



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA PODNIKATELSKÁ  
ÚSTAV INFORMATIKY

FACULTY OF BUSINESS AND MANAGEMENT  
INSTITUTE OF INFORMATICS

# ANALÝZA A PREDIKCE VÝVOJE DEVIZOVÝCH TRHŮ POMOCÍ CHAOTICKÝCH ATRAKTORŮ A NEURONOVÝCH SÍTÍ

ANALYSIS AND PREDICTION OF FOREIGN EXCHANGE MARKETS BY CHAOTIC ATTRACTORS  
AND NEURAL NETWORKS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. JAN PEKÁREK

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JAN BUDÍK, Ph.D.

BRNO 2014

# ZADÁNÍ DIPLOMOVÉ PRÁCE

**Pekárek Jan, Bc.**

---

Informační management (6209T015)

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách, Studijním a zkušebním řádem VUT v Brně a Směrnicí děkana pro realizaci bakalářských a magisterských studijních programů zadává diplomovou práci s názvem:

**Analýza a predikce vývoje devizových trhů pomocí chaotických atraktorů a neuronových sítí**

v anglickém jazyce:

**Analysis and Prediction of Foreign Exchange Markets by Chaotic Attractors and Neural Networks**

Pokyny pro vypracování:

Úvod

Cíle práce, metody a postupy

Teoretická východiska práce

Analýza problému

Vlastní návrhy řešení

Závěr

Použitá literatura

Seznam odborné literatury:

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM, 2012. 713 s. ISBN 978-80-7204-798-7.

GOLDBERG, D. Genetic Algorithms in Search, Optimization, and Machine Learning. USA: Addison-Wesley, 1989. 412 s. ISBN 978-0201157673.

JANÍČEK, P. Systémové pojetí vybraných oborů pro techniky: Hledání souvislostí. 1. sv. Brno: CERM, 2007. 682 s. ISBN 978-80-7204-555-6.

PEITGEN, H. O. et al. Chaos and Fractals: New Frontier of Science. USA: Springer-Verlag, 1992. 984 s. ISBN 0-387-97903-4.

REJNUŠ, O. Finanční trhy. Ostrava: KEY Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.

ŠÍMA, J. a R. NERUDA. Teoretické otázky neuronových sítí. Praha: MATFYZPRESS, 1996. 390 s. ISBN 978-80-8586-318-5.

Vedoucí diplomové práce: Ing. Jan Budík, Ph.D.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2013/2014.

L.S.

---

doc. RNDr. Bedřich Půža, CSc.  
Ředitel ústavu

---

doc. Ing. et Ing. Stanislav Škapa, Ph.D.  
Děkan fakulty

V Brně, dne 11.05.2014

## **Abstrakt**

Práce se zabývá komplexní analýzou a predikcí devizových trhů. Využívá při tom pokročilých metod umělé inteligence, zejména neuronových sítí a teorie chaosu. Představuje netradiční přístupy a metody z každé z těchto oblastí, srovnává je a aplikuje na reálný problém. Jádrem práce je návrh a srovnání několika predikčních modelů založených na zcela odlišných principech a teoriích. Výsledkem je výběr nejvhodnějšího predikčního modelu, jenž nese označení NAR + H. Model je hodnocen dle více kritérií, jsou diskutovány jeho klady a zápory, vyčíslena přibližná očekávaná ziskovost a riziko. Veškeré analytické, predikční a dílčí algoritmy jsou implementovány ve vývojovém prostředí Matlabu a tvoří jednotnou knihovnu všech použitých funkcí a skriptů. Ta je zároveň druhým hlavním výstupem práce.

## **Abstract**

This thesis deals with a complex analysis and prediction of foreign exchange markets. It uses advanced artificial intelligence methods, namely neural networks and chaos theory. It introduces unconventional approaches and methods of each of these areas, compares them and uses on a real problem. The core of this thesis is a comparison of several prediction models based on completely different principles and underlying theories. The outcome is then a selection of the most appropriate prediction model called NAR + H. The model is evaluated according to several criteria, the pros and cons are discussed and approximate expected profitability and risk are calculated. All analytical, prediction and partial algorithms are implemented in Matlab development environment and form a unified library of all used functions and scripts. It also may be considered as a secondary main outcome of the thesis.

## **Klíčová slova**

devizové trhy, umělá inteligence, neuronové sítě, teorie chaosu, predikce, Hurstův exponent, Lyapunovův exponent, chaotický atraktor, embedding teorém, NAR, Matlab

## **Keywords**

foreign exchange markets, artificial intelligence, neural networks, chaos theory, prediction, Hurst exponent, Lyapunov exponent, chaotic attractor, embedding theorem, NAR, Matlab

## **Bibliografická citace**

PEKÁREK, J. *Analýza a predikce vývoje devizových trhů pomocí chaotických atraktorů a neuronových sítí*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2014. 99 s. Vedoucí diplomové práce Ing. Jan Budík, Ph.D.

## Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně, dne 12. května 2014

.....

Jan Pekárek

## **Poděkování**

Rád bych tímto poděkoval Ing. Janu Budíkovi, Ph.D. za vedení a praktické připomínky k práci. Chtěl bych též vyjádřit své díky prof. Ing. Petru Dostálovi, CSc. za cenné odborné rady a ochotu, nejen ve věcech týkajících se závěrečné práce. Stejně tak bych rád poděkoval Ing. Davidu Schüllerovi, Ph.D. za entuziasmus a náměty pro obor mého studia, stejně jako hodnotné rady ve studijních záležitostech. V neposlední řadě patří mé díky rodině, která mě po celou dobu studia neocenitelně podporovala.



# Obsah

<b>ÚVOD</b> .....	<b>11</b>
<b>1 CÍLE PRÁCE, METODY A POSTUPY</b> .....	<b>12</b>
1.1 Hlavní cíle.....	12
1.2 Vedlejší cíle .....	12
1.3 Použité metody a postupy.....	13
<b>2 TEORETICKÁ VÝCHODISKA PRÁCE</b> .....	<b>14</b>
2.1 Systém .....	14
2.2 Finanční systém a finanční trhy .....	14
2.4 Devizové trhy .....	16
2.4.1 Forex .....	16
2.5 Technická analýza .....	17
2.6 Teorie chaosu .....	17
2.6.1 Fraktál .....	18
2.6.2 Chaotický atraktor .....	18
2.6.3 R/S analýza a Hurstův exponent.....	19
2.6.4 Lyapunovův exponent.....	23
2.8 Neuronové sítě.....	25
2.8.1 Neuron .....	25
2.8.2 Typy sítí.....	25
2.8.3 Neuronové sítě a finanční trhy .....	28
<b>3 ANALÝZA PROBLÉMU</b> .....	<b>30</b>
3.1 Rozdílné přístupy k predikci trhů.....	30
3.1.1 Neuronové sítě .....	30
3.1.2 Teorie chaosu .....	31
3.2 Zhodnocení situace .....	33
<b>4 VLASTNÍ NÁVRHY ŘEŠENÍ</b> .....	<b>34</b>
4.1 Filozofie práce a výchozí předpoklady .....	34
4.1.1 Fraktální charakteristiky – R/S analýza.....	35
4.1.2 Chaotické charakteristiky – LLE .....	35
4.1.3 Univerzální nástroj – SDLE.....	37
4.1.4 Teorie fraktálních trhů a neuronové sítě.....	39

<b>4.3</b>	<b>Představení a kalibrace algoritmů .....</b>	<b>40</b>
4.3.1	Hurstův exponent .....	40
4.3.2	Lyapunovův exponent - Rosenstein .....	42
4.3.3	Lyapunovův exponent – Gao (SDLE) .....	50
4.3.4	Predikce využitím chaotického atraktoru a LLE – Zhang .....	50
<b>4.4</b>	<b>Stážení dat a jejich konverze .....</b>	<b>55</b>
4.4.1	Stážení dat .....	55
4.4.2	Vytvoření OHLC databáze .....	56
4.4.3	Výběr dat z vytvořené databáze .....	57
4.4.4	Použité měnové páry .....	57
<b>4.5</b>	<b>Hurstův exponent měnových párů eura v letech 2010 - 2013 .....</b>	<b>57</b>
4.5.1	Korelace Hurstova exponentu a zisku .....	59
4.5.2	Plovoucí Hurstův exponent .....	61
<b>4.6</b>	<b>Lyapunovův exponent trhů v letech 2010 – 2013 .....</b>	<b>63</b>
4.6.1	LLE podle Rosensteina .....	63
<b>4.7</b>	<b>Užití získaných dat .....</b>	<b>68</b>
4.7.1	Simulace obchodování – MACD + H .....	69
4.7.3	Simulace obchodování – predikční modely NAR(X) + H (obecné parametry) .....	73
4.7.4	Simulace obchodování – NAR + H .....	74
4.7.5	Simulace obchodování – NARX + H .....	77
4.7.6	Predikční model – chaotický atraktor a LLE .....	79
4.7.7	Shrnutí a výběr nejvhodnějšího modelu .....	83
<b>4.8</b>	<b>Přínosy a omezení .....</b>	<b>85</b>
<b>4.9</b>	<b>Náměty na budoucí výzkum .....</b>	<b>87</b>
	<b>ZÁVĚR .....</b>	<b>88</b>
	<b>POUŽITÁ LITERATURA .....</b>	<b>89</b>
	<b>SEZNAM POUŽITÝCH ZKRATEK .....</b>	<b>96</b>
	<b>SEZNAM OBRÁZKŮ .....</b>	<b>97</b>
	<b>SEZNAM TABULEK .....</b>	<b>98</b>
	<b>SEZNAM ROVNIC .....</b>	<b>98</b>
	<b>SEZNAM PŘÍLOH .....</b>	<b>99</b>
	<b>PŘÍLOHY .....</b>	<b>100</b>

## Úvod

Umělá inteligence v podobě, jakou má nejméně poslední čtyři dekády, řeší úlohy reálného světa způsobem, který by mnozí označili za neexaktní. Při bližším pohledu je však zřejmé, že tomu tak není. S trochou nadsázky by se dalo říct, že je tomu právě naopak. Typickým znakem a zároveň hlavním nedostatkem „exaktních“ metod je tvorba podstatně zjednodušeného modelu reálného problému, který má daný problém dostatečně přesně popisovat. To platí za předpokladu, že tvůrce modelu je dopředu obeznámen s hlavními komponentami problému, tedy s těmi, které mají pro zkoumaný úhel pohledu zásadní význam. V reálném světě se však běžně stává, a u komplexních problémů je to spíše pravidlem, že dopředu nejsou známy všechny důležité komponenty problému. Potom vytvořený model nereflektuje zkoumaný problém ani přibližně a na jeho základě vytvořené závěry mohou být zcela chybné. To lze ovšem jen stěží označit jako exaktní přístup. Tohoto úskalí se snaží vyvarovat umělá inteligence aplikací neortodoxních metod, mnohdy na první pohled působících naivně triviálně. Ale právě takový je princip odlišné filozofie umělé inteligence, tedy hledání řešení úlohy „inteligentním“ způsobem – využitím napodobení fenoménu lidské inteligence. Ta, byť stále nepochopena, dovoluje přicházet na způsoby, jak „dělat složité věci jednoduše“ a hledat elegantně triviální, avšak velice efektivní řešení. Zkoumá problém v širokém záběru, a i když úlohu formuluje někdy vágně, vždy se snaží zachovat celkovou komplexitu problému a pracovat s ní. Právě toto se dá chápat jako mnohem exaktnější postup z globálního hlediska.

# 1 Cíle práce, metody a postupy

Obecným cílem práce je představení alternativních analytických a predikčních postupů při zkoumání devizových trhů. Konkrétně si práce vytyčuje dva hlavní a několik vedlejších cílů.

## 1.1 Hlavní cíle

Primárním hlavním cílem práce je **návrh predikčního obchodního modelu**. Tím je myšlen výběr takového modelu mezi navrženými alternativami, který dosáhne nejlepších výsledků ve vícekritériálním porovnání. Práce představí několik heterogenních modelů založených na principech umělé inteligence a porovná je. Neoptimálnější model bude vybrán a otestován na simulaci reálného použití.

Sekundárním hlavním cílem je **tvorba otevřené knihovny funkcí vývojového prostředí Matlab**. Knihovnou je myšlen soubor veškerých použitých funkcí a skriptů, který umožní provedené analýzy a predikce opakovat, přičemž především analytické funkce budou mít obecné použití. Při dodržení stanovených teoretických principů, popsaných postupů a omezení je bude možné použít na libovolné problémy kvalitativně podobného typu.

## 1.2 Vedlejší cíle

Za vedlejší cíle lze považovat všechny dílčí závěry získané během plnění hlavních cílů, jejichž přidaná informační hodnota ke zkoumané problematice není nulová. Lze je kategorizovat do přibližně těchto oblastí:

- Úspěšnost validace použitých algoritmů.
- Načítací a konverzní datový můstek.
- Prediktabilita devizových trhů obecně.
- Detailní popis postupu stanovení největšího Lyapunovova exponentu z experimentálních dat.
- Stanovení chaotických a fraktálních charakteristik zkoumaných systémů.
- Úspěšnost predikčních modelů založených na odlišných principech.

### 1.3 Použité metody a postupy

V práci jsou použity obecné postupy **modelování** a **simulace**. Modely systémů jsou tvořeny s cílem systém analyzovat, případně predikovat jeho budoucí výstup. Simulace reálného obchodování je prováděna za účelem validace zkonstruovaných modelů. Základní **kalibrace** modelů je provedena na předešlých závěrech jiných autorů opakováním jejich postupů.

Mezi konkrétně použitými metodami lze zmínit **konstrukci fázového prostoru** systému ze skalární časové řady (a vizualizaci případného atraktoru), **analýzu korelace**, metodu **konstrukce dynamické neuronové sítě** nebo **R/S analýzu**. V programovací oblasti byly použity základní **principy psaní dokumentace** a **strukturovaného programování**.

Celá problematika je pojímána **systémově**, je kladen důraz na **opakovatelnost postupů** a **holistický pohled**.

## 2 Teoretická východiska práce

Úvodní kapitola obsahuje skromný výčet vědeckých oblastí a pojmů, ze kterých autor práce čerpá. Jedná se o zcela základní vhled do široké problematiky umělé inteligence a finančního systému. Důraz je kladen na oblasti relevantní pro jádro práce, tedy finanční (resp. devizové) trhy, neuronové sítě a teorii chaosu.

### 2.1 Systém

V současnosti široce používaný pojem, jehož prvotní definice je stále platná, i když pro neznalé často příliš abstraktní a špatně srozumitelná. Přesto je vhodné se jí držet, neboť nejlépe vystihuje obecnou povahu pojmu systém:

*„Systém je účelově definovaná množina prvků a vazeb mezi nimi, jež vykazují jako celek určité vlastnosti, resp. chování“ [1].*

### 2.2 Finanční systém a finanční trhy

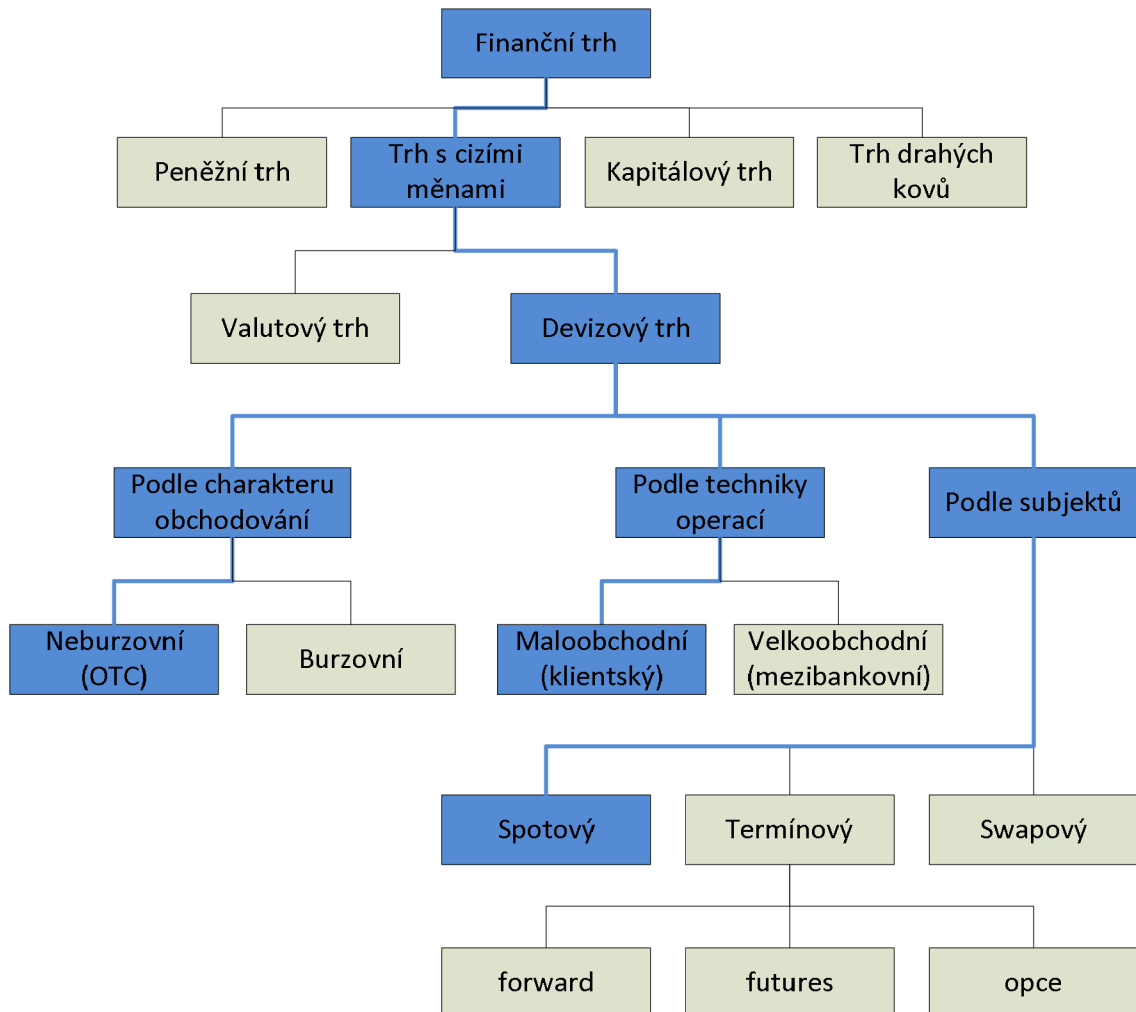
Finanční systém je podle Rose [2] definován jako soubor trhů, institucí, zákonů, regulací a technik, s jejichž pomocí jsou obchodovány obligace, akcie a jiné cenné papíry. Jedná se o jeden z nejdůležitějších vynálezů moderní společnosti. Jeho primárním úkolem je zajišťovat pohyb vzácného zápůjčního kapitálu od těch, kteří spoří k těm, kteří ho potřebují na investice a spotřebu.

Finanční systém moderní ekonomiky zajišťuje sedm základních funkcí. Jedná se o [2]:

- Depozitní funkce
- Funkce zabezpečení bohatství
- Funkce likvidity
- Kreditní funkce
- Platební funkce
- Funkce ochrany proti riziku
- Politická funkce

Finanční systém tyto své funkce zajišťuje prostřednictvím finančních trhů. Ty lze dělit v první řadě na trhy peněžní a trhy kapitálové. K nim lze přiřadit ještě specifitější trhy s cizími měnami a trhy drahých kovů [3].

Obrázek č. 1 znázorňuje základní dělení podle Rejnuše [3] s důrazem kladeným na větev podstatnou pro tuto práci, tedy Forex trh. Modře vyznačené bloky a spojnice tvoří strom popisující, pro které trhy budou navrhované nástroje a analýzy uvažovány.



Obrázek č. 1: Členění finančního trhu podle základních druhů finančních instrumentů: důraz kladen na oblast devizových trhů. Modře je vyznačena větev, do níž patří uvažované Forex obchodování v této práci.

(Zdroj: vlastní, podle [3, 4, 5])

## 2.4 Devizové trhy

Jedná se o trhy s bezhotovostními formami cizích měn (především peněz na účtech, směnek a šeků), na kterých dochází ke vzájemnému směňování různých konvertibilních měn. Nejvýznamnějšími subjekty na těchto trzích jsou dealeri centrálních bank, investičních fondů a brokeri (zprostředkovatelé devizových operací).

Devizové trhy lze dělit z mnoha různých hledisek. Hlavní dělení devizového trhu představuje obrázek č. 1.

### 2.4.1 Forex

V překladu trh cizích měn (FOREign EXchange market) je největším finančním trhem světa s celkovým denním obratem přes 5 bilionů amerických dolarů a jejich ekvivalentů. Na rozdíl od většiny finančních trhů je Forex decentralizovaný, rozprostřený díky ICT po celém světě. To umožňuje obchodovat 24 hodin denně podle toho, jak se posouvá denní doba napříč časovými pásmy. Lze jej dělit podle techniky operací (viz obrázek č. 1 a tabulka č. 1). Principu Forexu spočívá v současném průběhu dvou operací, totiž koupení jedné měny a prodání jiné. Proto se zpravidla hovoří o tzv. měnových párech (currency pairs) a jejich cenových kurzech. Takovým párem může být například EUR/USD, který je z hlediska množství obchodů zároveň nejpoužívanějším. Kurz je potom určován jako hodnota jedné měny v porovnání s druhou měnou. V případě EUR/USD kurz určuje, kolik amerických dolarů stojí jedno euro [6, 7].

Tabulka č. 1: Průměrný světový denní obrat Forexu v mld. \$ z pohledu měny a instrumentu, data z dubna 2013, pouze měny s celkovým obratem nad 100 mld.

Instrument	Celkem	Spoty	Forwardy	FX swapy	Měn. swapy	FX opce
<b>Celkem</b>	<b>5345</b>	<b>2046</b>	<b>680</b>	<b>2228</b>	<b>54</b>	<b>337</b>
USD	4652	1691	588	2030	50	293
EUR	1786	754	178	766	18	70
JPY	1231	612	123	332	11	153
GPB	631	227	69	301	5	29
AUD	462	196	50	183	6	27
CHF	275	84	27	149	1	14
CAD	244	93	36	101	2	12
MXN	135	57	14	58	1	6
CNY	120	34	28	40	1	17
NZD	105	39	11	50	2	3

(Zdroj: vlastní, podle [7])



## 2.5 Technická analýza

Technická analýza je metoda určená ke krátkodobé předpovědi budoucího vývoje ceny určitého investičního instrumentu v rámci finančního trhu. Jejím hlavním předpokladem je domněnka, že aktuální cena instrumentu obchodovaného na trhu odráží všechny relevantní informace. Další implicitní předpoklad počítá s alespoň nějakou (nenulovou) závislostí současné hodnoty na minulých hodnotách a tedy jisté možnosti předpověditelnosti budoucích hodnot z hodnot aktuálně známých. Jedná se tedy o metodu, jejíž použití je podmíněno neplatností teorie (informační) efektivnosti trhů [3, 8, 9].

Technická analýza obvykle používá grafické znázornění ceny měnící se v průběhu času. Na něj potom aplikuje nejrůznější ukazatele s cílem najít v datech nějaké vzory. Dalším přístupem je statistická analýza dat jako časových řad pomocí statistických metod. Mimoto existují ještě další přístupy k analýze dat představujících vývoj finančních trhů. Patří mezi ně například teorie chaosu nebo predikce pomocí neuronových sítí.

## 2.6 Teorie chaosu

Teorii chaosu poprvé uvažoval H. Poincaré, který v roce 1880 při studiu problému tří těles [10] zjistil, že některé oběžné dráhy mohou být neperiodické. V dalších letech byly G. D. Birkhoffem a A. N. Kolmogorovem provedeny studie v oblasti nelineárních diferenciálních rovnic, které spolu s Lorenzovým atraktorem E. Lorenze výrazně prohloubily poznatky v této disciplíně. Právě Lorenz na své práci ukázal, že není možné vytvořit model, který by umožňoval dlouhodobou předpověď počasí. V 70 a 80. letech minulého století se B. Mandelbrot svým dílem z oblasti fraktální geometrie zasloužil nejen o prohloubení teoretických poznatků v této oblasti, ale též o popularizaci této vědecké disciplíny [8].

Pojem teorie chaosu vznikl v technických vědách, kde popisuje chování nelineárních systémů. Ty se mohou zdát na první pohled řízeny ryze náhodně, obsahují však ve skutečnosti nějaký skrytý řád. Pokud by byl pro modelování takového systému použit lineární model, bude se jednat pouze o velmi hrubé zjednodušení, které bude fungovat pouze za ideálních podmínek a pouze omezenou dobu. Jelikož však jsou procesy

například v ekonomice téměř výhradně nelineární, nelze je takovými modely příliš úspěšně popisovat [8].

### 2.6.1 Fraktál

I když se koncept fraktálu poprvé objevil již v díle G. Leibnitze a byl bohatě rozpracován během přelomu 19. a 20. století mnoha světovými mysliteli, pojem „fraktál“ poprvé použil B. Mandelbrot v původním vydání své slavné knihy [11] až v roce 1975.

Do dnešního dne nebyla stanovena široce přijímaná definice fraktálů. Odbornou veřejností jsou chápány různě, avšak intuitivně se jedná stále o tytéž útvary. Jistou definici předložil v roce 2004 sám Mandelbrot [12], když tvrdil, že fraktál je matematická množina, jejíž fraktální dimenze obvykle překračuje dimenzi topologickou a může nebýt celočíselná.

Dnes víceméně přijímanou definici předložil Falconer [13], kde specifikuje fraktál jako množinu, jejíž Hausdorffova dimenze je ostře větší, než dimenze topologická.

Fraktály lze také vymezit výčtem společných charakteristik. Těmi jsou následující [14]:

- Soběpodobnost (soběpříbuznost) – fraktál je donekonečna dělitelný, přičemž všechny díly jsou stejné (podobné) jako původní celek.
- Velmi složitý tvar generovaný použitím jednoduchých pravidel.

### 2.6.2 Chaotický atraktor

Atraktor je pojem spojený obecně s určováním stability (především nelineárních) systémů. Od zrození jeho konceptu někdy v 60. letech 20. století bylo formulováno mnoho definic, převážně matematických [15, 16], které se snaží zahrnout všechny možné teoretické i reálně pozorované formy atraktorů. Pro aplikaci v této práci však bude postačující Dostálova [8] definice, totiž že atraktor je stavová veličina definující rovnováhu nelineárního systému, který nemusí být nehybný ve své rovnováze.

Atraktory lze rozlišovat na následující základní kategorie [8, 14]:

- Bodový – rovnováha představovaná bodem (např. reálné kyvadlo).

- Cyklický – rovnováha představována limitním cyklem (např. matematické kyvadlo).
- Chaotický – systém má dynamickou rovnováhu, je deterministický z hlediska určitosti budoucího stavu, ale dlouhodobě nepredikovatelný kvůli znalosti počátečních podmínek pouze s konečnou přesností (za některých počátečních podmínek se tak chová dvojitě kyvadlo).
- Podivný (Strange) – v literatuře jsou takto charakterizovány disipativní dynamické systémy, tedy systémy s určitou formou frikce, podivné atraktory totiž nemají ani v dlouhém období tendenci k ustálení do nějaké formy cyklu (teoreticky se tak může chovat turbulence v kapalinách [17]).

### 2.6.3 R/S analýza a Hurstův exponent

R/S analýzu, stejně jako Hurstův exponent poprvé představil v roce 1951 britský hydrolog H. E. Hurst [18]. Ten při studiu hladiny řeky Nilu uvažoval dlouhé časové období (řádově tisíce let) a porovnával změny hladiny řeky s meziročními změnami. Zjistil, že existuje podobnost v chování veličiny stavu hladin v dlouhém a krátkém období. Vyvinul proto analytickou metodu dnes známou jako R/S analýza (Rescaled Range Analysis). Analýza hodnotí časovou řadu hodnot podle proměnlivého „časového okénka“ – proměnlivého z hlediska měřítka hodnot.

V dnešní době se R/S analýza využívá téměř výhradně ke studiu cenových fluktuací na finančních trzích. Proto se také Hurstův exponent (Hurstova konstanta) časové řady často definuje jako indikátor nepravidelnosti ceny nějakého obchodovatelného instrumentu. Klíčovým úkolem takové aplikace je detekce intervalů časové řady, ve kterých se nepravidelnosti nacházejí [19].

$$X(t, \tau) = \sum_{i=1}^t (x_i - x(\tau)), t = 1, 2, \dots, \tau; \quad (1)$$

$$\bar{x}(\tau) = \frac{1}{\tau} \sum_{i=1}^{\tau} x_i,$$

$$S(\tau) = \sqrt{\frac{1}{\tau} \sum_{i=1}^{\tau} (x_i - \bar{x}(\tau))^2},$$

$$R(\tau) = \max_{1 \leq t \leq \tau} (X(t, \tau)) - \min_{1 \leq t \leq \tau} (X(t, \tau)),$$

$$H(\tau) = \frac{\log(R(\tau))}{\log(S(\tau))},$$

kde  $x = \{x_1, x_2, \dots, x_{\tau}\}$  je posloupnost čas. řady a  $\tau$  je počet hodnot

Zdroj: [8]

B. Mandelbrot později navíc ukázal [20], že existuje přímý vztah mezi zobecněným Hurstovým exponentem a fraktální dimenzí. Tento vztah vystihuje rovnice č. 1 a grafická interpretace časových řad s proměnlivou hodnotou Hurstova exponentu na obrázku č. 2.

$$D = 2 - H \quad (2)$$

Zdroj: [8, 20]


Rovnice v podstatě říká, že čím nižší je hodnota Hurstova exponentu, tím více přechází časová řada z první do druhé rozměrové dimenze. Jak plyne z fraktální geometrie, fraktální útvary s neceločíselnou dimenzí přecházejí do vyšší dimenze jejím postupným „vyplňováním“ útvarem nižší dimenze. V případě časové řady (a rovnice č. 2) se jedná o vyplňování plochy (2D objektu) křivkou (1D objektem). Při porovnání dvou časových řad na obrázku č. 2 lze jasně vidět rozdíl ve vyplnění plochy křivkou pro různé hodnoty H. Fraktální dimenze objektu na obrázku č. 2-nahoře s  $H = 0,1$  je  $D = 1,9$ . To znamená, že objekt je téměř dvojrozměrný (plocha). Na druhé straně fraktální dimenze objektu na obrázku 2-dole s  $H = 0,9$  je  $D = 1,1$ . Objekt je tedy téměř jednorozměrný (přímka).

