, panu prof. Ing. Vladimírovi Olejovi, CSc. a konzultantovi panu Ing. Ivanu Šedovi za odbornou pomoc, připomínky k obsahové i formální stránce, vedení a podporu při vypracovávání mé diplomové práce.

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

Shrnutí

Diplomová práce se zabývá návrhem modelů frontálních neuronových sítí pro predikci vývoje míry inflace. Jako vstupní hodnoty pro učení neuronové sítě je použit cenový index, index cen výrobků a deflátor, ze kterých se odvozuje míra inflace. Všechna data se týkají vývoje v ČR.

V diplomové práci jsou popsány jednotlivé indikátory míry inflace, typy inflací, ale také způsob modelování trendových složek použitých indexů pomocí klouzavých průměrů a exponenciálních vyrovnání. Je zde navrhnuta frontální neuronová síť a uvedeny i základy dopředných neuronových sítí, které jsou vhodné pro predikci. V další části práce jsou analyzovány navrhnuté modely frontálních neuronových sítí. Verifikace navrhnutých modelů je realizována v Stuttgartském simulátoru neuronových sítí.

Summary

Graduation theses are engaged in frontal neuron networks models proposal for prediction of inflation rate progress. As source figures for neuron network learning is used price index, products price index and deflator, from which is inflation rate deduced. All data are concerned about progress in Czech republic.

In graduation theses are described not only single indicators of inflations rate, inflations types, but also the way for trend units modelling of used indexes by the help of sliding means and exponential discharges. Here is proposed frontal neuron network and also stated basis of forwarding neuron networks, which are suitable for prediction. In subsequent part of work are analysed proposed models of frontal neuron network. Verification of proposed models is realised by the help of Stuttgart Simulator of Neuron networks.

Obsah

Úvod....10
1Základní pojmy....11
1.1Definice inflace....11
1.2Měření inflace....11
1.2.1Index spotřebitelských cen....12
1.2.2Index cen výrobců....13
1.2.3Deflátor hrubého domácího produktu....14
1.2.4Problémy měření inflace....15
1.3Typy inflace....15
1.3.1Podle tempa růstu cen....16
1.3.2Podle projevu....16
1.3.3Podle příčiny....17
1.3.4Další typy inflací....18
1.4Shrnutí kapitoly....19
2Průběh inflace....20
2.1Příčiny vzniku inflace....20
2.1.1Poptávková inflace....21
2.1.2Nabídková (nákladová) inflace....22
2.2Důsledky inflace....23
2.3Deflace....25
2.4Shrnutí kapitoly....25
3Protiinflační politika vlády....26
3.1Protiinflační politika....26
3.2Metody léčení inflace....26
3.2.1Metody dezinflace....27
3.2.2Metody léčení nabídkové inflace....29
3.2.3Důchodové politiky a léčení inflace....29
3.3Shrnutí kapitoly....30
4Metody předzpracování časových řad....31
4.1Časové řady – základní pojmy....31
4.2Analýzy časových řad....33
4.3Dekompozice časové řady....34
4.3.1Adaptivní postupy modelování trendu....36
4.3.2Metoda klouzavých průměrů....36
4.3.3Exponenciální vyrovnávání....39
4.4Shrnutí kapitoly....40
5Neuronové sítě....41
5.1Základní pojmy z neuronových sítí....41
5.2Dopředné neuronové sítě....44
5.3Perceptronové sítě....45
5.4Frontální neuronová síť....47
5.5Shrnutí kapitoly....49
6Návrh frontální neuronové sítě pro predikci vývoje inflace....50
6.1Model predikce....50
6.2Předzpracování dat pro tvorbu neuronové sítě....51
6.2.1Analýza časové řady....51
6.2.2Předzpracování dat....52

6.3Definování filtru....55
6.4Návrh struktury neuronové sítě....56
6.5Výsledky procesu učení....58
6.6Shrnutí kapitoly....61
7Analýza výsledků navrhnutých modelů....63
7.1Shrnutí kapitoly....70
8Uživatelská příručka k architektuře Time-Delay v prostředí SNNS similátoru....71
8.1SNNS Manager....71
Závěr....79
Seznam použité literatury....80
Seznam obrázků....82
Seznam tabulek....83
Seznam použitých zkratek....83
Seznam příloh....83

Úvod

Inflace je definována jako projev ekonomické nerovnováhy, jehož vnějším znakem je hlavně růst cenové hladiny. Pokud dochází k poklesu cenové hladiny, označuje se tento proces jako deflace. K vyjádření velikosti inflace se používají cenové indexy.

Cílem diplomové práce je navrhnout modely pro predikci vývoje míry inflace pomocí frontálních neuronových sítí. Vstupem do modelů je zvolen index spotřebitelských cen, index cen výrobků a deflátor HDP. Těmto vstupům vždy odpovídá výstup, který představuje procentuální vyjádření míry inflace. Při modelování frontálních neuronových sítí je nutné zvolit i vhodnou délku filtru.

Diplomová práce je rozdělena do osmi kapitol. V první kapitole jsou uvedeny základní ekonomické pojmy z oblasti inflace a ekonomických ukazatelů. Zahrnuje i základní způsoby měření inflace a členění inflace z hlediska různých pohledů. Druhá kapitola obsahuje popis průběhů inflace, její příčiny a důsledky. Zaměřuje se hlavně na poptávkovou a nabídkovou inflaci. Třetí kapitola se věnuje popisu protiinflační politiky jako je důchodová politika, fiskální a monetární politika. Zabývá se možnými metodami léčení inflace – cold turkey a gradualismus. Ve čtvrté kapitole se uvádějí základní způsoby modelování trendových složek časových řad - dekompozice, jako jsou klouzavé průměry a exponenciální vyrovnání spolu se vztahy pro výpočet. Nachází se zde i způsoby členění časových řad. V páté kapitole jsou uvedeny základní pojmy z oblasti neuronových sítí. Definuje dopředné neuronové sítě, ale také frontální neuronové sítě spolu s jejich strukturami a vztahy pro jejich výstupy. U frontálních neuronových sítí je specifikována i délka klouzavého okna (filtru), která je důležitá pro vzhled struktury navrhované sítě. Kapitola šestá je věnována návrhu modelu frontální neuronové sítě vhodné pro predikci vývoje míry inflace. Je zde specifikován model predikce, předzpracování dat použitých jako vstupní hodnoty, definování filtru neuronové sítě a vlastní návrh neuronové sítě. Model je verifikovaný v prostředí SNNS. Sedmá kapitola je zaměřena na analyzování navrhnutých modelů frontálních neuronových sítí. Navrhnuté modely jsou děleny podle délky filtru a následně podle vstupních neuronů. Poslední osmá kapitola obsahuje uživatelskou příručku k SNNS simulátoru k architektuře frontální neuronové sítě, která je použitá v diplomové práci.

1 Základní pojmy

Kapitola se zabývá základními ekonomickými pojmy z oblasti inflace. Je členěna do třech hlavních částí. V první části kapitoly se specifikuje základní definice inflace. Druhá část se zaměřuje na způsoby měření inflace, popisuje index spotřebitelských cen, index cen výrobců, deflátor HDP (Hrubý domácí produkt) a problémy měření inflace. Poslední část této kapitoly popisuje druhy inflace z různých pohledů (podle tempa růstu cen, projevů, příčin, aj.).

1.1 Definice inflace

Inflaci lze charakterizovat jako vždy se nerovnováhu mezi množstvím peněz a množstvím zboží a služeb. Důsledek této nerovnováhy je nepřetržitý růst cen, mezd a vznik cenově mzdové spirály. Inflace je dlouhodobý pohyb cenové hladiny směrem vzhůru pouze tehdy, jde-li o nepřetržitý proces. Pojem dlouhodobý může být i relativně krátké období jako např. dvě po sobě jdoucí čtvrtletí. Inflace [1] není, když:

-dojde k jednorázovému zvýšení cen,

-proporcionálně ceny některých statků rostly a jiných klesaly,

-v důsledku nejrůznějších příčin neefektivnosti všeobecně chudneme,

-zboží je drahé a lidé na ně nemají peníze.

Mírná inflace je někdy označována za pozitivní faktor ekonomického růstu. Např. monetaristé považují jakoukoliv inflaci za největší zlo v ekonomice a jsou ochotni nést vysoké náklady za cenu jejího zmírnění.

Opakem inflace je deflace, která nastává, jestliže celková hladina cen klesá. Dlouhodobě trvající deflace, kdy ceny nepřetržitě klesají, jsou spojeny s obdobím dlouhodobých recesí a depresí. Pojem desinflace vyjadřuje zpomalování tempa růstu cenové hladiny, tj. snižování míry inflace. V případě zvyšující se míry inflace se hovoří o akcelerované inflaci.

1.2 Měření inflace

Výše inflace se měří pomocí míry inflace, která vyjadřuje tempo růstu cenové hladiny. Pro výpočet míry inflace je nutné změřit cenovou hladinu. Nejčastěji se používají cenové

indexy – index spotřebitelských cen (Customer Price Index - CPI), index cen výrobců (Producer Price Index - PPI) a deflátor HDP.

Inflaci [2] v ČR počítá Český statistický úřad jako vážený průměr celkem 775 položek. Vahou je významnost (důležitost) položky na celkové spotřebě domácnosti. Jednotlivé položky se souhrnně nazývají spotřebitelský koš. Ze všech položek je 117 tzv. regulovaných, ale to už se týká dalšího pojmu a tím je čistá inflace. Určité zboží a služby podléhají regulaci státu. Stát nenařizuje kolik má stát litr mléka nebo jeden rohlík. U 117 položek spotřebního koše však cenu hlídá, stanovuje a tím ji reguluje. Regulované ceny jsou např. elektřina, plyn, dálniční známka, taxislužby, poštovní známka a další. Čistá inflace tak měří změny cen jen v neregulované části koše. Existují i jiné cenové indexy:

-indexy cen stavebních prací a stavebních subjektů,

-indexy cen průmyslových výrobců,

-indexy cen zemědělských výrobců,

-indexy cen tržních služeb v produktivní sféře.

1.2.1 Index spotřebitelských cen

Tento index [3] odráží změnu cen zboží a služeb, které nakupují domácnosti. Index měří náklady na zakoupení koše vybraného zboží a služeb v běžném roce ve srovnání s náklady, kterých bylo zapotřebí k nákupu stejného koše v základním roce. Cenové indexy poměřují úroveň cen vybraného spotřebního koše reprezentujících výrobků a služeb ve dvou srovnávaných obdobích, přičemž váha, která je jednotlivým cenovým reprezentantům

ve spotřebním koši přisouzena, odpovídá podílu daného druhu spotřeby, který zastupují, na celkové spotřebě domácností. Do spotřebního koše je zařazeno potravinářské zboží (potraviny, nápoje, tabák), nepotravinářské zboží (odívání, nábytek, potřeby pro domácnost, drogistické a drobné zboží, zboží pro dopravu a volný čas, aj.) a služby (opravárenské, z oblasti bydlení, provozu domácnosti, zdravotnictví, sociální péče, dopravy, volného času, vzdělávání, stravování a ubytování, osobní péče a služby finanční). Zboží a služby jsou do koše vybrány tak, aby odrážely kupní zvyklosti obyvatel dané země. Druh a množství zboží, které jsou v koši zahrnuty, se mění pouze jednou za několik let, kdy dojde k výrazné změně spotřebních zvyklostí.

V ČR došlo ke změně koše naposledy v roce 2001. Tento koš obsahuje jak již bylo řečeno 775 položek a nově do něho bylo ve srovnání s košem z roku 1993 zařazeno

38 položek, např. mobilní telefony, dětské plenkové kalhotky, dálniční známka, pronájem kurtu na squash, a také některé značky osobních automobilů.

Hodnota koše je získána tak, že je dané množství zboží a služby násobeno jeho cenou v příslušném období. Ty položky, které mají dlouhodobě větší podíl na spotřebě, tzn. že jsou více zastoupeny v průměrném rozpočtu rodin, mají při výpočtu větší váhu než položky, které jsou zastoupeny v menších částkách. Index spotřebitelských cen se vypočítat takto

$$CPI = \frac{\sum_{i=1}^{n} q_{0i} \times p_{1i}}{\sum_{i=1}^{n} q_{0i} \times p_{0i}} \cdot 100 \ [\%], \tag{1.1}$$

kde q_{0i} a p_{0i} představuje množství a cenu i-tého zboží nebo služby základního roku a p_{1i} představuje cenu i-tého zboží běžného roku. Tento vztah je znám jako Laspeyersův cenový index. Je-li známa hodnota cenových indexů, lze odvodit výpočet míry inflace pomocí indexu spotřebitelských cen. Dají se použít i jiné indexy, které vyjadřují cenovou hladinu

$$\pi = \frac{CPI_t - CPI_{t-1}}{CPI_{t-1}} \cdot 100 \ [\%]. \tag{1.2}$$

Při použití CPI k měření cenové hladiny mohou nastat problémy. Nejvýznamnějším je ten, že CPI neodráží změnu kvality výrobků v průběhu času. Během let dochází u výrobků ke značnému zlepšení kvality, ale toto zlepšení kvality je obtížně měřitelné. Znamená to, že zvýšení ceny může být znakem zvýšení kvality, nikoli pouze důsledkem inflace. Jiným problémem jsou změny relativních cen. Při zvýšení cen některých druhů zboží spotřebitelé snižují jejich spotřebu a spotřebovávají ta zboží, která jsou relativně levnější. Index nezachycuje změny spotřebovávaného množství, to ale znamená, že výše nákladů by mohla být vyšší než ve skutečnosti. Vývoj CPI v ČR v letech 1993 – 2006 je znázorněn na obr. 1.1.

1.2.2 Index cen výrobců

Je konstruován obdobně jako CPI s pevnými váhami, které jsou dány strukturou tržeb a měří ceny surovin, polotovarů i hotových výrobků jednotlivých odvětví. Český statistický úřad publikuje indexy cen stavebních prací, index cen průmyslových nebo

zemědělských výrobců. Fixní váhy jsou založeny na čistých dodávkách či prodejních komodit. Vývoj PPI v ČR v letech 1993 – 2006 je znázorněn na obr. 1.2.

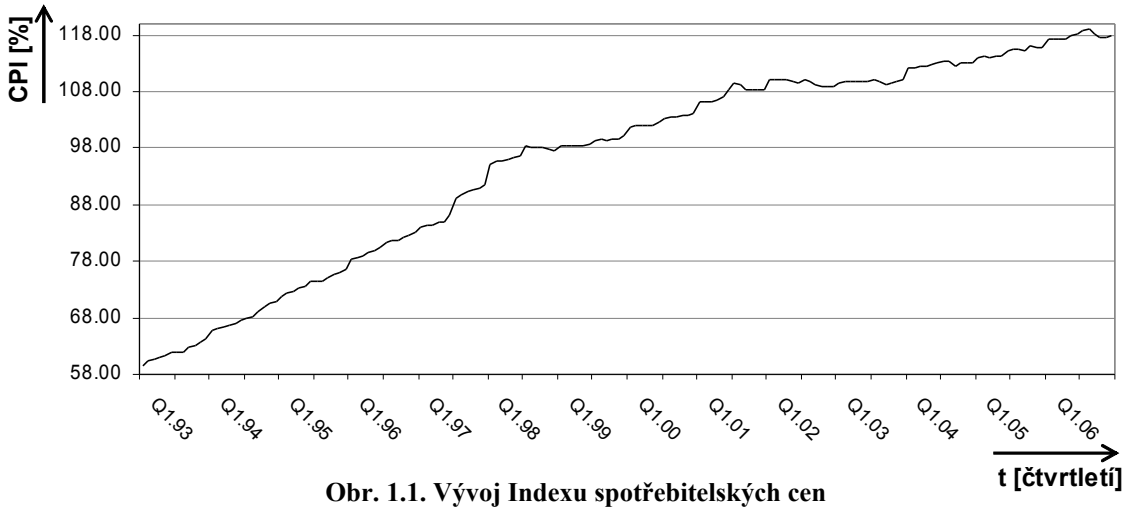

Obr. 1.1. Vývoj Indexu spotřebitelských cen

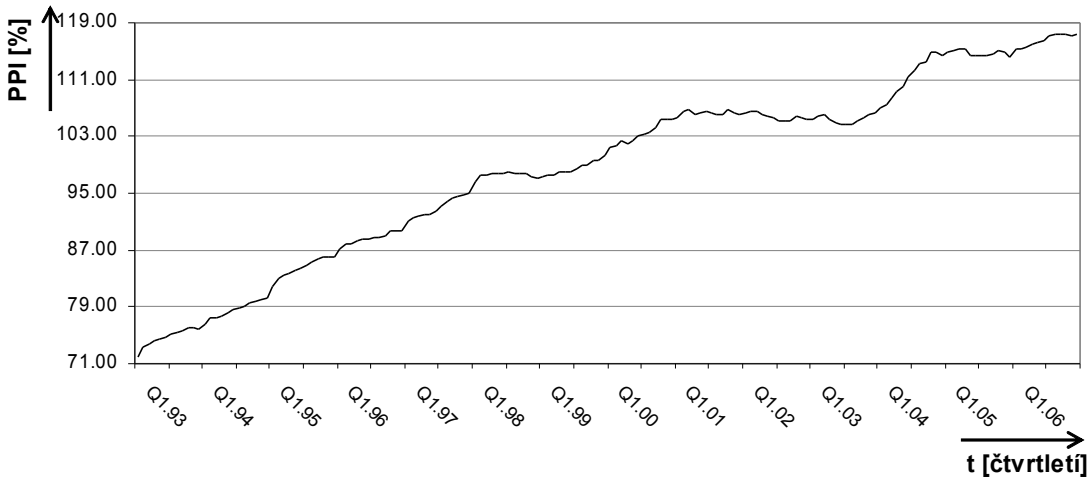

Obr. 1.2. Vývoj Indexu cen výrobců

1.2.3 Deflátor hrubého domácího produktu

Pojem deflátor [4] vychází z pojmu defilovat, což znamená očišťovat o změnu cen. Zjišťuje se jako HDP běžného roku se ocení nejprve v cenách běžného roku a poté v cenách minulého roku. Samotný výpočet se realizuje jako podíl HDP v běžných cenách s HDP v minulých cenách (ceny základního období). Tento vztah vyjadřuje, jak se zvýšila cenová hladina oproti minulému roku

$$Deflátor = \frac{Q_{at} \cdot P_{at} + Q_{bt} \cdot P_{bt} + \ldots + Q_{zt} \cdot P_{zt}}{Q_{at} \cdot P_{a(t-1)} + Q_{bt} \cdot P_{b(t-1)} + \ldots + Q_{zt} \cdot P_{z(t-1)}}, \tag{1.3}$$

kde Q_{at}, Q_{bt}, ... ,Q_{zt} jsou množství statků *a, b, ... ,z* (z nichž se skládá HDP) vyrobená v roce *t*, P_{at}, P_{bt},...,P_{zt}, jsou ceny těchto statků v témže roce *t* a $P_{a(t-1)}$, $P_{b(t-1}$, ... ,$P_{z(t-1)}$ jsou ceny statků v minulém roce. Vývoj deflátoru HDP v ČR v letech 1993 – 2006 je na. obr. 1.3.

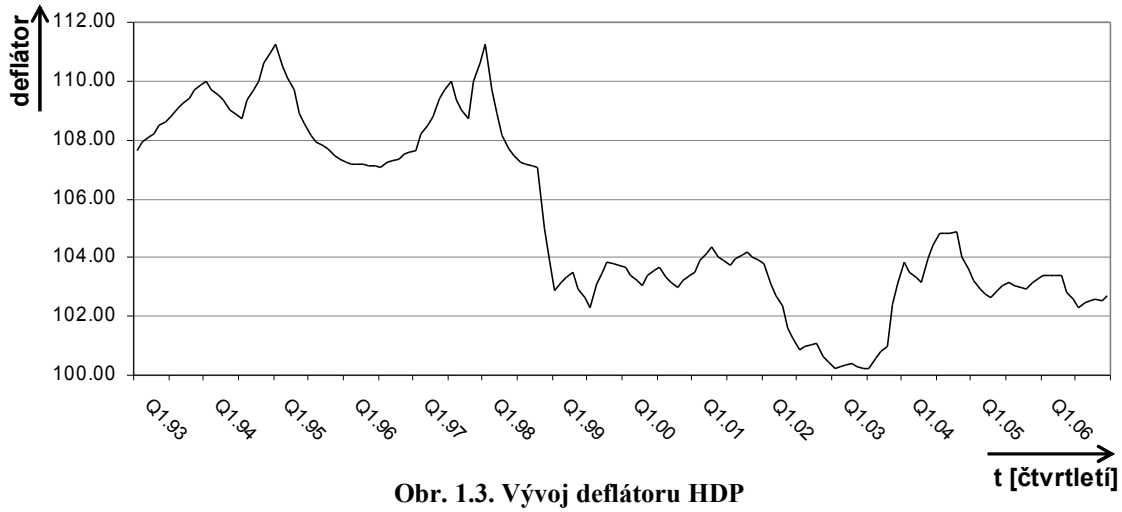

Obr. 1.3. Vývoj deflátoru HDP

1.2.4 Problémy měření inflace

Měření [5] inflace pomocí cenových indexů s sebou nese problémy typické pro cenové indexy. Volba vybraných výrobků a služeb je ovlivněna subjektivním přístupem k výběru a měření se v průměrném čase. Zahrnuje typické výrobky, tj. vybrané potraviny, oděvy, služby související s bydlením, dopravou, náklady na vzdělání atd. Pro výpočet cenových změn však musí být výběr reprezentantů neměnný po celé sledované období.

Každý produkt se prodává v mnoha druzích a kvalitách a v různých typech obchodů. Je obtížné rozhodnout, který druh jablek u kterého obchodníka je typický nebo jaké jsou typické sportovní pánské boty, atd. Také stejná služba se liší podle firmy, která ji provádí, a podle celé řady dalších skutečností. Dalším problémem může být volba základního roku. Je-li základní rok, rokem s mimořádně vysokou nebo nízkou hodnotou, ovlivní tak relaci srovnávané veličiny, eventuelně celou časovou řadu údajů.

1.3 Typy inflace

Inflace [5] je velmi složitý jev. Její vliv na ekonomiku nebo jiné ekonomické subjekty nelze hodnotit všeobecně. Záleží o jaký typ inflace se jedná. Typů inflace je celá řada podle hledisek, ze kterých se vychází.

1.3.1 Podle tempa růstu cen

Pozornost zasluhují dva příznaky inflace a to její rychlost a doba jejího trvání. Rychlost tvoří jeden z prvků, které vysvětlují, jak je inflace vnímána ekonomickými subjekty. Rychlost je pociťována silněji než inflace trvající delší čas. Co se týče trvání inflace, může jít o rychlý vzestup cen nebo v jiných případech je vzestup cen daleko delší a pomalejší. Podle rychlostí růstu cen se inflace dělí na mírnou, pádivou a hyperinflaci.

Mírná/plíživá inflace (Moderate/Creeping Inflation)

Za plíživou inflaci se považuje vzestup cenové hladiny o několik procent za rok. Je také označována jako jednociferná a vyznačuje se tím, že lidé neztratily důvěru k penězům. Jsou ochotni dále je používat jako oběživo, držet peníze na vkladech i úsporných účtech. Podepisují se nejen krátkodobé, ale i dlouhodobé smlouvy v penězích dané měny. Peníze plní své funkce.

Pádivá inflace (Galloping) a cválající inflace

Vzestup cen dosahuje desítek až stovek procent ročně, ceny tedy rostou dvou – až trojciferným tempy ročně. Tyto druhy inflace jsou spojeny s řadou vážných hospodářských poruch. Peníze rychle ztrácejí svou kupní sílu a lidé snižují jejich držbu. Rychlost oběhu peněz roste. Lidé přesouvají svá peněžní aktiva do aktiv reálných, jako jsou domy, půda, zlato, umělecké předměty, aj. Peníze plní své funkce jen ve velmi omezené míře. Většinou tato inflace přerůstá v hyperinflaci.

Hyperinflace

Vzestup cen dosahuje stovek, často i tisíců procent za rok. Hyperinflace znamená ztrátu schopnosti peněz plnit své funkce. Lidé nejsou ochotni přijímat peníze jako platební prostředek (oběživo) a požadují výměnou za zboží či službu buď jiné zboží nebo jinou než inflační měnu. Dochází k obrovskému narušení hospodářství, v němž peněžní směna se mění na směnu naturální.

1.3.2 Podle projevu

Inflace se může projevovat mnoha způsoby, někdy je velmi snadno viditelná. Nebezpečným druhem inflace je inflace skrytá, která není na první pohled zřetelná a proto se proti této inflaci nedá vhodným způsobem reagovat.

Otevřená inflace (Open Inflation)

Je to inflace zjevná, je možno ji měřit a údaje se publikují. Projevuje se jako trvalý růst cenové hladiny a je nejběžnějším typem inflace.

Skrytá inflace (Hidden Inflation)

Skrytá inflace je spjata s existencí centrálně řízených ekonomik. V těchto ekonomikách se ceny netvoří na základě vztahu nabídky a poptávky, ale jsou centrálně stanovovány, takže nemohou spontánně (tj. bez rozhodnutí centra) růst. Inflaci však nelze zrušit striktním stanovením cen, je-li porušena rovnováha mezi množstvím zboží a množstvím peněz. Administrativní opatření brání růstu cen, ačkoli jsou pro něj důvody na straně poptávky a nabídky. Za skrytou inflaci se označuje situace, kdy levné výrobky bývají nahrazovány dražšími, aniž by tomu odpovídala vyšší kvalita či lepší vlastnosti, kterými uspokojují potřeby spotřebitelů. V tomto smyslu se často hovoří o fiktivních inovacích. Jako důsledek skryté inflace vzniká stínová ekonomika a černý trh s vyššími cenami. Tím, že je tato inflace skrytá, není možno s ní účinně bojovat.

Potlačená inflace (Repressed Inflation)

Je to inflace, která není navenek patrná. Potlačená inflace vzniká tehdy, existuje-li na trzích všeobecný převis poptávky (při daných cenách jsou poptávaná množství zboží a služeb všeobecně vyšší než množství nabízená) a je-li bráněno cenám tento převis svým růstem eliminovat. Nejsou však uspokojeni všichni spotřebitelé, protože chybí některé výrobky nebo není jejich žádoucí sortiment. Nejsou uspokojeni ani výrobci a snaží se čelit inflaci předzásobením. Rovněž tak spotřebitelé skupují a hromadí nedostatkové zboží.

1.3.3 Podle příčiny

Obvykle se [3] uvádějí dílčí příčiny, například úroková inflace, mzdová inflace, dovážená inflace, inflace odpisů, rozpočtová inflace, inflace z přebytku platební bilance, inflace v důsledku devalvace, inflace v důsledku poklesu výroby, atd. Obecně se podle příčiny rozlišují dva druhy inflace, a to poptávkovou a nákladovou.

Poptávková inflace (Demant-Pull Inflation)

Poptávková inflace je také nazývána jako inflace tažená poptávkou. Vzestup poptávky je zapříčiněný změnami v investicích, ve spotřebě, zvýšením vládních výdajů nebo vývozu,

přičemž původní příčinou může být pokles úrokové míry nebo devalvace měny, event. zavedení některého z opatření monetární nebo fiskální politiky státu.

Nákladová inflace (Cost-Push Inflation)

Jinak řečeno také jako inflace tlačená náklady. Roste kterákoli z nákladových složek, ať jsou to ceny surovin nebo výrobního zařízení, a to tuzemské nebo dovážené. Růst nákladů může být důsledkem zvýšení mezd, odpisů, změny daňových sazeb, atd. Příčinou této inflace mohou být i tzv. nabídkové šoky.

Inflace a očekávání hospodářských subjektů

Lidé si obvykle utvářejí určité představy o budoucnosti. Míra, ve které lidé očekávají růst cenové hladiny v příštím období, se nazývá očekávaná míra inflace. Očekávání se nakonec mohou ukázat jako správná nebo mylná. Jestliže očekávání hospodářských subjektů při odhadu míry inflace byla správná a skutečná míra inflace je rovna očekávané míře inflace, pak je taková inflace nazývána jako anticipovaná (předvídaná) inflace. Míru inflace, která nebyla očekávaná správně, se pak nazývá neanticipovanou (nepředvídanou) inflací.

1.3.4 Další typy inflací

Nevyrovnaná inflace

Nevyrovnaná inflace je tehdy, kdy ceny jednotlivých statků rostou rozdílným tempem. Dochází tudíž ke změněn cenových relací (poměrů mezi cenami) neboli relativních cen. V širším smyslu je pojem nevyrovnaná inflace používán též pro vývoj relace mezi změnou cen statků (míry inflace) a změnou jiných nominálních veličin (např. nominálních mzdových sazeb, cen cenných papírů, apod.).

Strukturální inflace

Ve strukturální inflaci jsou dvě orientace. První se odvolává na prvky reálné a druhá poukazuje na tlaky sociální. Vztahuje se na disponibilní množství výrobních zdrojů a na vazby, které tato množství mezi sebou spojují. Určité stavy nouze zatěžují náklady výroby. Strukturální inflace lze uvažovat i podle sociálních skupin národa. Zde se uvažuje, že měnový aspekt inflace je jen sekundárním následkem svého aspektu sociálního, a že tedy jeden i druhý jsou součástí téhož procesu. Přitom sociální aspekt má často původ

v příčinách, které se případ od případu velmi mění, i když je lze odvozovat od napění mezi skupinami, toto napětí je vyvoláváno právě inflací.

