

## Strojové učení a modelování měnových kurzů v praxi finančního řízení<sup>1</sup>

Petr BURYAN\* – Josef TAUŠER\*\*

---

### Machine Learning and Exchange Rate Modelling in International Financial Management

#### Abstract

*Exchange rates forecasting is an important financial problem that is receiving increasing attention especially because of its difficulty and practical applications. This paper proposes utilisation of Machine Learning methods in the field of financial praxis. Two modelling approaches – enhanced Group Method of Data Handling (GMDH) and back propagation Neural network – were employed for CZK/EUR exchange rate forecasting. Predictions were used for financial management decision simulation of a virtual company and the results indicate, that machine learning proved to be useful source of information in the area. This implies that the proposed modelling approaches can be used as a feasible solution for exchange rate forecasting in exchange rate management.*

**Keywords:** machine learning, neural networks, group method of data handling, exchange rate forecasting, exchange rate risk management, exchange rate derivatives

**JEL Classification** F31, F37

---

#### Úvod

Práce analytiků se v dnešním světě, ve kterém exponenciálně roste množství dostupných informací a údajů různého typu, stává stále ekomplikovanější. I když se lidský mozek a jeho schopnost pojmout a zpracovat podněty bezesporu vyvíjí, rozhodně rychlost této evoluce nemůže konkurovat informační explozi posledních

---

\* Petr BURYAN, České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra kybernetiky, Karlovo náměstí 13, 121 35 Praha, Česká republika; e-mail: buryan@labe.felk.cvut.cz

\*\* Josef TAUŠER, Vysoká škola ekonomická v Praze, Fakulta mezinárodních vztahů, Katedra mezinárodního obchodu, nám. Winstona Churchilla 4130 67 Praha 3, Česká republika; e-mail: tauser@vse.cz

<sup>1</sup> Tato studie byla vypracována v rámci Výzkumného záměru FMV VŠE v Praze MSM6138439909 a grantového projektu AV ČR 1ET101210513.

let. Úměrně nárůstu vlivu počítačů v běžném životě roste i jejich schopnost sbírat a uchovávat množství údajů takřka o čemkoli. Následnou analýzou těchto datových souborů lze získat velké množství velice cenných znalostí o procesech, které za nimi stojí.

Nejčastěji používané metody zkoumání závislostí v datovém souboru vycházejí ze statistické analýzy, která je velice často spojená s obtížnou matematikou. Obecně jejich nasazení představuje nelehkou činnost, jež je v mnoha případech závislá na citu a zkušenosti analytika a na jeho znalostech o zkoumané problematice. Je náročná na čas i zdroje, což činí její dostupnost a použitelnost v běžné praxi značně omezenou, a to i přes skutečnost, že s touto analýzou a následnou optimalizací by bylo možné naopak mnoho získat. Zde se tedy otvírá prostor pro nasazení metod postavených na umělé inteligenci a strojovém učení, které umožňují automatizovat proces datové analýzy při schopnosti zahrnout do zkoumání daleko větší objem údajů než při běžné „ruční“ analýze.

I přes stále častější ujišťování o náhodném pohybu měnových kurzů (naposledy např. Alvarez [2]) je celá problematika analýzy vývoje a predikce měnových kurzů pomocí metod umělé inteligence (a zejména neuronových sítí) předmětem obsáhlého výzkumu. To lze přisuzovat kromě náročnosti tohoto úkolu mj. i snadné dostupnosti dostatečného množství dat. Kromě knižních publikací (Azoff [6]; Trippi [42]; Beltratti [9]; Smith [40]), existuje i velké množství článků v zahraničních periodikách, a to až u takových, které se zaměřují přímo na měnové kurzy (Balkin [7]; Walczak [45]; Chen [27]), či těch, jež berou tuto oblast jako jednu z možných aplikací (de Oliveira [16]; Foka [21]). Z oblasti samoorganizujících se metod, do které patří i algoritmus GMDH (*Group Method of Data Handling*) používaný v této práci, lze zmínit více publikací (Ivakhnenko [28]; Oh [37]; Nikolaiev [36]; Ni [35]; Hwang [25]; He [23] nebo Hiassat [24]).

V následujícím textu jsou prezentovány výsledky simulační analýzy, která demonstruje praktickou využitelnost metod strojového učení v procesu řízení kurzového rizika. Cílem práce přitom není odsoudit v současnosti používané postupy založené zejména na statistické analýze, ale spíše poukázat na relativně nový způsob zkoumání časových řad popisujících pohyb měnových kurzů, který by mohl přinést do této problematiky nový náhled. Část první krátce pojednává o strojovém učení a použitých algoritmech. Parametry simulační analýzy jsou blíže popsány v části 2. Dosažené výsledky jsou poté shrnuty v části 3.

## 1. Umělá inteligence

Metody strojového učení a jejich aplikace do oblasti dolování znalostí z dat (*datamining*) se snaží eliminovat potřebu lidského zásahu do datové analýzy, nebo ji aspoň omezit na minimum. Připomeňme, že *datamining* lze vymezit jako

proces netriviálního získávání implicitní, dříve neznámé a potenciálně užitečné informace z dat (Fayyad a kol. [20]). Přehled velké části této oblasti umělé inteligence lze nalézt například u Maříka et al. [33] a Berku [10].

Strojové učení svou automatizovanou povahou nabízí pro uživatele schůdnější možnost tvorby modelu datového souboru bez jeho náročného statistického zkoumání, protože vychází z předložených dat a snaží se z nich na bázi svých algoritmů odvodit obecnější model těchto dat (většinou při použití na informovaného prohledávání relativně široce vymezeného prostoru možných modelů zkoumaného datového souboru). V rámci této práce byly použity dva z těchto přístupů – neuronové sítě a algoritmus GMDH. Následující část se jim proto bude v krátkosti věnovat. Předem je nutné poznamenat, že rozsah této práce zdaleka nedává prostor být jen k základnímu úplnému popisu jejich funkce a jejich vlastností, čtenáře zajímajícího se o podrobnosti je proto nutné odkázat na uvedenou literaturu.

### 1.1. Strojové učení a ekonomické aplikace

Se základními přínosy těchto technik pro oblasti nejen finančního řízení ale oblasti podnikové ekonomiky vůbec se lze seznámit například v publikacích (Kloesgen [30] či Loofbourrow [31]). Využití metod strojového učení v predikci budoucího vývoje měnových kurzů otevírá prostor pro celou řadu konkrétních aplikací. Uplatnění nových metod umělé inteligence v praxi však musí vždy respektovat jejich specifický charakter. Vedle řady výhod existují i některá omezení, a tak každé konkrétní rozhodnutí musí být přijímáno s ohledem na základní vlastnosti prezentovaných modelů. Mezi hlavní výhody přitom patří především:

- možnost predikovat budoucí vývoj měnového kurzu jak na bázi hodnot pouze samotné predikované časové řady, tak i s využitím hodnot jiných ekonomicky relevantních časových řad;
- relativně snadná práce s modely na principu „černé skříňky“ na straně jedné, a současně schopnost modelovat vysoce nelineární procesy na straně druhé;
- výstupy v podobě predikce konkrétních hodnot, a nikoliv jen rostoucího či klesajícího trendu.

