VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ
ÚSTAV INFORMATIKY

FACULTY OF BUSINESS AND MANAGEMENT
INSTITUTE OF INFORMATICS

VYUŽITÍ UMĚLÉ INTELIGENCE NA KAPITÁLOVÝCH TRZÍCH

THE USE OF ARTIFICIAL INTELLIGENCE ON STOCK MARKET

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE Bc. JURAJ KOVÁČIK
AUTHOR

VEDOUCÍ PRÁCE prof. Ing. PETR DOSTÁL, CSc.
SUPERVISOR

BRNO 2014

Vysoké učení technické v Brně
Fakulta podnikatelská

Akademický rok: 2013/2014
Ústav informatiky

ZADÁNÍ DIPLOMOVÉ PRÁCE

Kováčik Juraj, 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:

Využití umělé inteligence na kapitálových trzích

v anglickém jazyce:

The Use of Artificial Intelligence on Stock Market

Pokyny pro vypracování:

Úvod
Vymezení problému a cíle práce
Teoretická východiska práce
Analýza problému a současné situace
Vlastní návrhy řešení, přínos návrhů řešení
Závěr
Seznam použité literatury
Přílohy

Podle § 60 zákona č. 121/2000 Sb. (autorský zákon) v platném znění, je tato práce "Školním dílem". Využití této práce se řídí právním režimem autorského zákona. Citace povoluje Fakulta podnikatelská Vysokého učení technického v Brně.

Abstrakt

Diplomová práca sa zaoberá tvorbou a optimalizáciou umelých neurónových sietí, ktoré sú následne využité pre predikciu vývoja časových rád.

Abstract

This master thesis describes the creation and optimization of artificial neural networks which are subsequently utilized to predict the development of time series.

Kľúčové slová

Neurónová sieť, MATLAB, FOREX, Technická analýza, GMMA, NARX, FTDN, optimalizácia

Keywords

Neural network, MATLAB, FOREX, Technical analysis, GMMA, NARX, FTDN, optimization

KOVÁČIK, J. *Využití umělé inteligence na kapitálových trzích.* Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2014. 72 s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Čestné prehlásenie

Prehlasujem, že predložená diplomová práca je pôvodná a spracoval som ju samostatne. Prehlasujem, že citácia použitých prameňov je úplná, že som vo svojej práci neporušil autorské práva (v zmysle Zákona č. 121/2000 Zb., o práve autorskom a o právach súvisiacich s právom autorským)

V Brne, 28.5.2014 ……..

Poďakovanie

Týmito slovami si dovoľujem poďakovať pánovi prof. Ing. Petrovi Dostálovi, CSc., za odbornú pomoc, vecné rady a pripomienky pri spracovaní tejto diplomovej práce.

Obsah

Úvod ... 9
1 Vymedzenie problému a cieľ práce ... 10
1.1 Vymedzenie problému ... 10
1.2 Cieľ práce ... 10
2 Teoretické východiska ... 11
2.1 Finančný systém a trhy ... 11
2.1.1 Finančné trhy ... 12
2.1.2 Trhy derivátov ... 17
2.2 Časové rady ... 17
2.2.1 Hurstov eponent ... 18
2.3 Analytické prístupy oceňovania ... 19
2.3.1 Fundamentálna analýza ... 19
2.3.2 Psychologická analýza ... 19
2.3.3 Technická analýza ... 20
2.4 Neurónové siete ... 25
2.4.1 História ... 25
2.4.2 Model neurónu ... 26
2.4.3 Aktivačné funkcie ... 26
2.4.4 Sieťová architektúra ... 28
2.4.5 Učenie siete ... 29
2.4.6 Prostredie MATLAB ... 31
3 Analýza súčasného stavu ... 35
3.1 Základné informácie o firme ... 35
3.1.1 Predmety podnikania ... 35
3.1.2 Sortiment služieb ... 36
3.1.3 Technické zázemie ... 36
3.2 SWOT analýza ... 37
3.2.1 Silné stránky ... 37
3.2.2 Slabé stránky ... 38
3.2.3 Príležitosti ... 38

3.2.4 Hrozby ... 38
3.3 Požiadavky na aplikáciu ... 39
4 Vlastný návrh riešenia ... 40
4.1 Príprava dát ... 40
4.1.1 Extrakcia dát z platformy ... 40
4.1.2 Výpočet indikátorov technickej analýzy ... 43
4.1.3 Rozdelenie dát ... 45
4.2 Neurónová sieť NARX ... 46
4.2.1 Štruktúra siete ... 46
4.2.2 Učenie siete ... 49
4.2.3 Výsledok predikcie ... 51
4.3 Neurónová sieť FTDN ... 53
4.3.1 Štruktúra siete ... 53
4.3.2 Učenie siete ... 53
4.3.3 Výsledok predikcie ... 56
4.4 Optimalizácia a porovnanie modelov ... 57
4.4.1 Model NARX ... 58
4.4.2 Model FTDN ... 60
4.5 Ekonomické zhodnotenie ... 66
4.5.1 Náklady ... 66
4.5.2 Prínosy ... 67
5 Záver ... 68
Zoznam použitej literatúry ... 69
Knižné publikácie ... 69
Elektronické zdroje ... 70
Zoznam obrázkov ... 71
Zoznam tabuliek ... 72

Úvod

Ľudská existencia bola odpradávna hnaná zvedavosťou a túžbou predpovedať budúcnosť. Túto snahu badať naprieč širokým spektrom oblastí, medzi ktoré možno zaradiť aj finančné trhy. Cieľom snahy o predpovedanie vývoja trhu je dosiahnutie zisku, a preto obchodníci hľadajú prostriedky, ktoré by viedli k dosiahnutiu tohto cieľa. V priebehu času vzniklo množstvo analytických prístupov, ktoré majú takéto predpovede umožňovať.

V prvom rade to sú metódy technickej analýzy založené na skúmaní minulého vývoja a hľadaní opakujúcich sa vzorov . Ďalším dôležitým prístupom je fundamentálna analýza, ktorá slúži k nájdeniu skutočnej (vnútornej) ceny a stavia ju do protikladu k cene tržnej. V neposlednom rade je potreba spomenúť psychologickú analýzu pracujúcu s predpokladom, že účastníci trhu podliehajú svojim emóciám.

V posledných rokoch sa však do popredia dostávajú prostriedky, ktoré boli inšpirované biologickými procesmi a systémami, ktoré sú známe z prírody. Medzi takéto systémy patria umelé neurónové siete, ktoré sú učené na historických dátach a na ich základe produkujú predikcie o budúcom vývoji.

Je však potrebné si uvedomiť, že súčasné technológie a prostriedky umelej inteligencie nenahrádzajú ľudskú inteligenciu a kreativitu. Môžu však slúžiť ako kvalitný podporný prostriedok pri rozhodovaní sa na finančnom trhu.

1 Vymedzenie problému a cieľ práce

1.1 Vymedzenie problému

Práca je spracovaná pre slovenskú spoločnosť IJM Group, s.r.o, ktorej hlavným predmetom činnosti je technická podpora retail obchodníkov a vývoj automatických obchodným stratégií. Spoločnosť prejavila záujem o inováciu v podobe využitia neurónových sietí vo svojich produktoch.

1.2 Cieľ práce

Cieľom práce je poskytnúť teoretické informácie z oblastí neurónových sietí a ich aplikácie na finančné časové rady. Praktická časť práce spočíva vo vytvorení dvoch modelov sietí, ich následnej optimalizácií a porovnaní dosiahnutých výsledkov.

Modely neurónových sietí budú predikovať zatváraciu cenu menového páru EUR/USD na 5 obchodných dní dopredu. Záverom budú modely porovnané za účelom zodpovedania otázky o možnosti využitia neurónových sietí spoločnosťou IJM Group, s.r.o. K vytvoreniu neurónových sietí a optimalizácií bude využitý program MATLAB.

2 Teoretické východiska

Nasledujúca kapitola poskytuje teoretické informácie potrebné pre porozumenie problematiky a širších súvislostí diplomovej práce.

2.1 Finančný systém a trhy

Finančný systém je mechanizmus, pomocou ktorého možno premiestniť kapital od prebytkových subjektov k potrebným. Je to priestor, v ktorom sú realizované finančné služby a je jedinečný pre každú krajinu. Štruktúru finančného systému možno predstaviť nasledovne: [10]

- Užívatelia finančného systému,
- finančné inštitúcie ktoré poskytujú finančné služby,
- finančné dokumenty, ktoré zaznamenávajú uávazok v podobe finančného nástroja,
- finančné trhy,
- orgány finančného dohľadu.

Finančný systém ako systém ovplyvňujúci hospodárstvo ma niekoľko funkcií: [7]

- **Platobná** – umožňuje sprostredkovanie platobného styku a to ako hotovostného tak bezhotovostného.
- **Emisná** – tvorba peňažných prostriedkov vo finančnom systéme.
- **Redistribučná** – obsahom funkcie je poskytnutie úverov čo znamená úverovú (investovanie úspor) a depozitnú činnosť finančného sprostredkovateľa pri presune prostriedkov od deficitného k prebytkovému subjektu.
- **Stimulačná**– má za úlohu motiváciu subjektov k úsporám. Stimuláciu reguluje štát a podporuje ju rôznymi krokmi (ochrana finančných prostriedkov, zvýhodnenie istých typov služieb a podobne).

- **Transformačná** –proces premeny úspor na fondy z ktorých možno financovať investície.
- **Informačná** – zabezpečuje a sprostredkováva informácie pre subjekty v systéme.
- **Kontrolná** –umožňuje dohľad a reguláciu , ktorú vykonáva orgán regulácie.
- **Ochrana proti riziku** – funkcia zaisťujúca ochranu jednotlivých ekonomických subjektov proti rôznym druhom rizika za využitia poistných zmlúv. Taktiež umožňuje subjektom vytváranie diverzifikovaných portfólií čím dochádza k rozkladu rizika prípadných cenových poklesov.
- **Uchovanie bohatstva** – za využitia finančných nástrojov umožňuje ekonomickým subjektom uchovať ich kúpnu silu až do doby použitia odložených peňažných zdrojov s minimalizáciou dôsledkov inflácie.

2.1.1 Finančné trhy

Trh je vo všeobecnosti miesto stretu dopytu a ponuky a je súčasťou finančného systému. Finančný trh umožňuje presun peňažných prostriedkov medzi rozličnými subjektmi - jednotlivcami prípadne firmami. Tieto subjekty sa stretávajú práve na finančnom trhu. Prebytkové subjekty vstupujú na finančný trh predovšetkým za účelom investície, teda obetovaniu súčasnej hodnoty s vidinou inkasovania vyššej hodnoty budúcej. Ďalšou dôležitou úlohou je likvidita, ktorá umožňuje pri minimálnych nákladoch zmenu portfólia pred splatnosťou a to ako deficitným tak prebytkovým subjektom. [7]

Finančné trhy možno členiť podľa niekoľkých hľadísk. Podkapitola ozrejmuje delenie podľa druhov finančných inštrumentov , ktoré sa na jednotlivých častiach trhu obchodujú.

2.1.1.1 Kapitálový trh

Na tomto type trhu dochádza k pohybu strednodobého a dlhodobého kapitálu medzi rozličnými ekonomickými subjektmi prostredníctvom úverov či rôznych foriem

cenných papierov. Obchody sú realizované prostredníctvom finančných sprostredkovateľov ktorými sú predovšetkým banky a obchodníci s cennými papiermi (tzv. broker, sprostredkováva prístup ku kapitálovému trhu). Sprostredkovateľ nenesie akékoľvek záväzky za dlžníka, vykonáva iba pokyn na nákup či predaj. Za zadanie pokynu je sprostredkovateľom účtovaný poplatok, provízia. Kapitálové trhy sa delia nasledovne: [9]

Trh dlhodobých cenných papierov

Tento typ trhu umožňuje emisiu cenných papierov. Najvýznamnejšie sú hlavne obligácie, teda dlhodobé dlhopisy a akcie. Subjekty, ktoré si na trhu požičiavajú peniaze sú emitenti zastúpení štátom, bankami a veľkými spoločnosťami. Dôvodom ich vstupu na trh je snaha získať dlhodobý kapitál na realizáciu investícií a projektov.

Na opačnej strane vstupujú investori tvorení bankami, fondmi, domácnosťami či jednotlivcami, ktorí sú motivovaní dosiahnutím vyššieho zhodnotenia investovaného kapitálu ako napríklad na peňažnom trhu.

Dôležitou vlastnosťou cenných papierov je prevoditeľnosť, inými slovami možnosť obchodovania. Investor ich nemusí držať počas celej doby životnosti. Podľa uváženia ich môže predať a realizovať zisk prípadne stratu.

Trh dlhodobých úverov

Poskytované sú predovšetkým bankami, ktoré za ne požadujú ručenie napríklad nehnuteľnosťou a to kvôli vysokému objemu prostriedkov a dlhodobému časovému úseku.

2.1.1.2 Peňažný trh

Doba trvania finančných operácii na peňažnom trhu spravidla nepresahuje trvanie jedného roku. Na tomto type trhu sa stretávajú prebytkové subjekty s deficitnými subjektmi, ktoré dopytujú peňažné prostriedky. Hlavnou funkciou je poskytovanie

peňažných pôžičiek a financovanie prevádzkového kapitálu. Významného hráča na finančnom trhu predstavuje štát, ktorý ako deficitný subjekt emituje pokladničné poukážky – dôležitý inštrument finančného trhu.

Trh krátkodobých cenných papierov

Deficitné ekonomické subjekty dopytujú finančné prostriedky prostredníctvom ponuky krátkodobých cenných papierov (pokladničné poukážky, zmenky a pod).

Trh krátkodobých úverov

Predstavuje poskytovanie úverov navzájom medzi bankami, centrálnou bankou a bankami. Taktiež sem patria obchodné úvery poskytované medzi firmami navzájom a uložené vklady obyvateľstva u bánk.

2.1.1.3 Menový trh

Ako vypovedá názov, tieto trhy možno charakterizovať ako trhy kde sa vykonáva zmena jednej meny za inú. Možno ich rozdeliť na dva segmenty: [6]

- **Devízové trhy** – sú trhy s bezhotovostnými formami cudzích mien kde dochádza k ich vzájomnej výmene a tým aj tvorbe devízového kurzu. Najvýznamnejší účastníci tohto trhu sú banky ktoré obchodujú na vlastný účet alebo zastupujú klienta. Centrálne banky majú na devízových trhoch zvláštne postavenie, pomocou nákupov a predajov mien môžu ovplyvňovať vývoj menových kurzov (intervencie).
- **Valutové trhy** – predstavujú trhy s hotovostnou formou cudzích mien, ktoré sa obchodujú na tzv. valutové kurzy. Tieto kurzy sú odvodzované spravidla z devízových kurzov.

Pre potreby diplomovej práce bude v nasledujúcej časti rozobraný devízový trh FOREX (foreign exchange, skrátene FX) , ktorého stredné kurzy sú považované za oficiálne svetové kurzy. Predstavuje mimoburzový (OTC, over the counter) trh, ktorý nie je geograficky lokalizovaný ani organizovaný. Účastníci trhu sa obracajú na svojho

sprostredkovateľa (broker) , ktorý vykoná obchod. Výška denných obratov podľa odhadov prekračuje 3 bilióny amerických dolárov, čo predstavuje najväčší finančný trh na svete. [6]

Špecifickou vlastnosťou je možnosť obchodovať 24 hodín denne, 5 dní v týždni. Tento trh svojim rozsahom pokrýva Tokio, Londýn a New York čím je zabezpečená 24 hodinová dostupnosť naprieč časovými pásmami. [5]

Menové páry

Pri obchodovaní na devízovom trhu dochádza k výmene jednej meny za menu inú. Z logiky veci nemá opodstatnenie výmena napríklad EUR za EUR. Dve navzájom vymeniteľné meny tvoria menový pár. Na prvom mieste páru je uvedená bázová mena a na druhom mieste mena kótovacia. Kurz páru vyjadruje cenu jednotky základnej (bázovej) meny v jednotkách kótovacej meny. [6]

Za hlavnú svetovú menu sa považuje americký dolár a je väčšinou uvádzaný ako základná mena. Páry ktoré neobsahujú dolár ani ako bázovú ani ako kótovaciu menu sú označované za krížové páry.

Z pohľadu likvidity možno rozdeliť meny na **hlavné**, ktoré sú najviac likvidné a zastúpené napríklad americkým dolárom, britskou librou či japonským jenom. **Vedľajšie** meny sú síce voľne dostupné ale na spotovom trhu môžu mať občasne nižšiu likviditu (nórska koruna, kanadský dolár, ...). **Exotické** meny predstavujú meny, ktoré nie sú často obchodovateľné z dôvodu malého záujmu a nízkej likvidity. [6]

Pákový efekt

Základným princípom pákového efektu je využitie menšieho objemu vlastného kapitálu doplneného cudzím kapitálom za účelom navýšenia zisku z investície. Výška pákového

efektu záleží od toho, s čím investor obchoduje. V prípade Forexu môže dosahovať 1:100 ale napríklad u akcií je častejšia podstatne nižšia páka, napríklad 1:2.

Finančná páka 1:100 umožňuje obchodovanie s kapitálom až 100-krát väčším, než je hodnota účtu. S prostriedkami v hodnote 1000 USD možno obchodovať s 100000 USD čím sa násobí prípadný zisk z obchodu ale rovnako aj prípadná strata. [5]

K obchodovaniu s pákou sa využívajú maržové účty. Broker od obchodníka požaduje záruku (maržu), ktorou sa broker istí voči prípadnej strate. Keď je pozícia obchodníka ohrozená, broker požaduje navýšenie kapitálu (margin call). Pokiaľ nedôjde k navýšeniu , obchod je uzavretý. Úroveň marže pri ktorej dochádza k margin call sa u brokerov líši.

Cena ponuky a dopytu

Na devízových trhoch neexistuje iba jedna univerzálna cena aktíva. Rozlišuje sa cena ponuky (**ask**) a cena dopytu **(bid).** Ask cena ponuky predstavuje cenu, za ktorú sa obchodníci pokúšajú predať daný inštrument. Naproti tomu bid cena dopytu predstavuje cenu , za ktorú je obchodník ochotný nakúpiť. Rozdiel medzi cenou ask a bid je **spread**, ktorý je úmerný likvidite inštrumentu. V málo likvidných trhoch a v čase vyhlasovania dôležitých makroekonomických dát dochádza k „roztiahnutiu“ spreadu, rozdiel medzi ask a bid cenou je väčší. [6]

Spred odráža transakčné náklady na otvorenie a uzavretie pozície. Častokrát sú jediným poplatkom ktorý obchodník platí brokerovi. Pre brokera tak predstavuje poplatok za vykonanie obchodného príkazu.

