



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

ÚSTAV SOUDNÍHO INŽENÝRSTVÍ

INSTITUTE OF FORENSIC ENGINEERING

ÚSTAV SOUDNÍHO INŽENÝRSTVÍ

INSTITUTE OF FORENSIC ENGINEERING

**VYUŽITÍ UMĚLÉ INTELIGENCE NA
KAPITÁLOVÝCH TRZÍCH KE SNÍŽENÍ RIZIKA
OBCHODOVÁNÍ**

THE USE OF ARTIFICIAL INTELLIGENCE IN THE CAPITAL MARKETS TO REDUCE THE
RISKS OF TRADING

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Štěpán Orság

VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. Petr Dostál, CSc.

BRNO 2016

Zadání diplomové práce

Ústav: Ústav soudního inženýrství
Student: **Bc. Štěpán Orság**
Studijní program: Rizikové inženýrství
Studijní obor: Řízení rizik firem a institucí
Vedoucí práce: **prof. Ing. Petr Dostál, CSc.**
Akademický rok: 2015/16

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

Využití umělé inteligence na kapitálových trzích ke snížení rizika obchodování

Stručná charakteristika problematiky úkolu:

Úvod
Cíle práce, metody a postupy zpracování
Teoretická východiska práce
Analýza současného stavu
Vlastní návrhy řešení
Závěr
Seznam použité literatury
Přílohy

Cíle diplomové práce:

Využití umělé inteligence na kapitálových trzích ke snížení rizika obchodování.

Seznam literatury:

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM Akademické nakladatelství, 2012. 718 p. ISBN 978-80-7204-798-7, e-ISBN 978-80-7204-799-4

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: CERM, 2011. 168 s. ISBN 978-80-7204-747-5

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM Akademické nakladatelství, 2012. 718 p. ISBN 978-80-7204-798-7, e-ISBN 978-80-7204-799-4.

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: CERM, 2011. 168 s. ISBN 978-80-7204-747-5.

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM Akademické nakladatelství, 2012. 718 p. ISBN 978-80-7204-798-7, e-ISBN 978-80-7204-799-4.

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: CERM, 2011. 168 s. ISBN 978-80-7204-747-5.

AZOFF, E.M. Neural Network Time Series Forecasting of Financial Markets. John Wiley & Sons Inc., USA, 1994. 196 s. ISBN 0-471-94356-8.

BOSE, K., LIANG, P. Neural Network, Fundamental with Graphs, Algorithm and Applications. Mc. Graw-Hill, 1996. 478 s. ISBN 0-07-114064-6

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2015/16

V Brně, dne

L. S.

doc. Ing. Aleš Vémola, Ph.D.
ředitel

Abstrakt

Tato práce se zabývá problematikou predikcí obchodování na finančních trzích a pomocí predikce se snaží snížit riziko spojené se vstupem na trh. Predikce je zpracována za využití prostředků umělé inteligence. Ta je v této práci zastoupena neuronovými sítěmi, které modelují a predikují chování trhu. Práce obsahuje popis finančních trhů, burzovního obchodování a jeho analýzami a metod umělé inteligence. Hlavní částí práce je model pro predikci vývoje ceny konkrétního instrumentu. Tento model byl vyvinut v prostředí MATLAB a měl by sloužit jako podpora pro obchodní rozhodování. Jeho cílem je předpovědět směr a velikost pohybu cenové hladiny pro následující obchodní den. Výstup tohoto modelu je zpracován pomocí platformy MetaTrader 4. Na závěr jsou vyčísleny možné zisky plynoucí z tohoto řešení.

Abstract

This thesis deals with the prediction of trading at financial markets and by using the prediction is trying to reduce the risks of entering at the market. The prediction has been work out by using of artificial intelligence. The artificial intelligence is in this thesis represented by neural networks witch model and predict market behavior. The thesis contains a description of the financial markets, exchange trading and its analysis, and artificial intelligence methods. The main part of this thesis is a model for prediction of prices of a particular instrument. This model was developed in MATLAB and should serve as a support for making business decisions. Its aim is to predict the direction and magnitude of movement the price level for the next trading day. The output of this model is processed using the platform MetaTrader 4. At the end are evaluated possible gains from this solution.

Klíčová slova

Finanční trh, akciové indexy, akcie, komodity, riziko, umělá inteligence, Matlab, neuronová síť, predikce, pokles ceny, růst ceny.

Keywords

Financial markets, stock indices, equities, commodities, risk, artificial intelligence, Matlab, neural network, prediction, price drop, prices rise.

Bibliografická citace

ORSÁG, Š. *Využití umělé inteligence na kapitálových trzích ke snížení rizika obchodování*. Brno: Vysoké učení technické v Brně. Ústav soudního inženýrství, 2016. 76 s.
Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Prohlášení

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Brně dne

.....

podpis diplomanta

Poděkování

Na tomto místě bych rád poděkoval prof. Ing. Petru Dostálovi, CSc. za odborné vedení této práce, dále pak rodině a všem blízkým a to především svojí mamince a přítelkyni, které to po mě musely číst.

OBSAH

ÚVOD.....	5
1 VYMEZENÍ PROBLÉMU A CÍLE PRÁCE	7
1.1 Definice Problému.....	7
1.2 Cíle	7
1.3 Metody.....	8
1.4 Použitá data a vybavení	9
2 TEORETICKÁ VÝCHODISKA.....	10
2.1 Finanční trh.....	10
2.1.1 <i>Peněžní trh</i>	12
2.1.2 <i>Kapitálový trh</i>	12
2.1.3 <i>Trh s cizími měnami</i>	13
2.1.4 <i>Trh drahých kovů</i>	13
2.2 Základní investiční faktory	14
2.2.1 <i>Ziskovost</i>	14
2.2.2 <i>Rizikovost</i>	15
2.2.3 <i>Likvidita</i>	16
2.3 Metody analýz finančního trhu.....	16
2.3.1 <i>Technická analýza</i>	17
2.3.2 <i>Fundamentální analýza</i>	24
2.3.3 <i>Ostatní metody analýzy trhu</i>	25
2.4 MetaTrader 4	25
2.4.1 <i>MetaQuotes Language 4</i>	26
2.5 Umělá inteligence	27
2.5.1 <i>Neuronové sítě</i>	27
2.5.2 <i>Genetické algoritmy</i>	30

3	ANALÝZA SOUČASNÉ SITUACE	32
3.1	Popis Společnosti.....	32
3.2	Predikce kapitálového trhu	32
3.2.1	<i>Přístupy k predikci</i>	33
3.2.2	<i>Použití neuronových sítí na finančních trzích</i>	33
3.3	Automatické obchodní systémy	34
4	NÁVRH ŘEŠENÍ	35
4.1	Predikční model.....	35
4.1.1	<i>Popis postupu řešení</i>	35
4.1.2	<i>Finální řešení</i>	42
4.1.3	<i>Vývoj predikčního modelu</i>	46
4.1.4	<i>Výsledky</i>	51
4.2	Automatický obchodní systém	53
4.2.1	<i>Popis řešení</i>	53
4.2.2	<i>Nastavení</i>	56
4.2.3	<i>Výsledky</i>	57
4.3	Omezení.....	59
	ZÁVĚR.....	60
	SEZNAM ZDROJŮ	62
	Seznam literatury	62
	Seznam Internetových zdrojů	64
	SEZNAM ZKRATEK A SYMBOLŮ.....	66
	SEZNAM OBRÁZKŮ	67
	SEZNAM TABULEK	68
	SEZNAM GRAFŮ	69
	SEZNAM PŘÍLOH	70

ÚVOD

Finanční trhy a především jeden jejich segment - kapitálový trh, který je hlavním předmětem této práce - se mohou na první pohled zdát velmi chaotické, ale pravý opak je pravdou. Trhy jsou velkým souborem vazeb a skutečností, které se vzájemně ovlivňují a jejich chování je sice náhodné a těžko předvídatelné, nikoliv však chaotické. Na trhu působí nespočet vazeb, korelací a dalších pravidel, některé z nich jsou již detailně popsány, některé naopak jen obecně nebo vůbec.

Hlavním cílem této práce je na základě známých pravidel, vazeb a korelací co nejpřesněji předpovědět nejen směr, ale i rozsah pohybu cenové hladiny daného instrumentu a v neposlední řadě také správný okamžik pro vstup do trhu za účelem spekulace na pokles nebo nárůst ceny. Prostředkem pro dosažení uvedeného cíle je model finančního trhu pracující na principu umělé inteligence.

Cílem teoretické části této práce je seznámení s alespoň základní problematikou a pojmy kapitálových a finančních trhů. Tímto problémem se zabývá především kapitola druhá. Je zde popsáno rozčlenění trhů podle jejich podkladového aktiva, dále vymezení pojmu „obchodování“ a základní informace o technické a fundamentální analýze, které jsou ve finančním trhu nepostradatelné. Dále následuje popis programu MetaTrader 4 jako nejpoužívanějšího nástroje pro online vstup do finančního trhu v cílové společnosti. Na závěr kapitoly je popsána problematika umělé inteligence, konkrétně neuronových sítí a genetických algoritmů. Aplikace některého z těchto principů na predikci vývoje kapitálového a finančního trhu je dále hlavním předmětem výzkumu a tvoří praktickou část práce.

V závěru je zhodnocen přínos vytvořeného modelu (neuronové sítě), který je s určitou mírou pravděpodobnosti schopen předpovídat vývoj na kapitálových trzích. Výstupem modelu jsou doporučení pro investora, který se na jejich základě rozhoduje kdy a jak vstoupit do obchodování. Zhodnocení je provedeno na základě vyčíslení zisků a ztrát v případě, že by se investor řídil jen doporučeními, která jsou výstupem predikčního modelu.

Předpověď budoucnosti v tak složitém prostředí jako jsou finanční a kapitálové trhy je velice problematická a proto i model, který by se stoprocentní přesností předpovídal vývoj tak málo deterministického odvětví jako je ekonomika je utopický. Ekonomika reaguje pokaždé jinak i na zprvu stejně vyhlížející události a události v ekonomice se jen málo kdy vyvíjejí přesně tak jako v minulosti. Vzhledem k tomu, že vývoj ceny na finančních trzích je ovlivněn nespočtem různých dat a vstupů, jeví se použití neuronových sítí, které dokážou vzít v potaz

leckdy více informací než lidský mozek, jako velmi příhodné. Tato práce by měla dát odpověď na otázku, zda tomu tak opravdu je a jakým způsobem by mohl být takovýto systém implementován do praxe.

Podstatnou částí práce je predikční model, fungující na principu neuronové sítě a způsob přenesení jeho výstupů ke klientovi. Tento model byl vyvinut ve vývojářském prostředí MATLAB od společnosti MathWorks, Inc. a k přenesení výstupních dat ke klientovi bylo použito programu MetaTrader 4 od společnosti MetaQuotes Software Corp. Výstupy z predikčního modelu však nelze vždy považovat za jednoznačná investiční rozhodnutí a každý investor by měl dle svého vlastního uvážení vstupovat či nevstupovat do finančního trhu. Predikční model slouží pouze jako jedna z alternativ pro analýzu možného budoucího vývoje trhu.

Například v aktuální ekonomické situaci je na trhu vidět velký trend snižování úrokových sazeb až do záporných hodnot a tisknutí velkých objemů nových peněz, za které centrální banky nakupují státní dluhopisy a to především v rozvinutých asijských zemích a Evropě. Naopak americká ekonomika vypadá uzdraveně po dlouho trvající finanční krizi a the Federal Reserve Systém (FED) vstoupil do éry zvyšování úrokových sazeb. I přes tyto silné fundamentální zprávy není vývoj hlavního a nejobchodovanějšího měnového páru tak jednoznačný, jak by se mohlo zdát. Tím lze ilustrovat fakt, že finanční a kapitálové trhy se leckdy chovají velmi iracionálně. V dobách kdy na trhy působí tak silný fundament, jako jsou u finančních trhů intervence centrálních bank nebo zveřejnění důležitých makrodat a u kapitálových trhů zveřejnění ročních výsledků hospodaření emitenta daného cenného papíru, stává se jakýkoli predikční model a tedy i ten, který je hlavním předmětem této práce, zcela bezcenným a jeho výstupy by měly být investorem ignorovány.

1 VYMEZENÍ PROBLÉMU A CÍLE PRÁCE

V této kapitole jsou stanoveny cíle výzkumné části této práce, které vyplývají především ze stávajícího způsobu obchodování na finančních a kapitálových trzích a problémů s ním spojených. Následně jsou popsány metody a nástroje, kterými lze přispět ke zlepšení stávající situace.

1.1 DEFINICE PROBLÉMU

Hlavním problémem společnosti Goldenburg Group LTD jsou požadavky klientů, kteří nemají čas nebo zájem zabývat se problematikou finančního trhu, ale zároveň by chtěli tímto způsobem zhodnocovat svůj kapitál. Společnost se dostala do stavu, kdy většina její konkurence začala nabízet automatické obchodní systémy fungující v programu MetaTrader 4 a zadávající do trhu pokyny na základě vyhodnocení technické a statistické analýzy trhu. Společnost nyní stojí před uskutečněním dvou zásadních rozhodnutí, jestli vůbec nabízet prostředky k automatickému obchodování a jestli ano, tak jaké.

- Jestliže společnost nepřijde s možností automatického obchodování, mohla by při stávajícím trendu na trhu přijít o řadu klientů, kteří by využili této možnosti u některého z konkurentů. Pokud by se naopak rozhodla přidat do svého portfolia služeb takovýto produkt, riskuje nemalé náklady na vývoj automatického obchodování, který nemusí být vždy úspěšný nebo nemusí být kladně přijat investory (klienty).
- Druhé rozhodnutí spočívá ve způsobu jak zajistit automatické obchodování, pakliže se firma rozhodne jej nabízet. Konkurence v České republice nabízí především různé automatické obchodní systémy, které běží jako skripty v programu MetaTrader 4 a snaží se najít ideální chvíli pro vstup do trhu. Tady lze vidět příležitost pro využití umělé inteligence, která by mohla být užitečným nástrojem k technické analýze na zcela odlišném principu, než používá současná konkurence.

