

**Univerzita Pardubice**

**Fakulta ekonomicko-správní  
Ústav systémového inženýrství a informatiky**

**Modelování na burze cenných papírů metodami  
umělé inteligence**

**Bc. Vojtěch Zákoutský**

**Diplomová práce  
2013**

Univerzita Pardubice  
Fakulta ekonomicko-správní  
Akademický rok: 2012/2013

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: Bc. Vojtěch Zákoutský  
Osobní číslo: E110150  
Studijní program: N6209 Systémové inženýrství a informatika  
Studijní obor: Informatika ve veřejné správě  
Název tématu: Modelování na burze cenných papírů metodami umělé inteligence  
Zadávací katedra: Ústav systémového inženýrství a informatiky

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

Analýza dat získaná z burzy cenných papírů  
Předpracování dat  
Navržení modelu obchodování na bázi RBF neuronové sítě  
Verifikace modelu  
Zhodnocení výsledků

Rozsah grafických prací:

Rozsah pracovní zprávy: cca 60 stran

Forma zpracování diplomové práce: tištěná/elektronická

Seznam odborné literatury:

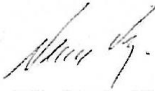
MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (3).  
Praha: Academia, 2001. ISBN 80-200-0472-6.

KVASNIČKA, V. a kol. Úvod do teorie neuronových sítí. Bratislava: IRIS,  
1997. ISBN 80-88778-30-1.

HAYKIN, S. Neural Networks: A Comprehensive Foundation. 2. vyd.  
Singapore: Pearson Education, 2005. ISBN 81-7808-300-0.

TUREK, L. První kroky na burze. Brno: Computer Press, 2008. ISBN 978-  
80-251-1915-0.


Vedoucí diplomové práce:

  
prof. Ing. Vladimír Olej, CSc.


Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: 3. října 2012

Termín odevzdání diplomové práce: 30. dubna 2013

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

L.S.

  
prof. Ing. Jan Čapík, CSc.  
vedoucí ústavu

V Pardubicích dne 3. října 2012

## **Prohlášení**

Prohlašuji, že jsem tuto práci vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

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

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 30. 4. 2013

Vojtěch Zákoutský

## **Poděkování:**

Tímto bych rád poděkoval svému vedoucímu práce, panu prof. Ing. Vladimíru Olejovi, CSc. za jeho odbornou pomoc, cenné připomínky k formální i obsahové stránce a podporu jak při vypracovávání práce, tak při studiu.

Dále bych rád poděkoval své rodině, jež mi stála vždy oporou a umožnila mi studovat na vysoké škole a sepsat tuto práci.

## **Anotace**

*Tato diplomová práce se zabývá modelováním na burze cenných papírů pomocí RBF neuronových sítí. Cílem je vytvoření modelů a následně jejich verifikace na datech reálných společností obchodovaných na burze. Výstupem je výběr nejvhodnějšího modelu s ohledem na vybraný obchodní styl.*

## **Klíčová slova**

*Neuronové sítě, radiálně bazické funkce, RBF neuronová síť, genetický algoritmus, časové řady, akcie*

## **Title**

*Stock Exchange Modelling using Methods of Artificial Intelligence*

## **Annotation**

*This thesis deals with the stock Exchange modeling using RBF neural networks. The aim of the work is to create models and then their verification on data of real companies traded on the stock exchange. The output is a selection of the best model with respect to selected trading style.*

## **Keywords**

*Neural network, radial basis function, RBF neural network, genetic algorithm, time series, stock*

## Obsah

Úvod .....	8
1. Obchodování na burze cenných papírů .....	10
1.1. Základní pojmy .....	10
1.2. Burza cenných papírů .....	11
1.3. Strategie a styly obchodování na burze cenných papírů .....	11
1.4. Technická analýza .....	12
1.5. Fundamentální analýza .....	14
1.6. Dílčí závěry .....	14
2. RBF neuronové sítě .....	16
2.1. Základní pojmy .....	16
2.2. Radiálně bazické funkce .....	17
2.3. Struktura RBF neuronové sítě .....	19
2.4. Učení RBF neuronové sítě .....	20
2.5. Dílčí závěry .....	23
3. Genetické algoritmy .....	24
3.1. Základní pojmy .....	24
3.2. Terminologie používaná v genetických algoritmech .....	24
3.3. Obecný genetický algoritmus .....	25
3.4. Modifikovaný genetický algoritmus .....	27
3.5. Implementace modifikovaného genetického algoritmu .....	31
3.6. Dílčí závěry .....	34
4. Návrh modelu obchodování na burze .....	35
4.1. Základní pojmy .....	35
4.2. Výběr datových sad .....	36
4.3. Analýza dat .....	37

4.4.	Návrh modelu obchodování.....	38
4.5.	Návrh modelů zapojení RBF neuronové sítě.....	40
4.6.	Návrh fitness funkce.....	41
4.7.	Návrh testovacích kritérií .....	42
4.8.	Dílčí závěry.....	43
5.	Výběr vhodné radiálně bazické funkce.....	44
5.1.	Stanovení průběhu experimentů .....	44
5.2.	Srovnání rychlosti učení.....	44
5.3.	Vliv nastavení poloměru neuronu na rychlost učení.....	45
5.4.	Srovnání hodnot fitness funkce.....	47
5.5.	Dílčí závěry.....	50
6.	Porovnání modelů PC, PMA, TD a P45 .....	52
6.1.	Stanovení průběhu experimentů .....	52
6.2.	Porovnání hodnot fitness funkce.....	52
6.3.	Kvalita predikce na trénovacích a testovacích datech.....	53
6.4.	Test určení trendu na trénovacích a testovacích datech .....	56
6.5.	Kvalita predikce na neznámých datech .....	56
6.6.	Test určení trendu na neznámých datech.....	57
6.7.	Dílčí závěry.....	59
	Závěr.....	60
	Seznam použité literatury .....	62
	Seznam použitých symbolů a zkratk .....	65
	Seznam obrázků .....	65
	Seznam tabulek .....	66
	Seznam příloh .....	67



## Úvod

Je snem každého obchodníka s akcemi, aby dokázal určit, jaký bude další vývoj na akciovém trhu a jakým směrem se vydá cena akcie. Existuje mnoho technik, jež se snaží poskytnout potřebné informace a rozhodnout se zda nakoupit či prodat a minimalizovat ztrátu či maximalizovat zisk. Neuronové sítě jsou díky své schopnosti aproximovat časovou řadu vhodným kandidátem právě pro tento účel využití.

Diplomová práce si bere za cíl využít vybrané metody umělé inteligence pro modelování dat získaných z burzy s cennými papíry. Je rozdělena do šesti kapitol tak, aby postupně naplnila své cíle:

- Výběr vhodných dat, jejich analýza a předzpracování.
- Navržení modelu obchodování na bázi RBF neuronových sítí.
- Verifikace modelu a zhodnocení výsledků.

První kapitola se zabývá samotnou burzou s cennými papíry, základními principy a názvoslovím. Definovány budou i jednotlivé obchodní styly a základy technické a fundamentální analýzy.

Druhá kapitola se věnuje neuronovým sítím typu RBF. Jsou popsány jednotlivé radiálně bazické funkce (RBF) a definována struktura tohoto typu neuronové sítě. Konec kapitoly je věnován učení RBF neuronové sítě s učitelem.

Následující kapitola pojednává o genetickém algoritmu (GA). Ten byl zvolen pro učení a optimalizaci struktury neuronové sítě. Je zde popsána základní terminologie spojená s genetickými algoritmy a popsán základní genetický algoritmus. Dále se kapitola věnuje modifikaci GA na řešený problém, tedy učení neuronové sítě typu RBF. Konec kapitoly popisuje aplikaci, která vznikla implementací modifikovaného GA. Ta je navržena jako webová aplikace a napsána v jazycích PHP a JavaScript.

Čtvrtá kapitola obsahuje popis, výběr, analýzu a předzpracování dat. Výběr padne na pět významných IT firem, s nimiž se obchoduje na burze s cennými papíry NASDAQ v USA. Dále obsahuje návrh modelů pro obchodování na burze, jejich popis a také návrh kritérií, pomocí kterých budou modely hodnoceny.

Další kapitola je věnována výběru nejvhodnější radiálně bazické funkce. Vybírána je jedna ze tří funkcí popsaných v druhé kapitole a právě volba funkce do značné míry ovlivňuje kvalitu modelu.

Poslední, šestá kapitola porovnává vybrané modely podle dříve stanovených kritérií. Analyzovány jsou čtyři modely, které slouží k predikci otevírací ceny akcie tak, aby odpovídaly vybranému stylu obchodování na burze. Součástí této diplomové práce je i množství příloh, převážně grafických výstupů, které dokumentují důležité poznatky a průběhy získané při provádění experimentů.

## **1. Obchodování na burze cenných papírů**

Cílem kapitoly je seznámení s pojmy souvisejícími s cennými papíry, konkrétně akciemi a s jejich obchodováním. Popsány budou základní funkční principy burzy s cennými papíry a možnosti obchodování na ní. S tím souvisí strategie a styly obchodování, které jsou rozděleny podle trendů, od dlouhodobých po krátkodobé, které obchodník využívá. Dále budou popsány postupy technické a fundamentální analýzy, jakožto základem znalostí každého obchodníka na burze s cennými papíry.

### **1.1. Základní pojmy**

Cenný papír je veřejná listina, či zápis ve stanovené podobě, se kterou je spojeno určité právo majitele. Cenným papírem jsou akcie, zatímni listy, podílové listy, dluhopisy, šeky, směnky, investiční kupóny, cestovní šeky, skladištní listy a další listiny podle zvláštních zákonů. Formy cenných papírů jsou tři: na doručitele, na jméno a na řád.[4]

Akcie je obchodovatelný cenný papír, s nímž jsou spojena práva jeho vlastníka na řízení společnosti a na podílu na zisk společnosti. Podíl na zisku společnosti vyplývající z jejího vlastnictví se nazývá dividenda.[26]

Okamžitá cena akcie na burze s cennými papíry představuje její kurz. Kurz je vytvářen na základě nabídky a poptávky po akciích dané společnosti a je závislý na skutečných i očekávaných hospodářských výsledcích společnosti, vývoji odvětví, stavu ekonomiky a dalších faktorech jako například tržním podílu společnosti, marketingu apod.[26]

Trendem je označena změna ceny akcie. Rozlišují se tři základní typy. Klesající trend znamená, že otevírací cena akcie daného dne je nižší než otevírací cena dne předchozího. Tuto definici lze aplikovat i na zavírací cenu stejným způsobem. Opakem je trend rostoucí, kdy cena, otevírací či zavírací je vyšší než u dne předešlého. Posledním typem jsou korekce, drobné fluktuace korigující dopady předešlého výrazného poklesu či růstu ceny akcie. Dále se rozlišují dlouhodobý primární trend, střednědobý sekundární trend a krátkodobý vedlejší trend.[26][24]

Broker je osoba oprávněná provádět operace na akciových trzích. Provádí je na přání zákazníka a za každou objednávku mu náleží odměna neboli provize.[26]

## **1.2. Burza cenných papírů**

Pro obchodování s akciemi jsou určeny takzvané burzy cenných papírů. Jejimi členy jsou specializované firmy nazývané brokerské společnosti. Ty spolu s bankovními domy mají jediný přímý přístup k obchodování na burze. Ostatní subjekty musí uzavřít smlouvu s obchodníkem s cennými papíry a ten pak na základě požadavků na nákup či prodej akcií plní jejich příkazy.[23]

Nejznámější světovou burzou je New York Stock Exchange (NYSE) nacházející se na Wall Street. Další velké burzy jsou v Londýně a Tokiu. V České Republice existují dvě burzy cenných papírů a to Burza cenných papírů Praha (BCPP) a RM-Systém.[23]

## **1.3. Strategie a styly obchodování na burze cenných papírů**

Existují dvě základní obchodní strategie. Nejpoužívanější je spekulace na vzestup ceny. Při ní se nakupují akcie za nízkou cenu, přičemž se očekává její růst a následný prodej za tuto vyšší cenu. Druhou možností je spekulace na pokles ceny, kdy jsou nejdříve vypůjčeny akcie od brokera a prodány za současnou cenu. Při poklesu ceny dané akcie se následně nakoupí stejné množství a vrátí brokerovi. Zisk tvoří rozdíl mezi prodejní a nákupní cenou.[26]

Obchodním stylem se rozumí doba držení akcie. Existuje více obchodních stylů od krátkodobých, s dobou držení jen několik hodin, až po dlouhodobé, fungující jako investice. Přitom platí, že čím kratší časové pásmo je, tím stoupá riziko. Důležité jsou v tomto případě zkušenosti obchodníka a méně zkušeným jsou doporučeny dlouhodobější styly s nižším rizikem.[26]

První obchodní styl se nazývá investování nebo také technika „kup a drž“. Jedná se o dlouhodobý obchodní styl, kdy jsou cenné papíry drženy v řádu měsíců i let. Před nákupem by měla být provedena potřebná fundamentální analýza a výběr by měl padnout na společnosti s vysokým růstovým potenciálem.[26]

Poziční obchodování se zaměřuje na nákup a prodej akcií v trendech. Obchodník se snaží odhadnout hladiny překoupenosti a přeprodanosti a následně spekuluje na návrat na normální hladinu. Obchoduje se převážně v týdnech a měsících. Tento styl je doporučen začínajícím obchodníkům.[26]

Swing obchodování je varianta pozičního obchodování. Obchodníka zajímají denní grafy a většina akcií je držena po dobu dvou až pěti dnů. Hlavním nástrojem je zde technická analýza. Výhodou je nejnižší psychologická zátěž a možnost dobře určit strategii obchodování. Statisticky je tento typ obchodování uváděn jako nejziskovější.[26]

Daytrading neboli obchodování v rámci jednoho dne je styl, kdy jsou všechny akcie prodány před koncem dne a nikdy nejsou drženy do dne dalšího. Je to psychicky velmi náročný styl využívající převážně technickou analýzu a grafy s intervaly 2 až 60 minut. Výhodou je nezávislost obchodníka na rozhodnutích z minulého dne. Nevýhodou je nemožnost využití dlouhodobých trendů a nejsou zaručeny lepší výsledky než u swing obchodování.[26]


Scalping je styl obchodování, kdy jsou akcie drženy jen několik minut či sekund. Jeho princip spočívá v nákupu velkých objemů a následný rychlý prodej. Malý zisk na akcii je násoben velkým kapitálem a tím vzniká i dostatečně velký zisk. Rizikovost tohoto stylu obchodování je vysoká a udržení zisku touto metodou v dlouhém horizontu není snadné. Výhodou je, že krátkodobé trendy akcií se odhadují snadněji než ty dlouhodobé.[26]

#### **1.4. Technická analýza**

Při obchodování s akciemi se často využívá technická analýza. Ta zkoumá trh nabídky a poptávky akcií a snaží se nalézt opakující se vzory v chování ceny akcie. Využívá ceny akcie a obchodovaný objem a předpokládá, že pokud se akcie v minulosti chovala určitým způsobem, kupříkladu rostla, bude se podobný jev znovu opakovat a průběh bude velice podobný. Předpokládá přitom, že trh je ovlivněn pouze nabídkou a poptávkou, že posuny nabídky a poptávky lze včas identifikovat a že studiem jejich vývoje lze prognózovat budoucí cenu akcie. [24][25]

Technická analýza se skládá hlavně ze tří operací. Vyhodnocení trendů, zkoumání grafů pomocí linií a formací a zkoumání klouzavých průměrů a dalších identifikátorů. Tato metoda je hojně používána a je prokázána její funkčnost.[26]

Hlavním nástrojem technické analýzy je graf. Nejčastěji využívané jsou čárkový graf a svíčkový graf. Oba grafy zakreslují čtyři základní údaje o denních cenách akcie a to otevírací, zavírací, minimální a maximální cenu. Rozdíl je v mírně odlišné vizuální interpretaci. Svíčkový graf, jehož ukázka je na obrázku 1, obsahuje jednu informaci navíc. Pokud není tělo, tvořené rozdílem mezi otevírací a zavírací cenou, obarveno, znamená to, že zavírací cena byla vyšší než otevírací a tedy došlo k převisu poptávky nad nabídkou. Naopak černé podbarvení značí opak. [24][26]



Obr. 1: Náhled průběhu vývoje akcií GOOG

*Zdroj: Vlastní zpracování*

Součástí technické analýzy mohou být i další indikátory. Je ale důležité upozornit, že cena je vždy na prvním místě a všechny indikátory slouží pouze ke zvýraznění určitých skutečností. Použití mnoha indikátorů učiní grafický výstup nepřehledný. Vhodná je tedy volba menšího počtu indikátorů, které obchodník skutečně využívá. Indikátory jsou děleny na trendové, indikátory volatility a indikátory hybnosti. Nejjednodušší a nejpoužívanější jsou klouzavé průměry (Moving Averages), patřící mezi trendové indikátory.[25][26]

## **1.5. Fundamentální analýza**

Cílem fundamentální analýzy je zhodnocení různých makroekonomických a mikroekonomických činitelů a nalezení podhodnocených společností s potencionálním růstem její hodnoty či naopak nadhodnocení investiční instrumenty. Hodnotí se vnější i vnitropolitické vlivy, majetek, finance, výsledky hospodaření a další kritéria. Cílem analýzy je nalezení vnitřní hodnoty (fair-value). Tato analýza je důležitá u investičního stylu obchodování. Fundamentální analýza se dělí na tři úrovně.[26] [9]

Globální analýza se snaží zhodnotit stav ekonomiky na úrovni státu či dokonce na celosvětové úrovni. Snaží se při tom identifikovat makroekonomické ukazatele, jež by předpověděly možný směr pohybu ceny akcie.[9]

Odvětvová analýza zkoumá vývoj a charakteristiky jednotlivých odvětví. Snaží se zjistit ziskovost odvětví, jeho schopnost inovací či technologických pokroků, nákladovost a další charakteristiky. Odvětví je děleno na cyklické, neutrální a anticyklické podle reakce na hospodářské cykly.[9]

Fundamentální analýza společnosti představuje nejnižší úroveň a předpokládá, že každá akcie má svou vnitřní hodnotu. Aktuální kurz akcie kolem této hodnoty pouze osciluje. Tato analýza se skládá ze dvou kroků. V prvním je z dostupných dat zjištěna vnitřní hodnota společnosti a možnosti jejího růstu do budoucnosti. V druhém kroku je zjištěná hodnota srovnána s aktuálním kurzem akcie a určeno její podhodnocení či nadhodnocení.[9]

## **1.6. Dílčí závěry**

Cenné papíry jsou listiny, s jejichž vlastnictvím jsou spojená určitá práva majitele. Pro jejich obchodování se používají burzy cenných papírů. Jejimi členy jsou brokerské společnosti a bankovní instituce, které jako jediné mají přímý přístup k burze. Ostatní subjekty musí využít jejich služeb.

Pro obchodování se využívají různé styly snažící se využít krátkodobé i dlouhodobé trendy. Čím kratší trend je, tím větší riziko obchod představuje. Pro nezkušené obchodníky je doporučeno začínat s pozičním obchodováním, při kterém jsou akcie drženy po dobu týdnů až měsíců.

Hlavním nástrojem technické analýzy jsou grafy. Podstatou je identifikovat opakující se situace a využít jejich znalost k výhodnému nákupu či prodeji. K tomu mohou kromě údajů ze svíčkových či čárkových grafů sloužit i klouzavé průměry či další technické indikátory.

Fundamentální analýza slouží k určení vnitřní hodnoty firmy. Pomocí makroekonomických i mikroekonomických ukazatelů se snažíme určit její potenciál a možnost budoucího růstu její hodnoty. Podle toho je určena její podhodnocenost případně nadhodnocenost.



## 2. RBF neuronové sítě

Kapitola pojednává o neuronových sítích typu RBF. V kapitole je popsána základní struktura tohoto typu neuronové sítě. Poté následuje definice a charakteristika jednotlivých radiálně bazických funkcí, které slouží jako aktivační funkce neuronů. Důraz je kladen i na princip učení tohoto typu neuronové sítě, jež je odlišný od vícevrstvých perceptronových sítí.