Jako nevýhodu lze spatřovat fakt, že výstupy strojového učení představují ve své podstatě modely typu „černé skříňky“ (*black-box*), kdy uživatel není detailně seznámen s důvody, proč byly parametry daného modelu nastaveny tak, jak je zrovna používá. S tím souvisí i skutečnost, že metody strojového učení nepracují ve své základní podobě s žádnými testy statistické významnosti. Jejich použití tak neumožňuje zevrubné pochopení fundamentálních vztahů mezi vysvětlujícími a vysvětlovanou proměnnou tak, jak tomu je například u složitějších ekonometrických analýz (Voit [44], Tsay [43]). Zde je však namísto poznamenat,

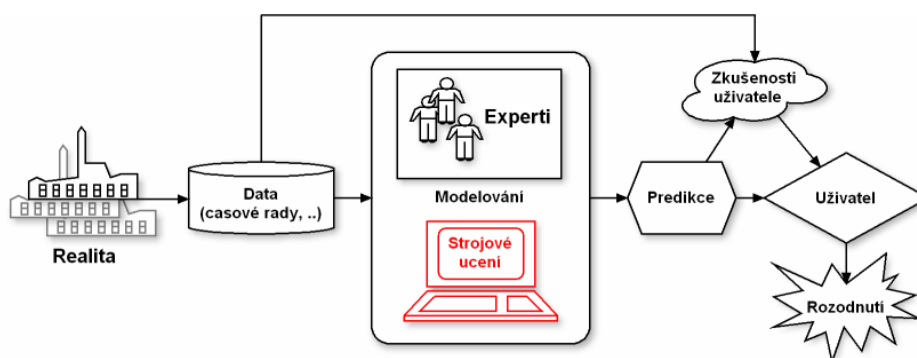
že hlavním kritériem pro volbu typu analýzy jednoznačně musí být otázka výsledného použití hledaného modelu.

Potřebuje-li uživatel pouze získat okamžitě několik modelů schopných predikce, aniž by potřeboval nutně rozumět příčinám predikovaného jevu, nabízí strojové učení přijatelné řešení. Je-li cílem, naopak, hlubší porozumění procesům stojícím za daty, pak je ovšem nutné sáhnout k zevrubné statistické (ekonometrické) analýze prováděné příslušným týmem expertů. Podstatné ovšem vždy je, že rozhodnutí o výsledném postupu záleží vždy na uživateli analýzy a je jen na něm a na jeho zkušenostech, jak a ke kterým dostupným zdrojům informace o řešeném problému přihlédne.

Roli strojového učení v daném rozhodovacím procesu pak lze schématicky zobrazit prostřednictvím obrázku 1.

Obrázek 1

#### Role strojového učení v reálném rozhodovacím procesu



Pramen: Buryan [13].

Další nevýhodou těchto metod může pak být vysoce nelineární přenos výsledného modelu (zejména u neuronových sítí), z jehož složitosti pramení i částečná neprůhlednost procedury stanovování parametrů. Dalšími negativy je schopnost naučit se závislost vyskytující se pouze v zpracovávaném datovém souboru a také fakt, že zpravidla lze jen velmi těžko nalézt obecný odhad chyby předpovědi, resp. její spolehlivosti (byť jsou zde pokusy o nápravu – viz např. Menezes [34]).

## 1.2. Modelování časových řad

Predikce časových řad určuje budoucí hodnoty řady na základě měření hodnot minulých. Za tímto účelem sestavují metody strojového učení na základě těchto hodnot vlastní model časové řady. Identifikace modelu časové řady spočívá

v hledání parametrů obecných modelů ze zvolené množiny tak, aby výsledný model co nejlépe splňoval zvolené kritérium. Parametry se zde rozumí na zkoumané časové řadě nezávislé veličiny (u časově invariantních modelů konstantní v čase), které se v modelu vyskytují, jejichž hodnoty nejsou předem známy a které je proto třeba určit. Důležitou informací často nesou tzv. intervenční, resp. exogenní proměnné (Arlt [3]) – informace o predikované řadě, případně o období, na které jsou sestavovány předpovědi.

Obecně tedy je třeba nalézt model, který určí souvislosti mezi vstupy a výstupy systému. Takových modelů je mnoho, pro účel predikce jsou zajímavé zejména modely matematické, které popisují vztahy mezi proměnnými systému pomocí matematických funkcí. Při určování modelu je tedy hledán takový model  $g$ , pro který platí (Ivakhnenko [28]):

$$\tilde{g} = \arg \min_{g \in G} CR(g) \quad (1)$$

kde

- $G$  – množina přípustných modelů,
- $CR(\cdot)$  – kritérium hodnotící kvalitu modelu.

Při výběru predikčního modelu není vždy důležitá pouze odchylka předpovědí od skutečných hodnot (měřená např. kritériem střední kvadratické odchylky). Přílišná přesnost modelu může být způsobena i jeho tzv. přeučení, tj. přílišným přilnutím ke známým datům a z toho plynoucí ztráty schopnosti modelu generalizovat. Je tedy zřejmě nutné zvolit kompromis mezi požadavky na přesnost a výslednou složitost – nejlepší model tedy je nejen přesný, ale také není zbytečně komplikovaný.

### 1.3. Neuronové sítě

Není pochyb, že nejdokonalejším nám doposud známým médiem určeným ke zpracování informace je *mozek*. Jeho masivně paralelní strukturu jednoduchých výpočetních jednotek – neuronů – navzájem hustě propojených komunikačními spoji se snaží napodobit umělé neuronové sítě. Jejich základními jednotkami (Berka [10]) jsou neurony – výpočetní jednotky navzájem komunikující pomocí sítě vzájemných propojení. Každý neuron vykonává relativně jednoduchou funkci. Přijímá signály od svých sousedů a na jejich základě počítá svůj výstupní signál, který se pak šíří do dalších jednotek. Jedná se tedy o paralelní systém v tom smyslu, že množství jednotek může vykonávat svůj početní úkol ve stejném čase. Změny stavů jednotlivých neuronů se mohou dít jak synchronně, kdy všechny jednotky vypočtou svůj výstup naráz v jednom okamžiku, tak i asynchronně.