Očekávaná inflace

Často je posun agregátní poptávky nebo nabídky pro tržní subjekty nečekaný, což domácnosti a firmy pociťují v podobě náhlých cenových šoků. Ne všechny změny v agregátní nabídce a poptávce jsou však pro tržní subjekty neočekávané. Domácnosti i firmy předpokládají určitou míru inflace. Přihlížejí k ní při jednáních o výši mezd, určování výše úroků apod. Tento druh inflace se označuje jako setrvačná či očekávaná inflace (Intetial Inflation). Pokud působí v ekonomice pouze setrvačná inflace, křivky agregátní poptávky a nabídky se posunují vzhůru ve stejné míře.

1.4 Shrnutí kapitoly

Kapitola obsahuje základní pojmy v oblasti inflace. Druhá část popisuje základní způsoby měření výše inflace, použití cenových indexů pro výpočty inflace i základní vztahy pro výpočty jednotlivých indexů. V poslední části kapitoly jsou definovány jednotlivé druhy inflací a jsou členěny z různých hledisek - podle tempa růstu cen, podle projevů a podle příčin. Zahrnuje i nezačleněné druhy inflací – nevyrovnaná, strukturální a očekávaná inflace.

2 Průběh inflace

Kapitola se týká příčin vzniku inflace, která se člení na poptávkovou a nabídkovou inflaci. Dále zahrnuje možné důsledky inflace jako je přerozdělovací efekt, sociální dopady nebo působení na rovnováhu ekonomiky. Další část kapitoly obsahuje náklady jednotlivých druhů inflací a jejich základní popis (anticipovaná a neanticipovaná inflace), protože se ve svých dopadech výrazně odlišují. Poukazuje na inflační spirálu, kde se příčina a následek stále opakují. Je zaměřena na definici pojmu deflace a jeho základního popisu.

2.1 Příčiny vzniku inflace

Na příčiny inflace jsou různé názory. V [5] se považuje za zdroj inflace rostoucí poptávka, která nemůže být uspokojena při stávající nabídce. Doporučuje se regulace poptávky různými opatřeními hospodářské politiky, zejména daňovou politikou (progresivní daňové sazby), pomocí výdajů ze státního rozpočtu, apod. Odpůrci reprezentovaní monetaristy sice spatřují hlavní zdroj inflace též v poptávce, ale přisuzují ho růstu oběživa, tedy nesprávné monetární politice centrální banky.

Naproti tomu ekonomové orientovaní na stranu nabídky se soustřeďují na vliv nákladů na ceny. Centrum jejich pozornosti jsou mzdy a ceny ostatních vstupů. Poptávkové faktory jako příčina inflace se považují za faktory klasické, nabídkové proti tomu za neklasické.

Ve skutečnosti jsou poptávková a nabídková inflace těsně propojeny. Zvýšení poptávky vede výrobce ke zvýšení cen výrobků, tím vyvolá požadavky na vzestup mezd, který znamená opět zvýšení cen, a to na všech stupních zpracování, tedy cen nejen hotových výrobků, ale i surovin a polotovarů. Takže zdražení surovin vede opět ke zvýšení cen hotových výrobků, atd. Tento postupný růst cen a mezd se nazývá inflační spirála a její roztočení odvádí pozornost od její příčiny k nalezení cest na její zastavení.

Při hodnocení dopadu inflace na ekonomiku je však třeba rozlišovat především tempo inflace. Podle stupně intenzity se rozeznávají tři hlavní typy podnětů:

- Inflační napětí se projevuje jako nerovnováha mezi nabídkou a poptávkou v některých důležitých sektorech, aniž se tato nerovnováha bezprostředně projeví. Podmínky inflace jsou již splněny v dostatečné míře, ale jsou zde určité překážky, některé zatím zadržují více či méně dočasně vzrůst cen. Ekonomická politika může

např. podmínky udržovat ve stabilním stavu, nebo je blokovat, tím spíše, když předběžné příznaky těchto tlaků nejsou vždy snadno rozeznatelné.

-Inflační tlak se převádí ve znatelné a stálé formě do cen.

-Inflační šok se od předchozích liší tím, že je zde velmi náhlý projev inflace. Může se stát, že země nemá vnitřní příčiny k inflaci, ale přece se v ní objeví. Tento jev přenosu inflace se označuje jako importovaná.

2.1.1 Poptávková inflace

Poptávková [7] inflace je způsobena pozitivními poptávkovými šoky. K poptávkové inflaci může dojít, pokud se skutečný produkt blíží svou velikostí produktu potenciálnímu nebo neklesají ceny vstupů. Možnost poptávkové inflace se promění ve skutečnost, když dále pokračuje růst agregátní poptávky a odpovídajícím způsobem neroste potencionální produkt. Proto jinak řečeno příčinou inflačního růstu cen je existence přebytečné koupěschopné poptávky při dané cenové hladině, a to z toho důvodu, že v podmínkách plné zaměstnanosti a při plném využití výrobních kapacit celková nabídka nereaguje dostatečně rychle na změny v koupěschopné poptávce. Některé možné příčiny poptávkové inflace jsou:

-Mzdy tvoří významnou složku spotřebních výdajů. Pokud růst nominálních mezd převýší růst produktivity (a tedy nabídku) při skutečném produktu, který odpovídá potencionálnímu, tím doje k inflaci.

-Stát svými opatřeními může prosadit levný úvěr. Zvýší tak spotřební a investiční výdaje a tím otevírá cestu poptávkové inflaci.

-Snížení daní zvyšuje poptávku a vytváří možnost, aby se projevila inflace.

-Zvýšení státních výdajů může být větší než růst nabídky a může vyvolat inflaci. Tak je tomu hlavně při deficitech státního rozpočtu. Stát zvyšuje výdaje na veřejnou spotřebu (školství, zdravotnictví, kulturu,…), zvyšuje výdaje do sociální oblasti, čím se zvyšují koupěschopnost obyvatelstva.

-S čistým exportem souvisí importovaná inflace.

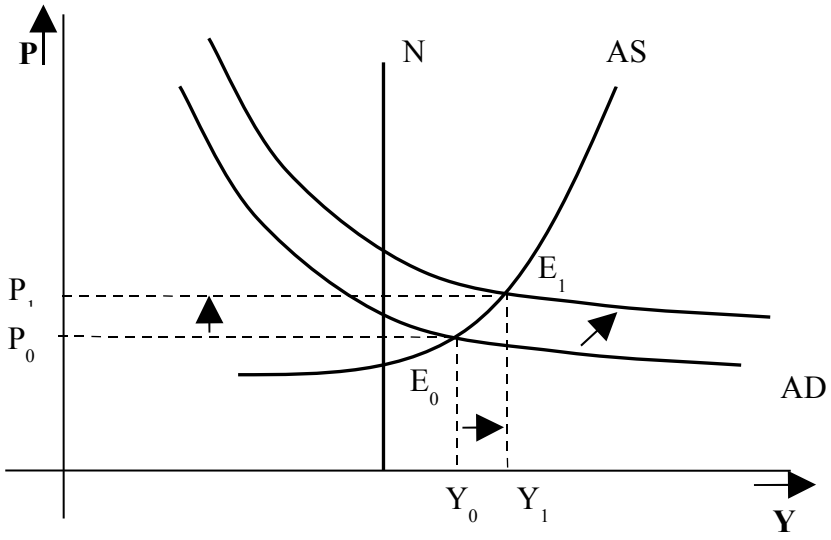

Obr. 2.1. Poptávková inflace

Jak se prosazuje poptávková inflace, je znázorněné na obr. 2.1. Na svislé ose se vynáší růst cenové hladiny a vodorovná osa znázorňuje množství reálného produktu. Agregátní poptávka (Aggregate Demands - AD) zde protíná agregátní nabídku (Aggregate Supply - AS) ve výchozím rovnovážném bodě E_0, kde ekonomika dosahuje hodnoty reálného produktu Y_0 a cenové hladiny P_0. V této situaci se zvýší agregátní poptávka, která je znázorněna křivkou AD‘. Bod rovnováhy se přesune do E_1 a ekonomika proto dosáhne nového reálného produktu Y_1 a nové cenové hladiny P_1. Reálný produkt se téměř nezmění, zvýší se zejména cenová hladina. Inflace je tedy tažená poptávkou.

2.1.2 Nabídková (nákladová) inflace

K nabídkové inflaci může dojít, i když skutečný produkt je nižší než potencionální. Důvodem je právě zvýšení nákladů, které se projeví jako posun křivky agregátní nabídky nahoru. Do centra pozornosti se tak dostává zkoumání vlivu výrobních nákladů na růst cen. K inflaci dochází proto v důsledku růstu cen vstupů surovin, materiálů, energie, mezd. Hlavním prvkem nákladů, který ovlivňuje vývoj cen, je teorie růst mzdových nákladů. Příčiny nabídkové inflace jsou různé:

- Nedokonalá konkurence – firmy v monopolním nebo oligopolním postavení mají vliv na tržní ceny. Pokud některé z těchto firem zvýší ceny a jejich výrobky slouží jako meziprodukty, zvýší se náklady ostatním výrobcům.

-Mzdy jsou důležitou složkou nákladů. Pokud odbory prosadí zvýšení mezd, může se to odrazit i ve zvýšení celkových nákladů.

-Politické události, které mohou např. vyvolat zdražení dovážených surovin a energetických zdrojů.

-Náklady se též zvýší, pokud je nutno přejít na méně kvalitní zdroje surovin nebo energii.

Důsledky růstu nákladů vůči cenové hladině a velikosti reálného produktu zobrazuje Obr. 2.2. Na svislé ose je vynášen růst cenové hladiny a vodorovná osa zachycuje množství reálného produktu. Agregátní poptávka protíná nabídku (AS) ve výchozím rovnovážném bodě E_0. Skutečný produkt je stejně velký jako potencionální, výrobní faktory jsou plně využity. Zvýšené výrobní náklady posunou krátkodobou křivku agregátní nabídky vzhůru AS‘. Bod rovnováhy se přesunul do bodu E_1. Snížil se reálný produkt (Y_1) a cenová hladina se zvýšila do polohy P_1. Inflace je tlačena nabídkou.

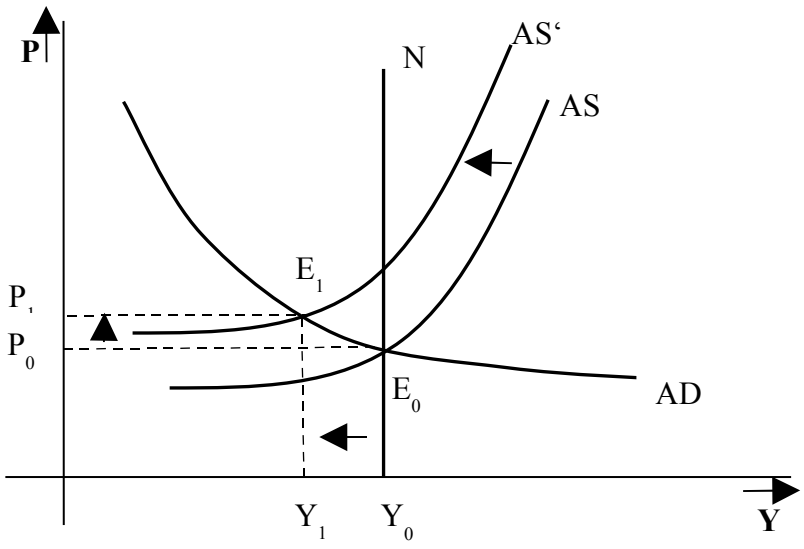

Obr. 2.2. Nabídková inflace

2.2 Důsledky inflace

Peněžní toky propojují celé hospodářství. Inflace, která narušuje jejich rovnováhu, tak svými důsledky zasahuje všechny části ekonomiky. Inflace všeobecně představuje nejistotu, proto vede k vědomému zkracování časového horizontu ekonomického rozhodování. Znamená preferování spotřeby před investicemi, podkovávání dlouhodobých

podmínek ekonomického růstu, vede k růstu zásob. Dopad inflace na ekonomiku se umocňuje s růstem jejího tempa a je patrný v oblastech redistribuce příjmů a aktiv mezi různými skupinami ekonomických subjektů, poklesu významu cenového systému jako informačního zdroje pro podnikatele a v oblasti narušení ekonomické rovnováhy a ekonomického růstu.

Inflace má přerozdělovací efekt

Postihuje příjemce fixních důchodů. Nominální výše starobních důchodů, stipendií, úroků z obligací a podobných příjmů se nemění, ale jejich reálná kupní hodnota klesá. Inflace nepříznivě ovlivňuje mzdy a platy. Reálné mzdy v mírné inflaci obvykle rostou, ale za cválající inflace se prosazuje tendence k poklesu reálných mezd. Právě při růstu cen profituje zaměstnavatel z vyšších příjmů a pokud abstrahuje do růstu cen vstupů, tak i z vyšších zisků. Zaměstnavatel růst svých cen promítne do růstu mezd obvykle až se zpožděním a není jisté, zda-li bude zvýšení mezd proporcionální ke zvýšení jeho příjmů. Pokud je míra inflace vyšší než nominální úroková míra, klesá absolutně hodnota vkladů a půjček. V tomto případě ztrácejí věřitelé a získávají dlužníci. Věřitelé sice obdrží dříve zapůjčenou nominální sumu peněz (dokonce zvětšenou o úroky), peníze jsou však v důsledku inflace znehodnoceny. Inflace nepostihuje vlastníky hmotných statků. Cena majetku s inflací stoupá.

Inflace má sociální dopady

Sociálně slabší skupiny obyvatelstva nejsou obvykle majiteli reálných hodnot. Jejich životní úroveň závisí na peněžních důchodech (často fixních). Inflaci proto pociťují výrazněji než majetkově a příjmově silné skupiny obyvatelstva.

Inflace působí na rovnováhu ekonomiky

Pádivá inflace sice nominálně zvyšuje poptávku, reálně ji však snižuje. Reálné snížení agregátní poptávky může způsobit pokles reálného produktu pod úroveň potencionálního, tj. vyvolat recesi. Mírná inflace posiluje agregátní poptávku úměrně růstu nabídky. Stimuluje tak výrobu a zaměstnanost. Inflace tedy mění strukturu spotřeby. Rychlejší růst cen základních životních potřeb (potravin apod.) snižuje zdroje důchodů použitelných na jiné výrobky a služby. Změny ve struktuře vyvolávají strukturální přesuny ve výrobě, které mohou narušit rovnováhu hospodářství.

2.3 Deflace

Opakem inflace je deflace [5], tedy všeobecný pokles cen. Míra inflace nabývá záporných hodnot. Teoreticky může být deflace jako pokles cen důsledkem posunu křivky agregátní nabídky doprava. Znamená tedy současně zvýšení vyráběné produkce. Pokles cen by měl spotřebitele motivovat k větším nákupům. Všeobecný pokles cen nemusí být vždy reakcí na peněžní deflaci. Při dané zásobě peněz může např. dojít v důsledku rostoucí ekonomiky a zvyšující se životní úrovně ke zvýšení poptávky po penězích. To potom povede ke všeobecnému poklesu cen a bude označeno za deflaci. V tržní ekonomice je pokles cen následkem zvýšení množství reálného bohatství mechanismem, jehož prostřednictvím dochází k šíření bohatství ekonomikou. V důsledku zvýšení kupní síly peněz si lidé mohou pořídit větší množství zboží a služeb. Klíčem k tomuto mechanismu je to, že zásoba peněz je udržována na stejné, neměnné úrovni.

2.4 Shrnutí kapitoly

Kapitola obsahuje popis základních příčin vzniků a podnětů inflace, její možný průběh. Zdůrazňuje i míru intenzity jednotlivých podnětů. Základními příčinami vzniku inflace je nabídka a poptávka, proto kapitola obsahuje jednotlivé subkapitoly pro tyto druhy inflace a jejich možné příčiny. Dále se zabývá dopady a důsledky inflace jako je přerozdělovací efekt, sociální dopady a možné dopady na rovnováhu ekonomiky a zaměřuje se na stručný popis deflace.

3 Protiinflační politika vlády

V úvodní části se kapitola zabývá specifikací protiinflační politiky, jako je řízení mezd a cen, zvýšení konkurenceschopnosti trhu, opatření fiskální a monetární politiky. V další části jsou definovány způsoby léčení inflace – zastavení inflace, léčení nabídkové inflace, důchodová politika a dezinflační politika, která obsahuje gradualistickou metodu a metodu Cold Turkey, viz kap. .

3.1 Protiinflační politika

Většina [5] tržních ekonomik se snaží inflaci podrobit své kontrole. Uplatňují se následující opatření.

Řízení mezd a cen (důchodová politika)

Státní orgány stanový strop cen nebo mezd, eventuelně nařídí zmrazení cen a mezd. Účinnost tohoto opatření je většinou jen dočasná a je podmíněna řešením příčin inflace.

Zvýšení konkurence schopnosti trhu

Zejména zastánci účinnosti volné hry tržních sil spoléhají na vnitřní síly trhu a tímto opatřením je podporují. Znamená to deregulaci státem řízených odvětví a sfér, privatizací nebo reprivatizací státních podniků, a tím zvýšení jejich efektivnosti a konkurence-schopnosti. Stejným směrem působí i veškerá antimonopolní politika.

Opatření fiskální a monetární politiky

Jedná se například o změny úrokové míry, změny progresivity zdanění a další opatření v rámci hospodářské politiky státu. Je zřejmé, že k využití těchto pák se přiklánějí zastánci nutnosti regulace hospodářství ze strany státu.

3.2 Metody léčení inflace

K léčení inflace existuje celá řada metod. Mezi radikální [1] opatření protiinflační terapie patří zrušení platnosti staré měny a zavedení nových peněz, tzv. nulifikace. Toto opatření je opravdu krajním řešením, jež je slučitelné pouze s mimořádnými společenským předpoklady, které navodí ochotu veřejnosti takové opatření přijmout. Základní přístupy k zastavení inflace spočívají v:

-Restriktivní monetární politice, tj. omezení a přísná kontrola množství peněz v ekonomice, znesnadnění přístupu k úvěru prostřednictvím diskontní sazby a úrokových měr.

-Restriktivní fiskální politice, tj. snížení vládních výdajů, případně zvýšení daní a daňová kázeň, eliminace rozpočtového deficitu.

-Politice stabilního měnového kurzu, která obvykle měnový kurz zavěsí na zahraniční měnu, jež ukotvuje ceny.

-Regulované důchodové politice (mezd a cen).

Výsledkem těchto opatření by mělo být snížení agregátní poptávky a posun její křivky směrem dolů. Existují další metody nazvané jako metody dezinflace.

3.2.1 Metody dezinflace

Protože poptávkovou inflaci vyvolává inflační monetární politika, a nadměrně expanzivní fiskální politika, pak je nutné provést deziflaci, tzn. snížit tempo růstu peněžní zásoby, tj. realizovat restriktivní monetární politiku, jež povede k tomuto cíli, nebo snížit vládní výdaje. Jsou možné dvě metody léčení inflace, resp. dvě strategie omezování inflace:

-Metoda Cold Turkey, jež znamená aplikaci výrazného a permanentního snížení míry růstu agregátní poptávky.

-Gradualistická metoda, jež spočívá v pomalém a postupném snižování míry růstu agregátní poptávky, tj. nominálního produktu.

Gradualistická metoda

Politika gradualismu se pokouší o pozvolný a soustavný pokles inflace. Metoda je znázorněna na obr. 3.1.. Gradualismus začíná mírným snížením tempa peněžního růstu, které posouvá křivku agregátní poptávky do polohy AD‘ a přemisťuje ekonomiku o nevelkou vzdálenost z bodu E do bodu E_1. Jako reakce na nižší míru inflace v bodě E_1 se agregátní nabídka AS posouvá dolů do polohy AS‘. Další malé snížení peněžního růstu přemisťuje ekonomiku do bodu E_2, křivka AS se opět posouvá dolů a celý proces pokračuje. Tento způsob snižuje míru inflace postupně dolů, přičemž se snaží, aby výstup neklesl příliš pod potenciální úroveň.

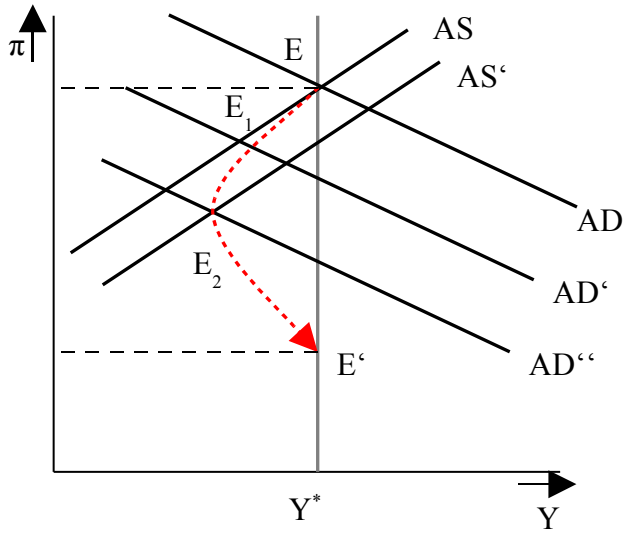

Obr. 3.1. Gradualismus

Metoda Cold Turkey

Jinak nazývána jako šoková terapie spočívá ve snaze o rychlé snížení míry inflace. Metoda je znázorněna na obr. 3.2. Začíná okamžitým prudkým snížením peněžního růstu, což posouvá agregátní poptávku z polohy AD do polohy AD‘ a přemisťuje ekonomiku z bodu E do bodu E_1. Vyvolaná recese (vzdálení výstupu od potenciálního produktu) je větší než při gradualismu. Bod E_1 šokové terapie představuje ovšem dosaženo nižší míru inflace, neb bod E_1 gradualismu. Znamená to, že pokles inflace je rychlejší při šokové terapii, než při gradualismu. Cenou, která se za to platí, je hlubší recese a vyšší nezaměstnanost.

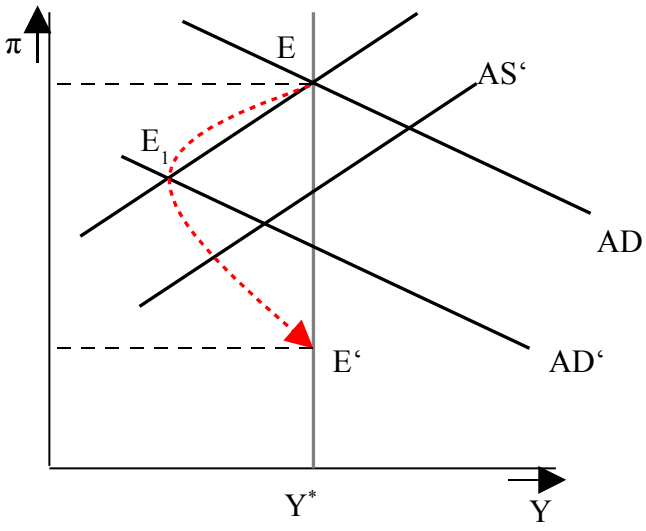

Obr. 3.2. Metoda Cold Turkey

3.2.2 Metody léčení nabídkové inflace

Obecně řečeno [8] spočívá léčba nabídkové inflace v tom, že se zeslabují, resp. odstraňují příčiny nepříznivých nabídkových šoků (lze-li je oslabovat či odstranit) a vláda usiluje o formování a uvádění pozitivních nabídkových šoků. Příznivé nabídkové šoky jsou takové faktory, jako např. předstih růstu produktivity práce před mzdami, snížení relativních cen některých druhů zboží a služeb např. v důsledku apreciace měnového kurzu, snížení nepřímých daní, kontrola cen a mezd, snížení relativních cen některých druhů zboží a služeb v důsledku pronikavých technologických objevů, jež vyvolávají výrazný růst produktivity při výrobě zboží a služeb aj.

3.2.3 Důchodové politiky a léčení inflace

Léčení inflace decelarací míry růstu agregátní poptávky je velmi nákladné a přináší recesi s poklesem produkce a zaměstnanosti. V teorii i praxi jsou proto hledány metody léčby inflace, které by mohly řešit problém dezinflace bez nezbytných průvodních nákladů, tj. recese a růstu nezaměstnanosti. Tyto politiky se nazývají důchodové politiky a zahrnují kontrolu mezd a cen, a to buď metodou vládního nařízení (zmrazení mezd a cen) nebo metodou, kdy vláda přesvědčuje představitele zaměstnanců (odbory) a zaměstnavatele (firmy), aby udrželi míru růstu mezd na určité přijatelné úrovni.

Dosavadní zkušenosti s kontrolou cen a mezd nejsou pozitivní, protože zmrazení mezd a cen vyřazuje v tržní ekonomice klíčový mechanismus alokace zdrojů. Změny relativních cen jsou klíčovým mechanismem efektivní alokace zdrojů.

Kromě toho pokusy kontrolovat ceny a mzdy, případně dočasné zmrazení cen a mezd, není pro samotné firmy přijatelné. Tyto pokusy měly obvykle krátké trvání. Klíčovou otázkou je, zda budou tyto kontroly mezd a cen a jejich efekty na snížení cenové hladiny vnímány hospodářskými subjekty jako trvalé, aby tak tyto subjekty přizpůsobily svá očekávání inflace (tj. snížily míru očekávané inflace), jíž zabudování do hospodářských institutů (do mezd, úrokových sazeb aj.). Pokud by tato politika byla dlouhodobá a byla by hospodářskými subjekty vnímána jako dlouhodobá, v důsledku snížení míry očekávané inflace by došlo k posunu křivky krátkodobé agregátní nabídky doprava a dolů, což by mělo, při dané křivce agregátní poptávky, vést ke snížení míry skutečné inflace a případně i k růstu produkce. Podmínkou tohoto však zároveň je, aby efekt kontroly cen a mezd byl doprovázen adekvátně sníženou (resp. nezvýšenou) mírou agregátní poptávky. Není-li

kontrola cen a mezd doprovázena snížením míry růstu agregátní poptávky a nebo dokonce dojede ke zvýšení míry růstu agregátní poptávky, efekt kontroly cen a mezd je tímto aktem částečně či úplně paralyzován.

3.3 Shrnutí kapitoly

V první části kapitoly jsou obecně popisovány metody protiinflační politiky – důchodová politika, zvyšování konkurenceschopnosti trhu a opatření fiskální, monetární politiky. Kapitola obsahuje také způsoby léčení inflace a jejich podrobnější specifikace. Podrobněji jsou definovány metody dezinflace – gradualistická metoda a metoda Cold Turkey. V závěru této kapitoly jsou popisovány metody léčení nabídkové inflace a důchodová politika.

4 Metody předzpracování časových řad

V kapitole jsou definovány základní pojmy z teorie zpracování časových řad, jejich vlastnosti a způsoby dělení. Dále se zde uvádí způsob dekompozice časových řad a jsou definovány jejich jednotlivé složky. Jsou zde zahrnuty způsoby vyrovnávání trendové složky časové řady, podrobně se uvádějí metody, kterými lze tohoto vyrovnání dosáhnout, způsob jejich použití a jejich zhodnocení.

4.1 Časové řady – základní pojmy

Jedním z důležitých úkolů statistický analýz ekonomických jevů je zkoumání jejich dynamiky. Empirická pozorování v ekonomické oblasti jsou často uspořádána do časové řady. Ekonomickou časovou řadou se rozumí řada hodnot jistého věcně a prostorově vymezeného ukazatele, která je upořádána v čase směrem od minulosti do přítomnosti.

Srovnatelnost údajů

Dříve než se začínají analyzovat časové řady, je nutné zajistit srovnatelnost údajů a to z hlediska věcného, prostorového, časového a cenového. U věcné srovnatelnosti [9] je třeba brát v úvahu, že často stejně nazývané ukazatele nemusí být vždy stejně obsahově vymezené. Mění-li se během času obsahové vymezení ukazatele, jsou údaje časové řady nesrovnatelné, např. jistý výrobek během let zastarává a nelze tedy srovnávat produkci v delší časové řadě. K věcné nesrovnalosti dochází také, pokud se časem mění způsob zjišťování ve vykazujících jednotkách, či dojde k použití jiné cenové hladiny. Prostorová srovnatelnost je možnost používat údaje v časových řadách, vztahující se ke stejným geografickým územím. Někdy se však nemusí jednat jen o čistě geografický problém. Odlišný ekonomický prostor totiž může vzniknout také změnou organizační struktury vykazujících jednotek, např. sloučením pracovišť, kapitálovým vstupem zahraniční firmy apod. Časová srovnatelnost údajů je problémem zejména u intervalových ukazatelů časových řad, tj. u ukazatelů, jejichž velikost závisí na délce intervalu. Problémem bývá i cenová srovnatelnost údajů v ekonomické časové řadě. V zásadě je možné pro sestavení delší časové řady postupovat dvojím způsobem. Použitím běžných (tj. aktuálních) cen a vyjádřit v nich nominální hodnotu určitého ukazatele, resp. tempa růstu, nebo vycházet ze stálých cen (cen fixovaných k určitému datu) a takto sestavit časovou řadu reálných hodnot ukazatele (nebo časovou řadu temp růstu ze stálých cen).

