

# Vážení zákazníci,

dovolujeme si Vás upozornit, že na tuto ukázkou knihy se vztahují autorská práva, tzv. copyright.

To znamená, že ukáзка má sloužit výhradně pro osobní potřebu potenciálního kupujícího (aby čtenář viděl, jakým způsobem je titul zpracován a mohl se také podle tohoto, jako jednoho z parametrů, rozhodnout, zda titul koupí či ne).

Z toho vyplývá, že není dovoleno tuto ukázkou jakýmkoliv způsobem dále šířit, veřejně či neveřejně např. umístováním na datová média, na jiné internetové stránky (ani prostřednictvím odkazů) apod.

*redakce nakladatelství BEN – technická literatura*  
[redakce@ben.cz](mailto:redakce@ben.cz)



metodika své opodstatnění, protože úspěšnost predikce větší než 50 % znamená v případě burzovního prediktivního softwaru úspěch.

Celkový počet rozpoznaných vzorů s mírou shody větší než 70 %	Celkový počet rozpoznaných vzorů s mírou shody větší než 80 %	Celkový počet rozpoznaných vzorů s mírou shody větší než 90 %	Počet úspěšných predikcí trendu na základě nalezených vzorů	Celková úspěšnost predikce v %
9326	6859	2361	1440	61

**Tabulka 4.8: Výsledky úspěšnosti klasifikace a predikce.**


V [43] byl v rámci experimentů používán software Refined Elliott Trader, který byl sice při klasifikaci Elliottových vln velmi přesný, ale na rozdíl od navržené metodiky, lze tento software využít pouze pro průběhy akciových indexů a průběhy jiného charakteru již není schopen klasifikovat. I proto celkový přínos navržené metodiky nelze hodnotit pouze z hlediska úspěšností klasifikace či predikce. Celkový přínos využití navržené metodiky spatřujeme hlavně v různorodosti a komplexnosti jejího nasazení na časové řady bez ohledu na typ zpracovávaných dat či použitý časový interval.

## 4.8 Jak jsme na tom v porovnání s jinými přístupy

Co se týče klasifikace, byla pro adaptaci neuronové sítě zvolena metoda Levenberg-Marquardta z komerčního aplikačního prostředí Wolfram Mathematica. V případě predikce tvořila alternativní přístup Box-Jenkinsonova metodologie implementovaná v NCSS. Následně jsou uvedeny výsledky několika ilustračních příkladů. Jiná experimentální ověření vykazovala podobné numerické výsledky.

### 4.8.1 Porovnání výsledků klasifikace

Pro porovnání výsledků klasifikace jsme za jeden z alternativních přístupů použili metodu Levenberg-Marquardta z komerčního aplikačního prostředí Wolfram Mathematica verze 8, které má implementován NNT (Neural Network Toolbox). V tomto prostředí jsme testovali více přednastavených metod adaptace na minutové řadě Forex EUR/USD od 11.3.2010, viz obrázek 4.39, publikováno v [42, 73].



**Obrázek 4.39: Testovací řada pro porovnání výsledků klasifikace.**

Cílem této experimentální studie, orientované na rozpoznávání Elliottových figur v grafu, bylo ověření vlivu různého nastavení parametrů neuronové sítě na výslednou klasifikaci. Analytické programování zde představovalo nástroj optimalizace pro nalezení vhodného tvaru přenosové funkce neuronů. Byly provedeny tři sady experimentů, nejprve s klasickou sigmoidou a ve dvou případech byl tvar přenosové funkce nalezen pomocí AP. Jelikož tato metoda není vázána ke konkrétnímu evolučnímu algoritmu, v provedených experimentech jsme pracovali s diferenciální evolucí.

### Adaptace metodou Levenberg-Marquardta s tvarem funkce vygenerované pomocí AP


Přenosová funkce vygenerovaná pomocí analytického programování (AP) má tvar (4.1):

$$f(x) = \text{Sin}\left(e^{0.0562851x}\right),$$


$$\text{kde } x = \sum_{i=1}^{n+1} x_i w_i,$$
(4.1)

tj. včetně prahu (=1) a váhy prahu.