Jednotlivé neurony jsou vzájemně propojeny a každému z těchto spojů je přiřazena váha. A právě tyto váhy v sobě uchovávají znalosti a schopnosti neuronových sítí. V nejjednodušším přiblížení realizuje každý neuron vážený součet svých vstupů, ze kterého je následně pomocí tzv. aktivační funkce vypočten výstup neuronu. Aktivační funkce neuronu je taková funkce  $F$ , pro kterou platí:

$$y_k(t+1) = F_k(y_k(t), s_k(t)) \quad (2)$$

kde

$$s_k(t) = \sum_j w_{jk} y_j(t) + \theta_k(t) \quad (3)$$

přičemž  $k$  označuje  $k$ -tou jednotku sítě,  $w_{jk}$  jsou váhy přiřazené jednotlivým vstupům neuronu  $y_j$  a  $\theta_k$  je konstanta. Výstup neuronu většinou není závislý na jeho aktuální hodnotě výstupu a má tedy tvar  $y_k(t+1) = F_k(s_k(t))$ . Nejběžnějšími aktivačními funkcemi jsou funkce signum, arkustangens, lineární, resp. Semi-lineární funkce, popřípadě spojitá sigmoida

$$F(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

Uvažujeme-li situaci předpovídání jedné hodnoty časové řady, lze vícevrstvý perceptron definovat (Haykin [22]) jako čtveřici  $(h, n, y, P)$ , kde  $h \in \mathbf{N}$  je počet skrytých vrstev,  $n = (n_0, n_1, \dots, n_h)$  je počet neuronů v jednotlivých vrstvách  $F: \mathbf{R} \rightarrow \mathbf{R}$  je aktivační funkce neuronu a  $\mathbf{P} = (\mathbf{W}^1, \dots, \mathbf{W}^h, w^y)$ , kde  $\mathbf{W}^i = (w_{i1}, \dots, w_{ini}) \in (\mathbf{R}^{n^{i-1}+1})^n$  jsou parametry (váhy a vychýlení) neuronů mezi  $(i-1)$ -tou vrstvou a  $i$ -tou vrstvou a  $w^y \in \mathbf{R}^{n^h}$  vektor parametrů výstupního neuronu.

#### 2.4. Sítě GMDH

Algoritmus sítí GMDH, poprvé zveřejněný Ivakhnenkem [30], byl vyvinut jako nástroj pro identifikaci závislostí v komplexních nelineárních vícerozměrných systémech, jejich predikci a aproximaci. Algoritmus hledá optimální strukturu modelu jako polynomiální (resp. multipolynomiální) funkci  $g: \mathbf{R}^n \rightarrow \mathbf{R}$ , kterou realizuje pomocí polynomiální vícevrstvé sítě. Cílem je získat matematický model objektu (problém identifikace a rozpoznávání), nebo popsat proces, který se na objektu bude odehrávat v budoucnosti (problém předpovídání). Algoritmus GMDH patří ke skupině tzv. induktivních algoritmů – nad předloženým datovým souborem se snaží samy bez přičinění uživatele nalézt model zkoumaných dat.

Kolmorovova-Gaborova věta (Barron [8]) dokazuje, že jakákoliv funkce  $y = f(\bar{x})$  může být vyjádřena ve formě diskrétního Volterrova rozvoje.

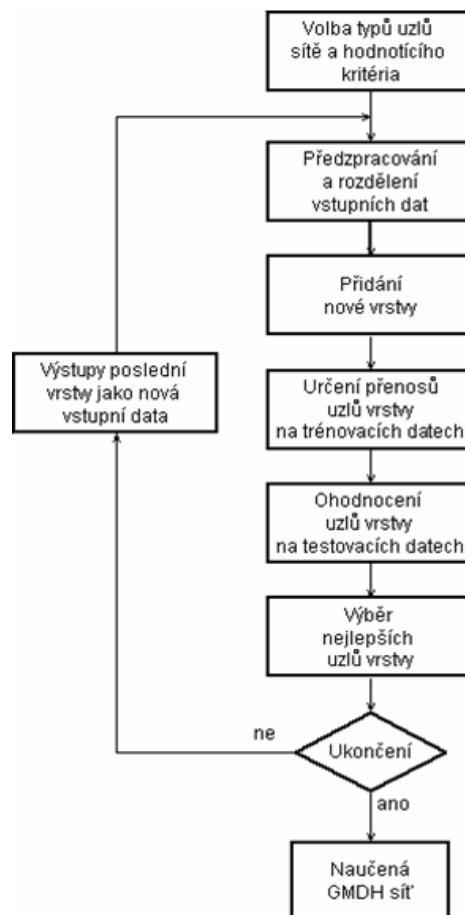
Tento rozvoj je tedy lineární vůči vektoru  $\vec{a}$  a nelineární vůči vektoru  $\vec{x} = (x_1, x_2, \dots)$ . Vektor  $\vec{x}$  může být tvořen nezávislými proměnnými, funkcemi nebo konečnými diferencemi.

Algoritmy GMDH jsou používány k určení vektoru koeficientů  $\vec{a}$  a k výběru takového vektoru proměnných  $\vec{x}$  z množiny vstupních dat, při jehož použití bude výstup sítě minimalizovat zvolené kritérium, kterým většinou bývá odchylka od hodnot naměřených na výstupu modelovaného systému při vstupech  $\vec{x}$ .

$$y(x) = a_0 + \sum_i a_i x_i + \sum_i \sum_j a_{ij} x_i x_j + \sum_j \sum_j \sum_k a_{ijk} x_i x_j x_k + \dots \quad (5)$$

Obrázek 2

### Základní algoritmus GMHD



Pramen: Ivakhnenko [29].

K pochopení principu GMDH algoritmu zde bude popsána jeho základní verze schematicky znázorněná na obrázku 2. Chování sítě je založeno na principu dopředného šíření signálu sítě – na uzly vstupní vrstvy (distribuční uzly) je přiložen vstupní vektor, jehož hodnoty jsou poté distribuovány do dalších (skrytých) vrstev složených z aktivních uzlů. Zde jsou provedeny příslušné kombinace. V poslední (výstupní) vrstvě bývá ve většině případů již jen jeden uzel, jehož výstup je i výstupem celé sítě. V rámci sítě nejsou zavedeny zpětné vazby z vyšších do nižších vrstev. Jak počty vrstev tak i počty uzlů v nich jsou omezeny pouze povahou řešené úlohy a požadavky uživatele.

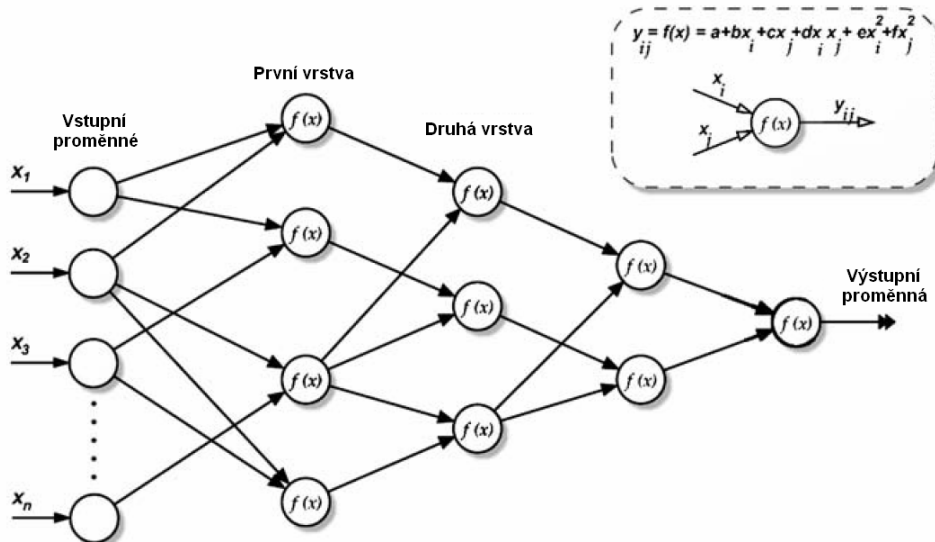
V případě GMDH sítě nejsou váhy přiřazeny přímo jednotlivým spojmům mezi uzly jako u klasického perceptronu. Každý uzel sítě má několik vstupů (v základním případě právě dva) a jeden výstup, který může být dále vícenásobně rozvětven. Přenosovou funkcí každého uzlu je většinou polynom druhého řádu, jehož koeficienty hrají podobnou roli jako váhy perceptronu. Výstup  $i$ -tého neuronu je tedy určen přenosovou funkcí

$$y_i = f(u_{i1}, u_{i1}) = a_{i0} + a_{i1} \cdot u_{i1} + a_{i2} \cdot u_{i2} + a_{i3} \cdot u_{i1} \cdot u_{i2} + a_{i4} \cdot u_{i1}^2 + a_{i5} \cdot u_{i2}^2 \quad (6)$$