Všechny časové řady [10] se dělí na dva základní typy. Časové řady stochastické a deterministické. Deterministické časové řady v sobě neobsahují žádný náhodný prvek. Při znalosti toho, jak jsou generovány, se mohou dokonale a bezchybně předpovídat. Příkladem deterministické časové řady je třeba posloupnost hodnot funkce sinus. Naproti tomu stochastické časové řady (jako realizace náhodného procesu) v sobě prvek náhodnosti obsahují. Většina ekonomických časových řad jsou stochastické. Dalším způsobem dělení časových řad je dělení podle jejich povahy na ekvidistantní a neekvidistantní. Ekvidistantní znamená, že časová vzdálenost mezi sousedními prvky řady je konstantní. Tato vzdálenost se časté označuje jako krok. Práce s neekvidistantními časovými řadami je poněkud složitější, protože se musí provádět korekce kvůli proměnlivé délce kroku. Ale většina ekonomických časových řad jsou svou povahou spíše ekvidistantní. Podle časového hlediska se časové řady dělí na intervalové (pohyblivé) a okamžité (stálé). V intervalových časových řadách jsou údaje získávány za určitý časový interval. Jsou to soubory událostí vzniklých během daného období (počet narozených dětí, počet uzavřených sňatků, produkce za určitý časový úsek apod.). Údaje tohoto typu lze sčítat. Okamžité časové řady jsou sestavovány z údajů, které mají určitou dobu setrvání (např. délka lidského života, doba uložení výrobku ve skladu, apod.). Lze je tedy zjišťovat k určitému časovému okamžiku (např. k určitému dni). Tyto údaje nemá smysl sčítat. Srovnávají se pomocí chronologických průměrů. Z hlediska periodicity se časové řady dělí na dlouhodobé (roční) a krátkodobé (čtvrtletní, měsíční aj.). U obou typů se mohou sledovat rozdílené faktory. U krátkodobých časových řad jsou to sezónní vlivy, u dlouhodobých spíše existence dlouhodobých trendů. Důležitý je také rozdíl mezi časovými řadami v naturálním a peněžním vyjádření. Zatímco u peněžně oceněné produkce se musí často provádět očištění od inflace, u naturálního vyjádření to není nutné (někdy je ovšem nutné provést očištění od vlivů změn kvality). Známé je dělení časových řad na řady absolutních ukazatelů a odvozených charakteristik. Časové řady absolutních ukazatelů je původní řada, tak jak vznikla pozorováním nebo měřením např. měsíční časová řada produkce průmyslového podniku. Časové řady odvozených charakteristik je naproti tomu nějakým způsobem transformována, např. na časové řady průměrných produkcí na jednoho zaměstnance.

4.2 Analýzy časových řad

Jedná se o široké spektrum různých metod [10] s odlišným použitím. Volba metody analýzy závisí především na jejím účelu a využití, typu časové řady, zkušenosti statistika, dostupném softwarovém vybavení, výchozí teoretické koncepci a podobně.

Expertní (kvalitativní) metody jsou vhodným nástrojem všude tam, kde není možné rozumně kvantifikovat sledované veličiny nebo vlivy, které působí na jejich vývoj. Ukazuje se, že pro dlouhodobé předpovědi vykazují velmi dobré výsledky. Jsou ovšem poměrně náročné a nákladné. Mezi hlavní kvalitativní metody patří Delphi metoda, metoda historické analogie, dotazování zákazníků, dotazování prodejců poslední instance, apod.

Grafické metody analýzy časových řad jsou asi nejjednodušším způsobem analýzy. Vychází se z časové řady, reprezentované grafem.V takovém grafu se potom např. hledá trend – buď zcela subjektivně, nebo některou z poněkud formalizovanějších metod, např. proložení trendem. Jinou možností je vyhledávání obrazců (Patterns). Tato metoda je jedním ze základních kamenů technické analýzy akcií. Pokud se analytikovi podaří v časové řadě objevit započatou formaci, má velkou šanci správně předpovědět budoucí vývoj sledované veličiny. Poměrně užitečné srovnávat graf časové řady se známými informacemi o vývoji relevantních veličin nebo porovnávat grafy různých časových řad mezi sebou, a tak se snažit odhadnout vliv vstupů na vývoj námi sledovaného ukazatele, popřípadě i zpoždění mezi vstupy a tímto ukazatelem.

Dekompozice časových řad vychází z předpokladu, že náhodný proces, který generuje časovou řadu, je závislý pouze na čase. Dále se předpokládá, že časovou řadu je možné rozdělit na několik nezávislých složek. Tento rozklad se provádí proto, že je snazší identifikovat postupně chování jednotlivých složek než chování celé řady naráz. Časovou řadu tedy tvoří trend, sezónní, cyklická a náhodná složka.

Box-Jenkinsovská metodologie staví na rozdíl od metod dekompozice na analýze náhodné složky, která může být tvořena korelovanými (tj. závislými) veličinami. Právě v této korelační analýze spočívá jádro Box-Jenkinsovských metod. Jde tedy o to, vyšetřit vzájemnou závislost jednotlivých prvků řady s různým zpožděním a závislost na různě zpožděném (náhodném) vstupu. Základní modely se konstruují přímo z dat, na rozdíl od dekompozičních metod.

Lineární dynamické a regresní modely představují kauzální modely, kde je vysvětlovaná proměnná vysvětlována pomocí jedné nebo více vysvětlujících proměnných. Snahou je tedy odhalit příčinné vazby mezi ekonomickými veličinami. Většinou se předpokládají lineární nebo linearizované závislosti mezi proměnnými. Např. při modelování inflace může být vysvětlovanou proměnnou cenová hladina P, vysvětlujícími proměnnými reálný HDP Y a množství peněz v oběhu M. Modely se konstruují na základě teoretických předpokladů. Lineární dynamické modely se používají v ekonometrii.

Spektrální analýza je také nazývána analýza ve spektrální doméně. Spektrální analýza vychází z předpokladu, že časová řada je nekonečnou směsí sinusových a kosinusových křivek s různými frekvencemi a amplitudami. Analýza usiluje o to, aby vyšetřila spektrum řady (tj. zjistila intenzitu zastoupení jednotlivých frekvencí a jejich parametrů v časové řadě). Pomocí spektrální analýzy se také často posuzuje zpoždění ve vývoji mezi dvěma veličinami.

4.3 Dekompozice časové řady

Dekompozice [10] časových řad vychází z předpokladu, že náhodný proces, který generuje časovou řadu, je závislý pouze na času. Dále se předpokládá, že časovou řadu je možné rozdělit na několik nezávislých složek. Tento rozklad se provádí proto, že je snazší identifikovat postupně chování jednotlivých složek než chování celé řady najednou. Časovou řadu tvoří trend, sezónní, cyklická a náhodná složka. Trend, sezónní a cyklická složka jsou souhrnně nazývány systematickou složkou. Dekompozice časové řady klade důraz právě na analýzu systematické složky. Náhodná složka je poněkud opomíjena. Jednotlivá pozorování se považují za nezávislá.

Trendová složka (T_t) [11] zachycuje dlouhodobé změny v chování časové řady. Zachycuje tedy dlouhodobý růst či dlouhodobý pokles. Trend vzniká důsledkem působení faktorů, které působí stejným směrem (např. technologie výroby, demografické podmínky, podmínky na trhu apod.). Jestliže hodnoty ukazatele dané časové řady v průběhu sledovaného období kolísají (oscilují) kolem určité úrovně, pak se jedná o časovou řadu bez trendu. Trend lze většinou popsat matematickou funkcí v celé délce časové řady. Při popisu trendu tedy nejde o to, zda časová řada krátkodobě klesá či roste, ale jde skutečně o zachycení tendence pohybu časové řady.

Sezónní složka (S_t) [10, 12] popisuje periodické změny v časové řadě (pravidelně se opakující odchylka od trendové složky), které se odehrávají v rámci jednoho kalendářního roku a každý rok se opakují. Nejčastěji se pozoruje sezónnost u čtvrtletních a měsíčních časových řad. Dalšími důvody mohou být pravidelně se opakující svátky, různé délky jednotlivých měsíců nebo lidské zvyky zakotvené institucionálně v ekonomické aktivitě.

Cyklická složka (C_t) popisuje [12] dlouhodobé fluktuace kolem trendu. Zachycuje tedy dlouhodobou fázi poklesu či růstu, která je mnohem větší než jeden rok. U ekonomických řad je cyklická složka často spojována se střídáním hospodářských cyklů. Cykly jsou v ekonomických časových řadách způsobeny ekonomickými i neekonomickými faktory. Protože působí dlouhodobě, je velmi obtížné ji vysledovat a popsat. Perioda cyklické složky se může pohybovat v násobcích let a proto pokud je k dispozici krátká časová řada, nemusí být cyklická složka vůbec rozeznatelná. Navíc se charakter této složky může v čase měnit. Někdy nebývá cyklická složka považována za samostatnou složku časové řady, ale je zahrnována pod složku trendovou jako její část (tzv. střednědobý trend), vyjadřující střednědobou tendenci vývoje, která má často oscilační charakter s neznámou, zpravidla proměnlivou periodou.

Náhodná (reziduální) složka (ε_t) [11] je taková veličina, kterou nelze popsat žádnou funkcí času. Je to složka, která zbývá po vyloučení trendu, sezónní a cyklické složky. Zatímco první tři složky časové řady patří mezi systematické, náhodná složka je složka nesystematická a je tvořena náhodnými výkyvy časové řady. Pod tuto složku se mohou zařadit všechny vlivy, které na časovou řadu působí a které nelze systematicky podchytit a popsat. V aditivním [13] modelu se jednotlivé složky sčítají a pro hodnotu časové řady Y_t se pak může psát

$$Y_t = T_t + S_t + C_t + \varepsilon_t . \tag{4.1}$$

Jednotlivé složky jsou uvažovány ve svých skutečných napozorovaných hodnotách a jsou měřeny v jednotkách řady Y_t.

V multiplikativním modelu se jednotlivé složky násobí a pro hodnotu časové řady Y_t pak se může psát

$$Y_t = T_t \cdot S_t \cdot C_t \cdot \varepsilon_t . \tag{4.2}$$

V tomto modelu je uvažována ve své skutečně napozorované hodnotě pouze trendová složka a je tedy měřeny v jednotkách řady Y_t. Ostatní složky se většinou uvádějí v relativních hodnotách vůči trendu a jsou tedy bezrozměrné.

4.3.1 Adaptivní postupy modelování trendu

Někdy není možné vyrovnat časovou řadu [13] jednou trendovou funkci v celé délce řady. Bývá, ale možné popsat takovou řadu trendovou funkcí s proměnlivými parametry. To znamená, že časová řada se může vyrovnat jednou matematickou křivkou v krátkých úsecích, přičemž tato křivka má v různých úsecích odlišné parametry. Jedná se tedy o tzv. lokální modelování trendu (koncepci postupného trendu). Nelze tedy vyrovnat časovou řadu přímkou ve tvaru

$$\beta_0 + \beta_1 \tau \quad \text{pro } t=1,2,\ldots,T, \tag{4.3}$$

pro krátké úseky se středy v jednotlivých časových bodech t, lze ale použít vyrovnání pomocí lokálních trendů

$$\beta_0(t) + \beta_1(t)\tau \quad \text{pro } \tau = t - m, \ldots, t-1, t, t+1, \ldots, t + m. \tag{4.4}$$

Adaptivní jsou tyto metody nazýváno proto, že proces eliminace trendové složky se rychle přizpůsobuje okamžitému lokálnímu průběhu časové řady. Navíc lze stupeň tohoto přizpůsobení řídit vhodnou volbou parametrů. Do této kategorie patří především dvě metody - metoda exponenciálního vyrovnávání a metoda klouzavých průměrů.

4.3.2 Metoda klouzavých průměrů

Metoda klouzavých průměrů je adaptivní metoda přístupu k modelování trendové složky. Počítá se mezi nejjednodušší způsob vyrovnání časových řad, který odstraňuje sezónní vlivy. Je založena na předpokladu, že časová řada se může vyrovnat v krátkých úsecích jednou matematickou křivkou, ovšem s různými parametry. Podstata vyrovnání [14] pomocí klouzavých průměrů spočívá v tom, že posloupnost empirických pozorování se nahradí řadou průměrů vypočítaných z těchto pozorování. Každý z těchto průměrů reprezentuje určitou skupinu pozorování. Cílem vyrovnání časové řady je potlačení šumových složek. Velmi důležité je stanovení počtu pozorování, ze kterých se jednotlivé klouzavé průměry počítají. Tento počet se nazývá klouzavá část období interpolace a je označována p, pro výpočet je používán vztah $p = (2m + 1)$ pro $p < n$, kde n je počet pozorování analyzované řady.

Volba hodnoty *p* (délky klouzavého průměru) je velmi zásadní. Čím větší je *p*, tím větší je vyhlazení, ale tím více roste počet nevyrovnaných hodnot na konci a na počátku řady. U periodických řad je voleno *p* tak, aby se rovnalo periodě, takže lze z charakteru příčin periodického výkyvu často logicky odvodit vhodné *p*. Je možné předpokládat, že *m* je liché číslo, takže $p = (m-1)/2$ je číslo sudé. Středním bodem první klouzavé části je proto v pořadí *p+1* bod, protože před ním a za ním leží vždy *p* bodů analyzované body. Podobně poslední klouzavá část má střední bod s pořadovým číslem *n – p*. Jednoduché klouzavé průměry [14] jsou vlastně aritmetické průměry z původních hodnot časové řady. Předpokladem je, že se chce vyrovnat hodnota časové řady v bodě *t*. Potom tedy hodnotu v bodě *t* vyrovnává aritmetický průměr z okolních hodnot a z hodnoty v čase *t*. Potom se provede posun v časové řadě o jednu hodnotu doprava a vyrovnává se hodnota v čase *t+1* jako průměr z okolních hodnot a z hodnoty v čase *t+1*. Jednoduchý zápis výpočtu klouzavého průměru je možné vyjádřit takto

$$\hat{y}_{t,n} = \frac{y_{t-m} + y_{t-m+1} + \ldots + y_t + \ldots + y_{t+m-1} + y_{t+m}}{2m+1}, \tag{4.5}$$

kde $\hat{y}_{t,n}$ představuje hodnotu průměru v čase *t* za periodu *n*, *n* je délka periody a y_t je zjištěná hodnota v bodě *t*.

Vážené klouzavé průměry [15] zobecňují jednoduché klouzavé průměry tím, že průměrovaným hodnotám $y_{t-m}, y_{t-m+1}, \ldots, y_t, \ldots, y_{t+m}$ neudávají stejné váhy *1/(2m+1)* jako tomu je u jednoduchých klouzavých průměrů, ale váhy vhodným způsobem symetricky klesají od středu k oběma okrajům. Vážené klouzavé průměry vyrovnávají hodnotu časové řady v bodě *t* váženým průměrem. Například, vážený klouzavý průměr pro n = 5 se vypočítá podle vztahu

$$\hat{y}_{t,5} = \frac{1}{35}\left(-3y_{t-2} + 12y_{t-1} + 17y_t + 12y_{t+1} - 3y_{t+2}\right). \tag{4.6}$$

Konstrukce jednotlivých vah je velmi často založena na prokládání pozorování vhodnými křivkami pomocí metody nejmenších čtverců. Základní vlastnosti vážených klouzavých průměrů jsou [16] :

- Součet vah je roven jedné (aplikuje se totiž klouzavý průměr na časovou řadu konstantních hodnot, pak vyrovnanou hodnotou musí být opět původní konstanta).
- Váhy jsou symetrické kolem prostřední hodnoty.

V tab. 1 jsou uvedeny váhy klouzavých průměrů 2. až 5. řádu a různých délek. Vzhledem k symetrii klouzavých průměrů je uvedena vždy jen polovina vah včetně prostřední váhy.

Tab. 1 Přehled vah pro různé délky klouzavých průměrů a různé řády polynomů

	2. a 3. řád	4. a 5. řád
	(0, 1, 0)	(0, 1, 0)
	$\frac{1}{35}$(-3, 12, 17, ...)	(0, 0, 1, ...)
	$\frac{1}{21}$(-2, 3, 6, 7, ...)	$\frac{1}{231}$(5, -30, 75, 131, ...)
	$\frac{1}{231}$(-21, 14, 39, 54, 59 ,...)	$\frac{1}{429}$(15, -55, 30, 135, 179, ...)
	$\frac{1}{429}$(-36, 9, 44, 69, 84, 89, ...)	$\frac{1}{429}$(18, -45, -10, 60, 120, 143, ...)
	$\frac{1}{143}$(-11, 0, 9, 16, 21, 24, 25, ...)	$\frac{1}{2431}$(110, -198, -135, 110, 390, 600, 677, ...)

Mezi vážené klouzavé průměry patří také i tzv. trojúhelníkový klouzavý průměr, jehož váhy rostou vždy o jedničku směrem k prostřední hodnotě a jsou symetrické kolem této prostřední hodnoty. Největší váhu mají tedy data ležící uprostřed periody délky *n*. Směrem do minulosti i do přítomnosti váha dat lineárně klesá. Například, trojúhelníkový klouzavý průměr pro n = 5 se vypočítá podle vztahu

$$\hat{y}_{t,5} = \frac{1}{9}\left(y_{t-2} + 2y_{t-1} + 3y_t + 2y_{t+1} + y_{t+2}\right). \tag{4.7}$$

V praxi je často nutné provést průměr přes sudý počet pozorování. Centrované klouzavé průměry jsou vážené průměry se speciálně zvolenými váhami tak, aby eliminovaly z časové řady sezónní složku. Oproti předcházejícím klouzavým průměrům, které používají liché *p*, centrované klouzavé průměry používají sudé *p,* tj. $p = 2m$. Centrovaný klouzavý průměr lze vypočíst jako průměr ze dvou sousedních klouzavých

průměrů, nebo pro 2*m* členů jako vážené klouzavé průměry pro 2*m*+1 členů, kdy první a poslední člen se počítá s vahou 1, ostatní s vahou 2 a kde součet vah je 4*m*, tedy

$$\hat{y}_t = \frac{y_{t-m} + 2y_{t-m+1} + \ldots + 2y_t + \ldots + 2y_{t+m-1} + y_{t+m}}{4m}. \tag{4.8}$$

Hodnota je vynášena na konec období *t*, první klouzavý průměr je počítán ke konci období *m+1*, poslední k období *n-m*.

4.3.3 Exponenciální vyrovnávání

Exponenciální vyrovnávání [16] je dalším adaptivním přístupem k trendové složce, který se v praxi často používá. V případě klouzavých průměru je snaha vyrovnávat v časové řadě polynomickými křivkami krátké úseky, jejichž vhodná délka je často problematická a určená subjektivně. Metoda exponenciálního vyrovnávání [17] je založena na všech předchozích pozorováních, přičemž jejich váha (*w*) směrem do minulosti klesá podle exponenciální funkce

$$w_t = (1-\alpha)\cdot\alpha^{n-t}, \tag{4.9}$$

kde *n* je počet pozorování a α je vyrovnávací konstanta v intervalu (0;1).

K velmi ceněným vlastnostem těchto metod patří jejich rekurentnost. Při dodání nového pozorování lze jeho vyrovnanou hodnotu zkonstruovat snadnou korekcí předchozí vyrovnané hodnoty.

Při jednoduchém exponenciálním vyrovnávání se předpokládá, že trend se v krátkém období vyvíjí zhruba konstantně. U časových řad, které jsou ve tvaru $y_t = Tr_t + E_t$, lze v případě konstantního trendu nahradit trendovou složku (*Tr*) konstantou $Tr_t = \beta_0$. Je třeba nalézt odhad parametru β_0, který se v tomto případě rovná vyrovnané hodnotě $\hat{y}$. Vyrovnaná časová řada se vypočítá podle následujícího rekurentního vztahu

$$\hat{y}_t = (1-\alpha)\cdot y_t + \alpha\cdot\hat{y}_{t-1}. \tag{4.10}$$

Pokud se *α* blíží k hodnotě 1, tak roste vliv minulých pozorování. Výše uvedený vztah lze přepsat i do následujícího tvaru [17]

$$\hat{y}_t = \hat{y}_{t-1} + (1-\alpha)\cdot(y_t - \hat{y}_{t-1}), \tag{4.11}$$

který vysvětluje vytváření nové vyrovnané hodnoty z předchozí vyrovnané hodnoty, opravenou o chybu danou rozdílem mezi skutečnou a předcházející vyrovnanou hodnotou.

Dvojité exponenciální vyrovnání se používá v případě, kdy v krátkých úsecích řady lze trendovou složku Tr_t považovat za lineární a lze vyrovnat přímkou. Tedy

$$Tr_t = \beta_0 + \beta_1 t . \tag{4.12}$$

Odhadují se parametry β_0 a β_1. Jejich odhady jsou označeny $b_0(t)$ a $b_1(t)$. Při odhadu v časovém bodě t se bude vycházet z minimalizace výrazu

$$\sum_{j=0}^{\infty} \left[y_{t-j} - (\beta_0 + \beta_1(-j))\right]^2 \alpha^j , \tag{4.13}$$

kde α je opět vyrovnávací konstanta, pro kterou platí $0 < \alpha < 1$.

4.4 Shrnutí kapitoly

V první části kapitoly je definovaná časová řada, jsou vymezeny pojmy věcná, prostorová, cenová a časová srovnatelnost údajů v časové řadě. Dále je zde uvedeno jakým způsobem se dělí časové řady ekonomických ukazatelů. V další části je popisována dekompozice časové řady na jednotlivé její složky (trendová, sezónní, cyklická a náhodná složka). V poslední části kapitoly jsou uvedeny adaptivní přístupy k modelování trendové složky časové řady. Také jsou ukázány metody klouzavých průměrů a exponenciálních vyrovnání.

5 Neuronové sítě

Kapitola vymezuje základní pojmy NS (neuronových sítí) jako je neuron, vstupy NS, váhy a synapse, prahová hodnota. Popisuje architekturu a pracovní fáze NS. Další podkapitoly pojednávají o dopředných NS, perceptronových sítí spolu s jejich strukturou. Poslední podkapitola je zaměřena na frontální NS a popis filtru NS.

5.1 Základní pojmy z neuronových sítí

Neuron je základní výpočtovou jednotkou. Úlohou neuronu je vypočítat výstupní signál neuronu jako funkci vstupních signálů, které skrz synapse do neuronu vcházejí. Neuron je vybaven konečným počtem vstupů x_i, aktivační funkcí a jedním výstupem y_i (ten je množitelný do potřebného počtu kopií).

Vstupem do NS mohou být číselné i nečíselné parametry, v převážné většině se jedná o reálná čísla. V závislosti na konkrétní poloze neuronu v určité NS se vstupy dělí do dvou skupin. První skupinu tvoří výstupy z jiných, předcházejících (presynaptických) neuronů, druhou skupinu vstupů představují podněty z vnějšího okolí.

Vstupní vektor $X = (x_1, x_2, \ldots, x_n)$ představuje soubor konkrétních hodnot, které mohou být buď kvalitativní nebo v kvantitativní formě. Kvalitativně vyjádřené vstupní veličiny obvykle nabývají booleovských hodnot ve smyslu ano nebo ne. Každý vstup se váže k určité vlastnosti a konkrétní kvalitativní hodnoty vyjadřují, zdali tato vlastnost v systému existuje či nikoli. Kvantitativně je hodnota vstupní veličiny vyjádřena reálným číslem. Toto číslo představuje skutečné hodnoty měřených veličin.

Váhy synapsí ovlivňují jednotlivé vstupy do neuronů a tím i celou NS. Každý vstup do neuronu je ohodnocen určitou hodnotou příslušné váhy synapsí. Tato hodnota reprezentuje citlivost, s jakou příslušný vstup působí na výstup z neuronu. Váhy synapsí neuronu jsou vyjadřovány obvykle reálnými čísly, jejichž hodnoty vypovídají o průchodnosti (důležitosti) daného spojení. Váhy synapsí patří do skupiny parametrů, jejichž změnou je možné v procesu učení dosáhnout shody mezi výstupy zkoumaného procesu a výstupy NS. Právě výpočty aktuálních hodnot vah a jejich postupné ladění představují podstatnou část učících algoritmů NS.

Prahová hodnota neuronu znamená bariéru, kterou musí vstupní signál neuronu překonat, aby se mohl dál šířit NS. Hodnota prahu tedy určuje, kdy je neuron aktivní resp.

neaktivní. Je-li hodnota vstupního signálu neuronu nižší než hodnota prahová, je na výstupu z neuronu signál odpovídající pasivnímu stavu neuronu. Jakmile dojde k překročení prahové hodnoty, stává se neuron aktivním a výstupní signál z neuronu roste až do určité maximální hodnoty. Ta je dána oborem hodnot příslušné aktivační funkce. Práh obecně představuje bariéru na vstupu do neuronu z okolního světa, nikoliv z jiných neuronů.

Úkolem aktivační funkce neuronu je převést hodnotu vstupního potenciálu na výstupní hodnotu z neuron. Konkrétní tvary přenosových funkcí bývají různorodé. V principu se dají funkce rozdělit na lineární a nelineární, případně na spojité a diskrétní. Výběr vhodné přenosové funkce je závislý na konkrétním typu řešené úlohy. Výběr vhodné přenosové funkce také ovlivňuje náročnost technické realizace navržené NS. Nejčastější používané aktivací funkce jsou aktivační skoková funkce, lineární, po částech lineární funkce, sigmoidální, hyperbolicko-tangenciální nebo gaussovská funkce. Aktivační funkce transformuje hodnotu potenciálu neuronu na číslo z určitého intervalu. Nejčastěji je obor výstupních hodnot omezen intervalem <0,1> nebo <-1,1>.

Pod pojmem topologie (architektura) [23] NS se rozumí způsob uspořádání a pospojování neuronů v NS. Architektura sítě je dána typem a počtem neuronů, popř. typem jejich vzájemného propojení. Neurony mohou být uspořádány v několika vrstvách tak, že pouze jednotky v sousedních vrstvách propojeny, někdy mohou být přidána i horizontální propojení v rámci téže vrstvy. Důležitým a nejrozšířenějším typem NS jsou vrstevnaté sítě (Multilayer Network), v nichž jsou neurony umístěny v několika lineárně uspořádaných vrstvách tak, že každý neuron v předchozí vrstvě je propojen s každým neuronem v následující vrstvě, tzv. úplné propojení neuronů. V první tzv. vstupní vrstvě (Input Layer) jsou vstupní neurony, které identicky přenášejí jednotlivé složky vstupního vektoru. Poslední vrstva se nazývá výstupní vrstva (Output Layer) a vytváří finální výstup. Mezilehlým vrstvám se říká skryté vrstvy (Hidden Layer). Vstupní a výstupní vrstva jsou přesně určeny počtem a typem vstupních a výstupních proměnných modelovaného systému, počet skrytých vrstev a počet neuronů ve skrytých vrstvách však také není zcela libovolný. Velké počty neuronů ve skrytých vrstvách sice urychlují dobu učení, ale znesnadňují postup testování sítě (síť si mnoho pamatuje, ale málo zobecňuje). Je tedy nutné rozhodnout o počtu skrytých vrstev a neuronech ve skrytých vrstvách NS. Na určení konkrétního optimálního počtu neuronů ve skryté vrstvě jsou potřebné experimenty. Struktura NS se znázorňuje s využitím symboliky teorie grafů.

Rozlišují se dva typy architektury: cyklická (resp. rekurentní) a acyklická (resp. dopředná) síť. V případě cyklické topologie existuje v NS skupina neuronů, která je zapojena v kruhu (tzv. cyklus). To znamená, že v této skupině neuronů je výstup prvního neuronu vstupem druhého neuronu, jehož výstup je opět vstupem třetího neuronu atd., až výstup posledního neuronu v této skupině je vstupem prvního neuronu.

V acyklických sítích naopak cyklus neexistuje a všechny cesty vedou jedním směrem. U acyklické NS lze neurony vždy (disjunktně) rozdělit do tzv. vrstev, které jsou uspořádány (např. nad sebou) tak, že synapse mezi neurony vedou jen z nižších vrstev do vyšších a obecně mohou přeskočit jednu nebo více vrstev. Speciálním případem takové architektury je tzv. vícevrstvá NS. V této síti je nultá (dolní), tzv. vstupní vrstva tvořena vstupními neurony a poslední (horní), tzv. výstupní vrstva se skládá z výstupních neuronů. Ostatní, tzv. skryté (mezilehlé) vrstvy jsou složeny ze skrytých neuronů. V topologii vícevrstvé NS jsou neurony jedné vrstvy spojeny se všemi neurony bezprostředně následující vrstvy.

Pracovní fáze

NS pracuje ve dvou fázích – adaptivní a aktivní. V adaptivní fázi se NS učí, v aktivní vykonává naučenou činnost. Jde o proces vybavování.

Proces učení probíhá po specifikaci architektury NS a typu aktivační funkce. Pod pojmem učení se rozumí proces hledání vhodných hodnot volných parametrů NS, kterými jsou váhy synapsí. Dochází ke změnám v NS, při nichž se adaptuje na řešení daného problému. V praxi se váhy na počátku učení nastavují na určité defaultové hodnoty, buď podle přání uživatele nebo náhodně. Pak se přivede na vstup sítě trénovaní množina, které představuje množinu dvojic vstup – požadovaný výstup. Síť poskytne výstup, odezvu. Existují dvě skupiny metod učení, a to učení s učitelem a bez učitele.

Při učení s učitelem či též kontrolovaném učení (Supervised Learning) jsou síti postupně předkládány dvojice, vstup a informace učitele o tom, jak má síť na tento vstup zareagovat. Po předložení vstupu je vypočten skutečný výstup, který se porovná s požadovaným výstupem a učící algoritmus automaticky upraví hodnoty vah tak, aby rozdíl mezi skutečným a požadovaným výstupem byl minimální.

Metoda učení s učitelem je tzv. zpětné šíření chyby (Back Propagation). Je to metoda minimalizující součet čtverců chyb výstupních hodnot uvažované NS. Tento přístup lze

aplikovat na libovolnou NS. Ve většině případů se však používá na vrstevnaté NS s dopředným šířením signálu. Proces učení zpětným šířením lze rozdělit do tří částí:

-dopředné šíření signálu,

-zpětné šíření analýzy odpovídajících chyb,

-adaptování vhodných parametrů sítě.