### 2.1. Základní pojmy

Normou ( $\|\cdot\|$ ) nazveme zobrazení z vektorového prostoru  $V$  na  $\mathbb{R}$  splňující:

- $\|x\| = 0 \Leftrightarrow x = 0$ .
- Pro všechna  $x, y \in V$  platí:  $\|x+y\| \leq \|x\| + \|y\|$ .
- Pro každé  $x \in V$  a reálné číslo  $k$  platí, že  $\|k \cdot x\| = |k| \cdot \|x\|$ . [14]

Metrikou nazveme zobrazení  $\rho$  z množiny  $M^2$  na  $\mathbb{R}$ :

- $\rho(x,y) = 0 \Leftrightarrow x = y$ .
- Pro všechny  $x, y \in M$  platí symetrie, tedy  $\rho(x,y) = \rho(y,x)$ .
- Pro všechny  $x, y, z \in M$  platí trojúhelníková nerovnost, tedy  $\rho(x,z) \leq \rho(x,y) + \rho(y,z)$ . [14]

Metriku lze definovat pomocí normy  $\rho(x,y) = \|x - y\|$ . [14]

Graf  $G$  lze definovat jako uspořádanou dvojici  $(V,E)$ , kde  $V$  je neprázdná množina vrcholů (vertex) a  $E$  množina dvoubodových podmnožin reprezentující hrany (edge). Pokud je graf orientovaný, potom množina  $E$  obsahuje uspořádané dvojice ve tvaru  $(x,y)$ . Hrana  $e = (x,y)$  začíná v uzlu  $x$  a končí v uzlu  $y$ . [17]

Neuronovou síť lze definovat jako orientovaný graf  $G=(V,E)$ , kde množina vrcholů ( $V$ ) reprezentuje neurony a množina hran ( $E$ ) jejich vzájemné propojení nazývané synapse. Množina  $V$  je rozdělena na disjunktní podmnožiny reprezentující jednotlivé vrstvy. Základním typem neuronové sítě je vícevrstvá perceptronová síť (Multi-Layer Perceptron, MLP). [15][18]

Učení neuronové sítě je proces adaptace synaptických vah. Při učení s učitelem je pro vstupní data znám optimální výstup. Ten je porovnán s výstupem neuronové sítě a pomocí zpětné vazby je provedena úprava synaptických vah.[11]

## 2.2. Radiálně bazické funkce

Radiálně bazické funkce jsou spojovány s teorií vícerozměrné interpolace. Obecně jsou definovány vztahem (2.1) kde  $\phi$  reprezentuje použitou, zpravidla nelineární funkci,  $c$  je takzvané centrum neuronu a  $R$  metrika sloužící k určení vzdálenosti mezi vstupem  $x$  a centrem  $c$ . Obecně může být  $R$  definováno libovolnou normou  $\|\cdot\|$  [11][22]

$$h(x) = \phi((x - c)^T R^{-1}(x - c)). \quad (2.1)$$

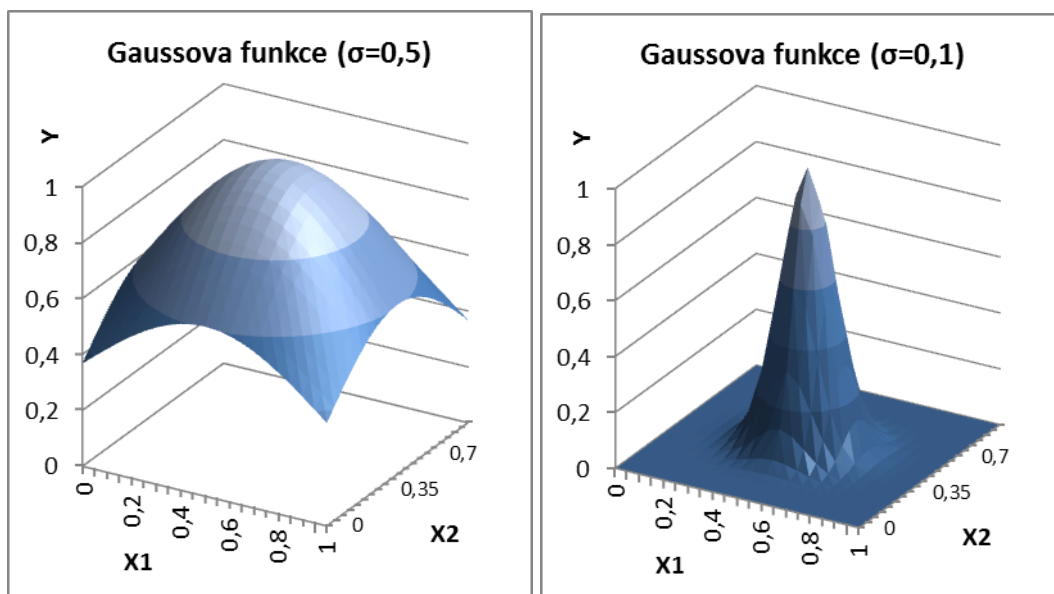
Níže jsou popsány tři nejčastěji používané radiálně bazické funkce. Symbol  $r$  značí metriku  $\|x - c\|$ . Nejčastěji používanou metrikou je Euklidovskou vzdálenost definovaná vztahem (2.2) [11][14]

$$\rho(\bar{x}, \bar{y}) = \|\bar{x} - \bar{y}\| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (2.2)$$

**Gaussova funkce** je definována rovnicí ve tvaru

$$\varphi(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right) \text{ pro } \sigma > 0, r \in \mathbb{R}. \quad (2.3)$$

Na obr. 2 je zobrazen průběh Gaussovy funkce pro dvě proměnné  $x_1$  a  $x_2$  se středy v hodnotě 0,5 a poloměrem  $\sigma = 0,5$  a  $0,1$ . Zatímco střed určuje pozici v prostoru, poloměr  $\sigma$  ovlivňuje tvar funkce. Určuje také hraniční vzdálenost, od které budou hodnoty funkce blízké či rovny nule. Čím blíže je vstupní vektor  $X$  středu, tím vyšší bude hodnota výstupní proměnné  $\phi$ . Gaussova funkce je pro rostoucí hodnotu  $r$ , tedy vzdálenost od středu, klesající do nuly. Obor hodnot je uzavřený interval od nuly do jedné.[11]

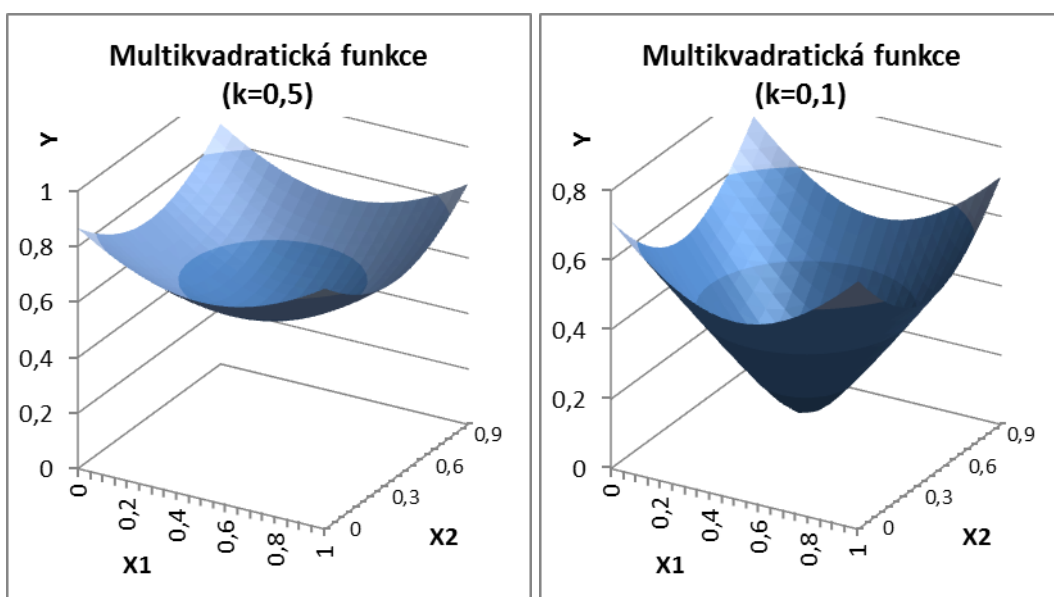


Obr. 2: Průběh Gaussovy funkce pro dvě různá nastavení poloměru

*Zdroj: Vlastní zpracování*

**Multikvadratická funkce** je na rozdíl od zbylých dvou funkcí jako jediná rostoucí se vzdáleností od centra. Zdola je omezena nulou a se vzdáleností od centra roste do nekonečna. Parametr  $k$  určuje strmost průběhu funkce. Průběh multikvadratické funkce pro dva různé parametry  $k$  zobrazuje obr. 3. Tvar funkce je [11]

$$\varphi(r) = (r^2 + k^2)^{1/2} \text{ pro } k > 0, r \in \mathbb{R}. \quad (2.4)$$

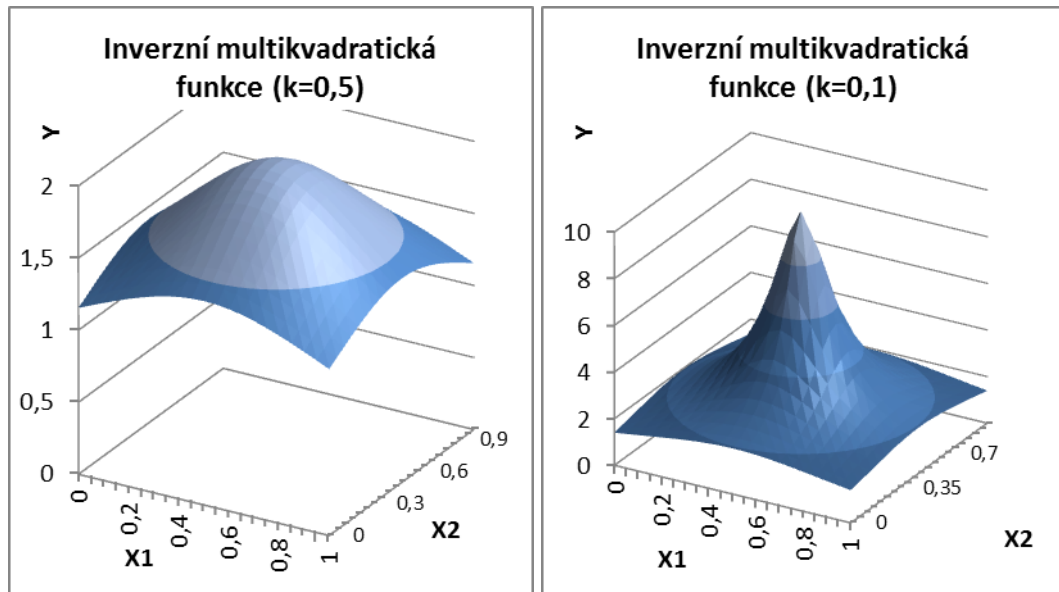


Obr. 3: Průběh multikvadratické funkce pro  $k=0,5$  a  $0,1$

*Zdroj: Vlastní zpracování*

**Inverzní multikvadratická funkce** je definována vztahem (2.5). Hodnota funkce klesá se vzdáleností od středu a je omezena zdola nulou. Parametr  $k$  ovlivňuje nejen tvar funkce, ale i maximální hodnotu, které funkce dosahuje ve svém vrcholu, viz obr. 4. Inverzní multikvadratická funkce je definována předpisem [11]

$$\varphi(r) = \frac{1}{(r^2+k^2)^{1/2}} \text{ pro } k > 0, r \in \mathbb{R}. \quad (2.5)$$



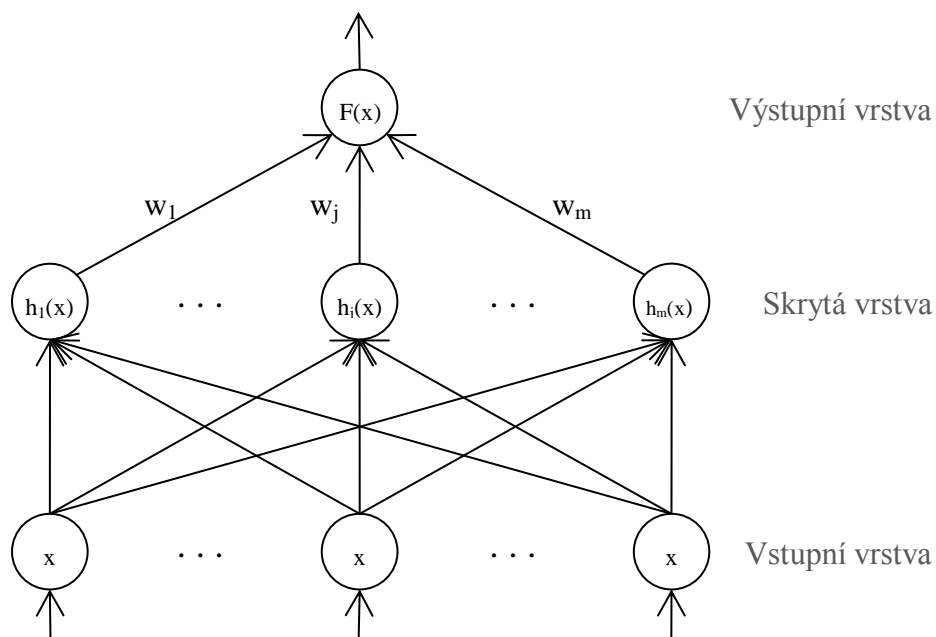
Obr. 4: Průběh inverzní multikvadratické funkce pro  $k=0,5$  a  $0,1$

*Zdroj: Vlastní zpracování*

Parametr  $\sigma$  Gaussovy funkce je nazýván poloměr. Multikvadratická ani inverzní multikvadratická funkce nemají poloměr, ale parametr  $k$ , jenž ovlivňuje strmost a hraniční hodnoty funkce. Při zakreslení vrstevnic ale tyto parametry ovlivňují míru ohodnocení vzhledem ke vzdálenosti ke středu. Dále v textu je parametr  $k$  i  $\sigma$  označen jako střed radiálně bazické funkce.

### 2.3. Struktura RBF neuronové sítě

RBF neuronové sítě typu využívají mírně odlišnou strukturu oproti MLP. Jako aktivační funkci neuronu využívají radiálně bazické funkce, ve většině případů obsahují jen jednu skrytou vrstvu a učí se s učitelem. Každý neuron je vždy propojen se všemi prvky vrstvy předchozí i následující. S výjimkou poslední vrstvy se zde nevyužívají váhy synapsí. Do všech neuronů v dané vrstvě vždy putuje stejný signál a právě nastavení centra neuronu určuje, jak bude vyhodnocen. [18]



Obr. 5: Struktura neuronové sítě typu RBF

Zdroj: Vypracováno podle [22]

RBF neuronová síť se skládá, ze vstupní vrstvy, alespoň jedné skryté vrstvy a vrstvy výstupní. Dále budeme uvažovat neuronovou síť s jednou skrytou vrstvou tvořenou  $m$  neurony, viz obr. 5. Na vstup neuronové sítě jsou přiváděny hodnoty veličiny  $X$ . Ty jsou pomocí synapsí distribuovány do všech neuronů skryté vrstvy. Zde jsou transformovány pomocí radiálně bazických funkcí. Každý neuron má nastaven vlastní střed či středy ( $c_j$ ) a poloměr neuronu ( $r_j$ ). Výstupem z  $j$ -tého neuronu skryté vrstvy je hodnota  $h_j(x)$ . Synapse mezi skrytou a výstupní vrstvou jsou ohodnoceny pomocí lineárních vah ( $w_j$ ). Výstup neuronové sítě  $F(x)$  lze vypočítat jako lineární kombinaci vah a výstupu ze skryté vrstvy podle vztahu [18]

$$F(\bar{x}) = \sum_{j=1}^m w_j h_j(\bar{x}) = \sum_{j=1}^m w_j \varphi(\|\bar{x} - \bar{c}_j\|). \quad (2.6)$$

#### 2.4. Učení RBF neuronové sítě

Pro neuronovou síť typu RBF, u níž jsou známá centra radiálně bazických funkcí ( $c_i$ ) a jejich poloměry ( $r_i$ ) spočívá učení ve stanovení lineárních vah ( $w_i$ ) mezi skrytou a výstupní vrstvou. Jedním ze způsobů, jak určit parametry  $c_i$  a  $r_i$ , se zabývá kapitola 3.

Data ( $X$ ), reprezentující nezávislé proměnné, jsou přivedena na vstup neuronové sítě a lze je popsat maticí o  $p$  řádcích a  $n$  sloupcích, kde  $p, n > 0$ . Necht' existuje neuronová síť typu RBF s  $n$  vstupy, jedním výstupem a  $m$  neurony v jediné skryté vrstvě jako je tomu na obr. 5. Dále existuje vektor vstupu  $\bar{x}_i$  (2.7) a jemu odpovídající hodnota výstupu  $y_i$ . Závislá proměnná  $y_i$  reprezentuje ideální hodnotu, které by měla neuronová síť pro daný vstup  $x_i$  dosáhnout. Jedná se tedy o učení s učitelem. Vektor  $\bar{x}_i$  je definován

$$\bar{x}_i = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{in} \end{bmatrix}, i = 1, 2, \dots, p. \quad (2.7)$$

Poté lze definovat vektor [22]

$$\bar{h}_i = \begin{bmatrix} h_1(\bar{x}_i) \\ h_2(\bar{x}_i) \\ \vdots \\ h_m(\bar{x}_i) \end{bmatrix}, i = 1, 2, \dots, p. \quad (2.8)$$

Vektor  $\bar{h}_i$  reprezentuje výstupy neuronů skryté vrstvy RBF neuronové sítě, pokud je na vstup přiveden vstupní vektor  $\bar{x}_i$ . Vektory  $h_i$  (2.8) tvoří jednotlivé řádky matice [11] [22]

$$H = \begin{bmatrix} h_1(\bar{x}_1) & h_2(\bar{x}_1) & \dots & h_m(\bar{x}_1) \\ h_1(\bar{x}_2) & h_2(\bar{x}_2) & \dots & h_m(\bar{x}_2) \\ \vdots & \vdots & \ddots & \vdots \\ h_1(\bar{x}_p) & h_2(\bar{x}_p) & \dots & h_m(\bar{x}_p) \end{bmatrix}. \quad (2.9)$$

Stejným způsobem je sestaven i výstupní vektor  $\bar{y}$  (2.10), kde hodnota  $y_i$  reprezentuje ideální hodnotu pro vstupní hodnoty  $\bar{x}_i$  [11]

$$\bar{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{bmatrix}. \quad (2.10)$$

Vektor lineárních vah reprezentuje synaptické váhy mezi skrytou a výstupní vrstvou [11]

$$\bar{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{bmatrix}. \quad (2.11)$$

Výstup neuronové sítě  $\bar{y}$  je lineární kombinací matice H (2.9) a vektoru lineárních vah  $\bar{w}$  (2.11). Řešený problém (2.6) lze zapsat rovnicí [11]

$$\begin{bmatrix} h_1(\bar{x}_1) & h_2(\bar{x}_1) & \dots & h_m(\bar{x}_1) \\ h_1(\bar{x}_2) & h_2(\bar{x}_2) & \dots & h_m(\bar{x}_2) \\ \vdots & \vdots & \ddots & \vdots \\ h_1(\bar{x}_p) & h_2(\bar{x}_p) & \dots & h_m(\bar{x}_p) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{bmatrix}. \quad (2.12)$$

Soustavu (2.12) lze přepsat do zjednodušeného tvaru

$$H * \bar{w} = \bar{y}. \quad (2.13)$$

Vzniká soustava  $p$  rovnic o  $m$  neznámým, kde  $m < p$ . Znamé jsou hodnoty matice H a vektoru  $\bar{y}$ . Neznámé jsou hodnoty lineárních vah  $w_i$ . Pro jejich výpočet se využívá metoda nejmenších čtverců [22]

$$\bar{w} = (H^T H)^{-1} H^T \bar{y}. \quad (2.14)$$

Použití metody nejmenších čtverců je velkou výhodou RBF neuronových sítí oproti MLP, pro jejichž optimalizaci je nutné použít iterativní postupy. Soustava (2.14) má řešení jen pokud jsou vektory matice H lineárně nezávislé. V jiném případě není možné vytvořit inverzní matici  $(H^T H)^{-1}$  a tedy vypočítat vektor  $\bar{w}$ . [22]

**Poznámka:** Při provádění experimentů s učením neuronové sítě, nebylo u 150 z celkových 156 271 jedinců možno vypočítat inverzní matici. Toto číslo odpovídá asi 0,1%. Jednu generaci tvořilo 20 jedinců. Z každé třetí generace tedy průměrně odpadne 1 jedinec. Snižující populace omezuje možnosti vývoje a přechodu na nové optimum. Proto byla do genetického algoritmu přidána operace doplnění o chybějící jedince.

## 2.5. Dílčí závěry

Neuronové sítě typu RBF jsou speciálním typem neuronových sítí využívající mírně odlišnou strukturu oproti sítím MLP. Jako aktivační funkce neuronu využívá speciální třídu radiálně bazických funkcí jako například Gaussovu, multikvadratickou a inverzní multikvadratickou funkci.

Před učením neuronové sítě, tedy adaptací lineárních vah, je nutné určit parametry radiálně bazických funkcí. Tím se zabývá následující kapitola. Samotné určení vah je lineární problém a lze proto využít metodu nejmenších čtverců.



### **3. Genetické algoritmy**

Genetické algoritmy se využívají k řešení velkého množství rozličných úloh. Cílem této kapitoly je seznámení s terminologií úzce spojenou s genetikou a s principem obecného genetického algoritmu. Na něj naváže jeho modifikace tak, aby co nejlépe řešil úlohu určení parametrů neuronové sítě, jmenovitě: centra radiálně bazických funkcí, jejich poloměry a také velikost skryté vrstvy.

#### **3.1. Základní pojmy**

Algoritmus lze definovat jako schematický postup k řešení určitého druhu úlohy splňující podmínky konečnosti, určitosti, korektnosti a obecnosti. Algoritmus tedy musí, pokud má na vstupu korektní data, vyřešit problém v konečném počtu kroků, každý krok je přesně definován a řeší úlohu obecně. S algoritmem se pojí pojem heuristika, jež reprezentuje sadu pravidel, jež může, ale nemusí vést k řešení. [19] [27]

Optimem, či optimálním řešením je nazýváno nejlepší známé řešení. Tedy to, které danou úlohu řeší s minimální hodnotou hodnotící funkce a je z množiny známých řešení. Nemusí tedy jít o globální optimum.