## Náhodná procházka, fraktální Brownův pohyb a Hurstův exponent

Ekonomie zná již řadu let teorii náhodné procházky, která tvrdí, že (nejen) finanční trhy fungují zcela náhodně, že všechny existující informace jsou zahrnuty v tržní ceně. Přesněji řečeno, budoucí hodnota kurzu, ceny, veličiny  $P_{(t+1)}$  je zcela nezávislá na současné hodnotě  $P_{(t)}$ . Toto je však teoretický model, spíše limitní případ reálného stavu. Pro tento limitní případ existuje dobře popsáný fyzikální ekvivalent, tzv. Brownův pohyb [8].

Koncem 60. let minulého století byl navržen model tzv. fraktálního Brownova pohybu (FBM). Je definován jako plovoucí průměr derivace obyčejného Brownova pohybu  $B(t)$ , kde jsou jeho minulé přírůstky váženy výrazem  $(t-s)^{H-0.5}$ . Autoři věří, že tento model bude lépe vystihovat skutečnou podstatu jevů objevujících se v široké škále vědeckých oborů [21].

Aby bylo možné provádět analýzy skutečných časových řad, je třeba mít tyto analýzy kalibrovány na dobře popsaná teoretická data. Taková lze vygenerovat prostřednictvím matematického modelu, který je zkonstruován z teoretických poznatků. Proto byla pro generování dat použita Matlab funkce `wfbm()` simulující FBM podle zadaného parametru Hurstova exponentu. Funkce je implementací Abryho článku [22] a umožňuje generovat náhodné časové řady vykazující podobné vlastnosti jako reálná data. Na této uměle vytvořené časové řadě pak lze optimalizovat analýzy, neboť jsou známy jejich žádané výstupy.



Obrázek č. 2: Časové řady s různou hodnotou Hurstova exponentu  
(Zdroj: vlastní, na základě Matlab funkce wfbm(), [22])

### Hurstův exponent a finanční časové řady

Řada autorů uvažovala použít R/S analýzu, resp. Hurstův exponent k analýze finančních trhů, jejichž časové řady vykazují obecně fraktální charakter. V současné době se autoři navíc zabývají otázkou, zda je taková analýza vůbec přínosná a za jakých podmínek jsou výsledky použitelné [23]. Mitra zjišťuje, že v určitých časových intervalech se dá hodnota Hurstova exponentu ( $H$ ) využít spolu s jinými ukazateli technické analýzy, k zpřesnění predikce pohybu kurzu. To prakticky znamená, že pokud bude hodnota  $H$  například výrazně vyšší, než průměrná, lze očekávat, že aktuální směr trendu se nezmění. To je užitečné v situaci, kdy není síla trendu přímo evidentní.

#### 2.6.4 Lyapunovův exponent

Přesněji se jedná o Lyapunovovy charakteristické exponenty (zkráceně LE), tedy několik čísel popisujících dynamické systémy z hlediska jejich chaotičnosti. Počet exponentů je roven počtu dimenzí jejich fázového prostoru. Tím se rozumí, zjednodušeně řečeno, rozměr prostoru, v němž je uvažován pohyb stavů systému v průběhu času.

Protože chaotické systémy jsou charakteristické jistou mírou neurčitosti, používá se právě LE k určení její velikosti. Obecně poskytují LE informaci o míře divergence nekonečně blízkých trajektorií. Toto tvrzení je pouze geometrickým vyjádřením stejného, totiž že LE měří průměrný růst nekonečně malých odchylek spojených se stanovením původního výchozího bodu v průběhu procesu iterace [14]. Jelikož neurčitost budoucích stavů systému roste konstantně pouze v těch nejjednodušších chaotických systémech, používá LE tzv. efektivní exponenciální růst, nebo také průměrný exponenciální růst, což je průměr růstu chyby za počet iterací limitně se blížící nekonečnu. Tento průměr je potom hledaným LE pro danou dimenzi. Exponenty se zpravidla řadí sestupně od největšího, který má nejdůležitější význam z hlediska predikce a bývá označován jako LLE (Largest Lyapunov Exponent). Často se také stává, že pokud se hovoří o Lyapunovově exponentu v jednotném čísle, má se zpravidla na mysli právě LLE. Exponenty mají jednotku bit za iteraci a v případě kladných hodnot tak určují rychlost ztráty informace (nebo ekvivalentně růst nejistoty) a tím i schopnosti predikce budoucích stavů. Prediktabilitu je poté možné vypočítat jako převrácenou hodnotu LLE. Její jednotka je iterace. Jako jednotka LLE se uvádí ztráta informace v systému v bit/s [8, 24, 25].

Také znaménko LLE je podstatné pro určení chaotičnosti systému. Pokud je největší exponent kladný, znamená to, že se jedná o chaotický systém. Jestliže je největší LLE nulový, jedná se o limitně cyklický systém, když je záporný, potom je takový systém deterministický v tradičním smyslu [8, 24, 25].

$$\lambda(x_0) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n \ln |f'(x_{k-1})| \quad (3)$$

(Zdroj: [14])

$$\ln c = \frac{1}{n} \ln \left| \frac{E_n}{E_0} \right| \quad (4)$$

$$c \cong e^\lambda$$

(Zdroj: [14])

### Výpočet Lyapunovova exponentu

Problém stanovení LE systému lze rozdělit z hlediska obtížnosti do dvou úrovní. Rozdíl je v míře explicitní znalosti systému. V případě, že je znám matematický popis systému (existují pohybové rovnice, které systém přesně nebo alespoň dostatečně přibližně charakterizují), lze použít přímých metod pro výpočet všech LE včetně největšího. Ve svém slavném článku však Wolf [26] ukazuje omezené možnosti použití těchto metod [27, 28] a navrhuje vlastní přístup pro stanovení LE pro neznámý systém. Využívá k tomu konstrukci fázového prostoru z časové řady. Ta se skládá z naměřených výstupních hodnot systému a Lyapunovovo spektrum (všechny LE) jejího atraktoru je stejné jako spektrum odpovídajícího systému popsaného pohybovými rovnicemi. To dokazuje na známých systémech tvořících chaotický atraktor. Výsledkem je potom metoda umožňující vypočítat LE systému, jehož matematický popis není znám.

V literatuře se objevují mnohé přístupy založené na Wolfově článku, v této práci se blíže rozebírá Rosensteinova metoda [29] vycházející mimo jiné z praktického Satova přístupu [30] při stanovování vstupních parametrů. Rosenstein si je vědom obtíží spojených s výpočtem celého Lyapunovova spektra, navrhuje tedy algoritmus pro výpočet pouze LLE, který je informačně nejobsažnější (ze všech exponentů řekne o zkoumaném systému nejvíce). Zároveň odstraňuje nedokonalosti předchozích metod, které dle něj trpěly vždy alespoň jedním z uvedených nedostatků [29]:

- Nespolehlivost výsledku pro krátkou časovou řadu.
- Výpočetní náročnost (důležité především v době publikování).
- Relativně obtížná implementace.



## 2.8 Neuronové sítě

Původní snahou průkopníků v oblasti neuronových sítí bylo vytvořit nástroj, kterým by dokázali napodobit chování lidského mozku. Inspirovali se proto nervovou soustavou člověka a pokusili se algoritmizovat základní jednotku této nervové soustavy – neuron. V první polovině 20. století se objevily první jednoduché modely neuronů. V roce 1957 se F. Rosenblattovi podařilo vytvořit funkční perceptron – jak nazval první nejjednodušší neuronovou síť. Ta byla tvořena pouze jedním neuronem a její použití bylo značně omezené. Z hlediska architektury neuronu však byla totožná s pozdějšími sítěmi [8].

### 2.8.1 Neuron

Umělý neuron (artificial neuron) je matematickým modelem, který zjednodušeně napodobuje architekturu biologického neuronu.

V popisu architektury neuronu (resp. perceptronu) se objevují tyto základní pojmy [8]:

- Vstupy (inputs) a výstupy (outputs).
- Váhy (weights).
- Uměle nastavená hodnota prvního vstupu (tzv. bias).
- Transformační, někdy také přenosová, či aktivační, funkce (transfer function).
- Prahová hodnota transformační funkce (threshold).

### 2.8.2 Typy sítí

Neuronové sítě mají širokou škálu oblastí využití. Jejich stavba je zpravidla uzpůsobena danému účelu, pro který je síť vytvořena. Neexistuje univerzální architektura sítě, která by dokázala efektivně řešit všechny druhy a komplexnosti problémů. Síť lze dělit z různých hledisek [8, 31, 32]:

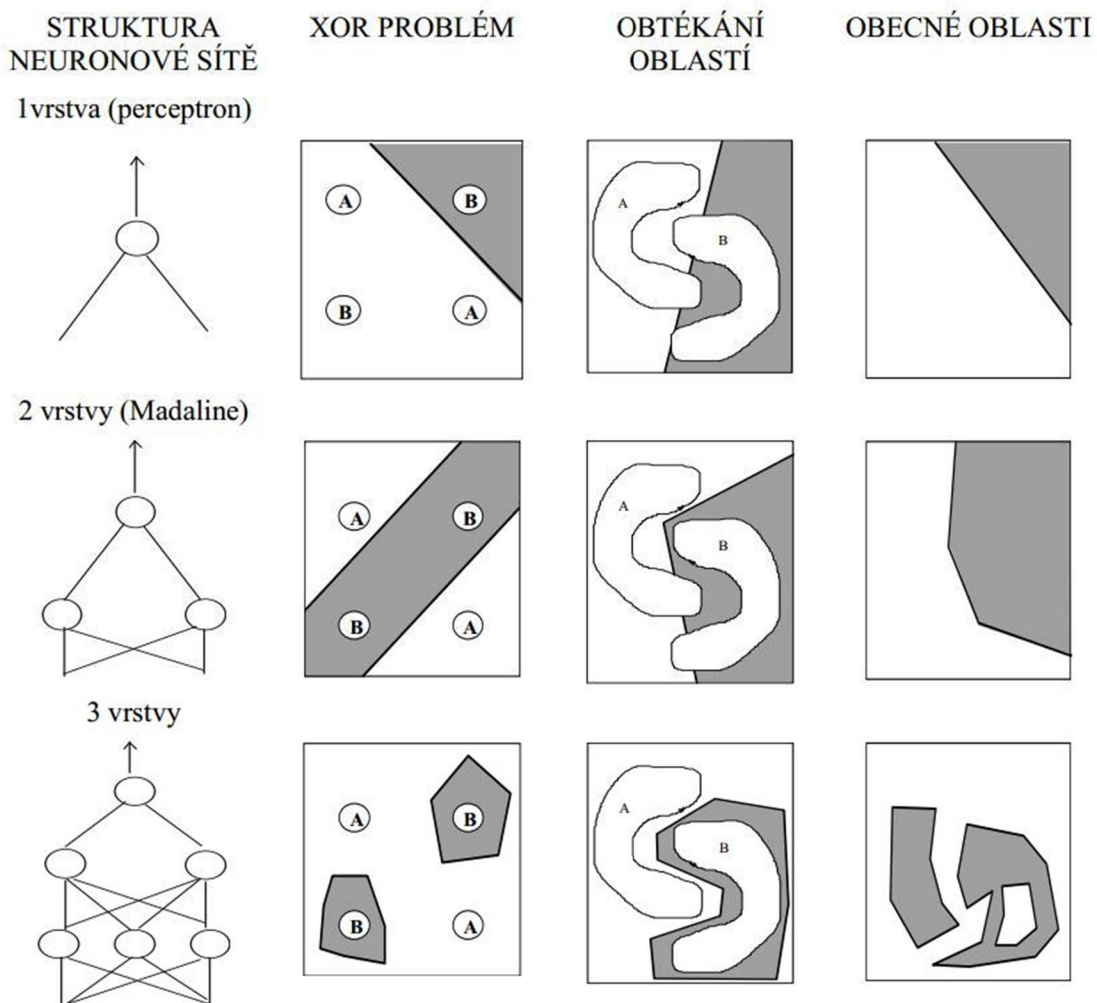
#### Podle použití

- Napodobení algoritmu (neuronová síť může simulovat algoritmus či operátor, aniž by byl znám jeho matematický předpis).

- Shlukování (též clusterování, hledá v množině prvků skupiny prvků s podobnými vlastnostmi, které se odlišují od ostatních skupin).
- Predikce (na základě historických hodnot dokáže přibližně simulovat budoucí vývoj).
- Klasifikace (zařadí prvky množiny do správné kategorie).
- Rozpoznávání vzorů (naučí se a následně rozpozná vzory v datech, např. obrazové vzory) aj.

### **Podle architektury**

- Počet vrstev (1, 2, 3 a více).
- Cykličnost vazeb (acyklické – přímé, cyklické).
- Organizovanost (pevné, samoorganizační).



Obrázek č. 3: Možnosti dělení stavového prostoru podle složitosti architektury NN  
(Zdroj: [32])

### Podle složitosti zapojení

- Jedna síť, jedna vrstva (lineárně separabilní problémy).
- Jedna síť, více vrstev (standardní klasifikační problémy, simulace algoritmů, základní predikce směru nebo hodnoty) – nejrozšířenější.
- Více sítí, provázané sítě sítí (problémy vyžadující zpracování více logicky nehomogenních vstupů, složité rozhodování závislé na více zdrojích dat).
- Komplexní, průběžně se optimalizující rozhodovací systémy založené na propojení mnoha NN různé funkce se vstupními (např. fuzzy) filtry pracující nad rozměrnou znalostní databází (komplexní analytická rozhodnutí založená na zkušenostech).

## Podle dynamiky dat

- Statické (logika dat je statická, v čase neproměnlivá) – například simulace matematických funkcí, algoritmů.
- Dynamické (logika dat je dynamická, vstupy sítě jsou časové řady) – například predikce kurzu měnového páru EUR/USD, predikce hladiny řeky v daném místě.

### 2.8.3 Neuronové sítě a finanční trhy

Použití neuronových sítí na predikci vývoje finančních trhů je diskutováno mnoha autory. Zajímavé práce jsou ty, kde autoři srovnávají predikční schopnosti jednotlivých typů sítí [33, 34]. Nelze předem jasně určit, která architektura sítě bude pro daný účel neoptimálnější, lze stanovit pouze parametry, které by ideální architektura měla splňovat. Velmi záleží také na úsudku osoby architekta, který nemusí být vždy racionální. Některým sítím může dávat přednost z důvodu jejich historické užitečnosti pro jiné účely, může volit sítě snáze pochopitelné či jednodušší na implementaci.

Obecně je při návrhu sítě nutné vyřešit otázku dynamiky dat s návazností na dynamiku sítě. Sítě pro predikce časových řad jsou zpravidla dynamické (NAR(X)), mohou však být použity i staticko-dynamické hybridy (FTDNN). Dále je nutné určit počet predikovaných kroků a logickou kvalitu predikce. Tím se myslí, zda cílem sítě bude správně predikovat absolutní hodnotu výstupu nebo pouze znaménko změny (směr výstupu vůči přechozí hodnotě). V neposlední řadě je nutné uvažovat variabilitu problému, možnosti generalizace sítě a výpočetní složitost predikčního systému.

V zásadě existují dvě možnosti, jak mohou být tyto charakteristiky sítě určeny. První z nich je slepá heuristická optimalizace parametrů na základě několika účelových funkcí a optimalizačních kritérií. Tato metoda je vhodná v případech, kdy existuje přibližná představa o typu sítě, typu architektury a dynamice úlohy, přičemž heuristický proces výběru optimální sady parametrů je vybrán např. pomocí genetického algoritmu zvyhodňujícího nejúspěšnější jedince.

Druhým způsobem stanovení parametrů je syntetická konstruktivistická metoda, kdy architekt sítě musí na základě dílčích charakteristik či předpokladů o datech a problému

zkonstruovat umělou neuronovou síť podle podstaty úlohy. Nemusí nicméně konstruovat síť zcela ze základních bloků, lze vybrat určitý existující typ sítě a ten následně parametrizovat, avšak záměrně, podle teoretických předpokladů o řešené úloze.

Obě metody mají klady a zápory. Metoda heuristické optimalizace není uživatelsky příliš pracná a je relativně přesná. Dá se ovšem použít pouze na problémy s úzce definovanými parametry. Lze totiž například měnit počet neuronů vrstev, počet vstupních dat a časové zpoždění. Z hlediska výpočetní složitosti však musí být pevně stanovena topologie sítě, počet vrstev a zpětná vazba.

Druhá metoda je obecnější, dokáže operovat nad širokou škálou problémů a správně navržená síť může být podstatně výkonnější. Na druhé straně její konstrukce je podstatně uživatelsky náročnější, vyžaduje rozsáhlé teoretické znalosti zkoumané problematiky, metod návrhů sítě a poznatky ze studií jiných autorů na téma srovnání jednotlivých architektur pro různé úlohy.

Obě dvě metody jdou pochopitelně v různém poměru kombinovat, přičemž lze využít výhod obou. V této práci bude využita právě kombinace uvedených metod, neboť návrh predikční sítě pro aplikaci na finančních, potažmo devizových trzích, je poměrně oblíbené téma a lze proto nalézt dostatek relevantních studií. Heuristická optimalizace bude upravovat parametry uživatelem navržené sítě, aby výsledný predikční model dovedl správně předpovídat vývoj finančních (či devizových) trhů. Kvůli složitosti úlohy bude pevně stanovena právě architektura sítě. V opačném případě by sice bylo možné provádět rozsáhlou fundamentální optimalizaci, podobně jako například Pacelli [35], který v rámci nalezení optimální konfigurace skládá samostatné perceptrony do různých typů zapojení. Takto by šlo konfigurovat topologii sítě na té nejnižší úrovni, čímž by bylo zajištěno její maximální variability. Výrazně by se tím však zvýšila obtížnost celého optimalizačního procesu.

### **3 Analýza problému**

Při snaze vytvořit model pro predikci vývoje finančních trhů se autoři neomezují pouze na standardní metody technické nebo fundamentální analýzy. Často jsou z různých důvodů použity nástroje umělé inteligence. Těmi mohou být například genetické algoritmy kvůli výpočetní složitosti optimalizace obchodních systémů. Optimalizace obchodního modelu je nutná prakticky vždy, bez ohledu na typ modelu, jeho filozofii nebo implementaci.

Pro samotnou predikci mohou být použity opět nástroje umělé inteligence, konkrétně neuronové sítě, které dovedou problematiku předpovědi vývoje trhu uchopit z různých pohledů (v závislosti na typu neuronové sítě).

Poslední, ne však nevýznamnou, oblastí umělé inteligence, jejíž filozofie bývá použita ve snaze analyzovat chování finančních trhů, je teorie chaosu. Z té ostatně vychází celá teorie o předpověditelnosti finančních trhů obecně. Teorie fraktálních trhů, která se staví proti teorii náhodné procházky, vychází právě z teorie chaosu, resp. fraktální geometrie. Je proto vhodné tento fakt brát jako vysoce podstatný a uvažovat jej při tvorbě modelu.

#### **3.1 Rozdílné přístupy k predikci trhů**

Během posledních několika let se řada autorů pokusila navrhnout přístupy k tvorbě modelů zachycujících možný vývoj finančních trhů (postačí se omezit na práce z oblasti devizových nebo kapitálových trhů). Pro účely následující analýzy je vhodné rozdělit je do dvou skupin. První skupinou budou práce zabývající se použitím neuronových sítí různých typů, konfigurací, metod optimalizace a implementace do výsledného obchodního systému. Druhou skupinou budou práce analyzující predikci trhů obecně, převážně na základě poznatků teorie chaosu. Jejich autoři si jsou vědomi nutnosti optimalizace modelu, avšak primárně se snaží dokázat pravdivost filozofie predikce, nehledě na konkrétní aplikaci nebo implementaci.

##### **3.1.1 Neuronové sítě**

Srovnání architektur neuronových sítí určených pro predikci finančních trhů provádí ve svém článku například Ghosh [36], který porovnává acyklickou vícevrstevnou

architekturu (Feedforward Multilayer NN) s cyklickou, dynamickou (Recurrent Time Delay NN). Obě sítě testuje na akciovém trhu NASDAQ, na bližší nespecifikovaných instrumentech. Ve výsledném porovnání se z hlediska výkonnosti i přesnosti jeví lépe druhá, rekurentní síť.

K použití cyklické sítě se přiklání i Brnka [37], jehož nelineární autoregresní síť (NAR) vykazuje velmi dobré výsledky na akcích firem jako Apple, Google a Microsoft. Autor však neprovádí porovnání výkonnosti jednotlivých architektur, spíše navrhuje celkový model pro co nejuspěšnější predikci. Zavádí optimalizaci architektury podle několika účelových funkcí pomocí genetických algoritmů. Přidává zároveň rozhodovací pravidla o aktuální vhodnosti vstupu na trh. Výsledkem je konstatování, že při optimálním nastavení pomocných pravidel a parametrů NAR sítě lze dosahovat slušné ziskovosti relativně stabilně.

Mírně odlišné výsledky uvádí Vrba [33]. Jako nejvhodnější architektura se v jeho práci jeví statická acyklická síť (Focused Time-Delay NN), která dynamiku simuluje pouze vstupním zpožděním. Dalo by se říci, že se jedná o hybrid mezi FFMLNN a RTDNN. Tu testuje oproti nelineární autoregresní síti s exogenními parametry (NARX). Jedná se o rozšířenou formu NAR, avšak, jak avizuje Brnka [37], ta je vhodnější pouze v případě použití relevantních exogenních proměnných. V opačném případě může být výkonnostně ještě horší, než NAR. Vrba rozděluje predikční modely na předpovědi absolutní hodnoty ceny a předpovědi směru pohybu kurzu. Sítě jsou porovnávány při aplikaci na devizový trh, konkrétně Forex a optimalizace parametrů sítě je prováděna pomocí genetických algoritmů. Za těchto předpokladů se mnohem úspěšněji jeví FTDNN, která vykazuje výjimečně dobré výsledky v predikci směru pohybu kurzu.

### **3.1.2 Teorie chaosu**

Aktuálně se autoři zabývají především otázkou, zda je vůbec možné finanční trhy predikovat pomocí nástrojů teorie chaosu, či spíše zda jsou analýzy založené na teorii chaosu pro predikci finančních trhů nějak přínosné. Takové otázky si pokládá Mitra ve svém článku [23], kde provádí výpočty Hurstova exponentu ( $H$ ) pro desetileté časové řady několika akciových indexů. Jelikož pro takto dlouhé časové úseky je hodnota  $H$  rovna téměř přesně 0,50, vyvozuje z toho platnost teorie efektivních trhů. Nicméně

analyzuje problematiku dále a dochází ke zjištění, že pro kratší časové úseky se  $H$  různí od hodnoty 0,50 a právě tyto odchylky od dlouhodobé střední hodnoty je třeba zachycovat a interpretovat. Protože samotný Hurstův exponent nelze použít k predikci, doporučuje autor použití nástrojů technické analýzy. Již při aplikaci běžného plovoucího průměru dokazuje užitečnost Hurstova exponentu při předpovědi směru pohybu kurzu. Dokazuje to na korelaci ziskovosti strategie a hodnoty  $H$  v průběhu obchodní seance. Mitra tedy potvrzuje domněnku o užitečnosti Hurstova exponentu při predikci pohybu finančních trhů.

Jiní autoři [38] se pouštějí do přímého srovnání teorie efektivních trhů (EMH) a teorie fraktálních trhů (FMH). Jako matematicko-statisticky podloženější a empiricky ověřenější se zde jeví FMH pro své rozlišování krátkého a dlouhého období. Navíc existuje jistá podobnost systému trhů s některými chaotickými systémy, konkrétně se jedná o nepředpověditelnost výstupu v dlouhém období, ale dobrou předpověditelnost v období krátkém. Tomu odpovídá model podivného (strange) atraktoru, který je jedním ze základních konceptů teorie chaosu. Autor zároveň upozorňuje, že nejobtížnějším úkolem vycházejícím z potřeb predikce je stanovení proměnných, které na systém (trh) působí, jejich počet a vzájemný vztah. Konkrétně tímto problémem se autor nijak zvlášť nezabývá, je však z hlediska pochopení podstaty trhu klíčový.

Zkoumat chaotický systém z hlediska principu jeho fungování lze pomocí Lyapunovových charakteristických exponentů. S jejich stanovováním pro různé systémy byl historicky vždy problém. Wolf ve svém článku [26] navrhuje postup, jímž lze stanovit tyto exponenty pro neznámý systém. Další autoři [29, 30] Wolfův postup zdokonalují a umožňují efektivně stanovovat Lyapunovovo spektrum, případně LLE z experimentálních dat pro obecný systém. Systémy uvažované v těchto pracích jsou však pouze jednodušší teoretické modely chaotických systémů, často s existujícím matematickým popisem.

Celou problematiku stanovení Lyapunovova spektra, resp. LLE zkoumá řada autorů. Nejde pouze o správné pochopení a aplikaci celého algoritmu, klíčovým prvkem celé analýzy je korektní stanovení vstupních parametrů algoritmu. Jsou jimi především vnořená dimenze systému a časové zpoždění, jejichž správné určení je v odborné literatuře často diskutováno [39, 40]. Obtížnost tohoto úkolu zpravidla vychází



z omezených informací o zkoumaném systému a jeho složitosti, ale také z problematiky neurčitosti chaotických systémů.

O aplikaci na reálné problémy z oblasti trhů se pokouší například Bask [41], který stanovuje dimenze a exponenty pro některé měnové páry obsahující švédskou korunu. Nedochozí bohužel k příliš prokazatelným závěrům, především z důvodu nedostatku dat.

Aktuálně se o testování použitelnosti na reálných časových řadách zajímají Park s Whangem [42]. Při snaze stanovit Lyapunovovy exponenty pro různé ekonomické časové řady (např. burzovní indexy – SP500, Dow-Jones nebo kurzy měnových párů – USD/JPY, USD/CAD) docházejí k závěru, že neexistuje jednoznačně prokazatelný důkaz o chaotickém chování těchto trhů. Oproti jiným autorů dokonce zastávají názor, že pro zachycení chování kapitálových a devizových trhů jsou vhodnější nechaotické stacionární modely či modely náhodné procházky, tedy modely, které upřednostňují EMH před FMH. Nicméně i zde si jsou autoři vědomi subjektivity svého empirického důkazu a doporučují problematiku k dalšímu zkoumání.

### **3.2 Zhodnocení situace**

Kromě uvedených prací, ve kterých autoři navrhují pro pochopení komplexní nelinearity finančních trhů použít výhradně nástroje umělé inteligence, existují i další, kteří pojmají problematiku standardnějším způsobem pouze s využitím prvků umělé inteligence [43]. Celá problematika je však stále značně neprobádaná a situaci navíc komplikuje značná multioborovost zkoumaného tématu. Jak uvádí například Yalamovová [44], v oblasti matematiky a fyziky existuje pokročilý teoretický výzkum, který místy bere v úvahu i ekonomické otázky. Praktický empirický výzkum nelineární dynamiky finančních trhů však zaostává, neboť postrádá vazby na výzkumné metody. Autorka konstatuje, že je často obtížné používat analogický přístup v několika oborech současně z důvodu rozdílné terminologie. Bohužel tím dochází ke značné ztrátě potenciálního synergického efektu, který by se spoluprací dostavil.

## **4 Vlastní návrhy řešení**

Samotné jádro práce začíná sumarizací závěrů výše zmíněných autorů a jejich vzájemným porovnáním. Mezi existujícími přístupy a metodami jsou záměrně vybírány ty, které jsou dle autora potenciálně použitelné na finančních trzích. Jsou představeny předpoklady a teorie, které umožňují aplikaci na těchto trzích, následuje výčet konkrétních algoritmů a je provedena jejich kalibrace v souladu s existujícím teoretickým pozadím. Kapitola pokračuje aplikací algoritmů na reálných datech Forexu, přičemž je popsán proces extrakce a zpracování těchto dat. Navržené algoritmy lze dělit do dvou skupin. Na jedné straně jsou vytvořeny a použity algoritmy analytické, které umožňují zjistit bližší charakteristiky zkoumaných dat (zkoumaných systémů), na druhé straně je použito algoritmů predikčních, ty využívají získaných informací a umožňují předpovídat budoucí hodnoty zkoumaných časových řad (výstupy zkoumaných systémů). Předpovězené budoucí hodnoty jsou použity ke spekulacím účelům, přičemž jsou srovnávány různé predikční modely. Následuje výběr nejúspěšnějšího modelu dle více kritérií a je vyčíslena jeho ziskovost při simulaci reálného obchodování. Jsou shrnuty zjištěné závěry, představeny přínosy celého návrhu vlastních řešení a zmíněna jeho omezení. Závěrem jsou nastíněna možná témata budoucího výzkumu.

### **4.1 Filozofie práce a výchozí předpoklady**

Práce se snaží záměrně kontrastovat s častými tématy posledních let, jimiž jsou mimo jiné návrhy obchodních systémů pro aplikaci na finančních trzích využívající klasických metod technické analýzy. Stejně tak je cílenou snahou autora vyhnout se prostému optimalizování tradičních predikčních modelů (implementovaných např. jako neuronové sítě). Není tomu tak proto, že by autor tyto přístupy považoval za nedostatečně potentní či zastaralé, jeho záměrem je uchopení problematiky z odlišného úhlu pohledu s cílem přispět k variabilitě názorů.

Práce analyzuje různé měnové páry eura a zkoumá, v jakých předem zjistitelných aspektech se od sebe liší. Porovnává mezi sebou jak jednotlivé páry ve stejných intervalech, tak různé časové intervaly jednoho páru mezi sebou. To provádí z hlediska domnělé chaotičnosti časových řad a používá k tomu nástrojů jako je R/S analýza,

konstrukce  $n$ -rozměrných fázových prostorů či empirické chaotické charakteristiky (LLE).

#### **4.1.1 Fraktální charakteristiky – R/S analýza**

Stejně jako Mitra [23] dokazuje ve své práci na kapitálových trzích, předpokládá autor i zde užitečnost R/S analýzy, konkrétně determinace Hurstova exponentu při rozlišení různých srovnatelných časových řad devizového trhu. Ačkoliv lze dlouhodobě tyto trhy považovat za efektivní, v kratších časových intervalech lze i tady detekovat odchylky způsobující neefektivitu. Právě tyto odchylky, někdy nazývané jako „setrvačnost trhu“ či „panika“, jsou předmětem hledání, neboť teoreticky umožňují, při správné klasifikaci, využívat tohoto stavu neefektivity k vlastnímu prospěchu.

Za efektivní trh se z hlediska R/S analýzy považuje takový trh, který hodnotu Hurstova exponentu má právě 0,50. Jedná se o situaci, kdy trh pružně reaguje na veškeré nákupní signály a aktuální kurz není nijak deformovaný. Jak je v literatuře obecně známo, a v práci bude dále potvrzeno, z dlouhodobého hlediska je devizový trh efektivní. Nicméně otázkou zůstává, zda detekovaná odchylka neefektivity má alespoň částečně determinující charakter na ziskovost obchodu v daný moment. Jinými slovy, zda lze zaznamenanou anomálii trhu skutečně využít jako konkurenční výhodu při obchodní seanci.