2.1.2 Trhy derivátov

Podstatou trhu derivátov sú inštrumenty odvodené od podkladového aktíva (napríklad akcie). Pohyb ceny derivátu súvisí s cenovým pohybom podkladového aktíva. Predstavujú inštrumenty , ktoré sa obchodujú na maržu a na ich nákup nie je potrebný celý objem peňažných prostriedkov v hodnote inštrumentu. Medzi deriváty sa okrem iného radia: [7]

- Futures – dohoda o budúcom dodaní určitého množstva komodity za vopred stanovenú cenu a vo vopred známom množstve.
- Opcie – predkupné právo, ktoré umožňuje prednostnú kúpu za presne stanovenú cenu. Vlastník opcie ma právo nie však povinnosť požadovať plnenie uzatvoreného terminováneho obchodu za vopred stanovenú cenu.
- CFD – rozdielové kontrakty (Contracts For Difference).

2.2 Časové rady

Vývoj cien na finančných trhoch vytvára časové rady, ktoré predstavujú postupnosť číselných hodnôt v závislosti na čase. Časový úsek medzi vzorkami je spravidla konštantný. Mení sa frekvencia, ktorá môže byť od minút až po roky a určuje sa na základe požadovanej presnosti merania a potreby aplikácie. [2]

Dostál delí zložky časových rad na deterministické a stochastické. Ich ďalšie delenie je nasledovné: [2]

- Stochastická časová rada
- Deterministická časová rada
    - Lineárna – konštantná, zostupná, vzostupná
    - Periodická – s konštantnou periódou, s premenlivou periódou
    - Chaotická

2.2.1 Hurstov eponent

Predstavuje štatistický prostriedok vychádzajúci z fraktálnej analýzy a možno ho využiť k deleniu časových rád a k posúdeniu miery ich chaotičnosti. Podľa hodnoty indexu rozlišujeme radu chaotickú alebo radu náhodnú. Snaha o predpovedanie vývoja náhodnej rady je väčšinou neúspešná, vývoj je možné s rozumnou mierou predpovedať u chaotickej rady. [2]

Hurstov exponent (H) dosahuje hodnoty v intervale od 0 do 1. Na základe nadobudnutých hodnôt možno rozdeliť časové rady do nasledujúcich troch kategórii: [2]

- H = 0,5 – náhodná časová rada s normálnym rozdelením, neobsahuje dlhodobý pamäťový cyklus. Medzi jednotlivými hodnotami neexistuje žiadna závislosť a preto je veľmi zložité odhadnúť jej ďalší vývoj.
- 0 < H < 0,5 – časová rada s dlhodobým pamäťovým cyklom, označuje sa ako antiperzistentná. Typickou vlastnosťou je nasledovanie vzostupného trendu zostupným (a opačne). Spomenutá vlastnosť nadobúda na intenzite s hodnotami bližšími k nule.
- 0 < H < 1 – obdobne ako v predchádzajúcom prípade sa jedná o časovú radu s dlhodobým pamäťovým cyklom avšak jej chovanie je perzistentné. Zachováva smer trendu, tzn. rastúci trend bude pravdepodobne rásť aj naďalej a opačne. Väčšina ekonomických časových rad spadá do tejto kategórie.

2.3 Analytické prístupy oceňovania

Rozhodnutie investora o investovaní do zvoleného inštrumentu podlieha analýze, ktorá sa delí na tri nasledujúce rozdielne typy: [7]

- Fundamentálna analýza,
- psychologická analýza,
- technická analýza.

2.3.1 Fundamentálna analýza

Vychádza z predpokladu, že každý inštrument na trhu je možno oceniť správnou, tzv. vnútornou cenou. Predpokladá, že cena je determinovaná cenotvornými faktormi, ktorých analýzou sa stanovuje vnútorná cena. Porovnaním ceny na trhu a vnútornej ceny investor zistí, či cena zodpovedá vnútornej cene a teda či je inštrument nadhodnotený alebo podhodnotený. Z tejto informácie vyplýva rozhodnutie o prípadnom nákupe a predaji. Fundamentálna analýza sa člení na tri časti. Odvetvová sa zaoberá makroekonomickými faktormi, špecifikami a dopadmi jednotlivých odvetví na cenu. Firemná fundamentálna analýza hodnotí najdôležitejšie finančné parametre spoločnosti. Trojicu uzatvára globálna analýza, ktorá skúma faktory ekonomiky a jej vplyv na cenu. [6]

2.3.2 Psychologická analýza

Predpokladá, že investovanie je subjektívne rozhodnutie a cena inštrumentu je ovplyvnená psychikou investorov. Snaží sa nájsť podnet, ktorý v danej situácií viedol k chovaniu investorov a teda k tomu, že začali hromadne kupovať alebo predávať. Cieľom psychologicky orientovaného investora je pozorovať chovanie ostatných investorov, porozumieť ich uvažovaniu a dôvodom ich skutkov a z toho vyvodiť vlastný záver. [5]

Problematikou psychologickej analýzy sa zaoberajú predovšetkým nasledovné teórie:

- Kostelanyho psychologický prístup.
- Teória špekulatívnych bublín.
- Keynesova investičná psychológia.

2.3.3 Technická analýza

Náplňou technickej analýzy je skúmanie historických dát, ktoré popisujú minulý vývoj na trhu. Na základe týchto dát sa snaží o prognózu budúcich cien. Východiskom pre technickú analýzu je teória formulovaná Charlesom Dowom postavená na pozorovaní akciového trhu. Základné predpoklady technickej analýzy možno definovať v troch nasledujúcich bodoch: [6]

- **Trh diskontuje všetko** – v cene inštrumentu sú zahrnuté všetky v danej dobe známe faktory ktoré ju môžu ovplyvniť.
- **Ceny sa pohybujú v trendoch** – rozpoznanie trendu (smeru) je možné čítaním grafov vývoja cien. Podľa Dowovej teórie sa pohyb na trhu skladá z troch druhov trendov na primárny, sekundárny a terciálny. Primárny trend trvá dlhšie ako jeden rok, sekundárny trvá v rozmedzí od troch týždňov až mesiac. Terciálny trend reprezentuje krátkodobé výkyvy trvajúce maximálne tri týždne.
- **História sa opakuje** – analýzou grafov možno nájsť opakujúce sa vzory (formácie) vo vývoji cien a dospieť tak k záveru, že tieto vzory sa v čase opakujú. Vyplýva to z faktu, že spôsob ľudského chovania sa v určitých situáciách opakuje. Dá sa predpokladať, že tieto vzory sa budú vo vývoji cien vyskytovať aj ďalej. Dôležité pre investora je vzory včas rozpoznať a reagovať na ne.

2.3.3.1 Grafické metódy

Predstavujú metódy čítania grafov, identifikovania trendov a hľadania opakujúcich sa vzorov. Podľa monotónnosti postupnosti lokálnych maxím a miním sú rozoznávané 3 typy trendov. Rastúci trend je charakterizovaný postupne sa zvyšujúcimi maximami a minimami. Klesajúci, analogicky, charakterizujú postupne klesajúce maximá a minimá. Pri bočnom (postrannom) trende maximá a minimá oscilujú v okolí

vodorovnej línie. K zakresleniu trendov sa využíva trendová línia, ktorá spája lokálne minimá (rastúci trend) respektíve lokálne maximá (klesajúci trend). [5]

Lokálne minimá a maximá môžu vytvárať oblasti podpory (support) a odporu (resistance), ktoré hrajú pri obchodovaní významnú psychologickú rolu. Podpora predstavuje cenovú hladinu, pri ktorej je dopyt po investičnom inštrumente na takej úrovni, že spôsobí zastavenie klesajúceho trendu a dôjde k otočeniu trendu. Reprezentuje cenu, pod ktorú už investori nechcú predávať. Odpor je hladina ceny, pri ktorej je ponuka na takej úrovni, že spôsobí zastavenie rastúceho trendu. Zodpovedá maximálnej cene, ktorú sú ochotní investori zaplatiť. Prielom (break) je situácia kedy sa cena inštrumentu dostane nad hranicu rezistencie (respektíve pod hranicu podpory).

Pre sledovanie grafov a obchodovanie sa využívajú tri hlavné typy grafov, ktoré zobrazujú na ose x čas a na ose y cenu. Schodový graf patrí medzi OHLC grafy, tzn. zobrazuje otváraciu, najvyššiu, najnižšiu a uzatváraciu cenu v danú jednotku času. Časová jednotka je reprezentovaná jednou úsečkou. Otváracia cena je na ľavej strane úsečky, uzatváracia cena na pravej strane.

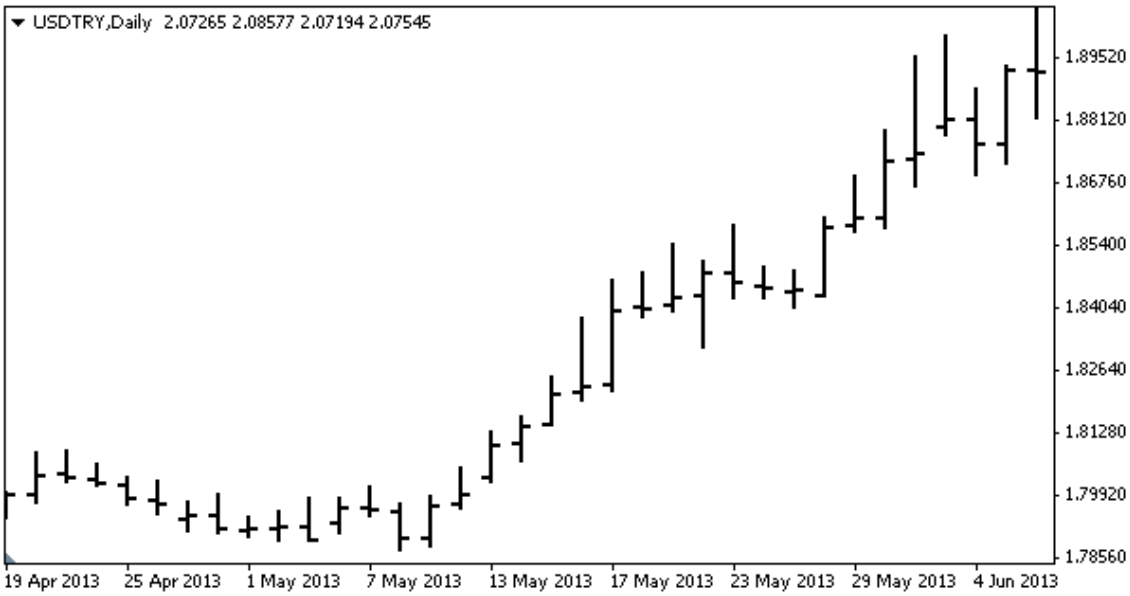

Obr. 2.1: Schodový graf (Zdroj: vlastný)

Sviečkový graf zobrazuje taktiež hodnoty OHLC ale s využitím lepšie graficky čitateľného spôsobu. Pozostáva z tela sviečky a knôtov. Telo je tvorené otváracou

a zatváracou cenou a pre jeho zobrazenie sa používajú rozdielne farby podľa toho, či je cena rastúca alebo klesajúca. Knôty zobrazujú rozpätie medzi maximálnou a minimálnou cenou.

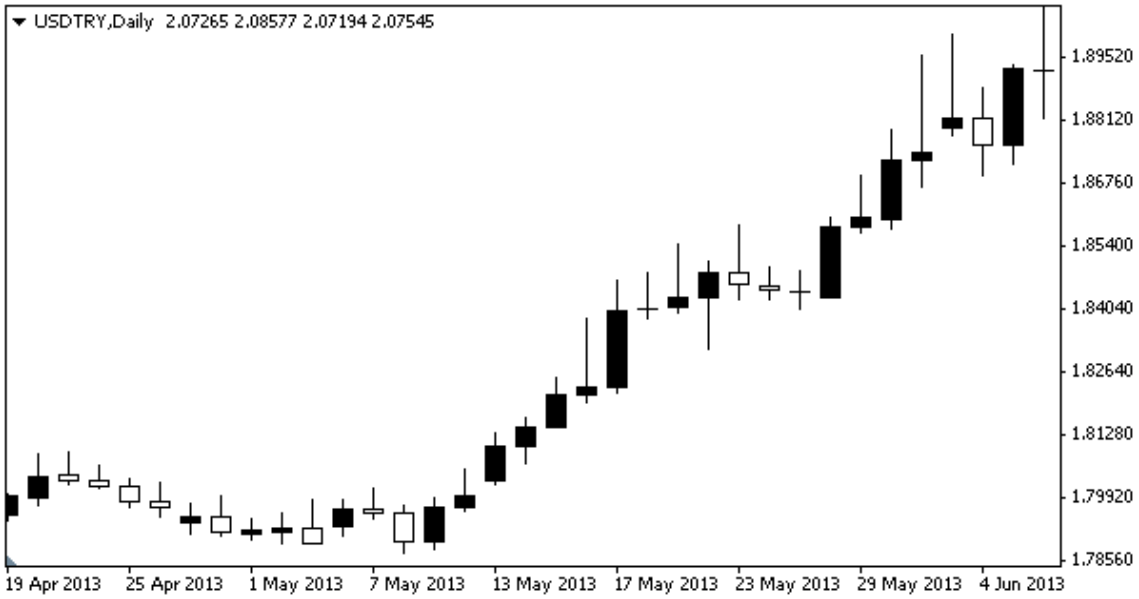

Obr. 2.2: Sviečkový graf (Zdroj: vlastný)

Najjednoduchším grafom je líniový. Zobrazuje iba jeden z údajov OHLC, najčastejšie uzatváraciu cenu. Ceny sú spojené čiarou.

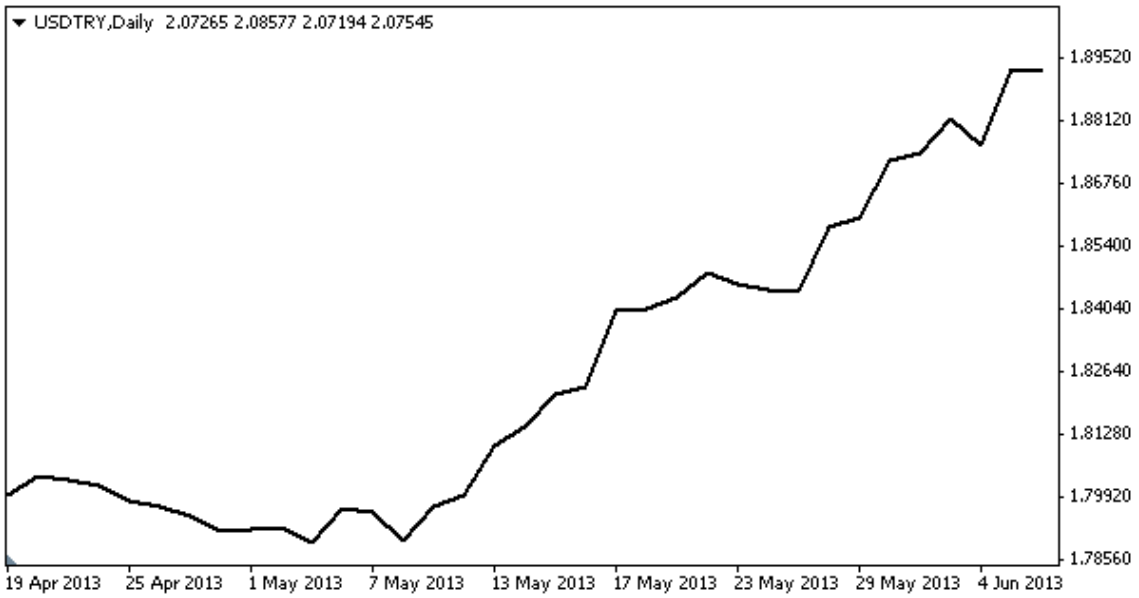

Obr. 2.3: Líniový graf (Zdroj: vlastný)

2.3.3.2 Technické indikátory

Technická analýza využíva pre analýzu grafov okrem grafických formácií i matematicko-štatistický aparát reprezentovaný technickými indikátormi. Predstavujú funkcie, ktorých vstupom sú ceny a prípadne objem obchodov.

Kĺzavé priemery – predstavujú jeden z najjednoduchších a najviac využívaných indikátorov. Používajú sa k vyhladeniu časovej rady a následne tak umožňujú ľahšiu identifikáciu trendu. Základné používané kĺzavé priemery: [1]

- Jednoduchý kĺzavý priemer (SMA) – predstavuje najjednoduchší typ, vypočíta sa ako aritmeticky priemer zvolenej dĺžky.
- Vážený kĺzavý priemer (WMA) – dátam na základe veku lineárne prideľuje váhy a to tak, že najstaršia hodnota ma pridelenú najmenšiu váhu a novšia hodnota ma váhu najväčšiu. Vypočíta sa ako suma súčinu ceny a váhy vydelená súčtom váh.
- Exponenciálny kĺzavý priemer (EMA) – tak ako WMA prideľuje dátam váhy podľa veku ale váhy sú rozdelené exponenciálne.

MACD – názov indikátoru je skratkou pre Moving Average Covergence Divergence. Ku svojej konštrukcií využíva rozdiel medzi dvomi kĺzavými priemermi, najčastejšie medzi dvanásť a dvadsaťšesť denným exponenciálnym priemerom. Okrem tohto rozdielu je počítaná signálna línia. Indikátor poskytuje informáciu o potvrdení smeru trendu keď signálna línia pretne 0. [8]

Bollingerové pásma – sú zobrazené pomocou 3 kriviek. Stredná krivka je kĺzavý priemer. Horná a spodná hranica pásma sú n násobok smerodajnej odchýlky od kĺzavého priemeru. Pomáhajú zobraziť či je cena lacná (pod hranicou) alebo drahá (nad hranicou).

Momentum – je typ oscilátoru, ktorý spočíva v porovnaní aktuálnej ceny inštrumentu s cenou pred zvoleným počtom časových úsekov. Pomocou momenta je možné analyzovať ako cenovú úroveň tak aj intenzitu oscilácie kurzu. Výhodou oscilátorov

vo všeobecnosti je možnosť aplikovať ich aj v trhoch bez výrazných trendov (na rozdiel od kĺzavých priemerov).

Rate of Change – je obdobou momenta. Udáva relatívnu zmenu poslednej ceny vzhľadom k cene pred zvoleným počtom časových jednotiek. Indikátor osciluje okolo nuly. Ak nadobúda veľmi nízke hodnoty a klesá, signalizuje prepredaný trh a možnosť nákupu. V prípade vysokých hodnôt poskytuje informáciu o prekúpenom trhu a možnosti očakávania budúceho poklesu ceny.