Celková přenosová funkce sítě je tedy v tomto případě polynom maximálně  $2n$ -tého stupně, kde  $n$  je počet vrstev sítě, síť tedy realizuje popis systému blízký se rozvoji (5). Jedna z možných výsledných podob sítě je pak zobrazena na obrázku 3.

Obrázek 3

#### Výsledná podoba sítě GMDH



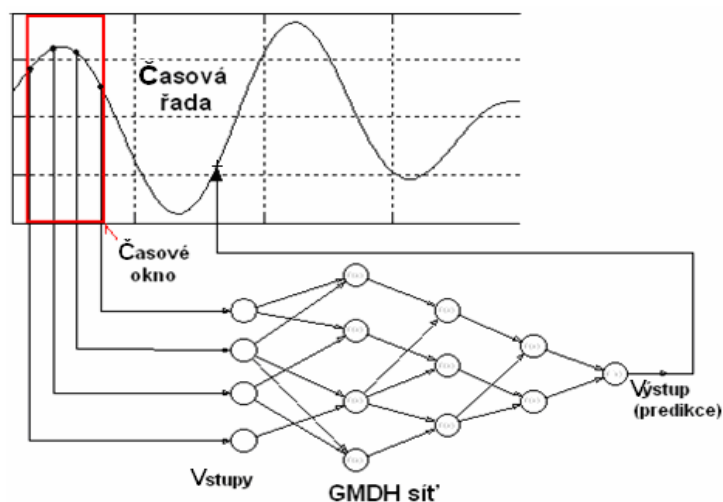


Na přenosový polynom uzlu je možné nahlížet jako na lineární kombinaci lineárních a nelineárních vstupních členů. Je samozřejmě možné přivést na vstup i jiná nelineárně modifikovaná data ze základního souboru, například jejich logaritmy atd. Obecně pak může mít přenosová funkce neuronu i jiný tvar než polynom (6), namísto prosté kombinace vstupů například kombinací harmonických nebo logistických funkcí. V těchto případech je však již učení složitější a jedná se často o tzv. hybridní GMDH algoritmy, používající k učení i dalších metod umělé inteligence. Koeficienty přenosu každého uzlu totiž lze na základě množiny vstupních dat nastavit nejen například zde používanou metodou nejmenších čtverců, možné jsou i jiné metody, například gradientní kvazi-Newtonova metoda, techniky evolučních algoritmů apod. Vlastní získání dat z časové řady je pak identické jako u neuronových sítí.

Při tvorbě GMDH sítě jsou, stejně jako při učení neuronových sítí, vstupní data nejprve rozdělena do dvou množin – trénovací a testovací. Trénovací data jsou použita k nastavení koeficientů aktivních neuronů sítě. Na bázi odchylek naměřených na testovacích datech je následně proveden výběr nejlepších modelů ve vrstvě, nad kterými jsou budovány vrstvy další. Toto dělení dat zvyšuje odolnost algoritmu proti šumu ve vstupních datech, a zároveň snižuje riziko přeučení celé sítě.

Příklad použití algoritmu pro analýzu časové řady uvádíme na obrázku 4, kde jsou k předpovědi časové řady použity pouze hodnoty řady samé, bez použití dalších dodatečných informací o problému v podobě dalších řad.

Obrázek 4  
Aplikace algoritmu GMDH na problém časových řad



Pramen: Buryan [13].

V rámci state byla použita upravená verze algoritmu MIA GMDH (označená jako eMIA – *enhanced MIA*), kterou jsme vyvinuli v rámci práce [13]. Konkrétní realizace algoritmu umožňuje na základě zvolených kritérií a omezení vystavět GMDH síť z předložených vstupních a jim odpovídajících výstupních dat. Zároveň umožňuje určit analyticky výsledný přenos sítě i vypočítat odezvu na předložené vstupy.

Pro tvorbu sítě byly zapracovány následující parametry, které umožňují zpřesnit výslednou predikci:

- omezení počtu vrstev sítě – ukončení učícího se algoritmu na požadované vrstvě;
- omezení počtu uzlů vrstvy – prořezání vrstvy a výběr předem stanoveného počtu uzlů;
- kritérium použité pro hodnocení uzlů – kritérium používané při prořezávání vrstev, příslušející historii; z této množiny je poté buď deterministicky, nebo náhodně vybrán požadovaný počet trénovacích  $n$ -tic);
- typ přenosové funkce uzlů – pro přenos uzlu je možné vybrat ze sedmi aplikovaných přenosových funkcí;
- poměr trénovacích a testovacích dat – určuje, jaký podíl dat z celkového souboru bude vybrán jako trénovací, zbytek použit jako testovací data (data jsou nejprve uspořádána do uspořádaných  $n$ -tic určujících výstup a jemu příslušející historii; z této množiny je poté buď deterministicky, nebo náhodně vybrán požadovaný počet trénovacích  $n$ -tic);
- úpravy stabilizující regresi;
- úpravy zvyšující diverzitu vrstvy.

Podstatný rozdíl mezi eGMDH a vícevrstým perceptronem spočívá ve způsobu určení struktury sítě. Zatímco u neuronové sítě je nutné stanovit její úplnou podobu před zahájením učícího se procesu, během něhož se pouze nastavují váhy jednotlivých spojení, u GMDH sítí probíhá sestavování struktury automaticky v rámci běhu algoritmu. Pro bližší informace o algoritmu eMIA GMDH viz Buryan – Onbuwolu [12].

## 2. Parametry simulační analýzy

Simulační analýza byla provedena na hypotetických finančních tocích fiktivní firmy a na reálných finančních datech v letech 2005 – 2006. Analyzovali jsme situaci vývozní firmy, které vznikaly v důsledku její hospodářské činnosti každý měsíc pohledávky ve výši 400 000 eur se splatností 1 měsíc. Firma se tedy opakovaně dostávala do tzv. dlouhé transakční devizové expozice.<sup>2</sup> Finanční manažer

---

<sup>2</sup> Blíže se tomuto problému věnují například Durčáková a Mandel [17], Eiteman et al. [19] a Madura [32].

měl k dispozici několik instrumentů k zajištění rizika – *FX forward*, jednoduchou opci a dvě vybrané opční strategie. Volba výsledného rozhodnutí pak byla založena na predikci poskytnuté algoritmem GMDH, nebo neuronovou sítí. V simulační analýze jsme přitom používali reálné parametry jednotlivých instrumentů, jež jsou bankami standardně nabízeny středně velkým firmám na českém trhu.