#### **4.1.2 Chaotické charakteristiky – LLE**

Velký finanční trh, kterým Forex bezpochyby je, byl vždy správně považován za velice komplexní systém, jehož chování je jen velice obtížně predikovatelné. Na problematiku existují dva protichůdné extrémní názory. Liší se pohledem na lidskou schopnost predikce trhů. Jeden názor tvrdí, že jakákoliv predikce je nemožná, že pohyb trhu je zcela náhodný. Na druhé straně existuje názor, že chování trhu je determinováno relevantními informacemi. Pokud by nějaká entita tyto informace měla, byl by pro ni trh zcela deterministický.

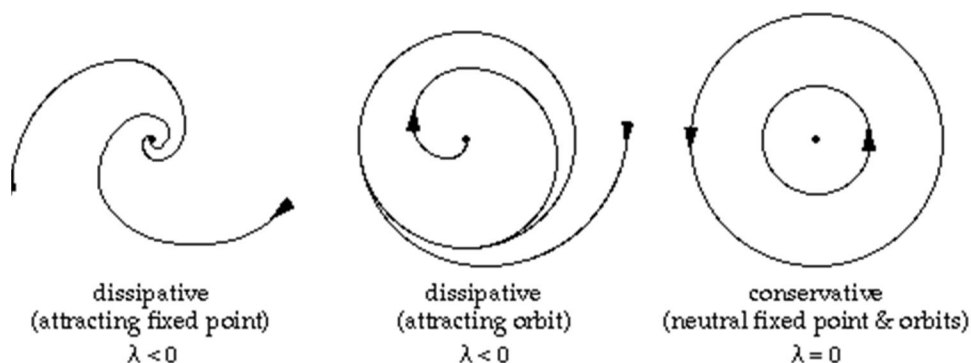
Problematikou determinismu systémů se zabývá i teorie chaosu. Jak velmi trefně popisuje Peitgen [14], situace je poněkud složitější. Jako velice výstižný příklad lze uvést dnes již notoricky známou příhodu prof. Lorenze, meteorologa z MIT, který v 60.

letech 20. století při studiu chování zemské atmosféry používal k simulacím tehdejší výpočetní techniku. Při zpracování a ukládání vstupních dat v počítači se vyskytla nesrovnalost, kdy měření provedená původně s přesností na 6 desetinných míst byla zpracovávána jako čísla s přesností pouze na 3 desetinná místa. Profesor Lorenz si toho však všiml a výpočet zopakoval, tentokrát již s původní, vyšší přesností. Zdánlivým paradoxem bylo, že předpověď počasí, zprvu pro oba výpočty naprosto stejná, se po několika dnech zásadně rozcházela. Z toho byl později vyvozen závěr, že kvůli kumulativnímu působení sebemenší chyby je predikce určitých druhů systémů dlouhodobě nemožná.

Charakteristikou, která tento jev zachycuje, jsou Lyapunovovy charakteristické exponenty. Celé spektrum exponentů popisuje chování systému ve fázovém prostoru, důležitý z hlediska možnosti predikce je především první, největší exponent (LLE). Ten lze dobře chápat při interpretaci jako Lyapunovovo číslo  $e^{\lambda_1}$  [14]. Toto číslo vystihuje, kolikrát se chyba měření zvětší v každé iteraci. Např. pro Lorenzův systém (tvořící chaotický atraktor) je  $\lambda_1$  rovno 1,50, proto  $e^{\lambda_1} \cong 4,48$ . To znamená, že v Lorenzově systému se i ta nejmenší chyba způsobená zaokrouhlením datového typu v každé iteraci zvětší asi 4,5 krát. To prakticky znamená, že i chyba v měření mající původně hodnotu jen  $10^{-10}$  se asi po 15 iteracích zvětší tak, že zcela zkreslí původní výstup.

I když hodnota LLE = 1,50 je relativně vysoká, exponenciální nárůst chyby způsobuje, že se chyba rychle projevuje i u systémů s nižšími hodnotami LLE. Z uvedeného matematického vztahu platí, že libovolná kladná hodnota LLE zvětšuje chybu a ta se v konečném počtu iterací stane natolik velkou, že zásadně ovlivní skutečný výstup. To však platí pouze v systémech, které mají kladnou hodnotu LLE, neboť v případě, že je LLE rovno nule, chyba se nezvětšuje, ale zůstává stále stejná. Nulovou hodnotu LLE typicky vykazují systémy s cyklickým atraktorem, který je stabilní a jeho velikost se v žádném směru nemění. Posledním druhem jsou systémy mající záporný LLE, což by znamenalo, že původní chyba postupně mizí. Tato interpretace však nedává příliš smysl, systémy se záporným LLE někteří autoři [45] označují jako disipativní (pojem používaný primárně pro fyzikální systémy), což zjednodušeně znamená stabilní a neměnné. Jakékoliv běžné výkyvy systému (neplatí pro extrémní výkyvy) jsou postupně

eliminovány a systém se vrací do rovnováhy, která může být realizována cyklem či statickým bodem.



Obrázek č. 4: Některé orbity atraktorů s různými LE  
(Zdroj: [45])

Z uvedeného plyne, že správná klasifikace trhu pomocí LLE by značně pomohla k pochopení jeho podstaty a očekávaného budoucího chování. I kdyby se však trh podařilo takto klasifikovat, je značně naivní se domnívat, že se bude striktně chovat podle domnělých pravidel. Jednoduchý konstruktivistický model vytvořený jediným člověkem má pramalou šanci modelovat trh v celé jeho komplexitě. Je však možné brát tento model jako základní kámen nové obchodní strategie a zkoumat, jak ob stojí mezi ostatními.

#### 4.1.3 Univerzální nástroj – SDLE

V poslední době se nicméně ukazuje, že správně stanovit LLE pro složitý systém typu devizový trh je i při dodržení zmíněných omezení stále značným problémem. Jak výstižně poukazuje Gao v úvodu své práce [46], jedna věc je schopnost stanovit hodnotu LLE a druhá věc je dát si ji do souvislosti. Mnoha autory bylo na základě korektně vytvořených metod vypočteno, že LLE některých finančních trhů (mimo jiné i devizových) je záporný. To by ovšem znamenalo, s přihlédnutím ke Kolmogorov-Sinaiově entropii, že takový trh funguje podle jednoduché, pravidelné, striktně deterministické dynamiky. To je však omyl i intuitivně, neboť komplexitu trhu, kde interagují v jednom okamžiku miliony nezávislých subjektů podle vlastních, dynamicky se měnících pravidel, nelze takto triviálně popsat [46, 47].

Problém spočívá v rozdílu mezi předmětem zkoumání Lyapunovových charakteristických exponentů a R/S analýzy. Ten je zcela zásadní, i když na první pohled nedostatečně zřejmý. LE na jedné straně zkoumají chaotické charakteristiky časové řady, tedy determinismus a růst vstupní chyby v iteracích systému. Oproti tomu R/S analýza zkoumá fraktální podstatu časové řady, kdy odhaduje její dlouhodobé paměťové schopnosti. To se projevuje v rozdílné volatilitě a persistenci existujícího trendu. Zde se však předměty zkoumání analýz LE a R/S střetávají, neboť právě nízkourovňový chaos může persistenci trendu narušovat, resp. zamlžovat.

Vskutku se ukazuje [46, 47], že detekovanou zápornou hodnotu LLE má na svědomí metoda jejího určování, která nedovede rozlišit mezi různými druhy specifického a velice komplexního chování způsobujícího nefunkčnost standardních přístupů k odhadu LLE. Autoři tohoto zjištění přicházejí s alternativním návrhem algoritmu, který kombinuje prvky R/S analýzy a divergence trajektorií – principu, na kterém jsou založeny standardní metody určení LLE.

Jejich analýza již detekuje LLE více realisticky, neboť ho stanovuje u některých finančních časových řad jako nízký, avšak kladný. Zároveň je schopna rozlišit 3 základní druhy chování v závislosti na měřítku pozorování [46, 47]:

- Čistě chaotické chování v malém měřítku a tzv. „noisy chaos“ (nízkourovňový chaos) [48].
- Čistě chaotické chování ve velkém měřítku a také tehdy, když je toto chování zkresleno na nižších úrovních „noisy chaosem“.
- Náhodné procesy se specifickou hodnotou Hurstova exponentu.

„Noisy chaos“ hypotézu lze shrnout tvrzením: „*Vysoká volatilita ničí persistenci trendu.*“ [48]. To podstatně ovlivňuje hodnotu H, neboť v určitém časovém úseku, který by jinak přispěl k vysoké hodnotě H z důvodu persistentního trendu, je tento trend zamlžen vysokou volatilitou kurzu, což R/S analýza interpretuje jako pravý opak – antipersistentní chování. To znamená, že oblasti, které vykazují velkou míru „noisy chaosu“ mají pravděpodobně odlišnou hodnotu H, než kterou určí standardní R/S analýza. To lze prakticky uchopit tak, že časové úseky, které mají H přibližně rovno

0,50, ale zároveň obsahují „noisy chaos“, mohou být chápány jako stejně nedokonale efektivní, jako ty úseky, jejichž  $H$  se od 0,50 různí.

#### 4.1.4 Teorie fraktálních trhů a neuronové sítě

Teorie fraktálních trhů (FMH) předpokládá, že budoucí cena (měnový kurz)  $p$  v čase  $t_{n+1}$  je závislý na současné hodnotě ceny v čase  $t_n$  a neznámém počtu předchozích hodnot v čase  $t_{n-1}$ ,  $t_{n-2}$ ,  $t_{n-3}$  atd. To znamená, že existuje neznámý, pravděpodobně nelineární funkční vztah mezi historickým vývojem trhu a jeho budoucím vývojem. I když momentálně neexistuje způsob, jak tento funkční vztah vyjádřit analyticky, lze teoreticky použít mechanismy, například neuronové sítě, které neznámou funkci dovedou simulovat a v některých aplikacích nahradit. Jedním z typů takové sítě simulující libovolnou matematickou funkci s konečným počtem nespojitostí je standardní statická Feedforward Multilayer NN. Staticčnost zde znamená způsob zacházení se vstupními daty. Jednotlivé hodnoty vstupů síť chápe podobně jako matematická funkce  $y = f(x)$ , kde  $x$  je vstup sítě,  $y$  je výstup a funkční vztah  $f(x)$  se síť snaží naučit. Takový postup se však nedá aplikovat na časové řady. Ty vyžadují dynamiku.

Dynamiku lze do sítě dostat zavedením prvku zpoždění o určitý počet (např.  $k$ ) kroků. Tím je dosaženo stavu, že síť při zpracování  $i$ -tého vstupu bere v potaz  $k-1$  předchozích vstupů. Výstup sítě  $y_i$  je pak dán vztahem  $y_i = f(x_i, x_{i-1}, x_{i-2}, \dots, x_{i-k+1})$ . Prvek zpoždění je zaveden v typech sítí nazývaných jako Focused Time-Delay NN, které ho však obsahují pouze ve vstupní vrstvě. Zbytek sítě je architektonicky totožný s klasickou statickou sítí.

Dynamika však nemusí být do sítě přidávána uměle, existují dynamické sítě přímo návrhem, jedná se o nelineární autoregresní sítě (NAR, NARX) obsahující ve vstupní vrstvě časové zpoždění a ve výstupní vrstvě jediný neuron. To umožňuje při odstranění zpoždění predikci jednoho kroku do budoucnosti. Tato informace je však ve většině případů na finančních trzích zcela dostačující.

### 4.3 Představení a kalibrace algoritmů

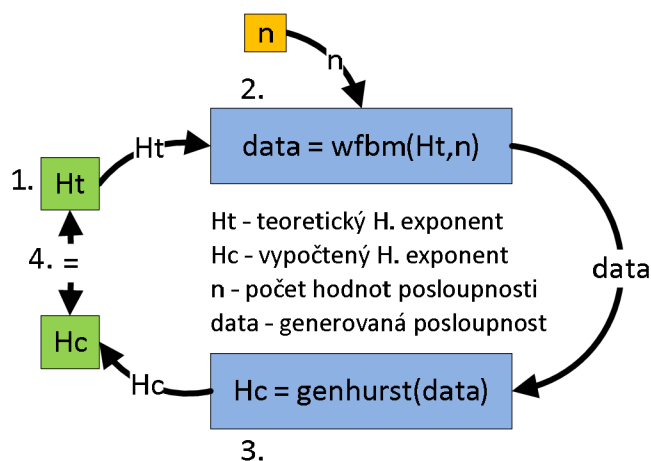
Používané analytické nástroje jsou zpravidla komplikované funkce či modely založené na teoreticky odvozených a literaturou popsaných algoritmech. Pro ověření správnosti implementace těchto funkcí a optimálního nastavení vstupních parametrů je třeba jejich skutečné výstupy srovnat s teoretickými předpoklady a experimentálními výstupy jiných autorů. Princip ověření korektnosti takové funkce (modelu) vychází z předpokladu, že jsou známy požadované výstupy pro konkrétní vstupy. Ty lze získat z výzkumu jiných autorů, kteří se zabývali daným tématem.

#### 4.3.1 Hurstův exponent

Pro výpočet Hurstova exponentu časové řady byla zvolena funkce `genhurst()` dostupná na stránkách MathWorks [49]. Je založena na pracích Di Mattea [50] a umožňuje stanovit zobecněný Hurstův exponent časové řady z experimentálních (empiricky zjištěných) dat. Ještě předtím, než může být funkce prohlášena za korektní, je třeba ověřit její správnost. To lze provést tak, že bude použita na časovou řadu, jejíž  $H$  je předem znám. Takovou řadu lze syntetizovat zabudovanou Matlab funkcí `wfbm()`. Ta je založena na Abryho metodě syntézy fraktálního Brownova pohybu [22] a generuje posloupnost náhodných čísel se zadanou hodnotou  $H$ . Samotnou funkci `wfbm()` není třeba ověřovat, neboť je standardní součástí produktu Matlab a je dobře zdokumentována.

Na obrázku č. 5 je schematicky zachycen algoritmus ověřování funkce `genhurst()`. Nejprve je stanovena hodnota  $H_t$ , pro kterou se vygeneruje posloupnost. Tato posloupnost se nechá analyzovat funkcí `genhurst()` a ta stanoví  $H_c$  dané posloupnosti. V závěru se porovnají hodnoty  $H_t$  a  $H_c$ . Pokud se výrazně neliší, funkce je prohlášena za korektní.

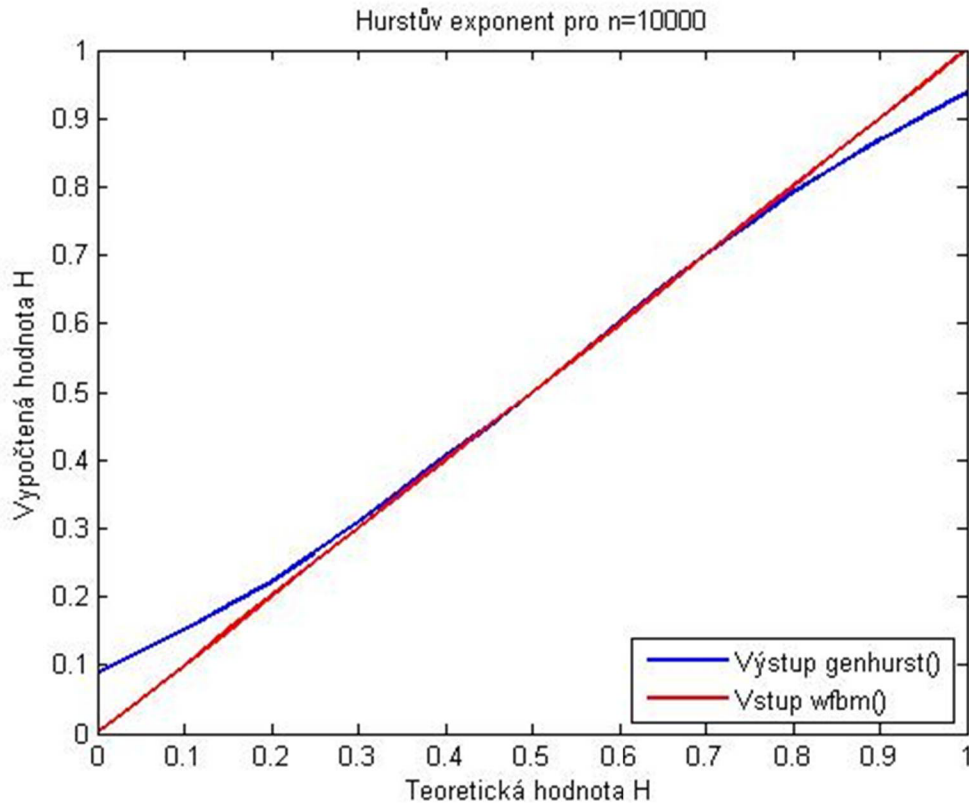




Obrázek č. 5: Ověření korektnosti funkce genhurst().  
(Zdroj: vlastní)

### Rozhodnutí o použitelnosti funkce

Z obrázku č. 6 je jasné vidět, že pro  $H$  z intervalu  $\langle 0,3;0,8 \rangle$  je hodnota stanovená funkcí `genhurst()` téměř nerozlišitelná od skutečné hodnoty  $H$ . Funkce proto může být prohlášena za způsobilou neboť pro další analýzy je rozsah tohoto intervalu zcela postačující. Významné odchylky, které by spadaly mimo tento interval, se nebudou vůbec vyskytovat nebo přesnost jejich hodnoty nebude již podstatná. Tak výrazná odchylka v systému, jehož hodnota  $H$  se dlouhodobě pohybuje mimo daný interval, by znamenala extrémní stav systému. Ten by se projevil zcela evidentními znaky.



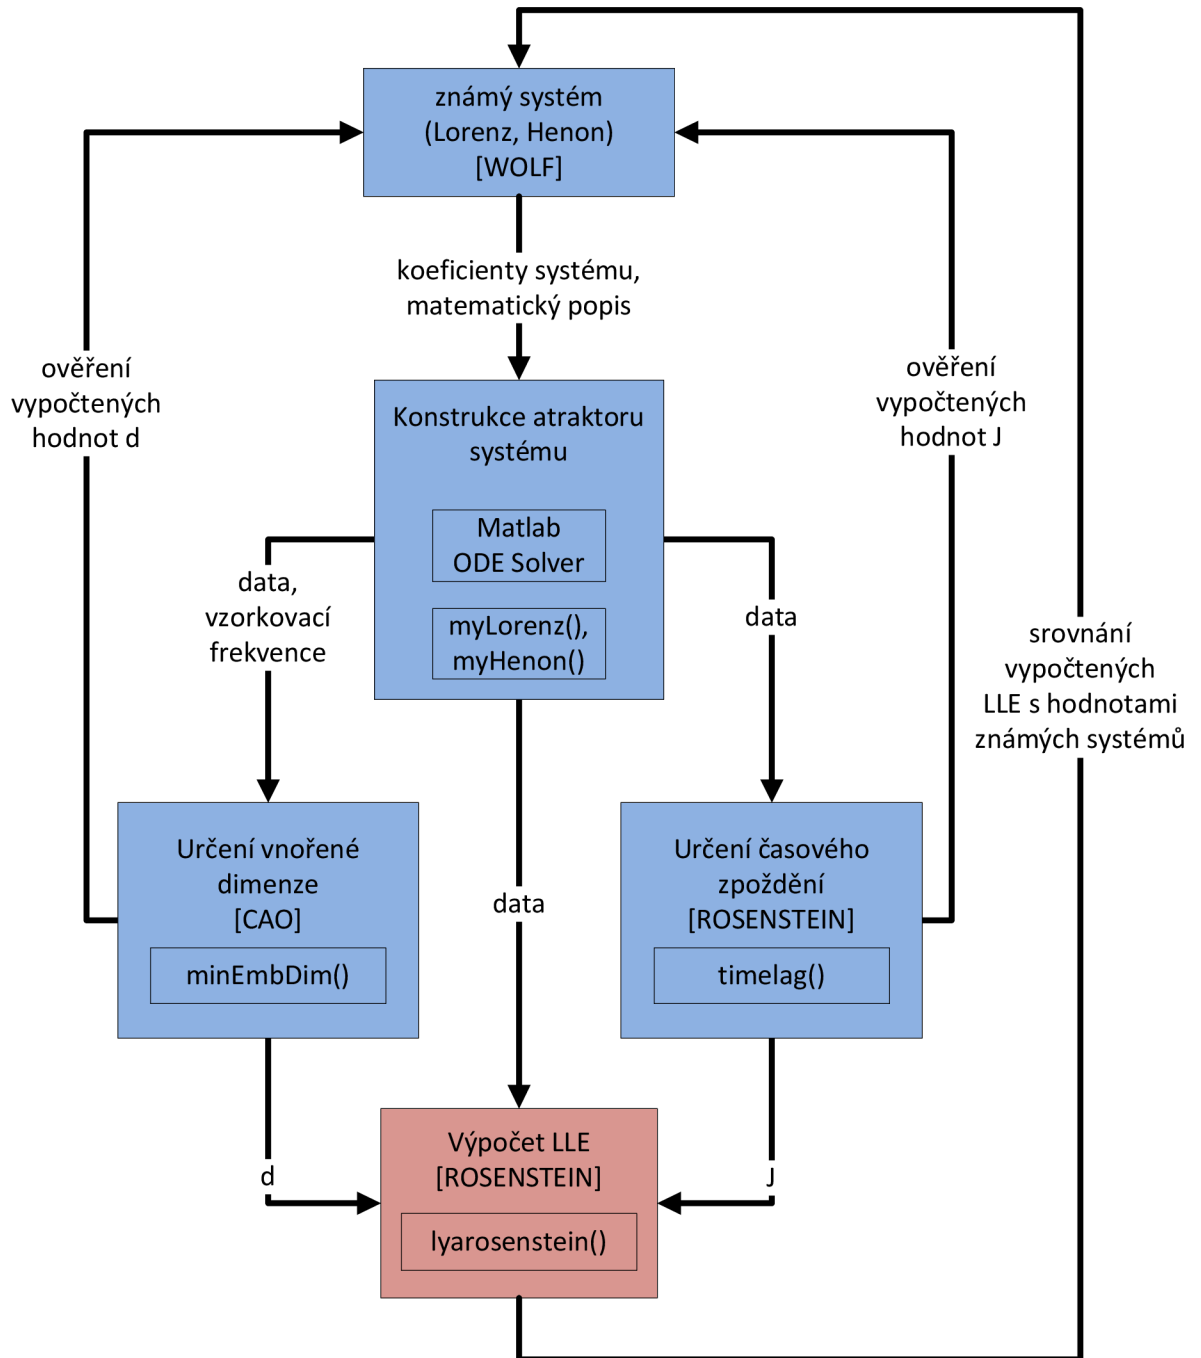
Obrázek č. 6: Ověření funkce genhurst()  
(Zdroj: vlastní)

#### 4.3.2 Lyapunovův exponent - Rosenstein

Podstatně obtížnější je nalezení a kalibrace algoritmu, který by zajišťoval korektní stanovení Lyapunovova spektra. To lze poměrně přímočaře vypočítat pro systémy, u nichž je znám jejich matematický popis [26]. Systémy, pro které takový popis neexistuje je nutno vyšetřovat jinými, podstatně složitějšími metodami. Jednou z takových metod je Rosensteinova metoda [29], která dokáže stanovit LLE z experimentálních dat. Stanoví však pouze první (největší) Lyapunovův exponent. Je to daň za výrazně robustnější a implementačně méně náročné řešení.

Celý algoritmus je detailně popsán v příslušném článku a bude zde pouze okrajově nastíněn. Není zcela automatický, pro neznámé systémy je třeba použít uživatelského úsudku a aplikaci teorie. V první řadě je nutné o systému zjistit 3 základní proměnné. První z nich jsou experimentální data, která lze získat relativně snadno, v případě devizových trhů se jedná např. o časovou řadu vývoje kurzu za určité období. Potom je systémem chápán trh dané měny, měnového páru. Druhou proměnou je minimální

vnořená dimenze systému (tzv. minimum embedding dimension [29], někdy též označovaná jako information dimension [26]). Zde už nastává problém, neboť její správné určení z časové řady je velmi obtížné a bude diskutováno dále. Třetí proměnnou je potom časové zpoždění (tzv. lag či reconstruction delay [29]). To je obtížné určit též, avšak při relativně správném odhadu naštěstí tolik neovlivňuje výsledek. Obrázek č. 7 schematicky zachycuje testování algoritmu stanovení LLE pro známé chaotické systémy.



Obrázek č. 7: Testování algoritmu stanovení LLE  
(Zdroj: vlastní, [26, 29, 40])

### Získání dat ze známých systémů

Některé chaotické systémy tvořící atraktory jsou dobře popsány. Jsou známy jejich charakteristiky i metody konstrukce. Dvěma z nich jsou Lorenzův a Henonův systém. Už Wolf ve své studii [26] používá znalosti jejich popisu k demonstraci výpočtu LE.

Konstruuje je za použití obvyklých parametrů, počítá jejich Lyapunovovo spektrum a dimenzi. Rosenstein z něj čerá [29] a svou metodu na těchto systémech ověřuje. Pro důkaz robustnosti svého algoritmu používá i jiné známé chaotické systémy, pro účely ověření přesnosti napodobení Rosensteinovy metody však postačí právě vybrané dva. Ty byly zvoleny proto, že každý z nich demonstruje odlišnou třídu atraktorů. Zatímco Henónův atraktor je diskrétní, je popsány diferenčními rovnicemi, Lorenzův atraktor je spojitý, jehož popis je dán diferenciálními rovnicemi. Testování implementované funkce na zástupce obou tříd zajistí její vyšší robustnost pro systémy s neznámou třídou.

Dostupná Matlab implementace konstrukce Henónova atraktoru [51] a Lorenzova atraktoru [52] je použita a mírně modifikována za účelem generování experimentálních dat. Ty jsou primárním vstupem dalších analýz.

### **Dimenze systému a časové zpoždění**

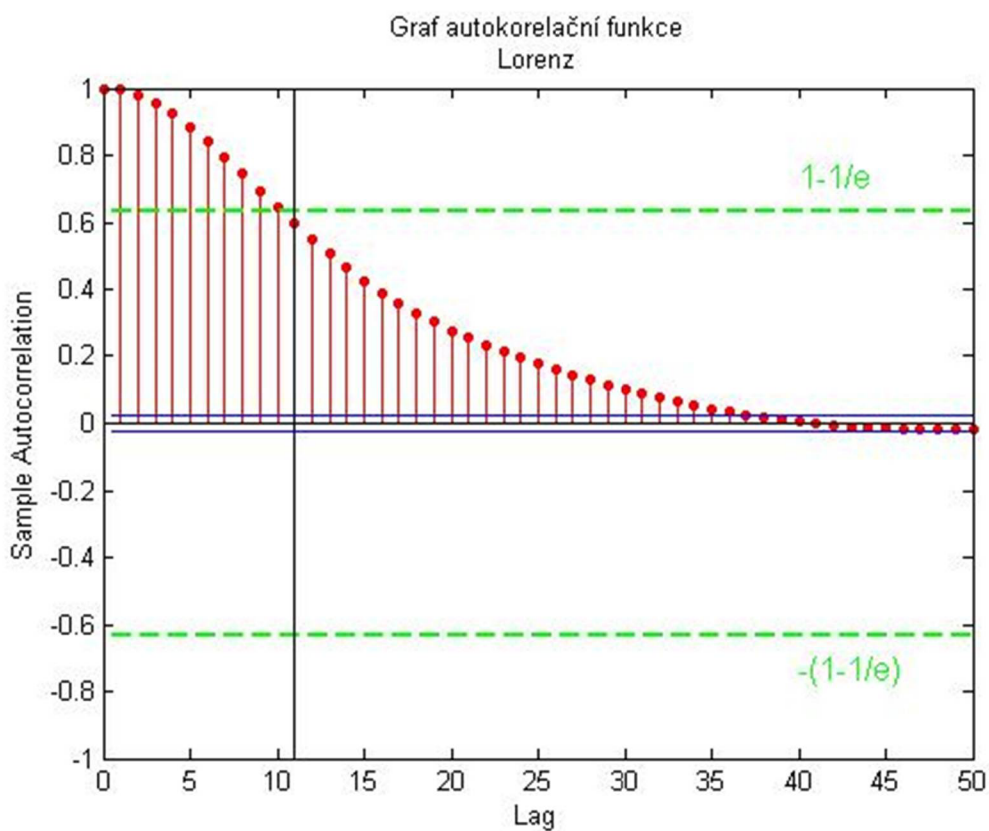
Jak bylo úvodem této podkapitoly řečeno, k určení LLE je kromě existující časové řady třeba znát další dva vstupní parametry. Těmi jsou dimenze systému a časové zpoždění.

Vnitřních dimenzí systému sice teorie rozlišuje několik, z praktického hlediska mezi nimi nejsou příliš velké rozdíly. Sato [30] i z něj vycházející Rosenstein [29] používají „vnořenou“ (embedding) dimenzi. Metodu k určení její minimální hodnoty navrhuje například Cao [40]. Ta je založena na modifikované „metodě falešných sousedů“ (false neighbor method). Její modifikace spočívá v zavedení zvláštní kvantity  $E(d)$ , která je závislá pouze na dimenzi  $d$  a externí proměnné  $\tau$ . Z ní jsou odvozeny další kvantitativní  $E1(d)$  a  $E2(d)$ . Metoda je založena na předpokladu, že při postupném zvětšování dimenze dojde k nasycení fázového prostoru, což zachytí kvantita  $E1(d)$  a ustálí se na určité hodnotě. Bod nasycení (saturation value) potom označuje nejmenší vnořenou dimenzi systému (minimum embedding dimension). Kvantita  $E2(d)$  je zavedena za účelem ošetření rozdílu mezi stochastickými a deterministickými systémy.

Torzo metody implementované v Matlabu je volně dostupné jako funkce pod BSD licenci [49]. Tato funkce musí být nejdříve podrobena testování, zda odpovídá Caově práci. To je provedeno na dvou případech chaotických systémů tvořících atraktor. Z obrázků v příloze č. 1 je jasně vidět, že k saturaci hodnot  $E1$  a  $E2$  došlo v případě Henónova systému na dimenzi 2, proto je minimální vnořená dimenze systému rovna 2.

Analogicky Lorenzova minimální dimenze je rovna 3. Ke stejným výsledkům dochází i Cao v původní publikaci [40], proto lze jeho metodu považovat za správně implementovanou.

Časové zpoždění Rosensteinem značeno jako  $J$  lze těžko určit dokonale přesně, nicméně jeho poměrně přesnou aproximaci lze stanovit pomocí autokorelační funkce [29]. Jako vhodné časové zpoždění se ukázalo takové, jehož absolutní hodnota autokorelace klesne pod  $1 - \frac{1}{e}$  násobku počáteční hodnoty, která je zpravidla rovna 1. Z toho plyne, že vhodné časové zpoždění pro například Lorenzův systém je 11, jak lze vidět z obrázku č. 8.