Stochastický oscilátor – popisuje vzťah aktuálnej zatváracej ceny k najvyššej a najnižšej cene vo zvolenom období. V grafe sa zobrazuje rýchlou %K a pomalou %D krivkou. Interval hodnôt leží v rozmedzí 0 až 100. Hodnoty pod 20 signalizujú prepredanosť, hodnoty nad 80 prekúpenosť trhu. [1]

RSI – oscilátor indexu relatívnej sily. Zohľadňuje pomer kladných a záporných kurzových zmien v rámci časovej periódy. Interval hodnôt leží v rozmedzí 0 až 100.

MFI - oscilátor podobný RSI, udáva dynamiku toku peňazí. Dôležitý rozdiel oproti RSI je, že do výpočtu MFI je zahrnutý aj volume obchodov.

2.4 Neurónové siete

Neurónové siete sú zjednodušená emulácia biologického nervového systému s cieľom napodobnenia inteligentného chovania. Tvorené sú umelými modelmi neurónov, ktoré transformujú vstupný signál a prenášajú ho k ďalším neurónom. [12]

Tvorca siete volí parametre akými sú napríklad topológia, transformačná funkcia prípadne kritéria pre ukončenie učenia. Neexistuje žiadne konkrétne pravidlo či vzorec ako vhodne nastaviť spomenuté parametre. Aj napriek vyššie uvedenému problému možno riešenia založené na aplikácii neurónových sieti považovať za efektívne. Umožňujú dosiahnuť schopnosti pripisované inteligentným živočíšnym druhom a síce získavať skúsenosti (učiť sa) a aplikovať nadobudnuté vedomosti pri riešení typovo podobných zadaní (generalizácia). [14]

2.4.1 História

História umelých neurónových sieti sa začala písať v 40. rokoch minulého storočia keď fyziológ Warren McCulloch a logik Walter Pitts podali vysvetlenie príčin podmienených reflexov a zaviedli grafické znázornenie štruktúry umelých neurónových sietí. Označovanie umelej nervovej bunky krúžkom a smer toku signálu šípkou bolo zavedené v 1943. [14]

Frank Rosenblatt prišiel v roku 1957 s modelom perceptronu, ktorý je najjednoduchším modelom doprednej neurónovej siete. V nasledujúcich dvoch rokoch realizovali Rosenblatt, Hoff a Windrow dva modely sietí vrátane mechanizmu učenia. Na prelome desaťročí bol vytvorený nelineárny filter slúžiaci k potlačeniu šumu v diaľkových telefónnych kábloch za využitia umelej neurónovej siete. [16]

O oživenie sa v 1984 postaral fyzik John Hopfield skonštruovaním autoasociatívnej neurónovej siete. O dva roky neskôr Rumelhart, Hinton a Williams popísali algoritmus backpropagation, ktorý je doposiaľ vo veľkej miere využívaný. [14]

2.4.2 Model neurónu

Ako bolo spomenuté, umelé neurónové siete vychádzajú z princípov biologických neurónových sietí. Umelý neurón je matematická funkcia , ktorá sa považuje za abstrakciu biologického neurónu. Neurónová sieť je tvorená množinou modelov neurónov, ktoré sú určitým spôsobom zoskupené a medzi sebou vzájomne prepojené.

Vstupy do neurónov sú ohodnotené váhami. Následne sa pridá prahová hodnota a celý výsledok je predaný aktivačnej funkcii, ktorá generuje výstup daného neurónu. Výstupný signál je predaný neurónom v nasledujúcej vrstve a môže byť použitý ako vstup do ďalších neurónov. [12]

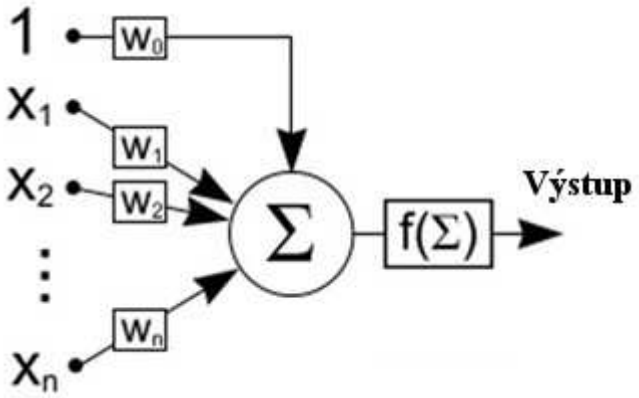

Obr. 2.4: Umelý neurón (Zdroj: [12])

Na predchádzajúcom obrázku je znázornený umelý neurón pre ktorý platí: x_1-x_n sú **vstupy** , w_1-w_n sú **synaptické váhy**, w_0 je **prahová hodnota.** Tieto charakteristiky udávajú celkový potenciál neurónu na ktorý reaguje výstupnou odozvou **aktivačná funkcia** (f).

2.4.3 Aktivačné funkcie

Voľba aktivačných funkcií u jednotlivých neurónov do veľkej miery ovplyvňuje mieru presnosti pre riešenie konkrétneho typu úlohy. Cieľom je normalizácia vstupných hodnôt, v opačnom prípade by vstupné hodnoty mohli dosahovať veľmi vysoké úrovne. [13]

Medzi typické aktivačné funkcie patrí **hardlim**, ktorá je používaná u neurónov sietí určených ku klasifikácií vstupných vektorov siete. Funkcia na výstupe neurónu vracia hodnotu 0 keď vstup nepresiahne daný prah, v opačnom prípade hodnotu 1 čo je popísane vzťahom: [11]

$$a = hardlim(n) = \begin{cases} a = 0 \; pre \; n < 0 \\ a = 1 \; pre \; n \geq 1 \end{cases}$$

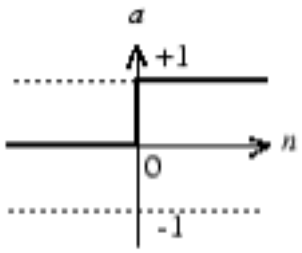

Obr. 2.5: Aktivačná funkcia hardlim (Zdroj:[11])

Logaritmická sigmoida označovaná **logsig** je ďalším typom prenosovej funkcie. Využíva sa vo viacvrstvových sieťach. Umožňuje učiacemu algoritmu určiť gradient a posúvať sa v smere minima funkcie. Vstupné hodnoty prevádza na interval od 0 do 1 na výstupe.

$$a = \frac{1}{1 + e^{-\xi * n}}$$

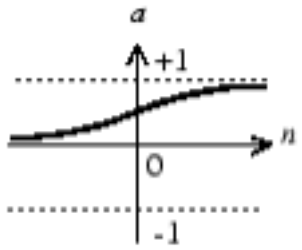

Obr. 2.6: Aktivačná funkcia logsig (Zdroj: [11])

Lineárna aktivačná funkcia **purelin** je využívaná v poslednej vrstve sietí určených k aproximácií. Podľa predpisu je výstupná hodnota rovná vstupnej.

$$a = n$$

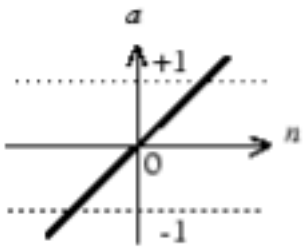

Obr. 2.7: Aktivačná funkcia purelin (Zdroj: [11])

Okrem spomenutých funkcií jestvujú ďalšie, ktoré môžu mať pozitívny účinok na presnosť siete, napríklad: hyperbolická tangetoida **tansig** prípadne **hardlims**.

2.4.4 Sieťová architektúra

Na riešenie zložitejších problémov by jeden neurón nepostačoval, preto sú neuróny spájané do vrstiev čím vytvárajú sieť. Sieť sa typicky skladá zo vstupnej a výstupnej vrstvy. Medzi vstupnou a výstupnou vrstvou sa môže nachádzať niekoľko skrytých vrstiev. [11]

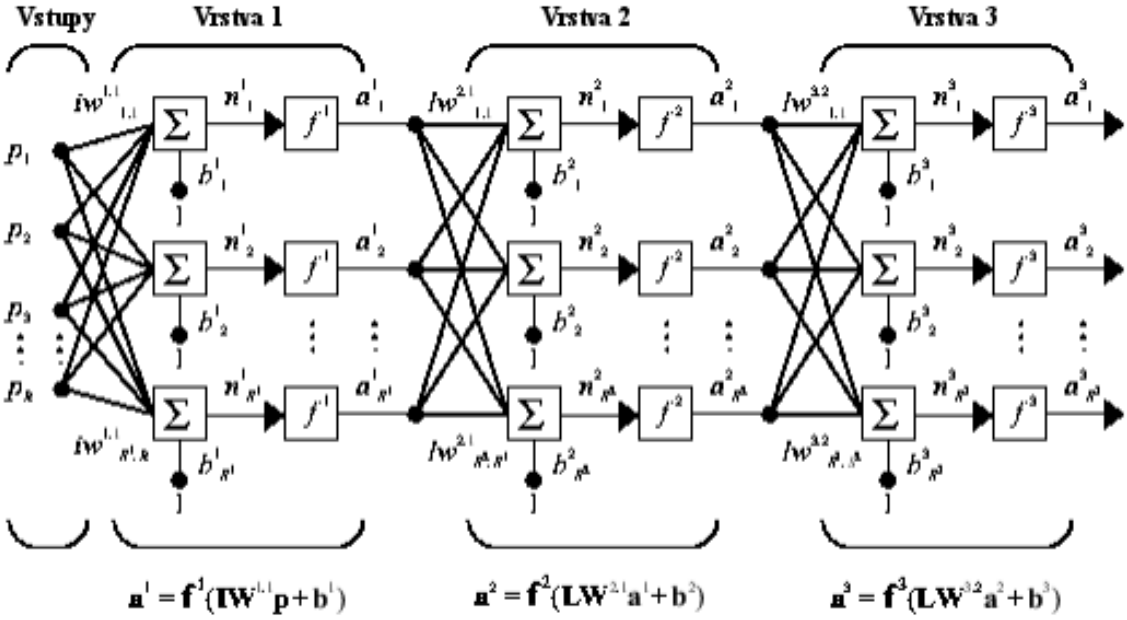

Obr. 2.8: Model doprednej viacvrstvovej siete (Zdroj: [11])

Predchádzajúca schéma znázorňuje doprednú viacvrstvovú sieť s R vstupmi, ktoré sú násobené váhami , následne sčítané a predané aktivačnej funkcii.

2.4.5 Učenie siete

Aby sieť bola schopná riešiť zadaný problém, je treba ju najskôr natrénovať. Cieľom trénovania neurónovej siete je úprava váh neurónov tak, aby sieť produkovala výstupy pokiaľ možno čo najbližšie očakávaniam. Inými slovami, sieť sa snaží minimalizovať chybu **E**, ktorá je definovaná ako stredná kvadratická chyba skutočnej a požadovanej odozvy siete. [11]

$$E = \sum (n_i - o_i)^2$$

V počiatku sú vypočítané výstupy a následne chyba. Výsledok je použitý pri ladení synaptických váh. Celý proces je cyklický do doby, kým nedôjde k nájdeniu akceptovateľnej úrovne chyby.

Presnosť výsledku siete ovplyvňuje presnosť vstupných dát, na ktorých je vykonávané učenie. Napriek schopnosti generalizácie vzťahov viacvrstvových sietí je potrebné , aby vstupné dáta pokrývali rozsah vstupných dát pre ktoré bude neurónová sieť použitá.

Pokiaľ sieť nedosahuje požadované výsledky je vhodné spustiť učenie siete odznova čím dôjde k reinicializácii synaptických váh, keďže tie sú inicializované náhodne.

Ďalšou možnosťou zvýšenia presnosti je navýšenie počtu neurónov v skrytých vrstvách a prípadne voľba inej učiacej funkcie. Veľký počet neurónov však môže mať za následok preučenie (overfitting), kedy sieť bude dávať správne odozvy na vstupy z tréningovej množiny ale na ostatné vstupy nebude reagovať správne. Preučená sieť nemá schopnosť generalizácie a zlyháva na testovacej množine dát. [16]

Rozlišujeme dva základné prístupy k učeniu siete. Učenie s učiteľom je vhodné pre modelovanie dynamických systémov , predikcií a klasifikácií dát ktoré sú skreslené šumom. Učenie bez učiteľa (samoorganizácia) hľadá v tréningových dátach vzory podľa ktorých sa snaží o klasifikáciu dát. [11]

2.4.5.1 Učenie s učiteľom

Ako bolo spomenuté v predchádzajúcej časti, siete učené s učiteľom sú využívané napríklad k predikcií. Dáta sú rozdelené do nasledujúcich troch kategórií, pričom pomer jednotlivých kategórii je možné meniť. [11]

- **Tréningová množina** - dáta sú použité k samotnému učeniu siete.
- **Validačná množina** - slúži k sledovaniu chyby v procese učenia a určeniu možného preučenia siete. Chyba na validačných dátach sa znižuje na začiatku učenia siete spoločne s chybou na tréningovej množine dát. V momente preučenia siete začne chyba na validačných dátach rásť.
- **Testovacia množina** - dáta sa používajú pre overenie schopnosti siete generalizovať a nie sú použité v procese učenia. Výrazný rozdiel medzi hodnotami validačnej a testovacej množiny v počte dosiahnutých iterácií potrebných k dosiahnutiu minima môže indikovať nesprávny pomer rozdelenia dát do spomenutých kategórií.

Podľa prostredia MATLAB možno rozlíšiť nasledovné typy sietí učené s učiteľom. [11]

- **Dynamické** – využívajú pamäť a spätné väzby pre rozpoznávanie vzorov v dátach. Hojne využívané pri modelovaní dynamických systémov a predikcií časových rád. V ďalšej časti práce budú popísané dynamické siete s oneskorením na vstupnej vrstve, s oneskorením na vstupnej vrstve a skrytých vrstvách a siete s spätnou slučkou.
- **Dopredné** – druh siete ktorý obsahuje „dopredné“ spojenia medzi neurónmi. Informácie smerujú iba v jednom smere a to od vstupu k výstupu. Nedochádza k cykleniu ani spätnému predávaniu informácií. Veľmi populárne pri riešení predikčných úloh a nelineárnych aproximácií funkcií.
- **Ďalšie typy** – medzi ďalšie typy možno zaradiť LVQ (learning vector quantization) určené pre klasifikačné úlohy. Dokážu klasifikovať ľubovoľný vstupný vektor, nie len lineárne separabilný. Podmienkou je dostatok neurónov v jednotlivých vrstvách. Za zmienku stoja aj siete RBF (Radial basis function network), ktoré ako aktivačnú funkciu

používajú radial basis. Použitie nachádzajú pri aproximácií, predikcií časových rád a klasifikácií. Sú alternatívou k dopredným sieťam.

2.4.5.2 Učenie bez učiteľa

Cieľom učenia bez učiteľa je nájsť skrytú štruktúru vo vstupných dátach a na jej základe dospieť ku klasifikácií. Najbežnejšou metódou je zhluková analýza (cluster analysis) ktorá slúži k triedeniu vstupov do skupín zhlukov tak, aby si vstupy v danej skupine boli podobnejšie než objekty z ostatných skupín. Zahŕňa nasledovné algoritmy: [11]

- **Hierarchický Clustering** – vytvorí zhlukový strom, v ktorom sú dáta usporiadané v niekoľkých úrovniach.
- **Samoorganizačné mapy** – klasifikujú vstupy podľa podobnosti, zohľadňujú príbuznosti vstupov a im odpovedajúce kategórie. Výsledkom je zväčša dvojdimenzionálna mapa.
- **Hidden Markov model** (HMM) – využitie predovšetkým pri rozpoznávaní reči, písma, gest a v bioinformatike.

2.4.6 Prostredie MATLAB

Program MATLAB reprezentuje prostredie pre technické výpočty. Tento systém bol zvolený k realizácii praktickej časti tejto diplomovej práce a to predovšetkým z dôvodu jednoduchosti ovládania, množstva knižníc a zabudovaných funkcií a užívateľsky prívetivého prostredia. Pre prácu s neurónovými sieťami disponuje nástrojom Neural Network Toolbox.

Podľa autorov prostredia je možné siete deliť na statické a dynamické. Statické siete nemajú žiadne oneskorenie alebo spätnú väzbu a odozva je počítaná od vstupu k výstupu. Odozva u dynamických sietí je závislá aj na predchádzajúcich vstupoch a stavoch siete. [11]

Dynamické siete je možné rozdeliť na **dopredné** a **so spätnou väzbou**. Dopredné dynamické siete na rozdiel od statických sietí disponujú oneskorením (tapped delay line

– TDL). Odozva preto nezávisí iba na súčasnom vstupe ale aj na histórii vstupnej sekvencie. Siete so spätnou väzbou majú bežne dlhšiu odozvu ako dopredné siete. Ich výstup v jednom kroku je vstupom pre ďalší krok. [11]

2.4.6.1 Siete NARX

NARX je akronym pre nelineárnu autoregresívnu sieť s exogénnymi vstupmi (Nonlinear Autoregressive network with exogenous inputs). Predstavuje rekurentnú dynamickú sieť so spätnými väzbami medzi niekoľkými vrstvami siete. Model je založený na lineárnom ARX modeli, ktorý je hojne využívaný pri modelovaní časových rad.

Siete NARX sa používajú k modelovaniu nelineárnych dynamických systémov, v ktorých je ako vstup použitý predchádzajúci výstup. Spätná slučka je v priebehu učenia odstránená a používajú sa skutočné výstupy, ktoré sú k dispozícií z trénovacej množiny dát. Výhodou takéhoto prístupu je, že vstup do doprednej siete je presnejší a tým pozitívne ovplyvňuje presnosť výslednej siete. Druhou výhodou je dopredná architektúra siete vo fáze učenia a s tým súvisiaca možnosť použitia metódy backpropagation, ktorá značne znižuje časovú náročnosť učenia. [11]

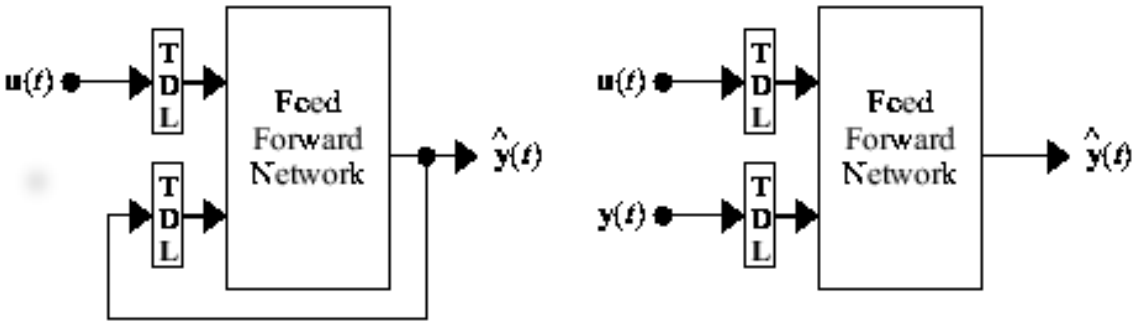

Obr. 2.9: Paralelný a sériový režim siete NARX (Zdroj: [11])

Prechádzajúca schéma zobrazuje dva režimy. Paralelný režim (s uzatvorenou slučkou) je vhodný k predikcii niekoľkých krokov dopredu. Odstránenie spätnej slučky (sériový režim) je vhodnejší k učeniu siete a predikcii iba jedného kroku vpred.