1.2 CÍLE

Cílem této práce je navrhnout model, který bude s určitou pravděpodobností předpovídat vývoj finančního trhu a tím sníží riziko vstupu na trh a zároveň bude přijatelnou alternativou pro společnost Goldenburg Group LTD., jak se začít rozvíjet a angažovat na poli

využití umělé inteligence v tomto prostředí. Dalším neméně důležitým cílem je zprostředkovat výsledek technické analýzy, provedené pomocí umělé inteligence, klientovi a zajistit její exekuci v trhu.

Prvního cíle se tento výzkum bude snažit dosáhnout pomocí umělých neuronových sítí, které jsou k predikci časové řady s mnoha vstupy vhodné. Práce by měla poskytnout odpověď na otázku, jestli tento předpoklad platí také pro predikci finančního trhu.

Druhého cíle by pak mělo být dosaženo pomocí Internetu a krátkého automatického obchodního systému v programu MeteTrader 4, jehož hlavním vstupem by měl být výstup z umělé neuronové sítě, který predikuje vývoj ceny daného instrumentu pro následující den. Tento systém by měl zajistit exekuci pokynů v trhu a nastavení rizikovosti.

Obě dvě části řešení musejí být použitelné v reálném prostředí finančního trhu. Druhá část musí být zároveň nenáročná na hardware a musí být uživatelsky přátelská, jelikož je velmi pravděpodobné, že ne každý klient bude disponovat nejnovější výpočetní technikou a programovacími dovednostmi.

1.3 METODY

V obou dvou částech, jak teoretické tak praktické, této práce budou shromážděny a popsány nejdůležitější poznatky z implementace umělé inteligence na finančním trhu. Především poznatky, které se v první řadě zabývají predikcí časových řad pomocí neuronových sítí.

V první části práce jsou též uvedeny obecné informace o fungování finančního trhu, se kterými by měl být seznámen každý, kdo uvažuje o vstupu do finančního trhu. Zde je pojednáno především o tom, co to finanční trh je, o náležitostech a možnostech jeho analýzy a o prostředcích které budou v druhé části použity pro dosažení hlavních cílů této práce.

Druhá část je věnována vývoji predikčního modelu a přenesení jeho výstupů k investorovi. Je zde porovnáváno několik predikčních modelů s různou vnitřní strukturou, různými vstupy a parametry. Modely jsou porovnávány na základě své procentuální úspěšnosti predikce a také na základě ziskovosti za předpokladu že by byly nasazeny do reálného provozu. Přičemž za nejdůležitější ukazatel je považována úspěšnost predikčního modelu, neboli s jakou pravděpodobností je model schopen předpovědět, zda následující obchodní den bude cena daného instrumentu růst či klesat. Druhým kritériem je ziskovost, neboli kolik by investor vydělal, respektive prodělal, pokud by se řídil pouze doporučeními predikčního modelu.

Na základě porovnání těchto dvou kritérií bude vybrán nejlepší model. Model je testován na americkém akciovém indexu S&P 500, jeho nasazení je možné i na další světové indexy jako je DAX, FTSE 100 nebo NIKKEI 225, ale jeho výsledky se mohou lišit.

1.4 POUŽITÁ DATA A VYBAVENÍ

Veškerá historická data, která byla použita v predikčním modelu, pocházejí ze serveru Yahoo! Finance [36], který nabízí denní historická data zdarma. Jelikož jsou tato data dostupná v požadované kvalitě i rozsahu, nebylo potřeba využívat služby jiného placeného serveru. V případě, že by došlo k rozšíření modelu i na měnové páry, bylo by již potřeba využít placených služeb, jelikož tato data Yahoo! ani jiný neplacený server nenabízí.

Predikční model byl vytvořen v prostředí programu MATLAB od společnosti The MathWorks Inc., protože tento program nabízí několik vestavěných funkcí pro tvorbu a práci s umělou inteligencí a především s neuronovými sítěmi. MATLAB je též považován za jeden z nejvyužívanějších programů pro náročné výpočetní úkoly. Pro řešení problému u investorů byl použit program MetaTrader 4 od společnosti MetaQuotes Software Corp. a to z důvodu jeho rozšířenosti, uživatelské přívětivosti, nízkých nároků na hardware a v neposlední řadě i jeho využitím ve společnosti Goldenburg Groupe LTD.. Tento program je volně ke stažení na stránkách společnosti [34].

Pro práci byly využity především tyto MATLAB toolboxes:

- Data Feed Toolbox
- Financial Toolbox
- Neural Network Toolbox

Pro účely této práce bylo využito nekomerční licence programu MATLAB na Vysokém učení technickém v Brně.

2 TEORETICKÁ VÝCHODISKA

Teoretická východiska této práce jsou zaměřena především na popis finančního a kapitálového trhu a možnosti využití umělé inteligence, zastoupené neuronovými sítěmi v programu MATLAB. První část se zabývá náležitostmi trhu a základním všeobecně uznávaným pravidlům při vstupu do trhu, jako jsou fundamentální a technická analýza, money management apod. Druhá část je pak zaměřena především na popis umělé inteligence, kterou je možné využít k predikci vývoje kapitálového a finančního trhu. Konkrétně se jedná o využití algoritmu neuronové sítě v prostředí MATLAB.


2.1 FINANČNÍ TRH

Úvodem je třeba definovat, co je to finanční trh a k čemu slouží. Nezpochybnitelnou autoritou, co se finančního trhu týče, je v České republice Česká národní banka (ČNB), která provádí regulaci a dohled nad finančním trhem a subjekty na něm působícím.

Podle České národní banky je finanční trh definován jako složenina ze dvou hlavních organicky na sebe navazujících trhů: peněžního trhu a kapitálového trhu, které se bezprostředně ovlivňují a vzájemně doplňují. [27] Detailněji je o těchto dvou segmentech finančního trhu pojednáno níže v kapitole 2.1.1 a 2.1.2.


Jiná definice [7] uvádí, že finanční trh je: „Složitý systém ekonomických vztahů a institucí, které zprostředkují soustřeďování, rozmisťování a přerozdělování uvolněných peněžních prostředků na základě nabídky a poptávky.“

Podle [17] se finanční trh nejčastěji člení na čtyři různé trhy podle jednotlivých druhů finančních instrumentů, které se na dílčích segmentech finančního trhu obchodují. Za hlavní jsou pak považovány trhy peněžní a kapitálový a vedlejší poněkud specifické trhy s cizími měnami a drahých kovů (viz obrázek 2.1.1-1). Peněžní a kapitálový trh je dále možné dělit na trhy krátkodobých úvěrů a krátkodobých cenných papírů a trhy dlouhodobých cenných papírů a dlouhodobých úvěrů (viz obrázek 2.1.1-1).



Obrázek 2.1.1-1: Finanční trh [17], str. 54

Nepostradatelnou částí finančního trhu je trh cenných papírů. Česká legislativa v novém občanském zákoníku definuje cenný papír následovně: „Cenný papír je listina, se kterou je právo spojeno takovým způsobem, že je po vydání cenného papíru nelze bez této listiny uplatnit ani převést“. [16] Trh cenných papírů se skládá z krátkodobých cenných papírů trhu peněžního a dlouhodobých cenných papírů trhu kapitálového, slouží k uspokojení nabídky a poptávky po finančních prostředcích a to jak v krátkodobém tak dlouhodobém časovém horizontu. Nejčastěji používané členění trhu cenných papírů je následující (viz Obrázek 2.1.1-2): [17]



Obrázek 2.1.1-2: Trh cenných papírů [17], str. 58

Rozdělení trhu s cennými papíry krátkodobými i dlouhodobými, dle toho jestli cenný papír na trh vstupuje poprvé nebo se na něm už nějakou dobu obchoduje, dělí trh na primární a

sekundární (viz Obrázek 2.2). Funkce primární trh je získání nových finančních prostředků pro emitenta cenných papírů a jejich přeměna na dlouhodobé zdroje především pro financování investic. Primární trh je se sekundárním úzce provázán, úspěšnost primárního úpisu je totiž závislá na likviditě cenných papírů na sekundárním trhu. Na sekundárních trzích jsou pak obchodovány již dříve emitované cenné papíry a jeho funkce spočívá ve stanovení jejich tržní ceny a zajišťování jejich likvidity. [17]

Trhy jak sekundární tak primární jsou dále nejčastěji děleny podle typu odchodů, které na nich probíhají a to na trhy veřejné a neveřejné (viz Obrázek 2.2). Na veřejných trzích se mohou obchodování zúčastnit všichni potencionální investoři, a proto jsou cenné papíry na těchto trzích obvykle obchodovány za nejvyšší nabídnutou cenu. Kdežto na trzích neveřejných jsou cenné papíry nabídnuty pouze jednomu nebo několika investorům zároveň a to na základě předem dohodnutých podmínek, tzv. smluvní obchody. [17]

2.1.1 Peněžní trh

Peněžní trh je charakteristický krátkodobostí obchodů na něm uzavíraných. Na tomto trhu se setkávají subjekty s přechodným přebytkem peněžních prostředků, se subjekty které tyto prostředky poptávají. Finanční nástroje obchodované na peněžním trhu se vyznačují především krátkou dobou jejich splatnosti a to zpravidla do jednoho roku. [17]

Finanční nástroje obchodované na trhu lze rozdělit na krátkodobé úvěry a krátkodobé cenné papíry (viz obrázek 2.1). [17] Trh krátkodobých úvěrů je jedním ze segmentů peněžního trhu. Nejčastěji jsou na tomto trhu poskytovány krátkodobé úvěry obchodními bankami a jinými licencovanými finančními institucemi, pochopitelně též krátkodobé vklady u bank a institucí spadají do této kategorie. Dále sem spadají obchodní úvěry, které si poskytují jednotlivé podnikatelské subjekty mezi sebou - tyto úvěry nejčastěji souvisejí s dodávkami zboží nebo služeb - a též úvěry a vklady obchodních bank u centrální banky[17]. Na trhu krátkodobých cenných papírů jsou většinou obchodovány abstraktní finanční instrumenty, které nejsou svázány se závazkem, ke kterému byly vydány. Proto je možné je dobře standardizovat a jednoduše obchodovat. Krátkodobé cenné papíry jsou především směnky, depozitní certifikáty a pokladní poukázky. [25]

2.1.2 Kapitálový trh

Kapitálový trh je typický dlouhodobostí finančních investičních instrumentů na něm obchodovaných. Prostřednictvím kapitálového trhu jsou poskytovány dlouhodobé úvěry a jsou

zde obchodovány dlouhodobé cenné papíry. Instrumenty zde obchodované se díky své dlouhodobosti vyznačují vyšší rizikovostí, která je na druhou stranu vyvážena vyšší výnosností. V porovnání s peněžním trhem jsou investice probíhající na trhu kapitálovém zpravidla podstatně rozsáhlejší co do objemu investovaných peněžních prostředků. [17]

Na trhu dlouhodobých úvěrů je nejčastěji nabízející stranou banka a poptávající je většinou povinen ručit reálným majetkem, zpravidla nemovitostí. Dále sem pochopitelně spadají i dlouhodobé vklady s dobou splatnosti delší než jeden rok. [17]

Trh dlouhodobých cenných papírů zahrnuje především obchodování s akcemi a dlouhodobými dluhopisy. Proto bývá tento trh také často nazýván „trhem cenných papírů“. Významnou předností tohoto trhu oproti trhu dlouhodobých úvěrů je, že finanční instrumenty obchodované na tomto trhu jsou převoditelné, tzn. jejich vlastnické právo může změnit majitele. Tento fakt významně přispívá k likvidnosti těchto instrumentů. Dále je také možné snížit rizikovost držby akcií nebo dluhopisů pomocí diverzifikace portfolia, neboli rozložení investora kapitálu do akcií a dluhopisů od různých upisovatelů. [17]

2.1.3 Trh s cizími měnami

Trh s cizími měnami je segmentován na devizový (bezhotovostní) trh a valutový (hotovostní) trh. [17] Na trh s bezhotovostními formami cizích měn dochází ke vzájemnému směňování různých konvertibilních měn a tím dochází i k tvorbě jejich kurzu. Tyto velkoobchodní transakce jsou nejčastěji prováděny obchodními bankami, centrálními bankami, investičními fondy a tzv. brokery a skrze tzv. termínové devizové kontrakty typu futures a kontrakty opční. [17] Na trzích valutových jsou obchodovány papírové peníze a mince za tzv. valutové kurzy, které se mohou od kurzů devizových drobně lišit, ale jsou jimi určovány. Trhy s hotovostí mají spíš maloobchodní význam nikoliv kurzotvorný.

2.1.4 Trh drahých kovů

Na trzích drahých kovů je nejčastěji obchodováno zlato, stříbro, platina a palladium. [17] Dle české legislativy se mezi drahé kovy řadí také iridium, rhodium, ruthenium a osmium. [25] Co se týče obchodování s nejvýznamnějším drahým kovem, kterým je zlato, lze ho

obchodovat ve formě fyzické, nebo přes CFD¹. K největším objemům obchodů s fyzickým zlatem dochází v Londýně, stejně tak i se stříbrem. [17]

2.2 ZÁKLADNÍ INVESTIČNÍ FAKTORY

Investor musí vždy pečlivě zvážit tři základní faktory investiční příležitosti: ziskovost, rizikovost a likviditu, které není schopen nijak ovlivňovat. [17] Tato kapitola je věnována krátkému popisu těchto faktorů a jejich dopadu na posouzení investice. Jejich definice je důležitá pro následné posouzení automatického obchodního modelu, který je hlavním předmětem této práce.