Rozpoznáno bylo 31 vzorů s mírou shody 90 až 99 % s definovanými vzory (P1 až P12) trénovací množiny. Následující grafy na obrázcích 4.40 a 4.41 zobrazují rozpoznání některých vzorů trénovací množiny s definovanou mírou shody.



**Obrázek 4.40: Rozpoznání vzoru P3 trénovací množiny (vlevo) s mírou shody 90 až 99 %.**



Obrázek 4.41: Ukázka nalezeného vzoru P4 v časové řadě.

### Adaptace metodou Levenberg-Marquardta s tvarem funkce vygenerované pomocí AP

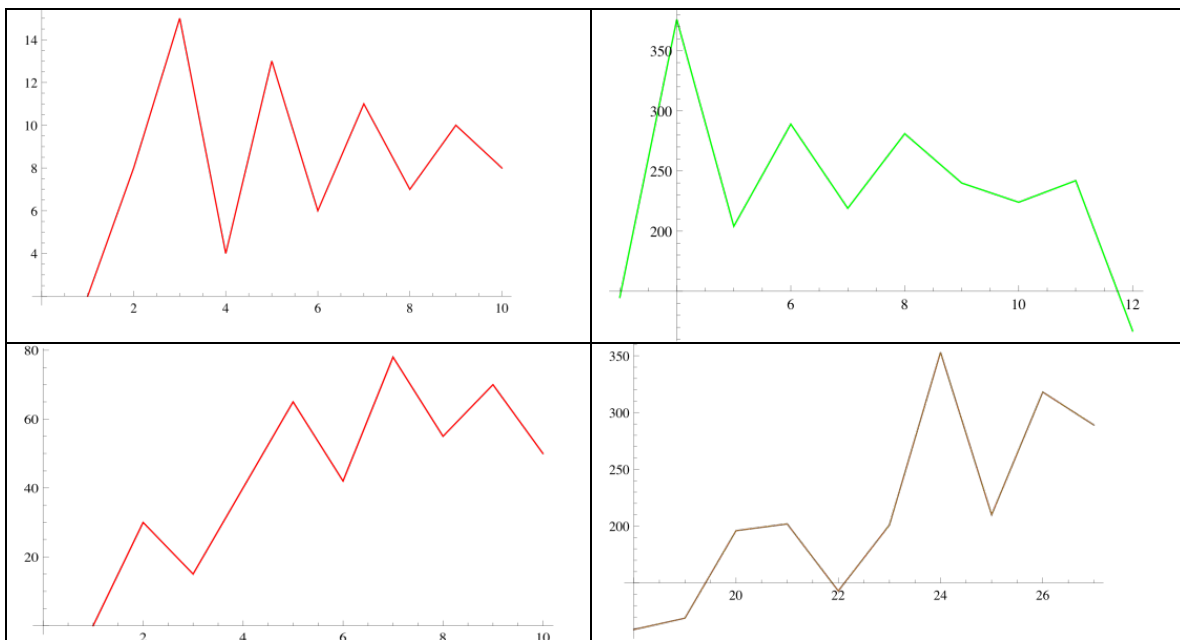
Přenosová funkce vygenerovaná pomocí analytického programování (AP) má tvar (4.2):

$$f(x) = e^{-0.367879e^x},$$


$$\text{kde } x = \sum_{i=1}^{n+1} x_i w_i,$$
(4.2)

tj. včetně prahu (=1) a váhy prahu.

Rozpoznáno bylo 118 vzorů s mírou shody 90 až 99 % s definovanými vzory (P1 až P12) trénovací množiny. Následující grafy na obrázcích 4.42 a 4.43 zobrazují rozpoznání některých vzorů trénovací množiny s definovanou mírou shody.




Obrázek 4.42: Rozpoznání vzorů P3 a P12 trénovací množiny s mírou shody 90 až 99 %.




Obrázek 4.43: Ukázka nalezeného vzoru P1 v časové řadě.