Rovnica definujúca model NARX vyjadruje, že nasledujúce hodnoty modelu závisia na čase, predchádzajúcich výstupných hodnotách a na hodnotách exogénnej veličiny. [11]

$$y(t) = f\,(y(t-1), y(t-2), \ldots, y(t-n_y), u(t-1), u(t-2), \ldots, u(t-n_u))$$

Implementácia pomocou NARX modelu za využitia doprednej neurónovej siete, ktorá aproximuje uvedenú funkciu je zobrazená pomocou nasledujúceho dvojvrstvového modelu.

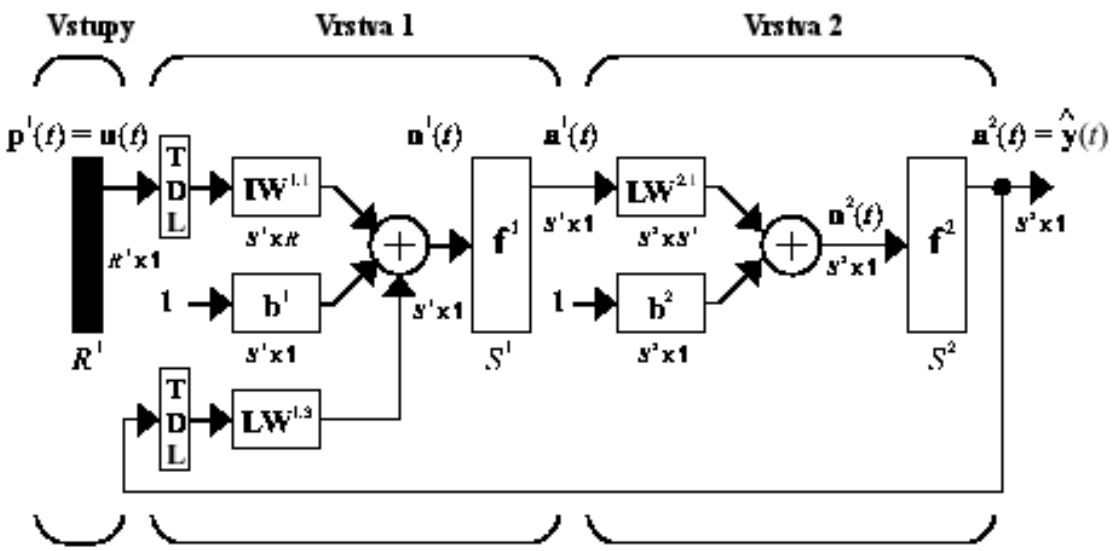

Obr. 2.10: Model siete NARX (Zdroj: [11])

2.4.6.2 Siete FTDN

Focused time-delay neural network predstavuje viacvrstvové dopredné neurónové siete s dynamickou zložkou vo vstupnej vrstve (reprezentovanú oneskorením - TDL).

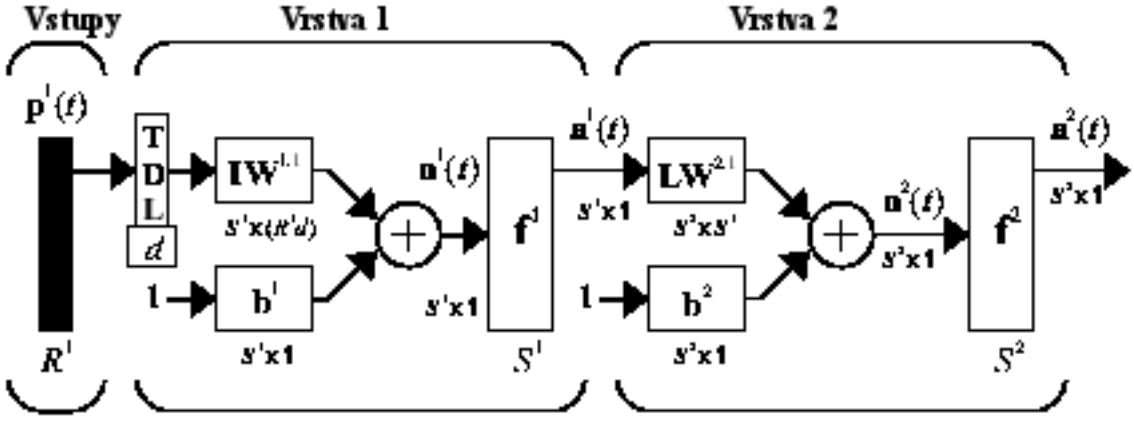

Obr. 2.11: Model siete FTDN (Zdroj: [11])

Predchádzajúca schéma predstavuje dvojvrstvovú FTDN sieť, ktorá je vhodná pre predikciu časových rád. Výhodou tohto typu siete je, že obsahuje dynamickú zložku iba na vstupe , neobsahuje spätné väzby a vďaka tomu sa rýchlo učí. [11]

2.4.6.3 Siete DTDN

Na rozdiel od FTDN tento typ siete distribuuje oneskorenie naprieč celou sieťou. Nasledujúci model zobrazuje dvojvrstvovú DTDN sieť s oneskorením v obidvoch vrstvách.

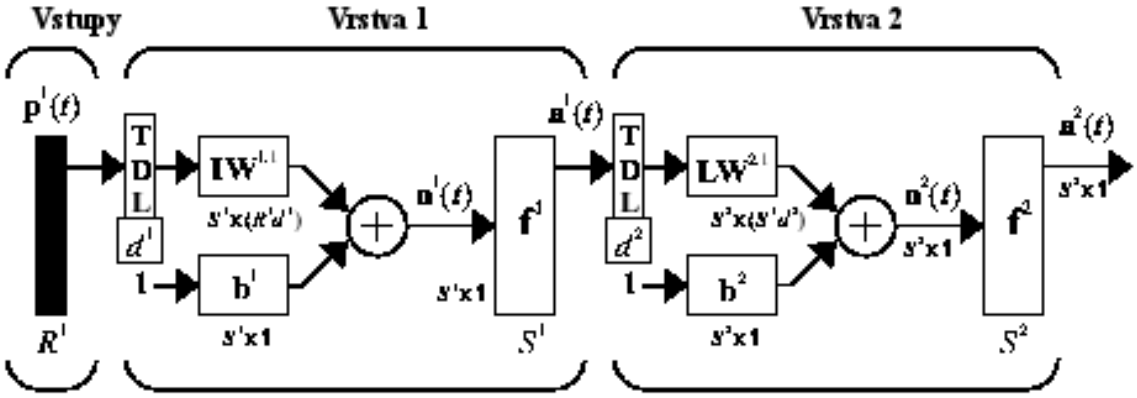

Obr. 2.12: Model siete DTDN (Zdroj: [11])

Nevýhodou tohto typu sietí je fakt, že pri učení využívajú dynamické varianty metódy spätnej propagácie čím je proces učenia výrazne časovo náročný.

3 Analýza súčasného stavu

Nasledujúca kapitola sa zameriava na základnú analýzu zadávateľskej spoločnosti, ktorou je spoločnosť IJM Group, s.r.o.

3.1 Základné informácie o firme

Spoločnosť IJM Group, s.r.o bola založená v roku 2011 s cieľom zabezpečovať informačné technológie a služby pre retail zákazníkov obchodujúcich na Forexe prostredníctvom automatických obchodných systémov. Je vlastnená dvomi spoločníkmi, ktorí sú zároveň aj konateľmi. Každý vlastník disponuje 50%-ným podielom v spoločnosti. Základný kapitál pri vzniku predstavoval zákonom stanovenú minimálnu čiastku 5100 EUR.

Názov spoločnosti:	IJM Group, s.r.o
Právna forma:	spoločnosť s ručením obmedzeným
Sídlo:	Sokolská 2518/48
	960 01, Zvolen
	Slovenská republika
IČO:	46050868
DIČ:	2023204865

3.1.1 Predmety podnikania

Spoločnosť podniká výhradne prostredníctvom internetu a k tomuto účelu ma v Obchodnom registri zapísané nasledovné predmety činnosti: [15]

- Kúpa tovaru na účely jeho predaja konečnému spotrebiteľovi (maloobchod) alebo iným prevádzkovateľom živnosti (veľkoobchod),
- sprostredkovateľská činnosť v oblasti obchodu,
- sprostredkovateľská činnosť v oblasti služieb,

- činnosť podnikateľských, organizačných a ekonomických poradcov,
- reklamné a marketingové služby,
- prieskum trhu a verejnej mienky,
- počítačové služby,
- služby súvisiace s počítačovým spracovaním údajov,
- vykonávanie mimoškolskej vzdelávacej činnosti.

3.1.2 Sortiment služieb

Hlavné zastúpenie v ponuke služieb spoločnosti majú virtuálne privátne servery (VPS), ktoré sú v rôznej forme potrebné pre každého zákazníka, ktorý využíva alebo plánuje využiť výhody automaticky obchodovanej stratégie. Pri poskytovaní VPS sú zhodnocované dlhoročné skúsenosti a znalosti členov technickej podpory. Technické zázemie je kvôli zníženiu prípadného rizika umiestnené v nemeckých a českých dátových centrách.

Dôležitý produkt je vývoj a optimalizácia automatických obchodných stratégií (AOS) v jazyku MetaQoutes Language. Zákazník definuje podmienky vstupu, výstupu a proces riadenia obchodu (money management). Na základe týchto parametrov je naprogramovaný automatický systém. Podľa potrieb je možné vykonať optimalizáciu vstupných parametrov automatu pomocou genetických algoritmov a zvýšiť tak úspešnosť naprogramovanej obchodnej myšlienky.

S vývojom stratégií súvisí aj posledný hlavný produkt ktorým je predaj jestvujúcich stratégii, či už sa jedná o vlastné alebo o stratégie tretích strán.

3.1.3 Technické zázemie

Firemná infraštruktúra pozostáva z prenajatých serverov v dátových centrách. Do siete Internet sú pripojené linkou o kapacite 1 Gbps. Samozrejmosťou je redundancia napájania zabezpečená dátovým centrom. Počas krátkeho výpadku je náhradným

zdrojom elektrickej energie UPS. Pre prípad dlhšieho výpadku centrá disponujú dieselovým agregátom.

Redundancia dát je zabezpečená hardwarovým RAID. Zálohy dát sú pravidelne ukladané na geograficky oddelenom úložisku. Prípady porúch hardwaru sú riešené technikmi dátového centra vďaka čomu je minimalizovaný čas potrebný pre odstránenie problému. Dátové centra majú dostatočné zásoby HW a dokážu urobiť výmenu kus za kus.

Každý server je osadený operačným systémom Windows. Zákazníci využívajú pre pripojenie službu vzdialenej plochy (RDP), ktorá po odhlásení sa z relácie neukončí spustené programy a tie fungujú ďalej. Užívatelia sú rozdelení na jednotlivých serveroch podľa dostupného výkonu, prípadne na základe vlastných špecifických žiadostí. Každý prístup zákazníka je overovaný centrálnym serverom na ktorom je nainštalovaný server licencií vzdialenej plochy. Firma je držiteľom licencie SPLA od Microsoft vďaka čomu dokáže promptne reagovať na softwarové požiadavky klienta.

Spomenutá infraštruktúra je vysoko dostupná, bezpečná, ľahko škálovateľná a umožňuje ad-hoc riešenie požiadaviek.

3.2 SWOT analýza

Swot analýza hodnotí silné a slabé stránky spoločnosti, príležitosti a hrozby, ktorým čelí na trhu. Umožňuje vyhodnotiť fungovanie firmy, zamerať sa na potlačenie slabých stránok a rozvíjanie príležitostí.

3.2.1 Silné stránky

Silnou stránkou je skúsenosť členov technickej podpory s virtualizačnými technológiami a administráciou serverov. Tieto vedomosti sú potrebné pre pochopenie požiadaviek a následného návrhu optimálneho riešenia pre zákazníka.

Unikátnosť a komplexnosť ponúkaných riešení predstavuje ďalšiu dôležitú silnú stránku. Produkty sú v priestore SR/ČR pomerne jedinečné predovšetkým vďaka možnosti ľahkého škálovania.

Nízka cena, ktorá je dosiahnutá prenájmom potrebného hardware priamo z dátového centra. Pre spoločnosť IJM Group, s.r.o tak zanikajú náklady súvisiace s údržbou HW.

3.2.2 Slabé stránky

Nedostatočné spektrum ponúkaných automatických obchodných systémov, ktoré je v súčasnosti reprezentované tromi produktmi tretích strán. Stratégie vytvorené bežnými konvenčnými metódami väčšinou zlyhávajú. Vytvorenie nového, fungujúceho systému by mohlo byť lákadlom pre nových aj súčasných zákazníkov.

Veľmi vážnym nedostatkom je slabá propagácia na internete. Noví zákazníci prichádzajú predovšetkým na základe odporučenia súčasných klientov.

3.2.3 Príležitosti

Významnú príležitosť ponúkajú produkty, ktoré vzhľadom na svoju nehmotnú podobu umožňujú osloviť zákazníkov celosvetovo. Spoločnosť tak nie je geograficky limitovaná. Oslovenie zahraničných zákazníkov predpokladá zvládnutie marketingu. Vďaka škálovateľnosti súčasného IT zázemia nie je nárast počtu zákazníkov problém.

Príležitosti sú aj v presadení sa na poli automatických obchodných systémov. Práve to je smer, na ktorý je v súčasnosti spoločnosťou kladený najväčší dôraz.

3.2.4 Hrozby

Nízke vstupné náklady umožňujú vstup nového podnikateľského subjektu. Konkurencia môže pôsobiť aj ako podnet k zdokonaleniu služieb.

Nestabilná situácia na finančných trhoch predstavuje hrozbu pre podnikateľské aktivity spoločnosti. Automatické obchodné systémy používané zákazníkmi môžu spôsobiť straty ktoré v dôsledku vedú k nezáujmu o AOS a tým aj o virtuálne servery.

Hrozba, ktorá spôsobuje IJM Group, s.r.o výrazné finančné straty je softwarové pirátstvo. Nelegálne šírenie digitálneho obsahu je globálny problém, ktorého riešenie je technicky aj finančne náročné.

3.3 Požiadavky na aplikáciu

Špecifikum na trhu s automatickými obchodnými stratégiami motivuje výrobcov pridávať ďalšie produkty. Na druhej strane stoja zákazníci, ktorých prirodzenou snahou je diverzifikácia portfólia pomocou pridávania nových systémov od rozličných výrobcov. Vďaka tomu je trh s AOS prakticky nemožné nasýtiť. Prirodzenou snahou spoločnosti je preto priniesť na trh produkt, ktorým predstihne konkurenciu.

Samotná aplikácia má predstavovať rámec potrebný k rozhodovaniu o tom, či sa spoločnosť bude ďalej zaoberať zvolenou technológiou, ktorou je v tomto prípade neurónová sieť.

Preto je potrebné minimalizovať časovú náročnosť a využiť dostupné prostriedky, ktoré poskytujú široké spektrum funkcionality (práca s dátami, súbormi, grafmi a neurónovými sieťami). Dôležitá je jednoduchá možnosť implementácie indikátorov technickej analýzy. Ako vhodný nástroj pre dosiahnutie tohto cieľa bol zvolený program MATLAB.

Požiadavky na aplikáciu:

- Menový pár EUR/USD
- Vstupné dáta sú denné OHLC
- Predikcia 5 krokov (5 dni)

4 Vlastný návrh riešenia

Návrhová časť diplomovej práce sa zaoberá tvorbou niekoľkých neurónových sietí a ich vyhodnotením. Text je doplnený o kľúčové fragmenty zdrojových kódov v jazyku MATBAL aj s popisom ich fungovania.

4.1 Príprava dát

Získanie a transformovanie tržných dát tvorí neoddeliteľnú a dôležitú súčasť návrhu, keďže tieto dáta predstavujú vstupy neurónových sietí. V požiadavkách aplikácie bolo spomenuté, aby boli modely neurónových sietí aplikované na Forexovom trhu, konkrétne na menovom páre EUR/USD.

Množstvo FX brokerov a samotná OTC povaha trhu nútia k zvýšenej opatrnosti pri manipulácií s historickými dátami. Správna voľba zdroja dát znižuje riziko chýb a prípadných manipulácií zo strany brokera.

Spomedzi množstva poskytovateľov bola zvolená americká firma Oanda, ktorú využívajú retail klienti aj veľké spoločnosti. Na trhu pôsobí od roku 1996 a je regulovaná významnými inštitúciami ako napríklad Commodity Futures Trading Commission alebo National Futures Association.

4.1.1 Extrakcia dát z platformy

Spoločnosť Oanda umožňuje klientom prístup na trh pomocou platformy MetaTrader. Táto platforma je zadarmo a predstavuje istý štandard medzi Forex brokermi. Disponuje historickými dátami, ktoré sú poskytované priamo brokerom a je možné ich exportovať do CSV súboru. Vďaka tejto vlastnosti je možné s dátami jednoducho pracovať a použiť ich pre vlastné potreby.

Dáta sú k dispozícií v nasledovných periódach vzorkovania:

- 1 minúta,5 minút,15 minút,
- 1 hodina, 4 hodiny,
- 1 deň, 1 týždeň, 1 mesiac, 1 rok.

Podľa požiadaviek zadania bol zvolený časový rámec 1 deň. Jeden riadok exportovaného CSV súboru preto reprezentuje jeden deň. Separátorom hodnôt je čiarka a štruktúra dát je nasledovná.

Dátum, čas, otváracia cena, najvyššia cena, najnižšia cena, close, volume

Zo spomenutých atribútov sú pre ďalšiu manipuláciu s dátami potrebné iba „OHLC" dáta. Informáciu o volume nie je možné využiť nakoľko sa jedná o hodnotu počtu obchodov realizovaných u daného brokera, ktorá nekorešponduje s celkovým počtom obchodov na FX trhu. Nie je preto možné využiť indikátory založené na volume ako napríklad Money Flow Index (MFI).

OHLC dáta je potrebné previesť na formát , v ktorom bude deň zastúpený stĺpcom. Dôvodom je nutnosť výpočtu technických indikátorov, pre ktoré je formátovanie CSV nepoužiteľné.

Nad takto očistenými a formátovanými dátami je možné počítať bežné technické indikátory. V príklade zdrojového kódu je využitá funkcia addGuppy() , ktorá bude bližšie popísaná v ďalšej časti.