2.2.1 Ziskovost

Jedním z hlavních faktorů finanční investice je ziskovost. Ziskovost udává míru zhodnocení finančních prostředků vložených do určitého finančního instrumentu, nebo do portfolia těchto instrumentů, za určité časové období. [17]

Existují dvě hlavní skupiny metod pro určení ziskovosti investice a to metody statické a metody dynamické. Statické metody výpočtu výnosnosti investic nezahrnují hledisko působení času, proto jsou tyto metody vhodné především pro hodnocení investic, u kterých není časové hledisko důležité. V případech krátkodobých investic do nástrojů peněžního trhu jsou zpravidla používány jen tehdy, jde-li o předběžné propočty pro posouzení a srovnání několika investičních příležitostí. Na druhé straně metody dynamické jsou používány v případech, kdy čas a výše úrokové míry v době trvání investice hrají důležitou roli. Tyto metody jsou pak používány při hodnocení dlouhodobých investic a v dobách vysokých úrokových sazeb. [17]

Další možností jak klasifikovat míru výnosnosti investice, je fakt jestli je nebo není třeba investici očistit o náklady s ní spojenými a to především o daň. Výpočet čistých výnosů z investice, tzn. očištěné o daň, může být velmi komplikovaný. Tento výpočet záleží především na legislativní úpravě daného státu, typu příjmu, typu subjektu, který příjem vykazuje (právnícká nebo fyzická osoba), smlouvách o mezinárodním zdanění, atd. [17].

Protože se tato práce zbývá hlavně krátkodobými investicemi, budou pro výpočet ziskovosti použity převážně metody statické. Pro zjednodušení budou všechny zisky z investic

¹ CFD je zkratka „contract of difference“ rozdílový kontrakt neboli rozdílové vypořádání prostřednictvím hotovostních plateb, a nikoli dodáním fyzického zboží nebo cenných papírů. [31]

vyjádřeny v hrubém výnosu (před daní), bude započítán pouze poplatek obchodníkovi s cennými papíry. Pro účely této práce je vyjádření ziskovosti před daní postačující, vyjádření bude sloužit především pro porovnání s jinými investičními příležitostmi a proto je důležité započítat poplatky spojené s exekucí investice.

2.2.2 Rizikovost

Rizikovost může být vyjádřena jako stupeň nejistoty spojený s budoucím očekávaným výnosem nebo ztrátou a to jak dividend, tak kapitálových plateb. [19] Existuje mnoho rizik spojených s investicemi na kapitálových trzích. Ta nejčastější jsou podle [17] tato:

- Riziko změny úrokových sazeb
- Riziko inflační
- Riziko událostí
- Riziko úpadku
- Riziko ztráty likvidity
- Riziko měnové
- A další

Veškeré výše zmíněné druhy rizik sebou nesou nespočet různých poddruhů s vlastními specifiky. Podstoupení jednotlivých rizik a jejich vah, musí být investorem důkladně zváženo před vstupem do finančního trhu. Posouzení je subjektivní a záleží jen na investorovi, jaké riziko je schopen akceptovat. [10] Proto je riziko v této práci a hlavně v automatickém obchodním modelu v praktické části práce zohledněno a je také možné jej upravovat dle požadavku investora, ovšem jen do určité míry.

Jedno z nejpoužívanějších vyjádření rizikovosti investice je použití směrodatné odchylky od očekávané míry výnosu. Toto vyjádření lze použít pouze tehdy, je-li k dispozici dostatečné množství vhodných statistických dat. [17][19] „... nestačí pouze určit očekávanou výnosnost zvažované investice, ale zároveň i to, jak se od ní mohou skutečné dosažené výnosnosti odchýlovat.“ [17] str. 187

Směrodatná odchylka nebo také výběrový rozptyl je kvadratický průměr odchylek hodnot znaku od jejich aritmetického průměru [12]

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}),$$

pak

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})},$$

kde σ je směrodatná odchylka,

X_i je historická cena,

$\bar{X}$ je výběrový průměr,

n je počet prvků výběru.

Čím vyšší je směrodatná odchylka, tím vyšší je nejistota dosažení požadované výnosnosti, takže držba finančního instrumentu s vyšší spočtenou směrodatnou odchylkou je rizikovější než držba instrumentů s odchylkou nižší. Vzhledem ke skutečnosti, že většina investorů má vysokou averzi k riziku (zvláště na českém trhu), bude při jinak nezměněných podmínkách platit, že poroste-li rizikovost instrumentu, pak bude klesat poptávka po něm a naopak. [17]

2.2.3 Likvidita

Třetím důležitým rozhodovacím kritériem je likvidita. Podle ČNB je likvidita investičního instrumentu definována jako schopnost přeměny na finanční hotovost při vynaložení minimálních časových a finančních prostředků. [29]

Na likviditu finančních instrumentů působí mnoho různých faktorů, nejvýznamnějším z nich je agregátní poptávka, která ovlivňuje téměř všechny instrumenty obchodované na daném trhu. [17] Agregátní poptávka je součtem všech poptávek v trhu působících a to především domácností, firem, státu, dovozců a vývozců. [7] Pakliže agregátní poptávka v daném trhu roste, roste s ní i likvidita všech finančních instrumentů obchodovaných na tomto trhu a naopak. Veškeré instrumenty s klesající likviditou ztrácejí svoji hodnotu. Z toho vyplývá, že dojde-li ke kolapsu trhu, nebo ztratí-li se z trhu veškerá likvidita, doplatí na to vždy investoři, nikoli skuteční majitelé trhu. [17]

2.3 METODY ANALÝZ FINANČNÍHO TRHU


Následující kapitola je zaměřena na dvě nejdůležitější skupiny analýz trhu, a to analýzy typu technického a analýzy typu fundamentálního.

Technická analýza se zabývá historickým vývojem ceny daného instrumentu, kdežto fundamentální zkoumá jak vnitřní tak vnější okolí subjektu, který má největší vliv na vývoj ceny instrumentu (u akcií je to emitent, u měn stát) a zkoumá především možné události, jak minulé tak budoucí, které emitenta nebo stát ovlivňují. [32]

2.3.1 Technická analýza

Technická analýza je předpovídání budoucích pohybů finančních trhů na základě zkoumání minulých cenových pohybů. Stejně jako u předpovědi počasí, technická analýza není absolutní předpověď budoucnosti. Technická analýza může pomoci investorům předvídat, co je "pravděpodobné", jakým směrem by se ceny mohly ubírat v průběhu času. Technická analýza využívá širokou škálu grafů, které ukazují vývoj ceny i ve vzdálené minulosti. Technická analýza se používá pro akcie, indexy, komodity, futures nebo jakékoli obchodovatelné nástroje, u nichž je cena ovlivňována nabídkou a poptávkou. Cena se vztahuje na jakoukoli kombinaci open, high, low nebo close pro daný cenný papír v určitém časovém horizontu. [16]

Velmi často používaný a vhodný graf pro zaznamenání minulého vývoje ceny je tzv. svíčkový graf, kde každá jedna „svíčka“ představuje zvolený časový úsek, např.: 1 hodinu aj. Každá svíčka se skládá z vrchního a spodního knotu a těla svíčky, jak je popsáno na Obrázku 2.3.1-1. Vrchní a spodní knot zachycuje, kde byla cena za zvolený časový úsek nejvýše tzv. high respektive nejnižší tzv. low. Tělo svíce je ohraničeno dvěma cenami, cenou otevírací (open), která zaznamenává, kde byla cenová hladina při začátku zvoleného období a cenou zavírací (close), kde se cena nacházela při konci časového období. V trhu lze rozlišit dva základní typy svící, svíce klesající, jejichž otevírací cena je více než cena zavírací a svíce stoupající, pro které platí opak. [32]




Obrázek 2.3.1-1: Svíčkový graf [32]

Dowova teorie

Dowova teorie (Dow theory) je historicky první ucelenou teorií, která se zabývá problematikou určování vývojů a trendů na globálních akciových trzích. Teorie je pojmenována podle Charlese H. Dowa, jenž se podílel největší mírou na jejím vytvoření. Dnes je již teorie v mnoha ohledech překonaná, ale přesto platí až doposud mezi nejznámější a nejuznávanější teorie tohoto druhu. [17]

Dowova teorie je založena na poznatku, že vývoj ceny většiny akcií se pohybuje se sentimentem celého akciového trhu. Z tohoto poznatku vyplývá, že nejdůležitějším předpokladem úspěšného investování na akciovém trhu je určení správného trendu trhu. Dění na akciových trzích a především na akciových indexech odráží chování investorů prostřednictvím agregátní nabídky a poptávky. Investoři ovlivňují kurz akcií příkazy jdoucími do trhu (nákup/prodej). Charles Dow pro sledování celkového sentimentu vytvořil dva historicky první akciové indexy (soubory akcií) a to „Dow Jones Industrial Average“ a „Dow Jones Transportation Average“. Oba tyto indexy existují na New Yorkské burze NYSE dodnes, ale změnilo se jejich složení. [32]

Určení trendu dle Dowovi teorie je zobrazeno na Obrázku 2.3.1-2, dále Dowova teorie rozlišuje hned několik typů trendu a dělí je podle délky jejich trvání a podle směru vývoje. [18]



Obrázek 2.3.1-2: Dowova teorie určení trendu [32]

Trendy dle délky trvání jsou

- primární trendy,
- sekundární trendy,
- terciální trendy.

Trendy dle směru vývoje jsou

- rostoucí (býčí) trh,
- klesající (medvědí) trh,
- postranní trh.


Dowova teorie byla v době svého vzniku cílena hlavně na dlouhodobé investiční příležitosti. Dnes je již známo, že využívání technické analýzy a trendu je možné i v krátkodobém intradenním horizontu. [32]

Teorie Elliotových vln

Zakladatel Ralph Nelson Elliott vycházel z Dowonovi teorie a zabýval se hlavně indikací a predikcí trendů akciových indexů. [17]

Teorie Elliottových vln (Elliott Wave theory) je podrobný popis toho, jak se chovají skupiny investorů. Základním funkční smysl této teorie je, že na trhu dochází v přirozeném sledu ke změnám nálad investorů od pesimismu k optimismu a zpět a tím vytvářejí v trhu konkrétní a měřitelné vzory. Tyto změny nálad a jejich vyjádření pomocí nákupu a prodeje pak vede k cenovým pohybům v trhu. Pokud je možné identifikovat opakující se vzory v cenových hladinách a zjistit, kde se trh v danou chvíli nachází, usnadňuje to pomocí opakujících se vzorů, předpovídat směr následujícího pohybu ceny. [30]

Ellittova teorie pracuje se stále se opakujícími vlnovými formacemi, nejdůležitější jsou vlny impulsu a korekce, které se dají dále rozkládat do dalších tzv. „podvln“. Podle teorie se „impulsivní vlny“ skládají vždy z pěti hlavních vln a „korekční vlny“ ze tří, jak je vidět na Obrázku 2.3.1-3.




Obrázek 2.3.1-3: Rozklad Elliottových vln [30]

Z Elliottovy teorie vzešlo mnoho dnes již standardně používaných ukazatelů technické analýzy, mezi ty nejznámější patří Fibonacciho metody. Tato teorie má mnoho zastánců i odpůrců, ale s rozvojem výpočetní techniky byly Elliottovy závěry částečně potvrzeny. [17]


Grafická analýza

Cenová hladina podpory a odporu (support and resistance level) je taková cenová hladina, kterou většina účastníků trhu v danou chvíli považuje za maximální nebo minimální a proto se od ní kurz odráží směrem dolů nebo nahoru jak je vidět na Obrázku 2.3.1-4. Podpora i odpor jsou v trhu dočasné, dříve nebo později dojde k jejich proražení a tím, buď k znehodnocení, nebo otočení jejich funkce. Z podpory se stane odpor a naopak. Křivka na Obrázku 2.3.1.4 (i všech následujících v této kapitole) vyjadřuje vývoj ceny v čase. [17]




Obrázek 2.3.1-4: Podpora a odpor [22]

Trendová linie představuje v trhu spojnici dvou nebo více minim při býčím trhu a maxim při trhu medvědí viz následující Obrázek 2.3.1-5. Stejně jako u hladin podpory a odporu dochází k jejich proražení, které může značit otočení trendu trhu, z býčího na medvědí a naopak. [22]




Obrázek 2.3.1-5: Trendové linie [22]

Trendový kanál je charakterizován jako rovnoběžné pásmo, v němž tržní cena určitou dobu osciluje. Kanál se skládá z klesající nebo rostoucí trendové linie a linie návratu, která vrací cenu zpět k trendové linii jak je vidět na Obrázku 2.3.1-6. [17]



Obrázek 2.3.1-6: Trendové kanály [22]


Formace hlava a ramena představuje speciální formaci vrchu a dna, přičemž stěžejní je tzv. krční linka, která spojuje obě ramena, jak je vidět na Obrázku 2.3.1-7, a teprve po jejím prozažení směrem dolů respektive nahoru, lze formaci považovat za dokončenou. Tato formace je jednou z nejsilnějších formací značících otočení trendu z trhu z býčího na medvědí a naopak. Přerušovaná čára v Obrázku 2.3.1-7 (i všech následujících) vyjadřuje objem obchodů. [17]



Obrázek 2.3.1-7: Hlava a ramena [22]


Formace dvojitého vrcholu respektive dna je velmi silnou reverzní formací a v trhu se vyskytuje mnohem méně často než jednoduchý vrchol. O to silnější je její reverzní signál. Formace se vyznačuje dvěma vrcholy respektive dny, jejichž výška je stejná viz Obrázek 2.3.1-8. Tyto vrcholy musí být dostatečně časově vzdáleny, jinak hrozí záměna s jinou formací - konsolidační. [17]

Formace trojitého vrcholu respektive dna je velmi obdobná výše uvedené. Její výskyt je však mnohem vzácnější a signál k reverzi silnější. [17]




Obrázek 2.3.1-8: Dvojitý a trojitý vrchol a dno [22]

Formace vzestupného a sestupného trojúhelníku se vyznačuje oscilací cenové hladiny mezi vodorovnou hladinou odporu respektive podpory a stoupající respektive klesající trendovou linií, jak je uvedeno na Obrázku 2.3.1-9. Po proražení vodorovné hladiny dochází většinou k impulsivnímu nárůstu respektive poklesu ceny. [17]



Obrázek 2.3.1-9: Vzestupný a sestupný trojúhelník [22]

Vlajková formace představuje dočasné pozastavení silného růstu respektive poklesu. Cena osciluje v rostoucím či klesajícím kanálu a mírně koriguje, načež pokračuje v impulsivním růstu či poklesu, jak je zřejmé z Obrázku 2.3.1-10. Tato formace se nejčastěji vyskytuje v prudkém růstovém nebo klesajícím trendu a signalizuje, že tento trend je zhruba ve své polovině. [17]



Obrázek 2.3.1-10: Rostoucí a klesající vlajka [22]

Ve finančním trhu lze najít i mnoho dalších formací technické analýzy, pro tuto práci byly vybrány pouze tyto, více o nich pojednává [17] v kapitole 6.