#### **3.2. Terminologie používaná v genetických algoritmech**

Genetický algoritmus je automatizovaný způsob strojového učení, založený na základech darwinovského principu evoluce. Hledání optimálního řešení, nebo alespoň dostatečně vyhovujícímu řešení, zde probíhá formou soutěže jedinců. Aby bylo možné jedince posoudit, musíme existovat možnosti jejich ohodnocení. K tomu slouží hodnotící (fitness) funkce. Jen těm nejlepším individuům je pak dovoleno se podílet na budování dalších generací. [13][3]

Účelem genetického algoritmu je hledání. Nejčastěji je hledáno řešení určitého problému z velkého množství kandidátů. Po vzniku algoritmu se ukázalo, že ideální úlohou je hledání globálního minima funkce. Dalšími aplikacemi je strojové učení, klasifikační problémy a další oblasti umělé a výpočetní inteligence. Výhodné je jejich použití ve všech, jinými metodami obtížně řešitelných, optimalizačních problémech. [20][15]

Myšlenky evolučních algoritmů lze objevit již na začátku 60. let 19. století v Německu. Později, v roce 1975, vyšla kniha Amerického teoretického biolog Johna Hollanda, shrnující jeho dlouholetý výzkum. Díky tomu převzaly názvosloví spadající spíše do oblasti biologie než informačních technologií. Po vzoru genetických algoritmů založil John Koza další oblast umělé inteligence a tou je genetické programování. Na rozdíl od evolučních algoritmů, jejichž cílem je nalézt řešení konkrétní úlohy, genetické programování má za úkol najít nejlepší program, řešící danou úlohu či skupinu úloh.[16]

Základem algoritmu je *populace* o  $n$  jedincích. Každý jedinec je reprezentován jedním či více chromozómy sloužící jako jednoznačný popis jedince. Stavebním článkem chromozómů jsou pak *geny*. Pokud má organismus více chromozómů v jedné buňce, hovoří se o *genomu*. Pojem genotyp odkazuje na přítomnost množiny určitých *genů* v *genomu*. Dvě individua se stejným *genomem* mají i stejný *genotyp*. *Genotyp* udává základ jedince, na rozdíl od *fenotypu*, který je ovlivněn vývojem jedince a je tedy souborem jeho fyzických i psychických vlastností.[20]

Populaci je nutné ohodnotit podle hodnotící funkce. Ta přidělí skóre podle toho, jak daný jedinec zvládl vyřešit problém. U běžného organismu je hodnotící funkcí schopnost přežití, či schopnost reprodukce (počet potomků). Nejlepším jedincům v populaci je pak dovoleno přežít a reprodukovat se, čímž vznikne nová *generace*. [20]

### 3.3. Obecný genetický algoritmus

V obecném genetickém algoritmu jsou geny reprezentovány jako bity nabývající hodnot nula nebo jedna a chromozom jako jejich uspořádaná posloupnost, nejčastěji pole. Přechod ze staré generace na novou se skládá ze tří operací:

- **Selekce:** Je zvolení chromozómů určených k reprodukci. Čím vyšší ohodnocení chromozom dostane, tím větší počet potomků by měl vytvořit.
- **Křížení:** Jsou zkříženy dva rodičovské chromozomy. Je náhodně určeno místo řezu a oba chromozomy jsou rozděleny na dvě části. Nový chromozom je složen tím způsobem, že první část chromozomu pochází z prvního rodiče a druhá část od druhého.

- **Mutace:** Libovolný gen či geny jsou náhodně pozměněny. Pravděpodobnost mutace by měla být pro všechny geny shodná.[20]

Základní genetický algoritmus je rozdělen do pěti kroků a obsahuje dříve popsané operace. Postup je následující:

1. *Vygenerování náhodné populace o n jedincích.*
2. *Ohodnocení jedinců.*
3. *Dokud nebude vytvořeno n nových chromozomů, opakuj:*
  - a. *Výběr dvou jedinců ke křížení.*
  - b. *Křížení dvou vybraných jedinců s náhodným místem řezu.*
  - c. *Mutace náhodných genů.*
4. *Nahrazení stávající populace nově vytvořenou populací.*
5. *Algoritmus pokračuje krokem 2. [20]*

Tato základní verze genetického algoritmu nemá zabudované žádné ukončení a běží tak do nekonečna. Lze to považovat za ekvivalent skutečné evoluce, která bude pokračovat, dokud bude na světě, či ve vesmíru jediný živý organismus. Pro potřeby běžného algoritmu je vhodné do pátého kroku zabudovat podmínku ukončení algoritmu. Tou může být počet generací, které algoritmus projde, dosažení určité hodnoty fitness funkce, případně jiná podmínka.


Genetický algoritmus je velice podobný jiným prohledávacím algoritmům, kupříkladu gradientnímu algoritmu (Hill-Climbing či horolezecký algoritmus). Společnou nevýhodou je možnost uvíznutí v lokálním optimu. Genetický algoritmus nemusí být schopen, vzhledem k použité pravděpodobnosti, dosáhnout globálního optima v konečném počtu kroků. Proto jako takový není řazen mezi algoritmy, ale patří do kategorie heuristik.[15]

### 3.4. Modifikovaný genetický algoritmus

Stavebním kamenem genetického algoritmu je chromozom tvořený geny. Chromozom zde reprezentuje neuronovou síť, přesněji parametry, jež je potřeba optimalizovat. Těmi jsou centra jednotlivých neuronů, poloměr radiální bazické funkce a počet neuronů ve skryté vrstvě. Lineární váhy, poslední chybějící parametr, je dopočítán pomocí metody nejmenších čtverců. Algoritmus je obecný a umí pracovat i s vícevrstevnými strukturami. Text se bude dále, vzhledem k řešenému problému, zabývat jen neuronovými sítěmi s jednou skrytou vrstvou.

Chromozom je tvořen množstvím parametrů a jeho délka je proměnná vzhledem k velikosti skryté vrstvy a počtu vstupů. Gen v základním GA je tvořen bitem nabývajícím hodnot nula nebo jedna, který určuje, zda jedinec danou vlastností disponuje či nikoliv. V tomto případě odpovídají geny rozmístění neuronů v prostoru a pro co největší variabilitu budou nabývat reálných čísel v rozmezí od nuly do jedné.

Chromozom je uspořádání reálných čísel do speciální struktury. Pro neuronovou síť o  $m$  vstupech a  $n$  neuronech ve skryté vrstvě, odpovídá struktura genomu zobrazené na obr. 6.



Obr. 6: Struktura reprezentující genom

*Zdroj: Vlastní zpracování*

Parametr  $C$  zde reprezentuje centra neuronů. Pokud má neuronová síť dva vstupy a tři neurony ve skryté vrstvě, obsahuje genom celkem šest center, dvě pro každý neuron.  $R$  představuje poloměr radiální funkce, každý neuron má vlastní. Obr. 7 reprezentuje tuto situaci přímo v aplikaci popsané v kapitole 3.5. Zobrazeny jsou jen hodnoty center.

0.92	0.197	0.943	0.921	0.388	0.037
------	-------	-------	-------	-------	-------

Obr. 7: Ukázka genomu z aplikace

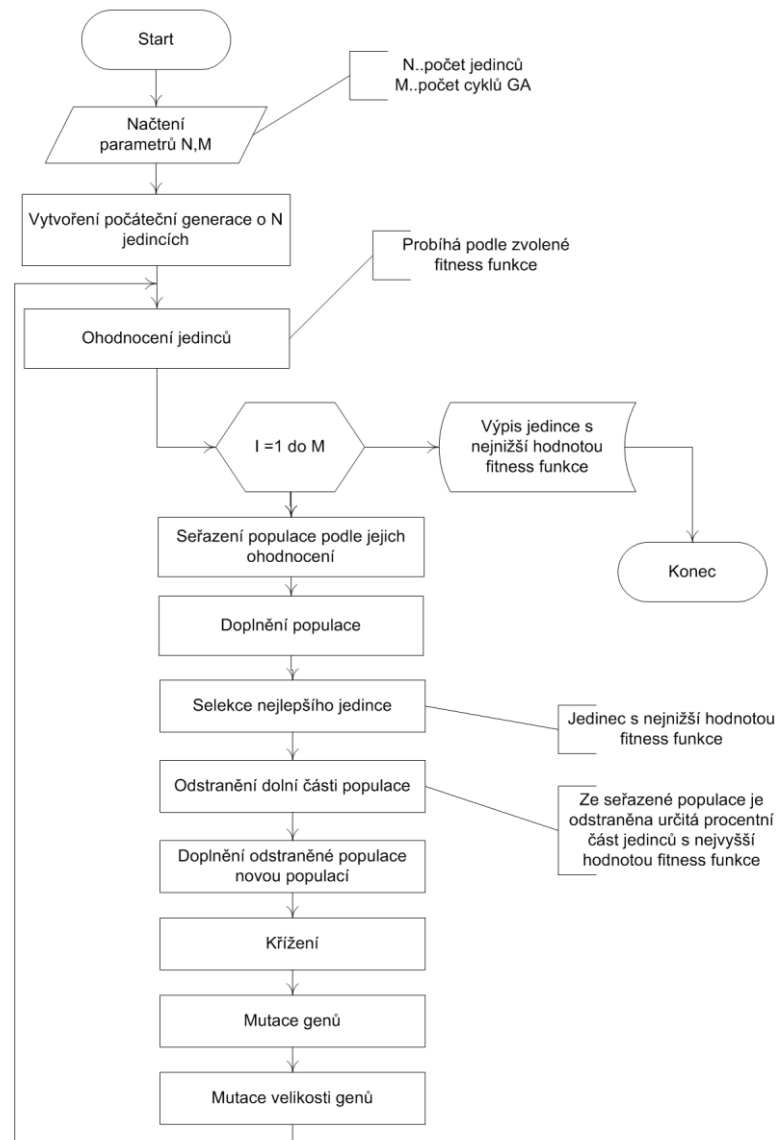
*Zdroj: Vlastní zpracování*

$C$  a  $R$  jsou variabilní parametry, které se budou v průběhu jednotlivých generací měnit. Každý genom si nese ale i statické informace, které slouží jak k jeho identifikaci, tak pozdějšímu použití. Nejdůležitější je použitá radiální funkce, hodnota fitness funkce, nebo rozměry neuronové sítě. Důležitý je především poslední parametr, protože genom sám o sobě nevypovídá o struktuře neuronové sítě a určité genomy mohou odpovídat více strukturám.

Každý jedinec, přesněji jeho genom, reprezentuje jednu neuronovou síť. Obsahuje centra neuronů, poloměry radiálních funkcí i počet neuronů ve skryté vrstvě. Při generování nového jedince jsou tyto parametry náhodně generovány. Jediný chybějící parametr jsou lineární váhy  $w$ . Pro jejich výpočet je potřeba určit matici  $H$  podle vzorce (2.9). Matice  $H$  reprezentuje výstupy ze skryté vrstvy. Na vstup neuronové sítě jsou přiváděna trénovací data, jsou transformována neurony ve skryté vrstvě a jejich hodnoty uloženy do příslušného řádku matice  $H$ . Do stejného řádku matice  $Y$  je uložen i odpovídající výstup. Z těchto dvou matic lze vypočítat váhy  $w$  podle vzorce (2.13), pokud ovšem má tato soustava řešení. Váhy jsou poslední díl skládky a představují naučenou neuronovou síť.

Chromozom plně reprezentuje neuronovou síť. Pro využití GA je dále nutné zvolit fitness funkci. Ta by měla být zvolena s ohledem na řešený problém a to tak aby dokázala ohodnotit všechny jedince. Výběrem hodnotící funkce pro tento typ problému se zabývá kapitola 4.6.

Pokud byla vybrána fitness funkce, je možné využít modifikovaný GA znázorněný na obr. 8. Vstupem modifikovaného GA jsou jednotlivé parametry, jako je velikost populace nebo počet generací. Výstupem je jedinec s nejnižší hodnotou fitness funkce. Jedinec reprezentuje RBF neuronovou síť, která je optimalizována a naučena.



Obr. 8: Vývojový diagram upraveného genetického algoritmu

Zdroj: Vlastní zpracování

- 1) **Inicializace:** Na začátku je vytvořena náhodná populace o  $n$  jedincích.
- 2) **Ohodnocení populace:** Ohodnocení jedinců probíhá s ohledem ke kapitole 4.6. Před ohodnocením je nutné vypočítat hodnotu lineárních vah  $w$ . Pokud je není možné určit, je jedinec odstraněn z populace. Pokud lineární váhy existují, lze provést ohodnocení jedince tak, že na vstup neuronové sítě jsou přivedena trénovací a testovací data a je měřena střední kvadratická odchylka (4.5) skutečných a predikovaných hodnot.
- 3) **Seřazení populace:** Jedinci jsou seřazení vzestupně od nejmenší po největší hodnotu fitness funkce.
- 4) **Doplnění populace:** Inverzní matice, která je nutná pro výpočet synaptických vah, nemusí existovat. Neuronovou síť tak nemusí být možné, v dané konfiguraci, naučit

a je nutné ji odstranit. Aby populace postupně neubývala, je nutné ji v každé generaci doplnit o nové náhodné jedince.

5) **Evoluce:** V rámci experimentů byly evoluční operátory pozměněny, aby dosahovaly lepších výsledků i variability. Rozdílný přístup je i k chromozomu jako takovému.

Evoluční operátory modifikovaného GA jsou následující:

a) Selekce nejlepšího jedince: Jedinec s nejnižší hodnotou fitness funkce je vybrán jako nejlepší. Jako jedinému je mu dovoleno křížení s ostatními jedinci.

b) Odstranění dolní části populace: Populace s vysokou hodnotou fitness funkce je odstraněna. Toto lze provést pro určitou hodnotu fitness funkce či procentně. V populaci se nacházejí jedinci, jejichž hodnota fitness funkce je příliš vysoká. Výhodné je proto jejich vyškrtnutí a nahrazení jedinci novými.

c) Doplnění odstraněné populace: Odstraněnou populaci je nutno doplnit. Aby byla zajištěna vyšší rozmanitost populace, je část jedinců doplněna náhodně. To umožní hledat nové optimální řešení i mimo cestu, kterou si původně evoluce vybrala. Druhá část je naopak doplněna o nejlepšího jedince, který je náhodně mutován. Toto reprezentuje hledání lepšího řešení v okolí prozatímního optima.

d) Křížení: Nejlepší jedinec je zkřížen se zbytkem nenahrazené populace. Při křížení jsou náhodně vybrány pozice genů. Hodnoty těchto genů jsou nahrazeny hodnotami genů nejlepšího jedince na stejných pozicích.

e) Mutace: Mutace reprezentuje náhodné změny jedince. Zde mohou nastat dvě změny. První je náhodná změna některých z chromozomů. Počet i míra změny je náhodná. Druhou změnou je délka chromozomu. Změnou délky chromozomu dochází ke změně počtu neuronů ve skryté vrstvě. Tento jev může postihnout každého jedince se stejnou pravděpodobností, s výjimkou jedince nejlepšího. Chromozom se může zvětšit i zmenšit. Šance zmenšit se větší, protože se algoritmus snaží nalézt co nejmenší a tedy nejjednodušší neuronovou síť.

6) **Konec:** Algoritmus končí po určitém počtu kroků. Pokud ho nebylo dosaženo, pokračuje algoritmus ohodnocením nově vzniklé populace, tedy krokem 2.

### 3.5. Implementace modifikovaného genetického algoritmu

Dynamické webové aplikace jsou v posledních letech čím dál populárnější a pronikají i do oblastí dříve nemyslitelných. Z původně statického webu se snaží, pomocí technologií jako například AJAX (Asynchronous JavaScript and XML), vytvořit interaktivní prostředí. Pro implementaci modifikovaného genetického algoritmu byly vybrány programovací jazyk PHP, skriptovací jazyk JavaScript a databáze MySQL. Aplikace je součástí přílohy A.

**PHP** představuje serverovou aplikaci. Není prvotně určen pro matematické výpočty, a potřebné knihovny musely být doprogramovány. V základních knihovnách chybí operace s maticemi. Výhodou tohoto jazyka je možnost využití objektového přístupu a množství dostupné dokumentace a příkladů. Pro běh webových aplikací je nutný webový server.

**JavaScript** je skriptovací jazyk obsažený ve všech moderních webových prohlížečích. Slouží k vytvoření interaktivního ovládacího prostředí. Pomocí příkazu zaslaných na pozadí komunikuje se serverem a zobrazuje datové výstupy. Komunikace se serverem využívá formát XML.

**MySQL** databáze slouží k přípravě i zpracování dat. Slouží k uchování průběhů experimentů a následně exportu strukturovaných datových exportů.

Pro vytvoření aplikace byly využity všechny standardní knihovny jazyka PHP. Ten však neobsahuje knihovny pro práce s maticemi, neuronovými sítěmi a pro genetický algoritmus. Všechny tři vytvořené knihovny využívají objektový přístup.

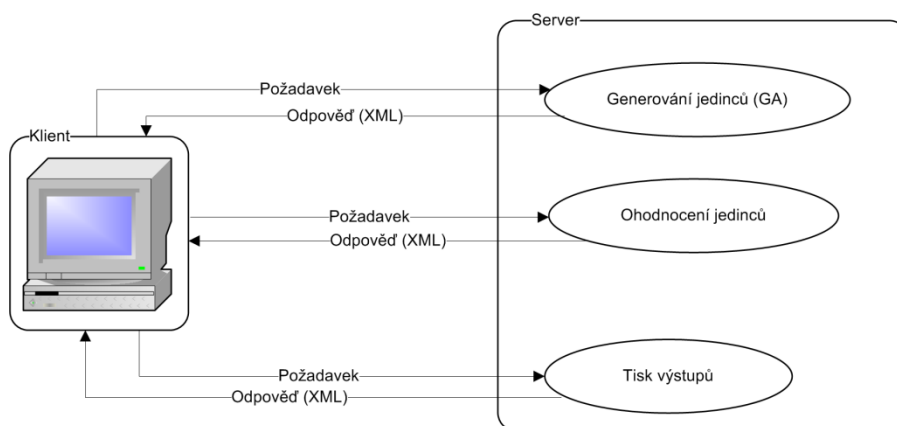
Knihovna starající se o operace s maticemi (*matrix.php*) obsahuje pouze takové, které jsou potřeba pro chod aplikace, tedy samotnou reprezentaci matic, násobení matic, transpozice matic a výpočet inverzních matice.

Neuronová síť je reprezentována jako třída pomocí knihovny *nn.php*. Přesněji řečeno jako množina objektů, jelikož jednotlivé neurony i synapse jsou reprezentovány jako samostatné objekty. Síť je navržena obecně a obsahuje tedy i váhy veškerých synapsí. Synaptické váhy mezi vstupní a skrytou vrstvou byly nastaveny na hodnotu 1. Knihovna obsahuje implementaci radiálně bazických funkcí definovaných v kapitole 2.2 a euklidovskou metriku.



O provádění operací genetického algoritmu se stará obecná knihovna *genom.php* a je zastřešena aplikací *ajax\_genetics.php*, jež spojuje problém učené neuronové sítě a genetický algoritmus do jednoho celku.

Aplikace je na bázi architektury klient-server. Na klientském počítači je ve webovém prohlížeči umístěna prezentační část, uložení a zpracování dat se nachází na serveru.



**Obr. 9: Komponenty a komunikace uvnitř aplikace**

*Zdroj: Vlastní zpracování*

Na obr. 9 jsou znázorněny hlavní bloky aplikace. Aplikace na straně klienta zasílá požadavky na serveru. Data jsou součástí adresy URL. Server zasílá odpovědi ve strukturované podobě XML. Ohodnocení jedinců je odděleno od samotného genetického algoritmu. Lze tak využít paralelní výpočty. Aplikaci by bylo možné i nasadit na více serverů a vytvořit distribuovanou aplikaci. Konfigurace neuronových sítí i data jsou uložena na straně serveru, výběr probíhá pomocí jednoznačných identifikátorů.

Uživatelské rozhraní aplikace, vyobrazené na obr. 10, je rozdělené na dvě části. První je hlavní menu, druhé je určeno pro výstup genetického algoritmu. V menu je možné určit typ zapojení neuronové sítě, počet vstupů a neuronů ve skryté vrstvě, počet skrytých vrstev a aktivační funkci neuronové sítě. Vstup je určen použitým modelem zapojení, jež jsou definovány v kapitole 4.5, a nastavení počtu vstupů se projeví jen u modelu TD.

Trénování pomocí genetického algoritmu se skládá z jednotlivých generací. Aplikace umožňuje postupovat jak krok po kroku, tak nastavit přesný počet generací, které postupně projde.

Poslední nabídkou aplikace je tisk výstupů. Základním formátem je typ `.csv`, tedy text oddělený středníkem. Jedná se o velice rozšířený formát využívaný mnoha aplikacemi. Na výběr jsou dva výstupy. První poskytuje informace o hodnotě fitness funkce během učení a druhý poskytne plný výstup včetně vstupu a výstupu neuronové sítě, odchylky skutečné a predikované hodnoty, hodnot vstupů do neuronové sítě. Dále obsahuje i rozšířené statistiky včetně procesu učení či velikostech skryté vrstvy neuronové sítě. Skutečný výstup aplikace je přiložen na konci této práce (Příloha N).



Obr. 10: Náhled běhu aplikace

*Zdroj: Vlastní zpracování*

Obr. 10 zobrazuje náhled aplikace, na němž lze pozorovat již dříve popsané rozdělení obrazovky na dvě části. V trénovací části reprezentují jednotlivé řádky chromozomy jedinců v populaci. Barevné rozlišení jednotlivých genů, od světle modré u hodnot blízkých nule po červenou u hodnot blízkých jedné, slouží pouze k vizuální kontrole. Lze tak snadno identifikovat podobné genové sekvence.

### 3.6. Dílčí závěry

Genetické algoritmy mají původ v Darwinově evoluční teorii. Techniky inspirované přírodou jsou přeneseny do prostředí výpočetní techniky a jsou využity k řešení různorodých jinými způsoby často složitě řešitelných úloh. Typickou úlohou genetických algoritmů je hledání globálního minima funkce.

Součástí kapitoly je i základní genetický algoritmus a jeho modifikace tak aby bylo možno řešit úlohu optimalizace center a poloměrů radiálně bazických funkcí a velikost skryté vrstvy RBF neuronové sítě. Implementací tohoto modifikovaného algoritmu vznikla aplikace sloužící k testování modelů uvedených v následující kapitole 4. Ta je postavena jakožto webová aplikace a její funkčnost i možnosti jsou plně podřízeny účelu, ke kterému byla stvořena. Popis funkcí aplikace je v závěru kapitoly.

## 4. Návrh modelu obchodování na burze

Tato kapitola je zaměřena na návrh modelu obchodování na burze. Za cíl je kladen výběr a analýza vhodných dat a dále navržení modelů k testování s ohledem na vybraný styl obchodování. Součástí kapitoly je i výběr vhodné fitness funkce a návrh testovacích kritérií modelů.