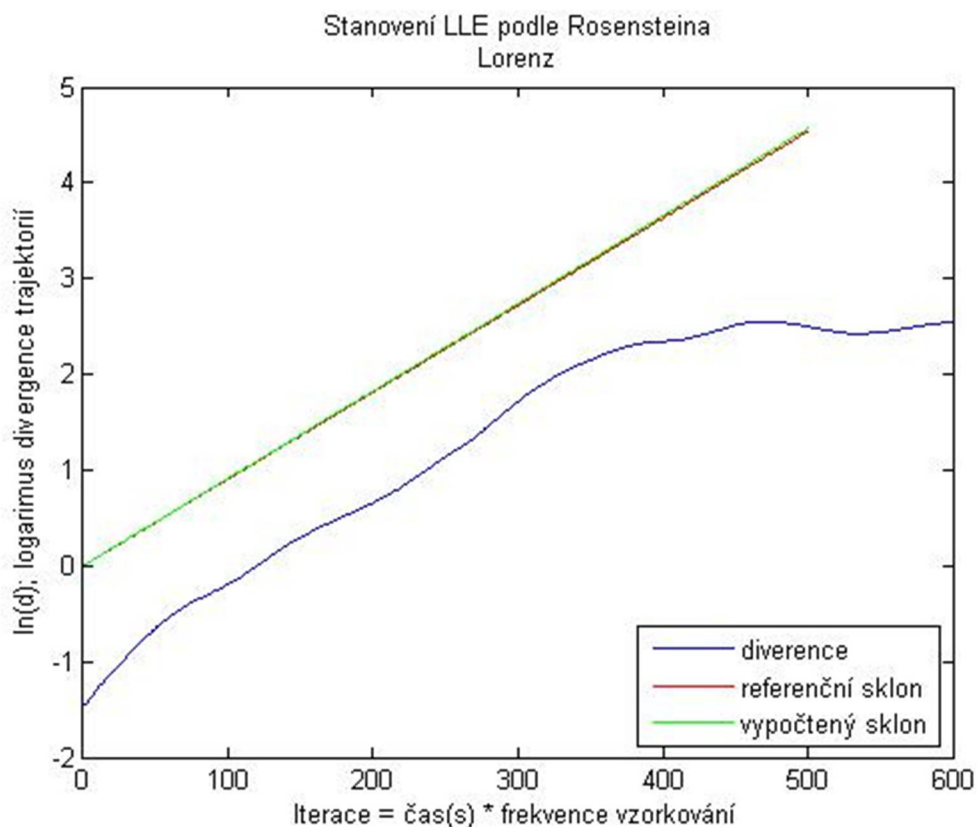


Obrázek č. 8: Určení časového zpoždění pro Lorenzův atraktor (Zdroj: vlastní)

Pro Henónův systém je časové zpoždění rovno 1. Obě dvě hodnoty přesně odpovídají Rosensteinovým výsledkům, proto lze považovat metodu stanovení časového zpoždění za korektní a platnou.

## Výpočet LLE pro známé systémy a porovnání výsledků

Jakmile jsou správně určeny vstupní parametry, lze přistoupit k aplikaci algoritmu pro výpočet LLE pro zkoumané známé systémy. Pro tento účel je použita volně dostupná Matlab funkce `lyarosenstein()` [49]. Ta implementuje přímo jádro Rosensteinovy metody a umožňuje konstrukci fázového prostoru, stejně jako torzo výpočtu LLE. Je poloautomatická, nedokáže detekovat interval, ze kterého se LLE stanoví. Ten je totiž aproximován jako sklon „roviny“ násobený frekvencí vzorkování. „Rovinou“ se myslí určitá oblast grafu, který vykresluje hodnoty divergence trajektorií v čase. Takový graf má tvar podobný logaritmické funkci a hledá se v něm určitý interval, který bude mít průběh přímky s nenulovým sklonem. Pro lepší ilustraci lze takový graf, konkrétně pro Lorenzův systém tvořící chaotický atraktor (s parametry počet hodnot  $N = 5000$ , dimenze  $d = 3$ , zpoždění  $J = 11$ ) spatřit na obrázku č. 9.



Obrázek č. 9: Výsledný graf pro stanovení LLE  
(Zdroj: vlastní)

Oblast roviny lze velmi těžko zobecnit. Autor metody navrhuje použít intervalu přibližně  $\langle i \cdot \Delta t \cdot 0,6 ; i \cdot \Delta t \cdot 1,6 \rangle$ , kde  $\Delta t$  je vzorkovací frekvence a  $i$  je pořadí

hodnoty v grafu. Tento interval vyhovuje aplikaci na Lorenzův systém, nikoliv však Henónův. Obecně ho lze použít spíše jako pomůcku pro stanovení oblasti, ve které rovinu pro výpočet LLE hledat, než k rigorózní automatizaci.

Graf, ze kterého se určuje LLE (podle sklonu detekované roviny), znázorňuje růst chyby v systému na logaritmickém měřítku. Jelikož je růst chyby exponenciální, na logaritmickém měřítku je znázorněn lineárně. Proto se hledá oblast, kterou lze dobře vyrovnat přímkou. Za touto oblastí se chyba již exponenciálně nezvětšuje, proto nemá vliv na LLE.

Dále je vhodné se zmínit o problematice jednotek a konstrukčních parametrů atraktorů. Lyapunovovo spektrum, potažmo LLE se stanovuje především pro dynamické systémy, které vykazují chaotický charakter pouze s určitými vstupními parametry. Příkladem může být tzv. logistická mapa (zde neuvažovaná), která mění svůj charakter z hlediska chaotičnosti (a tím i Lyapunovovo spektrum) v závislosti na vstupních parametrech nabývajících hodnot z intervalu  $\langle 1; 4 \rangle$ . Stejně tak Lorenzův systém tvoří atraktor právě s parametry  $\sigma = 10$ ,  $r = 28$ ,  $b = \frac{8}{3}$ , které jsou standardní [53]. V literatuře nicméně existují ještě další studie s jinými parametry [26, 29]. Navíc v této oblasti dochází k častému matení systému jednotek, neboť hodnoty Lyapunovova spektra jsou v některých pracích uváděny jako exponenty se základem 2 a někdy jako exponenty se základem  $e$ . To pochopitelně produkuje odlišné hodnoty exponentů. V této práci jsou používány výhradně exponenty při základu  $e$ .

Tabulka č. 2 sumarizuje výsledky testů funkce `lyarosenstein()` na známých chaotických systémech tvořících atraktor a porovnává je s referenčními hodnotami jiných autorů.



Tabulka č. 2: Souhrn vypočtených hodnot a srovnání s výsledky jiných autorů

	parametry atraktoru	délka čas. řady $N$	min. vnořená dimenze $d$	čas. zpoždění $J$	referenční LLE (base-e)	vypočtené LLE (base-e)
Henón	$a = 1,4$ $b = 0,3$	5000	2	1	0,419	0,402
Lorenz 1	$\sigma = 10$ $r = 28$ $b = 8/3$	5000	3	11	0,906	0,912
Lorenz 2	$\sigma = 16$ $r = 45,92$ $b = 4$	10000	3	11	1,5	1,81

(Zdroj: vlastní, [26, 29, 40, 53])

Všechny hodnoty jsou stanoveny v souladu s publikovanými výsledky uvedených autorů. Dimenze i časové zpoždění jsou určeny zcela správně, LLE mírně nevyhovuje v posledním případě, kdy se liší přibližně o 20% od referenční hodnoty. Nebylo zjištěno, co danou výjimku způsobuje. Není totiž závislá na dimenzi, délce časové řady ani na zpoždění. Existuje možnost, že ji způsobuje algoritmus konstrukce Lorenzova atraktoru, který není plně optimalizován na změnu vstupních parametrů. Velikost odchylky však není příliš velká, z hlediska uvažované aplikace LLE na finančních trzích je spíše zanedbatelná.

### **Rozhodnutí o použitelnosti zvolené funkce**

Na základě předchozích analýz lze prohlásit všechny použité funkce za způsobilé, neboť plní svůj účel a umožňují při správné aplikaci stanovit LLE ze skalární časové řady. Kritickými body celé metody jsou:

- Stanovení  $\tau$  pro výpočet nejmenší vnořené dimenze  $d$  (problém systémů s diskretním / spojitým časem).
- Určení bodu nasycení, taktéž při determinaci  $d$  (z grafu).
- Stanovení intervalu pro určení časového zpoždění  $J$ .
- Určení frekvence vzorkování (problém neekvidistantních dat, příliš nízká frekvence vzorkování).
- Stanovení intervalu pro detekci „roviny“, jejíž sklon násobený frekvencí vzorkování udává LLE (z grafu).
- Interpretace LLE.

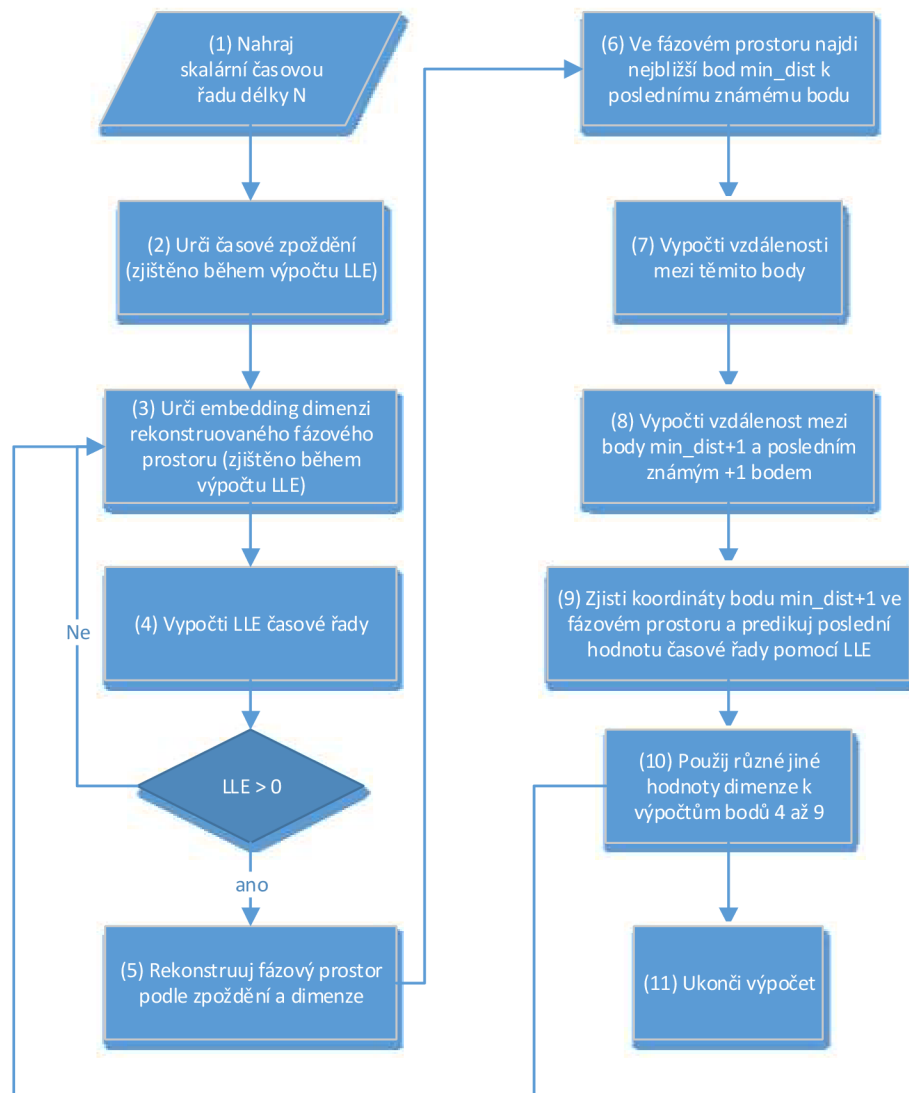
### 4.3.3 Lyapunovův exponent – Gao (SDLE)

Ačkoliv je Rosensteinova metoda výpočtu LLE velmi vhodná a přesná pro standardní, ryze chaotické systémy, je obtížněji použitelná pro komplexní systémy obsahující výrazně složitější, neznámé chaotické chování spolu s přítomností šumu, případně chyby měření. To si uvědomil Gao [46, 47] a vytvořil metodu, do níž zakomponoval prvky R/S analýzy. Gao přímo poskytuje funkce pro SDLE analýzu [47]. Ty testuje na známých chaotických systémech a několika jejich modifikacích. Výsledky, doporučené parametry, grafické výstupy i metody, jak je číst, publikuje. Z toho důvodu není nutné tyto poskytnuté algoritmy znovu testovat, stačí držet se doporučených postupů a omezení. SDLE bude využíván k paralelnímu výpočtu LLE a výsledky vždy porovnávány s Rosensteinovou metodou za účelem jejich ověření.

### 4.3.4 Predikce využitím chaotického atraktoru a LLE – Zhang

Posledním komplexním algoritmem, u něhož je nezbytná kalibrace, je jádro predikčního modelu založeného na možnosti konstrukce  $D$ -rozměrného fázového prostoru a znalosti alespoň základní chaotické charakteristiky zkoumaného systému – největšího Lyapunovova exponentu. Celou filozofii modelu, metodu jeho konstrukce, omezení a predikční chyby popsal ve svém článku Zhang [54].

Metoda predikce je elegantně založena na jedné z fundamentálních charakteristik chaotických systémů, kterou je citlivost na počáteční podmínky. Celou charakteristiku této vlastnosti poskytuje Lyapunovovo spektrum. Nejdůležitější z celého spektra je, jak již bylo řečeno, první (největší) Lyapunovův exponent. Ten se použije k predikci neznámé hodnoty ve zkonstruovaném fázovém prostoru dle embedding teorému. Následně lze provést inverzní transformaci a fázový prostor převést na skalární chaotickou časovou řadu, která bude obsahovat jednu (nebo více) predikovaných hodnot. Zhangův algoritmus sestává z 11 kroků. Článek obsahuje jeho slovní popis, avšak logikou a uspořádáním je velmi vhodný pro zobrazení jednoduchým vývojovým diagramem. Ten je k dispozici na obrázku č. 10. V popisících grafu je uveden pouze základní princip, vysvětlení pojmů a bližší grafické znázornění bude k dispozici dále.



Obrázek č. 10: Zhangův predikční algoritmus  
(Zdroj: vlastní, podle [54])

Body algoritmu 1 až 5 jsou společné algoritmu výpočtu LLE podle Rosensteina [29]. Princip spočívá ve správném určení chaotických charakteristik systému a následné konstrukci fázového prostoru z hodnot časové řady. Je tedy možné jejich popis přeskočit.

Pro vysvětlení bodu 6 až 9 je již třeba zavést některé pojmy. Ty budou postupně objasňovány, jak budou popisovány jednotlivé fáze algoritmu.

Je dána skalární chaotická časová řada  $x(1), x(2), x(3), \dots, x(N)$ , kde  $N$  je délka časové řady. Jestliže bude tato řada „vnořena“ (embedded) do  $D$ -rozměrného fázového prostoru


za použití časového zpoždění  $T$ , bude získáno  $(N - (D - 1)T)$  hodnot fázového prostoru  $Y(I)$ , kde  $I \in \langle 1; (N - (D - 1)T) \rangle$ ,  $I \in \mathbb{N}$ . Potom platí:

$$\begin{aligned} Y(1) &= [x(1), x(1 + T), \dots, x(1 + (D - 1)T)]; \\ Y(2) &= [x(2), x(2 + T), \dots, x(2 + (D - 1)T)]; \\ Y(3) &= [x(3), x(3 + T), \dots, x(3 + (D - 1)T)]; \\ &\dots \\ Y(I) &= [x(I), x(I + T), \dots, x(I + (D - 1)T)]; \end{aligned} \quad (5)$$

To znamená, že lze získat  $I = (N - (D - 1)T)$  bodů fázového prostoru. Na základě těchto bodů lze nalézt nejbližší bod bodu  $Y(N - (D - 1)T)$  a označit ho jako  $Y(\min\_dist)$  (ad 6). Následně lze vypočíst (např. pomocí euklidovských vzdáleností) vzdálenost  $dist\_0$  mezi body  $Y(N - (D - 1)T)$  a  $Y(\min\_dist)$  (ad 7). Tato vzdálenost by se měla (z teorie chaotického chování časové řady) v postupných iteracích mírně měnit. Velikost změny je dána LLE (zde použito značení  $\lambda_1$ ) a mezi počáteční  $dist\_0$  a následnou, iterativně změněnou hodnotou  $dist\_1$  fázového prostoru platí:

$$dist\_1 = dist\_0 \cdot e^{K \cdot \lambda_1} \quad (6)$$

$K$  je potom počet kroků (iterací) mezi vzdálenostmi  $dist\_0$  a  $dist\_1$ . Z uvedeného vztahu lze získat hodnotu  $dist\_1$  (ad 8), což musí být vzdálenost mezi body fázového prostoru, jejichž index je posunut o  $K$ . Obrázek č. 11 pěkně zachycuje celou situaci pro  $K = 1$ .



Obrázek č. 11: Část trajektorie časové řady ve fázovém prostoru (Zdroj: vlastní, podle [54])

Nyní přichází důležitá asociace.  $Y(\min\_dist)$  je některý z bodů fázového prostoru a z uvedeného platí, že  $\min\_dist < N - (D - 1)T$ . Z toho plyne, že souřadnice bodu  $Y(\min\_dist)$  jsou známé, jedná se totiž o některý z předchozích bodů fázového prostoru. Proto lze nalézt bod  $Y(\min\_dist + K)$ , pokud je splněno:

$$\min\_dist + K \leq N - (D - 1)T \quad (7)$$

Je-li znám bod  $Y(\min\_dist + K)$  (nebo z obrázku pro  $K = 1$  bod  $Y(\min\_dist + 1)$ ) a současně vzdálenost  $dist\_1$ , potom lze vypočítat bod  $Y(N - (D - 1)T + K)$ , resp.  $Y(N - (D - 1)T + 1)$ . Protože z rovnice (5) platí:

$$Y(N - (D - 1)T + K) = [x(N - (D - 1)T + K), x(N - (D - 1)T + T + K), \dots, x(N + K)], \quad (8)$$

pak může být predikována hodnota  $x(N + K)$ , resp.  $x(N + 1)$ (ad 9). „Vzdálenost“  $K$  predikované hodnoty do posledního známého bodu je dána hodnotou  $\min\_dist$ , která musí splňovat podmínku (7), a také druhem chaotického chování systému, na kterém závisí hodnota LLE (diskutováno při kalibraci algoritmu výpočtu LLE).

Zhang bohužel neuvádí, jak konkrétně postupovat při extrakci predikované skalární hodnoty časové řady ze souřadnic fázového prostoru. Při bližším zkoumání však zřejmě platí:

$$\begin{aligned} dist\_1 &= \|Y(N - (D - 1)T + K) - Y(\min\_dist + K)\| \\ dist\_0 \cdot e^{K \cdot \lambda_1} &= \|Y(N - (D - 1)T + K) - Y(\min\_dist + K)\| \end{aligned} \quad (9)$$

Zhang pracuje s hodnotou  $K = 1$ , přičemž neuvažuje dále jiné alternativy. V případě, že  $K > 1$ , potom je třeba zavést proměnnou  $B$ , která bude značit rozdíl indexů posledního známého bodu fázového prostoru  $Y(N - (D - 1)T)$  a bodu, který je mu nejbližší -  $Y(\min\_dist)$ . Tento rozdíl lze zapsat jako:

$$B = N - (D - 1)T - \min\_dist \quad (10)$$

a zároveň

$$B \geq K$$

S touto novou proměnnou lze vyjádřit body fázového prostoru jako vektory souřadnic délky  $D$ :

$$Y(\min\_dist + K) = Y(N - (D - 1)T - B + K) \quad (11)$$

$$\begin{aligned} Y(N - (D - 1)T + K) = \\ \left[ \begin{array}{l} x(N - (D - 1)T + K), x(N - (D - 2)T + K), \dots, \\ (N - T + K), x(N + K) \end{array} \right] \\ Y(N - (D - 1)T - B + K) = \\ \left[ \begin{array}{l} x(N - (D - 1)T - B + K), x(N - (D - 2)T - B + K), \dots, \\ (N - T - B + K), x(N - B + K) \end{array} \right] \end{aligned}$$

Dle rovnice pro výpočet euklidovských vzdáleností:

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (12)$$

platí po dosazení:

$$dist\_0 \cdot e^{K \cdot \lambda_1} = \quad (13)$$

$$\sqrt{\begin{aligned} & (x(N - (D - 1)T + K) - x(N - (D - 1)T - B + K))^2 + \\ & + (x(N - (D - 2)T + K) - x(N - (D - 2)T - B + K))^2 + \dots \\ & \dots + (x(N + K) - x(N - B + K))^2 \end{aligned}}$$

Původní skalární chaotická časová řada obsahuje všechny hodnoty kromě  $x(N + K)$ . Jedná se právě o jedinou neznámou v této rovnici a zároveň žádanou predikovanou hodnotu. Její vyjádření je otázkou triviálních matematických úprav a proto postačí uvést pouze konečný tvar:

$$x_{1;2}(N + K) = \quad (14)$$

$$\pm \sqrt{\left| \frac{dist_0^2 \cdot e^{2 \cdot K \cdot \lambda_1} - \sum_{i=1}^{D-1} (x(N - (D - i)T + K) - x(N - (D - i)T - B + K))^2}{\dots} \right| + x(N - B + K)}$$

Jak je vidět z rovnice (14), rovnost je splněna pro dvě hodnoty. To je logické, neboť trajektorie ve fázovém prostoru může pokračovat jak „nad“, tak „pod“ poslední známou hodnotou. Ze Zhangova článku není zcela jasné, jak tento paradox řeší. Pro zvýšení přesnosti predikce doporučuje provádět opakované výpočty s měnící se embedding dimenzí (obrázek č. 10: Zhangův predikční algoritmus, ad 10), nikde však neuvádí, jak

určit znaménko. Způsob aplikace predikční metody v původním článku naznačuje, že řešení této otázky je vynecháno záměrně. Jediným kritériem je totiž absolutní (či relativní) odchylka. Při jejím výpočtu se však uvažuje pouze absolutní hodnota rozdílu mezi skutečnou a predikovanou hodnotou. Při obchodování na finančních trzích je však znaménko predikované změny zcela zásadní. Tento fakt je fundamentálním nedostatkem Zhangovy metody, a ta proto není pro přímou predikci trhů samostatně vhodná. Její použití však může být alternativní a neméně významné. Na jedné straně umožňuje metoda konstruovat a graficky zobrazit fázový prostor. Jeho tvar sám o sobě může přinést uživateli nějaké zajímavé implikace. Na druhé straně odhad rozmezí hodnot, v němž se systém pohybuje, může mít zajímavou aplikaci v určování extrémů těchto hodnot. Tato problematika je dále aplikována a rozpracována na devizových trzích.

#### **4.4 Stažení dat a jejich konverze**

Jakmile jsou všechny uvažované algoritmy schváleny jako korektní, je možné přejít k jejich praktické aplikaci. Aby bylo možné zkoumat charakteristiky devizových trhů, je potřeba mít příslušná data. Ta lze bezplatně stáhnout ze stránky HistData.com [55]. Zde existuje poměrně rozsáhlá databáze historických dat (několik dní starých). Momentálně jsou k dispozici data ve formátech pro 4 různé platformy. Jako nejvhodnější pro další účely byl zvolen tick formát pro NinjaTrader s 1 sekundovým rozlišením. Je dostupný formát ještě s vyšším rozlišením (přesnost až na  $10^{-3}$  sekundy), ten je však zbytečně detailní. K dispozici jsou data pro 66 nejčastěji obchodovaných měnových párů od roku 2000 pro hlavní páry (EURUSD, USDJPY atp.) a od 2010 pro méně významné páry (EURCZK, USDHUF atp.). Data jsou uložena v .csv formátu zvlášť pro jednotlivé měsíce.

##### **4.4.1 Stažení dat**

Ačkoliv stránka umožňuje hromadné stahování dat přes FTP, jedná se o placenou službu. Zdarma jsou data k dispozici pouze při ručním stahování přes internetový prohlížeč. Jelikož jsou však rozdělena po měsících, není nijak časově náročné takové ruční stažení provést. Během hodiny je uživatel schopen bez problému stáhnout desítky let dat.

#### 4.4.2 Vytvoření OHLC databáze

Tick data nejsou příliš vhodná jako vstupní data obecných analýz. Mají sice nejpřesnější vypovídací schopnost o pohybech trhu, vedle toho však vykazují několik nevýhod. Množství tick dat je z hlediska výpočetní složitosti i triviální analýzy zbytečně velké. Dalším problémem je fakt, že jejich časová řada není zpravidla ekvidistantní. Taková řada by se musela zpracovávat netradičními metodami nebo by zkreslovala výsledky analýz. Protože se na finančních trzích běžně používá OHLC formát dat, jsou data transformována na OHLC formát.

Pro tento účel byla vytvořena Matlab knihovna obsahující několik transformačních funkcí, které vytvářejí redukovanou paralelní OHLC databázi ekvidistantních dat s periodami vzorkování M1, M5, M10, M15, M30, H1, H2, H4, H8, D1. Celá databáze je výrazně úspornější z hlediska úložného prostoru. Konkrétně zabírá zhruba 1/8 až 1/12 místa na disku oproti plné databázi tick dat. Data v ní mají vždy pevnou periodu vzorkování podle uvedeného nastavení. Databázi fyzicky tvoří standardní adresářová struktura vycházející z logicky ukládání souborů tick dat. Je tvořena stromem root > měnový pár > rok > měsíc > perioda vzorkování > data. Koncové soubory mají příponu .csv s defaultním formátem zápisu. Data jsou takto převoditelná na libovolnou platformu a i v surovém stavu dobře čitelná. Během celé procedury jsou čištěna od chybějících a nulových hodnot. Tabulka č. 3 obsahuje základní popis import funkcí. Seznam všech funkcí knihovny `mainLibrary` a jejich základní popis je pak uveden v příloze č. 4.

Tabulka č. 3: Obsah vlastní Matlab knihovny `mainLibrary/TIC data/`

Název	Popis
<code>tickImportFileCsv()</code>	Importuje data z .csv souboru přesně tak, jak jsou uložena na HistData.com.
<code>extractDate()</code>	Převádí časové razítko z původního formátu na Matlab vektorový formát ( <code>datevec()</code> ).
<code>tick2ohlc()</code>	Převádí formát dat z tick na OHLC s 10ti různými periodami vzorkování.
<code>createOhlcDBase()</code>	Hromadně vytvoří OHLC databázi na základě tick databáze. Zpracování po dávkách kvůli alokacím rozsáhlých matic (omezení operační paměti).
<code>selTScale()</code>	Vybere libovolný úsek OHLC databáze. Přesnost dny.
<code>mat2timeSeries()</code>	Převádí standardní maticový výstup <code>selTScale()</code> na formát časové řady Matlab třídy <code>timeseries</code> .

(Zdroj: vlastní)



#### 4.4.3 Výběr dat z vytvořené databáze

Jakmile je OHLC databáze vytvořena, jsou data připravena k použití. Zpět do prostředí Matlabu je lze dostat pomocí funkce `selTScale()`, která provádí výběr určitého měnového páru s příslušnou periodou vzorkování za stanovený časový interval. Přesnost tohoto výběru jsou dny, neboť i při případných intradenních analýzách bude vybírán minimálně jeden celý den.

Vybraná data jsou interpretována maticí hodnot. Takový formát je vhodný především k vyfiltrování neobchodních dní. Při zpracování se data interpretují jako vektor hodnot bez časového razítka, což umožňuje grafické zobrazení provést souvisle, bez viditelných mezer v datech. Pro volitelné analýzy je implementována ještě další funkce, která převádí maticová data na strukturu objektů třídy `timeseries`. Jedná se o zvláštní objekt Matlabu speciálně určený k manipulaci s časovými řadami. Data jsou graficky interpretována spolu s časovým razítkem, což způsobuje charakteristické mezery v době víkendů (neobchodních dní).

#### 4.4.4 Použité měnové páry

Finálním a zároveň klíčovým krokem je výběr měnových párů a časového rozpětí dat použitých k následným analýzám. Jako vhodné páry se ukázaly páry obsahující euro, neboť v takovém případě není třeba se v analýzách zabývat zvlášť případy, kdy jsou páry vzájemně provázány. Bylo vybráno 5 párů zachycující nejobchodovanější měny. Jedná se o EURUSD, EURGBP, EURJPY, EURCAD, EURCHF. Časová měřítka jsou uvažována prozatím všechna dostupná, tedy M1, M5, M10, M15, M30, H1, H2, H4, H8, D1, do analýz bude možné zahrnout pouze některá, z důvodu např. výpočetní složitosti či redundance informací. Časový interval byl určen na hodnotu 4 roky 2010 - 2013. Celá OHLC datová složka má velikost přibližně 430 MB.

### 4.5 Hurstův exponent měnových párů eura v letech 2010 - 2013

Výpočet fraktálních charakteristik měnových párů lze uchopit různým způsobem. Existují v zásadě 4 možnosti výpočtu  $H$  v závislosti na velikosti intervalu:

- Výpočet proveden přes celý interval  $P$  dlouhé časové řady délky  $n$ , výsledek je jediné číslo. Lze použít pro potvrzení teorie efektivních trhů, neboť tento skalár  $H_{P_{1;n}}$  bude velmi blízký hodnotě 0,50.
- Celý interval  $P$  je rozdělen do stejně dlouhých úseků délky  $m$  a  $H$  je vypočten pro každý z nich. Lze sledovat změnu hodnoty  $H$  v čase a detekovat odchylky od dlouhodobé střední hodnoty. Výsledkem je vektor délky  $\frac{n}{m}$  rovné počtu úseků:

$$[H_{P_{1;m}}, H_{P_{m+1;2m}}, H_{P_{2m+1;3m}}, \dots, H_{P_{n-m+1;n}}] \quad (15)$$

- Stejný jako předchozí, intervaly mají stále fixní délku, ale navzájem se překrývají o určitý počet kroků  $s$ . Lze sledovat změny v čase s tou výhodou, že nedochází ke ztrátě informace na hranicích intervalů. Výsledkem je vektor, jehož délka je závislá na délce intervalů a roste s počtem kroků překrytí. Tento princip částečně využívá Gaova SDLE [46].

$$[H_{P_{1;m-s}}, H_{P_{m-s+1;2(m-s)}}, H_{P_{2(m-s)+1;3(m-s)}}, \dots, H_{P_{\frac{n}{m(m-s)+1};n}}] \quad (16)$$

- Plovoucí interval fixní délky, z něhož se  $H$  vypočítává při každém kroku, kdy se „okno“ posune o jeden krok dále. Lze použít na detekci nejmenších změn v hodnotě  $H$ . Výsledkem je vektor délky  $n-m$ , tedy jako původní časová řada, avšak bez prvních  $m$  kroků, ze kterých se vypočítává první hodnota vektoru výsledků.

$$[H_{P_{1;m}}, H_{P_{2+m+1}}, H_{P_{3+m+3}}, \dots, H_{P_{n-m+1;n}}] \quad (17)$$

Bez ohledu na interval, jádro algoritmu zajišťuje výše validovaná funkce `genhurst()`. Jako analyticky nejoptimálnější se ukázala druhá metoda rozdělení intervalu. Funkce `createHexpStruct()` knihovny `/RS` dávkově vytváří strukturu dat obsahující vypočtené Hurstovy exponenty pro všechny měnové páry mezi roky 2010 a 2013 ve třech kategoriích. První kategorie, označena jako *Hlow*, jsou Hurstovy exponenty nejpodrobnějších period (M1, M5, M10, M15) počítané za jednotlivé dny čtyřletého období. Druhá kategorie, označena jako *Hmid*, jsou Hurstovy exponenty středně podrobných period (M30, H1, H2), které jsou počítány za každý měsíc čtyřletého období. Poslední kategorií, označenou jako *Hhigh*, jsou Hurstovy exponenty

dlouhých period (H4, H8, D1). Ty jsou počítány z důvodu nedostatku hodnot pro každý rok. Všechny vektory jsou uloženy do příslušných složek k OHLC datům.