2.3.2 Fundamentální analýza

Fundamentální analýza spočívá ve zkoumání podkladových sil, které mají vliv na blahobyt ekonomiky, průmyslových skupin a společností. Stejně jako u technické analýzy je jejím cílem odvodit prognózu a zisk z budoucích cenových pohybů. Na podnikové úrovni, fundamentální analýza může zahrnovat přezkoumání finančních dat, řízení, obchodní koncepce a hospodářské soutěže. Na úrovni průmyslu, by se mělo jednat o přezkoumání nabídkových a poptávkových sil u nabízených produktů. Pro národní hospodářství by se měla fundamentální analýza zaměřit na ekonomické údaje k posouzení současného a budoucího růstu ekonomiky. Předvídat budoucí ceny akcií fundamentální analýzou v sobě spojuje hospodářskou, průmyslovou a firemní analýzu. Podstatou je odvodit současnou reálnou hodnotu akcie či podkladového aktiva a předpovědět hodnotu budoucí. Pokud reálná hodnota není rovna současné ceně akcie, fundamentální analýza dává odpověď, jestli je instrument podhodnocený či nadhodnocený vzhledem k reálné tržní ceně. Následně fundamentalisté předpokládají, že vývoj ceny povede k jimi zjištěné reálné ceně instrumentu. [32]

Globální (makroekonomická) analýza

Globální analýza by měla odpovídat na míru stability a zdraví makroekonomického okolí emitenta. Z hlediska globálního (makroekonomického) ovlivňuje budoucí cenu a její vývoj na trhu celá řada faktorů, z nichž za ty nejpodstatnější jsou považovány následující: [17]

- reálný výstup ekonomiky,
- fiskální politika,
- peněžní nabídka,

- úrokové sazby,
- inflace,
- příliv respektive odliv zahraničního kapitálu,
- kvalita investičního prostředí.

Odvětvová (oborová) analýza

Odvětvová analýza má za úkol analyzovat mikroekonomické okolí emitenta cenných papírů. Provádí se z důvodů, že ne všechny odvětví jsou stejně citlivá na vývoj ekonomiky. Tato analýza se zaměřuje především na identifikaci charakteristických znaků jednotlivých odvětví a to především na jejich rizikovost a ziskovost. Za nejvýznamnější faktory jsou všeobecně považovány tyto: [17]

- citlivost odvětví na hospodářský cyklus,
- tržní struktura odvětví,
- způsoby statní regulace v odvětví,
- perspektivy budoucího vývoje odvětví.

2.3.3 Ostatní metody analýzy trhu

Existuje mnoho dalších metod analýzy trhu, které popisuje literatura. Od teorie psychologické analýzy [17], nebo statistického přístupu [9] až po sofistikované metody, které byly vyvinuty na základě informačních technologií. Různé podoby umělých inteligencí, jako jsou neuronové sítě, jsou jedny z nejširších a nejrychleji se rozvíjejících v oboru metod analýzy trhu. [1]


2.4 METATRADER 4

MetaTrader 4 (MT4) je jedna z velmi populárních a hojně užívaných obchodních platform. MT4 nabízí jednu z velmi dobrých obchodních a analytických technologií plus další služby. Platformu vyvíjí a provozuje společnost MetaQuotes Software Corp. se sídlem v Limassolu na Kypru. Platformu používá více než 750 brokerských společností a bank, které na ní obchodují s několika miliony investory. [35]

Brokerské společnosti jsou schopny si platformu MT4 přizpůsobit pro své vlastní specifické požadavky, proto má každá z těchto společností svůj vlastní přizpůsobený MetaTrade. [35]

Společnost MetaQuotes Software Corp. dále nabízí hned několik přidružených programů, které mohou, ale nemusí, být využívány brokerskými společnostmi a bankami ke správě a vedení investorů vstupujících do finančního trhu skrze jejich platformu. [35]

Na Obrázku 2.3.3-1 je zobrazeno celé produktové portfolio společnosti.



Obrázek 2.3.3-1: Portfolio MetaQuotes Software Corp. [35]

2.4.1 MetaQuotes Language 4

MetaQuotes Language 4 (MQL4) je vestavěný programovací jazyk pro programování obchodních strategií. Tento jazyk byl vyvinut MetaQuotes Software Corp. na základě jiného programovacího jazyka a to C++ a byl přizpůsoben pro internetové obchodní platformy. Použitím tohoto jazyka, lze vytvořit vlastní odborný systém, který automatizuje různé obchodní strategie. Kromě toho, lze pomocí MQL4 vytvořit vlastní technické indikátory, skripty a knihovny. [35]

MQL4 obsahuje velké množství vestavěných funkcí a základních indikátorů pro správu a exekuci obchodních příkazů. MetaEditor je vestavěný textový editor v platformě MT4, který je navržen speciálně pro psaní programového kódu v jazyce MQL4. MetaEditor pomáhá

uživatelům se poměrně snadno orientovat v programovém kódu automatického obchodního systému. [33]

Programy napsané v MQL 4 mají různé funkce a cíle, nejčastěji jsou to tyto:

- automatické obchodní systémy,
- indikátory,
- skripty,
- knihovny,
- zahrnující soubory [33].

2.5 UMĚLÁ INTELIGENCE

Obor umělé inteligence není lehké jednoduše popsat. Několik autorů uvádí různé pohledy na věc a různý výklad tohoto slovního spojení.

Podle české literatury, konkrétně podle Kotka [11] je umělá inteligence vlastnost uměle vytvořených systémů se schopností rozpoznávat předměty, jevy a situace, analyzovat vztahy mezi nimi a na základě těchto poznatků přijímat účelná rozhodnutí a objevovat nové zákonitosti. Podle jiné zahraniční literatury a to podle Munakata [13] je umělá inteligence věda zkoumající programy, které jsou schopné dělat věci, ke kterým lidé potřebují používat inteligenci. Existuje mnoho definic pojmu umělá inteligence, dvě výše vybrané k popisu problému používají rozdílné názory. První klade důraz na podstatu, že výstupy umělé inteligence musejí přinášet nové poznatky, druhý pak na srovnání umělé inteligence s myšlením člověka.

Vývoj umělé inteligence začal v 50. letech minulého století a dodnes prostupuje mnoha odvětvími lidské činnosti. Největší rozmach této vědy přišel po roce 1990 v Japonsku, kde došlo k jejímu nasazení do reálného provozu hned v několika odvětvích. [13]

V této práci jsou popsány dva typy umělé inteligence a to neuronové sítě a genetické algoritmy, v dnešní době existuje již mnoho dalších typů, více uvádí Dostál [5].


2.5.1 Neuronové sítě

Neuronové sítě jsou metody umělé inteligence, které jsou silně inspirovány přírodou a fungováním živých organismů. Umělé neuronové sítě by měly být určitým modelem, který simuluje myšlení lidského mozku. Podobně jako lidský mozek, fungují neuronové sítě na

principu neuronů, které jsou organizovány ve vrstvách a propojeny odkazy. Neurony mezi sebou šíří informace a na základě vah je upravují. [13]


Umělá neuronová síť funguje na principu tzv. „black boxu“, neboli černé skříňky. To znamená, že nikdy není možno přesně určit, po jakých přesných operacích byly vstupy transformovány na výstupy. Tento princip umožňuje neuronovým sítím zohlednit velké množství faktorů a vstupů, mnohem více než by vzal v potaz lidský mozek. [5]

Umělý neuron je sice založen na principu biologického neuronu, ale je výrazně jednodušší. Vstupní informace jsou upravovány pomocí vah a odečítá se prahová hodnota. Dále je signál transformován aktivační funkcí a předán následujícím neuronům ve skryté vrstvě, popřípadě výstupní vrstvě. Jak je uvedeno na Obrázku 2.5.1-1 jednotlivé vstupy jsou váženy vahami w a transformovány pomocí aktivační funkce $f(n)$. [5]




Obrázek 2.5.1-1: Jednovrstvá neuronová síť [5]

Vstupem neuronu je R hodnot $(x_1, x_2, \dots, x_R)$, po zvážení těchto hodnot vahami $(w_1, w_2, \dots, w_R)$ dochází k transformaci hodnot aktivační funkcí, ty nejpoužívanější jsou hardlim, purelin, logsig, transig, harlims, satlin, satlins, radbas atd. Grafy průběhu těchto funkcí jsou uvedeny na Obrázku 2.5.1-2. [5]



Obrázek 2.5.1-2: Aktivační funkce [5]

Pro většinu úkolů, které je potřeba řešit v reálné praxi, je nutné použít vícevrstevných neuronových sítí, kde se každá vrstva skládá z několika neuronů. Na Obrázku 2.5.1-3 je uvedeno zjednodušené schéma vícevrstvé neuronové sítě. Síť obsahuje jednu vrstvu vstupní, jednu nebo více vrstev skrytých a jednu vrstvu výstupní. Je nutné zmínit, že topologie sítě musí být správně navržena pro daný úkol, který má řešit. Správnost návrhu sítě, ve správném počtu skrytých vrstev, počtu neuronů v jednotlivých vrstvách a použití konkrétní aktivační funkce, má výrazný vliv na kvalitu řešení. [5]



Obrázek 2.5.1-3: Schéma vícevrstvé neuronové sítě [5]

Řízeným učením, nebo také tréninkem, neuronové sítě dochází k výpočtu jednotlivých vah. Cílem učení pomocí optimalizačního algoritmu je nalezení globálního extrému neboli globálního minima chyby pro daný vstup. Podle typu učení se neuronové sítě dělí na sítě s učením se s učitelem a bez učitele. [5]

Neuronové sítě s učením s učitelem

Neuronové sítě s učením s učitelem jsou sítě, které vyžadují vstupní data a data cílová. Tyto sítě jsou pak vhodné pro modelování a řízení dynamických systémů, klasifikaci dat zkreslených šumem nebo predikci. Existují tyto typy: [5]

- dopředné sítě,
- radial basis sítě,
- dynamické sítě,
- learning vector quantization sítě.

Neuronové sítě s učením bez učitele

Neuronové sítě s učením bez učitele nevyžadují žádné vnější kritérium neboli cílová data. Tyto sítě pak hledají ve vstupních datech určité vzory, podle nichž data klasifikují. Nejpoužívanějšími jsou následující: [5]

- competitive layers,
- self-organizing maps.

2.5.2 Genetické algoritmy


Genetické algoritmy jsou stejně jako neuronové sítě založeny na přírodních zákonech. Jsou v současné době asi nejrozšířenější umělou inteligenci používanou v podnikatelství. Jejich použití je vhodné tam, kde by systematické prozkoumání všech možností trvalo nekonečně dlouho. [5]

V biologickém pojetí genetiky se prosazují jedinci, kteří mají žádoucí vlastnosti pro přežití. U zrodu genetických algoritmů stála velmi podobná myšlenka a to, že by při hledání řešení složitých problémů byly použity vyhovující části stávajících řešení. [5]

Genetické algoritmy většinou pracují s náhodně vytvořenou vrstvou chromozomů (jedinců). Tato vrstva postupuje k lepším řešením problému pomocí genetických operací, kterými jsou nejčastěji selekce, mutace a křížení. V každé generaci, příznivá řešení generují

potomstvo, které nahradí nekvalitní jedince. Potomek kombinuje geny obou mateřských chromozomů s cílem využít jejich potenciálu. Účelem mutace je pak zachovat rozmanitost genofonu. Vyhodnocení ukončující podmínky rozlišuje mezi dobrým a špatným řešením[4]

Proces fungování algoritmu je systematicky zapsán na Obrázku 2.5.2-1.



Obrázek 2.5.2-1: Schéma reprodukce genetického algoritmu [5]

Podle Dostála [5] lze genetický algoritmus popsat následujícími kroky:

1. Náhodné vytvoření počáteční populace n chromozomů.
2. Ocenění kvality všech chromozomů pomocí fitness funkce.
3. Tvorba nových chromozomů pomocí operátorů selekce, mutace a křížení.
4. Odstranění starých chromozomů.
5. Vložení nových chromozomů namísto starých odstraněných.
6. Po splnění ukončující podmínky, je vybrán nejlepší chromozom jako řešení, jinak se proces opakuje od kroku 3.