Algoritmus Back Propagation je v podstatě gradientní metodou. Ta je založena na tzv. chybové funkci, která závisí na parametrech sítě. Během procesu učení se hledá takové nastavení vah, aby chyba sítě byla co nejmenší. Zpravidla se minimalizuje globální chyba sítě daná sumou čtverců žádaných a obdržených hodnot.

Při učení bez učitele či nekontrolovaném učení (Unsupervised Learning) jsou síti předkládány pouze vstupy, tzn. požadovaný výstup chybí a algoritmus učení je navržen tak, že hledá ve vstupních datech určité vzorky se společnými vlastnostmi. Ohodnocení vhodnosti vah probíhá buď na základě určitého kumulovaného kritéria po vypočítaní určité sekvenci vstupních signálů (sekvenční učení), nebo na základě kritéria nezávislém na typu řešeného problému, např. vytvoření určitého počtu tříd řešení. Učení bez učitele se také nazývá samoorganizace (Self-Organizing). Typický příklad samoorganizující se NS je Kohonenova mapa, která se využívá v klasifikačních úlohách.

Po úspěšném dokončení procesu učení je NS schopná s určitou přesností řešit typy problémů, na které byla naučená. Při aktivní fázi jsou zprácovávana vstupní data. Na základě vstupu dat vznikne ve vstupní vrstvě nerovnovážný stav. Výstupy neuronů ve všech vrstvách se začnou působením ostatních neuronů měnit podle jistého algoritmu a mění se, dokud opět nenastane stabilní rovnovážný stav. Na jejich výstupech je požadovaná odezva sítě na tento vstup.

5.2 Dopředné neuronové sítě

V případě, že se NS používá jako prediktor, je doporučeno mít ve skryté vrstvě minimálně o jeden neuron méně než ve vstupní. Jedním z typů vrstevnatých NS jsou NS s dopředným šířením signálu (Feed-Forward Neural Network), tzv. dopředné NS. Tyto NS jsou acyklickým typem sítí – nikdy nevzniká zpětnovazební smyčka. Neurony, z kterých synapse jen vystupují, tvoří vstupní vrstvu NS. Potenciál vstupních neuronů je zadaný uživatelem a neprochází skrz aktivační funkci. Neurony, které jsou propojené synapsemi, jež do nich vstupují a zároveň synapsemi, které z nich vystupují, tvoří skrytou vrstvu. Na

skrytých vrstvách se vypočítávají mezivýsledky řešení problému, které nejsou explicitně uvedené – jejich interpretace nemá smysl. Neurony, do kterých synapse jen vstupují, tvoří výstupní vrstvu sítě, zde dochází k výpočtu konečného výstupu NS.

Dopředné NS, při jejichž učení je využita metoda zpětného šíření chyby, patří mezi NS využívané jako klasifikátory a prediktory (rozdíl je v počtu výstupních neuronů). Příklad dopředné NS je na obr. 5.1.. Výstup dopředné NS lze vyjádřit [25] ve tvaru

$$Y = \sum_{k=1}^{K} \alpha_k \cdot d\left(\sum_{j=1}^{J} \beta_{jk} \cdot X_{jk} \right), \tag{5.1}$$

kde:

- Y je výstup NS,
- α je vektor vah synapsí mezi neurony ve skryté vrstvě a výstupním neuronem,
- β je vektor vah synapsí mezi vstupními neurony a neurony ve skryté vrstvě,
- k je index neuronu ve skryté vrstvě,
- d je aktivační funkce,
- j je index vstupního neuronu,
- X je vstupní vektor NS.

Dopřednou architekturu sítě mají perceptronové sítě, které se také nejčastěji používají pro predikci.

5.3 Perceptronové sítě

Perceptronové sítě (Multilayer Perceptron, MLP) využívají pevného počtu vrstev a neuronů v těchto vrstvách. Počet vstupů je záležitostí volby vhodného typu struktury modelu vstupů dle řešené problematiky. Topologie může být tvořena buď jedním výkonným prvkem – neuronem (jednoduchý perceptron) nebo více neurony (vícevrstvý perceptron). Základním výkonným prvek perceptronových sítí je obvykle základní model McCulloch-Pittsova neuronu, který má nastavitelné váhové koeficienty a nastavitelný práh.Učení perceptronu probíhá s učitelem. Požadovaná funkce NS je zadána trénovaní množinou ve tvaru dvojic vektorů – vektoru vstupních vzorů a vektoru požadovaných hodnot.

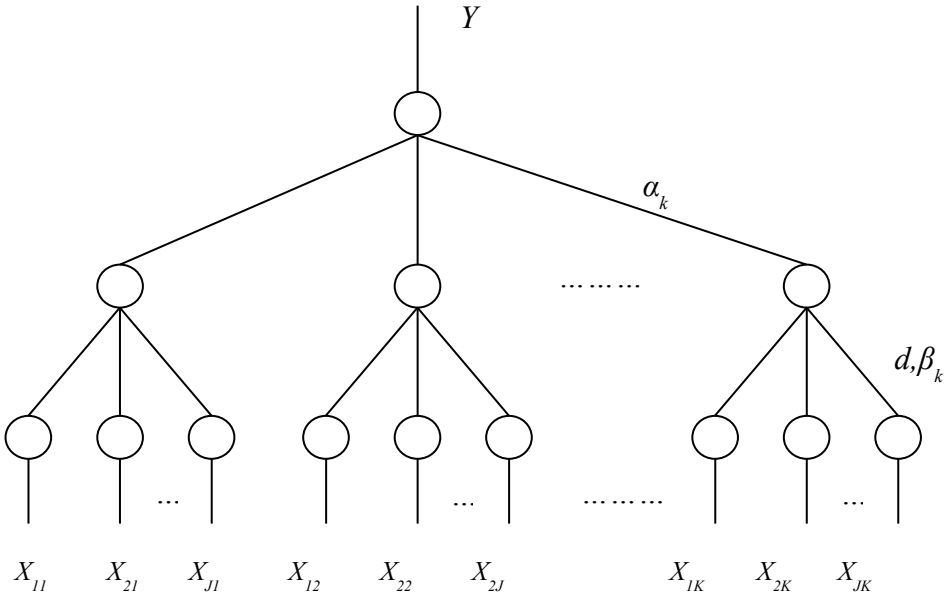

Obr. 5.1. Dopředná NS

Struktura sítě

Perceptronová síť obsahuje z hlediska struktury neurony – perceptrony, které jsou mezi sebou propojeny tak, že vytváří vrstevnatou síť. Perceptron je speciálním případem formálního neuronu představujícího obecný výpočet prvků všech NS, u něhož je vnitřní potenciál počítán jako vážený součet vstupů

$$\xi = \sum_{i=1}^{n} w_i x_i - \theta = \sum_{i=0}^{n} w_i x_i \tag{5.2}$$

a aktivační funkcí je diferencovatelná sigmoidální funkce

$$f(\xi) = \frac{1}{1+ e^{-\lambda \xi}}, \tag{5.3}$$

kde λ je parametr strmosti, jenž určuje míru změny nárůstu sigmoidální funkce v okolí počátku a většinou bývá stejný a pevný v rámci celé sítě. Jeho hodnota se obvykle pohybuje blízko jedné. Diferencovatelnost užité aktivační funkce a z ní plynoucí diferencovatelnost funkce sítě je podstatná pro učící algoritmus Back Propagation.

Perceptronová NS se skládá z několika vrstev perceptronů. Tyto jsou mezi sebou vzájemně propojeny tak, že výstup jednoho neuronu vrstvy je distribuován do vstupů všech

perceptronů následující vrstvy. Počty vrstev i počty perceptronů se odhadují pomocí heuristik. Pokud je počet perceptronů malý, sít nedokáže postihnout všechny závislosti v trénovacích datech. Pokud je naopak počet perceptronů velký, zvyšuje se doba učení a navíc vlivem nadměrného počtu trénovacích dat má síť špatnou schopnost generalizace způsobenou přeučením (Overfitting). Příklad uspořádání perceptronové sítě je uveden na obr. 5.2.

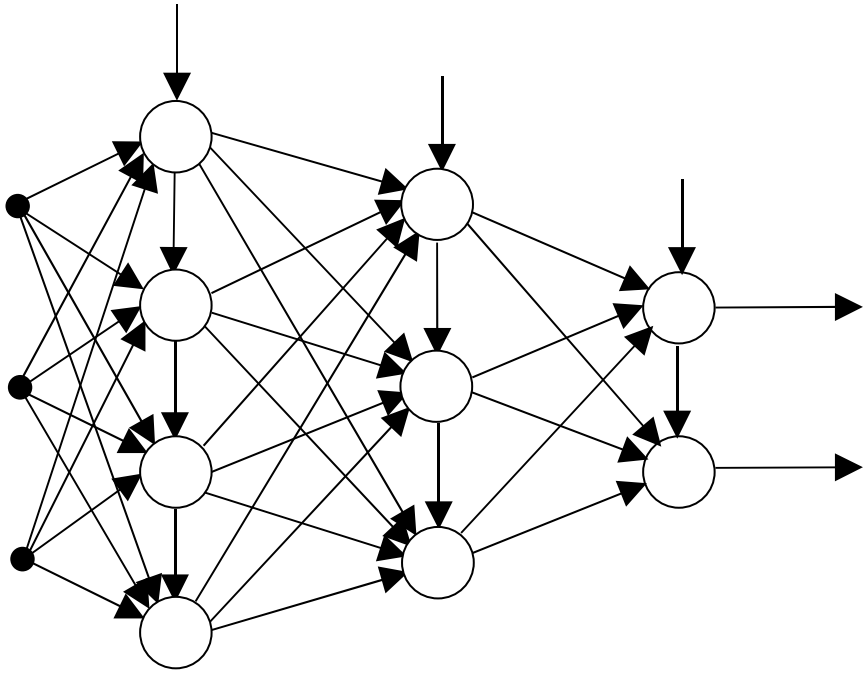

Obr. 5.2. Perceptronová síť

5.4 Frontální neuronová síť

Při zpracovávání posloupností údajů často vzniká situace, kdy jednomu vstupnímu vektoru odpovídá více možných výstupních vektorů, a to v závislosti od časového kontextu. Lze říci, že samotný výstup není závislý jen na vstupu, ale také na nějakém počtu předešlých vstupů. Je to určité rozšíření vícevrstvé dopředné NS. Jednoduché znázornění je na obr. 5.3.

Dá se říci, že frontální NS umožňují vícevrstvé dopředné NS „okno do minulosti“, tj. kromě momentálního vstupu (v čase t) „vidí“ svět i vstupy z minulých b kroků (v časech t-1, t-2,…, t-b). Kromě vstupního vektoru dostávají neurony na vstup i stav NS v minulém kroku (tj.výstupní aktivity všech neuronů). Okno [26] do minulosti má konečnou neměnnou délku *b*, dané okno je zobrazené na obr. 5.4.

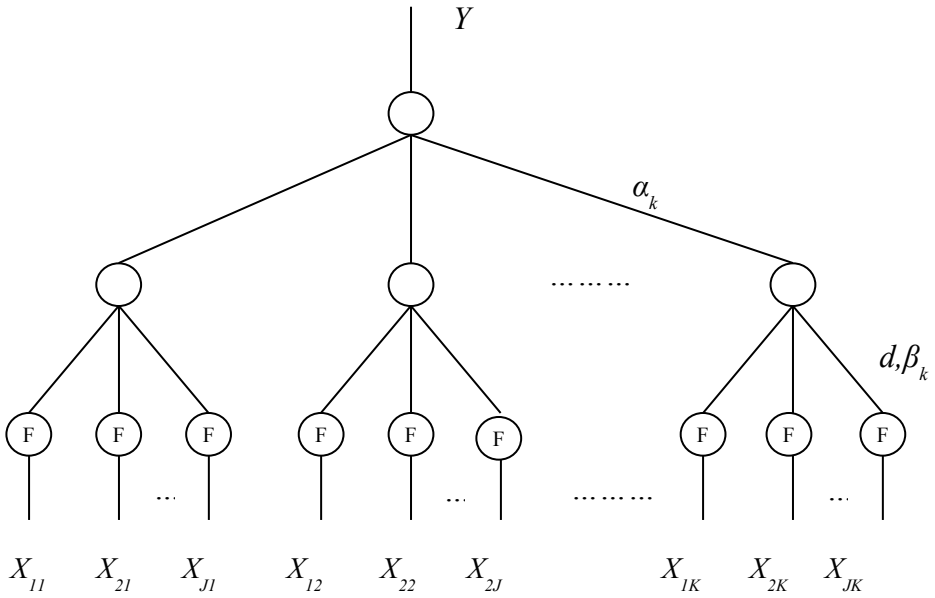

Obr. 5.3. Frontální NS

Ve frontálních NS je celá krátkodobá paměť situovaná na začátku NS, jako určitá předvrstva, která zpracovává časový kontext. Takovou NS je možné učit klasickou procedurou zpětného šíření chyb - Back-Propagation, přičemž je důležité zachovat pořadí trénovaných vzorek v trénovaní množině.

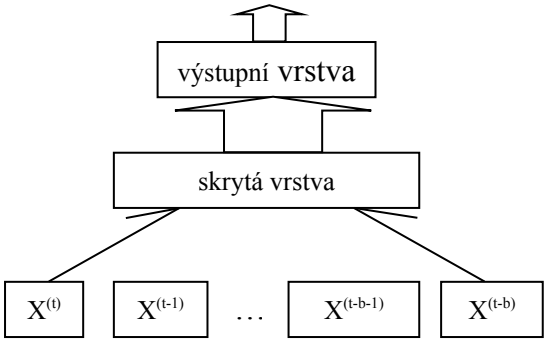

Obr. 5.4. NS s oknem do minulosti

Výstup frontální NS [25] se stejnou hloubkou paměti všech filtrů, lineárním filtrem a lineárním výstupním neuronem je možné vyjádřit následujícím způsobem

$$Y = \sum_{k=1}^{K} \alpha_k \cdot d\left(\sum_{j=1}^{J} \beta_{jk} \cdot \sum_{i=1}^{b} \chi_{ijk} \cdot X_{ijk} \right), \tag{5.4}$$

kde:

- Y je výstup NS,
- α je vektor vah synapsí mezi neurony ve skryté vrstvě a výstupním neuronem,

-β je vektor vah synapsí mezi filtry a neurony ve skryté vrstvě,

-χ je vektor vah synapsí uvnitř filtru,

-k je index neuronu ve skryté vrstvě,

-d je aktivační funkce,

-j je index filtru,

-i je index vstupu filtru,

-b je hloubka krátkodobé paměti filtru,

-X je vstupní vektor NS.

Na obr. 5.5. je zobrazen filtr frontální NS, kde $x(t)$ je hodnota vstupu filtru v čase t, b je hloubka paměti filtru, χ jsou váhy synapsí v rámci filtru, z^{-1} je operátor jednotkového časového zpoždění a $xf(t)$ je výstup filtru pro hodnotu vstupu v čase t.

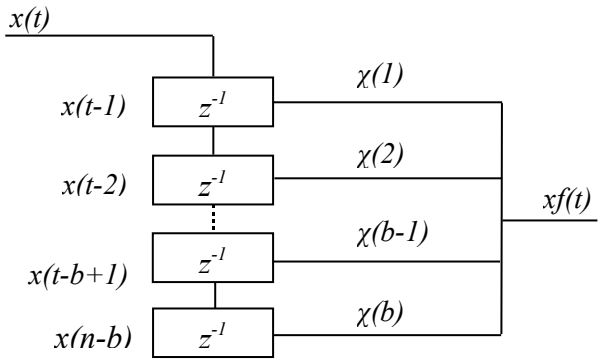

Obr. 5.5. Filtr frontální NS

5.5 Shrnutí kapitoly

Kapitola definuje základní poznatky o neuronech, je zde také specifikován základní vztah, vstupy do neuronu, váhy synapsí, práh neuronu, základní aktivační funkce neuronu. Kapitola uvádí základní rozdělení NS a jejich architekturu – cyklická a acyklická. Další část kapitoly se zaměřuje na pracovní fáze NS - adaptivní a aktivní fáze. Následně je definována dopředná neuronová síť, ve které nevzniká zpětná vazba, a je zde, vyjádřen i její výstup. V další podkapitole se uvádí popis perceptronové NS, která je často používána pro predikci. Poslední podkapitola je zaměřena na dopřednou NS, tzv. frontální, s jejím možným výstupem. V odborné literatuře se někdy vyskytuje i název TDNN (Time-Delay Neural Net). Je zde popsán i filtr frontální NS.

6 Návrh frontální neuronové sítě pro predikci vývoje inflace

Kapitola se zabývá navržením modelu predikce pomocí frontální NS. První podkapitola specifikuje jednotlivé fáze modelu. Další část se týká předzpracování dat potřebných pro modelování, ale také jejich analýzu. Následně je definován pojem filtru frontální NS a podle této hodnoty je navržena struktura NS. Kapitola také popisuje proces učení NS a poté jsou zobrazeny výsledky z prostředí Stuttgartského simulátoru.

NS mají výhodu v tom, že jsou schopny učit se na příkladech a po naučení jsou schopny vystihnout skryté i silně nelineární závislosti a to i za přítomnosti šumu v trénovací množině. Nevýhoda spočívá v tom, že se mohou naučit závislost platnou pouze v určitém období.

Modely NS jsou závislé na řadě faktorů. Patří k nim použitý typ NS, u stejného typu NS pak použitý počet vrstev a počet neuronů ve vrstvách. Výsledek učení NS ovlivňuje rovněž kvantitativní dělení množiny vstupních dat na trénovací a kontrolní množinu a rozdělení počtu prvků v těchto množinách

6.1 Model predikce

Základem modelu je vlastní sběr požadovaných dat z daného okolí, které budou následně využity pro predikci. Na kvalitě vstupních dat závisí výsledek navržené NS. Získaná data musí být vhodným způsobem předzpracovaná pomocí adaptivních metod (tj. klouzavé průměry, exponenciální vyrovnání). Pokud jsou data předzpracovaná, musí se nejprve stanovit filtr frontální NS. Daný filtr představuje tzv. „okno do minulosti“, jsou to hodnoty vstupů z předešlých kroků. Toto okno má pevně definovanou velikost. Podle velikosti filtru se následně odvíjí i struktura NS, hlavně to má vliv na počet neuronů ve skryté vrstvě. Po definování filtru a NS, je síť naučena pomocí trénovacích dat. Kontrola procesu učení se provádí pomocí testovacích dat. Po otestování NS je nutné provést analýzu získaných výsledků. Navrhnutý model je na obr. 6.1.

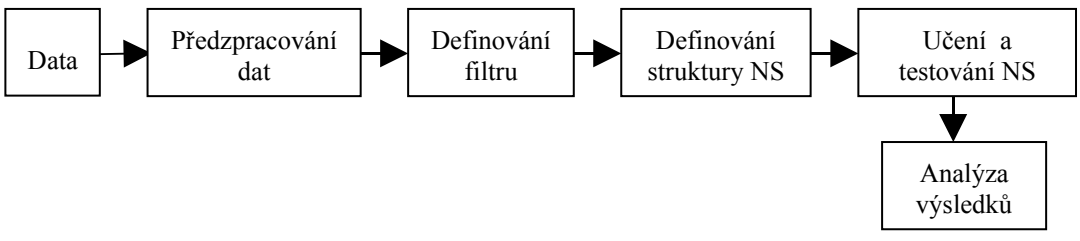

Obr. 6.1. Proces modelování

6.2 Předzpracování dat pro tvorbu neuronové sítě

Data, která budou následně využita pro tvorbu a testování NS, je nutné analyzovat a vhodně předzpracovat. Základní metody a postupy pro analýzu časových řad jsou uvedeny v kap. 4.2.

6.2.1 Analýza časové řady

Pro návrh frontální NS byly kromě časové řady míry inflace použity řady vývoje CPI a PPI, spolu s vývojem výše deflátoru. Dané hodnoty byly získány v období od ledna 1993 do prosince 2006. Časové řady byly získány za pomoci Českého statistického úřadu a ČNB. Časová řada vývoje míry inflace ČR od ledna roku 1993 do prosince roku 2006 (znázorněno na obr. 6.2.) je nestacionární časovou řadou. Dochází u ní ke změnám výše jednotlivých měsíčních hodnot a tyto změny mohou mít nesystematický náhodný charakter.

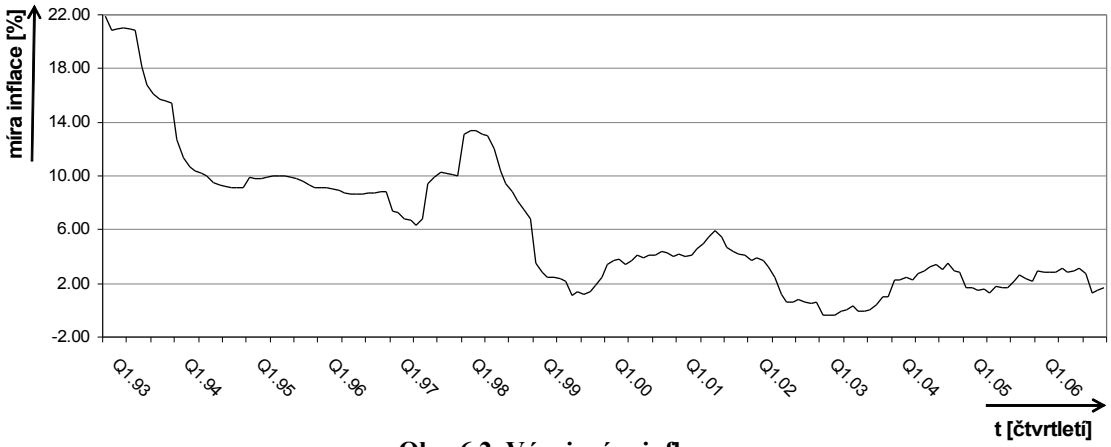

Obr. 6.2. Vývoj míry inflace

V roce 1993 byla zaznamenaná míra inflace vyšší, a to 20.8 %. Inflace v období 1994 – 1996 postupně klesala. V roce 1994 poklesla na 10%, v roce 1995 na 9.1% a v roce 1996 na 8.8%. Průměrná roční míra inflace, měřená spotřebitelskými cenami, činila v pětiletí 1993–1997 11.4 %. Toto snižování bylo způsobeno jednak menším převisem domácí poptávky na počátku transformace, jednak politikou pevného měnového kurzu v letech 1991–1997 a přísnější protiinflační politikou v průběhu transformace.

Zatímco v roce 1997 pokračoval pokles inflace - ta meziročně poklesla na 8.5%, v následujícím roce přesáhla 10%. Míra inflace za 12 měsíců roku 1998 proti průměru dvanácti měsíců roku 1997 činila 10.7 %. Průměrná míra inflace tak v roce 1998 dosáhla

nejvyšší hodnoty za posledních pět let, meziroční přírůstek indexu spotřebitelských cen v prosinci 1998 naopak hodnoty nejnižší. Tento rozdílný vývoj byl důsledkem výrazného cenového skoku již v lednu 1998 v kombinaci s mírným meziměsíčním poklesem cenové hladiny v jednotlivých měsících 4. čtvrtletí. Na snižování cenové hladiny působil zejména vývoj cen ve skupině potraviny, nápoje, tabák.

Vývoj inflace byl po roce 1998 ovlivněn tím, že ČNB si stanovila přijmout cílování inflace. Jako indikátor pro inflaci stanovila tzv. čistou inflaci, která je vyjádřena indexem spotřebitelských cen očištěným od vlivů administrativních změn cen a změn nepřímých daní. V roce 1999 došlo k mimořádnému průlomu v dezinflačním procesu, když se míra inflace z roku 1998 ve výši 10.7 % snížila na 2.1 % v roce 1999. Hlavním důvodem bylo přibrzdění deregulace cen usměrňovaných státem a pokles cen potravin.V roce 2000 prakticky dezinflační proces pokračoval a míra inflace dosáhla 3.9 %.

V roce 2001 míra inflace narůstala. Ve srovnání s rokem 2000 byl zaznamenán její nárůst ve výši 4.7 %. Na vzestup inflace působil především nárůst vyplývající z deregulace cen nájemného, elektřiny a plynu, dopravy, pošt a telekomunikací, výrazně se zvýšily i ceny potravin. Průměrná meziroční míra inflace v roce 2004 dosáhla 2.8 %, což je o 2.7 procentního bodu vyšší hodnota než v roce 2003, kdy byla míra inflace téměř nulová (0.1 %). V roce 2005 míra inflace dosáhla průměru 1.9 %, ale ke konci roku začala mírně růst a přesahovala přes 2 %, v roce 2006 také dochází k nárůstu a má hodnotu 2.5 % (nárůst je zaznamenán do 3. čtvrtletí roku a v posledním čtvrtletí dochází k poklesu).

6.2.2 Předzpracování dat

Získané údaje byly předzpracovány za pomoci základních metod a postupů pro analýzu časových řad uvedených v již zmíněné kap. 4.2. K vyhlazení časových řad byly tedy použity metody klouzavých průměrů, exponenciálního vyrovnávání, atd.

Metody klouzavých průměrů patří mezi nejjednodušší způsoby vyrovnání časové řady. Používají se k vyrovnání časové řady v krátkých úsecích pomocí matematických křivek. Jako vstupy do NS byly použity jednoduché klouzavé průměry délky 13, 11, 9, 7 a 5 pro jednotlivé řady. Klouzavý průměr délky 13 lze zapsat takto

$$\bar{y}_t = \frac{1}{13}\left(y_{t-6} + y_{t-5} + y_{t-4} + y_{t-3} + y_{t-2} + y_{t-1} + y_t + y_{t+1} + y_{t+2} + y_{t+3} + y_{t+4} + y_{t+5} + y_{t+6}\right). \quad (6.1)$$

Průběh původní časové řady vývoje deflátoru a vyrovnané časové řady pomocí jednoduchého klouzavého průměru délky 13 je znázorněn na obr. 6.3..

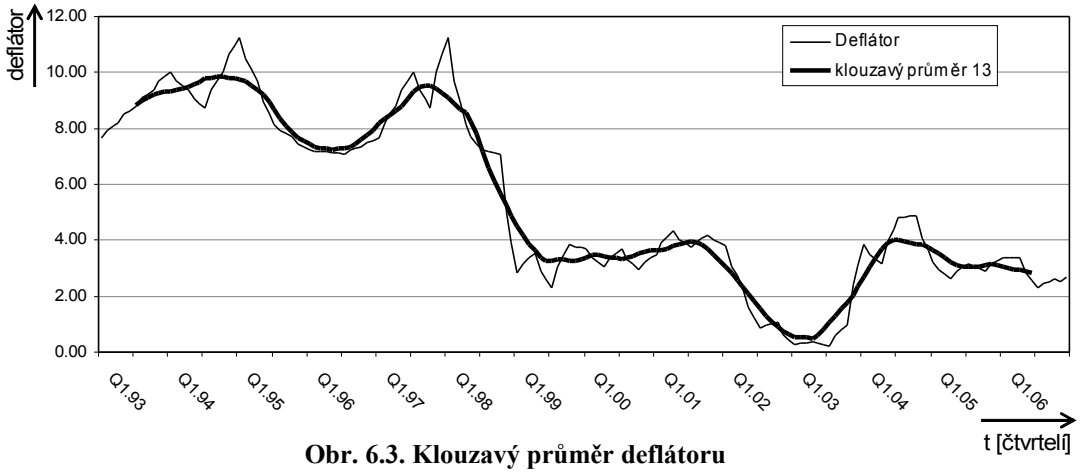

Obr. 6.3. Klouzavý průměr deflátoru

Spolu s prostými klouzavými průměry se jsou použity váhové klouzavé průměry, které vyrovnávají klouzavé části polynomickými křivkami. Jako vstup do NS byl použit váhový klouzavý průměr druhého (třetího) řádu a délek 13, 11, 9, 7 a 5. Váhový klouzavý průměr délky 13 je definován jako

$$\bar{y}_t = \frac{1}{143}\left(-11\cdot y_{t-6} + 0\cdot y_{t-5} + 9\cdot y_{t-4} + 16\cdot y_{t-3} + 21\cdot y_{t-2} + 24\cdot y_{t-1} + 25\cdot y_t + ...\right). \qquad (6.2)$$

Vzhledem k symetrii klouzavých průměrů je uvedena vždy jen první polovina vah včetně prostřední váhy. Na obr. 6.4. je vyobrazen konkrétní váhový klouzavý průměr délky 13 a řádu 2 (3) pro deflátor.

Obr. 6.4. Váhový průměr deflátoru

Jako další vstupy NS byly použity trojúhelníkové klouzavé průměry. V této práci byl použit průměr stejných délek jako předchozí klouzavé průměry. Trojúhelníkový klouzavý průměr délky 11 je možné ho zapsat pomocí vztahu

$$\bar{y}_t = \frac{1}{49}\left(y_{t-6} + 2\cdot y_{t-5} + 3\cdot y_{t-4} + 4\cdot y_{t-3} + 5\cdot y_{t-2} + 6\cdot y_{t-1} + 7\cdot y_t + ...\right). \quad (6.3)$$

Vyobrazení trojúhelníkového klouzavého průměru deflátoru délky 13 je nabr. 6.5..