Funkce `convertHexpStruct()` umožňuje zpětné načítání dat, jejich čištění a konverzi do souvislých časových řad.

#### **4.5.1 Korelace Hurstova exponentu a zisku**

Pro zjištění, zda hodnota Hurstova exponentu je skutečně nositelem informace, která je potenciálně využitelná k predikci trhů, byl proveden výpočet korelačních koeficientů hodnoty  $H$  a ziskovosti MACD strategie s určitými parametry. K tomuto účelu byly z  $H$  vypočtených pro jednotlivé měsíce vytvořeny roční časové řady. Obdobné časové řady stejné délky byly vytvořeny z konečných zůstatků obchodního účtu pro jednotlivé měsíce obchodování. Pro tyto dva malé datové soubory byly vypočteny korelační koeficienty zobrazené v tabulce č. 4. Nejvhodnější pro demonstraci tohoto vztahu se ukázaly střednědobé časové řady s periodami M30, H1 a H2.

Tabulka č. 4: Korelační koeficienty ziskovosti obchodní strategie a hodnoty Hurstova exponentu pro měnové páry v období 2010 - 2013

<b>EURUSD</b>	2010	2011	2012	2013
Mid				
M30	0,570779	0,692366	0,459746	0,040115
H1	0,172473	0,495492	0,793882	0,329672
H2	0,283624	0,73331	-0,37173	0,166195
			<b>průměr</b>	<b>0,363827</b>
<b>EURGBP</b>				
Mid				
M30	0,621546	0,721966	0,512139	-0,05038
H1	-0,07043	0,821038	0,69176	0,57475
H2	0,108053	0,036067	-0,38196	0,329343
			<b>průměr</b>	<b>0,326157</b>
<b>EURJPY</b>				
Mid				
M30	0,098906	0,481353	-0,05738	0,795896
H1	0,047751	0,338063	0,224044	0,279124
H2	-0,21494	0,264285	0,079939	0,127502
			<b>průměr</b>	<b>0,205379</b>
<b>EURCAD</b>				
Mid				
M30	0,453297	0,546825	0,42813	0,693456
H1	0,551896	0,6004	0,535473	0,466332
H2	0,614839	0,357033	0,30874	0,680182
			<b>průměr</b>	<b>0,519717</b>
<b>EURCHF</b>				
Mid				
M30	0,520084	0,833663	0,407101	0,226129
H1	0,697968	0,171029	0,64023	0,165153
H2	0,240904	0,238885	0,799732	0,717975
			<b>průměr</b>	<b>0,471571</b>

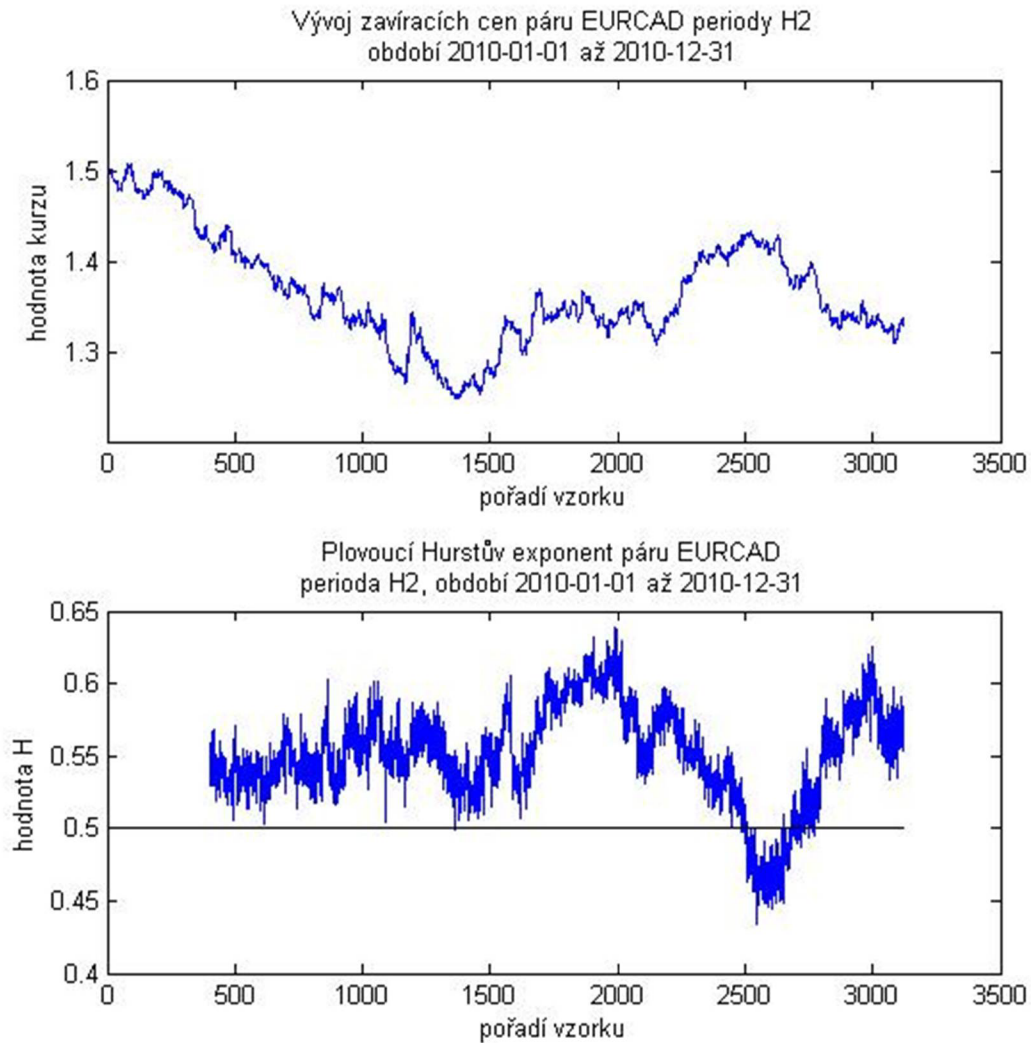
(Zdroj: vlastní)

Z uvedených dat je zřejmé, že ve sledovaném období hodnoty Hurstova exponentu a profitu vybrané obchodní strategie založené na MACD korelují. Nejsilnější korelace je u méně obchodovaných párů a EURCAD a EURCHF, naopak nejslabší u EURJPY. Zajímavé je sledovat směrodatnou odchylku korelačních koeficientů. Ze dvou párů s největší průměrnou korelací se mnohem lépe jeví EURCAD, neboť jeho průměrná směrodatná odchylka počítána jako střední hodnota směrodatných odchylek jednotlivých časových úseků je oproti EURCHF podstatně nižší. Pro EURCAD je tato

hodnota rovna 0,120, pro EURCHF 0,282. Z toho důvodu lze považovat EURCAD za nejoptimálnějšího kandidáta pro obchodování z analyzovaných měnových párů v daném období.

#### 4.5.2 Plovoucí Hurstův exponent

Změny  $H$  v čase lze znázornit i graficky. Jestliže je použit princip výpočtu  $H$  č. 4, tedy výpočet  $H$  z plovoucího intervalu fixní délky, potom lze získat poměrně výmluvný graf znázorňující časový vývoj  $H$  pro určitý měnový pár. Pro ukázkou je na obrázku č. 12 vypočten pomocí vlastní funkce `hurstOverTime()` plovoucí  $H$  s intervalem délky 400 vzorků. Při porovnání s časovou řadou odpovídajících hodnot kurzu lze spatřit jasnou spojitost mezi těmito dvěma grafy. Prvních asi 1000 hodnot kurzu má klesající trend, proto se hodnota  $H$  drží nad úrovní 0,50. Kolem ceny č. 1400 se kurz začíná lámat, a proto  $H$  mírně padá ke své střední hodnotě. Následuje zpočátku silný rostoucí trend, který však svou sílu brzy ztrácí a kolem hodnoty 2500 se láme a přechází v klesající. To je na grafu  $H$  zachyceno přechodem z persistence na antipersistenci a zpět, jak hodnota  $H$  v poslední pětině grafu klesá pod 0,50 a následně se vrací.



Obrázek č. 12: Plovoucí Hurstův exponent  
Zdroj: vlastní, zpracování Matlab

Zásadním nedostatkem plovoucího Hurstova exponentu, a důvodem, proč z něj nelze vyvozovat závěry přímo, je pevná velikost plovoucího okna. Princip R/S analýzy je totiž protikladný. Ta hodnotí časovou řadu právě v závislosti na proměnlivém měřítku, tedy v různě dlouhých intervalech. Stanovení fixní délky intervalu, která musí být z logiky věci navíc poměrně krátká, omezuje možnosti R/S správně zachytit delší trend (delší „paměť“ řady). To je právě důvod, proč jsou na obrázku č. 12 zachyceny různé trendy různě významně, přičemž jejich významnost (hodnotu nebo změnu hodnoty  $H$ ) nelze přímo odvodit ani z jejich délky, ani ze síly. Silné, krátké trendy, jejichž  $H$  by mělo být vysoké, jsou nezřetelné, protože zabírají pouze část intervalu dlouhého 400

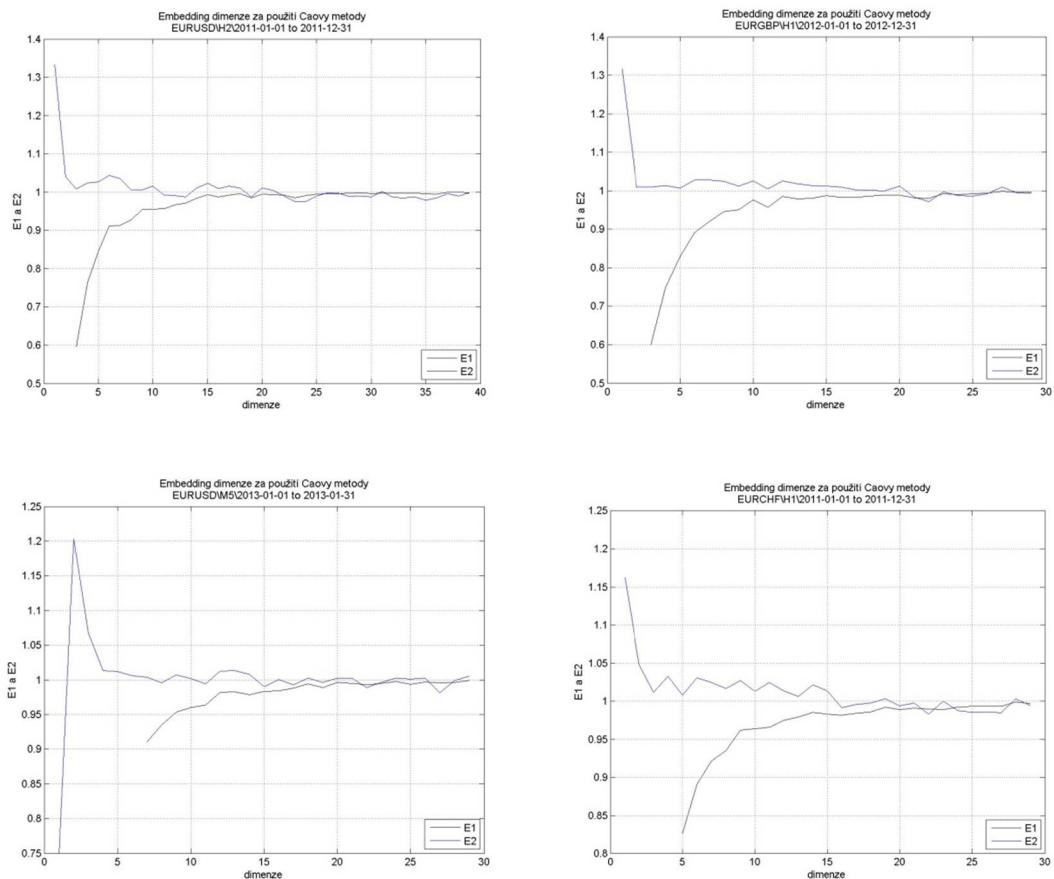
kroků. Stejně tak dlouhé trendy jsou v  $H$  méně rozpoznatelné, neboť fixní časový úsek je nedokáže celé zachytit.

## **4.6 Lyapunovův exponent trhů v letech 2010 – 2013**

Podobně jako Hurstův exponent dokáže zachytit fraktální charakteristiky různých časových řady a ty mezi sebou porovnávat, dokáže LLE stanovit jejich základní chaotické charakteristiky. Tím lze určit predikční možnosti jednotlivých trhů, resp. akumulaci počáteční chyby. Lze tak například porovnat, které měnové páry patří mezi stabilnější z hlediska predikce a jak daleko do budoucnosti je predikce možná.

### **4.6.1 LLE podle Rosensteina**

Metoda determinace LLE podle Rosensteina [26] je popsána v kapitole 4.3 Představení a kalibrace algoritmů. Metoda začíná stanovením časového zpoždění systému a jeho vnořené dimenze. Dimenze je počítána pro jednotlivé páry a různé časové úseky. Zajímavé je zjištění, že dimenzi nijak významně neovlivňuje volba měnového páru, časové periody dat nebo dokonce časového období. Průběh grafu, ze kterého se odečítá hodnota dimenze je pro různé parametry stále velice podobný (viz obrázek č. 14). Z něj plyne, že hodnota dimenze se reálně pohybuje někde mezi 15 a 20, neboť v této oblasti dochází k saturaci kvantity  $E2$ .



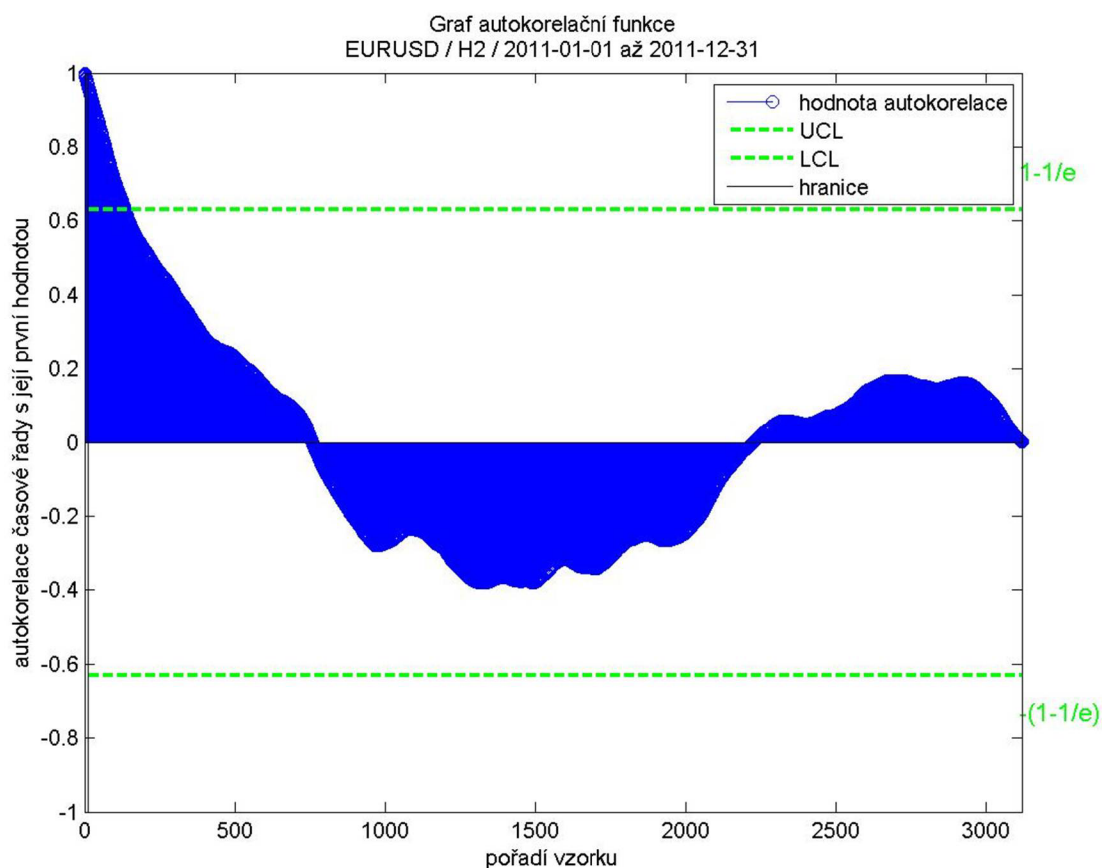
Obrázek č. 13: Grafy pro určení vnořené dimenze podle Cao, postupně zleva doprava a shora dolů: EURUSD / H2 / 2011-01-01 až 2011-12-31; EURGBP / H1 / 2012-01-01 až 2012-12-31; EURUSD / M5 / 2013-01-01 až 2013-01-31; EURCHF / H1 / 2011-01-01 až 2011-12-31.

(Zdroj: vlastní, zpracování Matlab)

Uvedené grafy na obrázku č. 13 mají pouze ilustrační charakter, originály nebyly z typografických důvodů přidány. Lze je nicméně vygenerovat příslušným přiloženým skriptem `automatedEmbDim.m` a jsou k dispozici na přiloženém přenosném médiu.

Určení časového zpoždění se řeší podobným způsobem – subjektivním zhodnocením průběhu grafu. Rosenstein naštěstí poskytuje vodítko ve formě hraničních hodnot, mezi které by se hodnota autokorelace měla dostat pro určení vhodného zpoždění. Ilustrační graf jednoho z měření je uveden na obrázku č. 14.





Obrázek č. 14: Autokorelační graf pro určení časového zpoždění, vstupními daty je časová řada EURUSD / H2 / 2011-01-01 až 2011-12-31. První hodnota spadající do intervalu leží v kroku 134.

(Zdroj: vlastní, zpracování Matlab)

Časové zpoždění pro různé měnové páry, různé periody a časová období dávkově zpracovává, obdobně jako v případě dimenze, funkce `automatedTimeLag.m`. Na tvaru autokorelačních grafů je zajímavé sledovat změnu korelace. Některé páry obecně vykazují rychlejší ztrátu korelace s přibývajícím časem, než jiné. To značí různé paměťové schopnosti každého měnového páru. Takové srovnání musí pochopitelně probíhat na stejném časovém měřítku a ve stejném období. Na druhé straně lze porovnávat změny autokorelace jednoho páru v různých obdobích. Tak lze sledovat, jak se paměťová schopnost trhu v čase měnila. Tyto informace jsou zajímavé především z hlediska určování počtu historických hodnot, které se budou používat pro predikci. Pokud v tomto duchu bude popisován graf na obrázku č. 14, pak lze tvrdit, že dle intervalů spolehlivosti, jak je definoval Rosenstein [26] je pro predikci užitečných přibližně prvních 135 hodnot. To je na grafu H2 přibližně 12 obchodních dní. Bude-li

chtít být využita většina relevantních informací dostupných na trhu, pak se použije přibližně 450 hodnot z grafu H2, což je přibližně 37 obchodních dní. Při budoucí predikci vývoje takového trhu má tedy smysl použít přibližně 135 až 450 minulých hodnot. Pokud by se použilo hodnot více, docházelo by k používání irelevantních informací nepřinášejících žádný užitek, případně, při použití až 1500 hodnot, k negativnímu zkreslení predikce. Uvedená analýza, resp. výpočet časového zpoždění má tedy smysl i samostatně, vedle aplikace pro výpočet LLE.

Tabulka č. 5: Vypočtená roční časová zpoždění za 4 roky pro různé měnové páry a periody, červeně vyznačená je dramatická meziroční změna zpoždění u páru EURCHF.

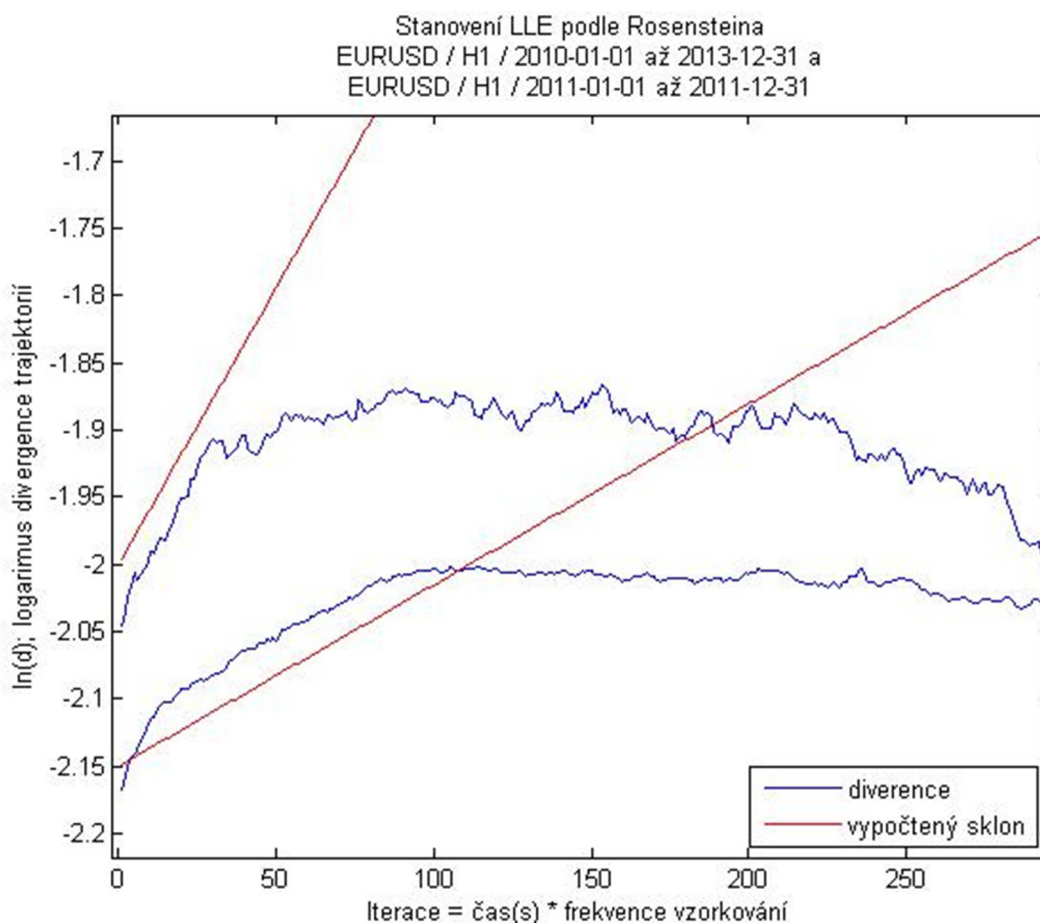
2010	M1	M5	M10	M15	M30	H1	H2	H4	H8	D1
EURUSD	21423	4295	2154	1443	729	377	189	95	48	20
EURGBP	21222	4274	2146	1438	731	387	195	98	50	21
EURCHF	26691	5360	2685	1802	911	486	243	122	62	26
EURCAD	23546	4713	2357	1572	787	400	200	101	51	21
EURJPY	24190	4848	2429	1620	814	413	207	104	53	22
<b>2011</b>										
EURUSD	15469	3105	1556	1041	525	268	135	69	35	15
EURGBP	11160	2248	1128	763	387	205	104	53	27	11
EURCHF	28783	5787	2908	1948	986	517	260	131	66	27
EURCAD	8264	1655	829	553	279	142	72	37	19	8
EURJPY	34056	6838	3432	2288	1151	585	293	147	75	30
<b>2012</b>										
EURUSD	25250	5054	2527	1687	845	424	213	108	55	22
EURGBP	38865	7783	3893	2600	1303	654	328	165	84	33
EURCHF	9859	1996	1001	673	343	183	92	47	25	11
EURCAD	33056	6616	3309	2207	1104	554	277	140	71	29
EURJPY	19721	3946	1974	1316	659	331	166	84	42	17
<b>2013</b>										
EURUSD	16185	3239	1620	1082	543	272	137	69	35	15
EURGBP	8630	1731	867	579	291	147	75	38	20	9
EURCHF	5693	1145	573	385	194	99	51	26	14	6
EURCAD	22829	4572	2288	1528	766	385	193	97	50	22
EURJPY	17044	3410	1706	1138	570	286	144	73	37	16

(Zdroj: vlastní, zpracování Matlab)

Pro výpočet LLE jsou v této chvíli známe veškeré parametry. Vnořená dimenze je stanovena fixně pro všechna analyzovaná data libovolně zvolenými celočíselnými hodnotami z intervalu  $\langle 15; 20 \rangle$ , příslušná časová zpoždění udává tabulka č. 5. Problematika použití Rosensteinova algoritmu na komplexní mnohohodnotový

systemy spočívá v tom, že se během výpočtu vytvoří poměrně rozsáhlá matice divergentních vektorů. Velký počet kalkulovaných hodnot v matici znamená sám o sobě dlouhý výpočetní čas. Ten nepředstavuje hlavní problém. Problém je, že (zjednodušeně řečeno) jeden z rozměrů matice musí být roven násobku časového zpoždění (time lag) a vnořené dimenze. Tato hodnota nicméně nemůže být větší, než počet dostupných hodnot časové řady. V případě známých popsanych systémů v tom není žádný problém, neboť  $d \cdot J$  se v případě Henónova atraktoru s hodnotami  $J = 11$ ,  $d = 2$  rovná 22. Tedy délka časové řady musí být pro možný výpočet LLE uvažovaným algoritmem alespoň 22 hodnot. V případě komplexního systému je ale situace jiná. Při minimální uvažované dimenzi  $d = 15$  a časovém zpoždění páru EURUSD v roce 2011 periody H1  $J = 268$ , je minimální délka časové řady 4020 hodnot. Najít tak dlouhou časovou řadu pro EURUSD, 2011, H1 sice problém ještě není (řada má délku 6237 hodnot), ale například pro EURUSD, 2012, H4 už toto nelze, neboť řada s těmito parametry je dlouhá 1560 hodnot, ale požadovaná minimální délka je  $108 \cdot 15 = 1620$  hodnot.

Graf na obrázku č. 15 zachycuje rozdíly v divergenci trajektorií při použití různě dlouhých intervalů (hodnoty odečtené ze svislé osy nelze brát absolutně, měřítko bylo upraveno pro účely grafického zobrazení; pro LLE je podstatný pouze sklon lineárního úseku). Ten je pro delší časovou řadu roven **0,014**, pro kratší potom **0,031**. Toto jsou potom dle Rosensteinovy metody hodnoty největších Lyapunonových exponentů odpovídajících chaotických systémů.



Obrázek č. 15: Finální graf Rosensteinovy metody určení LLE  
(Zdroj: vlastní, zpracování Matlab)

#### 4.7 Užití získaných dat


Výsledkem analytické části práce je získání obecných fraktálních a chaotických charakteristik odpovídajících systémů (angličtina v tomto směru používá výstižný termín „underlying system“) a jejich použití pro konstrukci predikčního modelu. Každý takový model disponuje určitým počtem parametrů, které je pro správnou funkci modelu nezbytné optimalizovat. I když je použita heuristická optimalizace, například některým z genetických algoritmů, je často výpočetní náročnost i tak příliš vysoká. Ke snížení počtu volných parametrů nebo snížení jejich rozsahu lze použít právě výsledků získaných předběžnou analýzou.

V práci jsou prozkoumány tři rozdílné predikční přístupy založené na poznacích získaných provedenou analýzou. První z nich je využití hodnoty Hurstova exponentu spolu s indikátorem technické analýzy založeným na klouzavém průměru. Tento postup

označil už Mitra [23] za přínosný, když ukázal, že ziskovost strategie statisticky významně koreluje s  $H$ . Za tímto účelem je v práci použito indikátoru MACD s optimalizovanými parametry. Druhý přístup využívá opět Hurstova exponentu, avšak je založen na predikční schopnosti dynamických neuronových sítí. Třetím způsobem je využití Zhangovy metody predikce [54] za použití vlastností chaotických atraktorů a Lyapunovova exponentu. Každá ze tří metod predikce je popsána a její úspěšnost je demonstrována na odpovídající ekvity křivce obchodního účtu.