3 ANALÝZA SOUČASNÉ SITUACE

Hlavním účelem této kapitoly je aktuální analýza finančního trhu a jeho propojení s neuronovými sítěmi a automatickými obchodními systémy. V první části je popsána společnost, pro kterou byl výzkum zpracováván a její současné aktivity ve směru implementace umělé inteligence a obchodních systémů k analýze trhu. Druhá část se pak zaměřuje na analýzu současného stavu využívání predikce finančního trhu pomocí neuronových sítí a exekuci výstupů prostřednictvím automatického obchodního systému. Analýza se nezabývá pouze možnými výhodami či nevýhodami, ale také ukazuje, jak byl v minulosti tento problém řešen jinými výzkumy.

3.1 POPIS SPOLEČNOSTI

Společnost Goldenburg Group LTD se sídlem na Kypru, 3042 Limassol se zabývá provozováním několika brokerů a dalších obchodníků s cennými papíry. Snaží se nabídnout svému klientovi široké možnosti v rámci obchodování s forexem a nesčetnými CFD's. Společnost je plně licencovaná a regulovaná kyperskou komisí pro cenné papíry (CySEC), a dále má v každém státě, kde působí svého vázaného zástupce, který je registrovaný u místního regulátora finančního trhu. Pro Českou republiku je vázaným zástupcem společnost QUAENTAS s.r.o., která je vázaná u České národní banky.

Jak bylo popsáno výše v kapitole 1.1, společnost stojí před rozhodnutím, zda se udat cestou automatizace obchodování, či nikoliv. Její rozhodnutí s největší pravděpodobností ovlivní zisky a ztráty do dalších let.

V České republice je trh s nabízením kvalitních brokerských služeb relativně rychle se rozvíjející. Konkurence zde existuje, avšak na trhu nemá nikdo výraznou převahu. Společnost Goldenburg Groupe LTD. se rozhodla jít cestou dražších, ale kvalitních služeb.

3.2 PREDIKCE KAPITÁLOVÉHO TRHU

Problematika predikce kapitálového trhu je hlavním předmětem této podkapitoly. Nejdříve je zde pojednáno o možných přístupech k predikci, dále o stávající situaci a nakonec o možnosti predikovat trh pomocí neuronové sítě.

3.2.1 Přístupy k predikci

Existuje mnoho metod, kterými je možné předpovídat vývoj na finančních trzích a doposud nebyla nalezena jedna, o které by se dalo říct, že je lepší než ty ostatní.

Skutečnost že většina lidí nedokáže předpovídat budoucí vývoj na finančních trzích, ještě neznamena, že jsou tyto trhy nepředvídatelné. Naopak je mnohem snazší dokázat, že trh je předpověditelný, než že tomu tak není. [14]

Z dlouhodobého hlediska není možné předpovídat vývoj ceny na trhu se sto procentní úspěšností, literatura uvádí, že modely a metody pro předpověď vývoje trhu se pohybují mezi padesáti až devadesáti procenty úspěšnosti. [14] Také neexistuje jedna metoda, která by byla použitelná na všechny instrument obchodované na finančních trzích, každá metoda musí být specifikována pro jeden nebo skupinu instrumentů. [3]

Tvrzení více vysvětluje Dostálovo rozdělení časových řad: [6]

- Deterministické časové řady
 - Lineární
 - Konstantní
 - Rostoucí
 - Klesající
 - Periodické
 - S konstantní periodicitou
 - S měnící se periodicitou
 - Chaotické
- Stochastické časové řady (náhodné)

3.2.2 Použití neuronových sítí na finančních trzích

Je těžké jednoznačně rozhodnout, zdali je použití neuronových sítí, při obchodování na reálných finančních trzích, opravdu přínosem. Názory na toto téma se různí.

Existuje několik výzkumů, které vykazují relativně vysoké úspěšnosti při obchodování s použitím neuronových sítí. V literatuře je uváděno, že byly vyvinuty takové predikční modely, s jejichž používáním investoři dosáhli až 90% úspěšnosti svých obchodů. [3] [9] Většina názorů však zastává stanovisko, že úspěšnost takovýchto modelů leží někde mezi 60% až 70%. Většina těchto modelů je srovnávána s náhodným vstupem do trhu nebo strategií koupit a držet. [8]

Stejně tak se zdroje rozcházejí v pohledu na vstupní data. Jsou zde názory pro používání otevírací, nejvyšší, nejnižší a zavírací ceny a denního objemu, [6] ale také názory tvrdící že je užitečnější používat klouzavé průměry a další indikátory na místo historických dat. [3] Velmi podobný rozkol byl nalezen i v názorech na délku vstupních dat, která se v literatuře pohybuje v rozmezí mezi 60-ti až 1000-ci dny. [13]

Literatura se však ve většině případů shoduje na tom, co je důležité zohlednit při vývoji predikčních modelů s využitím neuronových sítí. [5] [6] [13]

- Typ a učící funkce sítě
- Počet skrytých vrstev a neuronů v nich
- Typ aktivační funkce

Je prakticky nemožné zjistit, jaké jsou aktuálně používané modely neuronových sítí při reálném obchodování na finančním trhu. Natož jejich úspěšnost, vstupní data nebo atributy.

3.3 AUTOMATICKÉ OBCHODNÍ SYSTÉMY

V literatuře lze najít mnoho příkladů automatických obchodních systémů. Jistým typem těchto systémů jsou i ukazatele technické analýzy, na základě kterých mnoho obchodních systémů běží. Jiná literatura zase pojednává o vývoji indikátorů pomoc systémů. [20] V každém případě no při vývoje obchodních systémů hají tyto indikátory a jejich správné použití významnou roli.

Jiná literatura uvádí použití algoritmů pro sestavování a nákup optimalizovaného portfolia. [23] Použitím automatických obchodních systémů, ať už v jakémkoliv prostředí pro vstup na online trh, lze automatizovat mnoho různých strategií a přístupů k obchodování, další literatura například uvádí automatizovanou teorii Fraktálů v programu MetaTrader. [1]

Program MetaTrader a jeho vývojářské prostředí MetaEditor jsou ve vývoji automatických obchodních systémů velmi oblíbenými nástroji a to především díky svojí dostupnosti a velké komunitě uživatelů. [33]

Směrování trendu řízení finančních toků na trhu pomocí podobných automatických systémů je více než patrné. Požadavky investorů na úsporu času a přenesení odpovědnosti jsou naplňovány právě automatickými obchodními systémy.

4 NÁVRH ŘEŠENÍ

Předmětem této kapitoly je návrh na řešení problému popsaného na začátku této práce. V kapitole jsou podrobně popsány veškeré postupy a požadavky k navrhovanému řešení. První část je věnována predikci směru a velikosti pohybu finančního instrumentu, druhá pak vyřešení problému s přenesením těchto poznatků k investorovi a jejich exekuci v reálném finančním trhu. První část řešení je zpracována ve vývojářském prostředí MATLAB za použití oficiální dokumentace [21], druhá pak v programu MetaTrader 4 stejně tak za použití oficiální dokumentace od poskytovatele programu. [33] Na závěr kapitoly jsou pak zmíněna omezení a doporučení při užívání níže popsaného řešení.

4.1 PREDIKČNÍ MODEL

Pro predikci finančního trhu byl zvolen model založený na umělých neuronových sítích, který byl vyvíjen v prostředí MATLAB. Jak je zmíněno výše, tento model je neprogramován tak aby každý den předpověděl závěrečnou cenu pro následující obchodní den.

V kapitole je detailně popsáno, jak byl model vyvíjen a jaké proměnné byly v průběhu testování měněny a by poskytovali lepší a přesnější výstupy. Dále je níže zmíněno, který z predikčních modelů byl vyhodnocen jako nejvhodnější pro řešení problému a z jakého důvodu. Na závěr kapitoly je vyčíslen zisk/ztráta za předpokladu fungování modelu v reálném trhu.

4.1.1 Popis postupu řešení

Před přikročením k psaní samotného programovacího kódu je třeba stanovit si přesnější postup, jak by mělo být cíle dosaženo. Tato podkapitola se věnuje popisu kroků, které předcházely stanovení finálního navrhovaného řešení. Před začátkem řešení je důležité rozhodnout, co přesně je potřeba řešit, stanovit přesný cíl, a detailní postup, jak bude tohoto cíle dosaženo.

Co bude výstupem predikčního modelu

Bylo rozhodnuto, že výstupem predikčního modelu bude cenová hladina při uzavření trhu následující obchodní den. Dále bylo stanoveno, že tato cena bude porovnána s tržní cenou daného instrumentu při uzavření trhu v den předcházející, a tím bude stanoveno, zdali je předpoklad, že cena instrumentu bude stoupat či klesat. Pak je po zhodnocení číselného výstupu

modelu možno rozhodnout, zda je vhodné vstupovat na trh, a pokud ano, tak kterým směrem spekulovat, zdali na nárůst ceny nebo naopak na její pokles.

Druhým parametrem výstupu byla stanovena velikost pohybu. Velikost pohybu byla spočtena jako rozdíl dvou výše zmíněných cen. Tento parametr byl zaveden především pro rozhodnutí, zda do trhu vůbec vstupovat.

Zvolení instrumentu

Jak již bylo zmíněno výše, žádná analýza není aplikovatelná na všechny instrumenty finančního trhu. Proto ani tato technická analýza pomocí neuronových sítí není aplikována na široké portfolio instrumentů.

Pro technickou analýzu pomocí predikčního modelu byl vybrán akciový index S&P 500. Standard and Poor's 500 Index je vážená kapitalizace 500 vybraných akcií v indexu. Index je určen pro měření výkonnosti širokého okruhu domácí ekonomiky pomocí změny celkové tržní hodnoty 500 akcií, které zastupují všechny hlavní průmyslová odvětví. Index byl vyvinut v roce 1941, ovšem za léta své působnosti na finančním trhu několikrát změnil své složení. Index je obchodován na New Yorské burze cenných papírů (NYSE) [27] Tento index byl vybrán především pro svou vysoký počet obchodů, které jsou s ním denně uzavírány, pro svoji vysokou vypovídací hodnotu o stavu americké ekonomiky a v neposlední řadě proto, že bylo možné získat data o jeho denních pohybech na Yahoo! Finance bezplatně. [36]

Predikční model lze použít i pro další světové indexy, jako jsou např.: DAX, FTSE 100 nebo NIKKEI 225 a to z důvodů, že co se týče technické analýzy, jsou si tyto indexy velmi podobné. Je třeba poznamenat, že model nebyl testován pro tyto indexy a jeho nasazení na těchto instrumentech bude předmětem dalšího výzkumu.

Proces testování a měření

Jelikož je model určen pro reálné obchodování na reálném finančním trhu, je třeba ho testovat na těchto datech. Jeho výstupy pak musí být srozumitelné pro každého obvyklého investora.

Proces testování probíhal zpětně. Bylo uvažováno, že pokud předpovězený pohyb překoná velikost poplatku obchodníkovi, který je na indexu S&P 500 dva americké dolary za jeden kus, investor vstoupí do obchodu za otevírací cenu a vystoupí z něj za cenu zavírací. Velikost pohybu byla spočtena jako rozdíl předpovězené ceny a ceny zavírací z minulého obchodního dne.

Na základě těchto předpokladů byla stanovena zaprvé úspěšnost predikce a zadruhé ziskovost modelu. Model byl daný den úspěšný, pokud se cena na trhu vyvíjela stejným směrem, jak předpověděl a to bez ohledu na velikost predikovaného pohybu. V opačném případě byl model v daném dnu neúspěšný. Zisk, respektive ztráta, byly spočteny kumulací zisků a ztrát za jednotlivé dny, kdy velikost predikce překročila poplatek obchodníka.

Model byl testován na datech za měsíc březen. Tyto data byla velmi příhodná, jelikož index S&P 500 zaznamenal strmý a neočekávaný nárůst. Proto lze říct, že model byl testován v nepřívětivých, nikoliv však nevšedních podmínkách.

Vstupní data

Pro usnadnění práce se vstupními daty byl vytvořen krátký program yahooDataFetcher.m (M file) pro stažení historických dat ze serveru Yahoo! Finance. [36] Tento program, pomocí MATLAB Datafeed Toolbox, stahuje data o otvírání, zavírání, nejvyšší a nejnižší ceně (OHLC), které byly daný den v trhu zaznamenány. Spolu s těmito daty je stažen ukazatel volume, který vypovídá o objemu obchodů uskutečněných v daném instrumentem za den.

Na základě stažených dat jsou dopočítány, pomocí MATLAB Financial Toolbox a jeho funkcí, indikátory technické analýzy. MATLAB Financial Toolbox obsahuje mnoho metod a vzorců pro výpočet statistických indikátorů. Pro účely této práce byly vybrány tyto:

- Volume (objem obchodů)
- Open. High, low, close (OHLC)
- Jednoduchý klouzavý průměr (SMA)
- Exponenciální klouzavý průměr (EMA)
- Relativ strength index (RSI)
- Moving average convergence divergence (MACD)
- Bollingerova pásma (BB)
- Stochastic Oscillator (Stoch. Os.)


Přesné definice a výpočty indikátorů uvádí Rejnuš. [17]

Z výše zmíněných dat byly vytvořeny tři kombinace, které byly následně testovány, do jaké míry ovlivňují úspěšnost predikčního modelu.