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Priprava dat, nacitanie z MT4 *.csv, ulozenie ako *.MAT             %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

filename     = ['..\data\EURUSD1440_OANDA.csv'];
filenameSave = ['..\data\NN_D1_data_2_fullguppy.mat'];
cutFromStart = 1350;
cutFromEnd   = 150;
```

```
% nacitaj data z aktualneho adresaru
originalMT4data = csvread(filename, 0, 2);

% transformuj na maticu 4xN
data = originalMT4data(:,1:4)';

% vypocet GUPPY-ho
data = addGuppy(data);

% odstrihnutie dat
dataFinal = data(:,cutFromStart:length(data)-cutFromEnd);

% uloz do suboru
save(filenameSave, 'dataFinal');
```

Predchádzajúca ukážka zdrojového kódu umožňuje vyššie spomenutú transformáciu dát. V skripte dochádza k orezaniu dát zo začiatku a od konca. Odrezanie dát od počiatku ma opodstatnenie kvôli výpočtu technických indikátorov. Keďže indikátory sú počítané pre niekoľko periód spätne, dáta na pozícií menšej ako je perióda pre výpočet indikátoru by obsahovali nulovú hodnotu pre daný indikátor.

Úprava od konca môže byť využitá k prípadnému out of sample testovaniu modelu neurónovej siete. Ak by bol model učený so všetkými dátami ktoré sú k dispozícií k dnešnému dňu, nebolo by možné overiť fungovanie „v budúcnosti“.

Na záver skriptu sú dáta s vypočítanými indikátormi a v požadovanom formátovaní uložené ako MAT súbor.

Výslednú časovú radu na ktorej bude prebiehať učenie dát zobrazuje nasledujúci graf.

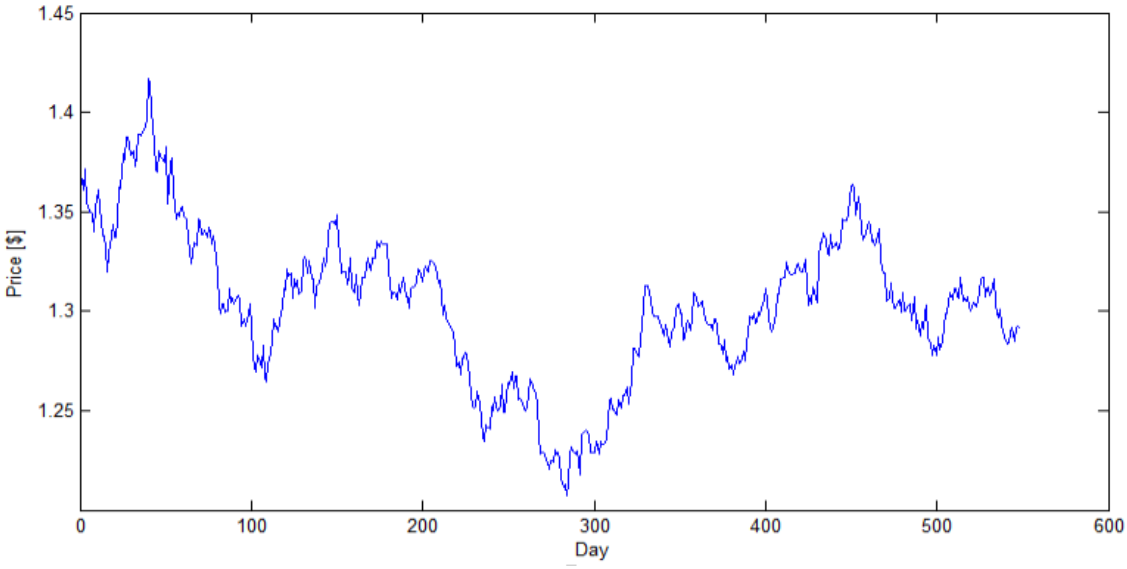

Obr. 4.1: Zdrojová časová rada (Zdroj: vlastný)

Z hľadiska technickej analýzy možno povedať, že časová rada počas svojho priebehu vytvorila maximum na hodnote 1,4168 a minimum bolo na hodnote 1,2073. Priebeh znázorňuje ako rastúci tak klesajúci trend.

V minulom priebehu sú zóny podpory (support) na hodnote 1,3000 , ktorá môže pôsobiť psychologicky na mnohých obchodníkov. Táto hodnota je v prezentovanom grafe považovaná za zónu odporu (rezistancia). Ako support je možno určiť hodnotu v okolí hladiny 1,2850.

4.1.2 Výpočet indikátorov technickej analýzy

Pri práci s OHLC dátami je možné vypočítať prakticky ľubovoľný indikátor technickej analýzy. Množstvo indikátorov je obsiahnutých priamo v MATLAB Financial Toolbox. V časti extrakcie dát je využitá funkcia addGuppy() ktorá pridáva tzv. Guppy Multiple Moving Average (GMMA).

GMMA zverejnil Daryl Guppy a predstavuje vizualizáciu trendu za pomoci dvoch skupín exponenciálnych kĺzavých priemerov. Prvá skupina je tvorená EMA s kratšou periódou, konkrétne: 3,5,8,10,12,15. Táto skupina reprezentuje obchodníkov (traders). Druhou skupinou sú investori, ktorí sú v GMMA zobrazení prostredníctvom EMA s periódou 30,35,40,45,50,55.

Autor predpokladá, že čím je trend silnejší, tým je väčší rozdiel medzi 30 a 55 dennou EMA. Kompresia krátkej 5 a 15 dennej EMA pri silnom trende môže indikovať pokračovanie pohybu v smere trendu. Kompresia 30 a 55 EMA môže znamenať ukončenie dlhodobého trendu.

Nasledujúci graf menového páru EUR/USD zobrazuje kompresiu spôsobenú investormi a následne nastolenie rastúceho trendu. Krátkodobí obchodníci mali 2 príležitosti vstupov do pozícií a to v miestach, kde sa krátkodobé EMA priblížili k stále rastúcim „investorom“.

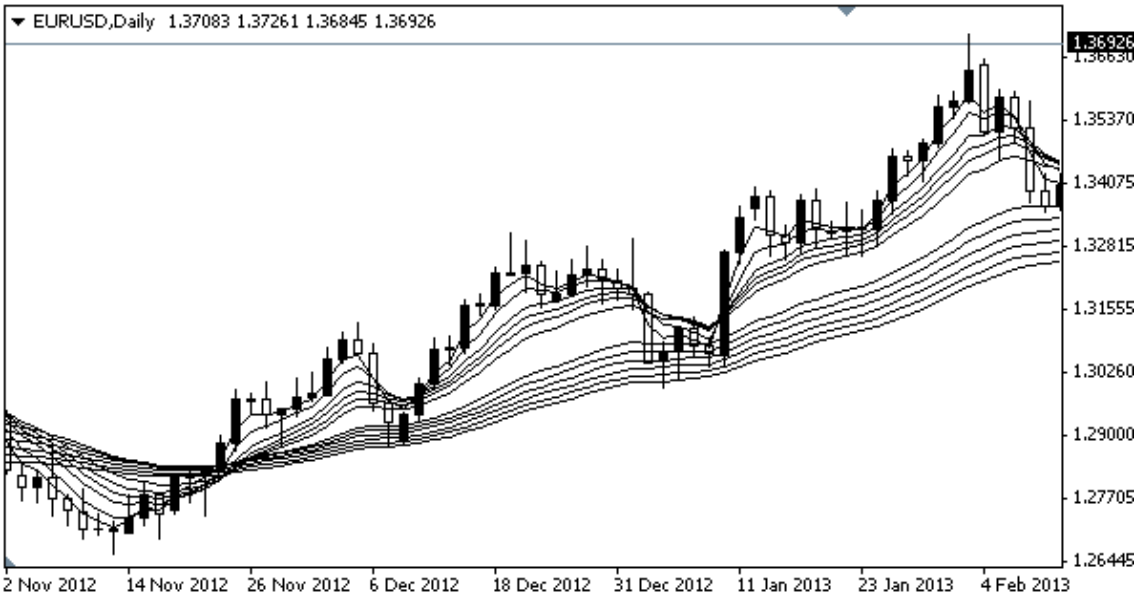

Obr. 4.2: Guppy Multiple Moving Average (Zdroj: vlastný)

Spomenuté vlastnosti systému možno ľahko implementovať. K tomuto účelu bola vytvorená funkcia addGuppy() ktorá na vstupe uvažuje OHLC dáta. K týmto dátam sú pripočítane kĺzavé priemery podľa pravidiel GMMA. Pre výpočet kĺzavých priemerov je využitá vstavaná funkcia tsmovavg() z Financial Toolbox.

```
% prida k cenam klzave priemery podla guppy systemu

function priceWithGuppy = addGuppy(ohlcData)
```

```
    tmpData = ohlcData;

    % short term -> 3,5,8,10,12,15; close (4) price
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 3);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 5);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 8);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 10);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 12);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 15);

    % long term -> 30,35,40,45,50,55
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 30);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 35);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 40);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 45);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 50);
    tmpData(end+1,:) = tsmovavg(ohlcData(4,:), 'e', 55);

    % return
    priceWithGuppy = tmpData;
end
```

Nespornou výhodou je skutočnosť, že vypočítané indikátory sú pridané k OHLC dátam. Vznikne tak matica 16xN, ktorú možno podľa potrieb využiť pre trénovanie neurónovej siete (napríklad trénovaním dát iba na OHLC respektíve na OHLC a krátkej časti GMMA systému a pod.).

4.1.3 Rozdelenie dát

Pomocou extrakcie dát boli získané dáta pre menový pár EUR/USD od 18.9.2011 do 21.5.2013 čo predstavuje 545 obchodných dní. Tieto dáta boli rozdelené na trénovaciu, validačnú a testovaciu množinu. Obchodné dáta od 21.5 do 27.5 boli ponechané pre overenie funkčnosti modelu.

K samotnému tréningu siete a nastaveniu váh neurónov je použitá prvá, trénovacia sada. Nad validačnými dátami sa zisťuje, či nedochádza k preučeniu siete. Váhy

neurónov nie sú menené, overuje sa či pri znížení chyby siete trénovacej množiny dôjde k níženiu aj pri validačných dátach. Ak by totiž chyba trénovacej množiny klesla ale chyba validačných dát by vykazovala rast, môže sa jednať o indikáciu zníženej schopnosti generalizácie siete a preučeniu. Testovacia množina obsahuje dáta, s ktorými sieť neprišla do styku v priebehu učenia a slúžia k overeniu naučenia siete.

Pomer rozdelenia dát medzi spomenuté tri množiny je ponechaný na štandardných hodnotách a to nasledovne:

- 70% trénovacia sada,
- 15% validačná sada,
- 15% testovacia sada.

Rozdelenie dát v jazyku matlab je realizované nasledovným spôsobom .

```
% Nastavenie rozdelenia dát pre učenie, validáciu, testovanie
net.divideMode = 'value';
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
```

Nakoľko je „net“ objektom vytvorenej siete, takého rozdelenie je možné aplikovať pre sieť NARX aj pre sieť FTDN.

4.2 Neurónová sieť NARX

Nasledujúca kapitola obsahuje konkrétny model neurónovej siete NARX. Vstupom siete sú OHLC dáta s vypočítanými indikátormi. Výstupom je predikcia zatváracích cien pre 5 nasledujúcich dní.

4.2.1 Štruktúra siete

Z nasledujúcej schémy je zrejmé, že vstupom pre sieť je 10 časových rád pre každý obchodný deň. Tieto časové rady sú reprezentované OHLC dátami (4 časové rady)

a 6 vypočítaných krátkodobých exponenciálnych kĺzavých priemerov podľa GMMA systému.

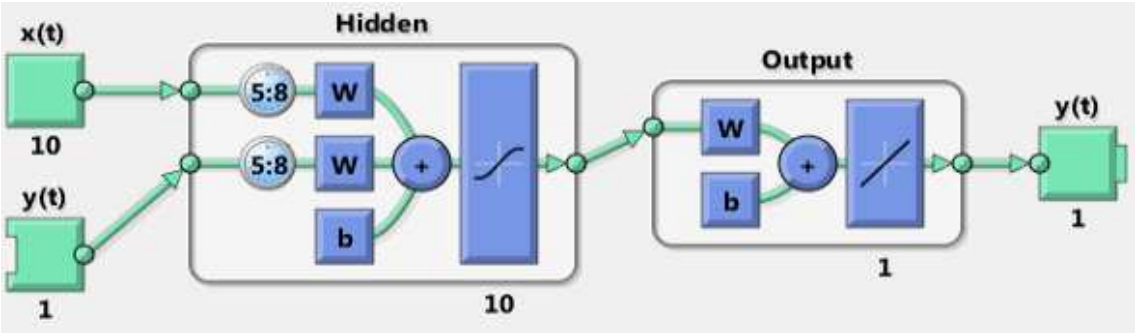

Obr. 4.3: Štruktúra siete NARX (Zdroj: vlastný)

Sieť je tvorená skrytou vrstvou s desiatimi neurónmi a výstupnou vrstvou. Na vstupnú vrstvu je aplikované časové oneskorenie 8 krokov. Výstupom siete je predikovaná zatváracia cena.

Pre vytvorenie takejto štruktúry bol využitý skript, ktorý v prvej časti načíta vstupné dáta. Následne sú nastavené parametre pre požadovaný počet predikovaných krokov, oneskorenie siete a počet neurónov v skrytej vrstve.

Parameter rows udáva rozsah vstupných dát a v tomto prípade môže nadobúdať hodnôt od 1 do 16, kde 1 reprezentuje na vstupe iba otváraciu cenu, 4 celú OHLC maticu a každý inkrement nad hodnotou 4 predstavuje postupné pridávanie hodnôt EMA z GMMA systému.

Dáta použité pre trénovanie siete sú reprezentované premennými inputSeries a targetSeries. Tieto premenné sú na základe oneskorenia a počtu predikovaných krokov odrezané od konca tak, aby bolo možno využiť vstupnú množinu dát a demonštrovať na nej naučenú sieť so schopnosťou predikcie pre požadovaný počet krokov. Vstupné dáta pre predikciu sú v premennej inputSeriesPrediction, požadovaný výstup v targetSeriesPrecition. Potreba podotknúť, že sa jedná o dáta s ktorými neurónová sieť v procese učenia neprichádza do styku.

Vytvorenie siete umožňuje funkcia narxnet, ktorá berie v úvahu spomenuté parametre ako počet neurónov v skrytej vrstve a pod. Následne je sieť trénovaná a uchovaná v premennej net. Z tejto premennej vznikne netpred ktorá reprezentuje sieť s odstráneným oneskorením vďaka čomu je možná predikcia požadovaný počet krokov dopredu.

```
%% Načítanie dát
S = load('data\NN_D1_data_2_fullguppy');
S = S.dataFinal;

% Nastavenie
N = 5;      % Počet krokov predikcie
delay = 8; % Oneskorenie
rows = 4;   % 1-open, 4-close, 16-guppy
neuronsHiddenLayer = 10;      % neurónov

% Transformácia dát
X = S(1:rows,:); % Vstupné dáta
T = S(4,:);      % Cieľ predikcie

% Dáta použité k trénovaniu siete
inputSeries  = X(1:rows,1:end-(N+delay));
targetSeries = T(1:end-(N+delay));
inputSeries = tonndata(inputSeries,true,false);
targetSeries = tonndata(targetSeries,true,false);

% Dáta použité k predikcii; skryté počas učenia
inputSeriesPrediction = S(1:rows, end-(delay+N)+1:end-N);
targetSeriesPrediction = S(4,end-(delay+N)+1:end-N);
inputSeriesPrediction=tonndata(inputSeriesPrediction,true,false);
targetSeriesPrediction=tonndata(targetSeriesPrediction,true,false);

%% Vytvorenie siete
net = narxnet(N:delay,N:delay,neuronsHiddenLayer);
view(net)

% Trénovanie siete
[Xs,Xi,Ai,Ts] = preparets(net,inputSeries,{},targetSeries);
```

```
[net,tr] = train(net,Xs,Ts,Xi,Ai);
Y = net(Xs,Xi,Ai);

% Predikcia N krokov dopredu
netpred = removedelay(net,N);
view(netpred);
[Xsr,Xir,Air,Tsr]=preparets(netpred,inputSeriesPrediction,{},targetSer
iesPrediction);
yPred = netpred(Xsr,Xir,Air);