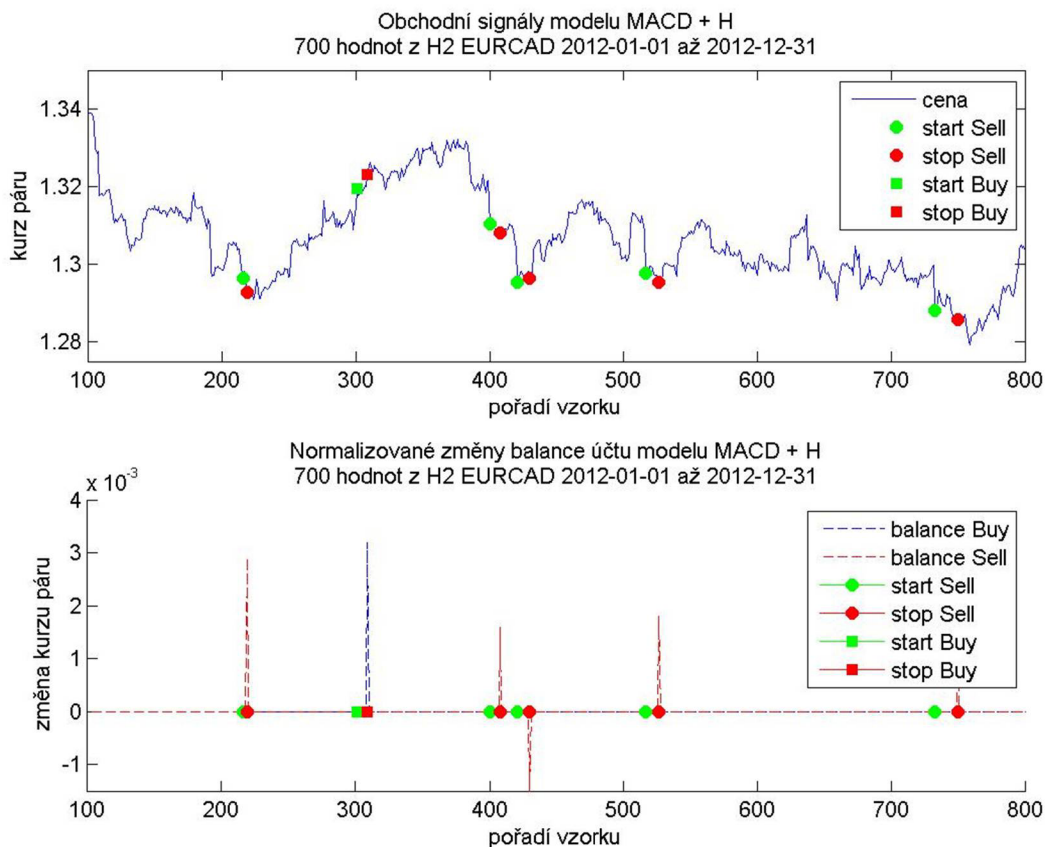
#### 4.7.1 Simulace obchodování – MACD + H

První predikční model lze zařadit do kategorie standardních metod používaných v technické analýze. Model prochází iterativně celou předloženou časovou řadu a obchoduje na základě chování daných indikátorů. Běžný MACD (9; 26) indikátor je použit pro tvorbu obchodních signálů. Pro určení spolehlivosti je zaveden plovoucí Hurstův exponent počítaný za 200 kroků časové řady a momentum indikátor pro měření síly křížení. Systém vyhodnocuje podle nastavených pravidel, zda obchod otevře (křížení signálů, hodnota  $H$  v dané iteraci, síla pohybu kurzu) a podle dalších pravidel, zda obchod zavře (zpětné křížení, hodnoty *stopLoss* a *takeProfit*). Parametry pravidel jsou určeny pomocí globální optimalizace GA toolboxem Matlabu, přičemž se v dále demonstrované verzi optimalizují pouze parametry indikátoru momentum a hodnoty *stopLoss* a *takeProfit*. Je tomu tak proto, že prahová hodnota Hurstova exponentu při optimalizaci vykazovala neustále snahu o přechod do antipersistentních hodnot (pod 0,50), což vedlo ke zcela náhodným výsledkům predikce. Z toho důvodu bylo rozhodnuto, že obchodní seance by se měla otevřít tehdy, když Hurstův exponent dosahuje hodnoty alespoň 0,55. Délka časové řady, z níž je plovoucí  $H$  počítán, je pevně nastavena na hodnotu 200 proto, že užitím delšího časového úseku dochází ke konvergenci hodnoty plovoucího  $H$  k hodnotě 0,50. Ta je z podstaty indikátoru pro predikci nepoužitelná. Kratší časová řada nemůže být použita z důvodu omezené přesnosti samotného stanovení  $H$  pomocí funkce `genhurst()`.



Obrázek č. 16: Ekvity křivka predikčního modelu MACD + H  
 (Zdroj: vlastní, zpracování Matlab)

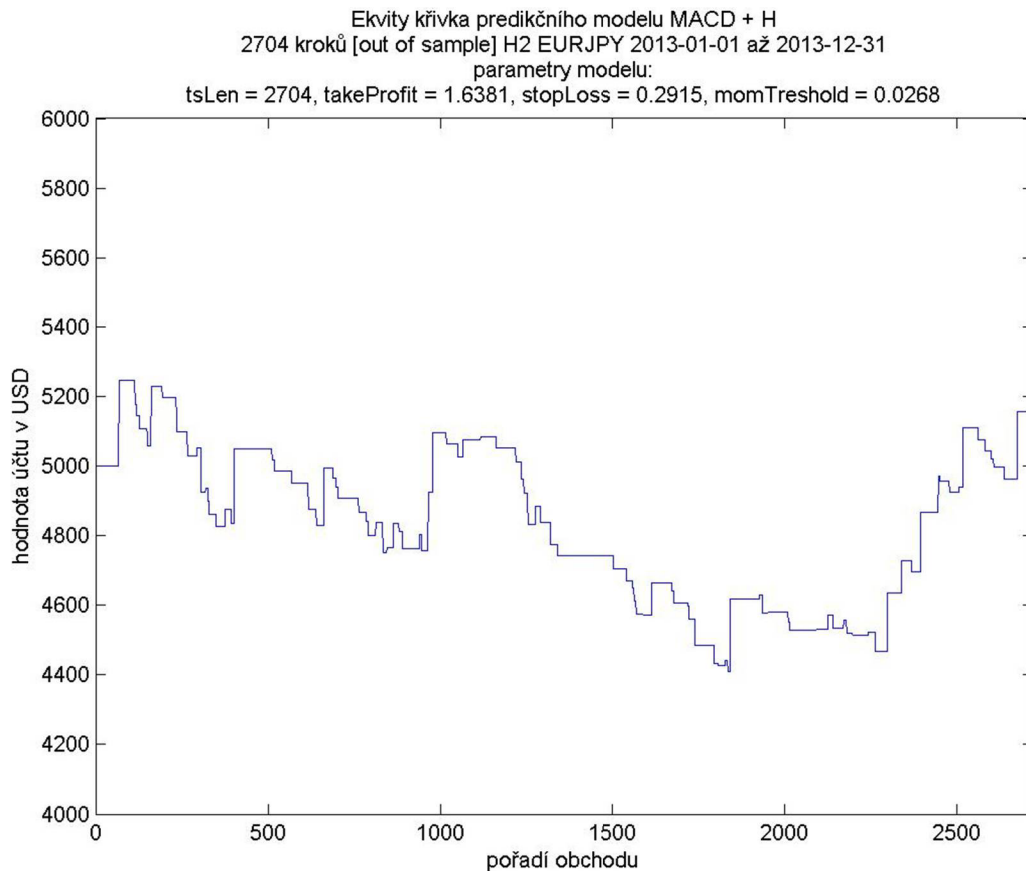
Dle ekvity křivky na obrázku č. 16 je zřejmé, že během sledovaného období strategie provedla celkem 8 obchodů, z toho je 6 ziskových (vzestupné hrany) a 2 ztrátové (sestupné hrany). Ekvity křivka je zjednodušená – nezahrnuje informaci o změnách hodnoty účtu v době, kdy byl nějaký obchod otevřen. Ukazuje pouze hodnotu účtu v době ukončení obchodu. Viditelné jsou tak pouze difference jednotlivých obchodů – zda byly kladné, či záporné, tedy, zda byl obchod ziskový, či ztrátový a o kolik.



Obrázek č. 17: Průběh šesti obchodů během roku 2012  
(Zdroj: vlastní, zpracování Matlab)

Představený obchodní model MACD + H má typicky dvě fáze ladění. První je optimalizace modelu na dostupných datech za účelem získání vhodných vstupních parametrů. Druhou fází je out of sample analýza neboli simulace reálného použití modelu na budoucích datech. Vysoká predikční úspěšnost modelu je dána velmi striktně nastavenými parametry. Ty, jak je vidět z uvedených obrázků, umožní pouze 8 krátkých obchodů ročně. I když je jejich úspěšnost vysoká (75%), nezaručují obecně nejlepší budoucí výsledky. Striktnost modelu se dá ovlivňovat především hodnotou *momThreshold* a staticky nastaveným prahem Hurstova exponentu. Out of sample analýza prokázala, že v celém roce 2013 nemusí trh ani jednou nabídnout tak příznivé podmínky, aby splnily příliš striktně nastavené parametry. Z toho důvodu byly parametry uvolněny a optimalizace provedena znovu. To vedlo k nárůstu počtu obchodů, ale též bohužel i ke snížení predikční úspěšnosti. Ta klesla na přibližně 55 – 60%, přičemž toto se v out of sample projevilo nulovým nebo nízkým zhodnocením počátečního vkladu páru EURCAD. Mírně ziskový se však i při out of sample ukázal

pár EURJPY. Za obrázku č. 18 je pak vidět out of sample vývoj odpovídající ekvity křivky.



Obrázek č. 18: Out of sample ekvity křivka MACD + H modelu roku 2013  
(Zdroj: vlastní, zpracování Matlab)

Jednoduchý obchodní model využívající postupů technické analýzy využívá kromě dvou běžně používaných indikátorů MACD a momentum třetí, tzv. plovoucí Hurstův exponent. Během optimalizace vykazuje velice dobré výsledky díky vysokému podílu ziskových obchodů. Na druhé straně při out of sample analýze dochází k propadu predikční úspěšnosti, což má za následek pouze mírnou ziskovost (jednotky %). Model MACD + H jako celek není příliš vhodný k samostatnému použití. Při striktněji nastavených parametrech by se však dal použít jako filtr příznivých tržních situací.



### 4.7.3 Simulace obchodování – predikční modely NAR(X) + H (obecné parametry)

Druhý predikční přístup využívá opět Hurstova exponentu, avšak ve spojení s dynamickou neuronovou sítí.

Predikční modely založené na neuronové síti mají obecně tyto parametry:

- Architektura sítě.
- Parametry vycházející ze specifické architektury.
- Velikost sítě.
- Metoda trénování.
- Input data.
- Target data.
- Metoda predikce.

Každý z parametrů má obrovské množství možných variant, proto je vhodné při konstrukci modelu parametry rozdělit do 3 skupin. První skupinou (I.) budou parametry určené zvolenou metodou. Druhá skupina (II.) obsahuje parametry volné, pro jejichž správné určení bude použita optimalizace s jediným kritériem (účelovou funkcí). Třetí skupinou (III.) jsou parametry volné, avšak omezené. Zvolená metoda s nimi pracuje jako s volnými, lze je při aplikaci jistých pravidel vypočítat či nějak jinak stanovit. Tím se podstatně snižuje výpočetní náročnost celého optimalizačního procesu. Tabulka č. 6 uvádí klasifikaci parametrů včetně jejich hodnot v uvažované úloze.

Tabulka č. 6: Kategorie a hodnoty parametrů predikčního modelu

Kategorie	Název	Hodnota	Sk.
Architektura sítě	Typ sítě	NAR	I.
Spec. parametry	delay	cíl optimalizace	II.
Velikost sítě	Počet vrstev	2 – dáno typem sítě	I.
	Počet neuronů	cíl optimalizace	II.
Metoda trénování	Učící algoritmus	trainlm() – obecně platné	I.
Input data	-	dle sítě nedefinované	I.
Target data	Rozdělení dat	70/15/15 – defaultní	I.
	Časový rozsah	2010-01-01 až 2013-12-31	I.
	Měnový pár	stanoví se analýzou	III.
	Perioda	stanoví se analýzou	III.
	Délka vektoru	stanoví se analýzou	III.
Metoda predikce	Počet kroků predikce	stanoví se analýzou	III.
	Indikátor	stanoví se analýzou	III.
	Parametry indikátoru	cíl optimalizace	II.

(Zdroj: vlastní)

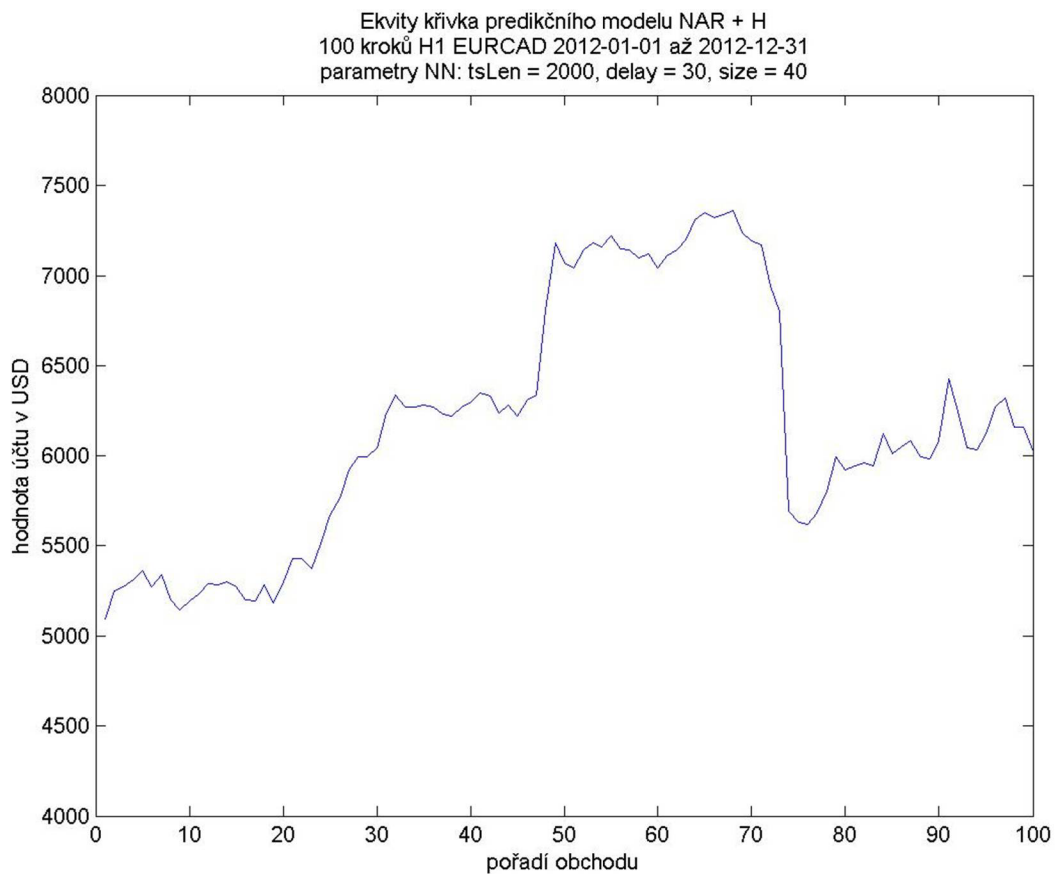
Užitím pevně stanovených hodnot skupiny I. a výsledků analytické části lze postupně doplňovat hodnoty parametrů skupiny III. Jako nejstabilnější měnové páry pro zvolenou metodu se ukázaly **EURCHF** a **EURCAD**. Vhodné periody v závislosti na jejich fraktálním charakteru, časovém zpoždění a časovém rozsahu jsou **H1** a **H2**. Délka vektoru je určena mírou autokorelace časové řady. Pro zadané parametry autokorelace mizí přibližně za **60 – 80 dní**, tedy 1440 – 1920 hodnot H1, resp. 720 – 920 hodnot H2. Počet kroků predikce je dán jednak architekturou sítě (NAR je typickou regresní NN s jedním neuronem ve výstupní vrstvě, tedy jedinou predikovanou hodnotou) a růstem chyby v systému. Jelikož chyba roste přibližně rychlostí  $e^{0,04} \cong 1,041$  a počáteční chyba může mít velikost  $\pm 0,5$  pipu ( $\pm 0,00005$ ), je predikce z hlediska informací dostupných ve výstupu systému (časové řady) možná na přibližně 18 kroků. Tehdy chyba přesáhne hodnotu  $\pm 1$  pip a po přibližně 60 krocích i hodnotu 6 pipů, což zpravidla „přehluší“ i aktuální spread. Z uvedeného plyne, že by se model měl ladit nejpozději každých 20 až 60 kroků. A to nejen přidáním nově dostupných hodnot řady, ale i opakováním optimalizace ostatních parametrů. Jako vhodný indikátor pro predikci se z analýzy korelace jeho hodnoty a ziskovosti strategie ukázal plovoucí **Hurstův exponent**. I když není sám schopen vydávat obchodní signály, je použitelný na zpřesnění směru trendu.

#### **4.7.4 Simulace obchodování – NAR + H**

Při tvorbě modelu bylo přistoupeno nejdříve ke standardnímu využití nejjednoduššího typu dynamické regresní sítě NAR. Ta byla naučena na předložené časové řadě a měla predikovat jeden krok dopředu za splnění podmínky vysoké hodnoty Hurstova exponentu. Pevné parametry byly zadány a pro určení zbylých bylo přistoupeno k nelineární heuristické optimalizaci pomocí GO toolboxu Matlabu užitím defaultního nastavení genetických algoritmů. V této fázi se však vyskytl problém, neboť se projevila fundamentální vlastnost neuronových sítí. Ty jsou obecně silně nelineárním systémem, který při svém vzniku náhodně generuje počáteční hodnoty synaptických vah v jednotlivých vrstvách. Jak je síť učena na předložených datech, váhy se přizpůsobují s cílem minimalizovat rozdíl mezi výstupem a vstupem. To nicméně způsobuje, že i při použití stejných dat dochází k různým výsledkům. Síť se někdy naučí lépe, někdy hůře. Při obecné aplikaci jediné sítě tato vlastnost není problém. Problémem se stává ve

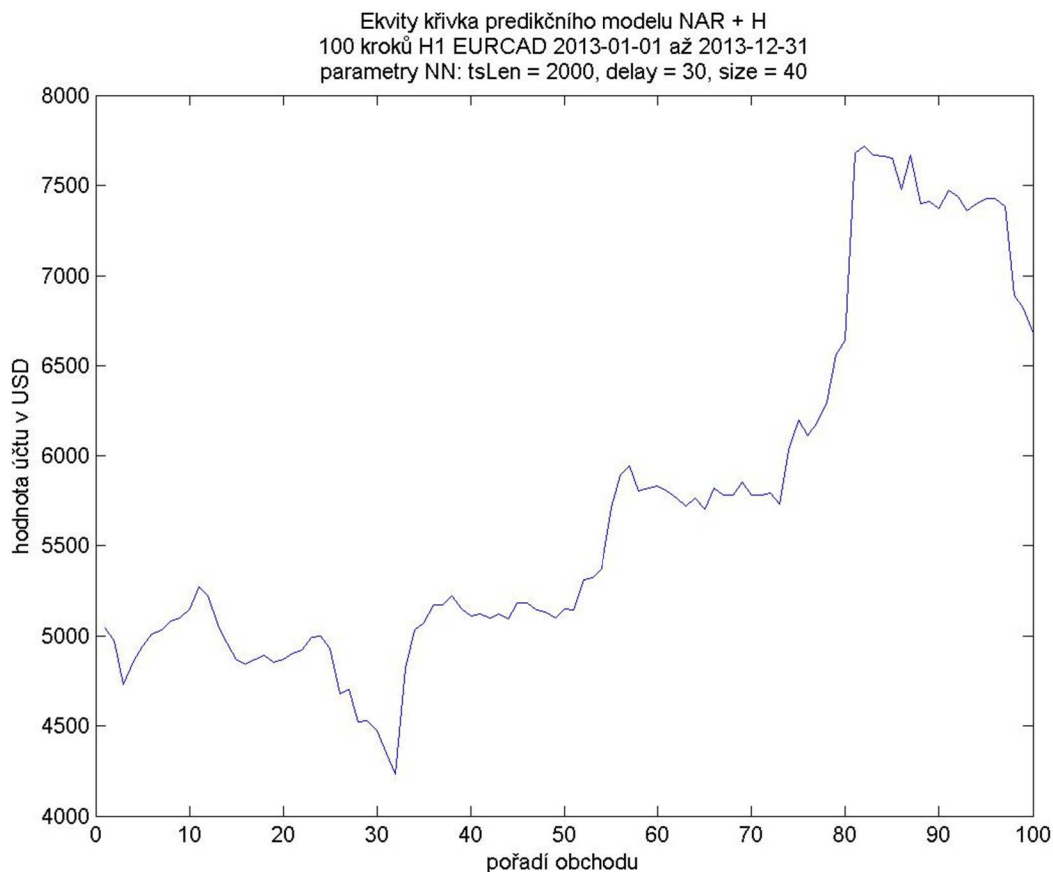
chvíli, kdy se síť snaží uživatel optimalizovat, např. pomocí genetických algoritmů. Přesnost výstupu ke vstupu je brána jako účelová funkce optimalizační úlohy při měnících se parametrech. Optimalizační algoritmus tak hledá změnou parametrů stabilní bod ve stavovém prostoru, který bude globálním (nebo alespoň lokálním) optimem. Důležité je poznamenat, že neuronová síť musí být při každé iteraci optimalizace resetována, tedy vrácena do počátečního nenatrénovaného stavu. To ovšem znamená opětné vytvoření sítě a náhodně generování nových synaptických vah. Ty způsobí změnu vnitřních parametrů sítě a při stejných optimalizačních parametrech změni hodnotu výstupu – hodnotu účelové funkce. Výsledkem tohoto problému je fakt, že optimalizační algoritmus nedokáže nalézt stabilní bod ve stavovém prostoru, neboť hodnota účelové funkce se mění i bez změny optimalizovaných parametrů.

Popsaný problém byl řešen snahou o nalezení parametrů uživatelem, to se částečně podařilo, nicméně tento výsledek nelze brát za objektivně optimální. Predikce sítě původně dosahovala značné míry nestability a výsledná ekvity křivka na původních datech bohužel nevykazovala dostatečně stabilní rostoucí průběh pro použití jako samostatný obchodní model.



Obrázek č. 19: Ekvity křivka predikčního modelu NAR + H  
(Zdroj: vlastní, zpracování Matlab)

O něco lepší výsledek vykazovala predikce při stejných parametrech, avšak během roku 2013 na obrázku č. 20. Zde je nevýhodou drawdown po prvních několika krocích o velikosti téměř 1000 USD. Ten je naštěstí vyrovnán následným trojitým správným určením směru pohybu.



Obrázek č. 20: Ekvity křivka predikčního modelu NAR + H  
(Zdroj: vlastní, zpracování Matlab)

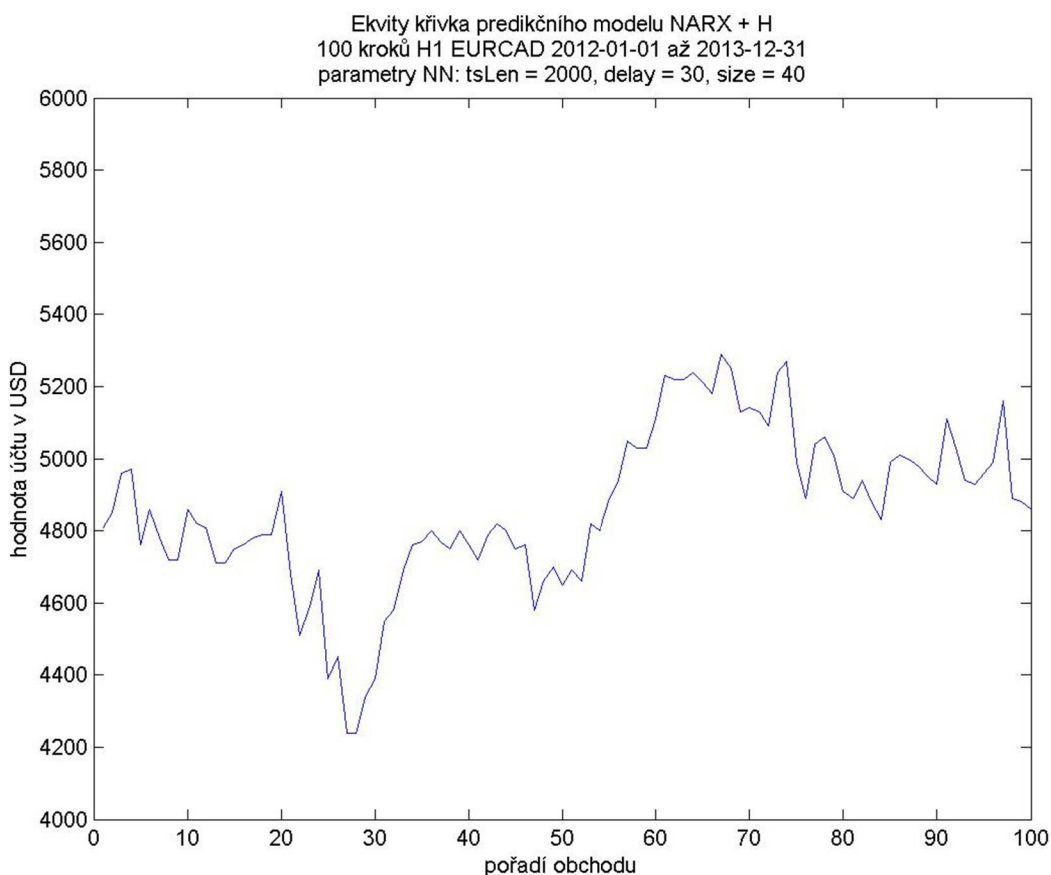
Lze konstatovat, že strategie založená na NAR síti a Hurstově exponentu vykazuje kladné, i když částečně nestabilní výsledky. Důležité je připomenout, že výrazné výkyvy ekvity křivky má na svědomí velký objem obchodovaných finančních prostředků. Je počítáno s obchodování celého 1 lotu s finanční pákou 100:1. Při nižší páce nebo menším objemu může být obchodování podstatně méně rizikové, přičemž pravděpodobnost ziskového obchodu nebude nijak ovlivněna.

#### 4.7.5 Simulace obchodování – NARX + H

Hurstův exponent se ukázal jako predikčně užitečný nejen v uvedené analýze, ale i v mnoha jiných aplikacích, proto jeho použití bylo znovu zopakováno na podobné, avšak mírně komplexnější NARX síti. X v názvu značí možnost vložení vektorů exogenních proměnných. Těmi mohou být například hodnoty plovoucího Hurstova exponentu. Síť by měla dle teorie mít schopnost absorbovat implicitní informaci obsaženou v H přímo ve svém modelu a výstupem by měl být rovnou nákupní či

prodejní signál. Stejně jako v případě NAR, není ani u NARX možná heuristická optimalizace, neboť neovlivnitelná proměnlivost účelové funkce přetrvává.

I když by měla být NARX síť teoreticky dokonalejší, než NAR, je faktem, kterého si všimli i jiní autoři [37], že nevhodně zvolené exogenní vstupy mohou mít značný negativní vliv na predikční schopnost sítě. V případě plovoucího Hurstova exponentu je tomu přesně tak. Vysvětlením tohoto fenoménu může být velice silně antipersistentní ( $H \cong 0,1$ ) podstata hodnoty plovoucího  $H$ . Časová řada vstupu tedy silně fluktuuje a neuronová síť není schopna zachytit žádnou přímou spojitost mezi jejími hodnotami a hodnotami kurzu.



Obrázek č. 21: Ekvity křivka predikčního modelu NARX + H  
(Zdroj: vlastní, zpracování Matlab)

Predikce s jinými parametry měla zpravidla ještě horší výsledky, než ty uvedené na grafu ekvity křivky na obrázku č. 21. Nejen že se kapitál na obrázku nijak zvlášť nezhodnotil, došlo navíc k počátečnímu poklesu o více než 800 USD. Graf jako celek vypadá podstatně více „chaoticky“, model v jednom kroku vydělá a v dalším prodělá

stejnou částku. To se objevuje prakticky v celé délce obchodní seance. Nelze vypořádat žádný pozitivní trend a výtěžky působí mnohem více náhodně, než je tomu u NAR + H modelu.

I když by se na první pohled zdálo, že dokonalejší model bude pro predikci vhodnější, z uvedených testovacích obchodů je zřejmé, že tomu tak není. NARX model nedokáže absorbovat antipersistentní chování vstupu a jeho predikce je spíše náhodná. Z uvedených dvou modelů je proto vhodnější použít jednodušší NAR + H model.

K oběma modelům založeným na neuronových sítích je nutné závěrem poznamenat, že logika jejich obchodování má charakter out of sample. Je tomu tak proto, že neuronová síť je naučena na  $N = tsLen$  hodnot časové řady a odstraněním zpoždění vstupní vrstvy predikuje jeden budoucí krok. Jakmile uplyne zvolená doba  $t = H1$  (1 hodina), na vstupu neuronové sítě se objeví nová hodnota. Je vytvořena nová neuronová síť, která je opět naučena na  $N$  hodnot, avšak časové posunutých o  $t$ . Výstupem je opět jediná predikovaná hodnota kurzu. Celý proces se opakuje dle libosti, v případě uvedených grafů se jedná o 100 iterací. Vytvoření a trénování sítě je výpočetně extrémně náročný proces, a jelikož se provádí v každé iteraci znovu, je pro ilustraci postačujících právě jen 100 iterací.

$$\begin{aligned} y(N + 1) &= f(x(1), x(2), \dots, x(N)) \\ y(N + 2) &= f(x(2), x(3), \dots, x(N + 1)) \\ &\dots \\ y(N + M) &= f(x(M), x(M + 1), \dots, x(N + M - 1)), \quad \text{kde:} \end{aligned} \tag{18}$$

$x(i) \in X, y(i) \in Y, X \dots$  vstupní vektor,  $Y \dots$  výstupní vektor

$N \dots$  délka vstupního vektoru

$M \dots$  délka výstupního vektoru, počet predikovaných hodnot

$f(X) \dots$  transformační funkce NN včetně time delay

#### 4.7.6 Predikční model – chaotický atraktor a LLE

Poslední model je založen na využití chaotických charakteristik časové řady. Dle popsaného Zhangova algoritmu a publikované práce [54] je zřejmé, že tato predikce je

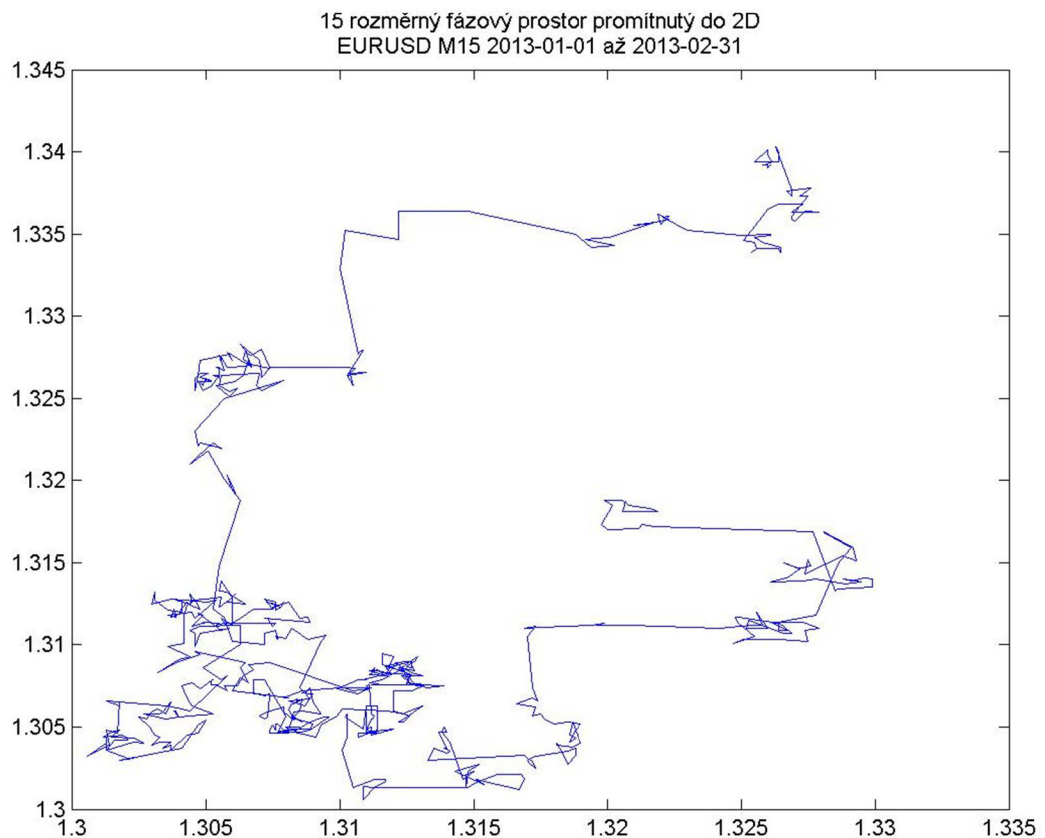
úspěšná především na systémech tvořící kompaktní atraktor. Je tomu tak proto, že metoda se snaží předpovídat vývoj trajektorie ve fázovém prostoru na základě LLE, avšak s implicitně zahrnutou podmínkou podobného tvaru orbit trajektorie. Jestliže tomu tak není, pak metoda dokáže sice určit očekávanou vzdálenost predikovaného bodu od posledního známého bodu (za pomoci růstu chyby v systému), ale už nedokáže určit směr v  $D$ -dimenzionálním fázovém prostoru. Tento  $D$ -rozměrný „směr“ se za použití embeddingu redukuje na dvě alternativní hodnoty – posun poslední souřadnice v kladném nebo záporném směru. „Zbytek“ směru je určen analogií k předchozí nejbližší hodnotě. To je nicméně užitečné pouze v případě, že nejbližší hodnota udržuje „správný“ směr (směr podobný jako hodnota predikovaná). Toto platí právě v systémech s jasně rozpoznatelnými atraktory, jejichž hodnoty se vždy pohybují po určitý čas „podobným“ směrem. U systémů jako je Henónův, Lorenzův nebo Rösslerův jsou atraktory viditelně souvislé a „cyklické“ (ve smyslu podobnosti jednotlivých orbit). Trochu jiný případ je systém dvojitého matematického kyvadla. Jeho orbity nejsou již tak jasně podobné, lze však vyzorovat, že se v určitých úsecích pohybují „podobným“ směrem. Proto by je Zhangovou metodou bylo možné predikovat. Zde však vyvstává problém vzorkování. Pokud nebude vzorkování dostatečně podrobné, pak se ztratí informace o vývoji trajektorie, směry dvou po sobě jdoucích bodů nebudou „podobné“ a predikce nebude možná. Právě určení dostatečně vysoké vzorkovací frekvence pro splnění Nyquist-Shannonovy podmínky je problém společný jak u modelu dvojitého matematického kyvadla, tak u modelu finančních, resp. devizových trhů.