### 4.1. Základní pojmy

Aproximace funkce znamená její nahrazení funkcí jednodušší, s podobným průběhem. Snahou je nalézt funkci s minimální odchylkou od funkce původní. Většinou se jedná o složité funkce, jež nelze analyticky vyjádřit. Využití nalezne kupříkladu u vykreslování průběhů funkcí, při zjednodušování výpočtů a dopočítávání průběhů funkcí.[5][6]

Interpolace funkce je jeden z typů aproximace. Na daném intervalu jsou známy některé funkční hodnoty. Snahou je proložit tyto hodnoty vhodnou funkcí s minimální chybou a následně dopočítat chybějící hodnoty uvnitř intervalu. Opakem je operace extrapolace, jež dopočítává neznámé hodnoty vně známého intervalu. [5][6]

Časová řada je sled věcně a prostorově srovnatelných pozorování jednoznačně uspořádaných z hlediska času. Při modelování časových řad se používá rozklad na její jednotlivé části: trendovou, sezónní, cyklickou a náhodnou složku. [8]

Pro určení trendu časové řady se kromě běžných analytických metod využívají také metody adaptivní. Jednou z nich je metoda vyrovnání časové řady pomocí klouzavých průměrů. Ta spočívá v rozdělení časové řady na kratší úseky a určení a odhadu pomocí lokálního polynomického stupně. Stupeň polynomu odpovídá typu trendu, například lineární trend se určuje pomocí polynomu prvního stupně. Délka klouzavých průměrů je určena počtem sezón, pokud časová řada nevykazuje sezónnost, je počet určen subjektivně.[2]

## 4.2. Výběr datových sad

Pro účely této práce bylo vybráno pět IT společností, které se obchodují na burze cenných papírů. Kvůli snadnému přístupu k datům byla vybrána americká burza NASDAQ. Veškerá data pocházejí z webu <http://finance.yahoo.com>, který poskytuje přístup k aktuálním i historickým datům.

Výběr firem byl směřován na známá jména v oblasti IT. Zastoupeny jsou firmy působící jak v oblasti software, tak hardware, společnosti s dlouholetou tradicí i nováčci na trhu. Výběr tvoří níže vyjmenované firmy, údaj v závorce udává identifikátor dané firmy na burze.

**Apple Inc. (AAPL)** a jeho dceřiné společnosti uvádí na celosvětový trh přístroje pro komunikaci, multimédia domácí výpočetní techniku. Mezi hlavní produkty patří mobilní telefon iPhone, tablet iPad, multimediální přehrávač iPod, stolní počítače Mac a přenosné počítače MacBook. Společnost také pro své produkty dodává operační systém iOS a OS X a další podpůrné nástroje. Do portfolia patří i služby na prodej digitálního obsahu iTunes, AppStore a iBookstore. Firma se zaměřuje jak na přímý prodej koncovým zákazníkům prostřednictvím přibližně 400 poboček po celém světě, tak na pře prodej pomocí třetích stran.[1]

**Facebook, Inc. (FB)** provozuje stejnojmennou celosvětovou sociální síť. Vytváří různé nástroje, jež uživatelům slouží ke kontaktu, sdílení, objevování a komunikaci skrze počítače nebo mobilní zařízení. Také nabízí vlastní aplikační platformu, jež umožňuje zabudovat služby Facebooku do aplikací třetích stran. Na konci roku 2012 měl Facebook 1,06 miliard aktivních uživatelů měsíčně a 618 aktivních uživatelů denně.[7]

**Google Inc. (GOOG)** vytváří produkty a poskytuje služby ke zpracování informací a pro přístup k nim. Toto reprezentuje hlavně služba Search, která dodává potřebné výsledky na dotazy uživatelů, dále služba Maps poskytující mapové podklady a aplikace a další. Dále společnost nabízí reklamní služby Adwords a AdSense. První je určena pro zadavatele reklamy, druhá pro vlastníky webových stránek, kteří mohou tuto reklamu umístit na své webové prezentace. V neposlední řadě nabízí firma i softwarové produkty jako je operační systém Android, Chrome OS a webový prohlížeč Chrome.[10]

**Hewlett-Packard Company (HPQ)** a její dceřiné společnosti poskytují produkty, technologie, software, řešení a služby individuálním zákazníkům, malým i velkým společnostem, vzdělávacímu sektoru a státní správě po celém světě. Osobní sektor zahrnuje počítačové produkty všeho druhu. Naopak firemní sektor zahrnuje konzultace, outsourcing, technologický servis, aplikační a business procesy. [12]

**Microsoft Corporation (MSFT)** vyvíjí, licencuje a poskytuje podporu softwarovým produktům po celém světě. Dále také navrhuje a prodává počítačový hardware. Nabízí operační systém Windows, serverové a databázové systémy, multimediální a vývojový software. Mezi webové služby patří vyhledávač Bing, informační web MSN a reklamní systém AdCenter. Microsoft dále nabízí kancelářské balíky Office a další kancelářské nástroje, herní platformu Xbox, komunikační služby Skype a mobilní operační systém Windows Phone.[21]

Datová sada obsahuje údaje zaznamenané každý den od uvedení firmy na burzu a zahrnuje následující parametry:

- otevírací cena (open) v USD;
- maximální cena (high) v USD;
- minimální cena (low) v USD;
- zavírací cena (close) v USD;
- obchodovaný objem (volume) v USD.

### **4.3. Analýza dat**

Z každé datové sady byl vybrán úsek 130 po sobě jdoucích dní pro další zpracování. Tento úsek bude následně sloužit jako vstup neuronové sítě.

Nejdražšími ve výběru jsou akcie společnosti Google s průměrnou otevírací cenou 691 USD následované společností Apple s hodnotou 591 USD za akcii. Nejvíce obchodovanou je společnost Facebook s objemem dosahujících téměř 6 miliard USD. Zájem o akcie této společnosti je nejspíše důsledkem jejího nedávného uvedení na trh a také častých zmínek v tisku. Velice málo obchodovanou je naopak společnost Google s objemem 260 milionů USD.

Analýza korelace jednotlivých parametrů vychází u všech řad obdobně. Tabulka 1 reprezentující datovou sadu GOOG. Cenové parametry vykazují vysokou míru závislosti. Tak by tomu mělo být, jelikož spolu všechny ceny velice úzce souvisí. Naopak obchodovaný objem takovou míru závislosti nevykazoval. Analýza zbylých řad je součástí přílohy B.

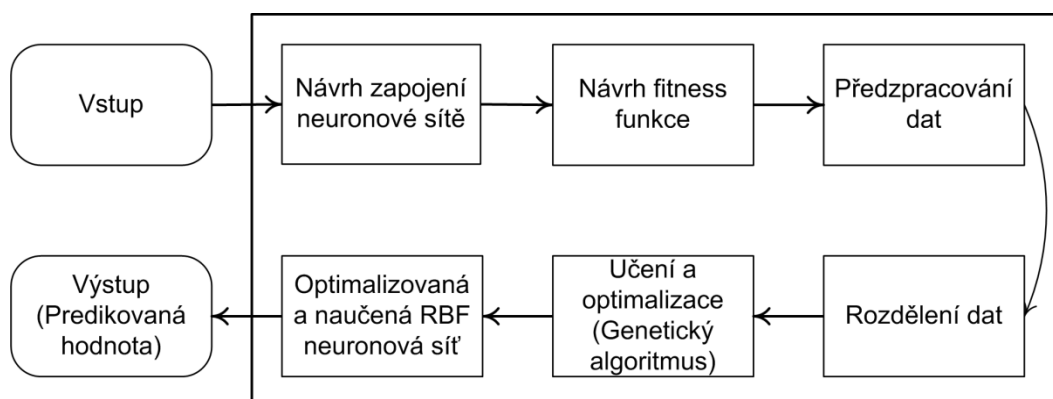
Tabulka 1: Korelace parametrů řady GOOG

	Objem	Open	Min	Max	Close
Objem	1				
Open	0,335073	1			
Min	0,34805	0,991909	1		
Max	0,170552	0,971341	0,973673	1	
Close	0,218421	0,966406	0,98034	0,991638	1

Zdroj: Vlastní zpracování

#### 4.4. Návrh modelu obchodování

Návrh modelu na obr. 11 vychází z učení neuronové sítě pomocí genetického algoritmu. Známý jsou jak vstupní data, tak skutečný výstup a jedná se tedy o metodu učení s učitelem. Model je navržen jako podpora obchodního stylu Swing. Výstupní proměnnou je vždy otevírací cena akcie. Návrhu zapojení a výběru fitness funkce se věnují zvláštní kapitoly.



Obr. 11: Návrh modelu obchodování na burze cenných papírů

Zdroj: Vlastní zpracování

Návrh modelu obchodování na burze cenných papírů je vyobrazen na obr. 11. Skládá se z návrhu zapojení neuronové sítě, návrhu fitness funkce, předzpracování dat, rozdělení dat a následně učení pomocí genetického algoritmu. Výstupem je predikovaná otevírací cena akcie.

Data o 130 záznamech jsou náhodně rozdělena na tři části. Prvních 100 hodnot v poměru 60:40. Větší částí jsou data *trénovací*, na kterých se bude neuronová síť učit. Menší část jsou data *testovací*. Ta slouží k ověření, zdali se neuronová síť nenaučila předkládané hodnoty z paměti a je schopná predikovat výstupní hodnotu s minimální odchylkou od skutečné i pro jiné vstupy, než jsou v trénovacích datech. Zbylá data jsou nazvána *neznámá*. Jsou přiváděna na vstup neuronové sítě a je zkoumáno, zdali dokáže extrapolovat hodnoty ceny akcie a udržet odchylku i bez nového učení nejnovějšího vývoje časové řady.

Kvůli použitému genetickému algoritmu, který je omezen hodnotami na intervalu od nul y do jedné, musí být data normována na tento rozsah. Normalizaci je nutné provést i kvůli souměřitelnosti hodnot, jelikož obchodovaný objem dosahuje řádově vyšších hodnot, než zbylé cenové parametry. Součástí předzpracování je i výpočet klouzavých průměrů. Jejich výběr není náhodný a vychází ze série testů, při kterých byly na vstup neuronové sítě přiváděny různé kombinace typů i délek klouzavých průměrů. Kombinace dosahující nejlepších výsledků byla vybrána pro další použití. Vybrány byly: jednoduchý klouzavý průměr délky 3 a 5, centrováný klouzavý průměr délky 7 a vážený klouzavý průměr délky 5 definované funkčními předpisy vztahy níže (4.1 až 4.4). [2]

#### **Jednoduchý klouzavý průměr délky 3 a 5**

$$JKP_3 = \frac{Y_{t-1} + Y_t + Y_{t+1}}{n}, \quad (4.1)$$

$$JKP_5 = \frac{Y_{t-2} + Y_{t-1} + Y_t + Y_{t+1} + Y_{t+2}}{n}. \quad (4.2)$$

#### **Centrováný klouzavý průměr délky 7**

$$CKP_7 = \frac{\left(\frac{Y_{t-3}}{2} + Y_{t-2} + Y_{t-1} + Y_t + Y_{t+1} + Y_{t+2} + \frac{Y_{t+3}}{2}\right)}{6}. \quad (4.3)$$

#### **Vážený klouzavý průměr délky 5**

$$VKP_5 = \frac{(-3Y_{t-2} + 12Y_{t-1} + 17Y_t + 12Y_{t+1} - 3Y_{t+2})}{35}, \quad (4.4)$$

- kde:
- $t$  je čas;
  - $Y_i$  je hodnota proměnné v čase  $i$ .



#### 4.5. Návrh modelů zapojení RBF neuronové sítě

Zapojení neuronové sítě určuje, jaké hodnoty budou přivedeny na její vstup i jaká hodnota bude na jejím výstupu. Zapojení jsou dělena na dva druhy: aproximační a prediktivní. První skupina slouží k otestování kvality aproximace neuronovou sítí. Druhá skupina slouží k predikci hodnot na o jeden den dopředu. Ve všech případech se jedná o neuronovou síť typu RBF s jednou skrytou vrstvou.

Vstupem neuronové sítě mohou být následující parametry:

- $Open_t$  - otevírací cena akcie v čase  $t$ ;
- $Min_t$  - minimální cena akcie v čase  $t$ ;
- $Max_t$  - maximální cena akcie v čase  $t$ ;
- $Close_t$  - zavírací cena akcie v čase  $t$ ;
- $Volume_t$  - obchodovaný objem akcie v čase  $t$ ;
- $JKP3_t$  - jednoduchý klouzavý průměr délky 3 v čase  $t$ ;
- $JKP5_t$  - jednoduchý klouzavý průměr délky 5 v čase  $t$ ;
- $CKP_t$  - centrováný klouzavý průměr délky 7 v čase  $t$ ;
- $VKP_t$  - vážený klouzavý průměr délky 5 v čase  $t$ .

Výstupem může být pouze hodnota  $Open_t$ . Dále jsou popsána jednotlivá zapojení, jejich vstupy, výstupy a jejich účel.

**Klasické (C).** Základní konfigurace sloužící k testování aproximačních schopností neuronové sítě. Z daných denních hodnot predikuje výstupní hodnotu.

Vstupní hodnoty:  $Min_t, Max_t, Close_t$  a  $Volume_t$ .

Výstup:  $Open_t$ .

**Klouzavé průměry (MA).** Slouží pro otestování využití klouzavých průměrů jako vstupů neuronové sítě. Základním nastavením jsou čtyři vstupy, tedy klouzavé průměry popsané v předchozí kapitole.

Vstupní hodnoty:  $JKP3_t, JKP5_t, CKP_t, VKP_t$ .

Výstup:  $Open_t$ .

**Prediktivní (PC).** Prediktivní varianta zapojený typu C. Z hodnot v čase  $t-1$  je predikována hodnota otevírací ceny v čase  $t$ . Použity jsou vždy všechny hodnoty z jednoho dne a predikuje se na den následující.

Vstupní hodnoty:  $Open_{t-1}, Min_{t-1}, Max_{t-1}, Close_{t-1}$  a  $Volume_{t-1}$ .

Výstup:  $Open_t$ .

**Prediktivní klouzavé průměry (PMA).** Oproti zapojení MA je vstup posunut o jeden den dozadu oproti výstupu.

Vstupní hodnoty:  $JKP3_{t-1}, JKP5_{t-1}, CKP_{t-1}, VKP_{t-1}$ .

Výstup:  $Open_t$ .

**Time-Delayed (TD).** Využití myšlenky přivést na vstup více časově posunutých hodnot. Vstupem je vektor  $X = [x_{t-1}, x_{t-2}, \dots, x_{t-n}]$  kde  $n$  značí délku posunu. Každá hodnota vektoru reprezentuje predikovanou hodnotu, tedy otevírací cenu, posunutou v čase o daný počet dnů dozadu. První hodnotou je tedy včerejší otevírací cena, poslední hodnotou otevírací cena před  $n$  dny. Toto zapojení má, jako jediné, proměnnou velikost vstupu.

Vstupní hodnoty:  $Open_{t-n}, Open_{t-n+1}, \dots, Open_{t-1}$ .

Výstup:  $Open_t$ .

**Prediktivní 45 (P45).** Kombinace zapojení PC a TD. Snahou je přivést na vstup více hodnot a více informací z předešlých dnů pro zlepšení kvality predikce.

Vstupní hodnoty:  $Open_{t-4}, Close_{t-4}, Volume_{t-4}, \dots, Open_{t-1}, Close_{t-1}, Volume_{t-1}$ .

Výstup:  $Open_t$ .

#### 4.6. Návrh fitness funkce

Pro porovnání jedinců musí existovat hodnotící funkce. Účel jedince je v tomto případě velice co nejlépe predikovat vývoj časové řady. Tomu odpovídá i fitness funkce. Bude jí odchylka predikované hodnoty od skutečné na trénovacích a testovacích datech dohromady.

Konkrétně půjde o střední kvadratickou odchylku (MSE) podle funkčního předpisu [2]

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}, \quad (4.5)$$

kde:

- $n$  je počet hodnot;
- $y_i$  je skutečná hodnota v čase  $i$ ;
- $\hat{y}_i$  je predikovaná hodnota v čase  $i$ .

Výhodou MSE je snadný výpočet přímo v průběhu učení a snadná interpretace. Je totiž běžně používaná v ekonomické praxi i dalších vědních oborech. Není však jedinou možnou volbou. Stejně dobře může jako fitness funkce sloužit například RMS, definovaná jako odmocnina z MSE, či jiné běžně používané funkce na měření odchylky. [2]

#### 4.7. Návrh testovacích kritérií

Cílem je navržení kritérií, jež povedou k ohodnocení a výběru nejvhodnějšího typu zapojení neuronové sítě s ohledem na vybraný styl obchodování. Základním kritériem je hodnota fitness funkce. Ta je minimalizována již v průběhu učení. Lze ji ale využít také jako srovnávací kritérium jednotlivých zapojení pokud je na vstup přivedena stejná datová sada. Přímé srovnání výsledků různých zapojení a různých datových sad nelze využít, vzhledem k rozdílným hodnotám jednotlivých časových řad.

Druhým kritériem je vizuální srovnání skutečné a predikované hodnoty. Ačkoli nízká hodnota fitness funkce zaručuje vysokou kvalitu aproximace, neuronová síť může ve skutečnosti oscilovat kolem skutečné hodnoty a nemusí se skutečnému průběhu podobat.

Posledním kritériem je test určení trendu. Při obchodním stylu Swing je právě určení otevírací ceny následujícího dne stěžejní záležitostí. Snahou je určit takové zapojení, které co nejlépe určí růst či pokles ceny akcie v následujícím dnu.

Tabulka 2: Ukázka hodnot testu určení trendu

Realita	ID													
	125	119	135	306	308	309	74	75	76					
y	Nárůst / Pokles													
0,165	↓ -1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1
0,171	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1
0,173	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1
0,165	↓ -1	↑ 1	↓ -1	↑ 1	↓ -1	↑ 1	↓ -1	↑ 1	↓ -1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1
0,163	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1
0,163	→ 0	↓ -1	↑ 1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↑ 1	↓ -1	↓ -1
0,163	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1
0,165	↑ 1	↑ 1	↑ 1	↑ 1	↓ -1	↑ 1	↑ 1	↑ 1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1	↓ -1
0,166	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↓ -1	↑ 1	↑ 1
0,165	↓ -1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1	↑ 1

Zdroj: Vlastní zpracování

Ukázka testu je v tabulce 2. Pokud skutečná hodnota otevírací ceny akcie vzrostla oproti předchozímu dni, bude na výstupu hodnota 1, pokud klesla, potom bude přiřazena hodnota -1. Hodnota 0 bude přiřazena, pokud se cena nezměnila. Stejný postup přiřazování je proveden i s výstupem neuronové sítě. Správné určení znamená, že na výstupu skutečné i predikované časové řady je shodná hodnota. Výstupem testu je počet případů, ve kterých byl trend určen správně, a počet případů, ve kterém byl naopak určen špatně. Třetím výstupním parametrem je chybovost, tedy procentní podíl chybně určených hodnot z celkového počtu.

#### 4.8. Dílčí závěry

V kapitole bylo pojednáno o výběru a předzpracování dat. Bylo vybráno celkem 5 datových sad velkých IT společností, obsahujících data z burzy cenných papírů. Z nich byl vybrán úsek 130 hodnot a rozdělen na tři části, použité k učení a testování výstupu neuronových sítí.

Dále bylo navrženo 6 různých modelů zapojení neuronové sítě a testovací kritéria s ohledem na obchodní styl. Zhodnocením výsledků a výběrem nejvhodnějšího zapojení se zabývají následující kapitoly.

## 5. Výběr vhodné radiálně bazické funkce

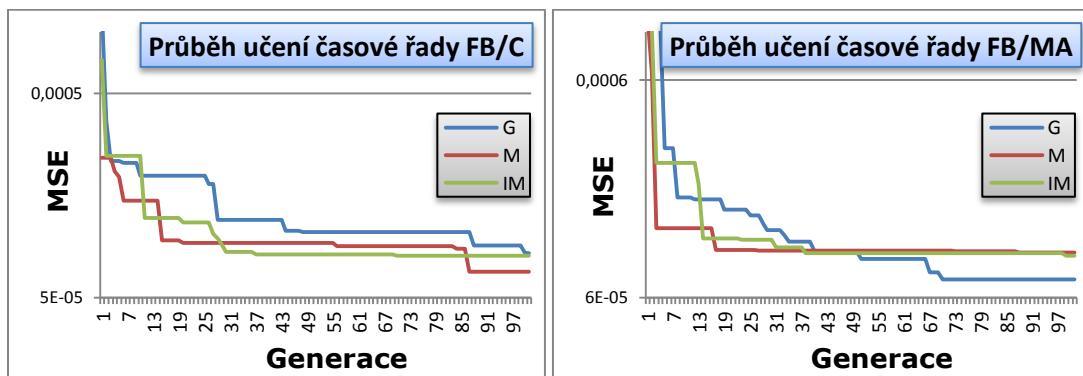
Cílem kapitoly je otestovat modely navržené v kapitole 4 za pomoci upraveného genetického algoritmu a z něj vzniklé aplikace popsané v kapitole 3. Jednotlivé radiálně bazické funkce budou podrobeny sérii dříve popsaných testů za pomoci zapojení C, MA a TD navržených v kapitole 4.5. Výsledkem by měla být volba nejlepší funkce a její následné použití u experimentů popsaných v kapitole 6.

### 5.1. Stanovení průběhu experimentů

Data jsou rozdělena na tři části podle popisu v kapitole 4.4. Testují se modely C, MA a TD. Velikost populace je 20 jedinců. Pro každý model a každou funkci jsou provedeny dva experimenty a zaznamenán ten s lepší hodnotou fitness funkce. Každý experiment bude trvat 100 generací, kvůli porovnatelnosti výsledků.

### 5.2. Srovnání rychlosti učení

Průběh jednotlivých experimentů lze graficky znázornit a porovnat postupné snižování hodnoty fitness funkce. Zatímco multikvadratická funkce na začátku rychle sníží hodnotu fitness funkce a dále ji snižuje jen minimálně, Gaussova funkce snižuje hodnotu pomalejším tempem. Ve většině případů se jí nakonec podaří dosáhnout lepší hodnoty fitness funkce než funkci multikvadratické. Třetí funkce, inverzní multikvadratická, se výsledky pohybuje někde mezi funkcemi dříve jmenovanými. Obr. 12 zobrazuje průběhy pro modely C a MM pro datovou sadu FB.



Obr. 12: Průběh učení řady FB pro model C a MA

Zdroj: Vlastní zpracování

Rychlost učení je možné ohodnotit i číselně viz tabulka 3. Pro každou časovou řadu je zvolena mezní hodnota. Tou byla zvolena nejhorší dosažená hodnota fitness funkce pro daný vstup a dané zapojení, tedy vždy nejvyšší hodnota v řádku tabulky 4. V tabulce 3 je zaznamenána generace, při které fitness funkce neuronové sítě poprvé dosáhla mezní hodnoty, nebo hodnoty nižší.