## 2.1. Zajišťovací strategie

Měsíční forwardový kurz byl v analýze odvozen z tzv. podmínky kryté parity úrokových sazeb při zohlednění transakčních nákladů arbitráže.<sup>3</sup> V případě jednoduché opce jsme pracovali s tzv. evropskou opcí se splatností 1 měsíc. Logicky jsme nakupovali prodejní opce, tj. právo prodat 400 000 eur za 1 měsíc za předem stanovený realizační kurz. Aby zaplacené opční prémie nebyly příliš vysoké, kupovali jsme opce s realizačním kurzem cca 1 % pod forwardem.<sup>4</sup>

Dále jsme vzali v úvahu rovněž dvě základní opční strategie – *Risk Reversal* a *Ratio Forward*. Jedná se o tzv. *zero cost* strategie, jež spočívají v tom, že firma na jedné straně jednu opci koupí a na straně druhé jednu opci prodává tak, aby se přijaté a zaplacené opční prémie celkově rovnaly.

Strategie *Risk Reversal* se skládá z nákupu jedné prodejní opce (pozice *long put*) a současného prodeje jedné kupní opce (pozice *short call*) s rozdílnými realizačními kurzy. Firma si realizačním kurzem prodejní opce fixuje nejhůře akceptovatelný kurz. Banka následně dopočte realizační kurz kupní opce tak, aby se obě opční prémie rovnaly. Z podstaty opčních premií přitom plyne, že čím nižší bude realizační kurz prodejní opce, tím vyšší bude realizační kurz kupní opce.

Realizační kurzy obou opcí tvoří koridor, v němž se pohybuje efektivní kurz pro inkaso uvedené pohledávky. Opční strategie *Risk Reversal* umožňuje zajistit se proti riziku, zároveň ponechává i určitý prostor podílet se na případném pozitivním vývoji kurzu. Tato možnost je však omezena realizačním kurzem prodané kupní opce.

Konstrukce opční strategie *Ratio Forward* je v principu velmi podobná strategii *Risk Reversal*. Firma kupuje jednu prodejní opci, a současně prodává jednu kupní opci. Obě opce mají v tomto případě ovšem různý objem podkladové měny. Prodaná kupní opce zní na větší částku bazické měny, což umožňuje posunout realizační kurz kupní opce nahoru při zachování rovnosti opčních premií obou opcí. Firmě se tak otevírá větší potenciál podílet se na pozitivním vývoji

<sup>3</sup> Viz například Taušer [41].

<sup>4</sup> Blíže se problematice opčních premií věnuje například Dvořák [18].

měnového kurzu. Na druhou stranu, nestejný objem podkladové měny vede k tomu, že se firma buď zajistí pouze částečně, anebo se tzv. přezajistí, tj. otevře si opačnou devizovou pozici, byť zpravidla v menším rozsahu.

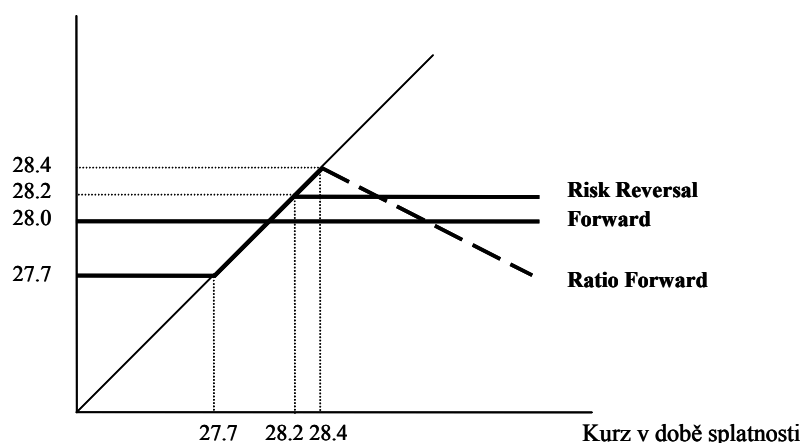
V naší simulační analýze jsme u obou opčních strategií stanovili realizační kurz koupené prodejní opce na úrovni realizačního kurzu jednoduché prodejní opce, tj. cca 1 % pod úrovní forwardového kurzu. Na základě vztahů mezi opčními prémii a realizačními kurzy byly pak dopočteny realizační kurzy kupních opcí prodaných bance. V případě opční strategie *Ratio Forward* jsme zvolili možnost přezajistění v poměru 1,5. Koupené prodejní opce tak zněly na 400 000 eur, zatímco prodané kupní opce byly na 600 000 eur. Jestliže by se tedy kurz v době expirace opčních kontraktů pohyboval nad realizačním kurzem prodané kupní opce, museli bychom bance prodat 400 000 eur za příslušný realizační kurz, a navíc bychom museli ještě dokoupit 200 000 eur za aktuální kurz a prodat je bance opět za stanovený realizační kurz kupní opce. Se znehodnocením kurzu nad realizační kurz prodané kupní opce v době splatnosti obou opcí tak začíná efektivní kurz pro inkaso pohledávky klesat, přičemž tento pokles není teoreticky omezen žádným nejhůře akceptovatelným kurzem.

Finanční manažer fiktivní firmy měl tedy každý měsíc k dispozici portfolio čtyř instrumentů k zajištění rizika změny kurzu během následujícího měsíce. Který z nástrojů zajištění však zvolit? Žádný z uvažovaných měnových derivátů nepřináší lepší výsledky než ostatní instrumenty po celém intervalu budoucího spotového kurzu v době splatnosti příslušných kontraktů.

Obrázek 5

#### Efektivní kurz pro inkaso zajištěné pohledávky

Efektivní kurz pro inkaso pohledávky



Pramen: Vlastní zpracování.

Obrázek 5 zachycuje vývoj efektivního kurzu pohledávky zajištěné jednotlivými instrumenty v závislosti na hodnotách spotového kurzu v době splatnosti. Forwardový kurz činí v tomto konkrétním příkladě 28,000 CZK/EUR. Nakoupené prodejní opce mají realizační kurz 27,700 CZK/EUR. Realizační kurz prodané kupní opce je v případě opční strategie *Risk Reversal* 28,200 CZK/EUR; u strategie *Ratio Forward* činí realizační kurz prodané kupní opce 28,400 CZK/EUR.

V obrázku není pro přehlednost zachyceno zajištění prostřednictvím jednoduché prodejní opce s realizačním kurzem 27,700 CZK/EUR. Ta je v důsledku nutnosti platit opční prémii relativně málo atraktivní. Poskytuje zajištění při nejhorším efektivním kurzu (realizační kurz minus zúročená opční prémie)<sup>5</sup> a nejlepších výsledků dosahuje až při výrazném znehodnocení kurzu. Přesněji musí být rozdíl budoucího spotového kurzu a realizačního kurzu prodané kupní opce v strategii *Ratio Forward* větší než dvě třetiny zúročené zaplacené opční prémie, aby jednoduchá opce přinášela lepší efektivní kurz. Formálně lze zapsat takto:

$$S - P \cdot (1 + i) > X - (S - X) \cdot 0,5 \quad (7)$$

po úpravě  $1,5 \cdot S > 1,5 \cdot X + P \cdot (1 + i) \quad (8)$

a konečně  $S - X > \frac{2}{3} P \cdot (1 + i) \quad (9)$

kde

- $S$  – spotový kurz v době splatnosti opčních kontraktů,
- $P$  – opční prémii koupené prodejní opce,
- $X$  – realizační kurz prodané kupní opce,
- $i$  – příslušná úroková sazba na měsíční bázi.