Ukazuje se, že při predikci vývoje trhů je to právě nízká vzorkovací frekvence způsobená nedostatkem dat, která má za následek nemožnost konstrukce trajektorie, nalezení dvou dostatečně „podobných“ bodů a následné predikce. Bližší analýza časových řad ukazuje, že optimální vzorkovací frekvence by se pravděpodobně musela limitně blížit nekonečnu. Tento koncept je bohužel neuchopitelný pomocí Zhangovy metody a ta proto není vhodná pro použití jako samostatný predikční model, který by na základě konstrukce fázového prostoru spolehlivě určil směr vývoje kurzu.

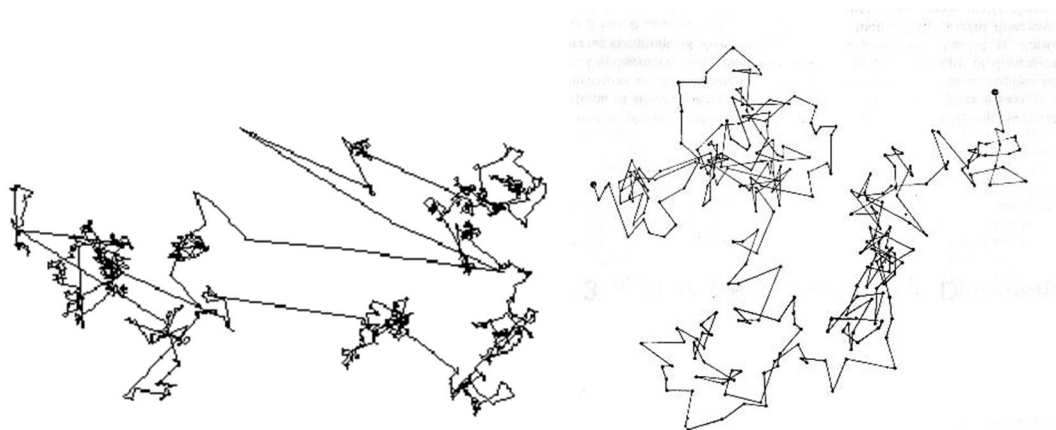
$D$ -rozměrný fázový prostor však lze promítnout do 2D a zkoumat jej z jeho grafické reprezentace. Na obrázku č. 22 lze část takového prostoru vidět. V grafu lze spatřit



oblasti „rychlého pohybu“ a oblasti „zauzlení“. Toto chování se zdá náhodné, což by značilo Brownův pohyb (případně fraktální Brownův pohyb). Ten ale vypadá odlišně, nevyskytují se tam uvedené dva druhy oblastí. Fázový prostor je spíše podobný jiné alternativě procesu náhodné procházky, tzv. Lévyho letu (Lévy flight). Srovnání Brownova pohybu a Lévyho letu je jasně demonstrováno na obrázku č. 23. Z uvedeného srovnání je vidět, že fázový prostor připomíná spíše Lévyho let. Tento poznatek může být využit při dalším výzkumu finančních, resp. devizových trhů.

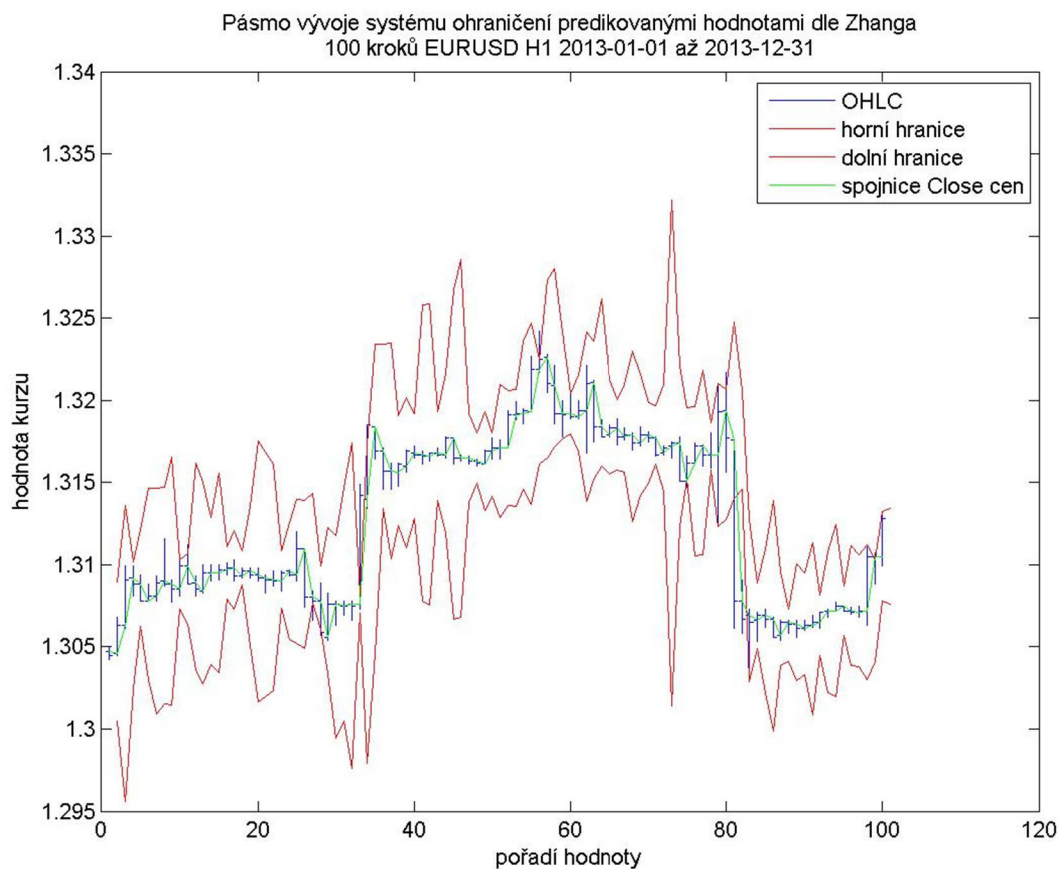


Obrázek č. 22: Zkonstruovaný fázový prostor promítnutý do 2D  
(Zdroj: vlastní, zpracování Matlab)



Obrázek č. 23: Srovnání Lévyho letu (vlevo) s Brownovým pohybem (vpravo)  
(Zdroj: [56])

Predikované hodnoty mohou být zároveň použity jako hraniční body pásma, ve kterém se měnový kurz pohybuje. Na obrázku č. 24 jsou tato pásma vyznačena červeně spolu s OHLC reprezentací kurzu.



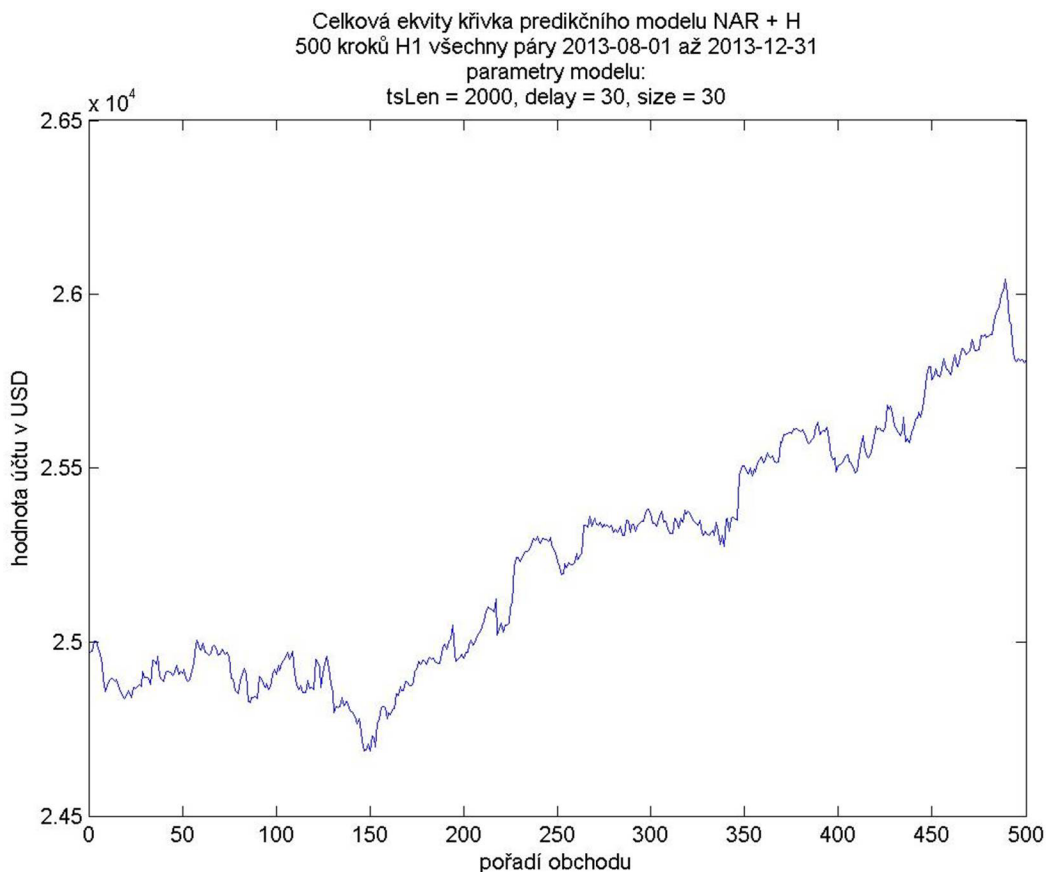
Obrázek č. 24: Pásma vývoje kurzu dle Zhangovy metody predikce  
(Zdroj: vlastní, zpracování Matlab)

Pásma byla konfrontována s několika indikátory technické analýzy a nebyla mezi nimi zjištěna žádná podobnost. Toho by mohlo být využito při tvorbě nových obchodních strategií, neboť by tento nový indikátor (dají-li se tak hranice chápat) mohl přinést do strategie novou informaci.

#### **4.7.7 Shrnutí a výběr nejvhodnějšího modelu**

Z uvedených modelů se za predikční v pravém slova smyslu dají označit pouze dva první, tedy modely MACD + H, NAR(X) + H. Poslední model neprokázal predikční schopnosti, které by se daly přímo využít při reálném obchodování (i když není vyloučeno, že na jeho základě by bylo možné vytvořit ziskovou predikční strategii).

Jako dlouhodobě nejúspěšnější se ukázal predikční model NAR + H i přes jeho relativně vysokou nestabilitu. Popsané výkyvy v hodnotě balance účtu byly zmírněny pomocí diverzifikace a snížení obchodovaného množství finančních prostředků. Konkrétně bylo obchodováno více (všech 5) měnových párů současně s finanční pákou 1:100, ale množstvím pouze 0,1 lotu. Průběhy jednotlivých ekvity křivek jsou zobrazeny v příloze č. 2, celkový vývoj balance účtu je potom uveden na obrázku č. 25.



Obrázek č. 25: Celková ekvity křivka predikčního modelu NAR + H  
(Zdroj: vlastní, zpracování Matlab)

Simulace obchodování obsahuje „pouze“ ilustračních 500 kroků. Složitost výpočtu však bohužel způsobuje, že i přesto se výpočetní doba pohybovala okolo 7-8 hodin při plném využití výkonu osmi výpočetních vláken procesoru Intel Core i7 (Haswell) s taktom 3,40 GHz. Algoritmus totiž provádí opakovanou tvorbu a učení 2500 poměrně velkých neuronových sítí. Z obrázku č. 25 je však vidět i po počátečním „zaváhání“ stabilní zhodnocování balance účtu.

Míru zhodnocení lze vypočítat například prostým vydělením konečné hodnoty účtu hodnotou počáteční. To v případě obrázku č. 25 znamená  $25813/25000 = 1,0325$ . Tedy zhodnocení účtu v této základní variantě je přibližně 3,25% za 500 obchodních kroků (500 obchodních hodin). Tato základní hodnota však charakterizuje pouze fakt, že predikční model je jako celek rentabilní. Ziskovost modelu nelze přepočítávat na roční hodnoty, protože nemusí být (a pravděpodobně ani nebude) konstantní v dlouhém ročním období. Lze však pojmut představenou obchodní strategii jako rizikový

investiční projekt, přičemž počáteční vložený kapitál bude libovolné výše (minimálně však při aktuálním nastavení asi 5000 USD), délka projektu bude 500 obchodních hodin (přibližně 25 kalendářních dní) a zisk zmíněné 3,25% vloženého kapitálu. Pokud by bylo žádoucí vyšší zhodnocení, lze jednoduše zvýšit obchodované množství finančních prostředků (z 0,1 lotu například zdvojnásobením na 0,2 lotu). To by mělo za následek přibližné zdvojnásobení ziskovosti. Negativně by se to však podepsalo na případné ztrátě, kterou by to pochopitelně též přibližně zdvojnásobilo. Rozhodnutí o množství obchodovaných finančních prostředků (či síle finanční páky) závisí na tom, jak spolehlivě bude strategie schopna dlouhodobě tvořit zisk, případně, jaký je postoj spekulanta k riziku.

V uvažovaném investičním projektu by mělo být též vyčísleno riziko, že se zhodnocení výrazně odchýlí od očekávané hodnoty (především negativně). To lze určit například opakovanou simulací na jiných datech či zjednodušeně rozptylem ziskovosti strategie na jednotlivých párech. Právě druhý postup je zvolen a střední hodnota finálního zůstatku balance účtu jednotlivých párů je 5162 USD, přičemž směrodatná odchylka je přibližně 164 USD. Pokud by se tedy ziskovost jednotlivých párů chovala podle normálního rozdělení, lze říct, že přibližně s pravděpodobností 0,83 bude obchodování páru ziskové. A pokud by toto platilo pro všechny páry, pak pravděpodobnost, že budou všechny páry ztrátové, že velice malá. Autor se v tuto chvíli úmyslně vyhýbá vyčíslení přesné hodnoty pravděpodobnosti ziskovosti celé strategie (všech párů dohromady), poněvadž nezná vzájemnou závislost chování párů. Pro toto krátké zhodnocení však postačí konstatovat, že rizikovost strategie se zřejmě snižuje diverzifikací, tedy obchodováním několika párů najednou. Proto je vhodné dostupný kapitál rozdělit mezi ty páry, které simulace označí za potenciálně ziskové.

## 4.8 Přínosy a omezení

Na představené výsledky práce lze pohlížet ve dvou rovinách. Na jedné straně byly v práci představeny nové, neortodoxní **metody analýzy časových řad**. Bylo popsáno jejich teoretické pozadí a použité algoritmy. Tyto analytické metody byly aplikovány na reálné **problematicke analýzy devizových trhů**, přičemž byly zohledněny a popsány jejich omezení v této aplikaci. Konkrétně lze zmínit **Hurstovu fraktální** [18] či

**Rosensteinovu** [29] (případně Gaovu [46]) **chaotickou charakteristiku**. Především druhá zmíněná byla popsána detailně se všemi úskalími a předběžnými výpočty, neboť její stanovení není triviálním problémem. Přínos je možné spatřit též v aplikaci metody na devizové trhy. Ta se v literatuře objevuje velice zřídka, výjimečně je tato problematika diskutována vědci převážně z oblasti východní Asie. Autor si nicméně není vědom existující analýzy pro měnové páry eura. Uvedené analytické metody jsou použitelné na **libovolná experimentální data** získaná jako výstupy neznámého systému. Díky nim lze tento systém částečně charakterizovat a odhadnout tak jeho chování.

Na druhé straně práce představuje **reálně uchopitelné a použitelné predikční modely** využívající právě závěrů provedených analýz. Tyto modely jsou srovnány jak z hlediska teoretického pozadí, tak podle aplikovatelnosti na reálné situace. Je vybrán nejvhodnější model (model dynamické neuronové sítě využívající Hurstovu fraktální charakteristiku, označovaný jako **NAR + H**) a simulací reálného out of sample obchodování je stanovena jeho přibližná ziskovost a rizikovost. Dále je popsán teoreticky velice perspektivní **predikční model založený na Zhangově metodě extrapolace fázového prostoru** [54]. Původní model je dále teoreticky rozpracován a je zjištěno úskalí, které bohužel znemožňuje jeho přímé použití pro predikční účely. Na jeho základě je nicméně **navržen nový indikátor** odlišující se od existujících indikátorů technické analýzy. Zároveň metoda umožňuje **vizualizaci vnitřního chování systému**, která implikuje zajímavý kontrast k široce přijímaným teoriím EMH a FMH. Z konkrétně uchopitelných výsledků práce je třeba zmínit ještě **Matlab knihovnu veškerých použitých funkcí**, která může být publikována prostřednictvím Matlab File Exchange webu [49] pod BSD licenci, případně z ní může být jednoduchým přidáním GUI vytvořen plnohodnotný Matlab toolbox.

Mezi aktuální omezení navržených postupů patří samozřejmě omezení kladená na jednotlivé výpočetní algoritmy. Určení LLE neznámého systému libovolné dimenze je stále teoreticky otevřenou otázkou. Fraktální charakteristiky časových řad mají vypovídací hodnotu pouze při dostatečné délce řady. To klade omezení na navržený plovoucí Hurstův exponent. Problematické je určení optimálních parametrů neuronových sítí v predikčních modelech. Ty totiž mají obrovskou variabilitu a

podstatně ovlivňují kvalitu predikce. V práci zcela chybí diskuze na téma inicializace synaptických vah sítí. Ta právě způsobuje zmíněné potíže s optimalizací parametrů sítě. Navržená Zhangova metoda je pouze teoretický koncept testovaný na modelových případech nejjednodušších chaotických systémů. Není prokázáno, že by mohla (nebo měla) fungovat na libovolně složitých systémech, či systémech s komplexním strange atraktorem. Matlab knihovna funkcí je stavěná přírůstkovou metodou, dalo by se říct ad hoc. Její struktura je pouze hrubě nastíněná, dokumentaci obsahuje základní, na úrovni jednoduchých Matlab funkcí. Implementované funkce nemusí používat vždy nejmodernější nebo nejúspornější algoritmy výpočtu, mohou obsahovat redundantní kód či komentáře. Další omezení mohou plynout ze samotné podstaty problému nebo konkrétní aplikace. Vždy je proto vhodné individuálně zhodnotit možnosti každého použití navržených metod.

#### **4.9 Náměty na budoucí výzkum**

Závěrem by bylo vhodné zmínit oblasti, které by si zasloužily detailnější rozbor. Například určení celého Lyapunovova spektra z experimentálního výstupu libovolného systému je výzvou pro teoretiky zabývající se analýzou časových řad. Hlubší zkoumání analytických či predikčních možností myšlenek teorie chaosu na finančních trzích by mohlo přinést zajímavé konsekvence. Konstrukce a vizualizace fázových prostorů komplexních systémů by mohlo vést k objevení nových typů atraktorů. Znalost atraktoru systému totiž představuje významný krok k porozumění jedné z jeho hlavních charakteristik, totiž jeho stabilitě. Na téma optimální architektury predikčních neuronových sítí by mohl být veden též rozsáhlý výzkum. Zároveň by mohl být rozpracován Zhangův článek [54] s cílem vytvořit přímo aplikovatelný predikční model pro finanční (případně jen devizové) trhy. Jako velice slibný se ukazuje indikátor založený na Zhangově článku. Ten totiž ukazuje teoretické hranice vývoje systému při zachování jeho stávající dynamiky. Může být použit například ve spojení s Gaovým SDLE, kdy bude detekovat anomálie ve vývoji systému a měřit pravděpodobnost jejich výskytu.

## Závěr

Diplomová práce zabývající se možnostmi využití principů umělé inteligence na devizových trzích v úvodu stručně stanovuje své dva hlavní a několik vedlejších cílů. Pro tyto cíle představuje teoretická východiska a charakterizuje současný stav poznání v dané oblasti. Důraz je kladen na aplikace umělé inteligence pro analytické a predikční účely na finančních, resp. devizových trzích.

Jádro práce obsahuje představení neortodoxních analytických a predikčních metod a jejich možné použití na forexovém trhu. Tím je zároveň naplněn primární hlavní cíl práce, neboť mezi těmito metodami **je vybrán nejúspěšnější predikční model**. Konkrétně se jedná o model NAR + H využívající určitého typu dynamické neuronové sítě a hodnoty fraktální charakteristiky předložené časové řady. Jsou popsány výhody tohoto modelu oproti ostatním, přibližně vyčíslena ziskovost, rizikovost a jsou stanovena jeho omezení.

Veškeré predikční modely jsou implementovány ve vývojovém prostředí Matlab podle teoretických předpokladů, stejně jako všechny dílčí analytické algoritmy. Tím je splněn sekundární hlavní cíl práce, neboť je takto **vytvořena Matlab knihovna funkcí** umožňující veškeré provedené analýzy a predikce opakovat. Knihovna je použitelná k obecné analýze předložených časových řad i k simulaci reálného použití predikčních modelů.

Během vlastních návrhů řešení je diskutována problematika předpověditelnosti finančních trhů obecně. Jsou definovány a kalibrovány použité algoritmy, stejně jako je detailně popsán složitý proces stanovení Lyapunovových exponentů systému. Do Matlab knihovny je integrován převodový datový můstek a implementované predikční modely jsou v závěru práce zhodnoceny a porovnány. Tyto a další **dílčí výstupy naplňují definované vedlejší cíle** práce.

Závěrem lze konstatovat, že úvodem stanovené **hlavní a vedlejší cíle byly splněny** v rozsahu nezbytném pro objasnění problematiky, zároveň však takovém, aby nebyl překročen zadaný formát práce. Smyslem práce bylo demonstrovat, že **je možné využít principů AI, resp. teorie chaosu k analýze a predikci devizových trhů**.



## Použitá literatura

- [1] JANÍČEK, P. *Systémové pojetí vybraných oborů pro techniky: Hledání souvislostí*. 1. vydání, 1. sv. Brno: CERM, 2007. 682 s. ISBN 978-80-7204-555-6.
- [2] ROSE, S. P. *Peněžní a kapitálové trhy: Finanční systém ve stále globálnější ekonomice*. 1. vydání. Praha: Victoria Publishing, 1994. 1014 s. ISBN 80-85605-52-X.
- [3] REJNUŠ, O. *Finanční trhy*. 1. vydání. Ostrava: Key Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.
- [4] KODERA, J. a J. MARKOVÁ. *Devizové obchody*. 2. vydání. Brno: CERM, 2001. 212 s. ISBN 80-7265-046-7.
- [5] DURČÁKOVÁ, J. a M. MANDEL. *Mezinárodní finance*. 4. vydání. Praha: Management Press, 2010. 494 s. ISBN 978-80-7261-221-5.
- [6] LEVINSON, M. *The Economist: Guide to Financial Markets*. 4. vydání. London: Profile Books, 2008. 250 s. ISBN 978-1-86197-958-8.
- [7] BANK FOR INTERNATIONAL SETTLEMENTS. *Global Exchange turnover in April 2013*. Švýcarsko, Basel: 2013 [cit. 2013-11-06]. Dostupné z: <http://www.bis.org/publ/rpfx13.htm>
- [8] DOSTÁL, P. *Pokročilé metody rozhodování v podnikatelství a veřejné správě*. 1. vydání. Brno: CERM, 2012. 713 s. ISBN 978-80-7204-798-7.
- [9] DOSTÁL, P. *Pokročilé metody manažerského rozhodování*. 1. vydání. Praha: Grada, 2005. 168 s. ISBN 80-247-1338-1.
- [10] CHENCINER, A. *Séminaire Poincaré XVI 2012*. Poincaré and the Three-Body Problem. Seminář. Paříž: Institut Henri Poincaré, 24-11-2012. s. 45-133 [online]. [cit.2014-01-25]. Dostupné z: [www.bourbaphy.fr/chenciner.pdf](http://www.bourbaphy.fr/chenciner.pdf)
- [11] MANDELBROT, B. *The Fractal Geometry of Nature*. 1. vydání. New York: W. H. Freeman, 1982. 468 s. ISBN 0-7167-1186-9.