Tabulka 3: Počet generací nutných k dosažení předem definované hodnoty

Časová řada	Model	Počet generací		
		Gaussova	Multikvadratická	Inverzní multikvadratická
AAPL	C	74	98	69
AAPL	MA	20	13	79
AAPL	TD	39	25	33
FB	C	100	86	36
FB	MA	50	88	37
FB	TD	3	1	83
GOOG	C	66	20	58
GOOG	MA	81	11	20
GOOG	TD	67	5	15
HPQ	C	2	19	9
HPQ	MA	5	45	9
HPQ	TD	16	2	83
MSFT	C	23	1	1
MSFT	MA	17	72	38
MSFT	TD	15	77	3

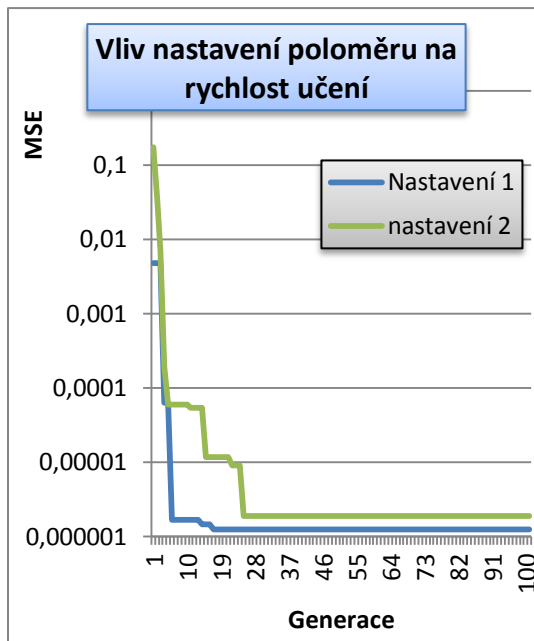
Zdroj: Vlastní zpracování

Hodnoty pro jednotlivé funkce působí vyrovnaně a skutečně tomu tak je. Pro všechny tři aktivační funkce je k dosažení dané hodnoty potřeba v průměru 38 generací. Vzhledem k pravděpodobnosti, která je hlavním činitelem v genetickém algoritmu, mají všechny tři funkce stejnou šanci nalézt nové optimum. Není tedy možné určitě, která funkce se učí rychleji, v průměru se učí všechny stejně rychle.


### 5.3. Vliv nastavení poloměru neuronu na rychlost učení

Při experimentech bylo zjištěno, že neuronové sítě s nejlepšími výsledky mají poloměr nastaven co nejbližší hodnotě jedna. Časová řada MSFT slouží k otestování vlivu nastavení počátečního středu na rychlost učení.

Byla vytvořena dvě nastavení genetického algoritmu. V prvním byly generovány poloměry v rozmezí hodnot 0,8 – 0,9, v druhém 0,1 – 0,9. Snahou je poukázat na fakt, že jelikož výsledné nejlepší neuronové sítě mají středy v okolí dříve zmíněného intervalu, není potřebné využívat celý dostupný rozsah.



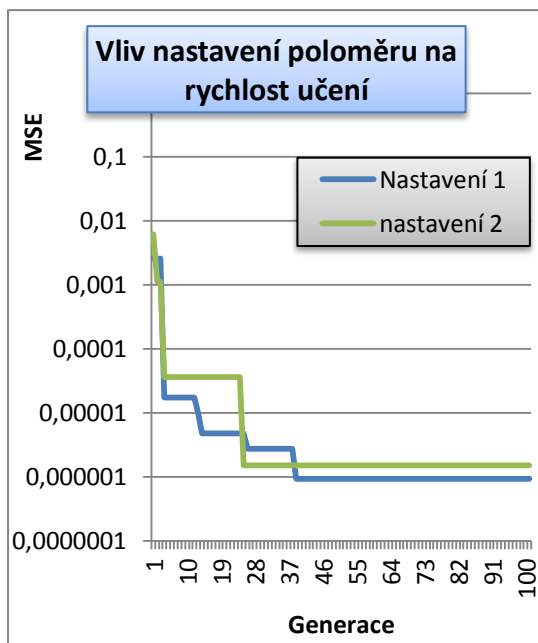
Obr. 13: Vliv nastavení na rychlost učení pro Gaussovu funkci




Obr. 14: Vliv nastavení na rychlost učení pro multikvadratickou funkci

*Zdroj: Vlastní zpracování*

Zelená spojnice na obr. 13 reprezentuje průběh učení druhého nastavení s větším rozptylem generovaných poloměrů. Je zřetelné že výsledná fitness funkce dosahuje horších výsledků, ale všechny průběhy mají podobný počet zlomů a i ve srovnatelném čase. Obdobný průběh nastává i u multikvadratické funkce na obr. 14. Zlomy reprezentují přechod na nové optimum, tedy byla nalezena konfigurace neuronové sítě s nižší hodnotou. Výsledné neuronové funkce druhého nastavení měly vždy výrazně nižší hodnotu středu než funkce v prvním nastavení. Lze se tak domnívat, že genetickému algoritmu trvá déle, než optimalizuje rozložení center neuronů a posléze i hodnotu poloměru.



Obr. 15: Vliv nastavení na rychlost učení u inverzní multikvadratické f.



Obr. 16: Vliv nastavení 1 a 3 na rychlost učení

Zdroj: Vlastní zpracování

Jediná výjimka nastala u inverzní multikvadratické funkce vyobrazené na obr. 15, kdy druhé neuronové sítě z druhého nastavení dlouhou dobu vykazovaly daleko nižší chybu. To je ale dáno náhodností genetického algoritmu.

První nastavení je jen podmnožinou druhého a tak existuje vysoká pravděpodobnost, že se budou řešení v obou nastaveních prolínat. Bylo tedy vytvořeno ještě třetí nastavení. Počáteční nastavení poloměru je zvoleno v rozmezí 0,1 - 0,3 a jeho růst je možný jen pomocí operací mutace či křížení. Z průběhu funkce na obr. 16 lze pozorovat počáteční zpoždění, a jen minimální vývoj u prvních generací. Po sto generacích je hodnota fitness funkce opět horší než ta u prvního nastavení.

#### 5.4. Srovnání hodnot fitness funkce

Výsledky jednotlivých experimentů jsou zobrazeny v tabulce 4. Tučně je vyznačena nejnižší hodnota MSE pro daný typ zapojení a danou časovou řadu. Na první pohled je patrné, že nejlepší hodnoty dosahovala Gaussova funkce. V osmi z patnácti případů podala nejlepší výsledek. Špatné výsledky nepodávala ani multikvadratická funkce, jež dosáhla nejlepších výsledků v šesti případech. Jak již bylo zmíněno dříve, inverzní multikvadratická funkce je ve většině případů hodnotou někde mezi Gaussovou a multikvadratickou funkcí, nejlepších výsledků tak dosáhla pouze v jednom případě.



Tabulka 4: Přehled dosažených hodnot MSE při učení

Časová řada	Model	MSE		
		Gaussova	Multikvadratická	Inverzní multikvadratická
AAPL	C	0,00003260	<b>0,00002254</b>	0,00002776
AAPL	MA	<b>0,00001061</b>	0,00005896	0,00008780
AAPL	TD	0,00031696	<b>0,00029453</b>	0,00030564
FB	C	0,00008234	<b>0,00006676</b>	0,00008007
FB	MA	<b>0,00007270</b>	0,00009665	0,00009323
FB	TD	<b>0,00045574</b>	0,00048526	0,00058098
GOOG	C	0,00005414	<b>0,00001693</b>	0,00004540
GOOG	MA	0,00005940	<b>0,00002976</b>	0,00004992
GOOG	TD	0,00025748	<b>0,00014567</b>	0,00015677
HPQ	C	<b>0,00000523</b>	0,00004376	0,00000691
HPQ	MA	<b>0,00000189</b>	0,00002225	0,00000262
HPQ	TD	<b>0,00001002</b>	0,00001310	0,00001255
MSFT	C	<b>0,00000109</b>	0,00000633	0,00000131
MSFT	MA	0,00000123	0,00000096	<b>0,00000093</b>
MSFT	TD	<b>0,00000633</b>	0,00001201	0,00000720

Zdroj: Vlastní zpracování

V tabulce 5 jsou porovnány aktivační funkce neuronové sítě podle rozdílu jimi dosažených hodnot a nejnižší dosažené hodnoty pro daný typ experimentu. Zeleně podbarvené hodnoty reprezentují minimální odchylku do 20 %. Červenou hodnotou jsou podbarveny hodnoty s vysokou odchylkou nad 150. Nepodbarvené jsou prostřední hodnoty s přijatelnou odchylkou 20 % až 150 %. Je nutno dodat, že naměřené hodnoty jsou většinou v milióntinách a tedy nárůst chyby do 100 % nemá tak dramatický vliv na kvalitu predikce, jak by se mohlo na první pohled zdát.

Tabulka 5: Porovnání odchylek funkcí mezi sebou

Časová řada	Model	Procentní odchylka od nejnižší hodnoty		
		Gaussova f.	Multikvadratická f.	Inverzní multikvadratická f.
AAPL	C	44,63	0,00	23,16
AAPL	MA	0,00	455,70	727,52
AAPL	TD	7,62	0,00	3,77
FB	C	23,34	0,00	19,94
FB	MA	0,00	32,94	28,24
FB	TD	0,00	6,48	27,48
GOOG	C	219,79	0,00	168,16
GOOG	MA	99,60	0,00	67,74
GOOG	TD	76,76	0,00	7,62
HPQ	C	0,00	736,71	32,12
HPQ	MA	0,00	1077,25	38,62
HPQ	TD	0,00	30,74	25,25
MSFT	C	0,00	480,73	20,18
MSFT	MA	32,26	3,23	0,00
MSFT	TD	0,00	89,73	13,74

Zdroj: Vlastní zpracování

V tabulce 5 je poukázáno na problém multikvadratické funkce. Zatímco Gaussova funkce podává buď nejlepší výsledek, nebo je mu velmi blízko, multikvadratická funkce mu je často velmi vzdálena. Buď dosáhne nejlepšího výsledku, nebo dosahuje nesrovnatelně horších výsledků než další dvě funkce. Je to patrné z tabulky 6, kde průměrná chyba této funkce dosahuje šestinásobku průměrné odchylky funkce Gaussovy. Hodnoty inverzní multikvadratické funkce sice nedosahují nejlepších výsledků, ale často jsou velice blízko nejlepší hodnotě.

Tabulka 6: Průměrná chyba jednotlivých funkcí

Funkce	Gaussova	Multikvadratická	Inverzní multikvadratická
Průměr MSE	<b>33,60</b>	194,23	80,24

Zdroj: Vlastní zpracování

Podobné výsledky vykazuje i tabulka 7, kde je zobrazena průměrná chyba jednotlivých časových řad. Gaussova funkce podává, krom akcí společnosti Google, nejlepší výsledky. Naopak multikvadratická funkce je ve třech případech již v červených hodnotách.

**Tabulka 7: Průměrná chyba podle časové řady**

Časová řada	Průměrná procentní odchylka od nejnižší hodnoty		
	Gaussova f.	Multikvadratická f.	Inverzní multikvadratická f.
AAPL	17,42	151,90	251,48
FB	7,78	13,14	25,22
GOOG	132,05	0,00	81,17
HPQ	0,00	614,90	32,00
MSFT	10,75	191,23	11,31

*Zdroj: Vlastní zpracování*

Tabulka 8 reprezentuje srovnání podle modelu, který byl vybrán. Ač inverzní multikvadratická funkce vykazuje u dvou modelů o výsledky, v celkovém kontextu je právě Gaussova funkce ideální volbou. Naopak Multikvadratická funkce ve dvou případech vykazuje neúměrně vysokou hodnotu průměrné odchylky.

**Tabulka 8: Průměrná chyba vzhledem k použitému modelu**

Model	Průměrná procentní odchylka od nejnižší hodnoty		
	Gaussova f.	Multikvadratická f.	Inverzní multikvadratická f.
C	57,55	243,49	52,71
MA	26,37	313,82	172,43
TD	16,87	25,39	15,57

*Zdroj: Vlastní zpracování*

Z měření jasně vyplynulo, že nejlepší volbou aktivací funkce je funkce Gaussova. Ta je také nejběžněji používána. V jednotlivých měřeních dosahovala většinou nejlepších výsledků a v průměru se drží ze všech tří funkcí co nejbližší nejlepší dosažitelné hodnotě. Naopak multikvadratická funkce působí na první pohled jako skvělá volba, často však dosahuje podstatně horších výsledků, někdy i o řád, než funkce Gaussova. Není tedy tak spolehlivá a mnohem stabilněji působí její inverze.

## 5.5. Dílčí závěry

Všechny tři radiálně bazické funkce uvedené v kapitole 2 podstoupily sérii testů. Cílem bylo vybrat funkci, která bude soužit k modelování průběhu časové řady reprezentující otevírací cenu akcie. Porovnána byla jak rychlost učení jednotlivých funkcí, tak hodnoty fitness funkce. Všechny tři funkce jsou do hlediska rychlosti učení

shodné. Důvodem je použitý genetický algoritmus a s ním spojená pravděpodobnost přechodu na nové optimum. Ta je pro všechny tři funkce totožná.

Ve většině případů nejsou rozdíly v kvalitě aproximace jednotlivých radiálně bazických funkcí velké. Po určité kombinace vstupů a datové sady ale nebylo možné určit takové nastavení parametrů neuronové sítě, aby byla hodnota MSE dostatečně nízká. S tímto problémem se potýká převážně multikvadratická funkce, u Gaussovy funkce k podobným situacím nedochází.

Gaussova funkce je z pohledu dosažených výsledků nejlepší volbou pro modelování časových řad. Kvalita dosažených výsledků je stabilní, a nenastaly u ní výkyvy, jako se tomu děje u funkce multikvadratické.

## 6. Porovnání modelů PC, PMA, TD a P45

Cílem této kapitoly je provedení série experimentů na prediktivních modelech zapojení neuronové sítě. Zkoumány budou modely PC, PMA, P45 a TD na jejich schopnost interpolace a extrapolace průběhu časové řady MSFT za pomoci kritérií stanovených v kapitole 4.7. Výstupem kapitoly by měl být nejvhodnější model zapojení, s ohledem na vybranou strategii obchodování na burze cenných papírů.

### 6.1. Stanovení průběhu experimentů

Experiment probíhá podle zadání v kapitole 5.1. Pro jednotlivé experimenty byla jako aktivační funkce neuronů zvolena Gaussova funkce. Všechny experimenty jsou provedeny a zobrazeny pro datovou sadu MSFT. Experimenty provedené na ostatních datových sadách dosahovaly podobných výsledků a jejich výstupy jsou součástí přílohy A. Vybrané grafické výstupy jsou součástí příloh D až M.

### 6.2. Porovnání hodnot fitness funkce

Pro všechny 3 radiálně bazické funkce byly provedeny 2 experimenty a byla stanovena nejnižší dosažená hodnota MSE, viz tabulka 9. Byla určena i průměrná hodnota MSE sloužící k porovnání jednotlivých modelů.

Tabulka 9: Dosažené hodnoty MSE pro jednotlivé modely

ID	Model	Funkce	MSE	Průměr MSE
74	TD	Gaussova	0,00000633	0,00000853
75	TD	Multikvadratická	0,00001207	
76	TD	Inverzní multikvadratická	0,00000720	
125	PC	Gaussova	0,00000256	0,00000325
119	PC	Multikvadratická	0,00000416	
135	PC	Inverzní multikvadratická	0,00000304	
306	PMA	Gaussova	0,00000170	0,00000381
308	PMA	Multikvadratická	0,00000664	
309	PMA	Inverzní multikvadratická	0,00000308	
291	P45	Gaussova	0,00000439	0,00001311
313	P45	Multikvadratická	0,00001886	
314	P45	Inverzní multikvadratická	0,00001608	

Zdroj: Vlastní zpracování


Nejlepších hodnot dosahují zapojení PC a PMA. Naopak model TD dosahuje v průměru více jak 2,5x horších hodnot než je tomu u modelu PC. Model P45, dosahoval dobrých výsledků pouze při použití Gaussovy funkce. U ostatních funkcí se nepodařilo dosáhnout dostatečně nízké hodnoty MSE.

### **6.3. Kvalita predikce na trénovacích a testovacích datech**

Je nutné prověřit výstup testovaných modelů i vizuálně, a zhodnotit, jak kvalitně aproximují skutečný výstup ( $y$ ). Na grafických výstupech níže je černou barvou zobrazena predikovaná hodnota ( $y'$ ) a také odchylka skutečné a predikované hodnoty ( $E$ ). Tyto výstupy poskytují ucelený pohled jak na kvalitu predikce, tak na úseky ve vývoji ceny akcie, které působí neuronové síti největší potíží.

Model TD na obr. 17 nedosahuje nejlepších hodnot MSE. Problém způsobuje skutečnost, že neuronová síť se v tomto zapojení neučí predikovat. Místo toho pouze obkresluje průběh časové řady s jednodenním zpožděním. Tato skutečnost se potvrdila i při testech na jiných datových sadách a i při využití zbylých radiálně bazických funkcí. Tento model tak ve skutečnosti nedokáže predikovat budoucí hodnoty otevírací ceny akcie.


S modelem TD byly provedeny i další testy, při kterých byl počet vstupů zvednut z původních čtyř až na hodnotu patnáct. Na vstupu byly tedy hodnoty z předešlých patnácti dnů. Ani toto rozšíření nedokázalo zlepšit kvalitu výstupu neuronové sítě. Další možné rozšíření tohoto modelu reprezentuje model P45, jehož výstup je popsán dále v kapitole.



Obr. 17: Výstup predikce modelu TD

Zdroj: Vlastní zpracování


Oproti tomu model PC znázorněný na obr. 18 dosahoval v průměru nejnižších hodnot z prediktivních typů zapojení. Odpovídá tomu predikovaný průběh. Časová řada je velice dobře aproximována, neuronové síti nečiní velké obtíže malé ani velké změny ceny akcie. K výraznému nárůstu chyby dochází pouze v případě velkého poklesu ceny.



Obr. 18: Výstup predikce modelu PC

Zdroj: Vlastní zpracování


Model využívající klouzavé průměry PMA aproximuje trend časové řady. Není přitom opsán průběh původní vyhlazené časové řady, jako je tomu u modelu MA viz příloha C, ale je vytvořen vlastní. Ten je výrazně hladší a naprosto vynechává menší výkyvy v ceně akcie jak je patrné na obr. 19. Jeho použitelnost, jakožto krátkodobého prediktoru tak je výrazně omezena.



Obr. 19: Výstup predikce modelu PMA

Zdroj: Vlastní zpracování

Model P45 vznikl jako kombinace modelů PC a TD s očekáváním lepších výsledů. Výsledný model dosahuje lepších výsledků než je tomu u zapojení TD. Hodnota MSE je nižší a i vizuálně je predikovaný průběh blíže realitě. V žádném experimentu ale nedokázal překonat výsledky modelu PC. Poměrně nízká odchylka je způsobena oscilací predikovaných hodnot okolo hodnot skutečných. Vizuálně ale predikovaný průběh, nacházející se na obr. 20 původní časové řadě neodpovídá.



Obr. 20: Výstup predikce modelu P45

Zdroj: Vlastní zpracování

Z hlediska predikování hodnoty ceny akcie v krátkém horizontu jednoho dne si nejlépe vede model PC. Pokud by byl zvolen obchodní styl s delší dobou držení akcie, mohl by být vhodným kandidátem model PMA.



#### 6.4. Test určení trendu na trénovacích a testovacích datech

Při testu určení trendu si nejlépe vedl model PC. Hodnoty testu obsahuje tabulka 10. Chybovost dosahovala 35 %. Překvapivě dobrých výsledků dosáhl i model P45 s s chybovostí necelých 40 %. Model TD vykazoval chybu téměř 48 %. Nedokáže tedy v téměř polovině případů správně určit budoucí směr růstu či poklesu ceny akcie.

Tabulka 10: Hodnoty testu určení trendu (trénovací a testovací data)

Model	TD	PC	PMA	P45
ID	ID 74	ID 125	ID 306	ID 291
Správné určení	49	61	56	57
Nesprávné určení	46	34	39	38
Chybovost [%]	47,92	35,42	40,63	39,58

Zdroj: Vlastní zpracování

Model PC byl otestován podrobněji a tabulka 11 reprezentuje výsledky testu určení trendu pro všechny časové řady. Velmi dobrý výsledek chybovosti, necelých 24 %, dosáhl tento model u časové řady APL. Velmi dobré výsledky vykazoval i u řad FB a MSFT. Za zmínku stojí i časová řada HPQ, kde chybovost dosahovala nejvyšší hodnoty 45 %. Přitom tato řada patří v testu k těm nejkolidnějším, má dlouhodobě sestupný trend a neobsahuje žádné významné výkyvy otevírací ceny. Průměrná chybovost pro všechny časové řady činí 35,5 %.


Tabulka 11: Test určení trendu modelu PC (trénovací a testovací data)

Časová řada	APL	FB	GOOG	HPQ	MSFT
ID	164	169	178	174	125
Správné určení	68	59	53	49	58
Nesprávné určení	21	30	36	40	31
Chybovost [%]	23,59551	33,70787	40,44944	44,94382	34,83146

Zdroj: Vlastní zpracování

#### 6.5. Kvalita predikce na neznámých datech


Při extrapolaci časové lze dojít ke stejným závěrům jako v kapitole 6.3. Skutečný průběh nejlépe opisuje model PC, viz obr. 21. Model TD opisuje průběh se zpožděním a zapojení PMA opisuje trend časové řady. Model P45, znázorněný zelenou spojnicí, není skutečnému průběhu podoben vůbec.