Konkrétní volba zajišťovacího instrumentu tedy závisí na hodnotě očekávaného spotového kurzu v době splatnosti. V naší simulační analýze jsme přitom nadefinovali zajišťovací strategii následujícím způsobem:

- Je-li očekávaný kurz pod forwardovým kurzem, zajišťujeme pohledávku forwardem.
- Jestliže se očekávaný kurz nachází nad forwardovým kurzem a pod realizačním kurzem prodané kupní opce u strategie *Risk Reversal*, využíváme strategie *Risk Reversal*.
- Nachází-li se očekávaný kurz mezi realizačními kurzy prodaných kupních opcí u obou opčních strategií, vstupujeme do strategie *Ratio Forward*.
- Pokud je očekávaný kurz nad realizačním kurzem prodané kupní opce u strategie *Ratio Forward*, maximálně však o dvě třetiny zúročené opční prémii, zůstáváme u opční strategie *Ratio Forward*.

<sup>5</sup> České banky vyžadují od svých klientů úhradu opční prémii zpravidla do dvou obchodních dnů od uzavření opčního kontraktu.

- Je-li očekávaný kurz nad realizačním kurzem prodané kupní opce u strategie Ratio Forward o více než dvě třetiny zúročené opční prémie, kupujeme pouze jednoduchou prodejní opci.

## 2.2. Použité predikční modely

Posledním krokem v simulační analýze byla implementace predikcí měnového kurzu na bázi neuronových sítí a algoritmu eGMDH (Buryan [13]) do modelovaného rozhodovacího procesu v rámci řízení kurzového rizika firmy. Využili jsme přitom měsíční predikce ex ante. Do modelu jsme tedy zařadili vždy pouze data časově dostupná k simulovanému okamžiku predikce. K ověření schopností a možností zkoumaných přístupů k predikci časových řad bylo zvoleno prostředí MATLAB, ke každému měsíci bylo sestaveno 5 modelů eGMDH a 5 modelů neuronové sítě (pouze nad daty staršími než období, pro které byla činěna predikce), výsledný predikční model byl pak vybrán vždy dle minima chybového kritéria MSE (*Mean Squared Error*) každého modelu nad historickými daty (ve většině případů – cca 80 % byl vybrán model eGMDH).

Takovýto poněkud časově náročný postup (přehodnocení časově známých a neznámých dat a stanovování 10 modelů pro každý měsíc zvlášť) sice není tradičním v oblasti srovnávání různých modelů časových řad, nicméně věrně simuloval situaci firmy, která má v každém okamžiku svého rozhodování k dispozici pouze historické údaje. Většina publikací využívá totiž všech dostupných dat, byť s vynecháváním trénovacích množin. To ovšem nutně vede ke skutečnosti, že vytvářený model má při procesu stanovování parametrů k dispozici i data, které by ve skutečnosti známa být neměla a má možnost tak přizpůsobit rozsahy předpovědí i těmto budoucím hodnotám. Výsledek takového experimentu je pak vždy s vysokou pravděpodobností zkreslený.

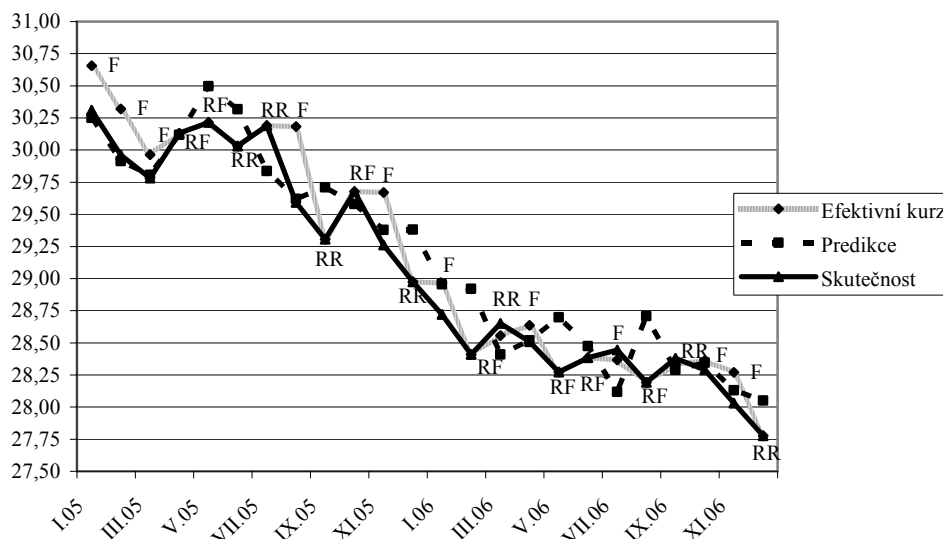
U algoritmu GMDH bylo použito nastavení s nepolynomiálními přenosy omezené na čtyři vrstvy, počet uzlů v každé vrstvě byl omezen na 80. Vstupní proměnné tvořily vybrané relevantní časové řady (spotový kurz CZK/EUR, tříměsíční a šestiměsíční forwardové kurzy CZK/EUR, úrokové sazby v ČR a v EU-15 apod.). Neuronová síť typu *back-propagation* měla jednu skrytou vrstvu čítající trojnásobek neuronů vrstvy vstupní (tedy trojnásobek počtu vstupních atributů).

## 3. Výsledky simulační analýzy

V simulační analýze jsme každý měsíc v letech 2005 – 2006 zajišťovali pohledávku ve výši 400 000 eur se splatností jeden měsíc. K dispozici jsme měli stanovenou zajišťovací strategii a příslušné měsíční predikce kurzu na bázi algoritmu

eGMDH. Celkově jsme tedy realizovali 24 zajišťovacích operací. Graficky je průběh strukturovaného *hedgingu* zachycen na obrázek 6, v němž jsou pro každý měsíc zobrazeny tři různé kurzy koruny vůči euru – ex ante predikovaný kurz, skutečný kurz a efektivní kurz dosažený realizovaným zajištěním. Současně lze z grafu vyčíst i konkrétní instrument použitý v daném měsíci – *forward* (F), opční strategie *Risk Reversal* (RR) a opční strategie *Ratio Forward* (RF).

Obrázek 6  
Průběh strukturovaného *hedgingu*



*Pramen:* Autoři s využitím údajů ČNB [14].

Celkem v deseti případech jsme pohledávku zajistili forwardovým kontraktem. Zajímavý je zde fakt, že z hlediska ex post hodnocení jsme na uzavření dohody o forwardové transakci prodělali pouze jednou, tj. pouze jednou je efektivní kurz pohledávky zajištěné forwardem nižší než skutečný kurz.