- [12] MANDELBROT, B. *Fractals and Chaos: The Mandelbrot Set and Beyond*. 1. vydání. Springer, 2004. 308 s. ISBN 978-0-387-20158-0.
- [13] FALCONER, K. *Fractal Geometry: Mathematical Foundations and Applications*. 2. vydání. J. Wiley & Sons, 2004. 366 s. ISBN 978-0-470-87135-5.
- [14] PEITGEN, H. O. et al. *Chaos and Fractals: New Frontier of Science*. New York: Springer-Verlag, 1992. 984 s. ISBN 0-387-97903-4.
- [15] RUELLE, D. Small Random Perturbations of Dynamical Systems and the Definition of Attractors. *Communications in Mathematical Physics* [online]. 1981, vol. 82, no. 1, s. 137-151 [cit. 2013-11-05]. ISSN 1432-0916. Dostupné z: <http://link.springer.com/article/10.1007/BF01206949>
- [16] MILNOR, J. On the concept of attractor. *Communications in Mathematical Physics* [online]. 1985, vol. 99, no. 2, s. 177-195 [cit. 2013-11-05]. ISSN 1432-0916. Dostupné z: <http://link.springer.com/article/10.1007/BF01212280>
- [17] RUELLE, D a F. TAKENS. On the nature of turbulence. *Communications in Mathematical Physics* [online]. 1971, vol. 20, no. 3, s. 167-192 [cit. 2014-04-21]. ISSN 1432-0916. Dostupné z: <http://link.springer.com/article/10.1007/BF01646553>
- [18] HURST, H. E. Long-term storage capacity of reservoirs. *Transactions of American Society of Civil Engineers*. 1951, vol. 116, s. 770-808. ISSN 0066-0604.
- [19] KLEINOW, T. *Testing continuous time models in financial markets*. Berlin: Humboldt-Universität zu Berlin, Wirtschaftswissenschaftliche Fakultät, 2002. 122 s. [online]. Disertační práce [cit. 2014-01-25]. Dostupné z: <http://edoc.hu-berlin.de/docviews/abstract.php?lang=ger&id=10480>
- [20] MANDELBROT, B. a J. R. WALLIS. Some long-run properties of geophysical records. *Water Resources Research* [online]. 1969, vol. 5, no. 2, s. 321-340 [cit. 2014-01-20]. ISSN 1944-7973. Dostupné z: <http://onlinelibrary.wiley.com/doi/10.1029/WR005i002p00321/abstract>

- [21] MANDELBROT, B. a J. V. van NESS. *Fractional Brownian Motions, fractional noises and applications*. SIAM Review. 1968, vol. 10, no. 4, s. 422-437  
[cit. 2014-01-22]. ISSN 1095-7200. Dostupné z:  
<http://epubs.siam.org/doi/abs/10.1137/1010093>
- [22] ABRY, P. a F. SELLAN. The Wavelet-Based Synthesis for Fractional Brownian Motion Proposed by F. Sellan and Y. Meyer: Remarks and Fast Implementaion. *Applied and Computational Harmonic Analysis* [online]. 1996, vol. 3, no. 4, s. 377-383  
[cit. 2014-01-20]. ISSN 1063-5203. Dostupné z:  
<http://www.sciencedirect.com/science/article/pii/S1063520396900305>
- [23] MITRA, S. K. Is Hurst Exponent Useful in Forecasting Financial Time Series? *Asian Social Sciences* [online]. 2012, vol. 8, no. 8, s. 111-120 [cit. 2014-01-20].  
ISSN 1911-2025. Dostupné z:  
<http://ccsenet.org/journal/index.php/ass/article/view/18513>
- [24] SMITH, L. A. *Chaos: A Very Short Introduction*. Oxford: Oxford University Press, 2007. 180 s. ISBN 978-0-19285-378-3.
- [25] CROSS, M. *Chaos on the Web* [online]. Pasadena: California Institute of Technology, 2000 [cit. 2013-10-28]. Dostupné z:  
[http://www.cmp.caltech.edu/~mcc/Chaos\\_Course/](http://www.cmp.caltech.edu/~mcc/Chaos_Course/)
- [26] WOLF, A. et al. Determining Lyapunov exponents from a time series. *Physica D: Nonlinear Phenomena* [online]. 1985, vol. 16, no. 3, s. 285-317 [cit. 2013-10-24].  
ISSN 0167-2789. Dostupné z:  
<http://www.sciencedirect.com/science/article/pii/0167278985900119>
- [27] BENETTIN, G. et al. Lyapunov Characteristic Exponents for smooth dynamical systems and for hamiltonian systems: A method for computing all of them. *Meccanica* [online]. 1980, vol. 15, no. 1, s. 21-30 [cit. 2013-10-28]. ISSN 1572-9648. Dostupné z:  
<http://link.springer.com/article/10.1007%2F02128237>

- [28] SHIMADA, I. a T. NAGASHIMA. A Numerical Approach to Ergodic Problem of Dissipative Dynamical Systems. *Progress of Theoretical Physics* [online]. 1979, vol. 61, no. 6, s. 1605-1616 [cit. 2013-10-28]. ISSN 1347-4081. Dostupné z: <http://ptp.oxfordjournals.org/content/61/6/1605.full.pdf+html?sid=00c31fcd-5d3c-4539-9b89-04eab663a350>
- [29] ROSENSTEIN, M. T. et al. A practical method for calculating largest Lyapunov exponents from small data sets. *Physica D: Nonlinear Phenomena* [online]. 1993, vol. 65, no. 1-2, s. 117-134 [cit. 2013-10-24]. ISSN 0167-2789. Dostupné z: <http://www.sciencedirect.com/science/article/pii/016727899390009P>
- [30] SATO, et al. Practical Methods of Measuring the Generalized Dimension and the Largest Lyapunov Exponent in High Dimensional Chaotic Systems. *Progress of Theoretical Physics* [online]. 1987, vol. 77, no. 1, s. 1-5 [cit. 2013-10-24]. ISSN 1347-4081. Dostupné z: <http://ptp.oxfordjournals.org/content/77/1/1.full.pdf+html>
- [31] ŠÍMA, J. a R. NERUDA. *Teoretické otázky neuronových sítí*. 1. vydání. Praha: Matfyzpress, 1996. 390 s. ISBN 978-80-8586-318-5.
- [32] VOLNÁ, E. *Neuronové sítě I* [online]. Studijní materiály pro distanční kurz, 2. vydání. Ostrava: Ostravská univerzita v Ostravě, 2008, 86 s. [cit. 2014-01-20]. Dostupné z: [http://www1.osu.cz/~volna/Neuronove\\_site\\_skripta.pdf](http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf)
- [33] VRBA, P. *Využití prostředků umělé inteligence na finančních trzích*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2011. 78 s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.
- [34] PODDIG, T. a H. REHKUGLER. A world model of integrated financial markets using artificial neural networks. *Neurocomputing* [online]. 1996, vol. 10, no. 3, s. 251-273 [cit. 2014-02-24]. ISSN 0925-2312. Dostupné z: <http://www.sciencedirect.com/science/article/pii/0925231296000495#>
- [35] PACELLI, A. et al. An Artificial Neural Network Model to Forecast Exchange Rates. *Journal of Intelligent Learning Systems and Applications* [online]. 2011, vol.3. no. 2a. s. 57-69 [cit. 2014-02-24]. ISSN 2150-8410. Dostupné z: <http://www.scirp.org/journal/PaperInformation.aspx?PaperID=4583>

- [36] GHOSH, A. Comparative study of Financial Time Series Prediction by Artificial Neural Network with Gradient Descent Learning. *Broad Research in Artificial Intelligence and Neuroscience* [online]. 2012, vol. 3, no. 1, s. 41-49 [cit. 2014-01-26]. ISSN 2067-3957. Dostupné z:  
<http://search.ebscohost.com/login.aspx?direct=true&db=a9h&AN=85678248&lang=cs&site=ehost-live>
- [37] BRNKA, R. *Využití umělé inteligence na kapitálových trzích*. Brno, 2012. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská. Vedoucí práce prof. Ing. Petr Dostál, CSc.
- [38] AJIT, H. Order in Disorder: The Chaotic Nature of Financial Markets. *Indian Institute of Management Bangalore Management Review* [online]. 2003, vol. 15, no. 2, s. 19-25. ISSN 0970-3896 [cit. 2014-01-25]. Dostupné z:  
<http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=11339060&lang=cs&site=ehost-live>
- [39] SMALL, M. a C. K. TSE. Optimal embedding parameters: a modeling paradigm. *Physica D: Nonlinear Phenomena* [online]. 2004, vol. 194, no. 3-4, s. 283-296 [cit. 2014-01-26]. ISSN 0167-2789. Dostupné z:  
<http://www.sciencedirect.com/science/article/pii/S0167278904001186>
- [40] CAO, L. Practical method for determining the minimum embedding dimension of a scalar time series. *Physica D: Nonlinear Phenomena* [online]. 1997, vol. 110, no. 1-2, s. 43-50 [cit. 2014-01-30]. ISSN 0167-2789. Dostupné z:  
<http://www.sciencedirect.com/science/article/pii/S0167278997001188#>
- [41] BASK, M. Dimensions and Lyapunov exponents from exchange rate series. *Chaos, Solitons & Fractals* [online]. 1996, vol. 7, no. 12, s. 2199-2214 [cit. 2014-01-26]. ISSN 0960-0779. Dostupné z:  
<http://www.sciencedirect.com/science/article/pii/S096007799600080X>

- [42] PARK, J. Y. a Y. J. WHANG. Random walk or chaos: A formal test on the Lyapunov exponent. *Journal of Econometrics* [online]. 2012, vol. 169, no. 1, s. 61-74 [cit. 2014-02-03]. ISSN 0304-4076. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0304407612000139#>
- [43] WILLIAMS, B. a J. GREGORY-WILLIAMS. *Trading chaos: maximize profits with proven technical techniques*. 2. vydání. Hoboken: John Wiley, 2004. ISBN 04-714-6308-6.
- [44] YALAMOVA, R. et al. *Detecting chaos in financial time series*. [online]. Tampa: Forex Factory, 2014 [cit. 2014-01-28]. Dostupné z: <http://www.forexfactory.com/attachment.php?attachmentid=204697&d=1234456574>
- [45] ELERT, G. *Hypertextbook* [online]. New York: G. Elert, ©1999-2009 [cit. 2013-20-11]. Dostupné z: <http://hypertextbook.com/>
- [46] GAO, J. et al. Multiscale analysis of economic time series by scale-dependent Lyapunov exponent. *Quantitative Finance* [online]. 2013, vol. 13, no. 2, s. 265-274 [cit. 2014-03-02]. ISSN 1469-7696. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/14697688.2011.580774#UxLns-N5PVo>
- [47] GAO, J. et al. Multiscale Analysis of Biological Data by Scale-Dependent Lyapunov Exponent. *Frontiers of Physiology* [online]. 2012, vol. 2, no. 00110 [cit. 2014-03-05]. ISSN 1664-042X. Dostupné z: [http://www.frontiersin.org/Journal/Abstract.aspx?s=454&name=fractal\\_physiology&ART\\_DOI=10.3389/fphys.2011.00110](http://www.frontiersin.org/Journal/Abstract.aspx?s=454&name=fractal_physiology&ART_DOI=10.3389/fphys.2011.00110)
- [48] KOBEISSI, Y. H. Multifractal Financial Markets: An Alternative Approach to Asset and Risk Management. *SpringerBriefs in Finance* [online]. 2013 [cit. 2014-03-02]. ISSN 2193-1739. ISBN 978-1-4614-4490-9. Dostupné z: <http://www.springer.com/business+%26+management/finance/book/978-1-4614-4489-3>
- [49] MATHWORKS, *Matlab Central: File Exchange* [online]. Natick: MathWorks, 2014 [cit. 2014-02-04]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/>

- [50] DI MATTEO, T. Multi-scaling in finance. *Quantitative Finance* [online]. 2007, vol. 7, no. 1, s. 21-36 [cit. 2014-02-03]. ISSN 1469-7688. Dostupné z: <http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=24077933&lang=cs&site=ehost-live>
- [51] UNIVERSITY OF COLORADO. *CU Mechanical Engineering: Dynamics Matlab tutorials* [online]. Boulder: University of Colorado, 2008 [cit. 2014-02-03]. Dostupné z: [http://www.colorado.edu/MCEN/programs/undergraduate/matlab\\_tutorials/dynamics/he\\_non\\_map.html](http://www.colorado.edu/MCEN/programs/undergraduate/matlab_tutorials/dynamics/he_non_map.html)
- [52] KJERLAND, M. *Marc Kjerland's Homepage* [online]. Chicago: University of Illinois at Chicago, 2011 [cit. 2014-02-03]. Dostupné z: <http://homepages.math.uic.edu/~kjerland/Lorenz/mylorenz.m>
- [53] SPOTT, J. C. *Chaos and time-series analysis*. 1. vydání. New York: Oxford University Press, 2003. 507 s. ISBN 0-19-850839-5.
- [54] ZHANG, J. et al. Time series prediction using Lyapunov exponents in embedding phase space. *Computers & Electrical Engineering* [online]. 2004, vol. 30, no. 1, s. 1-15 [cit. 2014-04-15]. ISSN 0045-7906. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0045790603000156#>
- [55] HISTDATA.COM. *HistData: Download Free Forex Historical Data* [online]. USA: HistData.com, 2014 [cit. 2014-02-09]. Dostupné z: <http://www.histdata.com/>
- [56] YALE UNIVERSITY. *Levy flights* [online]. New Haven: Yale University, 2014 [cit. 2014-04-21]. Dostupné z: <http://classes.yale.edu/fractals/randfrac/welcome.html>

## **Seznam použitých zkratk**

EMH – Efficient Market Hypothesis (teorie efektivních trhů)

FMH – Fractal Market Hypothesis (teorie fraktálních trhů)

LE – Lyapunov Exponent (Lyapunovův exponent)

LLE – Largest Lyapunov Exponent (největší Lyapunovův exponent)

NN – Neural Network (neuronová síť)

FBM – Fractional Brownian Motion/Fractal Brownian Motion (fraktální Brownův pohyb)

FTDNN – Focused Time Delayed Neural Network (typ neuronové sítě)

FFMLNN – Feedforward Multi-Layer Neural Network (typ neuronové sítě)

RTDNN – Recurrent Time Delay Neural Network (typ neuronové sítě)

NAR – Nonlinear Autoregressive (typ neuronové sítě)

NARX – Nonlinear Autoregressive with Exogenous Input (typ neuronové sítě)

H – Hurst exponent (Hurstův exponent)

MACD – Moving Average Convergence Divergence (indikátor technické analýzy)

BSD – Berkeley Software Distribution licence (licence pro svobodné publikování)

GUI – Graphic User Interface (grafické uživatelské rozhraní)

R/S – Rescaled Range Analysis (speciální analytická metoda časových řad)



## Seznam obrázků

Obrázek č. 1: Členění finančního trhu.....	15
Obrázek č. 2: Časové řady s různou hodnotou Hurstova exponentu .....	22
Obrázek č. 3: Možnosti dělení stavového prostoru.....	27
Obrázek č. 4: Některé orbity atraktorů s různými LE.....	37
Obrázek č. 5: Ověření korektnosti funkce genhurst(). .....	41
Obrázek č. 6: Ověření funkce genhurst()).....	42
Obrázek č. 7: Testování algoritmu stanovení LLE .....	44
Obrázek č. 8: Určení časového zpoždění pro Lorenzův atraktor.....	46
Obrázek č. 9: Výsledný graf pro stanovení LLE .....	47
Obrázek č. 10: Zhangův predikční algoritmus.....	51
Obrázek č. 11: Část trajektorie časové řady ve fázovém prostoru.....	52
Obrázek č. 12: Plovoucí Hurstův exponent .....	62
Obrázek č. 13: Grafy pro určení vnořené dimenze podle Caa.....	64
Obrázek č. 14: Autokorelační graf pro určení časového zpoždění .....	65
Obrázek č. 15: Finální graf Rosensteinovy metody určení LLE .....	68
Obrázek č. 16: Ekvity křivka predikčního modelu MACD + H.....	70
Obrázek č. 17: Průběh šesti obchodů během roku 2012 .....	71
Obrázek č. 18: Out of sample ekvity křivka MACD + H modelu roku 2013.....	72
Obrázek č. 19: Ekvity křivka predikčního modelu NAR + H .....	76
Obrázek č. 20: Ekvity křivka predikčního modelu NAR + H .....	77
Obrázek č. 21: Ekvity křivka predikčního modelu NARX + H.....	78
Obrázek č. 22: Zkonstruovaný fázový prostor promítnutý do 2D .....	81
Obrázek č. 23: Srovnání Lévyho letu (vlevo) s Brownovým pohybem (vpravo).....	82
Obrázek č. 24: Pásmo vývoje kurzu dle Zhangovy metody predikce.....	82
Obrázek č. 25: Celková ekvity křivka predikčního modelu NAR + H .....	84

## Seznam tabulek

Tabulka č. 1: Průměrný světový denní obrat Forexu v mld. \$.....	16
Tabulka č. 2: Souhrn vypočtených hodnot a srovnání s výsledky jiných autorů.....	49
Tabulka č. 3: Obsah vlastní Matlab knihovny mainLibrary/TIC data/ .....	56
Tabulka č. 4: Korelační koeficienty ziskovosti obchodní strategie a H.....	60
Tabulka č. 5: Vypočtená roční časová zpoždění za 4 roky.....	66
Tabulka č. 6: Kategorie a hodnoty parametrů predikčního modelu.....	73

## Seznam rovnic

(1) Analytické rovnice pro výpočet Hurstova exponentu z časové řady.....	20
(2) Vztah hodnot fraktální dimenze $D$ a Hurstova exponentu $H$ .....	20
(3) Obecný tvar stanovení Lyapunovova exponentu.....	23
(4) Vztah mezi růstem chyby $c$ a Lyapunovovým exponentem $\lambda$ .....	24
(5) $D$ -rozměrný fázový prostor podle Zhangovy metody.....	52
(6) Výpočet vzdálenosti budoucího bodu fázového prostoru podle Zhanga .....	52
(7) Podmínka pro nalezení predikovaného bodu .....	53
(8) Vyjádření predikovaného bodu v zápisu fázového prostoru.....	53
(9) Extrakce souřadnic predikovaného bodu ze zápisu fázového prostoru .....	53
(10) Zavedení a pomínka proměnné $B$ .....	53
(11) Vyjádření fázového prostoru jako vektoru souřadnic .....	54
(12) Rovnice pro výpočet euklidovských vzdálenosti v $n$ -rozměrném prostoru .....	54
(13) Vzdálenost dvou bodů $D$ -rozměrného prostoru.....	54
(14) Vyjádření skalární hodnoty časové řady ze souřadnic fázového prostoru .....	54
(15) Vektor nepřekrývajících se intervalů konstantní délky pro výpočet $H$ .....	58
(16) Vektor překrývajících se intervalů konstantní délky pro výpočet $H$ .....	58
(17) Vektor plovoucího intervalu konstantní délky pro výpočet $H$ .....	58
(18) Vztah mezi vstupy a výstupy dynamické neuronové sítě .....	79

## **Seznam příloh**

Příloha č. 1: Grafické určení nejmenší embedding dimenze (Cao)

Příloha č. 2: Ekvity křivky modelu NAR + H pro jednotlivé měnové páry

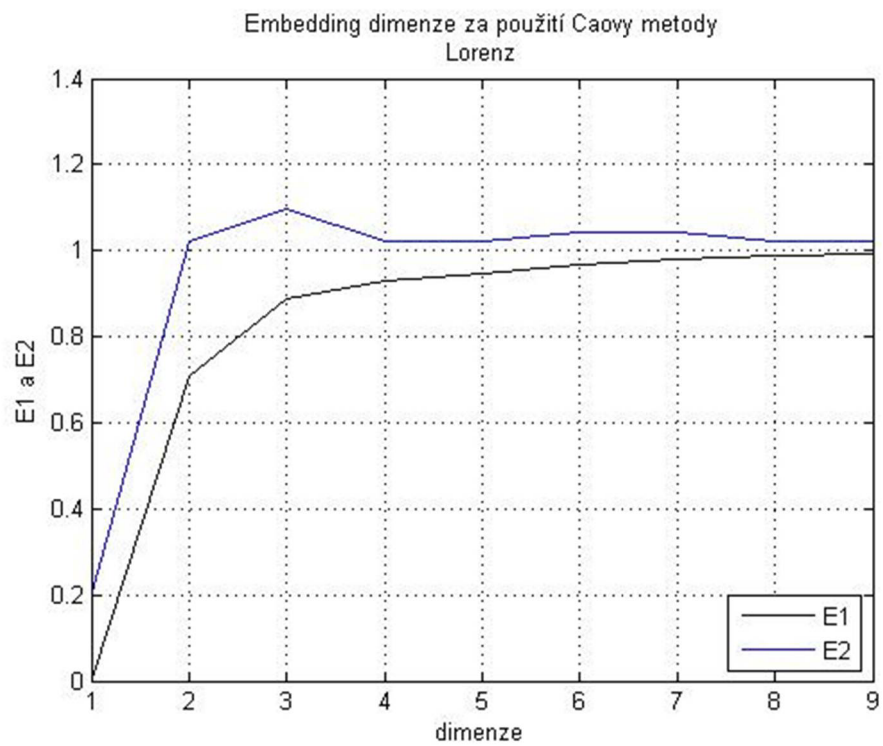
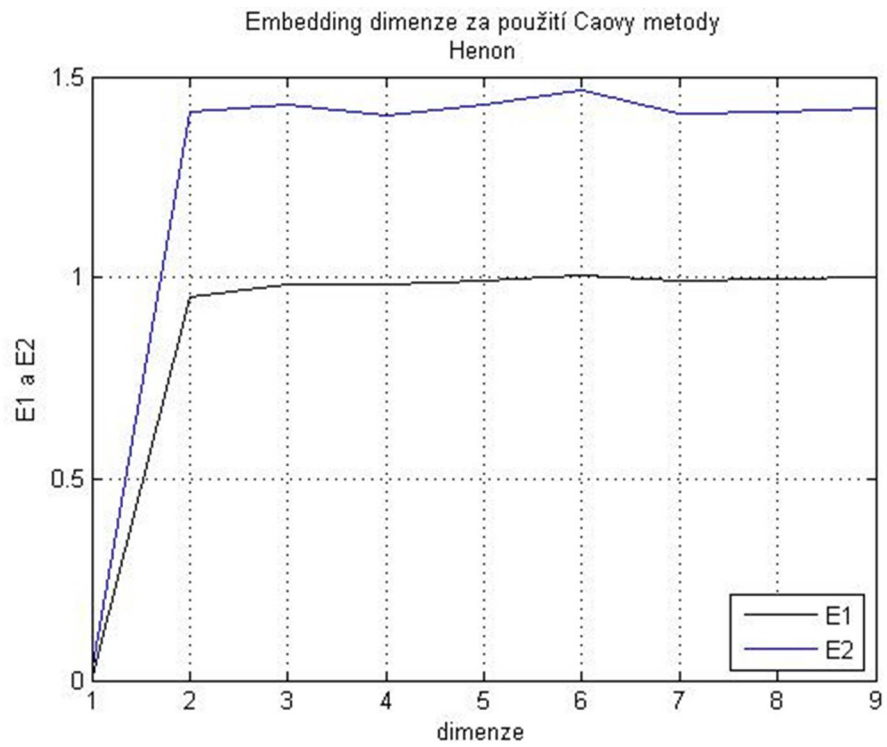
Příloha č. 3: Kompletní Matlab knihovna funkcí – Matlab screenshot

Příloha č. 4: Kompletní Matlab knihovna funkcí mainLibrary – základní popis

Příloha č. 5: Obsah CD

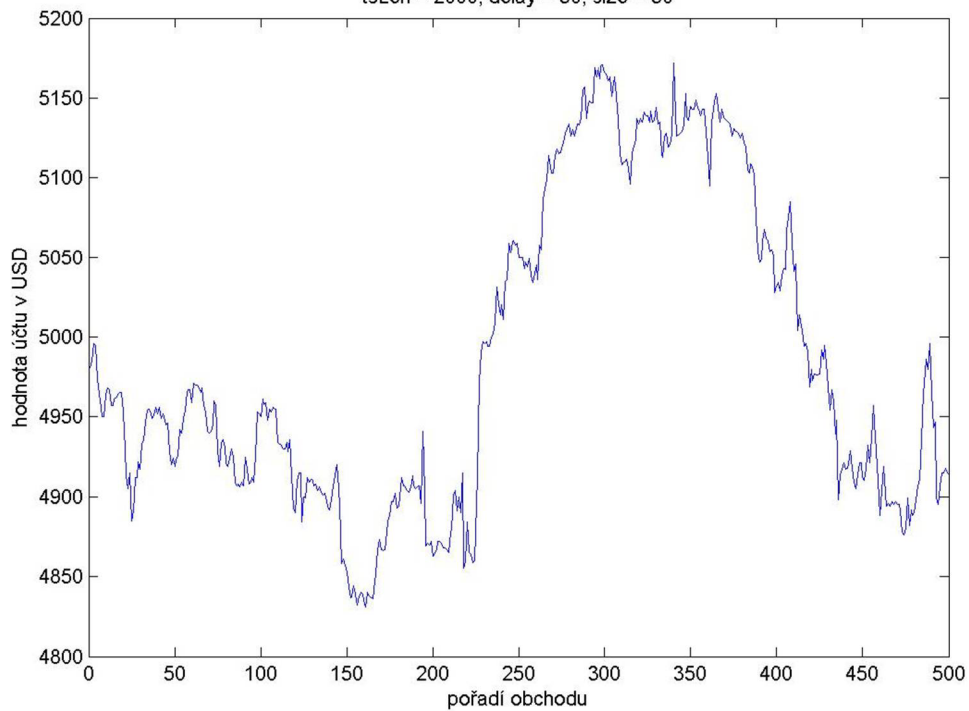
# Přílohy

## Příloha č. 1: Grafické určení nejmenší embedding dimenze (Cao)




## Příloha č. 2: Ekvity křivky modelu NAR + H pro jednotlivé měnové páry


Ekvity křivka predikčního modelu NAR + H  
500 kroků H1 EURCAD 2013-08-01 až 2013-12-31  
parametry modelu:  
tsLen = 2000, delay = 30, size = 30




Ekvity křivka predikčního modelu NAR + H  
500 kroků H1 EURCHF 2013-08-01 až 2013-12-31  
parametry modelu:  
tsLen = 2000, delay = 30, size = 30




Ekvity křivka predikčního modelu NAR + H  
500 kroků H1 EURGBP 2013-08-01 až 2013-12-31  
parametry modelu:  
tsLen = 2000, delay = 30, size = 30




Ekvity křivka predikčního modelu NAR + H  
500 kroků H1 EURJPY 2013-08-01 až 2013-12-31  
parametry modelu:  
tsLen = 2000, delay = 30, size = 30



Ekvity křivka predikčního modelu NAR + H  
500 kroků H1 EURUSD 2013-08-01 až 2013-12-31  
parametry modelu:  
tsLen = 2000, delay = 30, size = 30



### Příloha č. 3: Kompletní Matlab knihovna funkcí – Matlab screenshot





## Příloha č. 4: Kompletní Matlab knihovna funkcí mainLibrary – základní popis

název	cesta	popis	zdroj	poznámka
macdSignal	/Analysis/indicators/macdSignal.m	nenormalizovaný MACD indikátor	vlastní	
movAvg	/Analysis/indicators/movAvg.m	plovoucí průměr skalární časové řady	vlastní	
automatedEmbDim	/Analysis/Lyapunov/cao_deneme/automatedEmbDim.m	automatická konstrukce emb. dim. grafů pro všechny měnové páry	vlastní	
cao_deneme	/Analysis/Lyapunov/cao_deneme/cao_deneme.m	Caova metoda určení nejmenší embedding dimenze	Matlab File Exchange	původní
minEmbDim	/Analysis/Lyapunov/cao_deneme/minEmbDim.m	zpracování I/O pro funkci cao_deneme	vlastní	
fnn_deneme	/Analysis/Lyapunov/fnn_deneme/fnn_deneme.m	False neighbour metoda určení nejmenší embedding dimenze	Matlab File Exchange	původní
logistics_map	/Analysis/Lyapunov/logistics_map/logistics_map.m	konstrukce nejjednoduššího chaotického systému	Matlab File Exchange	původní
automatedLyapunov	/Analysis/Lyapunov/lyarosenstein/automatedLyapunov.m	zpracování I/O pro funkci lyarosenstein	vlastní	
lyarosenstein	/Analysis/Lyapunov/lyarosenstein/lyarosenstein.m	Rosensteinova metoda výpočtu LLE	Matlab File Exchange	upraveno
predictionByLLE	/Analysis/Lyapunov/lyarosenstein/predictionByLLE.m	Zhangův predikční model založený na LLE	vlastní	
psr_deneme	/Analysis/Lyapunov/lyarosenstein/psr_deneme.m	rekonstrukce fázového prostoru	vlastní	podle lyarosenstein
lambda	/Analysis/Lyapunov/SDLE/lambda.m	Gaova metoda výpočtu LLE	stránky autora	upraveno
plot_psic	/Analysis/Lyapunov/SDLE/plot_psic.m	konstrukce finálního grafického výstupu Gaovy metody výpočtu LLE	stránky autora	upraveno
plot_sdle	/Analysis/Lyapunov/SDLE/plot_sdle.m	konstrukce finálního grafického výstupu Gaovy metody výpočtu LLE	stránky autora	upraveno
automatedTimeLag	/Analysis/Lyapunov/automatedTimeLag.m	automatický výpočet časového zpoždění skalární časové řady	vlastní	
meanFreq	/Analysis/Lyapunov/meanFreq.m	výpočet střední frekvence časové řady	Matlab File Exchange	upraveno
myHenon	/Analysis/Lyapunov/myHenon.m	konstrukce Henónova chaotického systému	stránky autora	autor v hlavičce
myHenon2	/Analysis/Lyapunov/myHenon2.m	konstrukce Henónova chaotického systému	stránky autora	autor v hlavičce
myLorenz	/Analysis/Lyapunov/myLorenz.m	konstrukce Lorenzova chaotického systému	stránky autora	autor v hlavičce
timeLag	/Analysis/Lyapunov/timeLag.m	konstrukce autokorelačního diagramu a výpočet časového zpoždění	vlastní	
genericNarxPrediction	/Analysis/NN/genericNarxPrediction.m	konstrukce NARX predikční sítě - základní verze	vlastní	
predictionFitNetNARX	/Analysis/NN/predictionFitNetNARX.m	NARX predikční síť využívající fitnet vstupy	vlastní	
predictionNAR	/Analysis/NN/predictionNAR.m	základní predikční NAR model	vlastní	
predictionNAR_GA	/Analysis/NN/predictionNAR_GA.m	GA optimalizace predikčního NAR modelu	vlastní	
predictionNAR_updated	/Analysis/NN/predictionNAR_updated.m	optimalizovatelný predikční NAR model	vlastní	
predictionNAR_updated_main	/Analysis/NN/predictionNAR_updated_main.m	zpracování I/O pro GA optimalizaci predikčního NAR modelu	vlastní	
predictionNARX	/Analysis/NN/predictionNARX.m	základní predikční NARX model	vlastní	
predictionNARXwithHurst	/Analysis/NN/predictionNARXwithHurst.m	predikční NARX model s Hurst exponent vstupy	vlastní	
predictionPlots	/Analysis/NN/predictionPlots.m	konstrukce výstupních predikčních grafů	vlastní	
prepNarxData	/Analysis/NN/prepNarxData.m	příprava vstupních časových řad pro predikční NARX modely	vlastní	

testNARX	/Analysis/NN/testNARX.m	testovací skript	vlastní	
calibrateGenhurst	/Analysis/RS/calibrateGenhurst.m	kalibrační skript funkce genhurst	vlastní	
convertHexpStruct	/Analysis/RS/convertHexpStruct.m	konverze vypočtených Hurstových exponentů do jediné proměnné	vlastní	
createHexpStruct	/Analysis/RS/createHexpStruct.m	automatický výpočet struktury Hurstových exponentů	vlastní	
genhurst	/Analysis/RS/genhurst.m	funkce pro výpočet Hurstova exponentu	Matlab File Exchange	upraveno
hurstOverTime	/Analysis/RS/hurstOverTime.m	výpočet plovoucího Hurstova exponentu	vlastní	
calcCorrHexpReturn	/Analysis/calcCorrHexpReturn.m	výpočet korelace mezi hodnotou H a ziskovostí obchodní strategie	vlastní	
Entropy	/Analysis/Entropy.m	výpočet entropie skalární časové řady	Matlab File Exchange	původní
mainLyapunov	/Analysis/mainLyapunov.m	poloautomatický hromadný výpočet LLE	vlastní	
mainNNprediction	/Analysis/mainNNprediction.m	zjednodušený NARX predikční model	vlastní	
normalize1to1	/Analysis/normalize1to1.m	normalizace dat do intervalu <-1;1>	vlastní	
optTrading	/Analysis/optTrading.m	optimalizační skript obchodní simulace modelu MACD + H	vlastní	
simulateTrading	/Analysis/simulateTrading.m	základní predikční MACD model	vlastní	
simulateTrading2	/Analysis/simulateTrading2.m	kompletní predikční MACD + H testovací model	vlastní	
simulateTrading3opt	/Analysis/simulateTrading3opt.m	kompletní predikční MACD + H optimalizovatelný model	vlastní	
createOhlcDBase	/TIC Data/createOhlcDBase.m	hromadné zpracování souborů s tick daty a vytvoření OHLC databáze	vlastní	
extractDate	/TIC Data/extractDate.m	převod původního formátu data na Matlab datevec formát	vlastní	
mat2timeSeries	/TIC Data/mat2timeSeries.m	převod standardní matice OHLC dat na timeseries objekt	vlastní	
selTScale	/TIC Data/selTScale.m	výběr libovolného úseku časové řady, pracuje nad více soubory	vlastní	
tick2ohlc	/TIC Data/tick2ohlc.m	převod tick dat na OHLC formu	vlastní	
tickImportFile	/TIC Data/tickImportFile.m	import dat z formátu .xlsx	vlastní	
tickImportFileCsv	/TIC Data/tickImportFileCsv.m	import dat z formátu .csv	vlastní	

## **Příloha č. 5: Obsah CD**

**mainLibrary** – kompletní Matlab knihovna všech použitých funkcí a skriptů

**obrázky** – použité a automaticky generované obrázky, obsahuje adresář s dávkově generovanými výstupními grafy pro určení nejmenší embedding dimenze (Cao)

**readme.txt** – textový soubor se základním popisem obsahu CD