Obr. 21: Výstup predikce na neznámých datech

Zdroj: Vlastní zpracování

Všechny modely vykazují na testovaném intervalu podobné procento. Chybu jednotlivých modelů zobrazuje obr. 22. K nárůstu chyby dochází v místech velké změny ceny, tedy kolem pátého dne a dále v místě velkého propadu ve dnech 15 až 20. Důležitý je fakt, že s rostoucím časem nedochází k nárůstu chyby a i na konci testovaného intervalu jsou hodnoty chyby podobné těm na jeho začátku.



Obr. 22: Chyba modelů na neznámých datech

Zdroj: Vlastní zpracování

## 6.6. Test určení trendu na neznámých datech

U extrapolovaných hodnot byl zjištěn zajímavý úkaz, a to že u dvou modelů došlo k výraznému zlepšení určení trendu. Hodnoty testu obsahuje tabulka 12. Chyba modelu PC klesla o více jak 14 % na hodnotu 20,7 % a model P45 o 9 % na hodnotu 31 %. Za zlepšením může být skutečnost, že testovaný interval obsahuje méně výrazných změn v ceně akcie oproti trénovacím a testovacím datům. Naopak chybovost

modelů TD a PMA se zhoršila a s hodnotou 52 % a 45 % nelze uvažovat o jejich reálném využití.

Tabulka 12: Test určení trendu (neznámá data)

Model	TD	PC	PMA	P45
ID	74	125	306	291
Správné určení	14	23	16	20
Nesprávné určení	15	6	13	9
Chybovost [%]	51,72	20,69	44,83	31,03

Zdroj: Vlastní zpracování


Test provedený na modelu PC pro všechny časové řady ukázal pokles chybovosti, znázorněné v tabulce 13, oproti hodnotám v tabulce 11. Jedině u řady HPQ došlo ke zhoršení chybovosti na 52 %. V ostatních případech se drží chyba pod 30 %, v případě řady APL dokonce pouhých 10 %. Průměrná chybovost dosahuje necelých 28 %.

Tabulka 13: Test určení trendu modelu PPC (neznámá data)

Časová řada	APL	FB	GOOG	HPQ	MSFT
ID	164	169	178	174	125
Správné určení	26	21	21	14	23
Nesprávné určení	3	8	8	15	6
Chybovost [%]	10,34483	27,58621	27,58621	51,72414	20,68966

Zdroj: Vlastní zpracování

Příčinu nízké chybovosti lze hledat v grafickém znázornění skutečné a extrapolované hodnoty na obr. 23. Neuronová síť se naučila základní opakující se vzory a určitá pravidla při obchodování s akcemi AAPL. Dokáže tedy velmi dobře určit trend. Nedokáže ale správně predikovat cenu akcie. Skutečná otevírací cena stoupá strměji než průběh generovaný neuronovou sítí.



Obr. 23: Predikce modelu PC na datové sadě AAPL

Zdroj: Vlastní zpracování

## 6.7. Dílčí závěry

Vybrané prediktivní modely byly otestovány pomocí předem definovaných kritérií z kapitoly 4.7. Časová řada MSFT byla rozdělena na dva intervaly, první pro interpolaci a druhý pro extrapolaci. Nejnižších hodnot dosahují modely PC a PMA. Model P45 dosahuje nízkých hodnot MSE jen při využití Gaussovy funkce. Totéž by se dalo říci i o modelu TD, ale i při použité této funkce je hodnota MSE přibližně 3x horší než u modelu PMA.

Při vizuální kontrole predikovaného průběhu ceny akcie bylo zjištěno, že model TD prakticky nepredikuje, ale pouze opisuje průběh časové řady s jednodenním zpožděním. Aproximovat časovou řadu dokázal nejlépe model PC. Model PMA opisuje dlouhodobý trend akcie a není tak vhodný pro zvolený styl obchodování. Stejně závěry potvrdily i testy na neznámých datech.

V testu určení trendu dosahoval nejlepších výsledků opět model PC a to na obou intervalech časové řady. Na trénovacích a testovacích datech dosahuje průměrné chybovosti přibližně 35 %, na neznámých datech dokonce 28 %. Největší chybovosti dosahoval model TD, který, jak již bylo dříve zmíněno, pouze opisuje funkční průběh a tedy i trend určuje s jednodenním posunem.

Pro obchodní styl Swing je tedy nejvhodnější model PC, který dokáže velmi přesně predikovat jak samotnou hodnotu otevírací ceny akcie, tak případný pokles či vzestup ceny. Pro dobu držení akcie několika málo dní, by pro určení trendu mohl sloužit i model PMA. Ostatní modely nedosahovaly takových výsledků, aby se dalo uvažovat o jejich reálné využití při obchodování na burze cenných papírů.

## Závěr

Práce je zaměřena na návrh a následnou analýzou modelů, založených na RBF neuronových sítích, vhodných pro modelování dat získaných z burzy cenných papírů. Je rozdělena do 6 kapitol, ve kterých jsou postupně splněny všechny cíle definované v jejím úvodu.

První kapitola pojednává o trhu s cennými papíry. Jsou definovány základní pojmy a vysvětlen princip fungování burzy. Důležitou součástí je popis jednotlivých obchodních stylů, z kterých byl jeden vybrán a byl využit při definování modelů. Jedná se o styl Swing, s dobou držení akcie jen po dobu jednoho dne. Popsány jsou i prvky technické a fundamentální analýzy, jakožto základní nástroje každého obchodníka na burze.

Druhá kapitola popisuje RBF neuronové sítě. Definovány jsou tři základní radiálně bazické funkce a jejich parametry. Dále je definována struktura tohoto typu neuronové sítě. Konec kapitoly se věnuje učení RBFNN. To probíhá s učitelem a využívá metody nejmenších čtverců k určení synaptických vah.

Před učením RF neuronové sítě je nutno určit všechny parametry radiálně bazických funkcí. K tomu byl vybrán genetický algoritmus, jehož základní i modifikovanou verzi obsahuje kapitola tři. Výsledkem modifikace je aplikace napsaná v jazyce PHP a JavaScript, sloužící k učení RBF neuronových sítí právě pomocí genetického algoritmu. Ta dále poslouží k provedení experimentů na modelech, které jsou navrženy v kapitole čtyři. Ta se kromě návrhu popisu modelů a návrhu testovacích kritérií zabývá i výběrem, analýzou a předzpracováním vybraných dat. Data pochází z americké burzy NASDAQ a patří významným firmám v oblasti IT, jmenovitě: Google, Facebook, Microsoft, Apple nebo Hewlett-Packard.

Pátá kapitola se zabývá volbou radiálně bazické funkce. Nejběžněji používaná Gaussova funkce je srovnána s funkcí multikvadratickou a inverzní multikvadratickou. Volba aktivační funkce může výrazně ovlivnit výstup neuronové sítě. Multikvadratická funkce nebyla mnohdy schopna dosáhnout srovnatelných hodnot s ostatními funkcemi. Po důkladných testech byla vybrána Gaussova funkce jakožto nejvhodnější pro tento typ problému.

Poslední kapitola porovnává jednotlivé modely. Ty jsou celkem čtyři a každé odpovídá určitému zapojení neuronové sítě a jiným proměnným na jejím vstupu. Modely jsou postupně zhodnocovány podle předem daných kritérií. Prvním je hodnota střední kvadratické odchylky skutečné a predikované hodnoty. Druhé kritérium je vizuální zhodnocení kvality aproximace časové řady. Zde se ukázalo, že i při nízké hodnotě MSE nemusí průběh predikovaný neuronovou sítí odpovídat průběhu skutečnému. Posledním kritériem je test určení trendu. Porovnává modely podle toho, zdali jsou schopny správně určit budoucí růst či pokles otevírací ceny akcie.

Výstupem celé práce je model, který by měl co nejlépe predikovat hodnoty otevírací ceny akcie podle obchodního stylu Swing. Je jím model PC, jehož hodnoty MSE patřily v testu k těm nejnižším, velmi přesně aproximoval skutečný průběh časové řady a v testu určení trendu dosahoval průměrné chyby okolo 30 %. Tedy v 7 případech z 10 dokáže správně určit, zdali otevírací cena akcie bude zítra růst, či naopak klesne.

## Seznam použité literatury

- [1] AAPL Profile: Apple Inc. stock. *Yahoo! Finance* [online]. c2013 [cit. 2013-03-06]. Dostupné z: <http://finance.yahoo.com/q/pr?s=AAPL+Profile>
- [2] ARLT, Josef ARLTOVÁ, Markéta, RUBLÍKOVÁ, Eva. *Analýza ekonomických časových řad s příklady*. [online]. [cit. 2013-03-17]. Dostupné z: <http://nb.vse.cz/~arltova/vyuka/crsbir02.pdf>
- [3] BANZHAF, Wolfgang. *Genetic programming: an introduction on the automatic evolution of computer programs and its applications*. Heidelberg: Dpunkt-verlag, c1998, 470 p. ISBN 39-209-9358-6.
- [4] Cenné papíry. *Businessinfo.cz* [online]. 4. 5. 2011 [cit. 2013-04-10]. Dostupné z: <http://www.businessinfo.cz/cs/clanky/cenne-papiry-opu-4644.html>
- [5] ČERMÁK, Libor, HLAVIČKA, Rudolf. *Numerické metody*. [online]. [cit. 2013-04-1]. Dostupné z: <http://mathonline.fme.vutbr.cz/UploadedFiles/240.pdf>
- [6] E-Automatizace:Encyklopedie. *E-Automatizace* [online]. [cit. 2013-04-10]. Dostupné z: <http://www.e-automatizace.cz/encyklopedie.asp?Hledat=a>
- [7] FB Profile: Facebook, Inc. stock. *Yahoo! Finance* [online]. c2013 [cit. 2013-03-06]. Dostupné z: <http://finance.yahoo.com/q/pr?s=FB+Profile>
- [8] FIALA, Petr. *Úvod do ekonometrie*. Vyd. 1. V Praze: České vysoké učení technické, 2008, 173 s. ISBN 978-80-01-04004-1.
- [9] Fundamentální analýza. *Miras.cz* [online]. c2012 [cit. 2013-04-17]. Dostupné z: <http://www.miras.cz/akcie/akciove-analyzy-fundamentalni.php>
- [10] GOOG Profile: Google Inc. stock. *Yahoo! Finance* [online]. c2013 [cit. 2013-03-06]. Dostupné z: <http://finance.yahoo.com/q/pr?s=GOOG+Profile>

- [11] HAYKIN, Simon. *Neural Networks: A Comprehensive Foundation*. 2. vyd. Delhi: Pearson Education, 2005. ISBN 81-7808-300-0.
- [12] HPQ Profile: Hewlett-Packard Company common stock. *Yahoo! Finance* [online]. c2013 [cit. 2013-03-06].  
Dostupné z: <http://finance.yahoo.com/q/pr?s=HPQ+Profile>
- [13] HYNEK, Josef. *Genetické algoritmy a genetické programování*. 1. vyd. Praha: Grada, 2008, 182 s. ISBN 978-80-247-2695-3.
- [14] KRBÁLEK, Milan. *Matematická analýza III*. 1. vyd. Praha: České vysoké učení technické, 2005. ISBN 80-01-03216-7.
- [15] KVASNIČKA, Vladimír, BEŇUŠKOVÁ, Ľubica, POSPÍCHAL, Jiří, FARKAŠ, Igor, PETER, Tiňo, KRÁL, Andrej. *Úvod do teorie neuronových sietí*. Bratislava: IRIS, 1997. ISBN 80-88778-30-1.
- [16] MAŘÍK, Vladimír, ŠTĚPÁNKOVÁ, Olga, LAŽANSKÝ, Jiří a kolektiv. *Umělá inteligence (3)*. Praha: Academia, 2001. ISBN 80-200-0472-6.
- [17] MATOUŠEK, Jiří, NEŠETŘIL, Jaroslav. *Kapitoly z diskrétní matematiky*. 2. upr. vyd. Praha: Karolinum, 2000, 377 s. ISBN 80-246-0084-6.
- [18] MCNELIS, Paul D. *Neural networks in finance: gaining predictive edge in the market*. Burlington, MA: Elsevier Academic Press, c2005, 243 p. ISBN 01-248-5967-4.
- [19] MIČKA, Pavel. *Algoritmus. Algoritmy.net* [online]. c2013 [cit. 2013-04-10].  
Dostupné z: <http://www.algoritmy.net/article/1240/Algoritmus>
- [20] MITCHELL, M. *Introduction to genetic algorithms*. Vyd. 5. Massachusetts: MIT Press, 1999, 158 s. ISBN 0-262-63185-7.
- [21] MSFT Profile: Microsoft Corporation Stock. *Yahoo! Finance* [online]. c2013 [cit. 2013-03-06]. Dostupné z:  
<http://finance.yahoo.com/q/pr?s=MSFT+Profile>



- [22] ORR, Mark. *Introduction to Radial Basis Function Networks*. [online]. 1996 [cit. 2012-05-11]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.129.5503>
- [23] REŽŇÁKOVÁ, Mária, ČIŽINSKÁ, Romana. *Mezinárodní kapitálové trhy: zdroj financování*. 1. vyd. Praha: Grada, 2007, 222 s. Finance (Grada Publishing). ISBN 978-802-4719-221.
- [24] Technická analýza – 2. díl: Trendy a trendové čáry. [Investicniweb.cz](http://www.investicniweb.cz) [online]. 3. 5. 2010 [cit. 2013-04-10]. Dostupné z: <http://www.investicniweb.cz/univerzita/technicka-analyza/2010/5/3/technicka-analyza-2-dil-trendy-trendove-cary/>
- [25] Technická a fundamentální analýza v tradingu. [trhy.mesec.cz](http://trhy.mesec.cz) [online]. 12. 4. 2013 [cit. 2013-04-17]. Dostupné z: <http://trhy.mesec.cz/clanky/technicka-a-fundamentalni-analyza-v-tradingu/>
- [26] TUREK, Ludvík. *První kroky na burze*. Vyd. 1. Brno: Computer Press, 2008, 154 s. ISBN 978-80-251-1915-0.
- [27] Výkladový slovník: Kognitivní věda. *UHK* [online]. [cit. 2013-04-09]. Dostupné z: <http://fim.uhk.cz/cogn/?Module=dictionary&Letter=H>

## Seznam použitých symbolů a zkratek

$F(x)$	Výstup neuronové sítě
$H$	Výstupní matice skryté vrstvy neuronové sítě
$i, j$	Indexy
$k, \sigma, r$	Parametry radiálně bazických funkcí
$m$	Počet neuronů ve skryté vrstvě
$n$	Počet vstupů neuronové sítě
$p$	Počet řádků datového vstupu
$t$	Čas
$\bar{x}$	Vektor
$x$	Hodnota nezávislé proměnné, vstup neuronové sítě
$y, \bar{y}$	Skutečná hodnota závislé proměnné
$y', \hat{y}_i$	Predikovaná hodnoty
$\mathbb{R}$	Množina reálných čísel
$\Leftrightarrow$	Operátor ekvivalence
$\ \cdot\ $	Norma
AJAX	Asynchronous JavaScript and XML
GA	Genetický algoritmus
IT	Informační technologie
MLP	Vícevrstvá perceptronová síť (Multi-Layer Perceptron)
RBF	radiálně bazické funkce (Radial Basis Functions)

## Seznam obrázků

Obr. 1: Náhled průběhu vývoje akcií GOOG .....	13
Obr. 2: Průběh Gaussovy funkce pro dvě různá nastavení poloměru .....	18
Obr. 3: Průběh multikvadratické funkce pro $k=0,5$ a $0,1$ .....	18
Obr. 4: Průběh inverzní multikvadratické funkce pro $k=0,5$ a $0,1$ .....	19
Obr. 5: Struktura neuronové sítě typu RBF .....	20
Obr. 6: Struktura reprezentující genom .....	27
Obr. 7: Ukázka genomu z aplikace .....	27
Obr. 8: Vývojový diagram upraveného genetického algoritmu .....	29

Obr. 9: Komponenty a komunikace uvnitř aplikace.....	32
Obr. 10: Náhled běhu aplikace.....	33
Obr. 11: Návrh modelu obchodování na burze cenných papírů.....	38
Obr. 12: Průběh učení řady FB pro model C a MA .....	44
Obr. 13: Vliv nastavení na rychlost učení pro Gaussovu funkci .....	46
Obr. 14: Vliv nastavení na rychlost učení pro multikvadratickou funkci.....	46
Obr. 15: Vliv nastavení na rychlost učení u inverzní multikvadratické f. ....	47
Obr. 16: Vliv nastavení 1 a 3 na rychlost učení .....	47
Obr. 17: Výstup predikce modelu TD .....	54
Obr. 18: Výstup predikce modelu PC.....	54
Obr. 19: Výstup predikce modelu PMA .....	55
Obr. 20: Výstup predikce modelu P45 .....	55
Obr. 21: Výstup predikce na neznámých datech.....	57
Obr. 22: Chyba modelů na neznámých datech .....	57
Obr. 23: Predikce modelu PC na datové sadě AAPL.....	58

## **Seznam tabulek**

Tabulka 1: Korelace parametrů řady GOOG .....	38
Tabulka 2: Ukázka hodnot testu určení trendu .....	43
Tabulka 3: Počet generací nutných k dosažení předem definované hodnoty .....	45
Tabulka 4: Přehled dosažených hodnot MSE při učení.....	48
Tabulka 5: Porovnání odchylek funkcí mezi sebou .....	49
Tabulka 6: Průměrná chyba jednotlivých funkcí .....	49
Tabulka 7: Průměrná chyba podle časové řady.....	50
Tabulka 8: Průměrná chyba vzhledem k použitému modelu .....	50
Tabulka 9: Dosažené hodnoty MSE pro jednotlivé modely .....	52
Tabulka 10: Hodnoty testu určení trendu (trénovací a testovacích data) .....	56

Tabulka 11: Test určení trendu modelu PC (trénovací a testovacích data) .....	56
Tabulka 12: Test určení trendu (neznámá data).....	58
Tabulka 13: Test určení trendu modelu PPC (neznámá data).....	58

## **Seznam příloh**

Příloha A – Struktura přiloženého CD
Příloha B – Statistická analýza datových sad
Příloha C – Vybraný výstup modelu MA
Příloha D – Výstup predikce modelů PC a P45 (AAPL)
Příloha E – Výstup predikce modelů PC a P45 (FB)
Příloha F – Výstup predikce modelů PC a P45 (GOOG)
Příloha G – Výstup predikce modelů PC a P45 (HPQ)
Příloha H – Výstup predikce modelů PC a P45 (MSFT)
Příloha I – Výstup predikce modelů PMA a TD (AAPL)
Příloha J – Výstup predikce modelů PMA a TD (FB)
Příloha K – Výstup predikce modelů PMA a TD (GOOG)
Příloha L – Výstup predikce modelů PMA a TD (HPQ)
Příloha M – Výstup predikce modelů PMA a TD (MSFT)
Příloha N – Výstup modelu PC (ID 125)

## **Příloha A – Struktura přiloženého CD**

<b>Adresář</b>	<b>Popis</b>
<b>/Aplikace</b>	Zdrojový kód aplikace
<b>/Výstupy</b>	Výstupy všech provedených experimentů ve formátu csv

## Příloha B - Statistická analýza datových sad

### B. 1. AAPL

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Stř. hodnota	17,807208	591,5996	596,9379	584,9923	591,0817
Chyba stř. hodnoty	0,7462835	2,392294	2,327249	2,44917	2,419327
Medián	15,6656	590,71	597,58	582,115	586,695
Modus	#####	574,46	574	606	#####
Směr. odchylka	7,4628354	23,92294	23,27249	24,4917	24,19327
Rozptyl výběru	55,693912	572,3068	541,6086	599,8435	585,3142
Špičatost	0,5518531	-0,80186	-0,97336	-0,7039	-0,72482
Šikmost	1,0517901	-0,06405	0,008031	-0,08783	-0,09921
Minimum	6,9621	533,96	543,41	522,18	530,12
Maximum	38,4339	639,93	644	630,21	636,23
Součet	1780,7208	59159,96	59693,79	58499,23	59108,17
Počet	100	100	100	100	100

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Objem	1				
Open	0,0241107	1			
Min	0,0680059	0,976287	1		
Max	-0,110684	0,973664	0,972174	1	
Close	-0,058207	0,932192	0,972361	0,97301	1

### B. 2. FB

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Stř. hodnota	58,25898	22,2135	22,6178	21,7314	22,1535
Chyba stř. hodnoty	3,777733	0,299143	0,303928	0,288692	0,298689
Medián	48,53335	21,22	21,66	20,67	21,19
Modus	#####	19,5	22,5	26,76	27,71
Směr. odchylka	37,77733	2,991427	3,039283	2,886925	2,986887
Rozptyl výběru	1427,127	8,948635	9,237242	8,334333	8,921496
Špičatost	7,254828	-0,63108	-0,71886	-0,61998	-0,66517
Šikmost	2,278203	0,844118	0,770426	0,869873	0,824706
Minimum	15,6107	18,27	18,27	17,55	17,73
Maximum	229,751	28,7	28,88	27,66	28,24
Součet	5825,898	2221,35	2261,78	2173,14	2215,35
Počet	100	100	100	100	100

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Objem	1				
Open	0,200964	1			
Min	0,274467	0,985519	1		
Max	0,182198	0,989906	0,987036	1	
Close	0,254532	0,974621	0,991814	0,986947	1

### B. 3. GOOG

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Stř. hodnota	2,627633	691,4993	697,9857	685,4187	692,0128
Chyba stř. hodnoty	0,161638	3,752463	3,714184	3,629818	3,655064
Medián	2,22725	684,97	688,785	678,135	683,94
Modus	#####	695	669,8	672	#####
Směr. odchylka	1,616384	37,52463	37,14184	36,29818	36,55064
Rozptyl výběru	2,612698	1408,098	1379,516	1317,558	1335,949
Špičatost	21,90564	-0,57864	-0,65235	-0,52047	-0,58836
Šikmost	4,22709	0,437789	0,45817	0,506795	0,470312
Minimum	0,9225	618,89	635	617,5	628,75
Maximum	12,4424	770,71	774,38	765,01	768,05
Součet	262,7633	69149,93	69798,57	68541,87	69201,28
Počet	100	100	100	100	100

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Objem	1				
Open	0,335073	1			
Min	0,34805	0,991909	1		
Max	0,170552	0,971341	0,973673	1	
Close	0,218421	0,966406	0,98034	0,991638	1