### Adaptace metodou Levenberg-Marquardta se sigmoidální přenosovou funkcí

Rozpoznáno bylo 502 vzorů s mírou shody 90 až 99 % s definovanými vzory (P1 až P12) z trénovací množiny. Toto číslo je značně zkresleno nalézáním více vzorů najednou, což není chybný krok v případě, že bude predikovat správný směr trendu. Tento fakt však nebyl ověřen. Následující grafy na obrázcích 4.44 a 4.45 zobrazují rozpoznání některých vzorů trénovací množiny s definovanou mírou shody.




Obrázek 4.44: Rozpoznání vzoru P9 trénovací množiny s mírou shody 90 až 99 %.



Obrázek 4.45: Ukázka nalezeného vzoru P6 v časové řadě.

## Výsledky navržené metodiky

V daném průběhu testovací řady z obrázku 4.29 bylo rozpoznáno 131 vzorů s mírou shody 90 až 99 %. Navržený multiklasifikátor navíc v 82 případech správně predikoval trend řady po rozpoznání některého vzoru P1 až P12 trénovací množiny, což činí 62,4% úspěšnost. Následující grafy na obrázku 4.46 zobrazují rozpoznání některých vzorů trénovací množiny s definovanou mírou shody.



Obrázek 4.46: Rozpoznání vzorů P12 a P6 trénovací množiny s mírou shody 90–99 %. (červeně je zobrazen vzor trénovací množiny).

Výsledky komparativní studie navrženého klasifikátoru a klasifikátorů, pro jejichž adaptaci byla zvolena metoda Levenberg-Marquardta z komerčního aplikačního prostředí Wolfram Mathematica, jsou vzájemně srovnatelné. Přínosem navržené metodiky je zejména schopnost predikce trendu grafu, po rozpoznání některého vzoru trénovací množiny. Rozhodujícím kritériem tedy je kvalita klasifikace a následná predikce.

### 4.8.2 Porovnání výsledků predikce

Jedním z alternativních přístupů pro porovnání výsledků této predikce byla zvolena Box-Jenkinsonova metodologie s využitím softwaru NCSS. V rámci této metodologie se jako základní prvek konstrukce modelu časové řady bere reziduální složka, která může být utvořena závislými náhodnými veličinami. Tato metodologie může zpracovávat časové řady s navzájem závislými pozorováními. Hlavní myšlenka tedy vychází z korelační analýzy. Celá analýza se v této metodologii provádí podle předem daného postupu, a to v daném pořadí: identifikace modelu, odhad parametrů modelu a výsledné ověřování modelu. Tato metodologie je implementována v mnoha aplikačních modelech, zejména pro úspěšnost predikce a celkovou variabilitou použití. Následují ilustrační příklady provedených srovnávacích experimentů (obrázky 4.47 až 4.49).



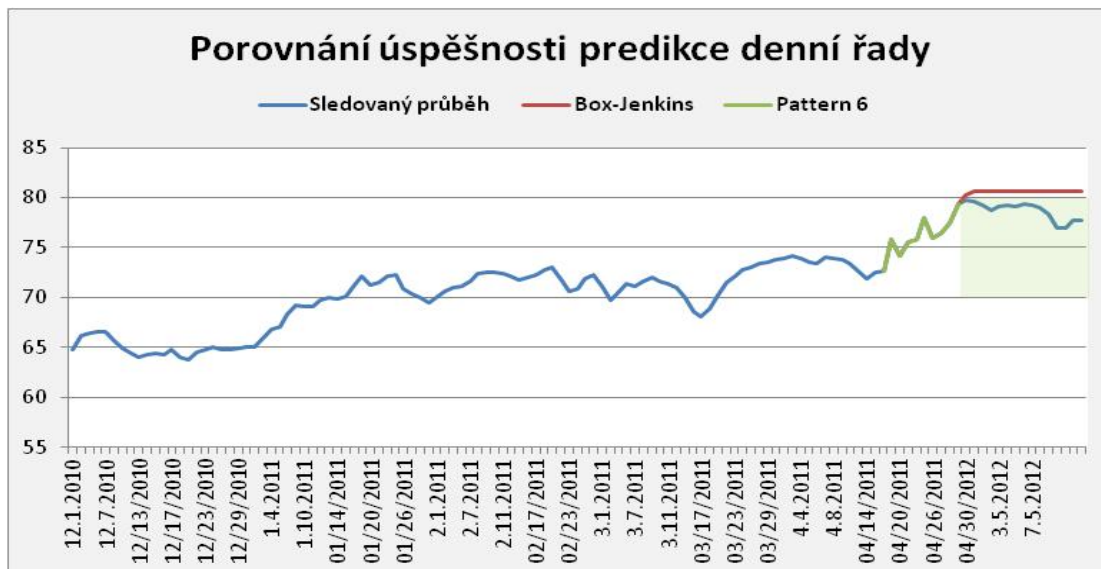
Obrázek 4.47: Porovnání úspěšnosti predikce minutové řady.