% Grafický výstup
titulok = ['NARX - ', num2str(N) , ' days ahead prediction'];
generate_graph(T,yPred,N,100,titulok);
```

V závere skriptu sa využíva funkcia generate_graph, ktorá zaručuje vykreslenie grafu s priebehom časovej rady, predikcii siete a očakávaných hodnôt.

4.2.2 Učenie siete

Po spustení skriptu z predchádzajúcej časti sa otvorí Neural Network Training Tool, ktorý poskytuje informácie o použitých algoritmoch , procese učenia a výsledkoch.

Vzorová sieť bola natrénovaná za 1 minútu a 2 sekundy a to v 11-tich iteráciách. K ukončeniu trénovania došlo po dosiahnutí počtu validačných kontrol (štandardná hodnota nastavená na 6).

Ako ďalšie parametre obmedzujúce dĺžku učenia možno zvoliť nasledovné hodnoty, ktoré však boli ponechané na štandardné hodnoty:

- Maximálny počet dosiahnutých epoch reprezentujúcich počet iterácií učenia siete.
- Výkonnosť siete meraná pomocou strednej kvadratickej chyby (Mean Squared Error).
- Výška gradientu.

4.2.2.1 Výkonnosť siete

Graf Performance plot zobrazuje vývoj strednej kvadratickej chyby počas trénovania siete. Funkcia znázornená modrou farbou zobrazuje klesajúcu chybu trénovacích dát. Tréning je zastavený v momente , keď sa chyba validačných dát znázornená zelenou farbou dostane na svoje minimum. V grafe je minimum označené zeleným krúžkom.

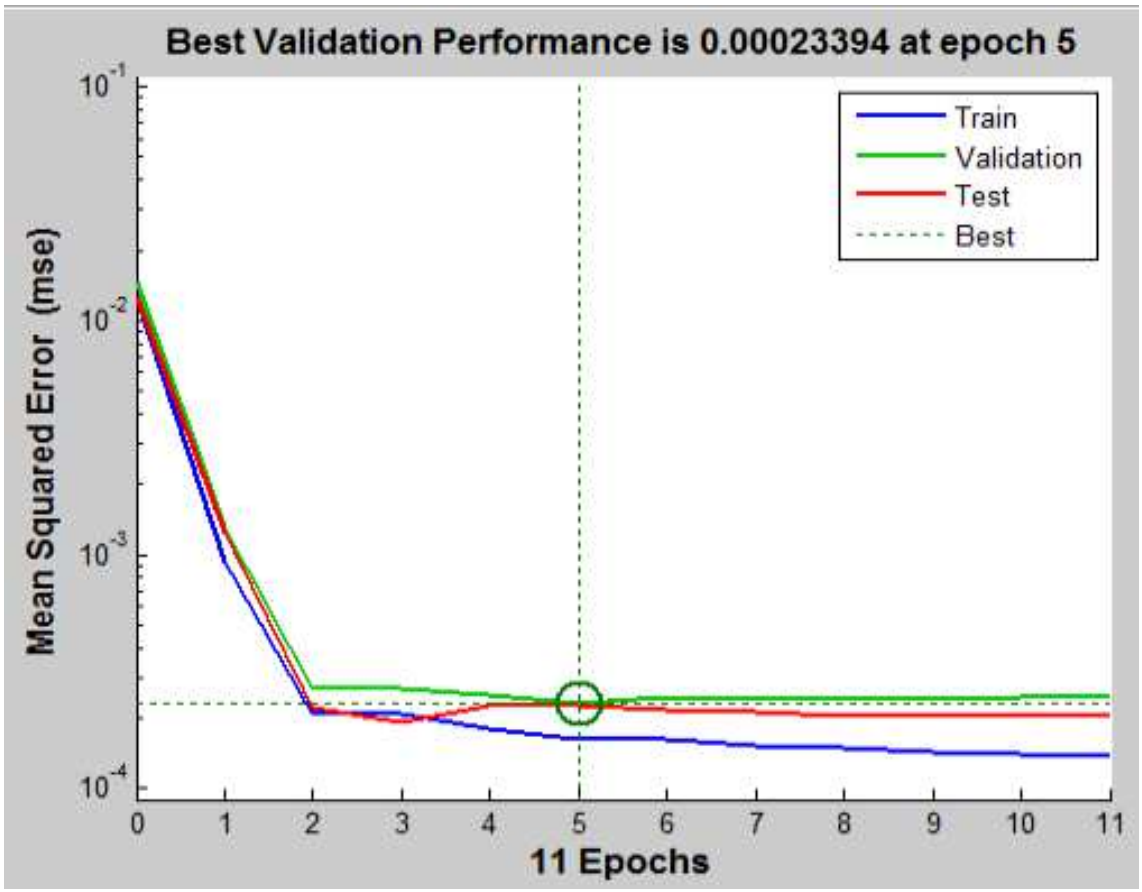

Obr. 4.4: Performance plot pre sieť NARX (Zdroj: vlastný)

Možno povedať, že po piatu iteráciu dochádzalo k zníženiu strednej kvadratickej chyby. Po konečnú jedenástu iteráciu táto hodnota nepatrne stúpala u validačnej množiny. Hodnota MSE po piatej iterácií klesala ako u trénovacej tak aj testovacej množiny.

4.2.2.2 Rozloženie chyby

Graf Error Histogram predstavuje grafickú reprezentáciu najčastejšie dosahovaných chýb natrénovaným modelom. Obdobne ako v predchádzajúcom prípade i tu sú jednotlivé množiny dát reprezentované rozdielnymi farbami.

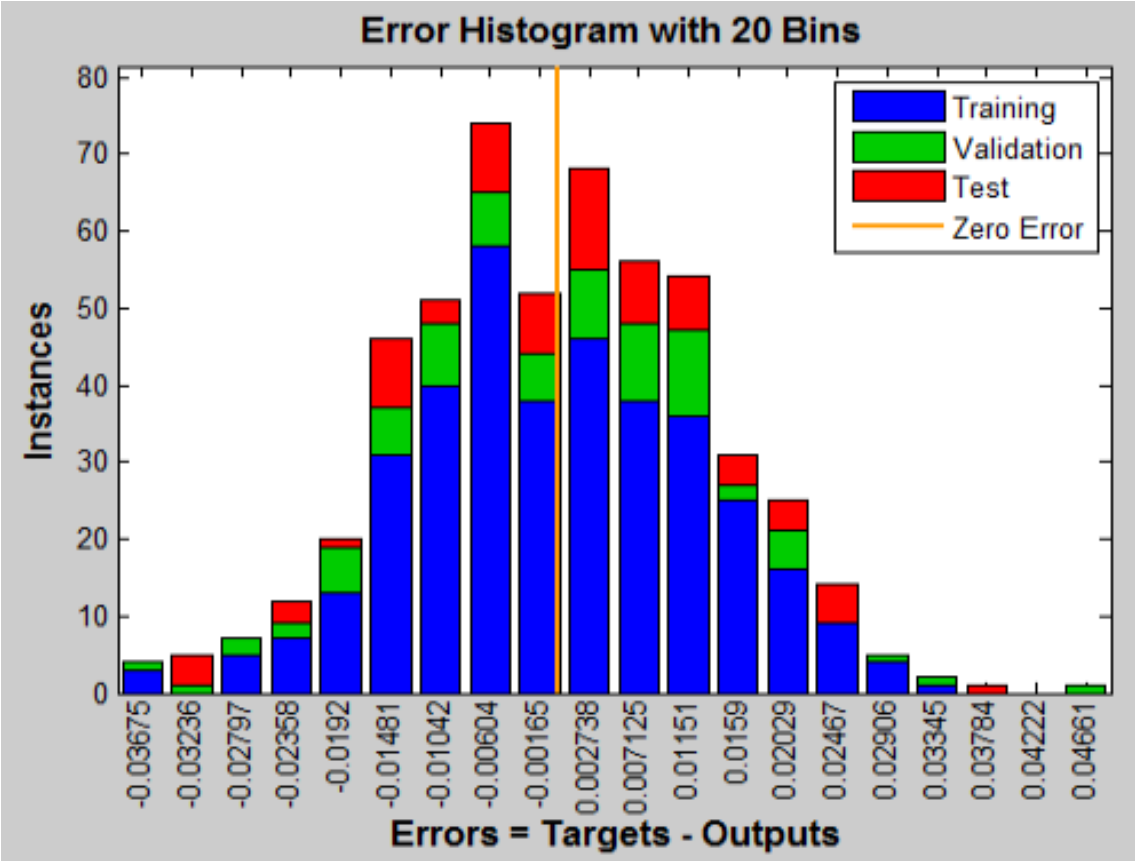

Obr. 4.5 Error Histogram pre sieť NARX (Zdroj: vlastný)

Z grafu je zrejmé, že rozsah hodnôt je od -0,03675 po 0.04661 a tvar pripomína normálne rozdelenie.

4.2.3 Výsledok predikcie

Sieť bola natrénovaná k predikcii 5 obchodných dni dopredu. Výsledok predikcie je k dispozícií na nasledujúcom grafe. Modrou farbou je zobrazená časová rada na ktorej prebiehalo učenie siete, červenou je očakávaný (skutočný) priebeh a zelenou je výsledok predikcie modelu. Graf je priblížený na takú úroveň, aby bolo možné prezentovať rozdiely medzi predikciou a skutočným priebehom.

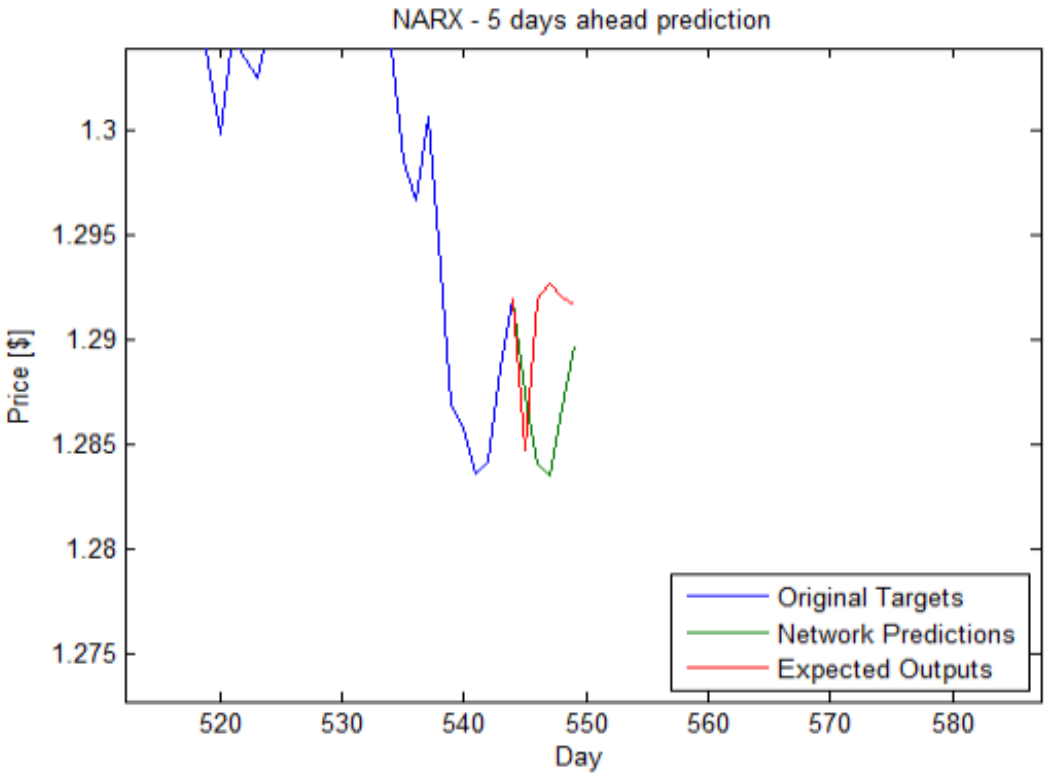

Obr. 4.6: Predikcia siete NARX (Zdroj: vlastný)

Z grafu priebehu predikcie a porovnaniu k skutočnému priebehu časovej rady možno vyvodiť záver, že v prvom kroku bola predikovaná hodnota blízka skutočnosti. V druhom kroku došlo k nárastu skutočnej hodnoty, avšak predikovaná hodnota naďalej pozvoľna klesala. Nárast, ktorý zaznamenala skutočná časová rada na konci druhého obchodného dňa predpovedala neurónová sieť až pre tretí deň. V závere 5 dňového cyklu prišlo k dorovnaniu predikovaného a skutočného priebehu i keď rozdiel medzi týmito časovými radami tvoril približne 20 bodov.

Možno si povšimnúť skutočnosť, že ako skutočný priebeh časovej rady tak aj predikovaný model pomerne presne reagovali na zónu v oblasti 1,2850 až 1,2800 ktorá bola v analýze časovej rady označená za možnú úroveň podpory.

4.3 Neurónová sieť FTDN

Neurónová sieť typu FTDN bola trénovaná na totožných dátach ako predchádzajúci model (sieť NARX) a to predovšetkým kvôli jednoduchšiemu porovnaniu modelov. Ako vstupná hodnota bola použitá matica s 10 hodnotami pre každý obchodný deň.

4.3.1 Štruktúra siete

Štruktúra siete je taktiež veľmi podobná modelu NARX. Vstupných 10 hodnôt na ktoré je aplikované časové oneskorenie 8 krokov. Výstupom je opäť iba jedna hodnota a to zatváracia cena. V skrytej vrstve sa nachádza 10 neurónov.

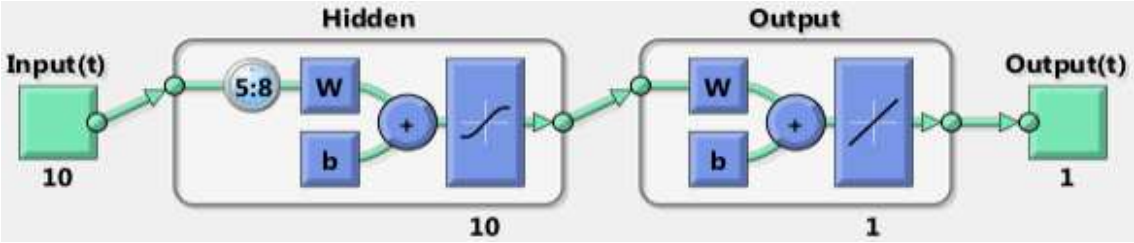

Obr. 4.7: Štruktúra siete FTDN (Zdroj: vlastný)

4.3.2 Učenie siete

Parametre pre proces učenia sú viac-menej totožné s NARX modelom. Dáta sú delené náhodne, učiaca funkcia je trainlm (upravuje váhy neurónov podľa Levenberg - Marquardt optimalizácie) a výkonnosť siete určená strednou kvadratickou chybou. Ostatne spomenuté parametre s výsledkami učenia zobrazuje nasledovný obrázok.

K zastaveniu trénovania siete došlo z dôvodu dosiahnutia počtu validačných kontrol, ktoré boli nastavené na 6. Veľkosť chyby bola rovná 0,000147. Za povšimnutie rozhodne stojí rozdiel v čase trénovania siete NARX a FTDN. Sieť FTDN s podobnou štruktúrou a rovnakými vstupmi bola naučená za 13 sekúnd v 11 iteráciách (naproti tomu učenie NARX trvalo 1 minutú a 2 sekundy, taktiež 11 iterácií).

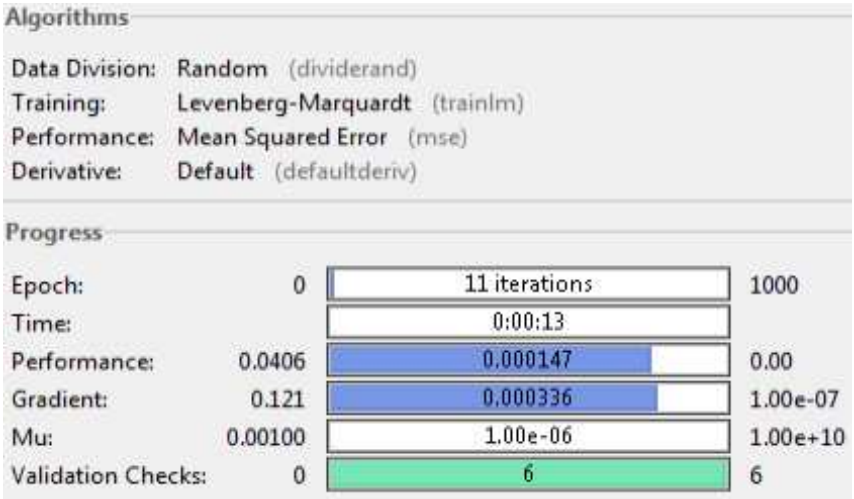

Obr. 4.8: Informácie o priebehu učenia FTDN siete (Zdroj: vlastný)

Samotné učenie a tým aj skript využívaný k učeniu siete je podobný okomentovanému skriptu v predchádzajúcej časti zameranej na NARX sieť. Rozdiel je v použitej MATLAB funkcii ktorou sa vytvára sieť.

```
N = 5;      % Počet krokov predikcie
delay = 8; % Oneskorenie
neuronsHiddenLayer = 10;      % neurónov