### B. 4. HPQ

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Stř. hodnota	27,28469	16,3851	16,6191	16,1444	16,3515
Chyba stř. hodnoty	2,080066	0,240631	0,238659	0,237022	0,238028
Medián	21,85665	17,185	17,4	16,83	17,17
Modus	26,2577	13,8	14,5	13,8	17,21
Směr. odchylka	20,80066	2,406313	2,386594	2,370219	2,380284
Rozptyl výběru	432,6674	5,79034	5,695833	5,61794	5,665754
Špičatost	22,9138	-1,33633	-1,40238	-1,30154	-1,3186
Šikmost	4,46911	-0,28222	-0,22985	-0,254	-0,20778
Minimum	10,9882	11,64	12,17	11,35	11,71

Maximum	154,6736	20,22	20,7	19,76	20,9
Součet	2728,469	1638,51	1661,91	1614,44	1635,15
Počet	100	100	100	100	100

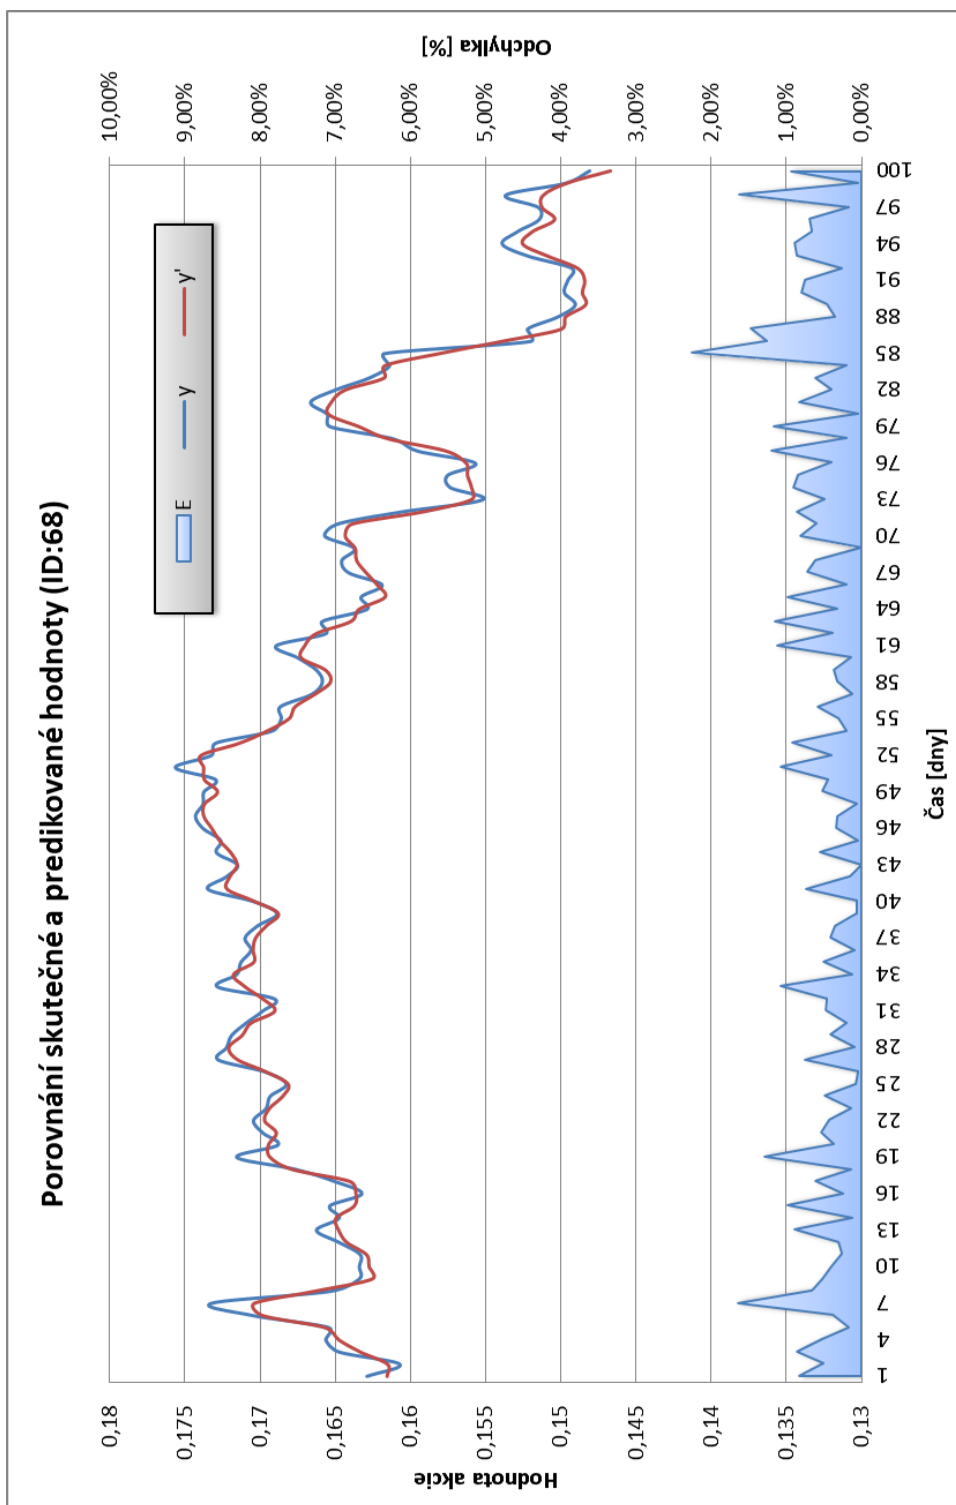
	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Objem	1				
Open	-0,2587	1			
Min	-0,24528	0,99205	1		
Max	-0,32855	0,989718	0,989122	1	
Close	-0,31916	0,984616	0,988612	0,992538	1

#### B. 5. MSFT

	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Stř. hodnota	47,04306	29,4987	29,714	29,2609	29,4739
Chyba stř. hodnoty	1,807611	0,129843	0,133491	0,13395	0,133368
Medián	45,21125	29,645	29,875	29,49	29,705
Modus	#####	29,48	29,74	29,33	30,39
Směr. odchylka	18,07611	1,298427	1,33491	1,339499	1,333683
Rozptyl výběru	326,7458	1,685912	1,781984	1,794259	1,778711
Špičatost	4,575157	-0,25916	-0,12561	-0,31288	-0,20045
Šikmost	1,587287	-0,82345	-0,84774	-0,81113	-0,79753
Minimum	22,9433	26,5	26,63	26,34	26,37
Maximum	131,6892	31,43	31,7	31,3	31,5
Součet	4704,306	2949,87	2971,4	2926,09	2947,39
Počet	100	100	100	100	100


	<i>Objem</i>	<i>Open</i>	<i>Min</i>	<i>Max</i>	<i>Close</i>
Objem	1				
Open	-0,48543	1			
Min	-0,47171	0,987669	1		
Max	-0,53848	0,981542	0,980949	1	
Close	-0,50984	0,966928	0,979169	0,979643	1






**Příloha C – Vybraný výstup modelu MA**

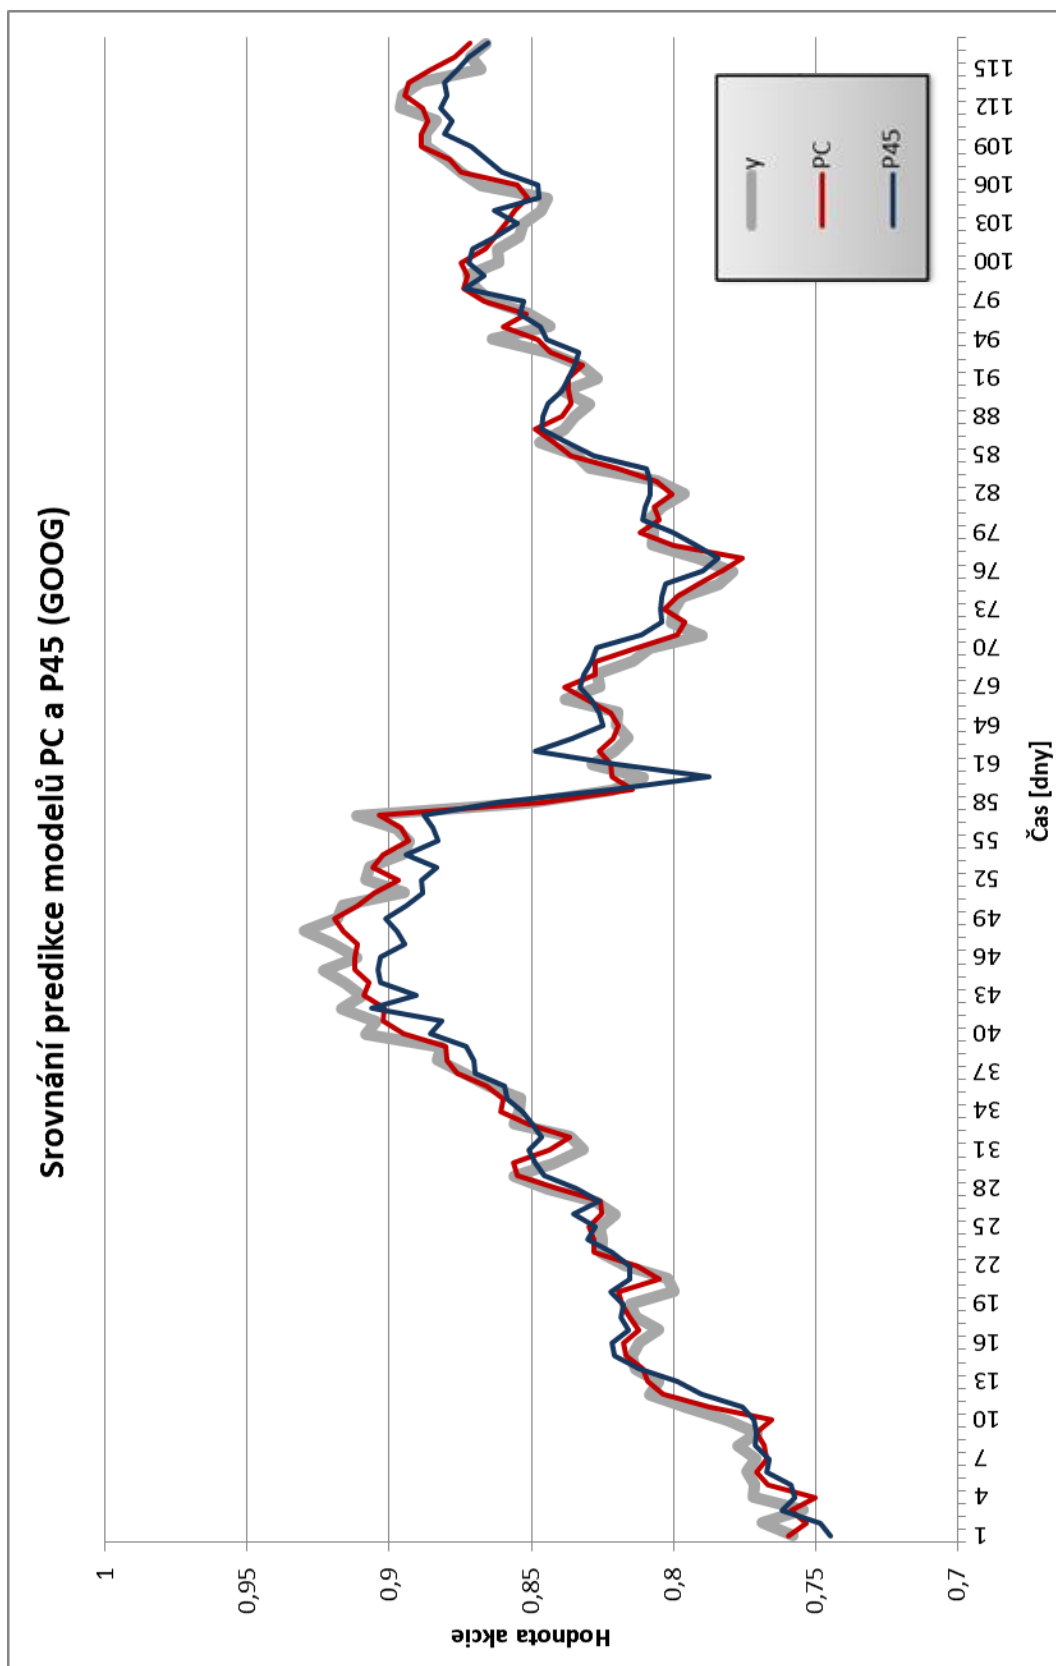
## Příloha D – Výstup predikce modelů PC a P45 (AAPL)




## Příloha E – Výstup predikce modelů PC a P45 (FB)




## Příloha F – Výstup predikce modelů PC a P45 (GOOG)




## Příloha G – Výstup predikce modelů PC a P45 (HPQ)




## Příloha H – Výstup predikce modelů PC a P45 (MSFT)



# Příloha I – Výstup predikce modelů PMA a TD (AAPL)




## Příloha J – Výstup predikce modelů PMA a TD (FB)







## Příloha K – Výstup predikce modelů PMA a TD (GOOG)



## Příloha L – Výstup predikce modelů PMA a TD (HPQ)



## Příloha M – Výstup predikce modelů PMA a TD (MSFT)



## Příloha N – Výstup modelu PC (ID 125)

TID: 125  
Dataset: MSFT  
Populace: 20  
Generací: 101

Uceni

mse	step	size
0,000423	1	6
0,000018	2	2
0,000018	3	2
0,000018	4	2
0,000017	5	2
0,000017	6	2
0,000017	7	2
0,000017	8	2
0,000017	9	2
0,000017	10	2
0,000007	11	2
0,000007	12	2
0,000007	13	2
0,000007	14	2
0,000007	15	2
0,000007	16	2
0,000007	17	2
0,000007	18	2
0,000006	19	2
0,000006	20	2
0,000006	21	2
0,000006	22	2
0,000006	23	2
0,000006	24	2
0,000006	25	2
0,000006	26	2
0,000006	27	2
0,000006	28	2
0,000006	29	2
0,000006	30	2
0,000006	31	2
0,000006	32	2
0,000006	33	2
0,000006	34	2
0,000006	35	2
0,000006	36	2
0,000006	37	2
0,000006	38	2
0,000006	39	2
0,000006	40	2
0,000006	41	2
0,000006	42	2
0,000006	43	2
0,000006	44	2
0,000006	45	2
0,000006	46	2
0,000006	47	2
0,000006	48	2

0,000006	49	2
0,000006	50	2
0,000006	51	2
0,000006	52	2
0,000006	53	2
0,000006	54	2
0,000006	55	2
0,000006	56	2
0,000006	57	2
0,000006	58	2
0,000006	59	2
0,000006	60	2
0,000006	61	2
0,000006	62	2
0,000006	63	2
0,000006	64	2
0,000006	65	2
0,000006	66	2
0,000006	67	2
0,000006	68	2
0,000006	69	2
0,000006	70	2
0,000006	71	2
0,000004	72	3
0,000004	73	3
0,000004	74	3
0,000004	75	3
0,000004	76	3
0,000004	77	3
0,000004	78	3
0,000004	79	3
0,000004	80	3
0,000004	81	3
0,000004	82	3
0,000004	83	3
0,000004	84	3
0,000004	85	3
0,000004	86	3
0,000004	87	3
0,000003	88	3
0,000003	89	3
0,000003	90	3
0,000003	91	3
0,000003	92	3
0,000003	93	3
0,000003	94	3
0,000003	95	3
0,000003	96	3
0,000003	97	3
0,000003	98	3
0,000003	99	3
0,000003	100	3

Nejlepsi podle velikosti

mse	step	size
6E-06	19	2
2,6E-06	88	3

1,5E-05	30	4
2,3E-05	81	5
0,00025	27	6
0,12926	4	7

Vypis T+T

Nejlepší: 0b06a8c4f76ae9c529fed5d6a24b222886972a72  
MSE: 2,6E-06  
Function: g  
in: 5  
out: 1  
model: cp

Weights

1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
-				
0,20475	1,17584	1,26741		

Centers

0,84	0,202	0,5	0,5295	0,2848
0	0,0094	0,1062	0,231	0,1187
0	0,35	0,46	0,17	0,06

Radius

0,87  
0,9542  
1

Výstup T+T

y	y'	e	re	open	close	high	low	volume
0,1607	0,1609	-0,0002	-0,0013	0,1629	0,1591	0,1618	0,1624	0,0616
0,1647	0,1641	0,0007	0,0042	0,1607	0,1633	0,1634	0,1634	0,0379
0,1656	0,1651	0,0005	0,0033	0,1647	0,1636	0,1637	0,1673	0,0270
0,1654	0,1664	-0,0010	-0,0060	0,1656	0,1648	0,1655	0,1661	0,0327
0,1705	0,1695	0,0010	0,0059	0,1654	0,1692	0,1688	0,1676	0,0398
0,1732	0,1713	0,0020	0,0113	0,1705	0,1704	0,1708	0,1729	0,0452
0,1653	0,1716	-0,0063	-0,0384	0,1732	0,1674	0,1746	0,1735	0,0620
0,1634	0,1640	-0,0006	-0,0038	0,1653	0,1627	0,1640	0,1656	0,0535
0,1634	0,1632	0,0002	0,0013	0,1634	0,1620	0,1628	0,1644	0,0463
0,1634	0,1625	0,0009	0,0054	0,1634	0,1602	0,1626	0,1638	0,0442
0,1647	0,1636	0,0012	0,0072	0,1634	0,1621	0,1635	0,1701	0,0439
0,1663	0,1662	0,0001	0,0006	0,1647	0,1654	0,1655	0,1660	0,0429
0,1647	0,1665	-0,0017	-0,0104	0,1663	0,1647	0,1653	0,1676	0,0280
0,1654	0,1653	0,0000	0,0002	0,1647	0,1638	0,1647	0,1669	0,0365
0,1632	0,1653	-0,0021	-0,0127	0,1654	0,1634	0,1644	0,1662	0,0307
0,1650	0,1640	0,0010	0,0063	0,1632	0,1622	0,1637	0,1648	0,0383
0,1677	0,1667	0,0010	0,0059	0,1650	0,1653	0,1660	0,1677	0,0348
0,1716	0,1681	0,0034	0,0200	0,1677	0,1664	0,1669	0,1696	0,0266
0,1688	0,1699	-0,0011	-0,0065	0,1716	0,1682	0,1683	0,1700	0,0271
0,1698	0,1701	-0,0003	-0,0016	0,1688	0,1686	0,1689	0,1713	0,0254
0,1704	0,1711	-0,0007	-0,0040	0,1698	0,1695	0,1699	0,1724	0,0242

0,1696	0,1708	-0,0012	-0,0073	0,1704	0,1691	0,1698	0,1721	0,0270
0,1693	0,1704	-0,0011	-0,0064	0,1696	0,1689	0,1689	0,1716	0,0223
0,1683	0,1692	-0,0010	-0,0057	0,1693	0,1674	0,1685	0,1713	0,0335
0,1697	0,1693	0,0004	0,0021	0,1683	0,1678	0,1679	0,1708	0,0236
0,1728	0,1722	0,0006	0,0036	0,1697	0,1711	0,1715	0,1722	0,0347
0,1722	0,1729	-0,0006	-0,0036	0,1728	0,1717	0,1714	0,1741	0,0316
0,1719	0,1725	-0,0006	-0,0035	0,1722	0,1708	0,1710	0,1740	0,0230
0,1710	0,1727	-0,0018	-0,0104	0,1719	0,1712	0,1716	0,1742	0,0279
0,1698	0,1714	-0,0015	-0,0090	0,1710	0,1697	0,1705	0,1734	0,0324
0,1691	0,1698	-0,0007	-0,0041	0,1698	0,1682	0,1685	0,1752	0,0275
0,1729	0,1712	0,0017	0,0096	0,1691	0,1698	0,1698	0,1717	0,0222
0,1716	0,1724	-0,0008	-0,0049	0,1729	0,1706	0,1716	0,1741	0,0336
0,1713	0,1720	-0,0008	-0,0044	0,1716	0,1702	0,1708	0,1737	0,0232
0,1706	0,1719	-0,0013	-0,0078	0,1713	0,1703	0,1705	0,1732	0,0226
0,1710	0,1707	0,0003	0,0016	0,1706	0,1685	0,1697	0,1719	0,0232
0,1702	0,1724	-0,0023	-0,0134	0,1710	0,1713	0,1716	0,1729	0,0355
0,1689	0,1702	-0,0013	-0,0077	0,1702	0,1689	0,1700	0,1716	0,0471
0,1704	0,1702	0,0003	0,0016	0,1689	0,1689	0,1693	0,1719	0,0326
0,1735	0,1743	-0,0008	-0,0046	0,1704	0,1742	0,1739	0,1733	0,0469
0,1723	0,1748	-0,0025	-0,0144	0,1735	0,1720	0,1757	0,1749	0,0413
0,1715	0,1721	-0,0006	-0,0033	0,1723	0,1707	0,1713	0,1736	0,0393
0,1729	0,1726	0,0003	0,0015	0,1715	0,1711	0,1714	0,1742	0,0244
0,1726	0,1733	-0,0006	-0,0036	0,1729	0,1711	0,1729	0,1749	0,0318
0,1738	0,1732	0,0006	0,0033	0,1726	0,1719	0,1729	0,1730	0,0437
0,1743	0,1739	0,0004	0,0022	0,1738	0,1734	0,1732	0,1753	0,0498
0,1738	0,1745	-0,0007	-0,0039	0,1743	0,1734	0,1733	0,1766	0,0354
0,1737	0,1743	-0,0005	-0,0029	0,1738	0,1733	0,1730	0,1781	0,0335
0,1730	0,1745	-0,0015	-0,0089	0,1737	0,1751	0,1729	0,1766	0,0474
0,1756	0,1752	0,0005	0,0027	0,1730	0,1748	0,1745	0,1759	0,0441
0,1732	0,1732	0,0000	0,0001	0,1756	0,1733	0,1752	0,1769	0,0992
0,1730	0,1742	-0,0013	-0,0073	0,1732	0,1711	0,1757	0,1743	0,0454
0,1692	0,1712	-0,0020	-0,0118	0,1730	0,1689	0,1719	0,1727	0,0526
0,1686	0,1692	-0,0006	-0,0033	0,1692	0,1677	0,1696	0,1730	0,0530
0,1687	0,1688	-0,0002	-0,0011	0,1686	0,1676	0,1685	0,1701	0,0457
0,1666	0,1673	-0,0007	-0,0044	0,1687	0,1654	0,1678	0,1692	0,0526
0,1659	0,1657	0,0001	0,0007	0,1666	0,1639	0,1662	0,1674	0,0524
0,1663	0,1662	0,0001	0,0005	0,1659	0,1648	0,1657	0,1679	0,0420
0,1675	0,1668	0,0007	0,0040	0,1663	0,1659	0,1663	0,1688	0,0452
0,1689	0,1689	0,0000	0,0001	0,1675	0,1684	0,1680	0,1683	0,0423
0,1656	0,1680	-0,0023	-0,0142	0,1689	0,1659	0,1677	0,1692	0,0399
0,1659	0,1669	-0,0011	-0,0065	0,1656	0,1655	0,1659	0,1681	0,0288
0,1629	0,1649	-0,0020	-0,0120	0,1659	0,1627	0,1649	0,1660	0,0437
0,1633	0,1626	0,0007	0,0041	0,1629	0,1611	0,1625	0,1647	0,0458
0,1619	0,1626	-0,0007	-0,0046	0,1633	0,1609	0,1622	0,1643	0,0402
0,1641	0,1631	0,0011	0,0064	0,1619	0,1623	0,1625	0,1639	0,0450
0,1646	0,1652	-0,0006	-0,0039	0,1641	0,1640	0,1648	0,1664	0,0411
0,1637	0,1651	-0,0014	-0,0082	0,1646	0,1639	0,1649	0,1668	0,0463
0,1657	0,1650	0,0007	0,0041	0,1637	0,1644	0,1643	0,1701	0,0428
0,1649	0,1648	0,0000	0,0001	0,1657	0,1639	0,1648	0,1665	0,0574
0,1606	0,1619	-0,0013	-0,0081	0,1649	0,1592	0,1652	0,1622	0,0877
0,1552	0,1576	-0,0024	-0,0156	0,1606	0,1556	0,1598	0,1584	0,0808
0,1574	0,1571	0,0002	0,0014	0,1552	0,1584	0,1563	0,1580	0,0624
0,1575	0,1564	0,0011	0,0072	0,1574	0,1551	0,1563	0,1586	0,0517
0,1557	0,1564	-0,0007	-0,0042	0,1575	0,1549	0,1563	0,1585	0,0524
0,1596	0,1571	0,0024	0,0151	0,1557	0,1568	0,1571	0,1584	0,0560
0,1612	0,1593	0,0019	0,0115	0,1596	0,1586	0,1601	0,1622	0,0673
0,1654	0,1635	0,0019	0,0115	0,1612	0,1641	0,1639	0,1640	0,0698
0,1655	0,1650	0,0006	0,0034	0,1654	0,1639	0,1650	0,1669	0,0554