V případě porovnání úspěšnosti predikce minutové řady jsme použili průběh zobrazující Forex EUR/USD poměr od 11.3.2010 obsahující 500 minutových hodnot. Navrženou metodikou byl s mírou shody 98 % rozpoznán vzor P6 a je jasně stanoveno, že při nalezení vzoru P6 se vývoj trendu bude po impulsní fázi formovat korekčním směrem. Pro srovnání také Box-Jenkinsonova metodologie predikovala klesající trend vývoje řady. Vše je patrné z obrázku 4.47, kde zeleně vyznačený čtyřúhelník ukazuje místo plochy, kam by se měl dle navržené metodiky ubírat trend řady po rozpoznání vzoru P6.



Obrázek 4.48: Porovnání úspěšnosti predikce hodinové řady.

V následném provedeném experimentu byla zvolena hodinová řada zobrazující objem daných obchodů společnosti Coca Cola corp. od 1.1.2012 do 24.1.2012 obsahující 500 hodinových hodnot. Navrženou metodikou byl s mírou shody 93 % rozpoznán vzor P9 korekčního charakteru a multiklasifikátor predikoval impulsní charakter trendu. Z grafu na obrázku 4.48 je patrné, že Box-Jenkinsonova metodologie také predikovala úspěšně směr trendu řady. Zeleně vyznačený čtyřúhelník ukazuje místo plochy, kam by se měl dle navržené metodiky ubírat trend řady po rozpoznání vzoru P9.



Obrázek 4.49: Porovnání úspěšnosti predikce denní řady.

V dalším experimentu byla použita denní data průběhu zobrazujícího akciový vývoj společnosti Boeing corp. od 12. 1. 2010 až 6. 5. 2012. V tomto případě byl navrženou metodikou rozpoznán vzor P6 s mírou shody 89 % a budoucí vývoj trendu by se pak měl ubírat korekčním směrem, což je patrné i z grafu na obrázku 4.49. Box-Jenkinsonova metodologie predikovala na rozdíl od navrženého multiklasifikátoru vývoj trendu neklesající.

## 4.9 Závěry a přínosy navržené metodiky

Navržená metodika využívá interdisciplinárního přístupu a efektivně kombinuje jednotlivé metody umělé inteligence za účelem rozpoznání struktur Elliottových vln s následnou predikcí trendu řady. Pro optimalizaci parametrů neuronové sítě bylo použito analytické programování. Byly provedeny experimentální studie, které demonstrují možnosti použití navržené metodiky na prediktivní úlohy. Kvalita řešení na základě navržené metodiky byla srovnána s výsledky získanými jinými metodami nejen z oblasti umělé inteligence.