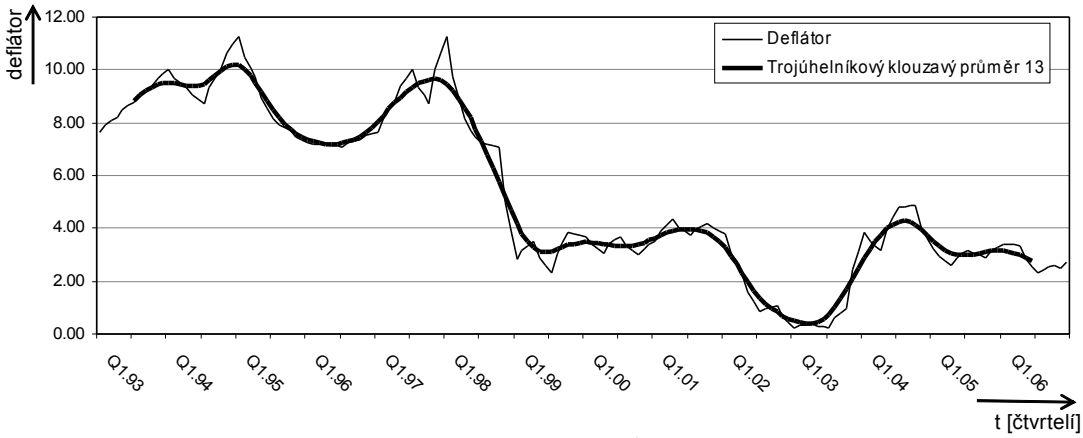

Obr. 6.5. Trojúhelníkový průměr deflátoru

Pro vyhlazení časový řad byla použita také metoda exponenciálního vyrovnávání. Při této metodě se vyrovnaná hodnota stanoví na základě exponenciálně váženého průměru současné hodnoty a všech předchozích hodnot časové řady. Přitom se používá systém koeficientů – vah, kdy novější hodnota má vždy větší váhu (tj. důležitost), než hodnota starší. Jednoduché exponenciální vyrovnávání bylo vypočítáno podle vztahů uvedených v kapitole Exponenciální vyrovnávání. Byla použita váha 0.8. Jako vstupy byly použity 13, 11, 9, 7 a 5 měsíční exponenciální vyrovnání. Vyrovnání časové řady vývoje deflátoru pomocí jednoduchého 13 měsíčního exponenciálního vyrovnávání je zobrazeno na obr. 6.6.

Klouzavý medián slouží k potlačení tzv. odlehlých pozorování, která vybočují za charakteru ostatních pozorování a mohou svou přítomností v časové řadě značně zkreslovat výsledky. Pro vstupy byl použit klouzavý medián kroku 13, 11, 9, 7 a 5. Vztah pro klouzavý medián kroku 13 je zapsán v tvaru

$$KM_{t,13} = med(y_{y-6}, y_{y-5}, y_{y-4}, y_{t-3}, y_{t-2}, y_{t-1}, y_t, ...). \quad (6.4)$$

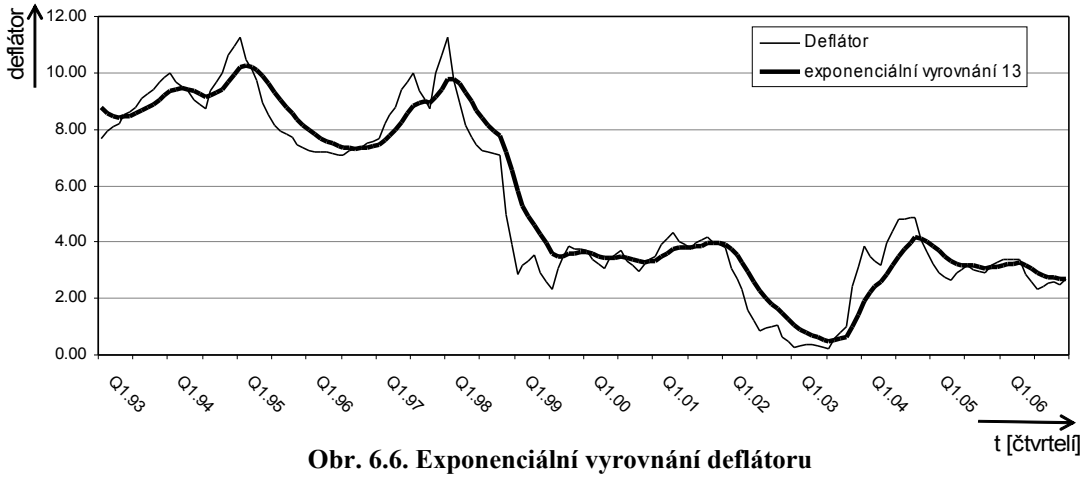

Obr. 6.6. Exponenciální vyrovnání deflátoru

Vyobrazení klouzavého mediánu je vidět na obr. 6.7.

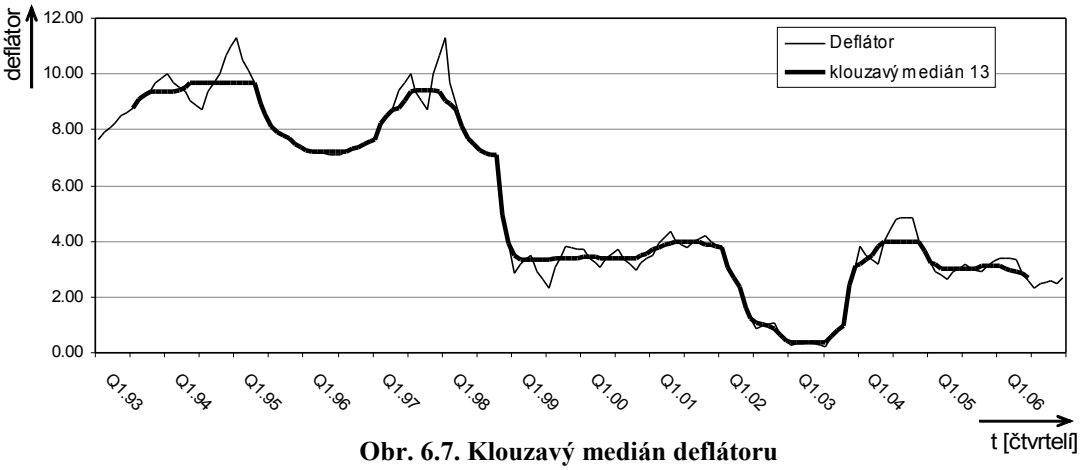

Obr. 6.7. Klouzavý medián deflátoru

6.3 Definování filtru

Délka filtru určuje velikost časového zpoždění, které reprezentuje počet minulých vstupů. Od velikosti filtru se následně odvíjí struktura NS. Pokud je počet vstupních neuronů do NS konstantní, mění se podle velikosti filtru počet neuronů ve skryté vrstvě. Při zvyšování délky filtru se NS lépe naučí a snižuje se střední čtvercová chyba. Tato chyba představuje kvalitu navrhnutého modelu. Je vypočítána při použití kontrolních dat v procesu učení. Střední čtvercová chyba je vypočtena podle vztahu

$$MSE = \frac{\sum_{p \in patterns} \sum_{j \in output} \left(t_{pj} - o_{pj}\right)^2}{n - a}, \tag{6.5}$$

kde t_{pj} je výstup procesu učení NS pro neuron j a vzor p, o_{pj} je skutečný výstup, n je počet vzorů a a je počet volných parametrů NS (tj. počet synapsí mezi neurony).

6.4 Návrh struktury neuronové sítě

Dále je navrhnuta frontální NS s filtrem délky 9 a strukturou, která obsahuje dvanáct vstupních neuronů, čtyři neurony ve skryté vrstvě a výstupní vrstva obsahuje jeden neuron. Struktura je znázorněna na obr. 6.8.. Vstupy do NS jsou zvoleny hlavní indikátory, které ovlivňují míru inflace, všechny indikátory jsou předzpracováni pomocí aditivních metod a jsou použity 13 měsíční trendové složky:

-jednoduchý klouzavý průměr deflátoru,

-jednoduchý klouzavý průměr CPI,

-jednoduchý klouzavý průměr PPI,

-váhový klouzavý průměr deflátoru,

-váhový klouzavý průměr CPI,

-váhový klouzavý průměr PPI,

-trojúhelníkový klouzavý průměr deflátoru,

-trojúhelníkový klouzavý průměr CPI,

-trojúhelníkový klouzavý průměr PPI,

-jednoduché exponenciální vyrovnání deflátoru,

-jednoduché exponenciální vyrovnání CPI,

-jednoduché exponenciální vyrovnání PPI.

Výstupem navrhnuté NS je procentuelní vyjádření míry inflace.

Trénovaní a testovací data jsou v poměru 90:66. Trénovaní data mají za úkol naučit danou NS a testovací množina dat se stará o určení, jak moc se síť naučila.

Pro učení frontální NS je použit učící algoritmus zpětného šíření chyby TimeDelayBackprop, což je modifikovaný algoritmus Backpropagation pro frontální NS. Tento druh algoritmu se nejčastěji používá pro predikci. Algoritmus má nastavitelnou dvojici parametrů:

-η je parametr učení, učící koeficient (délka kroku), který určuje rychlost učení. Čím je délka kroku nastavena na vyšší hodnotu, tím je proces učení rychlejší. Pro tento návrh je zvolena hodnota parametru η = 0.01.

-d_{max} je maximální rozdíl mezi učící hodnotou a výstupní hodnotou výstupního neuronu, který je tolerován, tzn. který je možné zpětně šířit. Typické hodnoty d_{max} jsou 0, 0.1, 0.2. Pro tento návrh je zvolena hodnota parametru d_{max} = 0.

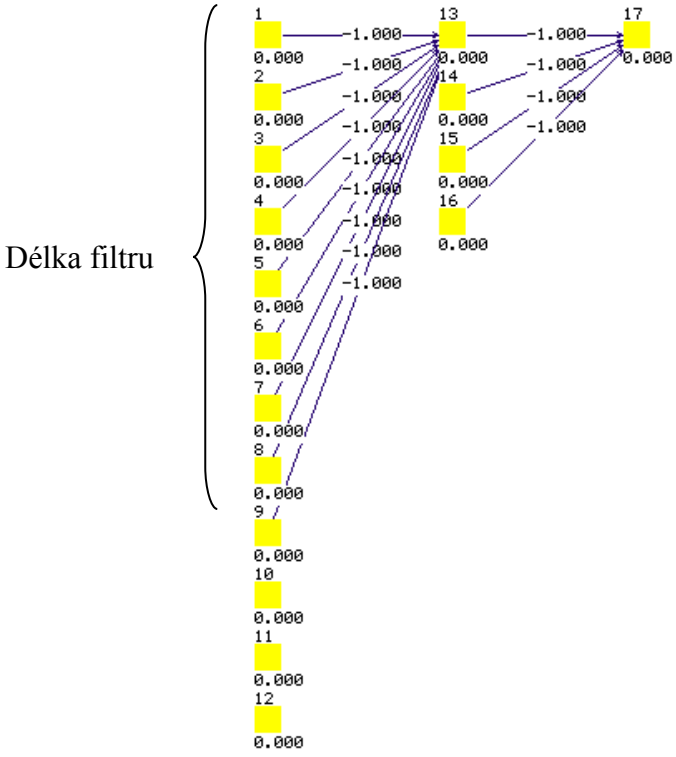

Obr. 6.8. Struktura navržené sítě

Operace s jednotlivými neurony jsou prováděny ve specifickém pořadí, které závisí na dané struktuře navrhnuté NS. Pro každou NS je nutné vybrat update mód určující dané chování NS. V prostředí SNNS pro verifikaci modelu je zvolena funkce TimeDelay Order. Funkce je používána pro rozšíření modelu během časového zpoždění sítě. Její chování je podobné funkci Topological Order, při níž jsou výpočty pro jednotlivé neurony prováděny v pořadí závisle na struktuře NS. Jako první je zpracována vstupní vrstva, následně skrytá vrstva a poslední je zpracovávaná výstupní vrstva, tím proces učení prochází přes všechny

neurony. Před samotným učením je NS inicializována pomocí inicializační funce Randomize wieghts, která nastavuje váhy synapsí, hodnoty vah jsou z intervalu <-1.0 ; 1.0>.

Přenosová funkce představuje změnu požadovaného výstupu, aniž by se musel změnit vstupní soubor. Funkce upravuje výstupní část vzorů, vstupní část zůstává nedotčena. Hodnoty každého vzoru procházejí přenosovou funkcí před samotným učením. Pro tento návrh je použita funkce LinearScale. Tato přenosová funkce představuje lineární transformaci všech výstupních vzorů podle hlavní linky rovnosti

$$novHodnota = par1 \cdot Hodnota + par2, \tag{6.6}$$

kde *Hodna* představuje původní hodnotu vzoru, *par1* a *par2* jsou parametry přenosové funkce. Tyto parametry definují lineární transformaci. V návrhu jsou voleny parametry 0.02 a 1.0.

6.5 Výsledky procesu učení

Proces učení se vykonává pro definovaný počet cyklů, v každém cyklu jsou použity trénovaní data jako vzory NS právě jedenkrát. Pro návrh je definováno 1000 cyklů a v každém cyklu se provádí i testování učení. Kvalitu učení představuje chyba MSE trénovací skupiny. Tato chyba je v průběhu učení NS minimalizována. Průběh chyby pro navrhnutou frontální síť struktury 12-4-1 je znázorněn na obr. 6.9., kde černá křivka představuje chybu pro trénovací data a červená křivka je chyba pro testovací data. Chyba učení MSE dosáhla hodnoty 1.0209 a pro na učení potřebovala síť 450 cyklů učení.

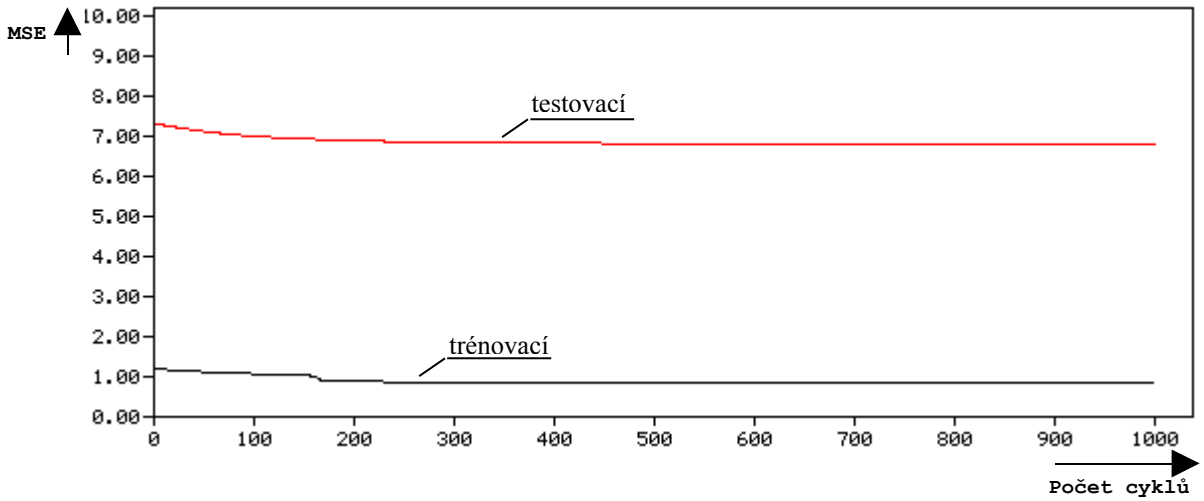

Obr. 6.9. Chyba učení frontální NS

Protokol o učení NS

```
Learning func:  TimeDelayBackprop
Update func:  TimeDelay_Order
Init. func:  Randomize_Weights
Remap. func:  LinearScale

Learning all patterns:
  epochs   : 1000
  parameter:  0.01000
  #o-units : 1
  #patterns: 90 (total: 90)

     epoch:         SSE            MSE            SSE/o-units

Train 1000:     105.53317        1.17259         105.53317
Test  1000:     481.37799        7.29361         481.37799
Train  900:      94.26991        1.04744          94.26991
Test   900:     460.37695        6.97541         460.37695
Train  800:      77.15454        0.85727          77.15454
Test   800:     453.20471        6.86674         453.20471
Train  700:      75.45560        0.83840          75.45560
Test   700:     450.41434        6.82446         450.41434
Train  600:      74.69711        0.82997          74.69711
Test   600:     449.16034        6.80546         449.16034
Train  500:      74.27386        0.82527          74.27386
Test   500:     448.45874        6.79483         448.45874
Train  400:      74.00542        0.82228          74.00542
Test   400:     448.01312        6.78808         448.01312
Train  300:      73.82055        0.82023          73.82055
Test   300:     447.70575        6.78342         447.70575
Train  200:      73.68574        0.81873          73.68574
Test   200:     447.48126        6.78002         447.48126
Train  100:      73.58321        0.81759          73.58321
Test   100:     447.31036        6.77743         447.31036
Train    1:      73.50333        0.81670          73.50333
Test     1:     447.17728        6.77541         447.17728
---------- s t a t i s t i c
s-----------------------------------
Number of Patterns :         90
Number of parameters (Links+bias)          :         18
sse                :    73.5030
tss                :     0.5348
rsq                :  -136.4480
mse                :     1.0209
rmse               :     1.0104
adjrsq             :  -168.9009
J_p                :     1.2250
gcv                :     1.2761
pc                 :  -205.1719
S_p                :     0.0144
gmsep              :     1.2939
shibata            :   102.9042
aic                :    17.7765
sbc                :    62.7731
```

Nastavení vah synapsí a prahů neuronů

SNNS network definition file V1.4-3D
generated at Sun Apr 08 09:40:53 2007

network name : net12-4
source files :
no. of units : 17
no. of connections : 13
no. of unit types : 0
no. of site types : 0

learning function : Std_Backpropagation

update function : Topological_Order

unit default section :

act	bias	st	subnet	layer	act func	out func
0.00000	0.00000	h	0	1	Act_Logistic	Out_Identity

unit definition section :

no.	typeName	unitName	act	bias	st	position	act func	out func	sites
1			3.63000	-1.00000	i	2, 2,17632	Act_TD_Logistic		
2			5.25000	-0.99998	i	2, 3,17632	Act_TD_Logistic		
3			5.02000	-0.99999	i	2, 4,17632	Act_TD_Logistic		
4			3.46000	-0.99998	i	2, 5,17632	Act_TD_Logistic		
5			5.67000	-0.99998	i	2, 6,17632	Act_TD_Logistic		
6			4.72000	-0.99999	i	2, 7,17632	Act_TD_Logistic		
7			3.54000	-0.99999	i	2, 8,17632	Act_TD_Logistic		
8			5.42000	-0.99997	i	2, 9,17632	Act_TD_Logistic		
9			4.88000	-0.99997	i	2,10,17632	Act_TD_Logistic		
10			3.31000	-0.99998	i	2,11,17632	Act_TD_Logistic		
11			3.96000	-0.99999	i	2,12,17632	Act_TD_Logistic		
12			3.16000	-0.99997	i	2,13,17632	Act_TD_Logistic		
13			0.00000	-1.09191	h	5, 2,17632	Act_TD_Logistic		
14			0.00699	-4.95592	h	5, 3,17632	Act_TD_Logistic		
15			0.00699	-4.95592	h	5, 4,17632	Act_TD_Logistic		
16			0.00699	-4.95592	h	5, 5,17632	Act_TD_Logistic		
17			0.26484	-0.99999	o	8, 2,17632	Act_TD_Logistic		

connection definition section :

target	site	source:weight
13		1:-1.68623, 2:-0.40941, 3:-0.05594, 4:-1.67970, 5:-0.39837, 6:-0.04552, 7:-1.68351, 8:-0.40451, 9:-0.05114
17		13:-0.99998, 14:-0.99998, 15:-0.99998, 16:-0.99998

time delay section :

no.	LLN	LUN	Toff	Soff	Ctype
1	3	0	0	0	0
2	3	0	0	0	0
3	3	0	0	0	0
4	3	0	0	0	0
5	3	0	0	0	0
6	3	0	0	0	0
7	3	0	0	0	0
8	3	0	0	0	0
9	3	0	0	0	0
10	0	0	0	0	0
11	0	0	0	0	0
12	0	0	0	0	0
13	2	0	0	0	0
14	2	0	0	0	0
15	2	0	0	0	0
16	2	0	0	0	0
17	1	0	0	0	0

Na obr. 6.10. je znázorněna NS po procesu učení, jsou zde vidět nastavené váhy synapsí a prahy jednotlivých neuronů. Tímto způsobem nastavenou síť lze použít pro predikci vývoje míry inflace.

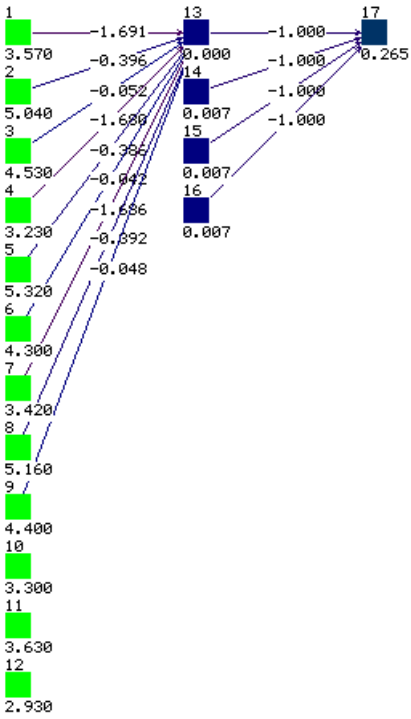

Obr. 6.10. NS po procesu učení

6.6 Shrnutí kapitoly

V této kapitole je hlavním cílem navrhnout frontální NS a provést její verifikaci v prostředí SNNS a následně analyzovat výsledky. V první podkapitole je specifikován

model predikce a jeho jednotlivé části jsou rozvedeny v následujících podkapitolách. V druhé části je definováno předzpracování dat pro tvorbu sítě, hlavně jejich analýza a následně i aditivní metody předzpracování. Potom je popsán filtr NS a struktura návrhu sítě, konkrétně síť 12-4-1 s filtrem délky 9. Další podkapitola zobrazuje výstupy z prostředí SNNS, hlavně graf zobrazující MSE průběhu učení, protokol o učení a nastavení vah na synapsích všech neuronů naučené frontální NS.

.

7 Analýza výsledků navrhnutých modelů

Pomocí prostředí SNNS simulátoru byly verifikovány navrhnuté modely frontálních NS pro predikci vývoje míry inflace. Dané modely jsou rozlišeny podle délky filtru a také podle struktury dané NS. U všech modelů byly použity následující funkce a parametry:

-učící funkcí je zvolena funkce TimeDelayBackprop s parametry $\eta = 0.01$ a $d_{max} = 0$,

-update funkcí je TimeDelay Order,

-NS byla inicializovaná pomocí Randomize Wieghts,

-přenosovou funkcí je LinearScale s parametry 0.02 a 1.0.

Kvalita navržených modelů byla sledována pomocí velikostí střední čtvercové chyby (MSE). Čím je chyba menší, tím se model lépe naučil.

Modely s filtrem délky b = 4

Vstupy do NS byly zvoleny hlavní indikátory, které ovlivňují míru inflace, a byly použity 5, 7, 9, 11 a 13 měsíční trendové složky:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Pro délku filtru b = 4 byly navrženy 3 typy sítí, kde se měnil počet vstupních neuronů a na základě velikosti filtru byl stanoven počet neuronů ve skryté vrstvě. Tím vznikly neuronové sítě struktur 15-12-1, 12-9-1 a 9-6-1. Pro vstup do sítě s dvanácti vstupními neurony nebyl použit klouzavý medián a pro vstup do neuronové sítě s devíti vstupními neurony nebyla použita náhodně vybraná vyrovnání. Výsledky jsou znázorněny v tab. 2. Z tabulky vyplývá, že při snižování počtu neuronů ve vstupní vrstvě se snižuje i chyba učení. Na velikost chyby učení má vliv i délka klouzavých průměrů. S prodlužující délkou se chyba snižuje.

Jako nejlepší variantou se jeví model se strukturou 9-6-1 a 13 měsíčními modely trendových složek, protože má nejnižší hodnotu chyby MSE.

Tab. 2 Modely s filtrem délky 4

Model	Měsíční	RMSE	MSE	Počet cyklů
15-12-1	7	1.1296	1.2761	780
	9	1.1248	1.2652	950
12-9-1	7	1.0700	1.1450	850
	9	1.0655	1.1352	550
	11	1.0609	1.1254	625
	13	1.0562	1.1156	580
9-6-1	5	1.0244	1.0493	760
	13	1.0066	1.0133	700

Modely s filtrem délky b = 5

Pomocí simulátoru SNNS byly verifikovány 3 modely frontální neuronové sítě. Struktura je ovlivněna délkou filtru, modely mají podobu 15-11-1, 12-8-1 a 9-5-1. Vstupy do neuronové sítě byly zvoleny hlavní indikátory, které ovlivňují míru inflace, a byly použity 5, 7, 9, 11 a 13 měsíční trendové složky:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

V průběhu navrhování modelů byly měněny počty vstupních neuronů a počtu neuronů ve skryté vrstvě. Zjištěné výsledky jsou obsahem tab. 3, v jednotlivých měřeních dochází ke snižování chyby MSE při zvyšující se délce klouzavých průměrů, ale i oproti předešlým měření s filtrem délky 4.

Tab. 3 Modely s filtrem délky 5

Model	Měsíční	RMSE	MSE	Počet cyklů
15-11-1	7	1.1179	1.2497	700
	9	1.1132	1.2391	850
	11	1.1084	1.2285	850
	13	1.1036	1.2179	780
12-8-1	5	1.0649	1.1340	500
	7	1.0603	1.1243	750
	11	1.0512	1.1050	550
	13	1.0466	1.0954	500
9-5-1	7	1.0113	1.0228	425
	13	0.9981	0.9962	550

Nejlepším navrhnutým modelem je NS se strukturou 9-5-1 a 13 měsíčními předzpracováními, tento model se naučil během 550 cyklů.

Modely s filtrem délky b = 6

Jako vstupy do NS byly vybrány hlavní indikátory, které ovlivňují míru inflace, a byly použity 5, 7, 9, 11 a 13 měsíční modely trendové složky:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Výsledky těchto návrhů jsou v tab. 4. Při použití filtru délky 6 vznikly struktury sítí 15-10-1, 12-7-1 a 9-4-1. V porovnání s předešlými výsledky filtru délky 5 a 4 je patrné, že při zvyšující se délce filtru se snižuje počet neuronů ve skryté vrstvě, ale také dochází ke snižování chyby učení MSE.

Tab. 4 Modely s filtrem délky 6

Model	Měsíční	RMSE	MSE	Počet cyklů
15-10-1	9	1.1020	1.2143	780
	13	1.0924	1.1934	700
12-7-1	5	1.0554	1.1140	950
	7	1.0509	1.1044	650
	9	1.0464	1.0949	500
	11	1.0418	1.0854	480
	13	1.0372	1.0759	850
9-4-1	7	1.0031	1.0061	420
	9	0.9987	0.9974	300
	11	0.9943	0.9887	250

Při porovnání jednotlivých výsledků je viditelné, že vhodnou variantou pro predikci je síť se strukturou 9-4-1 s 13 měsíčními předzpracováními použitých řad, které stačilo 250 cyklů pro naučení a má nejnižší hodnotu chyby MSE. Při srovnání s 11 měsíčním předzpracováním není rozdíl chyb MSE tak markantní, i počet cyklů učení není příliš odlišný oproti ostatním měřením.

Modely s filtrem délky b = 7

Vstupními neurony do frontální NS s délkou filtru b = 7 byly zvoleny tři indikátory, které významně ovlivňují míru inflace, a byly použity 7, 9, 11 a 13 měsíční modely trendové složky. Použité modely jsou:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Hodnoty výsledků jednotlivých návrhů jsou zachyceny v tab. 5. Při délce filtru b = 7 byly navrženy modely NS struktury 15-9-1, 12-6-1 a síť 9-3-1. U těchto modelů byla provedena měření, při kterých se měnily délky klouzavých průměrů.

Tab. 5 Modely s filtrem délky 7

Model	Měsíční	RMSE	MSE	Počet cyklů
15-9-1	7	1.0953	1.1997	880
	9	1.0051	1.0102	875
	11	1.0859	1.1793	650
	13	1.0812	1.1689	600
12-6-1	7	1.0415	1.0848	550
	9	1.0370	1.0754	900
	13	1.0279	1.0567	700
9-3-1	7	0.9949	0.9899	200
	9	0.9906	0.9813	350
	13	0.9819	0.9641	290

Po srovnání všech výsledků opět vyšla jako nejlepší síť s devíti vstupními neurony a 13 měsíčním předzpracováním vstupních dat. Rozdíly mezi jednotlivými chybami MSE nejsou příliš velké, při srovnání modelu 9-3-1 s 9 měsíčním a 7 měsíčním předzpracováním lze konstatovat, že tyto dvě měření mají téměř shodné výsledky, jen síť se 7 měsíčním předzpracováním má méně cyklů učení.

Modely s filtrem délky b = 8

Vstupními hodnotami do NS byly použity indikátory, které ovlivňují míru inflace, a byly zvoleny 5, 7, 9, 11 a 13 měsíční klouzavé průměry. Všechny vstupy jsou:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Výsledky jednotlivým modelů, které vznikly za použití filtru frontální NS délky 8 jsou zahrnuty v tab. 6, vyskytují se zde modely sítí, jejichž struktura je 15-8-1, 12-5-1 a 9-2-1.