	Vstupní data	Úspěšnost v %	Zisk v USD
1. kombinace	OHLC, Volume, SMA 50, SMA 200, EMA 50, EMA 200, RSI, MACD, Stoch. Os.	63,6%	\$58,00
2. kombinace	Volume, SMA 50, SMA 200, EMA 50, EMA 200, RSI, MACD, Stoch. Os.	68,2%	\$123,00
3. kombinace	Volume, SMA 10, SMA 100 EMA 10, EMA 100, RSI, MACD, Stoch. Os., BB	81,8%	\$153,00

Tabulka 4.1.1-1: Vstupní data [vlastní zpracování]

Kombinace vstupních dat byly testovány po dobu jednoho měsíce a vyjádření zisku bylo spočteno za předpokladu, že investor každý den nakupoval nebo prodával pouze jeden kus daného instrumentu. Při výpočtu procentní úspěšnosti byl za úspěšný obchodní den považován takový den, kdy směr pohyby trhu se shodoval se směrem, který byl predikován modelem. Jedná se o určení trendu na následující obchodní den, jestliže bude trend klesající, stoupající nebo stranový. Srovnání předpokládaného vygenerovaného zisku je pak přehledně srovnáno na Grafu 4.1.1-1, v zisku není započítán poplatek obchodníkovi.



Graf 4.1.1-1: Profit v závislosti na složení vstupních dat [vlastní zpracování]

Za nejvíce úspěšnou kombinaci vstupních dat, co se procentní úspěšnosti týče, byla vyhodnocena 3. kombinace ve složení volume, desetidenní jednoduchý klouzavý průměr, stodenní jednoduchý klouzavý průměr, desetidenní exponenciální klouzavý průměr, stodenní exponenciální klouzavý průměr, Relativ strength index za 14 dní, Moving average convergence

divergence, Stochastic Oscillator a Bollingerova pásma. Dále již bylo pracováno pouze s touto kombinací vstupních dat.

Délka časové řady na vstupu


Předmětem dalšího zkoumání byla délka časového intervalu vstupních dat, neboli na kolika dnech by bylo ideální neuronovou síť, která je hlavní částí predikčního modelu, trénovat. Literatura uvádí různé přístupy a to od krátkých časových řad v rámci dvou až třech měsíců až po časové řady jdoucí do stovek vstupních dnů.

Znovu byly stanoveny tři délky vstupních dat a to 90, 150 a 252 dní. Tyto délky časových řad byly následně testovány po dobu jednoho měsíce. Vrchní hranice 252 dní byla zvolena, protože v roce 2015 bylo 252 obchodních dní, tím pádem tato časová řada obsahuje data za jeden rok.

	Počet dní	Úspěšnost v %	Zisk v USD
1. varianta	90 dní	50,0%	-\$58,00
2. varianta	150 dní	63,6%	\$103,00
3. varianta	252 dní	81,8%	\$153,00

Tabulka 4.1.1-2: Délka vstupních dat [vlastní zpracování]

Kritéria pro vyhodnocení úspěšnosti a zisku testovaných časových řad byla stejná, jako u výše uvedených vstupních dat. Jak je vidět v Tabulce 4.1.1-2 i Grafu 4.1.1-2 s prodlužující se délkou vstupních dat stupá jak úspěšnost, tak ziskovost, ale bohužel kvůli omezenému vybavení výpočetní technikou, nebylo možno zkoumat, jak by se model choval, kdyby na vstupu dostal data o délce několika let.



Graf 4.1.1-2: Profit v závislosti na délce vstupních dat [vlastní zpracování]

Na Grafu 4.1.1-2 je vidět že vstupní data s délkou 90 dnů skončila dokonce v 58 dolarové ztrátě a to bez započítání poplatků obchodníkovi. Testování ukázalo, že v tuto chvíli je nejvhodnější použít pro trénování neuronové sítě časovou řadu o délce 252 dní. Dále už je pracováno jen s touto variantou.

Optimalizace neuronové sítě

Neexistuje mnoho literatury, která by se zbývala tak specifickým problémem, jako je návrh neuronové sítě pro predikci finančního trhu. Přesto bylo nalezeno pár doporučení. [6] [13]

Při návrhu a optimalizaci neuronové sítě byl kladen největší důraz na čtyři následující body.


- **Typ sítě:** dle výše zmíněných doporučení byl použit typ sítě Feed-forward backpropagation network, jako nejčastěji používaný typ pro predikci.
- **Učící funkce:** byla použita učící funkce Conjugate gradient backpropagation with Fletcher-Reeves updates.
- **Počet neuronů v jedné skryté vrstvě:** toto nastavení bylo předmětem testování popsaného výše. I když existuje nekonečně mnoho kombinací této optimalizační úlohy, hlavně pokud by se uvažovalo o rozdílné počty neuronu v jednotlivých vrstvách, byly pro tuto práci zvoleny tři varianty a to 100 200 a 300 neuronů v každé z deseti skrytých vrstev. Z Tabulky 4.1.1-3 i Grafu 4.1.1-3 je vidět

rostoucí trend úspěšnosti i ziskovosti s přibývajícími neurony. Bohužel omezení hardwarem nedovolilo dále zvyšovat počet neuronů. Tento trend by mohl být předmětem dalšího zkoumání.

	Počet neuronů ve skryté vrstvě	Úspěšnost v %	Zisk v USD
1. varianta	100 neuronů	54,5%	\$69,00
2. varianta	200 neuronů	72,7%	\$139,00
3. varianta	300 neuronů	81,8%	\$153,00

Tabulka 4.1.1-3: Počet neuronů ve skryté vrstvě [vlastní zpracování]

Pro finální řešení byla zvolena nejúspěšnější a nejziskovější 3. varianta se třemi sty neurony v každé z deseti skrytých vrstev. Níže v Grafu 4.1.1-3 je uvedeno porovnání kumulativního zisku všech tří variant.




Graf 4.1.1-3: Profit v závislosti na počtu neuronů ve vrstvě [vlastní zpracování]

- **Aktivační funkce:** dle výše zmíněné literatury jsou nejpoužívanějšími funkcemi pro predikci finančního trhu funkce sigmoidové a tangentové. MATLAB Neural Network Toolbox nabízí funkce „tansig“ a „logsig“. Použití obou těchto funkcí vykazoval prakticky stejné výsledky, přičemž funkce „logsig“ byla jemně přesnější, co se týče předpovědi velikosti pohybu.

4.1.2 Finální řešení

Finální řešení predikčního modelu bylo sestaveno z neúspěšnějších výše testovaných řešení.

Po spuštění PredictPrice.m je v příkazovém okně vypsán text: „Neural network prediction model for S&P 500“ (viz Obrázek 4.1.2-1).




```
Command Window
>> PredictPrice
Neural network prediction model for S&P 500
```

Obrázek 4.1.2-1: Příkazové okno [vlastní zpracování]

Dále je spuštěn program yahooDataFetcherSPY.m, který automaticky stáhne historická data o vývoji ceny ze serveru Yahoo! Finance. [36] Za použití těchto dat je provedena technická analýza spočtením následujících indikátorů ze závěrečné ceny:


- Desetidenní jednoduchý klouzavý průměr
- Stodenní jednoduchý klouzavý průměr
- Desetidenní exponenciální klouzavý průměr
- Stodenní exponenciální klouzavý průměr
- Relativ strength index
- Moving average convergence divergence
- Stochastic Oscillator
- Bollingerova pásma

Po nastavení veškerých vstupů je následně vytvořena neuronová síť typu Feed-forward backpropagation network s deseti skrytými vrstvami, kde každá z vrstev obsahuje 300 neuronů. Tato síť je následně učena pomocí funkce Conjugate gradient backpropagation with Fletcher-Reeves updates dokud není dosaženo stanovené chyby, jak je uvedeno na Obrázku 4.1.2-2.




Obrázek 4.1.2-2: Proces učení neuronové sítě [vlastní zpracování]

Po dokončení učení neuronové a stanovení všech vah jsou simulována data pro predikci. Ve chvíli kdy jsou k dispozici jak data historická, tak data nasimulovaná neuronovou sítí jsou výsledky zobrazeny v grafu, kde historická cena je zobrazena modře a predikovaná cena oranžově, na ose x je vynesena cena instrumentu a na ose y datum (viz Obrázek 4.1.2-3 a 4).

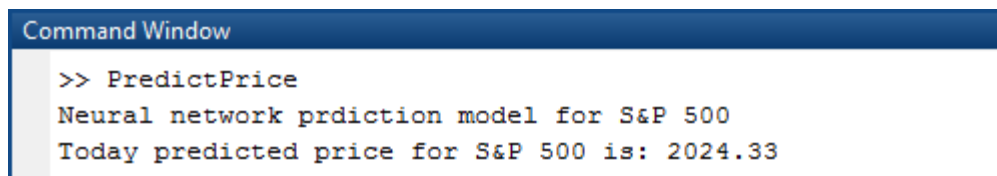


Obrázek 4.1.2-3: Výstup predikčního modelu v grafu 1 [vlastní zpracování]



Obrázek 4.1.2-4: Výstup predikčního modelu v grafu 2 [vlastní zpracování]

Po vykreslení grafu je vyexportována predikovaná změna a její velikost do CSV souboru s názvem output.csv, který je následně uploadován na server. Na závěr vypíše predikční model jím spočtenou cenu pro následující obchodní den do příkazového okna (viz Obrázek 4.1.2-5).

A screenshot of a command window with a dark blue title bar labeled "Command Window". The window has a light gray background. The text inside is as follows:

```
>> PredictPrice
Neural network prdiction model for S&P 500
Today predicted price for S&P 500 is: 2024.33
- . . - .
```

Obrázek 4.1.2-5: Příkazové okno konec [vlastní zpracování]

4.1.3 Vývoj predikčního modelu


V následující podkapitole je detailně popsán vývoj predikčního modelu a jeho postup. Jsou zde uvedeny nejdůležitější části programového kódu a jejich komentář. Celý program je pak uveden v přílohách.

Vývoj predikčního modelu probíhal v následujících krocích:

- Spuštění funkce yahooDataFetcher.m
- Stažení dat ze serveru Yahoo! Finance
- Příprava indikátorů technické analýzy
- Příprava vstupních a cílových dat pro učení a simulaci neuronové sítě
- Vytvoření a konfigurace neuronové sítě
- Učení neuronové sítě
- Simulace při využití naučené neuronové sítě
- Zobrazení výsledků v grafu
- Spočtení velikosti pohybu a jeho export do CSV souboru
- Testování modelu a jeho zpětná úprava

Predikční model je složen ze dvou samostatných programů a to PredictPrice.m a yahooDataFetcher.m, přičemž první zmíněný automaticky spouští druhý. Hlavní program PredictPrice.m je spouštěn pomocí vývojářského prostředí MATLAB. Veškerá potřebná data a proměnné jsou zobrazeny po exekuci programu na pracovní ploše prostředí Matlab, jak je zobrazeno na Obrázku 4.1.3-1. Pro exekuci yahooDataFetcher.m je třeba mít přístup k internetu.

Po exekuci celého programu je automaticky vytvořen soubor output.csv a do něj je vyexportována hodnota velikosti předikovaného pohybu. Tento soubor je následně nachystán na upload přes FTP spojení na server pro přenesení hodnoty k investorovi.



Name ▲	Value
Bolling	412x3 double
BollingLowr	1x412 double
BollingMid	1x412 double
BollingUppr	1x412 double
Close	1x431 double
data	431x6 double
DataT	6x431 double
dysplayPrice	'2047.5790'
EMA10	1x431 double
EMA100	1x431 double
fileName	'output.xlsx'
HiddenNeurons	[300 300 300 300 300 ...
Input	13x253 double
InputC	13x252 double
lastPrice	2067
LearningData	252
lowr	412x1 double
macd	1x431 double
mid	412x1 double
net	1x1 network
netInput	13x253 double
netOutput	1x252 double
nineperma	1x431 double
NNInputSeq	1x252 cell
NNSampleSeq	1x252 cell
NNTargetSeq	1x252 cell
preDayDate	736467
predChange	-19
predPrice	2048
RSI14	431x1 double
Sample	13x252 double
SimHistPrice	1x252 double
SimPredPrice	1x252 double
SMA10	1x431 double

Obrázek 4.1.3-1: Pracovní plocha prostředí Matlab [vlastní zpracování]

Jak již bylo výše zmíněno, prvním krokem modelu je spuštění programu yahooDataFetcher.m, dále je níže v kódu vidět práce se staženými daty. Konkrétně jejich transpozice a výběr závěrečné ceny a její uložení do proměnné. Dále je v kódu vidět zvolení délky časové řady pro učení neuronové sítě.

```
%Download from Yahoo Finace
[data] = yahooDataFetcherSPY();

%Prepare data for training and simulation Neural Network
DataT = data';
Close = DataT(5, 1:end);
LearningData = 252;
```

Zde je uveden celý programovací kód yahooDataFetcherSPY.m, vkódu jsou stanovena dvě data a to data, která ohraničují délku stažených historických cen ze serveru Yahoo! Finance. První datum (toDate) je stanoveno jako aktuální datum mínus jeden den neboli datum předchozího dne. Druhé datum (fromDate) je pak spočteno jako výchozí datum mínus 452 a to proto, že je dále potřeba spočíst dvou set denní klouzavý průměr, který je možné spočíst poprvé po dvou stech dnech a jeden den navíc pro účely predikce. Dále je použita vestavěná funkce MATLABu Finance Toolbox „fetch“ a stanovení jejich parametrů.

```
function [data] = yahooDataFetcherSPY()

c = yahoo;

toDate = today - 1;
fromDate = toDate - 453;

dataYahoo = fetch(c, '^GSPC', {'Open', 'High', 'Low', 'Close', 'Volume'}, toDate,
fromDate, 'd');

close(c);

data = flipud(dataYahoo);
```