net = distdelaynet({N:delay,0},neuronsHiddenLayer);
```

4.3.2.1 Výkonnosť siete

K meraniu výkonnosti siete bola zvolená hodnota strednej kvadratickej chyby, ktorá je znázornená na nasledujúcom grafe. Jednotlivé dátové sady sú zobrazené rozdielnými farbami. Po piatu iteráciu učenia siete chyba klesala až k svojej najnižšej úrovni, ktorá je znázornená zeleným krúžkom. Nasledujúcich šesť iterácií nedošlo k zníženiu MSE u validačných dát a tak bolo učenie siete zastavené.

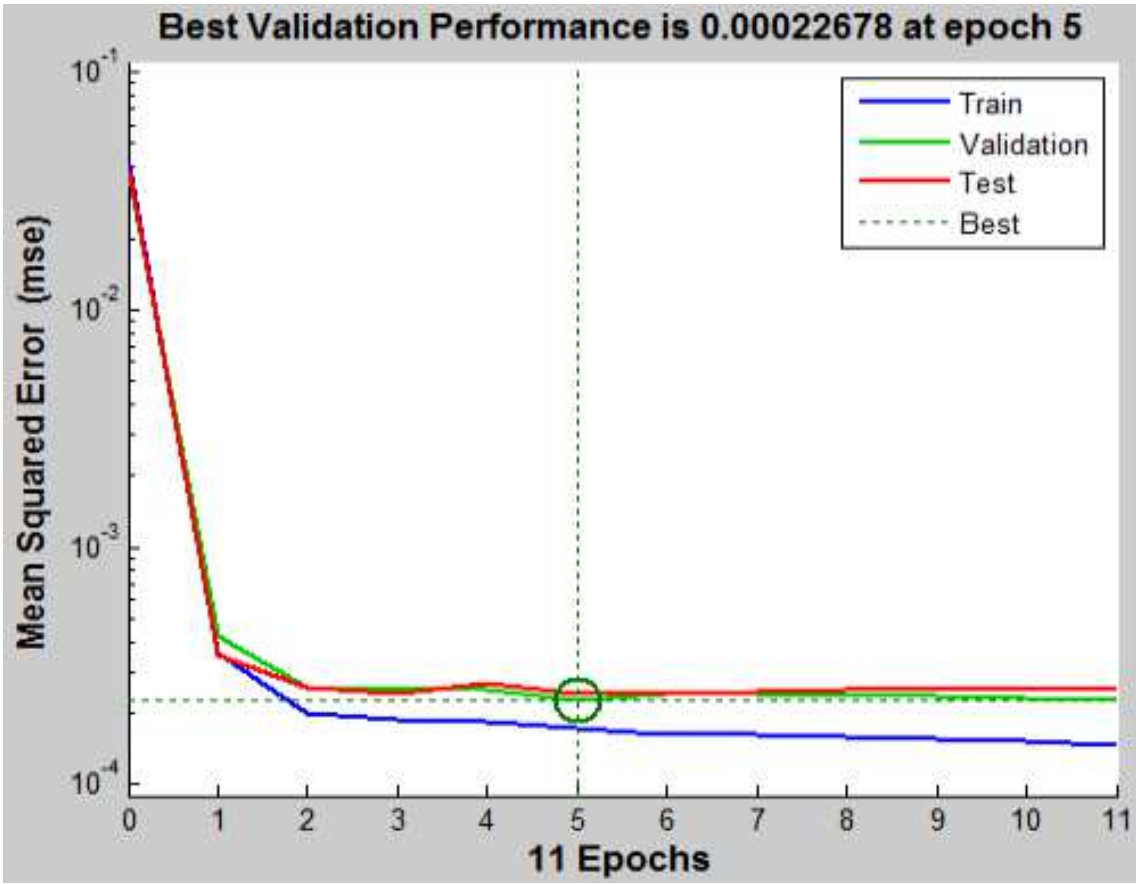

Obr. 4.9: Performance plot pre sieť FTDN (Zdroj: vlastný)

Napriek skutočnosti, že hodnota strednej kvadratickej chyby trénovacej sady klesala aj po piatej iterácií, hodnota MSE validačnej sady oscilovala okolo dosiahnutého minima a hodnota MSE testovacej množiny mierne narástla, možno považovať model za správne naučený. Nie je predpoklad preučenia a neschopnosť generalizácie.

4.3.2.2 Rozloženie chyby

Rozloženie chyby je znázornené histogramom, z ktorého je zrejmá najčastejšie dosahovaná chyba a to 0,007386. Rozsah hodnôt sa pohybuje v rozmedzí od -0,03649 po 0,03929.

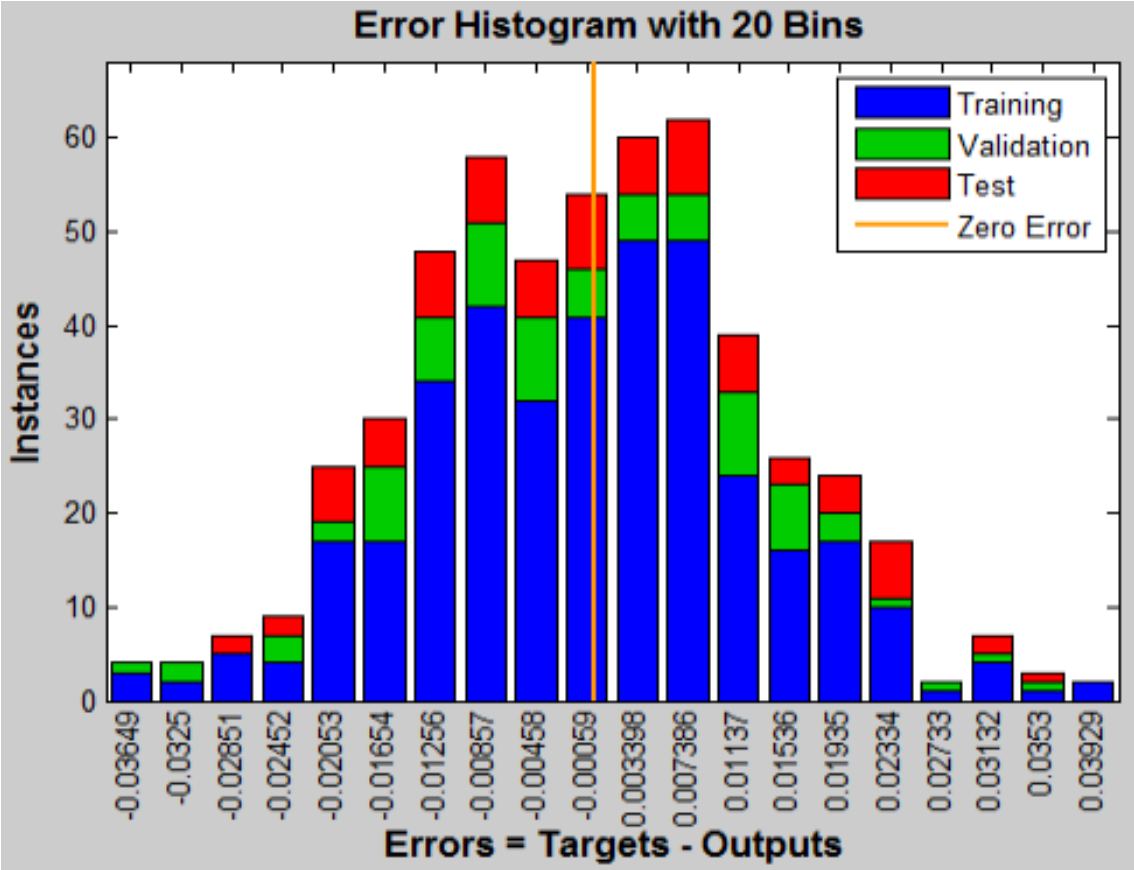

Obr. 4.10: Error Histogram pre sieť FTDN (Zdroj: vlastný)

Rozdelenie má horší priebeh ako v prípade siete NARX. Obzvlášť v pravej časti grafu, kde je na hodnote 0,02733 vidieť pokles počtu chýb a následný skokový nárast pre ďalšiu hodnotu.

4.3.3 Výsledok predikcie

Nasledujúci graf predstavuje výsledok natrénovaného modelu siete FTDN pre predikciu 5 obchodných dní. Opäť bolo použité priblíženie pre detailné zobrazenie rozdielu medzi predikovanou hodnotou (označenou zelenou farbou) a skutočným priebehom časovej osi , ktorá je znázornená červenou farbou. Modrá farba predstavuje priebeh originálnej časovej rady na ktorej prebiehalo učenie modelu. Znázornené hodnoty sú zatváracie ceny jednotlivých obchodných dni.

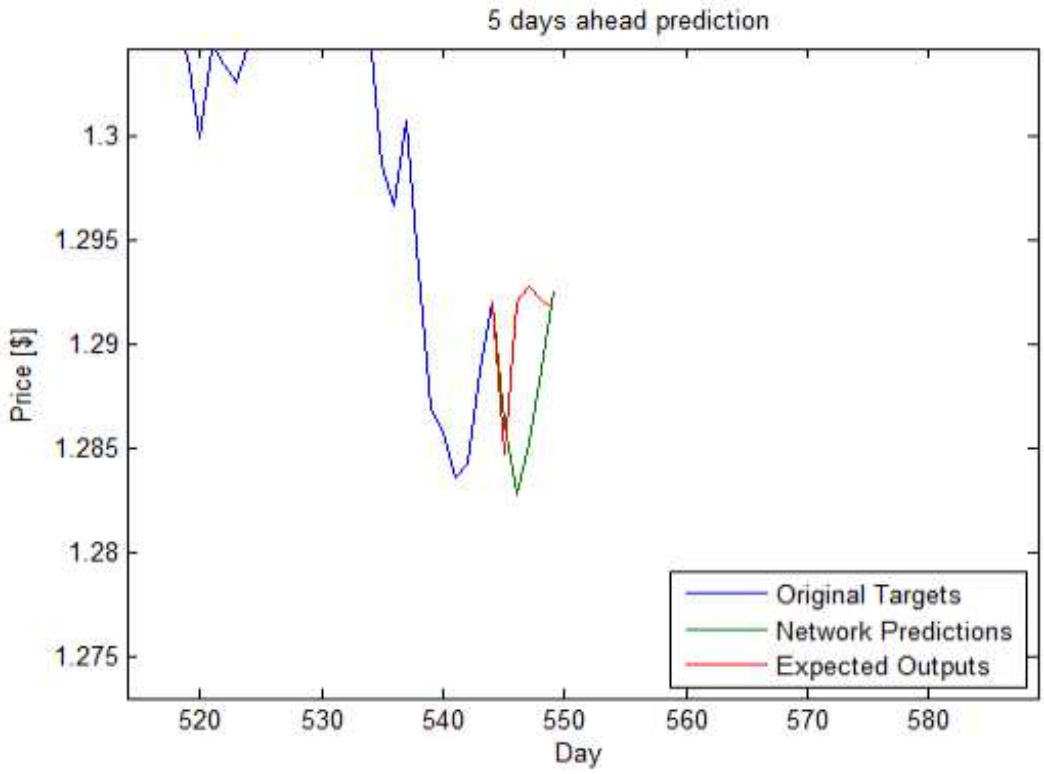

Obr. 4.11: Predikcia siete FTDN (Zdroj: vlastný)

Z grafu možno vypozorovať, že najvernejšie kopírovanie skutočného priebehu modelom bolo v prvom kroku predikcie. Nárast, ktorý zaznamenala skutočná časová rada v druhom kroku model „vyrovnal“ počas posledných dvoch krokov.

Dôležité je upozorniť na úroveň medzi cenami 1,2850 a 1,2800 ktorú model rešpektoval a taktiež fakt, že predikovaná uzatváracia cena po piatich obchodných dňoch bola veľmi podobná skutočnej cene. Rozdiel medzi hodnotami nebol väčší než 10 bodov.

4.4 Optimalizácia a porovnanie modelov

V nasledujúcej kapitole je popísaný rozdiel medzi výkonnosťami jednotlivých modelov pri postupnej zmene parametrov. Pôvodným zámerom bolo vykonať optimalizáciu pomocou Optimization Toolbox nástroja priamo v prostredí MATBAL. Nakoľko sa zámer z technických problémov nepodarilo zrealizovať, genetická optimalizácia bola nahradená niekoľkými „for“ cyklami, kde sa postupne menili parametre.

Cieľom porovnania modelov je získať informácie o správaní sa jednotlivých sietí pri rozličnej štruktúre (počet neurónov skrytej vrstvy a oneskorenie) a pri pridaní indikátorov technickej analýzy k vstupnej časovej rade.

Učenie obidvoch typov sietí prebieha na totožných OHLC dátach a tak je možné aj optické porovnanie výstupu predikových hodnôt.

4.4.1 Model NARX

V prvej časti optimalizácie sa uvažovalo o najjednoduchšej vstupnej časovej rade, ktorá bola reprezentovaná výhradne OHLC dátami bez dopočítaných indikátorov.

Sledovaná veličina optimalizácie bola dosiahnutá stredná kvadratická chyba a taktiež čas potrebný k naučeniu siete. Vývoj spomenutých sledovaných znakov je znázornený v nasledujúcej tabuľke.

Tab. 4.1: Výsledky optimalizácie 1, sieť NARX (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	2,0041	3s
2.	10	7	2,1902	3s
3.	10	8	2,3207	4s
4.	10	9	1,9617	7s
5.	10	10	1,9924	6s
6.	10	15	2,1679	13s
7.	15	6	1,9452	4s
8.	15	7	1,8465	9s
9.	15	8	1,9865	8s
10.	15	9	1,9940	8s
11.	15	10	2,0195	9s
12.	15	15	2,1770	26s

Najnižšiu dosiahnutú chybu $1{,}8465 \times 10^{-4}$ mala sieť s poradovým číslom 8 ktorá pozostáva z 15 neurónov v skrytej vrstve a oneskorením 7 krokov. Pri optickej kontrole

na predikovaných dátach bolo zrejmé rešpektovanie supportu , kde sa výstup modelu a priebeh skutočnej časovej rady v prvom kroku temer nelíšil.

Za povšimnutie stojí dĺžka učenia všetkých sietí z predchádzajúcej tabuľky. Okrem modelov s najväčším oneskorením nepresiahol čas učenia 10 sekúnd.

Druhým krokom optimalizácie bolo navýšenie počtu vstupných dát zo 4 na 10 . Tieto dáta boli reprezentované OHLC a vypočítanými exponenciálnymi kĺzavými priemermi podľa popisovaného GMMA systému (reprezentujúce krátkodobých obchodníkov). Výsledky sú znázornené nižšie.

Tab. 4.2: Výsledky optimalizácie 2, sieť NARX (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	1,8334	11s
2.	10	7	1,6748	16s
3.	10	8	2,1228	8s
4.	10	9	1,7728	12s
5.	10	10	1,9213	23s
6.	10	15	2,0247	55s
7.	15	6	1,8129	8s
8.	15	7	1,4705	49s
9.	15	8	1,8980	28s
10.	15	9	1,6829	50s
11.	15	10	1,5361	1m 25s
12.	15	15	2,0260	2m 31s

Navýšenie počtu vstupov výrazne ovplyvnilo dĺžku učenia siete. Pri najvyššom počte neurónov a oneskorení 15 krokov trvalo učenie viac ako 2 minúty avšak hodnota sledovanej chyby modelu bola druhá najväčšia v sledovanej množine. Tieto hodnoty podporujú tvrdenie, že navýšenie počtu neurónov nemusí znamenať lepší výsledok a vyžaduje úpravu aj ostatných parametrov siete.

Posledná dátová sada obsahuje ako vstup 16 časových rád pre každý obchodný deň. Tieto dáta sú tvorené OHLC dátami a vypočítaným GMMA systémom pozostávajúcim z exponenciálnych kĺzavých priemerov ako pre krátkodobý tak pre dlhodobý priebeh.

Tab. 4.3: Výsledky optimalizácie 3, sieť NARX (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	1,9097	16s
2.	10	7	1,9396	12s
3.	10	8	1,6590	51s
4.	10	9	1,5759	47s
5.	10	10	1,8458	54s
6.	10	15	0,7372	9m 44s
7.	15	6	1,2004	28s
8.	15	7	0,9431	2m 8s
9.	15	8	0,6745	3m 31s
10.	15	9	0,8988	3m 30s
11.	15	10	0,8882	4m 28s
12.	15	15	1,4970	12m 10s

Navýšenie počtu vstupných dát spolu s navyšovaním oneskorenia malo za následok, že učenie siete číslo 6 trvalo bezmála 10 minút. Zároveň je dôležité upozorniť na nižšiu dosiahnutú chybu. Siete v sledovanom súbore, ktoré boli učené dlhšie ako minútu dosahovali lepšie hodnoty sledovanej chyby.

4.4.2 Model FTDN

Obdobne ako v prípade modelu NARX boli cykly pre zmenu parametrov rozdelené do 3 kategórií. V prvej dátovej sade boli na vstupe 4 časové rady pre každý obchodný deň. Tieto hodnoty pozostávali z OHLC dát.

Tab. 4.4: Výsledky optimalizácie 1, sieť FTDN (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	1,9731	1s
2.	10	7	1,9674	2s
3.	10	8	1,9715	2s
4.	10	9	1,8086	4s
5.	10	10	1,9882	3s
6.	10	15	2,0577	9s
7.	15	6	1,9657	2s
8.	15	7	1,9263	2s
9.	15	8	2,1026	3s
10.	15	9	1,9305	7s
11.	15	10	1,8008	9s
12.	15	15	2,0367	23s

Čas potrebný pre učenie nepresiahol 10 sekúnd okrem posledného 12-teho modelu. V porovnaní so sieťou NARX boli hodnoty času učenia v priemere nižšie. Taktiež najnižšia dosiahnutá chyba bola nižšia ako u modelu NARX. Chyba dosiahla hodnotu 1.8008×10^{-4}.

Pre model s 10-timi časovými radami na vstupe boli časy potrebné k učeniu vyššie u modelu FTDN (na rozdiel od modelu so 4 vstupmi). Dosiahnuté hodnoty sú znázornené v tabuľke.

Tab. 4.5: Výsledky optimalizácie 2, sieť FTDN (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	1,9833	13s
2.	10	7	1,5040	15s
3.	10	8	1,9809	11s
4.	10	9	1,6341	19s
5.	10	10	1,6671	29s
6.	10	15	1,8842	1m 13s

7.	15	6	1,8040	12s
8.	15	7	1,6456	28s
9.	15	8	1,5824	34s
10.	15	9	1,9960	39s
11.	15	10	1,7146	42s
12.	15	15	1,3581	4m 17s

Výrazný rozdiel v čase učenia bol zaznamenaný v poslednej, 12-tej sieti. Model FTDN síce potreboval 4 minúty a 17 sekúnd (v porovnaní s modelom NARX pri podobnej štruktúre ktorého učenie trvalo 2 minúty a 31 sekúnd) avšak dosiahol lepšiu sledovanú hodnotu chyby.

Z hľadiska sledovaných veličín bol jednoznačne najzaujímavejší priebeh modelov siete FTDN, ktoré na vstupe obsahovali všetkých 16 časových rád.

Tab. 4.6: Výsledky optimalizácie 3, sieť FTDN (Zdroj: vlastný)

Číslo siete	**Neurónov**	**Oneskorenie**	**Chyba [10^{-4}]**	**Čas**
1.	10	6	1,7724	7s
2.	10	7	1,1475	28s
3.	10	8	1,9659	19s
4.	10	9	1,0294	56s
5.	10	10	0,6880	3m 19s
6.	10	15	0,7706	7m 6s
7.	15	6	0,7946	57s
8.	15	7	0,9072	2m 10s
9.	15	8	0,8015	2m 15s
10.	15	9	0,6758	7m 17s
11.	15	10	0,7907	4m 58s
12.	15	15	0,6995	18m 45s

Ako je zrejmé z údajov vyššie, najdlhší čas potrebný k učeniu siete dosiahol 18 minút a 45 sekúnd pre model číslo 12. Zároveň však klesla chyba o jeden rád pre siete, ktoré v skrytej vrstve obsahovali 15 neurónov.

Najnižšiu chybu spomedzi všetkých FTDN modelov bol dosiahnutý v modeli číslo 10 s parametrami 15 neurónov pri oneskorení 9 krokov a 16 časových rád na vstupe. Chyba dosiahla hodnotu 6.7581×10^{-5}, histogram rozloženia chyby je znázornený na nasledujúcom obrázku.

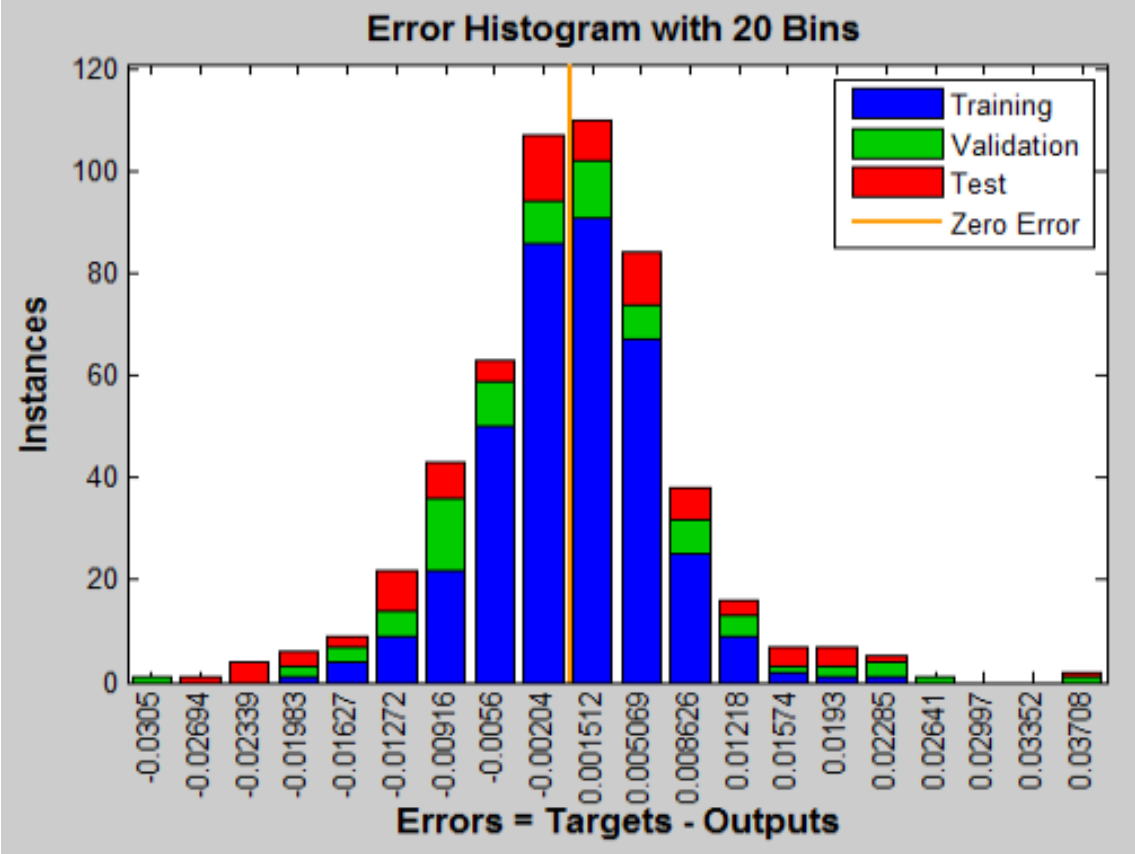

Obr. 4.12: Error Histogram optimalizovanej FTDN siete (Zdroj: vlastný)

V porovnaní s modelmi predstavenými v predchádzajúcich častiach tejto kapitoly je badať výrazný progres. Hodnoty pripomínajú normálne rozdelenie. Taktiež dosahované hodnoty strednej kvadratickej chyby podľa očakávaní splňujú predpoklad postupného znižovania. Najnižšia hodnota MSE bola podľa nasledujúceho grafu dosiahnutá v 44-tej iterácií. Proces učenia tak skončil po 51 iteráciách a čas potrebný k učeniu bol 7 minút a 17 sekúnd.