Tab. 6 Modely s filtrem délky 8

Model	Měsíční	RMSE	MSE	Počet cyklů
15-8-1	5	1.0895	1.1870	550
	7	1.0848	1.1768	780
	9	1.0802	1.1667	580
	11	1.0755	1.1567	580
	13	1.0708	1.1465	550
12-5-1	5	1.0370	1.0754	625
	7	1.0325	1.0661	425
	11	1.0236	1.0477	700
	13	1.0191	1.0385	550
9-2-1	7	0.9870	0.9743	625
	9	0.9827	0.9658	200
	11	0.9784	0.9573	180
	13	0.9740	0.9487	120

Při zvyšování délky filtru dochází stále ke snižování počtu neuronů ve skryté vrstvě, ale tyto modely nejsou vhodné pro predikci, protože modely s malým počtem neuronů ve skryté vrstvě příliš zobecňují. Při tomto procesu se také snižuje hodnota chyby učení MSE. Struktura sítě s nejnižší chybou má devět vstupních neuronů a dva neurony ve skryté vrstvě. V porovnání těchto výsledků s předcházejícími měřeními se model 12-5-1 s 11 měsíčním zpracováním podobá modelu 9-6-1 s filtrem délky 4 a 5 měsíčním předzpracováním, modely jsou si podobny v chybě učení, ale i v počtu cyklů učení.

Modely s filtrem délky b = 9

Vstup do NS tvoří 5, 7, 9, 11 a 13 měsíční předzpracování vstupních dat, vstupy tvoří:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Přehled výsledků jednotlivých simulací je vyobrazen v tab. 7. Při použití délky filtru b = 9 byly navrženy struktury sítí 15-7-1 a 12-4-1, zde se již neuvažuje struktura 9-1-1, protože síť s jedním neuronem ve skryté vrstvě je příliš zobecňuje. Nejvýhodnějším modelem se nyní stal model 12-4-1 s 13 měsíčním předzpracováním a chybou učení MSE = 1.0209, který má dostatek neuronů ve vstupní i skryté vrstvě. Tento model je popsán v kap. .

Tab. 7 Modely s filtrem délky 9

Model	Měsíční	RMSE	MSE	Počet cyklů
15-7-1	5	1.0794	1.1650	950
	7	1.0747	1.1550	680
	9	1.0701	1.1450	500
	13	1.0607	1.1252	800
12-4-1	5	1.0283	1.0573	460
	7	1.0238	1.0482	325
	9	1.0194	1.0391	550
	11	1.0149	1.0300	550
	13	1.0104	1.0209	450

Model 15-7-1 má stejnou chybu učení jako model z předešlých měření se strukturou 12-9-1 a 7 měsíčními klouzavými průměry, tento model má délku filtru 4, ale modelu 15-7-1 stačilo k naučení 500 cyklů. S vyšší hodnotou délky filtru se modely s větším počtem vstupních neuronů stávají stejně kvalitní jako modely s nižším počtem vstupů a menší délkou filtru.

Modely s filtrem délky b = 10

Jako vstupy do NS byly vybrány důležité indikátory, které ovlivňují míru inflace, a bylo použito jejich 7, 9, 11 a 13 měsíční předzpracování pomocí aditivních metod, jako jsou:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Výsledky tohoto modelování zobrazuje tab. 8, při této délce filtru vznikly NS se strukturou 15-6-1 a 12-3-1.

Tab. 8 Modely s filtrem délky 10

Model	Měsíční	RMSE	MSE	Naučení
15-6-1	7	1.0648	1.1337	550 cyklů
	9	1.0602	1.1239	900 cyklů
	11	1.1142	1.0556	880 cyklů
12-3-1	7	1.0152	1.0307	225 cyklů
	9	1.0108	1.0217	350 cyklů
	11	1.0064	1.0128	350 cyklů
	13	1.0019	1.0038	290 cyklů

Při hodnocení těchto výsledků se dá usuzovat, že naměřené hodnoty chyb učení MSE se podobají výsledkům měření s délkou filtru 4, mění se počet vstupních neuronů. Model

s 15 vstupními neurony je podobný modelu s 12 vstupními neurony a model s 12 vstupy je podobný modelu s 9 vstupy. Z těchto výsledných modelů je nejlepším (s nejmenší chybou učení MSE) model 12-3-1 s 13 měsíčním předzpracováním, ale není vhodný pro predikci, protože příliš zobecňuje, proto je vhodné z této skupiny modelů použít model se strukturou 15-6-1 a 11 měsíčním předzpracováním.

Modely s filtrem délky b = 11

Vstupy do NS byly použity opět 5, 7, 9, 11 a 13 měsíční předzpracování časových řad, jsou to hlavně:

-jednoduchý klouzavý průměr deflátoru, CPI a PPI,

-váhový klouzavý průměr deflátoru, CPI a PPI,

-trojúhelníkový klouzavý průměr deflátoru, CPI a PPI,

-jednoduché exponenciální vyrovnání deflátoru, CPI a PPI,

-klouzavý medián deflátoru, CPI a PPI.

Při použití filtru s délkou b = 11 vznikly modely frontálních NS se strukturou 15-5-1 a 12-2-1, což je patrné z tab. 9. Z těchto modelů mají nejnižší hodnotu chyby MSE sítě se strukturou 12-2-1, ale tato struktura není vhodná pro predikci, protože opět příliš zobecňují, tzn. že již patrně nedokáží správně postihnout závislosti ve vstupních datech.

Tab. 9 Modely s filtrem délky 11

Model	Měsíční	RMSE	MSE	Počet cyklů
15-5-1	5	1.0598	1.1232	650
	7	1.0552	1.1135	450
	9	1.0506	1.1038	650
	13	1.0414	1.0845	550
12-2-1	7	1.0069	1.0138	650
	9	1.0025	1.0050	180
	11	0.9981	0.9961	185
	13	0.9936	0.9872	180

7.1 Shrnutí kapitoly

Cílem této kapitoly byla vyhodnocení navrhnutých modelů frontálních NS vhodných pro predikci vývoje míry inflace. Celkem bylo navrhnuto 75 modelů NS, lišily se volbou délky filtru, který ovlivňuje následně strukturu NS. Bylo zvoleno 7 druhů filtrů od délky 4 do délky 11. Při použití pevného počtu vstupních neuronů 15, 12 a 9 se měnil počet neuronů ve skryté vrstvě podle zvoleného filtru. Nejvhodnějším modelem pro predikci vývoje míry inflace byl zvolen model s topologií 12-4-1 s 13 měsíčním předzpracování dat, který obsahuje dostatek vstupních neuronů i neuronů ve skryté vrstvě, tento model je schopen postihnou závislosti ve vstupních datech. Při zvyšující délce filtru se snižuje počet neuronů ve skryté vrstvě, ale zároveň se snižují hodnoty chyby MSE. Při vhodném počtu vstupních neuronů a délce filtru lze vytvořit další množství jiných modelů.

8 Uživatelská příručka k architektuře Time-Delay v prostředí SNNS similátoru

SNNS simulátor [27] (Stuttgart Neural Network Simulator) je programový systém pro simulaci NS, vyvinutý v Institutu pro paralelní a distribuované vysoce -výkonnostní systémy (Institute for Parallel and Distributed High Performance Systems – IPVR) na Univerzitě ve Stuttgartu v roce 1989. Cílem projektu, v rámci kterého byl vytvořen programový systém pro simulaci NS, je tvorba efektivního a flexibilního simulační prostředí pro výzkum aplikací NS.

Prostředí SNNS simulátoru se skládá ze dvou hlavních částí, a to z jádra simulátoru napsaného v jazyce C a grafického uživatelského prostředí (XGUI), které dovoluje ovládat jádro simulátoru v průběhu simulace. XGUI může být užíváno pro přímou tvorbu, manipulaci a zobrazení NS v různých stádiích. I komplikované NS tak mohou být navrhovány rychle a snadno. XGUI by měl být vhodný pro nezkušené uživatele, kteří se chtějí dozvědět o spojitostech v modelech NS za pomoci simulátoru.

8.1 SNNS Manager

Po zapnutí SNNS simulátoru se na obrazovce objeví základní panel – SNNS Manager. Tento panel je znázorněn na obr. 8.1.. Tento panel se skládá ze tří řádků ikon. První řádek obsahuje funkce pro návrh NS, ve druhém řádku jsou uvedeny funkce pro úpravu parametrů jiných než dopředných NS a ve třetím řádku jsou pomocné funkce. Z Manager panelu je možné aktivovat ostatní okna, která jsou užívána pro návrh modelu NS. Pro tyto jeho vlastnosti je doporučeno, aby byl Manager panel zobrazen po celou dobu práce se SNNS simulátorem.

Pro práci se SNNS simulátorem je využíváno pět druhů souborů. Nejdůležitějšími typy souborů specifikovanými příponami jsou:

- soubory s příponou „.net“ obsahují informace o struktuře NS a učících algoritmech,
- soubory s příponou „.pat“ obsahují trénovací a kontrolní (validační) data, každý druh dat musí být ve samostatném souboru,
- výsledky navržených NS jsou ukládány do souborů s příponou „.res“.

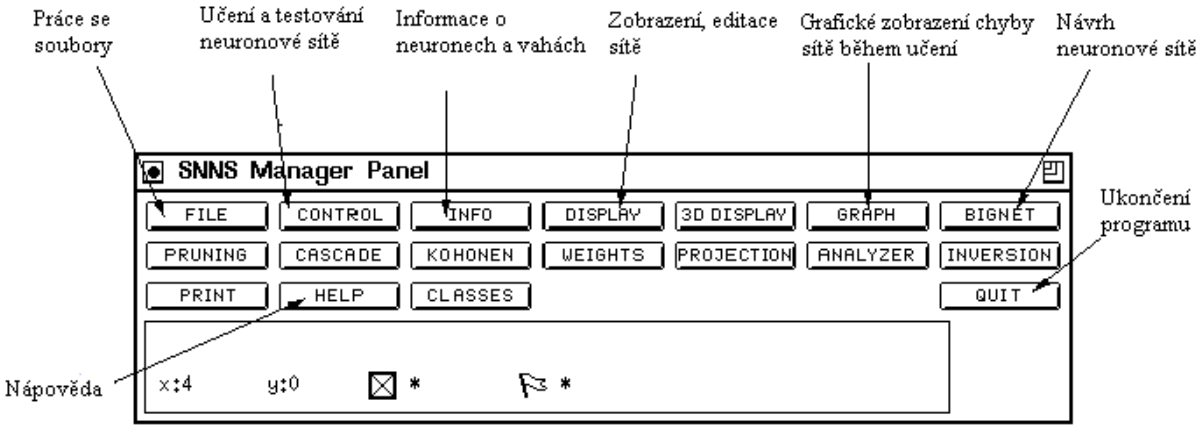

Obr. 8.1. Manager Panel

Otevírání a ukládání souborů

Soubory používané pro práci se SNNS simulátorem jsou načteny pomocí nabídky FILE na panelu SNNS Manager. Pomocí této funkce jsou vybrány soubory definující strukturu NS a soubory s trénovacími a kontrolními daty. Ukázka tohoto okna je znázorněné na obr. 8.2.. V horním textovém poli je zobrazena cesta k souborům, které jsou zobrazeny v textovém poli hned pod ním. Vpravo od seznamu souborů je možné pomocí tlačítek zvolit typ souboru, který se bude zobrazovat. Po aktivování souboru, který má být použit k práci se SNNS simulátorem, se jeho název objeví vpravo nahoře v poli, kde se zobrazují jména souborů. Vybraný soubor je načten pomocí tlačítka LOAD a práce s oknem je ukončena aktivováním DONE v levém dolním rohu okna.

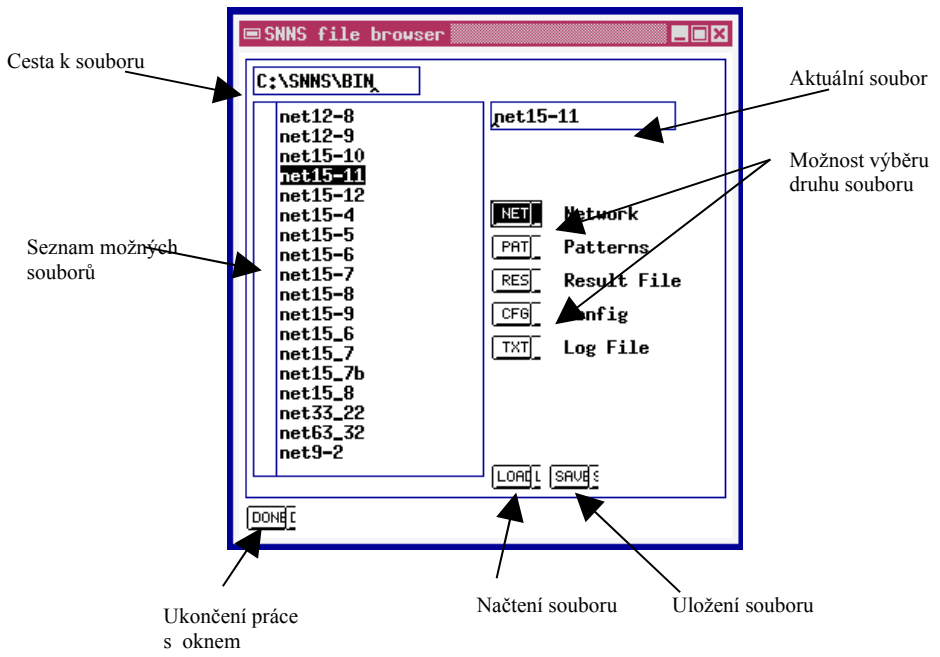

Obr. 8.2. Okno File

Návrh NS

Pro uskutečnění návrhu NS je nutné aktivovat funkci BIGNET z panelu SNNS Manager-u a následně vybrat z nabídky volbu TIME-DELAY, která specifikuje, že se bude jednat o návrh frontální NS. Ukázka okna této funkce je na obr. 8.3..

V horní části okna na funkce BIGNET je definována struktura NS. Do volných políček jsou zadávány, parametry NS tak jakým způsobem bude síť zobrazena na obrazovce. Pomocí tlačítka TYPE se mění jaký druh vrstvy bude uložen při stisknutí tlačítka ENTER. Pomocí tlačítka POS je definována pozice dané vrstvy, jakým způsobem bude zarovnána. Ve spodní části okna se propojují jednotlivé vrstvy NS a stanovuje se zde délka filtru (okna do minulosti). V části definované Edit Link se nastavuje mezi kterými vrstvami bude propojení. Následně v části Receptive Field Coordinates se specifikuje vlastní spojení a délka filtru.

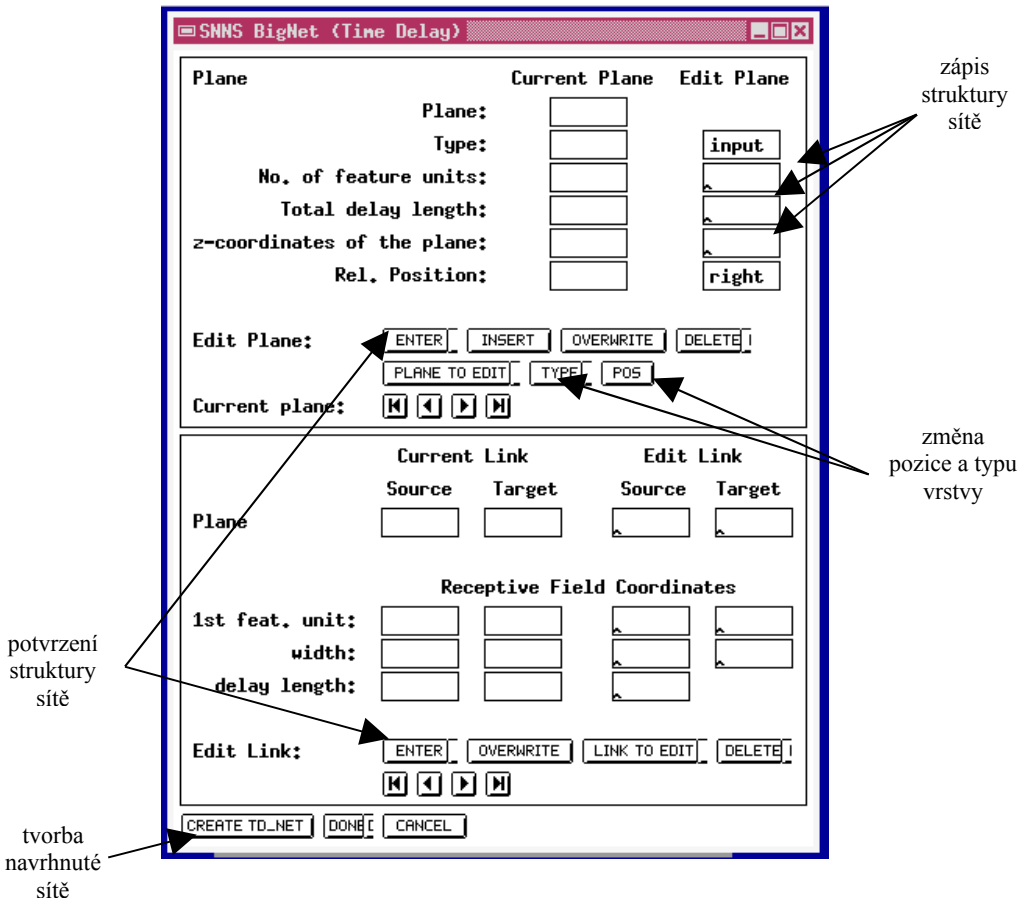

Obr. 8.3. Funkce Bignet

Nejprve se definuje vstupní vrstva vyplněním volných míst vpravo nahoře v části Edit Plane (struktura vrstvy). Má-li mít např. vstupní vrstva 12 neuronů, do kolonky No. of feature units se zapíše hodnota 1, do kolonky Total delay length se zaznamená hodnota 12

a do kolonky Z-coordinates of the plane: 0. Struktura vrstvy je potvrzena tlačítkem ENTER.

Stejným způsobem se pokračuje v definování ostatních vrstev. Nejprve se použije tlačítko TYPE, které změní druh vrstvy na skrytou, dále zapisujeme požadované parametry (No. of feature units: 1, Total delay length: 4, Z-coordinates of the plane: 0). Pro výstupní vrstvu se opět použije tlačítko Type (No. of feature units: 1, Total delay length: 1, Z-coordinates of the plane: 0).

Propojení takto vytvořený vrstev se definuje ve spodní části Link editoru. V prázdných pozicích pro Plane v Edit Linku se do Source zadává číslo výchozí vrstvy a do Target číslo cílové vrstvy. Do kolonky 1st feat. Unit se zadávají souřadnice [1,1], do kolonky width zadáváme šířku NS, do Delay Length se zapisuje délka filtru. Pro příklad NS se strukturou 12-4-1 se postupuje: při propojovaní vstupní a skryté vrstvy se definuje do Source 1, do Target 2, do dvojice políček 1st feat. unit: 1 a 1, width 1 a 1, Delay Length bude 9 a následuje stisknutí tlačítka ENTER. Potom se opakuje stejný postup pro spojení mezi skrytou a výstupní vrstvu. Do políčka Source 2, do Target 3, do dvojice políček 1st feat. unit: 1 a 1, width 1 a 1, Delay Length se zadá 4 a následuje potvrzení stisknutím tlačítka ENTER. Pro samotné vytvoření nadefinované sítě je nutné tuto strukturu potvrdit pomocí tlačítka CREATE TD_NET. Struktura NS je zobrazena pomocí nabídky DISPLAY z panelu SNNS Manager-u. Ukázka tohoto okna je na obr. 8.4..Pro zobrazení propojení mezi jednotlivými neurony se uskuteční stiskem tlačítka SETUP v okně DISPLAY, kde je nabídka ‚links' aktivována tlačítkem ON. Práce s oknem je ukončena pomocí DONE.

Po vytvoření návrhu struktury jsou načteny soubory obsahující trénovací a kontrolní data, nyní se může přistoupit k učení NS.

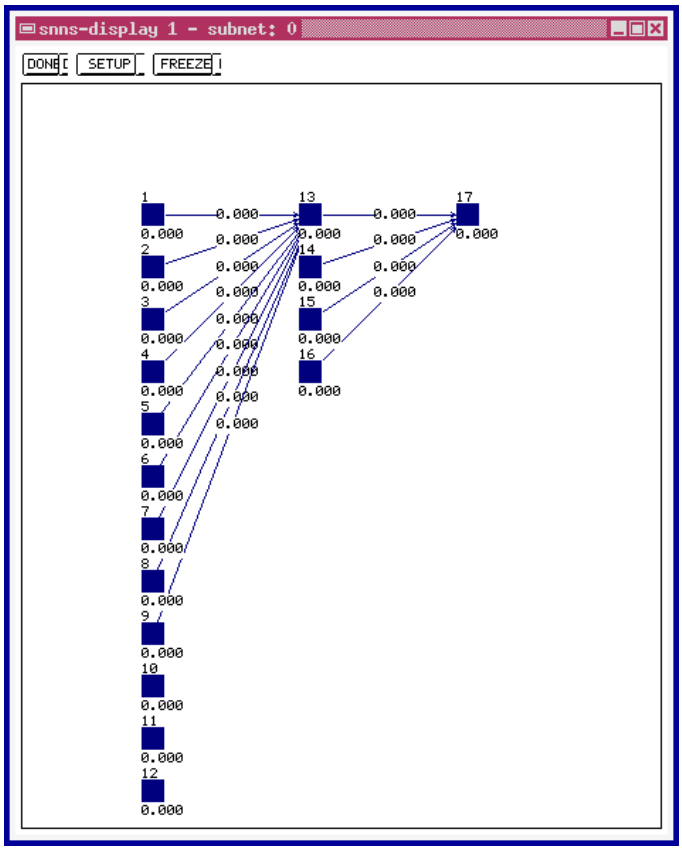

Obr. 8.4. Struktura navrhnuté sítě

Proces učení nerunové sítě

Učení navržené NS se provádí pomocí nabídky CONTROL, která se aktivuje z panelu SNNS Manager-u. Okno pro učení NS se skládá ze dvou částí. V horní části okna se definují parametry pro učení NS, ve spodní části jsou čtyři políčka s volnými místy pro

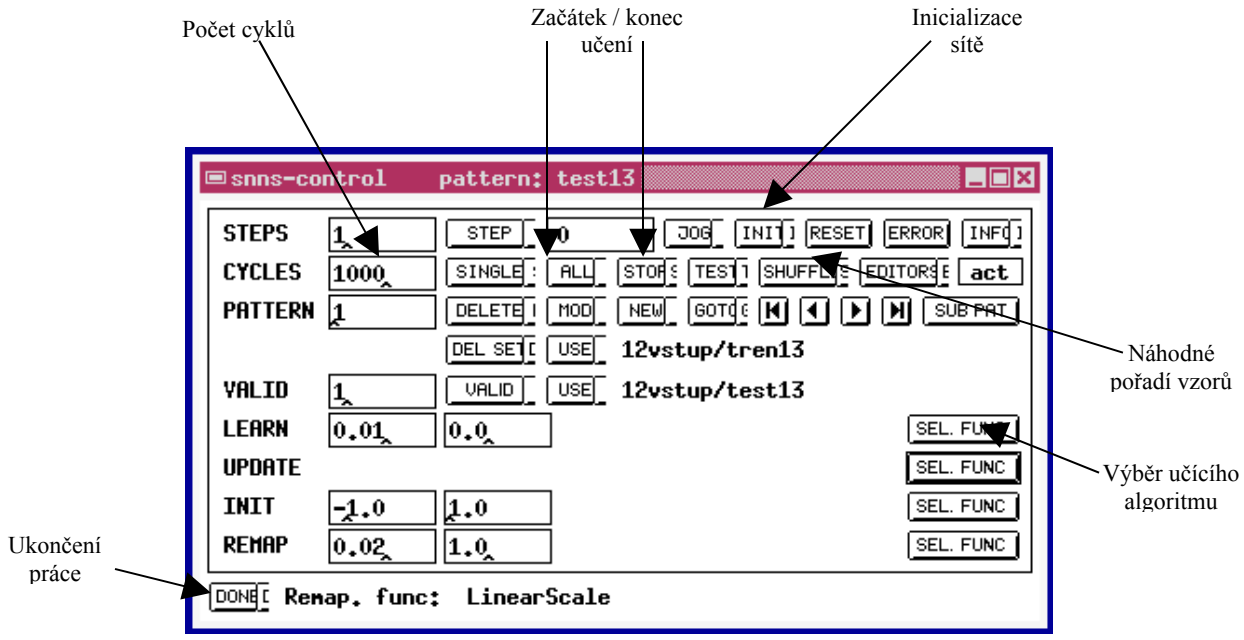

Obr. 8.5. Okno CONTROL

vyplnění parametrů učení a intervalu, v kterém budou váhy náhodně rozloženy při inicializaci NS. Přednastavené hodnoty parametrů učení jsou (0.2 0) a přednastavená hodnota váhy je v intervalu (1.0 -1.0). Ukázka okna pro učení je na obr. 8.5..

Většina NS je před procesem učení inicializována. Inicializace se aktivuje pomocí tlačítka INIT v horním řádku. Interval, ve kterém budou náhodně rozloženy hodnoty při inicializaci, je možné změnit ve spodní části okna ve volných místech vedle názvu INIT (přednastavené hodnoty -1.0 a 1.0).

Pro učení frontální NS je používán algoritmus TimeDelayBackprop. Algoritmus učení je možné vybrat aktivováním prvního tlačítka SEL FUNC. Druhé tlačítko SEL. FUNC. slouží k výběru aktualizační funkce (Update Function), která definuje v jakém pořadí jsou neurony v NS používány. Pořadí neuronů závisí na vybrané aktualizační funkci. Aktualizační funkcí pro frontální NS je TimeDelay_Order. Pomocí třetího tlačítka SEL. FUNC. se volí druh inicializační funkce, která slouží k nastavení počátečních hodnot (vah). Z inicializačních funkcí se nejčastěji používá funkce Randomize_Weights. Posledním tlačítkem SEL. FUNC. je vybrána funkce, pomocí které je změněn požadovaný výstup bez zásahu do trénovacího a kontrolního souboru (tzn. do souborů obsahujících vzory). Je možné použít funkci LinearScale, popřípadě i jiné, podle typu zvolené funkce je možné nastavit její parametry.

Učení NS je realizováno na zadaném množství cyklů, které se nastaví v horní části vedle názvu CYCLES. Všechny vstupní vzory (spojení vstup – výstup) jsou použity v každém cyklu. Je možné i zadat náhodné použití vzorů, tento náhodný výběr se provede stisknutím tlačítka SHUFFLE.

Pro zobrazení výsledků procesu učení se může aktivovat panel GRAPH z Manager panelu, ve kterém se zobrazuje chyba procesu učení. Pokud chceme vidět zakreslení chyby MSE musí se v panelu GRAPH změnit v kolonce Display z SSE na MSE. Proces učení je aktivován tlačítkem ALL a ukončen pomocí tlačítka STOP.

Tlačítko USE slouží k výběru trénovacích (horní tlačítko USE) a kontrolních dat (dolní tlačítko USE). Pokud je napsána nenulová hodnota vedle názvu VALID, budou použita kontrolní data a chyba použití těchto dat bude v grafu znázorněna červenou barvou, pokud bude napsána nula budou kontrolní data vyřazena. Pomocí tlačítka TEST je možné si postupně prohlédnout jednotlivé vzory (vstupní a výstupní hodnoty). Parametry LEARN

slouží k nastavení učení. Čím vyšší číslo je u prvního parametru tím se NS rychleji učí. Druhý parametr udává jaká chyba je při procesu učení přijatelná.

Hodnoty určitého vzoru je možné si prohlédnout dosazením čísla vzoru do volného místa vedle názvu PATTERN a aktivováním tlačítka GOTO nebo použitím šipek pro posun vedle tlačítka GOTO. Hodnoty vzorů se zobrazí na panelu DISPLAY.

Zobrazení chyby procesu učení NS

Pomocí nabídky GRAPH, která je aktivována z panelu SNNS Manager, je možné zobrazit průběh chyby při učení NS na trénovacích i kontrolních datech. Ukázka okna s průběhem chyby je na obr. 8.6..

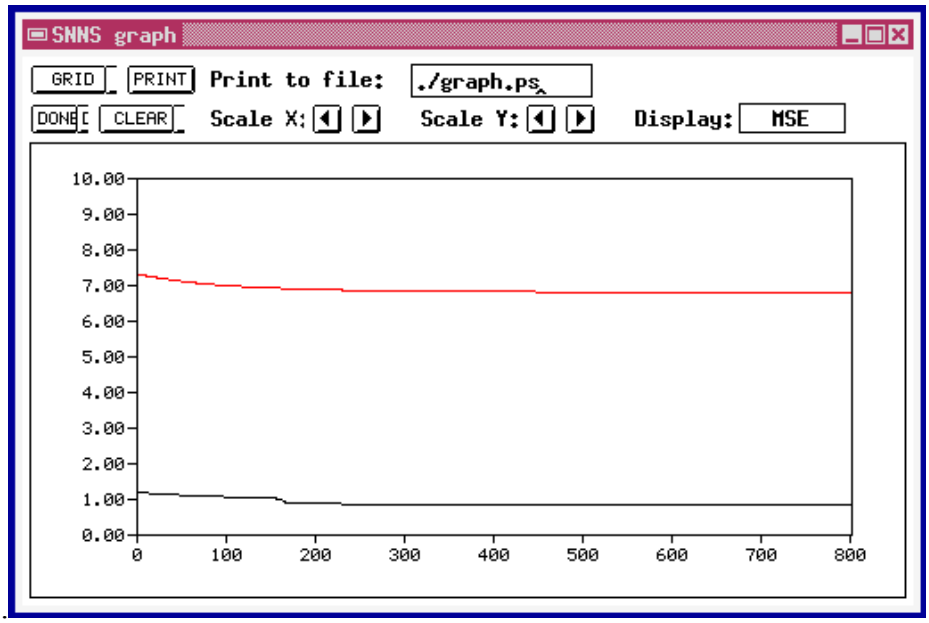

Obr. 8.6. Chyba učení MSE

Na x-ové ose je počet cyklů, na y-ové pak velikost chyby. Aktivováním nabídky CLEAR je graf vyčištěn pro další návrh NS. Šipkami je možné měnit měřítko x-ové a y-ové souřadnice. Pomocí nabídky na pravé straně (kde je na obr. napsáno MSE) se mění způsob zobrazení chyby. Simulátor nabízí možnosti zobrazení:

-SSE (celková čtvercová chyba),

-MSE (střední čtvercová chyba),

-SSE/out (celková čtvercová chyba / počet výstupů).