Obě opční strategie byly využity shodně, každá v sedmi měsících. Jednoduchá opce tedy nebyla nakoupena nikdy. Pokud jde o opční strategii *Risk Reversal*, tak při ex post hodnocení lze konstatovat, že ve čtyřech případech bylo toto zajištění výhodnější než *forward*, naopak ve třech měsících bychom byli dosáhli lepších výsledků, pokud bychom bývali místo opční strategie uzavřeli dohodu o forwardové transakci. Koupenu prodejní opci v rámci dané strategie jsme

využili jednou, zatímco banka využila svou kupní opci dvakrát. V ostatních případech jsme prodávali 400 000 eur za tržní kurz, tj. obě opce vypršely bez užitku.

Také u opční strategie *Ratio Forward* bychom, ex post hodnoceno, bývali dosáhli ve třech měsících lepších výsledků při zajištění forwardem; čtyřikrát byla naopak úspěšnější opční strategie. Pozitivně lze hodnotit rovněž fakt, že ve všech sedmi případech vypršely obě opce bez využití, tj. vždy jsme prodávali 400 000 eur za aktuální tržní kurz.

Celkově přinesl strukturovaný dynamický hedging ve srovnání s nezajištěními pozicemi dodatečný příjem ve výši 939 896 Kč. Pouze ve třech případech byl efektivní kurz zajištěné pohledávky nižší než aktuální kurz v době splatnosti pohledávky. Firma se přitom nikdy nevystavovala žádnému nadměrnému riziku, protože vždy měla zajištěný nejhorší efektivní kurz buď na úrovni realizačního kurzu koupené prodejní opce, anebo na hodnotě forwardového kurzu.

Využití predikcí na bázi eGMDH algoritmu v rozhodovacím procesu řízení kurzového rizika přineslo lepší výsledky i ve srovnání se strategií zajištění všech otevřených pozic vždy jen jednoduchou opční pozicí (o 3 456 119 Kč), opční strategií *Risk Reversal* (o 1 015 955 Kč) a případně opční strategií *Ratio Forward* (o 801 257 Kč). Pouze strategie zajištění všech otevřených pozic forwardovou operací byla spojena s vyšším celkovým korunovým příjmem (o 118 130 Kč). To lze patrně vysvětlit silným apreciačním trendem české koruny ve sledovaném období a s tím související tendencí k systematickému podhodnocení forwardových kurzů ve vztahu k příslušným budoucím spotovým kurzům (Durčáková a Mandel [17]) na straně jedné a značným prostorem pro další rozvoj a zdokonalování jednotlivých metod strojového učení na straně druhé.

## **Závěr**

Modely umělé inteligence jsou svým charakterem vhodným nástrojem, jenž může jako podpůrný prostředek přispět k fundovanějšímu řešení řady otázek ve finančním řízení firem. Ve srovnání s klasickou statistickou analýzou nabízejí řadu výhod. Tradiční statistické přístupy jsou náročné nejen na čas, ale i na potřebné programové prostředky a znalosti a zkušenosti analytika. Nejčastěji používané modely navíc kladou často velice silné požadavky na zkoumaná data (např. požadavek stacionarity časových řad apod.). V možnostech této analýzy také není zkonstruovat natolik komplexní modely, jaké jsou výsledkem strojového učení, a poskytují pouze linearizovaný model, přičemž je zřejmé, že část zdánlivé náhodnosti v ekonomických časových řadách může být projevem skrytých nelineárních závislostí. V důsledku toho dosahují klasické statistické modely velmi často menší přesnosti než například algoritmy GMDH nebo neuronové sítě.



Představené modely jsou schopny dosáhnout přijatelných výsledků, a to i bez dlouhého ladění jeho různých nastavení, i bez důkladného předzpracování a prozkoumání vstupního datového souboru. Výsledky práce naznačují, že algoritmy strojového učení jsou schopny poskytnout relevantní odhady budoucí situace a přihlídnutí k nim při finálním rozhodování závislé na budoucím stavu měnových kurzů tak s sebou může nést pozitivní výsledky. V naší simulační analýze jsme se přitom snažili především naznačit, jakým způsobem mohou být výsledky modelů strojového učení implementovány do konkrétního rozhodovacího procesu finančního manažera při řízení měnového kurzu. Reálných aplikací pak bude, samozřejmě, mnohem více – od otázek stanovení budoucího kurzu ve finančních plánech firmy, až po problematiku využívání finančních zdrojů a ukládání dočasně volných prostředků v cizích měnách s cílem minimalizovat efektivní sazbu financování, resp. maximalizovat efektivní míru výnosnosti.<sup>6</sup>

## Literatura

- [1] ABRHÁM, J.: Economic Growth and Convergent Processes of the EU Member Base. In: Effective Responses to Globalisation: EU and Beyond. [Sborník.] Praha: Vysoká škola ekonomická v Praze 2007.
- [2] ALVAREZ, F. – ATKESON, A. – KEHOE, P.: If Exchange Rates Are Random Walks, Then Almost Everything We Say about Monetary Policy is Wrong. [Research Department Staff Report 388.] Minneapolis: Federal Reserve Bank of Minneapolis 2007.
- [3] ARLT, J.: Kointegrace v jednorovnicových modelech. Politická ekonomie, VL, 1997, č. 5, s. 733 – 746.
- [4] ARLT, J.: Moderní metody modelování ekonomických časových řad. 1. vyd. Praha: Grada Publishing 1999. 312 s. ISBN 80-7169-539-4.
- [5] ARLT, J. – ARLTOVÁ, M. – ROUBÍKOVÁ, E.: Analýza ekonomických časových řad s příklady. Praha: VŠE v Praze 2002. ISBN 80-245-0307-7.
- [6] AZOFF, E.: Neural Networks Time Series Forecasting of Financial Markets. New York: John Wiley & Sons, Inc. 1994.
- [7] BALKIN, S.: On Forecasting Exchange Rates Using Neural Network: P. H. Franses and P. V. Homelen. Applied Financial Economics, 8, 1998, s. 589 – 596.
- [8] BARRON, R. – MUCCIARDI, A. – COOK, F. – CRAIG, J. – BARRON, A.: Adaptive Learning Networks: Development and Applications in the United States of Algorithms Related to GMDH. In: FARLOW, S. J. (ed.): Self-Organizing Methods in Modeling: GMDH Type Algorithms. New York: Marcel Dekker 1984, s. 25 – 65.
- [9] BELTRATTI, A. – MARGARITA, S. – TERNA, P.: Neural Networks for Economic and Financial Modelling. London: International Thomson Computer Press 1996. ISBN 1-85-032169-8.
- [10] BERKA, P.: Dobývání znalostí z databází. Praha: Academia 2003. ISBN 80-200-1062-9.
- [11] BRADA, J.: Technická analýza. 1. vyd. Praha: VŠE v Praze 2000. 171 s. ISBN 80-245-0096-5.
- [12] BURYAN, P. – ONWUBOLU, G. C.: Design of Enhanced MIA-GMDH Learning Network. International Journal of Systems Science 2007. [Přijaté na publikování.]