0,1666	0,1659	0,0008	0,0047	0,1655	0,1647	0,1649	0,1669	0,0369
0,1650	0,1675	-0,0025	-0,0152	0,1666	0,1659	0,1674	0,1685	0,0421
0,1627	0,1657	-0,0030	-0,0185	0,1650	0,1656	0,1654	0,1679	0,0561
0,1614	0,1623	-0,0009	-0,0055	0,1627	0,1601	0,1628	0,1639	0,0483
0,1617	0,1619	-0,0002	-0,0012	0,1614	0,1602	0,1618	0,1639	0,0420
0,1520	0,1597	-0,0077	-0,0509	0,1617	0,1568	0,1613	0,1605	0,0592
0,1522	0,1505	0,0017	0,0114	0,1520	0,1551	0,1513	0,1522	0,1276
0,1502	0,1502	0,0000	0,0002	0,1522	0,1492	0,1513	0,1525	0,0737
0,1490	0,1496	-0,0006	-0,0039	0,1502	0,1482	0,1495	0,1515	0,0494
0,1498	0,1480	0,0018	0,0119	0,1490	0,1474	0,1480	0,1499	0,0621
0,1495	0,1491	0,0005	0,0032	0,1498	0,1486	0,1486	0,1506	0,0554
0,1493	0,1494	-0,0001	-0,0006	0,1495	0,1484	0,1486	0,1506	0,0456
0,1522	0,1501	0,0020	0,0134	0,1493	0,1498	0,1506	0,1518	0,0643
0,1539	0,1541	-0,0002	-0,0011	0,1522	0,1539	0,1540	0,1548	0,0561
0,1529	0,1521	0,0008	0,0055	0,1539	0,1522	0,1529	0,1546	0,0826
0,1514	0,1538	-0,0024	-0,0156	0,1529	0,1545	0,1518	0,1559	0,0436
0,1515	0,1524	-0,0009	-0,0060	0,1514	0,1521	0,1518	0,1523	0,0514
0,1537	0,1508	0,0029	0,0189	0,1515	0,1498	0,1517	0,1528	0,0674
0,1497	0,1492	0,0005	0,0032	0,1537	0,1479	0,1504	0,1507	0,0811
0,1481	0,1486	-0,0005	-0,0032	0,1497	0,1469	0,1487	0,1502	0,0515

#### Vypis predikce

y	y'	e	re	open	close	high	low	volume
0,1721	0,1685	0,0036	0,0208	0,1683	0,1667	0,1676	0,1694	0,0297
0,1660	0,1682	-0,0021	-0,0129	0,1721	0,1653	0,1675	0,1679	0,0364
0,1629	0,1651	-0,0022	-0,0137	0,1660	0,1628	0,1649	0,1656	0,0380
0,1607	0,1609	-0,0002	-0,0013	0,1629	0,1591	0,1618	0,1624	0,0616
0,1647	0,1641	0,0007	0,0042	0,1607	0,1633	0,1634	0,1634	0,0379
0,1656	0,1651	0,0005	0,0033	0,1647	0,1636	0,1637	0,1673	0,0270
0,1654	0,1664	-0,0010	-0,0060	0,1656	0,1648	0,1655	0,1661	0,0327
0,1705	0,1695	0,0010	0,0059	0,1654	0,1692	0,1688	0,1676	0,0398
0,1732	0,1713	0,0020	0,0113	0,1705	0,1704	0,1708	0,1729	0,0452
0,1653	0,1716	-0,0063	-0,0384	0,1732	0,1674	0,1746	0,1735	0,0620
0,1634	0,1640	-0,0006	-0,0038	0,1653	0,1627	0,1640	0,1656	0,0535
0,1634	0,1632	0,0002	0,0013	0,1634	0,1620	0,1628	0,1644	0,0463
0,1634	0,1625	0,0009	0,0054	0,1634	0,1602	0,1626	0,1638	0,0442
0,1647	0,1636	0,0012	0,0072	0,1634	0,1621	0,1635	0,1701	0,0439
0,1663	0,1662	0,0001	0,0006	0,1647	0,1654	0,1655	0,1660	0,0429
0,1647	0,1665	-0,0017	-0,0104	0,1663	0,1647	0,1653	0,1676	0,0280
0,1654	0,1653	0,0000	0,0002	0,1647	0,1638	0,1647	0,1669	0,0365
0,1632	0,1653	-0,0021	-0,0127	0,1654	0,1634	0,1644	0,1662	0,0307
0,1650	0,1640	0,0010	0,0063	0,1632	0,1622	0,1637	0,1648	0,0383
0,1677	0,1667	0,0010	0,0059	0,1650	0,1653	0,1660	0,1677	0,0348
0,1716	0,1681	0,0034	0,0200	0,1677	0,1664	0,1669	0,1696	0,0266
0,1688	0,1699	-0,0011	-0,0065	0,1716	0,1682	0,1683	0,1700	0,0271
0,1698	0,1701	-0,0003	-0,0016	0,1688	0,1686	0,1689	0,1713	0,0254
0,1704	0,1711	-0,0007	-0,0040	0,1698	0,1695	0,1699	0,1724	0,0242
0,1696	0,1708	-0,0012	-0,0073	0,1704	0,1691	0,1698	0,1721	0,0270
0,1693	0,1704	-0,0011	-0,0064	0,1696	0,1689	0,1689	0,1716	0,0223
0,1683	0,1692	-0,0010	-0,0057	0,1693	0,1674	0,1685	0,1713	0,0335
0,1697	0,1693	0,0004	0,0021	0,1683	0,1678	0,1679	0,1708	0,0236
0,1728	0,1722	0,0006	0,0036	0,1697	0,1711	0,1715	0,1722	0,0347
0,1722	0,1729	-0,0006	-0,0036	0,1728	0,1717	0,1714	0,1741	0,0316
0,1719	0,1725	-0,0006	-0,0035	0,1722	0,1708	0,1710	0,1740	0,0230
0,1710	0,1727	-0,0018	-0,0104	0,1719	0,1712	0,1716	0,1742	0,0279
0,1698	0,1714	-0,0015	-0,0090	0,1710	0,1697	0,1705	0,1734	0,0324
0,1691	0,1698	-0,0007	-0,0041	0,1698	0,1682	0,1685	0,1752	0,0275



0,1729	0,1712	0,0017	0,0096	0,1691	0,1698	0,1698	0,1717	0,0222
0,1716	0,1724	-0,0008	-0,0049	0,1729	0,1706	0,1716	0,1741	0,0336
0,1713	0,1720	-0,0008	-0,0044	0,1716	0,1702	0,1708	0,1737	0,0232
0,1706	0,1719	-0,0013	-0,0078	0,1713	0,1703	0,1705	0,1732	0,0226
0,1710	0,1707	0,0003	0,0016	0,1706	0,1685	0,1697	0,1719	0,0232
0,1702	0,1724	-0,0023	-0,0134	0,1710	0,1713	0,1716	0,1729	0,0355
0,1689	0,1702	-0,0013	-0,0077	0,1702	0,1689	0,1700	0,1716	0,0471
0,1704	0,1702	0,0003	0,0016	0,1689	0,1689	0,1693	0,1719	0,0326
0,1735	0,1743	-0,0008	-0,0046	0,1704	0,1742	0,1739	0,1733	0,0469
0,1723	0,1748	-0,0025	-0,0144	0,1735	0,1720	0,1757	0,1749	0,0413
0,1715	0,1721	-0,0006	-0,0033	0,1723	0,1707	0,1713	0,1736	0,0393
0,1729	0,1726	0,0003	0,0015	0,1715	0,1711	0,1714	0,1742	0,0244
0,1726	0,1733	-0,0006	-0,0036	0,1729	0,1711	0,1729	0,1749	0,0318
0,1738	0,1732	0,0006	0,0033	0,1726	0,1719	0,1729	0,1730	0,0437
0,1743	0,1739	0,0004	0,0022	0,1738	0,1734	0,1732	0,1753	0,0498
0,1738	0,1745	-0,0007	-0,0039	0,1743	0,1734	0,1733	0,1766	0,0354
0,1737	0,1743	-0,0005	-0,0029	0,1738	0,1733	0,1730	0,1781	0,0335
0,1730	0,1745	-0,0015	-0,0089	0,1737	0,1751	0,1729	0,1766	0,0474
0,1756	0,1752	0,0005	0,0027	0,1730	0,1748	0,1745	0,1759	0,0441
0,1732	0,1732	0,0000	0,0001	0,1756	0,1733	0,1752	0,1769	0,0992
0,1730	0,1742	-0,0013	-0,0073	0,1732	0,1711	0,1757	0,1743	0,0454
0,1692	0,1712	-0,0020	-0,0118	0,1730	0,1689	0,1719	0,1727	0,0526
0,1686	0,1692	-0,0006	-0,0033	0,1692	0,1677	0,1696	0,1730	0,0530
0,1687	0,1688	-0,0002	-0,0011	0,1686	0,1676	0,1685	0,1701	0,0457
0,1666	0,1673	-0,0007	-0,0044	0,1687	0,1654	0,1678	0,1692	0,0526
0,1659	0,1657	0,0001	0,0007	0,1666	0,1639	0,1662	0,1674	0,0524
0,1663	0,1662	0,0001	0,0005	0,1659	0,1648	0,1657	0,1679	0,0420
0,1675	0,1668	0,0007	0,0040	0,1663	0,1659	0,1663	0,1688	0,0452
0,1689	0,1689	0,0000	0,0001	0,1675	0,1684	0,1680	0,1683	0,0423
0,1656	0,1680	-0,0023	-0,0142	0,1689	0,1659	0,1677	0,1692	0,0399
0,1659	0,1669	-0,0011	-0,0065	0,1656	0,1655	0,1659	0,1681	0,0288
0,1629	0,1649	-0,0020	-0,0120	0,1659	0,1627	0,1649	0,1660	0,0437
0,1633	0,1626	0,0007	0,0041	0,1629	0,1611	0,1625	0,1647	0,0458
0,1619	0,1626	-0,0007	-0,0046	0,1633	0,1609	0,1622	0,1643	0,0402
0,1641	0,1631	0,0011	0,0064	0,1619	0,1623	0,1625	0,1639	0,0450
0,1646	0,1652	-0,0006	-0,0039	0,1641	0,1640	0,1648	0,1664	0,0411
0,1637	0,1651	-0,0014	-0,0082	0,1646	0,1639	0,1649	0,1668	0,0463
0,1657	0,1650	0,0007	0,0041	0,1637	0,1644	0,1643	0,1701	0,0428
0,1649	0,1648	0,0000	0,0001	0,1657	0,1639	0,1648	0,1665	0,0574
0,1606	0,1619	-0,0013	-0,0081	0,1649	0,1592	0,1652	0,1622	0,0877
0,1552	0,1576	-0,0024	-0,0156	0,1606	0,1556	0,1598	0,1584	0,0808
0,1574	0,1571	0,0002	0,0014	0,1552	0,1584	0,1563	0,1580	0,0624
0,1575	0,1564	0,0011	0,0072	0,1574	0,1551	0,1563	0,1586	0,0517
0,1557	0,1564	-0,0007	-0,0042	0,1575	0,1549	0,1563	0,1585	0,0524
0,1596	0,1571	0,0024	0,0151	0,1557	0,1568	0,1571	0,1584	0,0560
0,1612	0,1593	0,0019	0,0115	0,1596	0,1586	0,1601	0,1622	0,0673
0,1654	0,1635	0,0019	0,0115	0,1612	0,1641	0,1639	0,1640	0,0698
0,1655	0,1650	0,0006	0,0034	0,1654	0,1639	0,1650	0,1669	0,0554
0,1666	0,1659	0,0008	0,0047	0,1655	0,1647	0,1649	0,1669	0,0369
0,1650	0,1675	-0,0025	-0,0152	0,1666	0,1659	0,1674	0,1685	0,0421
0,1627	0,1657	-0,0030	-0,0185	0,1650	0,1656	0,1654	0,1679	0,0561
0,1614	0,1623	-0,0009	-0,0055	0,1627	0,1601	0,1628	0,1639	0,0483
0,1617	0,1619	-0,0002	-0,0012	0,1614	0,1602	0,1618	0,1639	0,0420
0,1520	0,1597	-0,0077	-0,0509	0,1617	0,1568	0,1613	0,1605	0,0592
0,1522	0,1505	0,0017	0,0114	0,1520	0,1551	0,1513	0,1522	0,1276
0,1502	0,1502	0,0000	0,0002	0,1522	0,1492	0,1513	0,1525	0,0737
0,1490	0,1496	-0,0006	-0,0039	0,1502	0,1482	0,1495	0,1515	0,0494
0,1498	0,1480	0,0018	0,0119	0,1490	0,1474	0,1480	0,1499	0,0621

0,1495	0,1491	0,0005	0,0032	0,1498	0,1486	0,1486	0,1506	0,0554
0,1493	0,1494	-0,0001	-0,0006	0,1495	0,1484	0,1486	0,1506	0,0456
0,1522	0,1501	0,0020	0,0134	0,1493	0,1498	0,1506	0,1518	0,0643
0,1539	0,1541	-0,0002	-0,0011	0,1522	0,1539	0,1540	0,1548	0,0561
0,1529	0,1521	0,0008	0,0055	0,1539	0,1522	0,1529	0,1546	0,0826
0,1514	0,1538	-0,0024	-0,0156	0,1529	0,1545	0,1518	0,1559	0,0436
0,1515	0,1524	-0,0009	-0,0060	0,1514	0,1521	0,1518	0,1523	0,0514
0,1537	0,1508	0,0029	0,0189	0,1515	0,1498	0,1517	0,1528	0,0674
0,1497	0,1492	0,0005	0,0032	0,1537	0,1479	0,1504	0,1507	0,0811
0,1481	0,1486	-0,0005	-0,0032	0,1497	0,1469	0,1487	0,1502	0,0515
0,1474	0,1479	-0,0004	-0,0030	0,1481	0,1465	0,1476	0,1499	0,0482
0,1498	0,1486	0,0012	0,0082	0,1474	0,1482	0,1493	0,1494	0,0662
0,1499	0,1502	-0,0003	-0,0020	0,1498	0,1486	0,1496	0,1514	0,0380
0,1484	0,1489	-0,0005	-0,0033	0,1499	0,1470	0,1487	0,1500	0,0447
0,1537	0,1502	0,0035	0,0226	0,1484	0,1497	0,1495	0,1509	0,0456
0,1539	0,1528	0,0010	0,0067	0,1537	0,1518	0,1524	0,1565	0,0507
0,1527	0,1533	-0,0006	-0,0038	0,1539	0,1514	0,1531	0,1582	0,0426
0,1515	0,1526	-0,0011	-0,0072	0,1527	0,1507	0,1526	0,1533	0,0437
0,1497	0,1509	-0,0011	-0,0076	0,1515	0,1490	0,1504	0,1519	0,0408
0,1523	0,1515	0,0007	0,0048	0,1497	0,1506	0,1509	0,1518	0,0408
0,1547	0,1537	0,0011	0,0070	0,1523	0,1532	0,1532	0,1544	0,0489
0,1529	0,1535	-0,0006	-0,0041	0,1547	0,1518	0,1537	0,1551	0,0519
0,1534	0,1541	-0,0007	-0,0044	0,1529	0,1538	0,1535	0,1545	0,0510
0,1520	0,1514	0,0006	0,0040	0,1534	0,1526	0,1524	0,1536	0,0957
0,1526	0,1538	-0,0012	-0,0078	0,1520	0,1534	0,1511	0,1536	0,0202
0,1503	0,1516	-0,0014	-0,0091	0,1526	0,1493	0,1508	0,1519	0,0307
0,1493	0,1532	-0,0039	-0,0262	0,1503	0,1498	0,1547	0,1512	0,0382
0,1486	0,1499	-0,0013	-0,0086	0,1493	0,1475	0,1491	0,1511	0,0274
0,1523	0,1493	0,0030	0,0194	0,1486	0,1484	0,1484	0,1500	0,0414
0,1544	0,1540	0,0004	0,0028	0,1523	0,1535	0,1537	0,1545	0,0513
0,1524	0,1533	-0,0009	-0,0061	0,1544	0,1514	0,1533	0,1545	0,0468
0,1496	0,1510	-0,0014	-0,0092	0,1524	0,1486	0,1516	0,1521	0,0509
0,1495	0,1499	-0,0004	-0,0025	0,1496	0,1483	0,1490	0,1516	0,0360
0,1493	0,1490	0,0003	0,0019	0,1495	0,1475	0,1485	0,1506	0,0433
0,1489	0,1491	-0,0002	-0,0011	0,1493	0,1484	0,1483	0,1511	0,0475
0,1480	0,1483	-0,0003	-0,0018	0,1489	0,1470	0,1496	0,1496	0,0692
0,1503	0,1495	0,0008	0,0054	0,1480	0,1491	0,1493	0,1495	0,0538
0,1499	0,1524	-0,0025	-0,0166	0,1503	0,1494	0,1541	0,1523	0,0468
0,1517	0,1518	-0,0001	-0,0004	0,1499	0,1512	0,1513	0,1527	0,0468
0,1520	0,1525	-0,0006	-0,0037	0,1517	0,1523	0,1510	0,1542	0,0398
0,1514	0,1524	-0,0009	-0,0063	0,1520	0,1514	0,1523	0,1570	0,0501
0,1526	0,1519	0,0007	0,0046	0,1514	0,1514	0,1513	0,1559	0,0506
0,1520	0,1520	0,0000	0,0001	0,1526	0,1509	0,1522	0,1536	0,0568
0,1548	0,1538	0,0010	0,0066	0,1520	0,1534	0,1532	0,1548	0,0488
0,1541	0,1550	-0,0009	-0,0058	0,1548	0,1536	0,1591	0,1563	0,0986
0,1570	0,1550	0,0020	0,0126	0,1541	0,1549	0,1565	0,1558	0,0793
0,1555	0,1564	-0,0009	-0,0059	0,1570	0,1551	0,1565	0,1580	0,0543
0,1570	0,1566	0,0004	0,0026	0,1555	0,1562	0,1559	0,1570	0,0477
0,1553	0,1566	-0,0013	-0,0082	0,1570	0,1548	0,1563	0,1580	0,0422
0,1546	0,1546	0,0000	-0,0001	0,1553	0,1526	0,1551	0,1559	0,0490
0,1558	0,1569	-0,0011	-0,0073	0,1546	0,1552	0,1580	0,1568	0,0539
0,1544	0,1553	-0,0009	-0,0060	0,1558	0,1525	0,1563	0,1560	0,0490
0,1530	0,1544	-0,0013	-0,0088	0,1544	0,1528	0,1533	0,1557	0,0343
0,1528	0,1533	-0,0005	-0,0030	0,1530	0,1519	0,1527	0,1551	0,0406
0,1528	0,1529	0,0000	-0,0003	0,1528	0,1516	0,1518	0,1542	0,0369
0,1545	0,1545	0,0000	0,0001	0,1528	0,1531	0,1536	0,1554	0,0323
0,1558	0,1560	-0,0002	-0,0012	0,1545	0,1548	0,1548	0,1565	0,0313