V další části kódu je uvedeno, jak byly spočteny indikátory technické analýzy, pro každý z nich je v MATLABu Finance Toolbox předefinována funkce. Většina z indikátorů je spočtena výhradně ze zavírací ceny. Některé je pak potřeba počítat z dat před transpozicí např.: RSI nebo Bollingerova pásma, jiné je možné spočíst z již transponovaných dat např.: klouzavé průměry.

```
%Technical Anlyst
SMA10 = tsmovavg(Close, 's', 10);
SMA100 = tsmovavg(Close, 's', 100);
EMA10 = tsmovavg(Close, 'e', 10);
EMA100 = tsmovavg(Close, 'e', 100);
RSI14 = rsindex(data(1:end, 5), 14);
[macd, nineperma] = macd(Close);
STOSCkd = stochosc(data(1:end, 3), data(1:end, 4), data(1:end, 5), 10, 3, 'e');
STOSCk = STOSCkd(1:end, 1)';
STOSCd = STOSCkd(1:end, 2)';
[mid,uppr,lowr] = bolling(data(1:end, 5),20);
Bolling = [mid, uppr, lowr];
BollingMid = Bolling(1:end,1)';
BollingUppr = Bolling(1:end,2)';
BollingLowr = Bolling(1:end,3)';
```

Přidání technické analýzy k ukazateli volume a jejich uložení do jedné vstupní proměnné je uvedeno níže. Kód pokračuje důležitou prací se vstupními a cílovými daty. Data vstupní musí být o jeden den zpožděna, aby se neuronová síť učila počítat cílová data z dat starších o jeden den. Tento princip je velice důležitý pro fungování celého predikčního modelu. Na základě této úvahy je postavena celá teorie předpovědi v této práci.

```
%Input for training
Input = DataT(6,:);
Input (end+1,:) = SMA10;
Input (end+1,:) = SMA100;
Input (end+1,:) = EMA10;
Input (end+1,:) = EMA100;
Input (end+1,:) = RSI14';
Input (end+1,:) = macd;
Input (end+1,:) = nineperma;
Input (end+1,:) = STOSCk;
Input (end+1,:) = STOSCd;
Input = Input (:,20:end);
Input (end+1,:) = BollingMid;
Input (end+1,:) = BollingUppr;
Input (end+1,:) = BollingLowr;

Input = Input(:, end - LearningData:end);
netInput = Input( :, :);
InputC = netInput(:, 1:end - 1);

%Target for training
Target = DataT(5, end - LearningData + 1:end);

%input for simulation
Sample = netInput(:, 2:end);
```

Zde je již přikročeno k vytvoření, trénování a simulaci samotné neuronové sítě. Jak bylo zmíněno výše v kapitole 4.1.1 neuronová síť byla vytvořena s deseti skrytými hladinami po tři sta neuronech a aktivační funkce všech hladin byla stanovena na „logsig“. Posledním atributem při vytvoření sítě je učící funkce.

Dále byly stanoveny dva parametry pro učení neuronové sítě a to maximální počet epoch (10 000) a maximální chyba, které má být při učení dosaženo (tisícina průměru cílových hodnot). Po dokončení učícího procesu je spuštěna simulace sítě a uložení výstupů do proměnné se kterou je dále pracováno.

```

%NN model
HiddenNeuronsInLayer = [300 300 300 300 300 300 300 300 300 300];
%Creat NNModel
net = newff(NNInputSeq, NNTargetSeq, HiddenNeuronsInLayer, {'logsig' 'logsig'
'logsig' 'logsig' 'logsig' 'logsig' 'logsig' 'logsig' 'logsig' 'logsig'},
'traincgf');

%Train NNModel
net.trainParam.epochs = 10000;
net.trainParam.goal = mean(Target) * 0.001;

[net,tr] = train(net, NNInputSeq, NNTargetSeq);

%Simulate NNModel
NNsimDataSeq = sim(net, NNSampleSeq);
simData = seq2con(NNsimDataSeq);

netOutput = simData{1,1};

```

Před vykreslením historické a spočtené ceny neuronovou sítí je třeba přiřadit jednotlivým zavíracím hodnotám datum, ke kterému se vztahují. Tím bylo také dosaženo toho, že linka znázorňující vypočtenou zavírací cenu je o jeden den delší než linka znázorňující cenu historickou a to právě o den, pro který je cena modelem predikována.

Krátká funkce „když“ zajišťuje, aby i při spuštění modelu o víkendu bylo predikované ceně přiřazeno správné datum a to datum pondělní, které je datem nejbližšího následující obchodní dne.

```

%Plot
SimHistPrice = DataT(1, end - LearningData + 1:end);
SimPredPrice = SimHistPrice(:, 2:end);
preDayDate = SimPredPrice(1,end) + 1;
if weekday(preDayDate) == 7
    preDayDate = preDayDate + 2;
end
SimPredPrice(:,end+1) = preDayDate;

tsReal = timeseries(Target, datestr(SimHistPrice));
tsReal.Name = 'Real Price';
tsReal.TimeInfo.Units = 'Days';

tsPredict = timeseries(netOutput, datestr(SimPredPrice));
tsPredict.Name = 'Predicted Price';
tsPredict.TimeInfo.Units = 'Days';

plot(tsReal), grid on;
hold on;
plot(tsPredict);

```

Na konci programovacího kódu predikčního modelu je spočtena velikost predikovaného pohybu ceny daného instrumentu. Změna je rovna rozdílu poslední známé historické závírací ceny a ceny predikované modelem. Tato změna je následně vyexportována do souboru output.csv.

```
lastPrice = int64(Target(end,end));  
  
predPrice = int64(netOutput(end,end));  
  
change = predPrice - lastPrice;  
  
fileName = 'output.csv';  
csvwrite(fileName, change);
```


Exekuce celého programovacího kódu zabere něco mezi deseti až dvaceti minutami v závislosti na hardwaru, pomocí kterého je kód exekvován. Nejdelší čas zabere učení neuronové sítě, kdy jsou vyhodnocovány a přepočítávány váhy jednotlivých vstupů a které je zároveň nejnáročnější na hardware.

4.1.4 Výsledky

Výsledky úspěšnosti a ziskovosti výstupů z predikčního modelu byly vyhodnocovány tak, jak je popsáno výše v kapitole 4.1.1. Finální řešení modelu bylo testováno po délku 58 obchodních dní a to od 1.3.2016 do 20.5.2016. V tomto období byl v USA jeden den svátek a to 25.5.2016 a ve dvou dnech nepřekonala velikost predikovaného pohybu poplatků obchodníka, tím pádem nebylo modelem doporučeno vstoupit na trh. Ve výsledku bylo vyhodnocováno 56 doporučení.


Alternativou k predikčnímu modelu byla zvolena strategie náhodného vstupu na trh, která byla zastoupena funkcí v Microsoft Excelu „Randbetween“, konkrétně „=RANDBETWEEN(-1;1)“, kde hodnota -1 značí vstup na trh spekulací na pokles a hodnota 1 opačným směrem.

Výsledná úspěšnost za výše popsaný časový úsek dosáhla hodnoty 75%. V Grafu 4.1.4-1 je zobrazeno, který den byly obchody úspěšné a který nikoliv. Alternativní strategie náhodného vstupu na trh vykazoval ve stejném časovém období úspěšnost 48,3%. Lze konstatovat, že predikční model dosáhl vyšší úspěšnosti než alternativní strategie.



Graf 4.1.4-1: Úspěšnost predikčního modelu [vlastní zpracování]

Následně byla vyhodnocena ziskovost modelu a porovnána s výše zmíněnou alternativou. Ziskovosti obou dvou strategií jsou zaznamenány v Grafu 4.1.4-2. Ziskovost predikčního modelu dosáhla na konci časového období, za které byla vyhodnocena, hodnoty +255 USD. Tato hodnota je vypočtena bez poplatků obchodníkovi za vstup na trh. Hodnota ziskovosti alternativní strategie za stejné období skončila ve ztrátě -30 USD. V tuto chvíli je možné konstatovat, že predikční model byl úspěšnější i podle kritéria ziskovosti než strategie s ním porovnávaná.



Graf 4.1.4-2: Porovnání zisků predikčního modelu [vlastní zpracování]

4.2 AUTOMATICKÝ OBCHODNÍ SYSTÉM

Druhá část řešení byla zpracována pomocí jazyka MQL4, který je oficiálním jazykem pro vývoj automatických obchodních systémů pro platformu MetaTrader 4. Tento program od společnosti MetaQuotes Software Corp. byl vybrán z důvodu vysoké rozšířenosti ve společnosti Goldenburg Groupe LTD. (GG) a též kvůli své vysoké kompatibilitě s automatickými obchodními systémy.

Hlavním úkolem níže popisovaného systému je stažení souboru ze serveru jedné z partnerských společností společnosti GG, ve kterém je zaznamenán výstup výše popsaného predikčního modelu. Dále jeho vyhodnocení a následná exekuce obchodních příkazů na trhu, na základě vyhodnocení vstupujícího souboru.

Níže popisované řešení je optimalizováno pro průměrného klienta společnosti GG, který se rozhodl investovat 10 tis USD. Klientovi je níže doporučeno základní nastavení obchodního systému, ale konečné rozhodnutí musí vždy učinit investor a společnost bude jeho rozhodnutí vždy respektovat.

4.2.1 Popis řešení

V této podkapitole jsou popsány nejdůležitější části programovacího kódu obchodního systému, který byl zpracován za pomoci vývojového prostředí MetaEditor. Celý program je přílohou této práce

První částí kódu jsou tzv. externí proměnné, které může uživatel měnit při spuštění systému. V tomto případě se jedná o nastavení automatického ztráty a zisku, neboli cenová hladina, jejímž dosažením bude obchod automaticky ukončen.

```
extern double Lots=10;  
extern double lStopLoss = 4000;  
extern double sStopLoss = 4000;  
extern double lTakeProfit = 2500;  
extern double sTakeProfit = 2500;  
extern double TrailingStop= 2500;  
extern int Slippage=4;
```

Následuje spuštění kódu při otevření New Yorské burzy NYSE a to každý obchodní den v 15:30 SEČ. Skript je pouštěn pomocí funkce „když“, to znamená, že pokud je dosaženo správného času a na trhu není otevřená pozice pomocí tohoto obchodního systému, je podmínka vyhodnocena kladně.

```
int start() {
//start at time
if(Hour==15 && Minute==31 && !ExistPositions()) {
```

Výše zmíněná existence obchodu otevřeného tímto obchodním systémem je testována následující funkcí ExistPosition.

```
bool ExistPositions()
{
for(int i=0; i<OrdersTotal(); i++)
{
if(OrderSelect(i,SELECT_BY_POS,MODE_TRADES))
{
if(OrderSymbol()==Symbol() && OrderMagicNumber()==MAGIC)
{
return(True);
}
}
}
return(false);
}
```

Při kladném vyhodnocení podmínky uvedené výše je spuštěno následující hlavní tělo programu. Tato část programu zajišťuje stažení CSV souboru ze serveru společnosti MMC – Moravia Marketing Company, s.r.o., která úzce spolupracuje se společností GG. Následuje jeho vyhodnocení pomocí dvou podmínek, které následně zajišťují spuštění funkcí „OpenBuy“ a „OpenSell“.

```
string cookie,headers,MMC_url;
char post[],result[];
int res, filehandle,timeout;
double priceChange;

//--- Reset the last error code
ResetLastError();
//--- Loading a html page from MMC
MMC_url="http://www.2mc.cz";
cookie=NULL;
timeout=5000; //--- Timeout below 1000 (1 sec.) is not enough for
res=WebRequest("GET",MMC_url,cookie,NULL,timeout,post,0,result,headers);

if(res==-1) {
Print("Error in WebRequest. Error code =",GetLastError());
}
else {
PrintFormat("The file has been successfully loaded, File size =%d bytes.",ArraySize(result));
```

```

filehandle = FileOpen("output.csv",FILE_READ|FILE_CSV);
priceChange = FileReadNumber(filehandle);

if(priceChange >= 2.1) {
    OpenBuy();
    return(0);
}

if(priceChange <= -2.1) {
    OpenSell();
    return(0);
}
}

```

Funkce „OpenBuy“ a „OpenSell“ provádí samotnou exekuci obchodních příkazů na trh a jsou zobrazeny níže.

```

void OpenBuy()
{
    double ldLot,ldStop,ldTake,ticket;
    ldLot=GetSizeLot();
    ldStop = GetStopLossBuy();
    ldTake = GetTakeProfitBuy();
    ticket = OrderSend(Symbol(),OP_BUY,ldLot,Ask,Slippage,ldStop,ldTake,"",MAGIC,0,clrBlue);
}

void OpenSell()
{
    double ldLot,ldStop,ldTake,ticket;
    ldLot=GetSizeLot();
    ldStop = GetStopLossSell();
    ldTake = GetTakeProfitSell();
    ticket = OrderSend(Symbol(),OP_SELL,ldLot,Bid,Slippage,ldStop,ldTake,"",MAGIC,0,clrRed);
}

```

Programovací kód končí zavřením všech pozic, které na trhu systém otevřel, ve 22:29

```

if(Hour()==22 && Minute()==29 && ExistPositions())
{
    CloseAll();
    return(0);
}
return (0);
}

```

SEČ.

Vstupy a výstupy na trh jsou v grafu vývoje ceny instrumentu zaznamenávány pomocí šipek. Modrá šipka značí vstup na trh při spekulaci na nárůst, červená naopak a žlutá šipka zaznamenává výstup z trhu (viz Obrázek 4.2.1-1). Ze záznamů lze pak vyčíst za jakou cenu a v jaký čas bylo na trh vstoupeno, respektive vystoupeno z něj.




Obrázek 4.2.1-1: Graf vývoje ceny se vstupem a výstupem [vlastní zpracování]

4.2.2 Nastavení

Výchozí nastavení automatického obchodního systému je cíleno na investory s počátečním kapitálem 10 000 USD z důvodů uvedených výše. Toto nastavení se týká především velikostí níže uvedených proměnných a lze je kdykoli změnit, buď při spuštění systému, nebo na vyžádání klienta přímo v programovacím kódu.