<sup>6</sup> Blíže se tímto problémem zabývají například Eiteman et al. [19] a Madura [32].

- [13] BURYAN, P.: Predikce časových řad – statistické metody a strojové učení. [Diplomová práce.] Praha: ČVUT 2006.
- [14] Česká národní banka. 2007. Systém časových řad ARAD. [Online.] Praha 2007. Dostupné z: <[http://www.cnb.cz/cnb/STAT.ARADY\\_PKG.STROM\\_KOREN](http://www.cnb.cz/cnb/STAT.ARADY_PKG.STROM_KOREN)>.
- [15] DAVIS, J. T. – EPISCOPOS, A. – WETTIMUNY, S.: Predicting Direction Shifts on Canadian – US Exchange Rates with Artificial Neural Network. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 10, 2007, č. 2.
- [16] DE OLIVEIRA, K. A. – VANNUCCI, A. et al.: Using Artificial Neural Networks to Forecast Chaotic Time Series. *Physica A: Statistical Mechanics and its Applications*, 284, 2000, č. 1 – 4, s. 393 – 404.
- [17] DURČÁKOVÁ, J.– MANDEL, M.: Mezinárodní finance. Praha: Management Press 2000. ISBN 80-7261-017-1.
- [18] DVOŘÁK, P.: Finanční deriváty. 1. vyd. Praha: VŠE v Praze 1998. ISBN 80-7079-633-2.
- [19] EITEMAN, D. – STONEHILL, A. – MOFFETT, M.: Multinational Business Finance. 10th edition. Boston: Pearson Addison Wesley 2004. ISBN 0-321-20470-0.
- [20] FAYYAD, U. – PIATESKY-SHAPIO, G. – SMYTH, P. – UTHURUSAMY, R. (eds.): Advances in Knowledge Discovery and Data Mining. Chicago: AAAI Press/MIT Press 1996.
- [21] FOKA, A.: Time Series Prediction Using Evolving Polynomial Neural Networks. [Dissertation.] Manchester: University of Manchester, Institute of Science and Technology 1999.
- [22] HAYKIN, S.: Neural Network. New York: Macmillan College Publishing Company, Inc. 1994.
- [23] HE, C. – XU, X.: Combination of Forecasts Using Self-organizing Algorithms. *Journal of Forecasting*, 24, 2005, č. 4, s. 269 – 278.
- [24] HIASSAT, M. – ABBOD, M – MORT, N.: Using Genetic Programming to Improve the GMDH in Time Series Prediction. *Statistical Data Mining and Knowledge Discovery*. Hamparsum Bozdogan (ed.). Boca Raton: Chapman & Hall CRC Press 2003, s. 257 – 268.
- [25] HWANG, H. S. – BAE, S.-T. – CHO, G.-S.: Using Fuzzy GMDH and Neural Network Method. [The Second International Conference on Innovative Computing Information and Kontrol.] Kumamoto City, Japan, September 5 – 7, 2007.
- [26] CHEN, A.-S. – LEUNG, M. T.: Regression Neural Network for Error Correction in Foreign Exchange Forecasting and Trading. *Computers and Operations Research*, 31, 2004, s. 1049 – 1068.
- [27] CHEN, Y. – PENG, L. – ABRAHAM, A.: Exchange Rate Forecasting Using Flexible Neural Trees. [Proceedings of 3<sup>rd</sup> International Symposium on Neural Network 2006.] Chengdu, China, May 2006.
- [28] IVAKHNENKO, A. G. – IVAKHNENKO, G. A.: The Review of Problems Solvable by Algorithms of Group Method Data Handling (GMDH). *Pattern Recognition and Image Analysis*, 5, 1995, č. 4. s. 527 – 535.
- [29] IVAKHNENKO, A. G. – MADALA, H. R.: Inductive Learning Algorithm for Complex System Modelling. Boca Raton: CRC Press 1994. ISBN 0-8493-4438-7.
- [30] KLOESGEN, W. – ZYTKOW, J.: Handbook of Data Mining and Knowledge Discovery. Oxford: Oxford University Press 2002.
- [31] LOOFBOURROW, J. – LOOFBOURROW, T.: What AI Brings to Trading and Portfolio Management. In: FREEDMAN, R., KLEIN, R. and LEDERMAN, J.: Artificial Intelligence in the Capital Markets. Chicago: Irwin 1995, s. 3 – 28.
- [32] MADURA, J.: International Corporate Finance. 8. edition. Mason: Thomson South-Western 2006. ISBN 0-324-32382-4.
- [33] MAŘÍK, V. – ŠTĚPÁNKOVÁ, O. – LAŽANSKÝ, J. a kol.: Umělá inteligence 1 – 4. Praha: Academia 1993. ISBN 80-200-049-3.
- [34] MENEZES, L. M. – NIKOLAEV, N. Y.: Confidence and Prediction Intervals for Polynomial Neural Network. [Online.] 2006. <<http://www.gmdh.net/articles>>.

- 
- [35] NI, H. – YIN, H.: Recurrent Self-organising Maps and Local Support Vector Machine Models for Exchange Rate Prediction. [Proceedings of 3<sup>rd</sup> International Symposium on Neural Networks 2006.] Chengdu, China, May 2006.
- [36] NIKOLAEV, N. – IBA, H.: Genetic Programming using Chebishev Polynomials. [Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2001).]. San Francisco: Morgan Kaufmann 2001, s. 89 – 96.
- [37] OH, S. K. – PEDRYCZ, W.: The Design of Self-organizing Polynomial Neural Network. *Informatic Science*, 141, 2002, s. 237 – 258.
- [38] ONWUBOLU, G. C. – BURYAN, P. – LEMKE, F.: Modeling Tool Wear in End-milling Using Enhanced GMDH Learning Network. *The International Journal of Advanced Manufacturing Technology* 2007. [Přijaté na publikování.]
- [39] SATO, A.: *Mezinárodní obchodní operace II*. 1. vyd. Praha: HZ Editio 1999. 50 s. 40 příloh. ISBN 80-86009-27-0.
- [40] SMITH, K. A.: *Introduction to Neural Networks and Data Mining for Business Applications*. Melbourne: Eruditions Publishing, Monash University Melbourne 1999.
- [41] TAUŠER, J.: *Měnový kurz v mezinárodním podnikání*. Praha: VŠE v Praze 2007. ISBN 978-80-245-1165-8.
- [42] TRIPPI, R. – TURBAN, E.: *Neural Networks in Finance and Investing*. Chicago: Irwin 1996.
- [43] TSAY, R.: *Analysis of Financial Time Series*. New York: John Wiley & Sons, Inc. 2002.
- [44] VOIT, J.: *The Statistical Mechanics of Financial Markets*. Vol. 2. Berlin: Springer 2003.
- [45] WALCZAK, S.: An Empirical Analysis of Data Requirements for Financial Forecasting with Neural Network. *Journal of Management Information Systems*, 17, 2001, č. 4, s. 203 – 222.
- [46] ŽAMBERSKÝ, P.: Silná slabá, slabá silná. Pozor: nebezpečí centrálně plánované ekonomiky. *Euro*, 5, 2002, č. 44, s. 72 – 73.