Práce s oknem je ukončena aktivováním nabídky DONE.

Uložení výsledků

Výsledky navrženým modelů je možné uložit pomocí nabídky FILE na panelu SNNS Manager-u a aktivováním tlačítka RES se zvolí, že se bude ukládat výsledek učení. Název souboru, do kterého mají být výsledky uloženy, se zapisuje do volného políčka v pravé horní části okna FILE. Výběr adresáře pro uložení souboru je proveden v levé části tohoto okna. Aktivováním tlačítka SAVE se objeví okno, které je zobrazeno na obr. 8.7.. Stiskem tlačítka DONE v tomto okně se výsledky uloží.

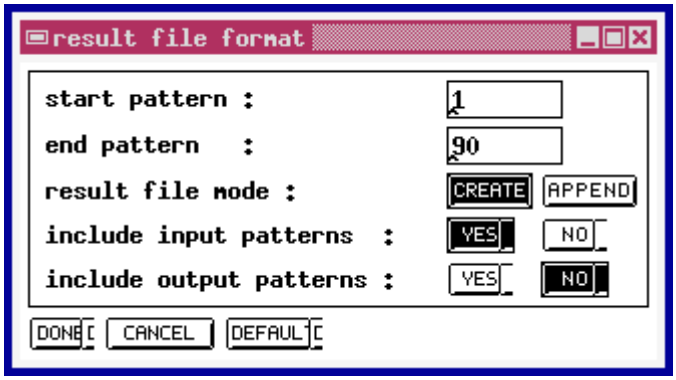

Obr. 8.7. Uložení výsledku

Závěr

Cílem diplomové práce bylo navrhnout model frontální NS pro predikci vývoje míry inflaci. Z tohoto důvodu byly získány data z Českého statistického úřadu, hlavními ukazateli byli cenový index, index cen výrobců, deflátor HDP, ale i vývoj míry inflace. Tyto časové řady byly předzpracovány pomocí klouzavých průměrů a exponenciálního vyrovnání, aby mohly být použity jako vstupy při verifikaci v prostředí SNNS simulátoru.

Pro zvolení nejvhodnějšího modelu frontální NS byly uskutečněny experimenty, ve kterých se měnila délka filtru a následně i struktura NS. Při těchto experimentech byly také zvolena různé druhy předzpracování (klouzavé průměry, exponenciální vyrovnání). Nejvhodnější model byl vybrán podle velikosti chyb MSE. Proto jako nevhodnější model byl zvolen model se strukturou sítě 12-4-1 a filtrem délky b = 9.

Hlavním problémem při návrhu frontální NS byla volba okna do minulosti (filtru), ale i volba vhodných parametrů učícího algoritmu, typu a parametrů funkce měnící požadovaný výstup. Při nevhodně zvolených parametrech byla chyba učení sítě příliš vysoká, nebo z klesající fáze přecházela v rostoucí, tzn. docházelo k přeučení sítě.

Součástí diplomové práce je také příručka pro verifikaci frontální NS v prostředí SNNS.

Seznam použité literatury

[1] PAČESOVÁ, H.: *Makroekonomická teorie*. 1. vydání. Praha, ČVUT, 1995.
[2] *Když se řekne inflace, res. míra inflace...* [online]. Praha : Český statistický úřad, 2006 [cit. 2006-10-27]. Dostupný z WWW: <http://www.czso.cz/csu/redakce.nsf/i/mira_inflace>
[3] LIŠKA, V.: *Makroekonomie*. 1.vydání. Praha, Professional publishing, 2002. ISBN 80-86419-27-4
[4] KOTLÁN, V.: *Monetární politika*. 1. vydání. Ostrava, VŠB – Technická univerzita Ostrava, 1999. ISBN 80-7078-675-2
[5] FIALOVÁ, H.: *Úvod do ekonomiky*. 3. vydání. Praha, ČVUT, 2006. ISBN
[6] FLAMMANT, M.: *Inflace*. 1. vydání, 1990. ISBN 80-901918-4-3.
[7] RUSMICHOVÁ, L.: *Makroekonomie* : Základní kurs. 1. vydání. Praha, Melandrium, 2002. ISBN
[8] MACH, M.: *Makroekonomie pro inženýrské studium, část II.* Praha: VŠE, 2003. ISBN 80-7079-498-4
[9] HINDLS R., HRONOVÁ, S., SEGER, J. *Statistika pro ekonomy.* 4. vydání. Praha: Professional Publishing, 2003. ISBN 80-86419-52-5. 415 s.
[10]KVASNIČKA, M.: *Úvod do analýzy časových řad*. 2001
[11]ŘEZANKOVÁ, H.: *IASTAT – Interaktivní učebnice statistiky* [online]. [cit. 2007-02-05]. Dostupný z WWW: <http://iastat.vse.cz/>.
[12]ŠEDIVÝ, P.: Demografie [online] Praha : 2005 [cit. 2007-02-10]. Dostupný z WWW: <mujweb.atlas.cz/www/fmkf2003/Sylaby/EKST/texty1.doc>.
[13]ŘEZANKOVÁ, H.: *Časové řady* [online]. [cit. 2007-02-11]. Dostupný z WWW: <http://iastat.vse.cz/casovky/>.
[14]ZAPLETAL, J. *Úvod do analýzy ekonomických časových řad.* 1. vydání. Brno: PC-DIR Real, 2000. ISBN 80-214-1719-6. 112 s.
[15]CIPRA, T. *Praktický průvodce finanční a pojistnou matematikou.* 1. vydání. Praha: HZ Praha, 1995. ISBN 80-901918-0-0. 320 s.
[16]CIPRA, T. *Analýza časových řad s aplikacemi v ekonomii.* 1. vydání. Praha: SNTL/Alfa, 1986. ISBN 04-012-86. 248 s.
[17]HANČLOVÁ, J., TUHÝ, L. *Úvod do analýzy časových řad* [online].2003. [cit.2007-03-04]. Dostupné na <http://gis.vsb.cz/pan/Skoleni_Texty/TextySkoleni/AnalyzaCasRad.pdf>.
[18]KVASNIČKA, V. a kol. *Úvod do teórie neurónových sietí.* Bratislava: IRIS, 1997. ISBN 80-88778-30-1. 262 s.
[19]KUKAL, Jaromír. Úvod do neuronových sítí. *AUTOMA* [online]. 2005, č. 1 [cit. 2007-02-22]. Dostupný z WWW: < http://www.automa.cz/>.
[20]MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. *Umělá inteligence (4).* 1. vydání. Praha: Academia, Akademie věd České republiky, 2003. ISBN 80-200-1044-0. 475 s.
[21]*Neuronové sítě* [online]. ČVUT [cit. 2007-03-20]. Dostupný z WWW: <http://cyber.felk.cvut.cz/gerstner/biolab/bio_web/teach/FunBio/neuron/neursite.html> .
[22]JIŘINA, M. *Neuronové sítě*. Praha, 1995.
[23]ŠÍMA, J., NERUDA, R. *Teoretické otázky neuronových sítí*. 1. vydání. Praha: MATFYZPRESS, 1996. ISBN 80-85863-18-9.
[24]TUČKOVÁ, J. *Úvod do teorie a aplikací umělých neuronových sítí. 1.* vydání. Praha: ČVUT, 2003. ISBN 80-01-02800-3.

[25]OLEJ, V. *Modelovanie ekonomických procesov na báze výpočtovej inteligencie*. Hradec Králové: Miloš Vognar – M&V, 2003. ISBN 80-903024-9-1. 160s
[26]*Neuronové sítě* [online]. Univerzita Komenského v Bratislavě : Fakulta matematiky, fyziky a informatiky, 2005 [cit. 2007-03-29]. Dostupný z WWW: <http://people.ksp.sk/~misof/skola/!to%20process/Neuronove%20siete/uns.pdf>
[27]ŠNOREK, M. *Neuronové sítě a neuropočítače*. Praha: Vydavatelství ČVUT, 2002.

Seznam obrázků

Obr. 1.1. Vývoj Indexu spotřebitelských cen....14
Obr. 1.2. Vývoj Indexu cen výrobců....14
Obr. 1.3. Vývoj deflátoru HDP....15
Obr. 2.1. Poptávková inflace....22
Obr. 2.2. Nabídková inflace....23
Obr. 3.1. Gradualismus....28
Obr. 3.2. Metoda Cold Turkey....28
Obr. 5.1. Dopředná NS....46
Obr. 5.2. Perceptronová síť....47
Obr. 5.3. Frontální NS....48
Obr. 5.4. NS s oknem do minulosti....48
Obr. 5.5. Filtr frontální NS....49
Obr. 6.1. Proces modelování....50
Obr. 6.2. Vývoj míry inflace....51
Obr. 6.3. Klouzavý průměr deflátoru....53
Obr. 6.4. Váhový průměr deflátoru....53
Obr. 6.5. Trojúhelníkový průměr deflátoru....54
Obr. 6.6. Exponenciální vyrovnání deflátoru....55
Obr. 6.7. Klouzavý medián deflátoru....55
Obr. 6.8. Struktura navržené sítě....57
Obr. 6.9. Chyba učení frontální NS....58
Obr. 6.10. NS po procesu učení....61
Obr. 8.1. Manager Panel....71
Obr. 8.2. Okno File....71
Obr. 8.3. Funkce Bignet....72
Obr. 8.4. Struktura navrhnuté sítě....74
Obr. 8.5. Okno CONTROL....74
Obr. 8.6. Chyba učení MSE....76
Obr. 8.7. Uložení výsledku....77

Seznam tabulek

Tab. 1 Přehled vah pro různé délky klouzavých průměrů a různé řády polynomů.....38
Tab. 2 Modely s filtrem délky 4.....64
Tab. 3 Modely s filtrem délky 5.....64
Tab. 4 Modely s filtrem délky 6.....65
Tab. 5 Modely s filtrem délky 7.....66
Tab. 6 Modely s filtrem délky 8.....67
Tab. 7 Modely s filtrem délky 9.....67
Tab. 8 Modely s filtrem délky 10.....68
Tab. 9 Modely s filtrem délky 11.....69

Seznam použitých zkratek

CPI	Index spotřebitelských cen
PPI	Index cen výrobců
HDP	hrubý domácí produkt
AD	Agregátní poptávka
AS	Agregátní nabídka
ČNB	Česká národní banka
MSE	střední kvadratická chyba
RMSE	střední kvadratická odchylka
SNNS	Stuttgart Neural Network Simulator
XGUI1	grafické uživatelské rozhraní SNNS
TDNN	Time-Delay Neural Net

Seznam příloh

Příloha 1 – Modelování trendové složky CPI a PPI
Příloha 2 – Protokoly o průběhu učení vybraných modelů, nastavení vah synapsí a prahů neuronů

Příloha 1 – Modelování trendové složky CPI a PPI

Jednoduché klouzavé průměry

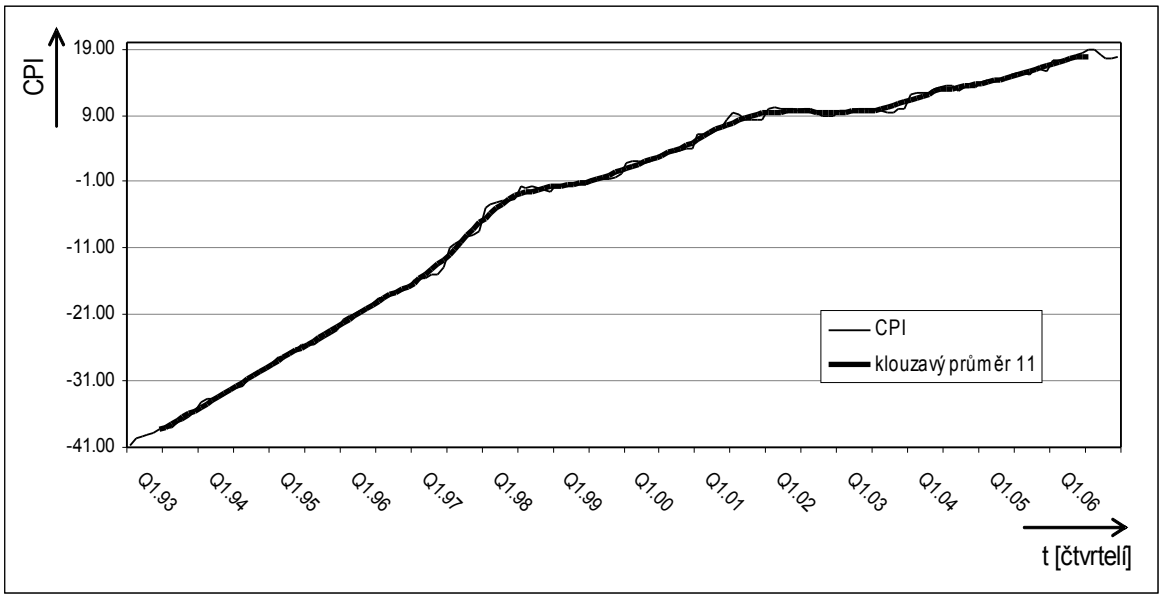

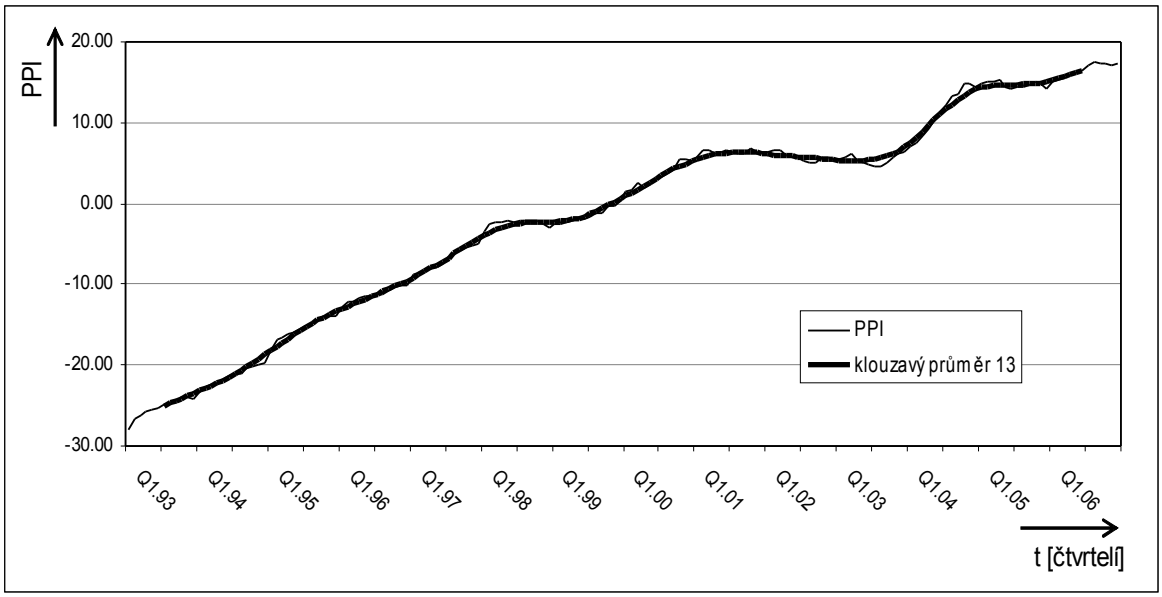

Váhové klouzavé průměry

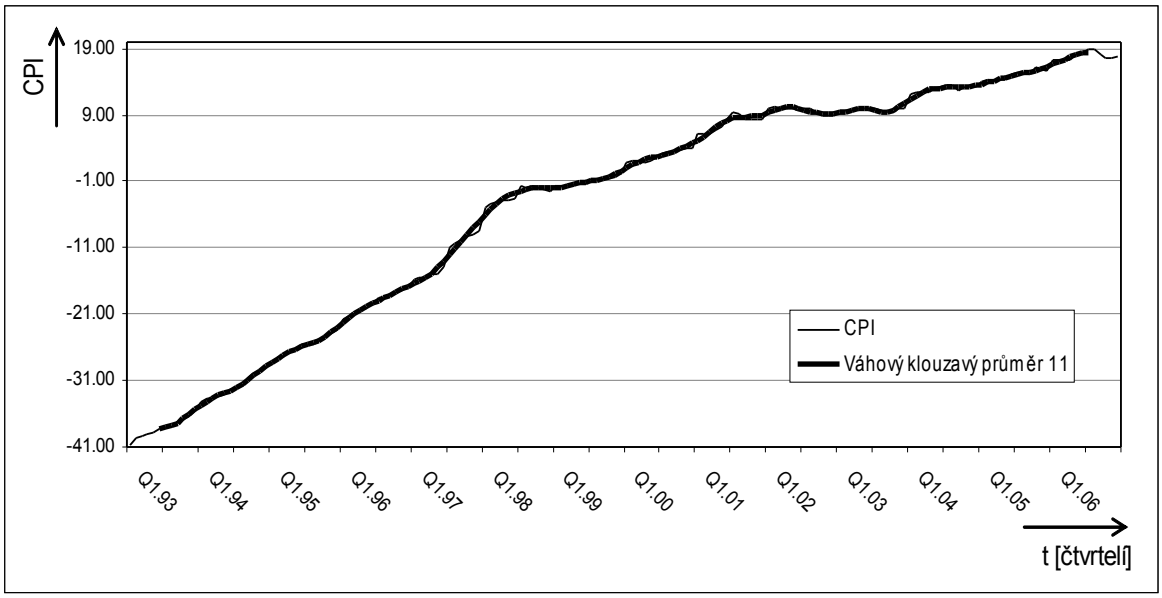

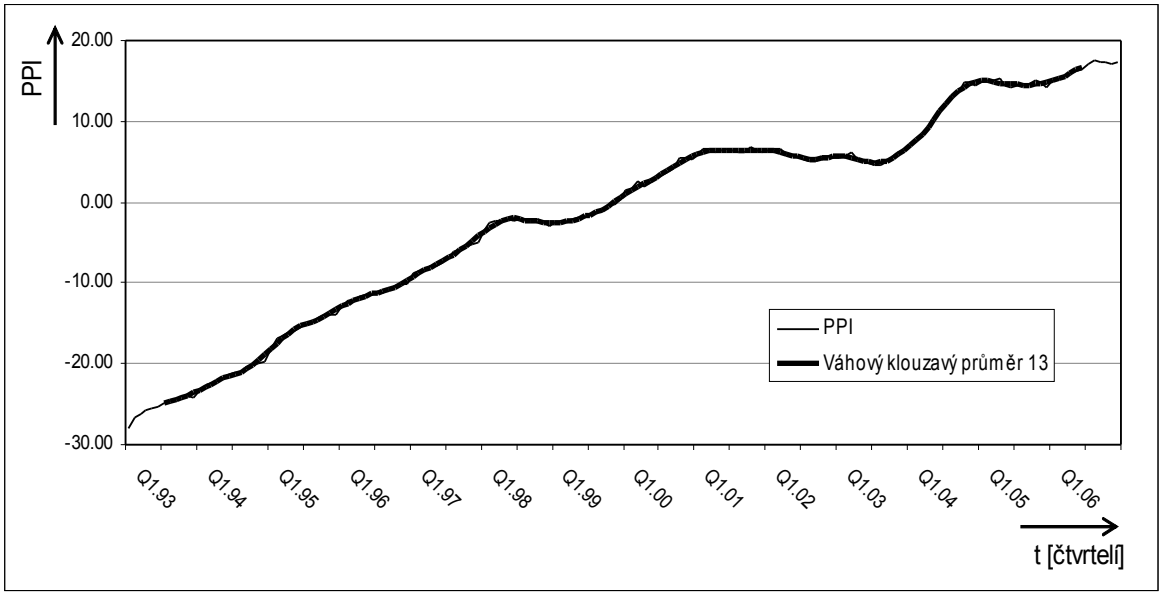

Trojúhelníkové klouzavé průměry

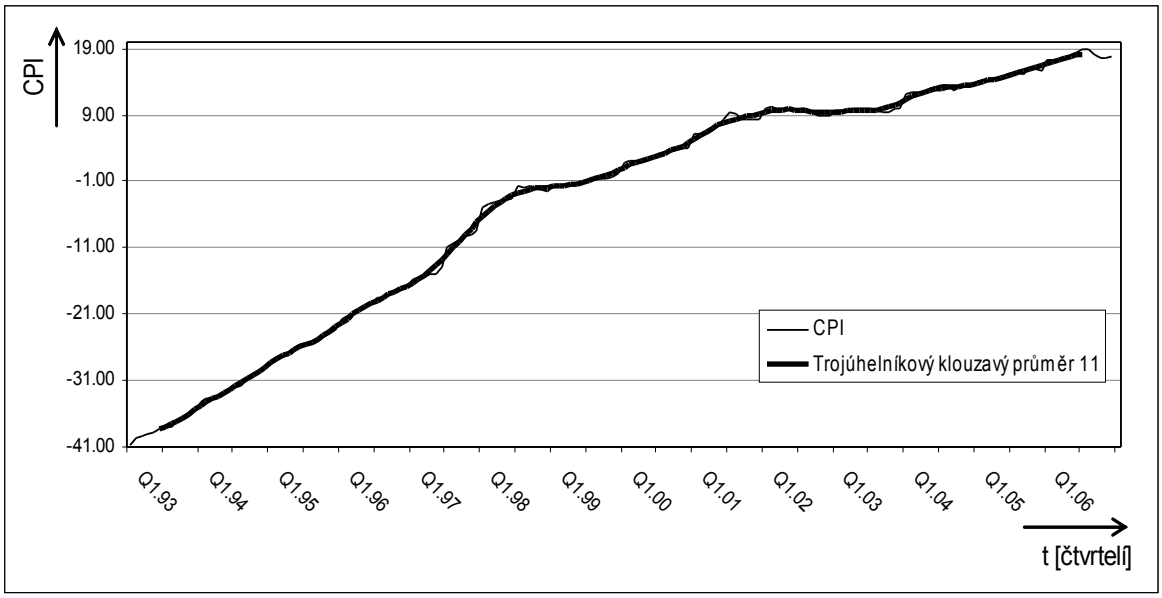

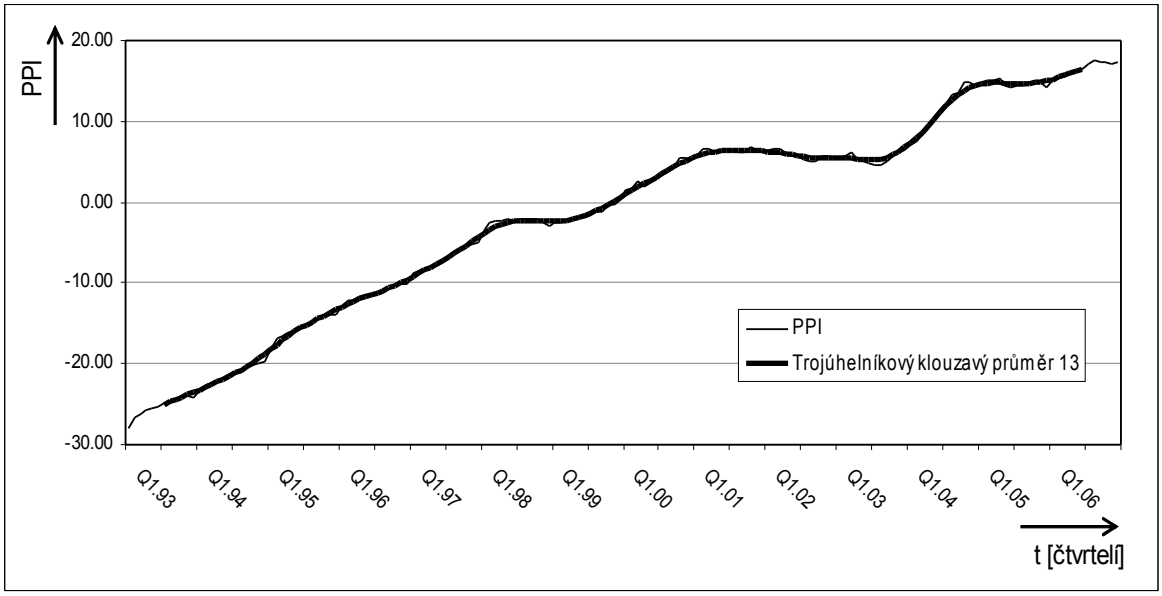

Klouzavé mediány

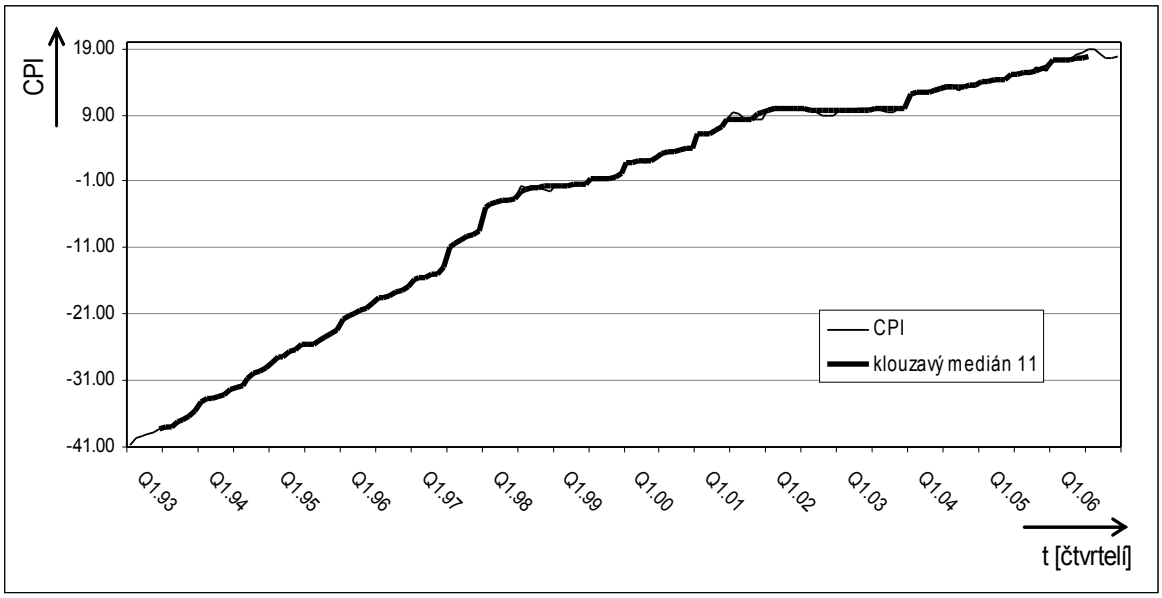

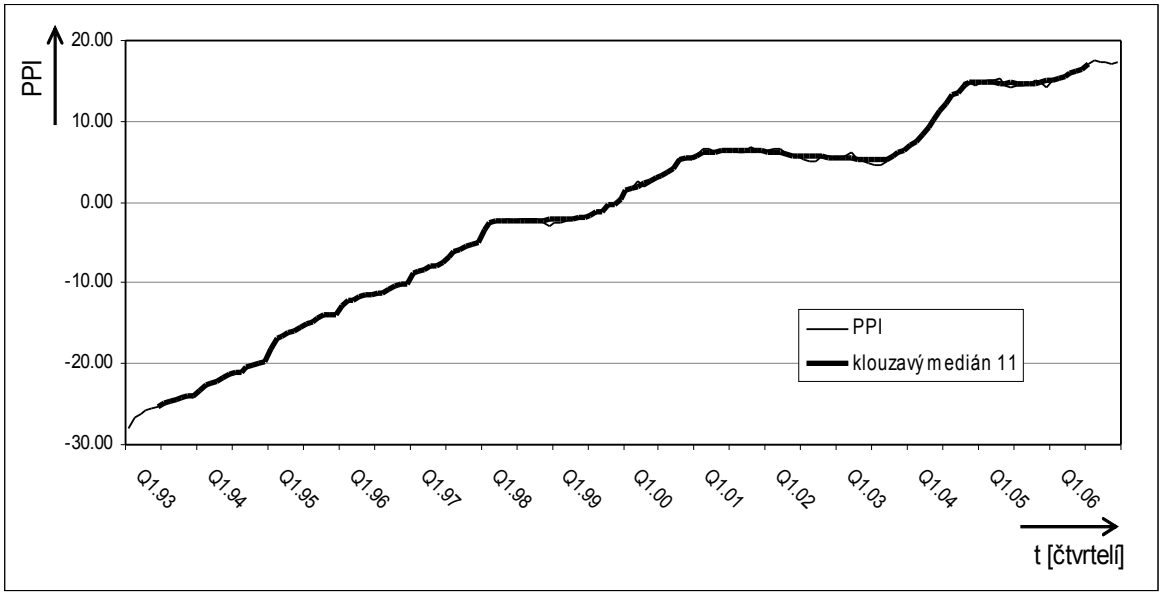

Jednoduché exponenciální vyrovnání

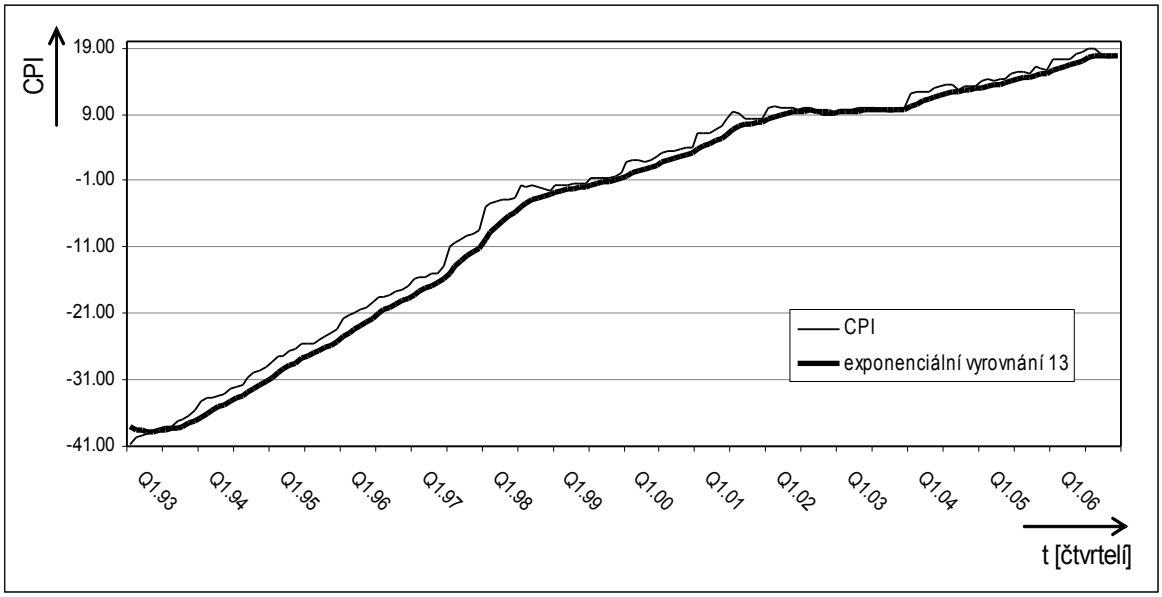

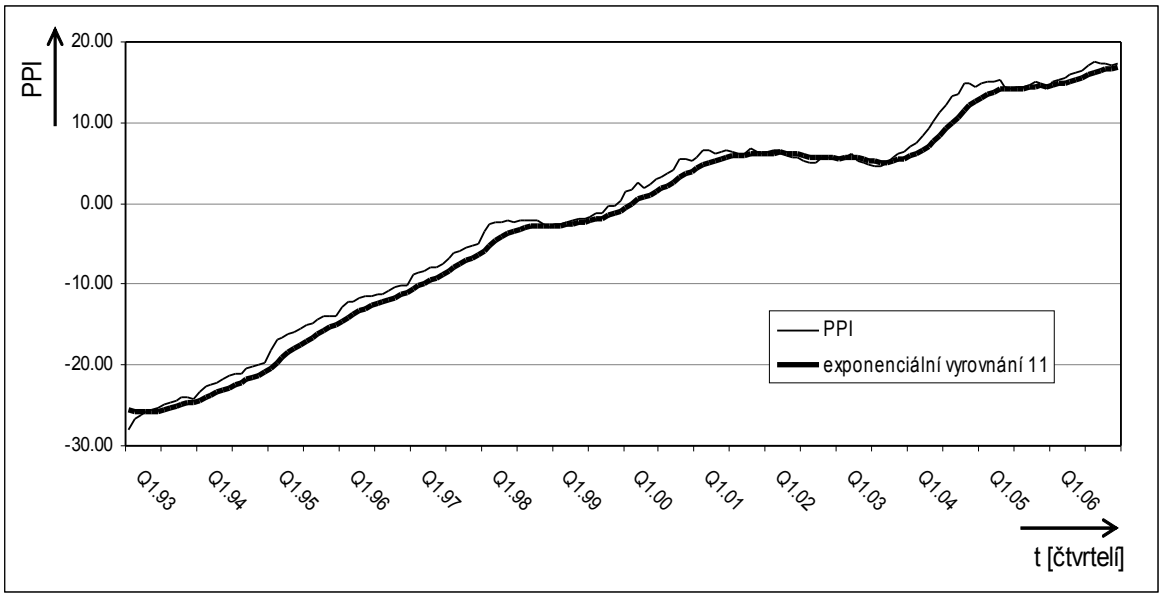

Příloha 2 – Protokoly o průběhu učení vybraných modelů, nastavení vah synapsí a prahů neuronů