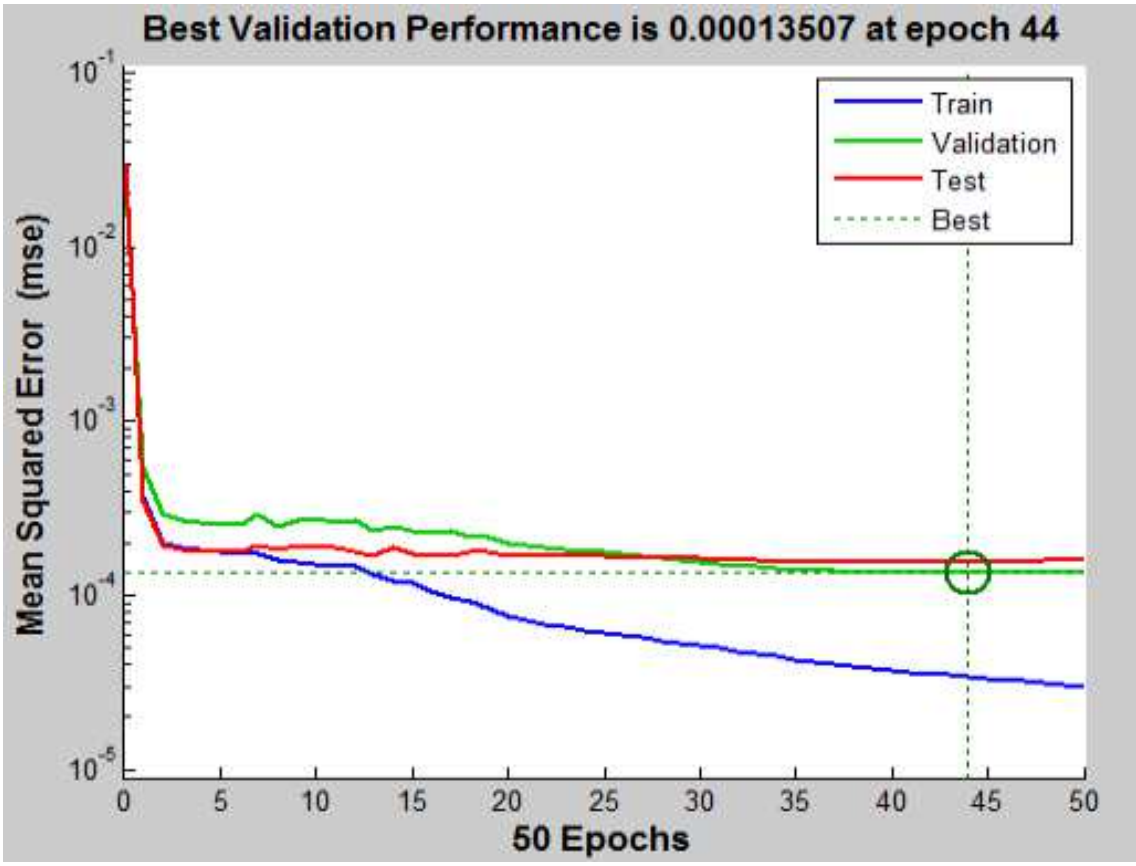

Obr. 4.13: Performance plot pre sieť optimalizovanú sieť FTDN (Zdroj: vlastný)

Výsledok predikcie popisovanej siete je znázornený nižšie. Rozsah hodnôt siete bol menší ako rozsah hodnôt skutočnej časovej rady. Napríklad pri pohybe 50 bodov skutočnej časovej rady model predpokladal pohyb „iba“ o 30 bodov (prvý krok). Čo je však dôležité a nutné podotknúť, model verne predpovedal smerový pohyb časovej rady.

Interpretácia výsledku predikcie ako smerového systému je podporená aj podstatou na ktorej sú založené indikátory pridané k vstupnej časovej rade.

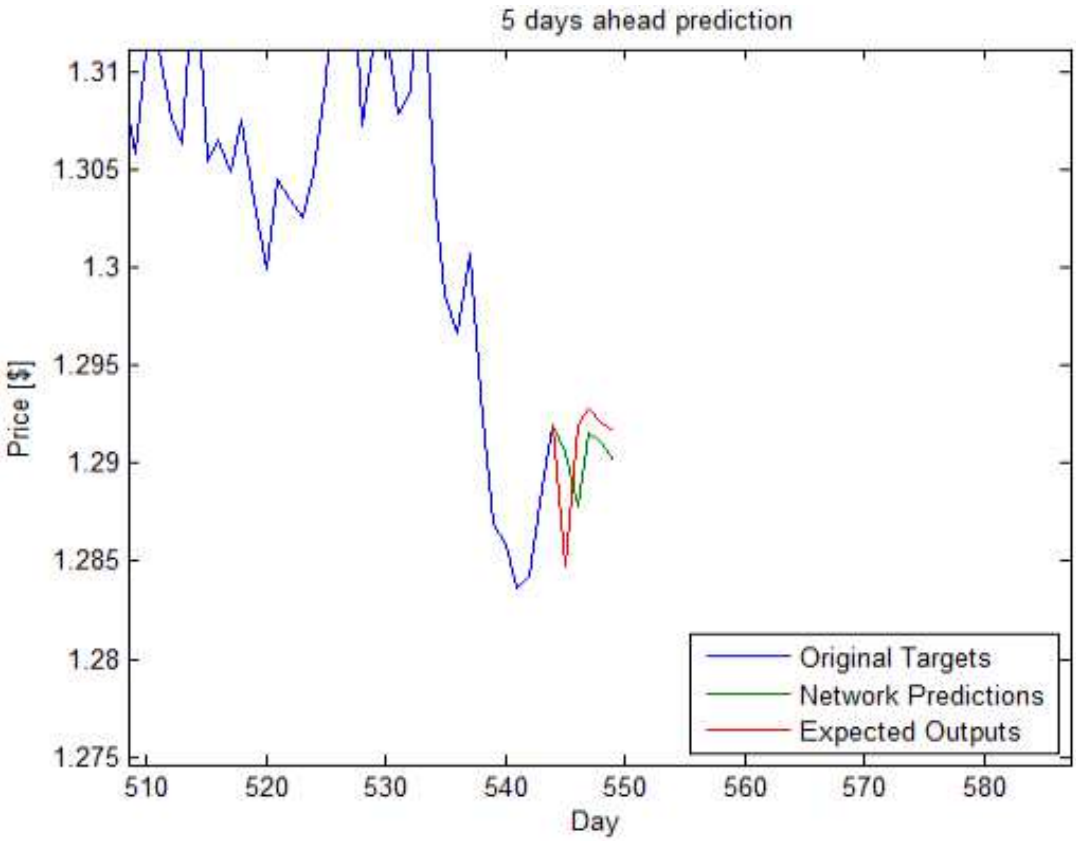

Obr. 4.14: Výsledok predikcie optimalizovanej FTDN siete (Zdroj: vlastný)

Záverom porovnania možno povedať, že oba typy neurónových sietí poskytovali rôznorodé výsledky. Po vyhodnotení strednej kvadratickej chyby a času učenia sa ako lepšia voľba javí sieť FTDN. Úspech modelu je však závislý na množstve faktorov akými sú počet neurónov, aktivačná funkcia alebo oneskorenie na vrstvách. Dôležitý je taktiež charakter časovej rady, volatilita a aplikované indikátory.

Pridaním indikátorov technickej analýzy, ktoré neboli „samoúčelné“ ale predstavovali jasne popísaný systém (GMMA), došlo k výraznému zlepšeniu predikovaných výsledkov, cenou však bol dlhší čas učenia siete.

4.5 Ekonomické zhodnotenie

Nasledujúca kapitola predstavuje ekonomický pohľad na navrhnuté riešenie. Vyčísľuje náklady a prínosy spojené s realizáciou.

4.5.1 Náklady

Náklady spojené s realizáciou predstaveného riešenia možno rozdeliť do dvoch hlavných kategórií, menovite na programovanie, testovanie a vyhodnotenie a realizačné náklady.

Programovanie ako aj činnosti s tým spojené, predovšetkým testovanie a vyhodnotenie nie je možné exaktne ohodnotiť cenou práce.

Pomerne presne možno ohodnotiť realizačné náklady, ktoré predstavujú zabezpečenie potrebného software a hardware. Z hľadiska časovej náročnosti tréningu sietí sa javí rozumné využiť možnosť prenajatého dedikovaného serveru tretej strany. Po softwarovej stránke je potrebný operačný systém a software MATLAB s prídavkami pre neurónové siete.

Nasledujúca tabuľka zobrazuje prehľad nákladov rozdelených podľa vyššie spomenutých kategórii.

Tab. 4.7: Odhadované náklady na realizáciu (Zdroj: vlastný)

Názov položky	**Čiastka v Kč**
Hardware	
Prenájom serveru	1000 / mesiac
Software	
Licencia Windows	1000 / mesiac
Licencia MATLAB	60000
Licencia Neural Network Toolbox	29000

Celkové náklady firmy na realizáciu sú vyčíslené na čiastku 113 000 Kč, ktoré by musela vynaložiť v prvom roku na zadováženie požadovaného softwarového vybavenia. V nasledujúcich rokoch by sa čiastka znížila iba na periodicky opakované platby za prenájom serveru a systému Windows.

Je potreba podotknúť, že uvedené náklady sú uvažované pre prípad záujmu zo strany spoločnosti a nepredstavujú skutočne vynaložené náklady na realizáciu. K realizácií boli využité dostupné študentské licencie softwaru na počítačoch Fakulty podnikatelskej.

4.5.2 Prínosy

Hlavným prínosom predstaveného riešenia je rozšírenie know-how spoločnosti IJM Group, s.r.o pre ktorú bola práca určená. Firma získala technologický postup a sadu nástrojov, ktoré môže využiť v budúcnosti pokiaľ sa rozhodne implementovať neurónové siete do svojich produktov.

Nezanedbateľným prínosom je taktiež vytvorenie akýchsi mantinelov, ktoré dávajú predstavu o možnosti zapracovania neurónových sietí do automatických systémov, nutnosti ľudského faktoru pri vyhodnotení a časovej náročnosti.

Nemožno preto hovoriť o prínosoch aktuálnych ale o prínosoch budúcich.

5 Záver

Diplomová práca mala za cieľ predstaviť problematiku neurónových sietí a ich následnú aplikáciu na devízovom trhu. Z toho dôvodu je teoretická časť rozdelená na časti, ktoré sa postupne venujú finančným trhom s dôrazom na trh devízový. Následne je predstavená problematika analýz finančných časových rád. V závere teoretickej časti je popísaná problematika neurónových sietí a ich aplikácia v prostredí MATLAB.

V praktickej časti boli vytvorené a optimalizované modely rôznych neurónových sietí. Na tieto modely boli aplikované indikátory technickej analýzy čo umožnilo sledovať zmenu správania v predikcií pri zmene indikátorov.

Výstupom diplomovej práce sú v práci komentované zdrojové kódy a postupy umožňujúce extrakciu dát, ich následné spracovanie a vytvorenie modelov neurónových sietí. Tie môžu slúžiť zadávateľskej spoločnosti IJM Group, s.r.o ako rámec pre ďalšiu prácu s neurónovými sieťami na finančnom trhu.

Zoznam použitej literatúry

Knižné publikácie

[1] ANDĚL, J. *Základy matematické statistiky*. 2. vyd. Matfyzpress, 2007. 358 s ISBN : 978-80-7378-001-2.

[2] DOSTÁL, P., RAIS, K., SOJKA, Z. *Pokročilé metody manažerského rozhodování: konkrétni příklady využití metod v praxi*. Grada Publishing a.s., 2005. 166 s. ISBN : 80-247-1338-1.

[3] FAUSETT, L.V. *Fundamentals of Neural Networks: Architecture, algorithms, and applications*. Prentice-Hall, 1994. ISBN : 0-13-334-186-0.

[4] GUPPY, D. *Trend Trading: A Seven-step Approach to Success*. 1. Vyd. Wrightbooks, 2004. 440 s. ISBN : 978-0-7314-0085-0.

[5] HARTMAN, O., TUREK, L. *První kroky na FOREXu: Jak obchodovat a uspět na měnových trzích*. Brno: Computer Press, 2009. 120 s. ISBN : 978-80-251-2006-4.

[6] HORNER, R. *ForeX tradingem k maximálním ziskům.* 1. vyd. BIZBOOKS, 2011. 232 s. ISBN 978-80-251-2921-0.

[7] REJNUŠ, O. *Peněžní ekonomie (finanční trhy)*. 3. vyd. Brno: Akademické nakladatelství Cerm, 2012. 374 s. ISBN : 978-80-214-4415-7.

[8] ŘÍHA, J. *Technická analýza cenných papírů*. Praha: Comenia Nova, 1994. 104 s. ISBN : 80-901-7840-5.

[9] ROSE, P.S. *Peněžní a kapitálové trhy*. Victoria publishing, 1995. 1014 s. ISBN : 80-85605-52-X.

[10] SŮVOVÁ, H. *Specializované bankovnictví*. 1. vyd. Praha: Bankovní institut, 1997. 398 s. ISBN : 80-902243-2-6.

Elektronické zdroje

[11] BEALE, M.H., HAGAN, M.T., DEMUTH, H.B. *Neural Network Toolbox: User's Guide.* [online]. The MathWorks, Inc. 2014 [cit. 2014-04-15]. Dostupné z WWW: <http://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf>.

[12] CHALUPNÍK, V. *Biologické algoritmy (4): Neurónové sítě.* [online]. Root.cz. 25.4.2012 [cit. 2014-04-18]. Dostupné z WWW: <http://www.root.cz/clanky/biologicke-algoritmy-4-neuronove-site/>.

[13] *Introduction to neural networks*. [online]. Imperial College London. [cit. 2014-05-01]. Dostupné z WWW: <http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html>.

[14] KOUKAL, J. *Úvod do neuronových sítí*. [online]. AUTOMA časopis pro automatizační techniku. [cit. 2014-04-15]. Dostupné z WWW: <http://www.odbornecasopisy.cz/index.php?id_document=30255>.

[15] MINISTERSTVO SPRAVODLIVOSTI SLOVENSKEJ REPUBLIKY. Obchodný register na Internete. [online]. [cit. 2014-05-01]. Dostupné z WWW: <http://www.orsr.sk/vypis.asp?ID=200687&SID=3&P=0>.

[16] RIOS, D. *Introduction to Neural Networks*. [online]. Learn artificial neural networks. [cit. 2014-05-01]. Dostupné z WWW: <http://www.learnartificialneuralnetworks.com/introduction-to-neural-networks.html>.

Zoznam obrázkov

Obr. 2.1: Schodový graf (Zdroj: vlastný) 21
Obr. 2.2: Sviečkový graf (Zdroj: vlastný)..... 22
Obr. 2.3: Líniový graf (Zdroj: vlastný)..... 22
Obr. 2.4: Umelý neurón (Zdroj: [12])..... 26
Obr. 2.5: Aktivačná funkcia hardlim (Zdroj:[11])..... 27
Obr. 2.6: Aktivačná funkcia logsig (Zdroj: [11])..... 27
Obr. 2.7: Aktivačná funkcia purelin (Zdroj: [11])..... 28
Obr. 2.8: Model doprednej viacvrstvovej siete (Zdroj: [11]) 28
Obr. 2.9: Paralelný a sériový režim siete NARX (Zdroj: [11]) 32
Obr. 2.10: Model siete NARX (Zdroj: [11])..... 33
Obr. 2.11: Model siete FTDN (Zdroj: [11])..... 34
Obr. 2.12: Model siete DTDN (Zdroj: [11])..... 34
Obr. 4.1: Zdrojová časová rada (Zdroj: vlastný) 43
Obr. 4.2: Guppy Multiple Moving Average (Zdroj: vlastný)..... 44
Obr. 4.3: Štruktúra siete NARX (Zdroj: vlastný) 47
Obr. 4.4: Performance plot pre sieť NARX (Zdroj: vlastný)..... 50
Obr. 4.5 Error Histogram pre sieť NARX (Zdroj: vlastný) 51
Obr. 4.6: Predikcia siete NARX (Zdroj: vlastný) 52
Obr. 4.7: Štruktúra siete FTDN (Zdroj: vlastný) 53
Obr. 4.8: Informácie o priebehu učenia FTDN siete (Zdroj: vlastný) 54
Obr. 4.9: Performance plot pre sieť NARX (Zdroj: vlastný)..... 55
Obr. 4.10: Error Histogram pre sieť FTDN (Zdroj: vlastný)..... 56
Obr. 4.11: Predikcia siete FTDN (Zdroj: vlastný) 57
Obr. 4.12: Error Histogram optimalizovanej FTDN siete (Zdroj: vlastný) 63
Obr. 4.13: Performance plot pre sieť optimalizovanú sieť FTDN (Zdroj: vlastný)..... 64
Obr. 4.14: Výsledok predikcie optimalizovanej FTDN siete (Zdroj: vlastný) 65

Zoznam tabuliek

Tab. 4.1: Výsledky optimalizácie 1, sieť NARX (Zdroj: vlastný)..... 58
Tab. 4.2: Výsledky optimalizácie 2, sieť NARX (Zdroj: vlastný)..... 59
Tab. 4.3: Výsledky optimalizácie 3, sieť NARX (Zdroj: vlastný)..... 60
Tab. 4.4: Výsledky optimalizácie 1, sieť FTDN (Zdroj: vlastný) 61
Tab. 4.5: Výsledky optimalizácie 2, sieť FTDN (Zdroj: vlastný) 61
Tab. 4.6: Výsledky optimalizácie 3, sieť FTDN (Zdroj: vlastný) 62
Tab. 4.7: Odhadované náklady na realizáciu (Zdroj: vlastný)..... 66