Celá metodika je navržena tak, že skýtá bohaté možnosti dalšího vývoje. Navržená metodika je uplatnitelná nejen na predikci trendu burzovního vývoje cen a volume, ale lze ji aplikovat na jakoukoliv jinou časovou řadu s fraktální dynamikou (např. na predikci slunečních skvrn). Celá Elliottova teorie je tvořena spoustou jednoznačně definovaných pravidel, které zde nebyly zohledněny. Další možností, jak lze navrženou metodiku zpřesnit, je navrhnout více vzorů s využitím dalších pravidel a směrnic Elliottovy teorie a vytvořit tak bohatší trénovací množinu, jež umožní detailnější klasifikaci. Klasifikační problém řešený neuronovými sítěmi je obvykle reprezentován vhodně vytvořenou trénovací množinou. Pokud by byla vytvořena trénovací množina reprezentující jiný klasifikační problém a báze pravidel znalostního systému reprezentujícího následnou predikci trendu řady, lze navrženou metodiku použít bez omezení časové řady, což je případ regulace chování libovolného systému na základě nalezení charakteristických vzorů jeho chování v grafu.



## 5 Automatické obchodní systémy

### 5.1 Několik mýtů úvodem

Spousta obchodníků (traderů), a to i těch zkušenějších, jsou poznamenáni představami, předsudky a mýty o automatickém obchodování, ke kterému přistupují buď nezdravě optimisticky, nebo naopak s předsudky. Proto uvedeme několik těchto nejznámějších „pravd“ o automatických obchodních systémech (AOS) na pravou míru. Celý tento úvodní text je volně zpracován podle [60].

#### **Mýtus první: „AOSy nevydělávají a dlouhodobě nefungují“ [60].**

Pravda je taková, že ano i ne. Fakt, zda AOS bude fungovat a vydělávat závisí na několika již předem daných faktorech. Prvním z nich je již návrh samotného systému tak, jak jej obchodujeme. Pokud máme systém již hotový a jako takový jej dlouhodobě obchodujeme ručně a se ziskem, je velmi nepravděpodobné, že nám přestane po nějakém čase fungovat, pokud si jej přesně tak naprogramujeme i s případnými nastavitelnými parametry, které jsme za tu dobu, co systém používáte, museli změnit nebo poupravit. V tomto případě je mýtus vyvrácen experimentem.

Složitější situace nastane, pokud systém teprve navrhujeme, vymýšlíme, případně používáme krátkou dobu. Pak je rozhodným faktorem naše psychologie, tj. jaké chování systému jsme schopni snést, jak často má systém ztrátovou „šňůru“, a další podobné parametry. Proto, když navrhujeme systém, měl by být robustní. Pokud máme při určitém nastavení indikátorů na konci testu zisk, a stačí, když jej jen trochu změníme a máme ztrátu, je něco špatně už na samotné myšlence. Takový systém nikdy nebude správně fungovat.

#### **Mýtus druhý: „AOS mně zbaví psychologické náročnosti a zodpovědnosti za moje obchody“ [60].**

Rozdělme si tuto větu na dvě části. V té první je pravda opět někde „mezi“. Záleží na přístupu k tradingu jako takovému a opět záleží na tom, jak je AOS „starý“, prověřený časem a reálnými obchody. Druhou část mýtu uvedeme na pravou míru hned a okamžitě: Nikdy! Vždy si neseme odpovědnost za obchod, který nám AOS otevřel nebo zavřel jen my sami, a to ať už byl tento obchod ztrátový či ziskový.

#### **Mýtus třetí: „Diskreční systémy se nikdy nemohou stát AOSem“ [60].**

Pod pojmem „diskreční systém“ rozumíme takový systém, jehož pravidla jsou srozumitelná člověku, ale nelze je interpretovat strojům. V tom případě je tento mýtus lež. Naopak, pokud si někdo představuje diskreci jako „mrknu se na graf a vidím ... ale proč vidím a co vidím, říct neumím, prostě to tam je“, tak v tomto případě je to čistá pravda a toto se opravdu programovat nedá.

Stroj nemyslí, je přísně pragmatický a racionální, ale zato je přesný a neomylný. Takže pokud do stroje dáme nějaká čísla, on je zpracuje na výsledek. Jinými slovy, pokud obchodujeme něco, ať je to cokoli, co dokážeme vyjádřit v číslech, tak takovéto systémy je možné programovat jako AOS. Čísla zde stanovují meze, kdy signál je kvalitní, a kdy už je horší kvality.