Model se strukturou 12-2-1

Síť po procesu učení

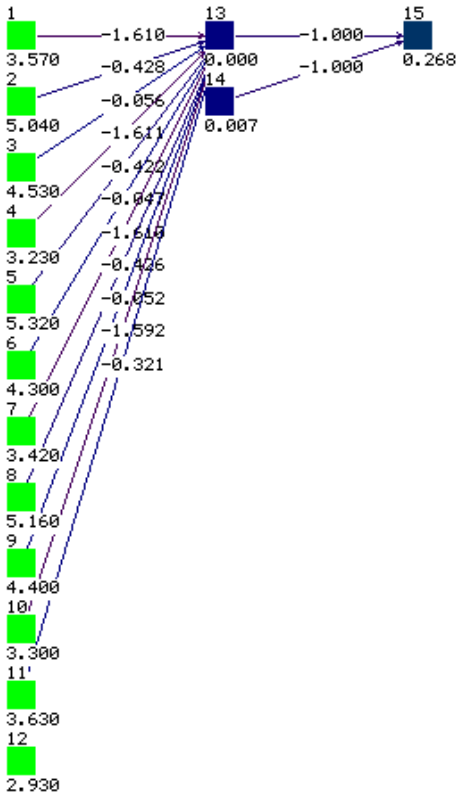

Zobrazení chyby MSE

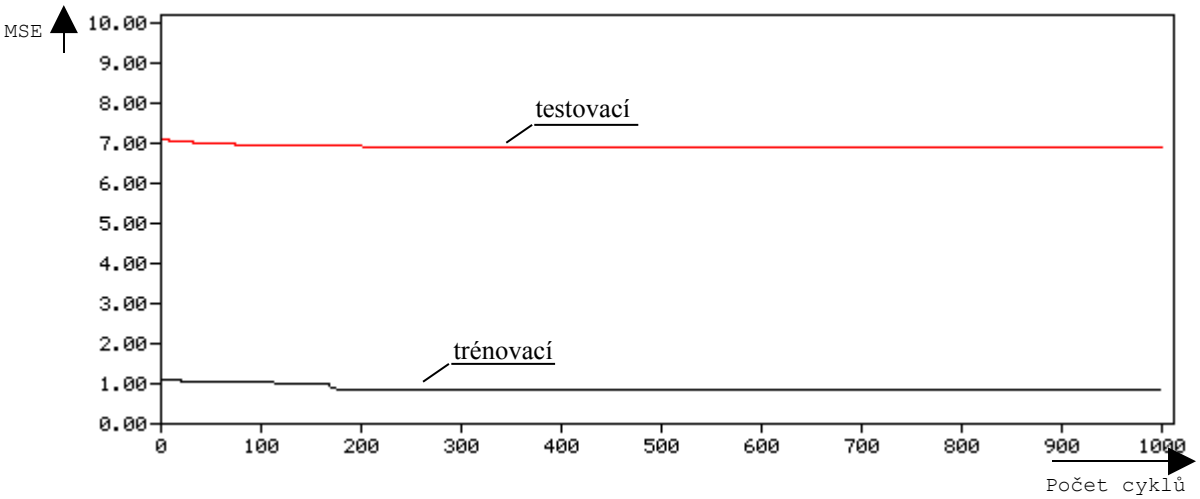

Protokol o průběhu učení

```
Learning func:  TimeDelayBackprop
Update func:  TimeDelay_Order
Init. func:  Randomize_Weights
Remap. func:  LinearScale

Learning all patterns:
  epochs   : 1000
  parameter:  0.01000
  #o-units : 1
  #patterns: 90 (total: 90)

     epoch:         SSE            MSE            SSE/o-units

Train 1000:      96.30921        1.07010          96.30921
Test  1000:     480.86832        7.07159         480.86832
Train  900:      90.50416        1.00560          90.50416
Test   900:     471.40848        6.93248         471.40848
Train  800:      74.81884        0.83132          74.81884
Test   800:     469.20248        6.90004         469.20248
Train  700:      74.31610        0.82573          74.31610
Test   700:     468.33505        6.88728         468.33505
Train  600:      74.08646        0.82318          74.08646
Test   600:     467.93674        6.88142         467.93674
Train  500:      73.95615        0.82174          73.95615
Test   500:     467.71054        6.87810         467.71054
Train  400:      73.87252        0.82081          73.87252
Test   400:     467.56540        6.87596         467.56540
Train  300:      73.81442        0.82016          73.81442
Test   300:     467.46420        6.87447         467.46420
Train  200:      73.77177        0.81969          73.77177
Test   200:     467.39011        6.87338         467.39011
Train  100:      73.73917        0.81932          73.73917
Test   100:     467.33325        6.87255         467.33325
Train    1:      73.71365        0.81904          73.71365
Test     1:     467.28897        6.87190         467.28897
-------------------- s t a t i s t i c s----------------------------------
Number of Patterns :         90
Number of parameters (Links+bias)          :         16
sse                :    73.7135
tss                :     0.5891
rsq                :  -124.1254
mse                :     0.9961
rmse               :     0.9981
adjrsq             :  -149.4886
J_p                :     1.1732
gcv                :     1.2115
pc                 :  -178.2336
S_p                :     0.0136
gmsep              :     1.2280
shibata            :    99.9228
aic                :    14.0339
sbc                :    54.0309
-------------------------------------------------------------------------
```

Nastavení vah na synapsích a prahů neuronů

SNNS network definition file V1.4-3D
generated at Sun Apr 22 16:55:08 2007

network name : net12-2v
source files :
no. of units : 15
no. of connections : 13
no. of unit types : 0
no. of site types : 0

learning function : TimeDelayBackprop
update function : TimeDelay_Order

unit default section :

act	bias	st	subnet	layer	act func	out func
0.00000	0.00000	h	0	1	Act_Logistic	Out_Identity

unit definition section :

no.	typeName	unitName	act	bias	st	positron	act func	out func	sites
1			3.57000	-1.00000	i	2, 2,17632	Act_TD_Logistic		
2			5.04000	-0.99998	i	2, 3,17632	Act_TD_Logistic		
3			4.53000	-0.99999	i	2, 4,17632	Act_TD_Logistic		
4			3.23000	-0.99998	i	2, 5,17632	Act_TD_Logistic		
5			5.32000	-0.99998	i	2, 6,17632	Act_TD_Logistic		
6			4.30000	-0.99999	i	2, 7,17632	Act_TD_Logistic		
7			3.42000	-0.99999	i	2, 8,17632	Act_TD_Logistic		
8			5.16000	-0.99997	i	2, 9,17632	Act_TD_Logistic		
9			4.40000	-0.99997	i	2,10,17632	Act_TD_Logistic		
10			3.30000	-0.99998	i	2,11,17632	Act_TD_Logistic		
11			3.63000	-0.99999	i	2,12,17632	Act_TD_Logistic		
12			2.93000	-0.99997	i	2,13,17632	Act_TD_Logistic		
13			0.00000	-1.07321	h	5, 2,17632	Act_TD_Logistic		
14			0.00680	-4.98443	h	5, 3,17632	Act_TD_Logistic		
15			0.26761	-0.99999	o	8, 2,17632	Act_TD_Logistic		

connection definition section :

target	site	source:weight
13		1:-1.60969, 2:-0.42839, 3:-0.05594, 4:-1.61072, 5:-0.42196, 6:-0.04738, 7:-1.61002, 8:-0.42550, 9:-0.05181, 10:-1.59231, 11:-0.32148
15		13:-0.99998, 14:-0.99998

time delay section :

no.	LLN	LUN	Toff	Soff	Ctype
1	3	0	0	0	0
2	3	0	0	0	0
3	3	0	0	0	0
4	3	0	0	0	0
5	3	0	0	0	0
6	3	0	0	0	0
7	3	0	0	0	0
8	3	0	0	0	0
9	3	0	0	0	0
10	3	0	0	0	0
11	3	0	0	0	0
12	0	0	0	0	0
13	2	0	0	0	0
14	2	0	0	0	0
15	1	0	0	0	0

Model se strukturou 9-4-1

Síť po procesu učení

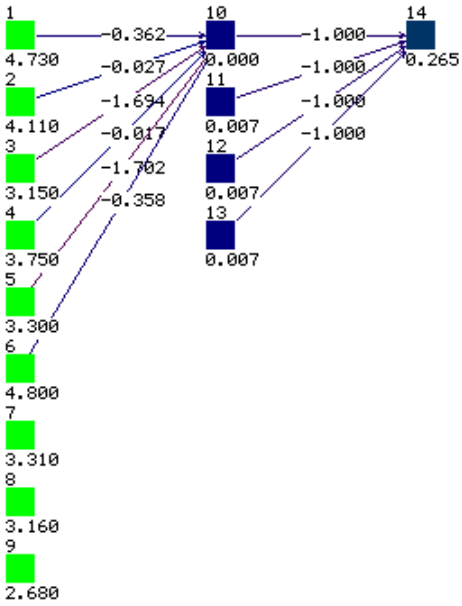

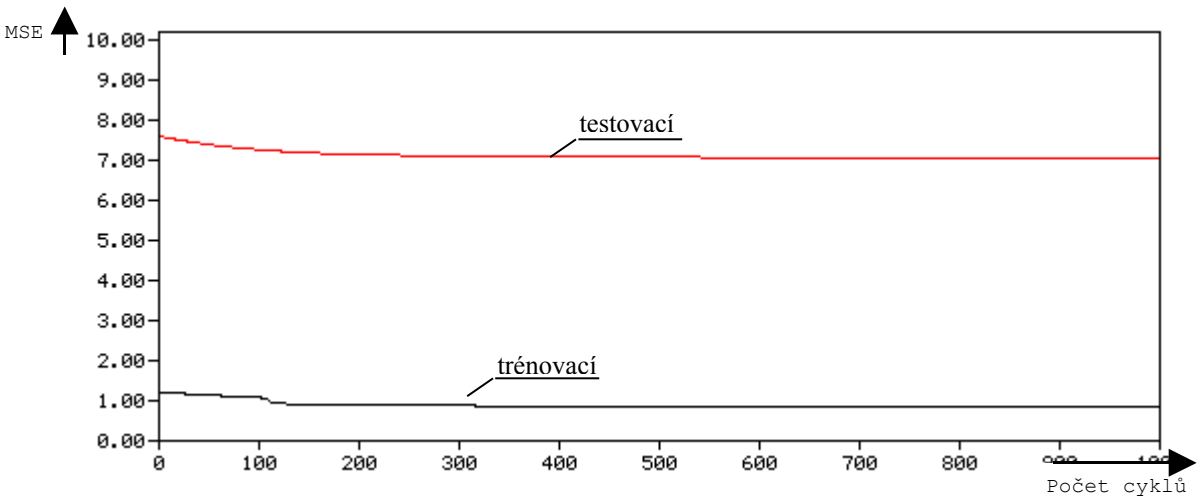

Protokol o průběhu učení

```
Learning func:  TimeDelayBackprop
Update func:  TimeDelay_Order
Init. func:  Randomize_Weights
Remap. func:  LinearScale

Learning all patterns:
  epochs   : 1000
  parameter:  0.01000
  #o-units : 1
  #patterns: 90 (total: 90)

     epoch:         SSE            MSE            SSE/o-units

Train 1000:     107.52612        1.19473         107.52612
Test  1000:     529.91113        7.57016         529.91113
Train  900:      94.75300        1.05281          94.75300
Test   900:     506.82037        7.24029         506.82037
Train  800:      78.16169        0.86846          78.16169
Test   800:     498.40543        7.12008         498.40543
Train  700:      76.64529        0.85161          76.64529
Test   700:     495.68979        7.08128         495.68979
Train  600:      75.94450        0.84383          75.94450
Test   600:     494.42776        7.06325         494.42776
Train  500:      75.54603        0.83940          75.54603
Test   500:     493.70816        7.05297         493.70816
Train  400:      75.29040        0.83656          75.29040
Test   400:     493.24567        7.04637         493.24567
Train  300:      75.11297        0.83459          75.11297
Test   300:     492.92398        7.04177         492.92398
Train  200:      74.98277        0.83314          74.98277
Test   200:     492.68832        7.03840         492.68832
Train  100:      74.88335        0.83204          74.88335
Test   100:     492.50781        7.03583         492.50781
Train    1:      74.80561        0.83117          74.80561
Test     1:     492.36676        7.03381         492.36676
-------------------- s t a t i s t i c s------------------------------
Number of Patterns :         90
Number of parameters (Links+bias)          :         15
sse                :    74.8053
tss                :     0.6430
rsq                :  -115.3409
mse                :     0.9974
rmse               :     0.9987
adjrsq             :  -137.0579
J_p                :     1.1636
gcv                :     1.1969
pc                 :  -161.8773
S_p                :     0.0135
gmsep              :     1.2129
shibata            :    99.7404
aic                :    13.3571
sbc                :    50.8542
```

Nastavení vah na synapsích a prahů neuronů

SNNS network definition file V1.4-3D
generated at Sun Apr 22 17:22:53 2007

network name : net9-4v
source files :
no. of units : 14
no. of connections : 10
no. of unit types : 0
no. of site types : 0

learning function : TimeDelayBackprop
update function : TimeDelay_Order

unit default section :

act	bias	st	subnet	layer	act func	out func
0.00000	0.00000	h	0	1	Act_Logistic	Out_Identity

unit definition section :

no.	typeName	unitName	act	bias	st	position	act func	out func	sites
1			4.73000	-1.00000	i	2, 2,17632	Act_TD_Logistic		
2			4.11000	-0.99998	i	2, 3,17632	Act_TD_Logistic		
3			3.15000	-0.99999	i	2, 4,17632	Act_TD_Logistic		
4			3.75000	-0.99998	i	2, 5,17632	Act_TD_Logistic		
5			3.30000	-0.99998	i	2, 6,17632	Act_TD_Logistic		
6			4.80000	-0.99999	i	2, 7,17632	Act_TD_Logistic		
7			3.31000	-0.99999	i	2, 8,17632	Act_TD_Logistic		
8			3.16000	-0.99997	i	2, 9,17632	Act_TD_Logistic		
9			2.68000	-0.99997	i	2,10,17632	Act_TD_Logistic		
10			0.00000	-1.10695	h	5, 2,17632	Act_TD_Logistic		
11			0.00684	-4.97752	h	5, 3,17632	Act_TD_Logistic		
12			0.00684	-4.97753	h	5, 4,17632	Act_TD_Logistic		
13			0.00684	-4.97753	h	5, 5,17632	Act_TD_Logistic		
14			0.26492	-0.99999	o	8, 2,17632	Act_TD_Logistic		

connection definition section :

target	site	source:weight
10		1:-0.36192, 2:-0.02671, 3:-1.69388, 4:-0.01685, 5:-1.70229, 6:-0.35784
14		10:-0.99997, 11:-0.99999, 12:-1.00000, 13:-1.00000

time delay section :

no.	LLN	LUN	Toff	Soff	Ctype
1	3	0	0	0	0
2	3	0	0	0	0
3	3	0	0	0	0
4	3	0	0	0	0
5	3	0	0	0	0
6	3	0	0	0	0
7	0	0	0	0	0
8	0	0	0	0	0
9	0	0	0	0	0
10	2	0	0	0	0
11	2	0	0	0	0
12	2	0	0	0	0
13	2	0	0	0	0
14	1	0	0	0	0

Model se strukturou 15 -6-1

Síť po procesu učení

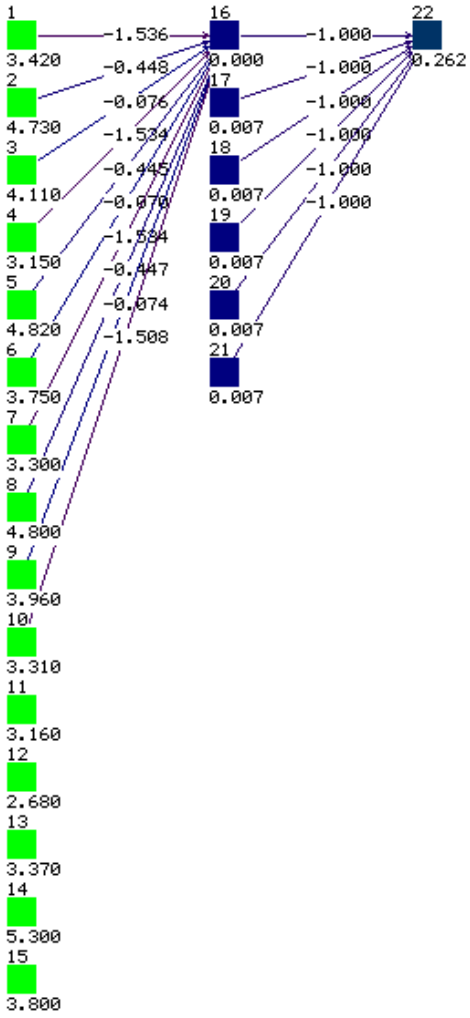

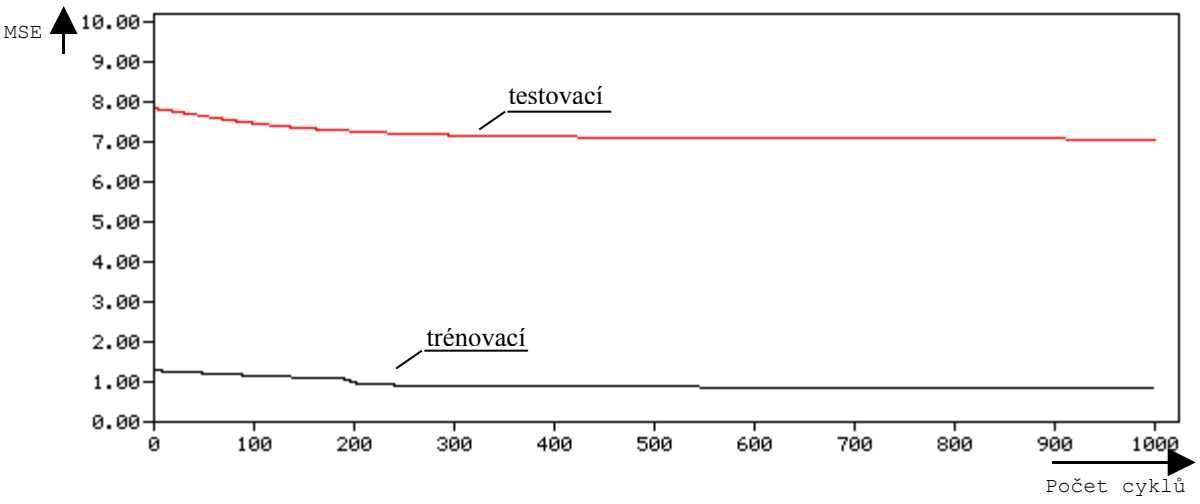

Protokol o průběhu učení

```
Learning func:  TimeDelayBackprop
Update func:  TimeDelay_Order
Init. func:  Randomize_Weights
Remap. func:  LinearScale

Learning all patterns:
  epochs   : 1000
  parameter:  0.01000
  #o-units : 1
  #patterns: 90 (total: 90)

     epoch:         SSE            MSE            SSE/o-units

Train 1000:     113.27649        1.25863         113.27649
Test  1000:     547.00421        7.81435         547.00421
Train  900:     102.23265        1.13592         102.23265
Test   900:     520.93127        7.44188         520.93127
Train  800:      87.07006        0.96745          87.07006
Test   800:     506.92911        7.24184         506.92911
Train  700:      79.17849        0.87976          79.17849
Test   700:     500.22897        7.14613         500.22897
Train  600:      77.59717        0.86219          77.59717
Test   600:     497.40436        7.10578         497.40436
Train  500:      76.75508        0.85283          76.75508
Test   500:     495.89227        7.08418         495.89227
Train  400:      76.23743        0.84708          76.23743
Test   400:     494.95956        7.07085         494.95956
Train  300:      75.88863        0.84321          75.88863
Test   300:     494.33002        7.06186         494.33002
Train  200:      75.63829        0.84043          75.63829
Test   200:     493.87756        7.05539         493.87756
Train  100:      75.45023        0.83834          75.45023
Test   100:     493.53732        7.05053         493.53732
Train    1:      75.30518        0.83672          75.30518
Test     1:     493.27466        7.04678         493.27466
-------------------- s t a t i s t i c s------------------------------
Number of Patterns :         90
Number of parameters (Links+bias)          :         23
sse                :    75.3045
tss                :     0.6430
rsq                :  -116.1174
mse                :     1.1239
rmse               :     1.0602
adjrsq             :  -154.5739
J_p                :     1.4112
gcv                :     1.5098
pc                 :  -196.5264
S_p                :     0.0170
gmsep              :     1.5325
shibata            :   113.7935
aic                :    29.9558
sbc                :    87.4514
```

Nastavení vah na synapsích a prahů neuronů

SNNS network definition file V1.4-3D
generated at Sun Apr 22 17:47:40 2007

network name : net15-6v
source files :
no. of units : 22
no. of connections : 16
no. of unit types : 0
no. of site types : 0

learning function : TimeDelayBackprop
update function : TimeDelay_Order

unit default section :

act	bias	st	subnet	layer	act func	out func
0.00000	0.00000	h	0	1	Act_Logistic	Out_Identity

unit definition section :

no.	typeName	unitName	act	bias	st	position	act func	out func	sites
1			3.42000	-1.00000	i	2, 2, 0	Act_TD_Logistic		
2			4.73000	-0.99998	i	2, 3, 0	Act_TD_Logistic		
3			4.11000	-0.99999	i	2, 4, 0	Act_TD_Logistic		
4			3.15000	-0.99998	i	2, 5, 0	Act_TD_Logistic		
5			4.82000	-0.99998	i	2, 6, 0	Act_TD_Logistic		
6			3.75000	-0.99999	i	2, 7, 0	Act_TD_Logistic		
7			3.30000	-0.99999	i	2, 8, 0	Act_TD_Logistic		
8			4.80000	-0.99997	i	2, 9, 0	Act_TD_Logistic		
9			3.96000	-0.99997	i	2,10, 0	Act_TD_Logistic		
10			3.31000	-0.99998	i	2,11, 0	Act_TD_Logistic		
11			3.16000	-0.99999	i	2,12, 0	Act_TD_Logistic		
12			2.68000	-0.99997	i	2,13, 0	Act_TD_Logistic		
13			3.37000	-0.99998	i	2,14, 0	Act_TD_Logistic		
14			5.30000	-0.99998	i	2,15, 0	Act_TD_Logistic		
15			3.80000	-0.99999	i	2,16, 0	Act_TD_Logistic		
16			0.00000	-1.06090	h	5, 2, 0	Act_TD_Logistic		
17			0.00725	-4.91886	h	5, 3, 0	Act_TD_Logistic		
18			0.00725	-4.91887	h	5, 4, 0	Act_TD_Logistic		
19			0.00725	-4.91885	h	5, 5, 0	Act_TD_Logistic		
20			0.00725	-4.91884	h	5, 6, 0	Act_TD_Logistic		
21			0.00725	-4.91884	h	5, 7, 0	Act_TD_Logistic		
22			0.26187	-0.99998	o	8, 2, 0	Act_TD_Logistic		

connection definition section :

target	site	source:weight
16		1:-1.53557, 2:-0.44814, 3:-0.07642, 4:-1.53351, 5:-0.44451, 6:-0.06978, 7:-1.53439, 8:-0.44665, 9:-0.07378, 10:-1.50810
22		16:-0.99999, 17:-0.99999, 18:-1.00000, 19:-0.99998, 20:-0.99998, 21:-0.99998

time delay section :

no.	LLN	LUN	Toff	Soff	Ctype
1	3	0	0	0	0
2	3	0	0	0	0
3	3	0	0	0	0
4	3	0	0	0	0
5	3	0	0	0	0
6	3	0	0	0	0
7	3	0	0	0	0
8	3	0	0	0	0
9	3	0	0	0	0
10	3	0	0	0	0
11	0	0	0	0	0
12	0	0	0	0	0
13	0	0	0	0	0
14	0	0	0	0	0
15	0	0	0	0	0
16	2	0	0	0	0
17	2	0	0	0	0
18	2	0	0	0	0
19	2	0	0	0	0
20	2	0	0	0	0
21	2	0	0	0	0
22	1	0	0	0	0

Údaje pro knihovnickou databázi

Název práce	Modelování vývoje inflace pomocí frontálních neuronových sítí
Autor práce	Klára Trpišovská
Obor	Informatika ve veřejné správě
Rok obhajoby	2007
Vedoucí práce	prof. Ing. Vladimír Olej, CSc.
Anotace	Diplomová práce se zabývá návrhem modelů frontálních neuronových sítí pro predikci vývoje míry inflace. Jako vstupní hodnoty pro učení neuronové sítě je použit cenový index, index cen výrobků a deflátor, ze kterých se odvozuje míra inflace. Všechna data se týkají vývoje v ČR. V diplomové práci jsou popsány jednotlivé indikátory míry inflace, typy inflací, ale také způsob modelování trendových složek použitých indexů pomocí klouzavých průměrů a exponenciálních vyrovnání. Je zde navrhnuta frontální neuronová síť a uvedeny i základy dopředných neuronových sítí, které jsou vhodné pro predikci. V další části práce jsou analyzovány navrhnuté modely frontálních neuronových sítí. Verifikace navrhnutých modelů je realizována v Stuttgartském simulátoru neuronových sítí.
Klíčová slova	Inflace, CPI, PPI, deflátor HDP, dopředné neuronové sítě, frontální neuronové sítě, perceptron, filtr NS, SNNS