Při spuštění systému je otevřeno potvrzovací okno, ve kterém je možné měnit proměnné, které jsou v kódu označené jak „extern“. Okno a proměnné jsou zobrazeny na Obrázku 4.2.2-1.



Obrázek 4.2.2-1: Spuštění automatického obchodního systému [vlastní zpracování]


Nejdůležitějšími nastaveními systému jsou právě proměnné uvedené na Obrázku 4.2.2-1. První proměnná „Lots“ určuje, s jakým objemem bude do obchodů vstupováno, výchozí nastavení uvádí 10 lotů, což znamená deset kusů daného instrumentu. Dále jsou nastaveny proměnné „StopLoss“, které vyjadřují velikost pohybu proti směru spekulace, po kterém bude obchod automaticky uzavřen se ztrátou. Stejný pohyb pak představují proměnné „TakeProfit“ akorát ve směru spekulace.

Nastavené velikosti byly pečlivě zváženy. Velikost objemu obchodu je cca 20 000 USD, což znamená využití finanční páky 1:2. Toto využití finanční paky bylo vyhodnoceno jako přiměřené a rizikovost takového obchodu by investora neměla nijak ohrozit. Nastavení maximální přípustné ztráty na jednom obchodu byla spočtena jako 2,5% z celkové investované částky.

Toto nastavení není nijak závazné a každý investor musí zvážit hlavně svůj vlastní přístup k riziku a výši investované částky a podle těchto kritérií se rozhodnout.

4.2.3 Výsledky

Výsledky obchodování pomocí tohoto automatického obchodního systému byly spočteny za předpokladu jeho výše popsaného nastavení a výše zmíněném investovaném kapitálu. Výsledky byly srovnávány s teorií „buy and hold“ neboli na začátku testovaného období byl nakoupen výše zmíněný objem instrumentů a na konci zase prodán. Toto srovnání je zobrazeno v Grafu 4.2.3-1.



Graf 4.2.3-1: Srovnání zisků obchodního systému [vlastní zpracování]

Do zisků obou strategií byly tentokrát již započítány poplatky obchodníkovy za exekuci pokynů, které činily výše 2 USD za každý nakoupený nebo prodaný kus indexu S&P 500.

Na Grafu 4.2.3-1 je vidět že na konci testovaného období nebyl v generovaném zisku obou strategií velký rozdíl, avšak i tak byl obchodní systém o cca 250 USD ziskovější. Důležitým ukazatelem je kumulovaný zisk. Zatímco zisky strategie za použití obchodního systému neustále mírně rostly na ziscích z alternativní strategie je vidět jejich pomalý propad s obracíjícím se sentimentem na trhu. Z toho lze vyvodit závěr, že strategie obchodního systému je schopna být ziskovou bez ohledu na vývoj ceny instrumentu.

Na konci testovaného období bylo za pomoci výše popsaného obchodního systému dosaženo čistého zisku 1 390 USD, jedná se o 14% zhodnocení vloženého kapitálu za 81 dní.

4.3 OMEZENÍ

V této podkapitole jsou popsána omezení, se kterými by měl být investor seznámen, pokud se rozhodne využít výše uvedené řešení pro řízení svého kapitálu na finančním trhu.

Zisky uváděné v této práci nejsou nijak garantované. Obchodování pákových produktů, jako jsou CFD a FX, zahrnuje významné riziko ztráty a nemusí být vhodné pro všechny investory. Obchodování takových instrumentů je riskantní a celý investovaný kapitál může být ztracen.

Predikční model je testován a optimalizován pro specifický instrument a to akciový index S&P 500. Jeho nasazení pro predikci jiných, i když podobných instrumentů by mělo být pečlivě zváženo a otestováno.

Při testování modelu nebyly testovány všechny možné varianty a kombinace, a je možné, že jiné varianty nebo kombinace, ať už kteréhokoli z výše uvedených parametrů ovlivňujícího fungování modelu, povedou ke zlepšení respektive zhoršení úspěšnosti predikce.

Jelikož se v trhu objevují silné fundamentální impulsy a predikce je založena na technické analýze, měl by být uživatel řešení v dobách silného fundametu velmi obezřetný. Měl by pozdržet nebo vůbec neprovést vstup na trh při vysoké volatilitě způsobené těmito zprávami.

ZÁVĚR

Tato práce byla zaměřena na aplikaci predikce finančního trhu pomocí neuronových sítí. Navržené řešení bylo rozděleno do dvou kroků, a to predikce trhu a automatizované exekuce obchodních příkazů na základě predikce. Predikční model byl vyvíjen v programu MATLAB a využíval právě neuronových sítí. Vyhodnocení a exekuce výstupních dat predikčního modelu byla zajištěna pomocí programu MetaTrader 4.

První část výzkumu byla zaměřena na predikci finančního trhu a jejím výstupem byla vstupní data pro část druhou. Výstupem predikčního modelu byl směr a velikost předpokládaného pohybu cenové hladiny následující obchodní den indexu S&P 500. Tento model dokázal za testované období dosáhnout úspěšnosti své predikce ve výši 75%. Při této úspěšnosti vygeneroval model zisk 255 USD při obchodování vždy s jedním kusem tohoto instrumentu, jehož průměrná cena za testované období byla cca 2 000 USD. Instrument samotný si za období připsal zisk 115 USD. Z těchto výsledků lze konstatovat, že predikce za pomoci neuronových sítí je vhodná pro finanční trh a výrazně snižuje vysokou rizikovost při vstupu na trh.

Druhá část výzkumu se zabývala problematikou automatizovaného vyhodnocení a exekuci výstupních dat části první. Vstupem do automatického obchodního systému byl směr a velikost predikovaného pohybu, na základě kterého tento systém pak nakupoval nebo prodával daný instrument. Zde již bylo počítáno se vstupním kapitálem a jeho zhodnocením očištěným o poplatky. Při vstupním kapitálu 10 000 USD zaznamenal obchodní systém míru zhodnocení za 81 dní ve výši 13,9%, přičemž neriskoval současně více než 2.5%. Křivka zůstatku na obchodním účtu se zdála být stabilně rostoucí bez větších výkyvů, což lze považovat za úspěch.

Finální řešení pomocí obou kroků se zdá být příhodné pro reálné obchodování. Jeho používání by mělo přinést zisk jak investorovi tak společnosti Goldenburg Groupe LTD. Dále by mělo díky své automatizaci ušetřit investorovi čas a práci co se týče analýzy trhu a následného rozhodování o vstupu na něj. Toto řešení má však také svoje omezení, které jsou zmíněny výše a investování na finančním trhu nemusí být pro každého investora vhodné.

Bylo dosaženo výše uvedených cílů práce. Omezení rizika při obchodování na finančních trzích bylo pomocí jejich predikce sníženo a díky nastavení automatického systému není souběžně riskováno více než 2,5% z investované částky. Úspěšnost řešení na reálném trhu s podobnými službami a tím i jeho přínos pro společnost Goldenburg Groupe LTD. se ukáže až s odstupem času.

SEZNAM ZDROJŮ

SEZNAM LITERATURY

- [1] Blackledge, J., Murphy, K.:Forex trading using MetaTrader 4 with the fractal market hypothesis.InfoSys 2011: The Third International Conference on Resource Intensive Applications and Services, vol: 978-1-61208-006-2, pages: 1 - 9, Venice, Italy, 2011
- [2] CHAN, Ernest P. *Quantitative trading: how to build your own algorithmic trading business*. Hoboken, N.J.: John Wiley, c2009. Wiley trading series. ISBN 04-702-8488-9.
- [3] CHEN, An-Sing, Mark T. LEUNG a Hazem DAOUK. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers*. 2003, **30**(6), 901-923. DOI: 10.1016/S0305-0548(02)00037-0. ISSN 03050548. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0305054802000370>
- [4] CORDÓN, Oscar. *Genetic fuzzy systems: evolutionary tuning and learning of fuzzy knowledge bases*. Singapore: World Scientific, 2001. ISBN 981-02-4017-1.
- [5] DOSTÁL, Petr. *Soft computing v podnikatelství a veřejné správě Díl I*. Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.
- [6] DOSTÁL, Petr. *Soft computing v podnikatelství a veřejné správě Díl II*. Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-897-7.
- [7] FIALOVÁ, Helena a Jan FIALA. *Malý ekonomický slovník s výkladem pojmů v češtině a v angličtině*. Praha: A plus, 2006. ISBN 80-902-5148-X.
- [8] GATELY, Edward. *Neural networks for financial forecasting*. New York: Wiley, c1996. ISBN 04-711-1212-7.
- [9] HASSAN, M.R. a B. NATH. Stock market forecasting using hidden Markov model: a new approach. *5th International Conference on Intelligent Systems Design and Applications (ISDA'05)*. IEEE, 2005, , 192-196. DOI: 10.1109/ISDA.2005.85. ISBN 0-7695-2286-6. Dostupné také z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1578783>

- [10] KOHOUT, Pavel a Martin HLUŠEK. *Peníze, výnosy a rizika: příručka investiční strategie*. 2. rozš. vyd. Praha: Ekopress, 2002. ISBN 80-861-1948-3.
- [11] KOTEK, Zdeněk. *Kybernetika*. Praha: SNTL, 1990. ISBN 80-030-0584-1.
- [12] KROPÁČ, Jiří. *Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady*. Brno: Vysoké učení technické v Brně, 2007. ISBN 978-80-214-3295-6.
- [13] MUNAKATA, Toshinori. *Fundamentals of the new artificial intelligence: neural, evolutionary, fuzzy and more*. 2nd ed. London: Springer, c2008. ISBN 978-184-6288-395.
- [14] MURPHY, John J. *Technical analysis of the financial markets: a comprehensive guide to trading methods and applications*. New York: New York Institute of Finance, c1999. ISBN 07-352-0066-1.
- [15] PERSON, John L. *A complete guide to technical trading tactics: how to profit using pivot points, candlesticks*. Hoboken, N.J.: J. Wiley, c2004. ISBN 04-715-8455-X.
- [16] REJNUŠ, O. *Cenné papíry a burzy*. 2. přepracované vyd. Brno: CERM, 2013, 406 s. ISBN 978-80-214-793-703-1
- [17] REJNUŠ, O. *Finanční trhy*. 3., rozš. vyd. Ostrava: KeyPublishing, 2011, 689 s. KeyPublishing. ISBN 978-80-7418-128-3.
- [18] RHEA, Robert. *The Dow theory: an explanation of its development and an attempt to define its usefulness as an aid in speculation*. New York: Barron's, 1932.
- [19] RYAN, Bob. *Finance and accounting for business*. 2nd ed. London: Soth-Western/Cengage Learning, 2008. ISBN 978-184-4808-977.
- [20] SOLTERO, Francisco J., Diego J. BODAS-SAGI, Pablo FERNÁNDEZ-BLANCO, J. Ignacio HIDALGO a Francisco FERNÁNDEZ-DE-VEGA. Optimization of technical indicators in real time with multiobjective evolutionary algorithms. *Proceedings of the fourteenth international conference on Genetic and evolutionary computation conference companion - GECCO Companion '12*. New York, New York, USA: ACM Press, 2012, ,

- 1535-. DOI: 10.1145/2330784.2331033. ISBN 9781450311786. Dostupné také z: <http://dl.acm.org/citation.cfm?doid=2330784.2331033>
- [21] THE MATHWORKS. MATLAB – *Neural Network Toolbox* – User's Guide. The MathWorks, Inc. 2010.
- [22] VÍŠKOVÁ, Hana. *Technická analýza akcií*. Praha: HZ Systém, 1997. ISBN 80-860-0913-0.
- [23] WANG, Feng, Keren DONG a Xiaotie DENG. Algorithmic trading system: design and applications. *Frontiers of Computer Science in China*. 2009, 3(2), 235-246. DOI: 10.1007/s11704-009-0030-6. ISSN 1673-7350. Dostupné také z: <http://link.springer.com/10.1007/s11704-009-0030-6>
- [24] Zákon č. 89/2012 Sb., občanský zákoník §514 ze dne 3. února 2012
- [25] Zákon č. 539/1992 Sb., o puncovníctví a zkoušení drahých kovů (puncovní zákon) ze dne 4. Listopadu 1992
- [26] ZEMAN, Václav a Tomáš MELUZÍN. *Bankovníctví: studijní text pro kombinovanou formu studia*. Brno: Akademické nakladatelství CERM, 2006. ISBN 80-214-3255-1.

SEZNAM INTERNETOVÝCH ZDROJŮ

- [27] *Bloomberg* [online]. U.S.: Bloomberg L.P., 2016 [cit. 2016-05-22]. Dostupné z: <http://www.bloomberg.com/quote/SPX:IND>
- [28] Česká Národní Banka. *Česká Národní Banka* [online]. Praha: ČNB, 2016 [cit. 2016-05-14]. Dostupné z: <http://www.cnb.cz/cs/obecne/slovník/f.html>
- [29] Česká Národní Banka. *Česká Národní Banka* [online]. Praha: ČNB, 2016 [cit. 2016-05-17]. Dostupné z: <http://www.cnb.cz/cs/obecne/slovník/l.html>
- [30] *Ew-forecast.com* [online]. Slovinsko: ew-forecast.com, 2016 [cit. 2016-05-19]. Dostupné z: <http://www.ew-forecast.com/theory/>
- [31] *Investopedia.com* [online]. U.S.: Investopedia, LLC, 2016 [cit. 2016-05-26]. Dostupné z: <http://www.investopedia.com/terms/c/contractfordifferences.asp>
- [32] *Stock Charts* [online]. U.S.: StockCharts.com, Inc., 2016 [cit. 2016-05-19]. Dostupné z: http://stockcharts.com/school/doku.php?id=chart_school

- [33] *MetaQuotes Language 4* [online]. Limassol: MQL5 Ltd., 2000 [cit. 2016-05-17]. Dostupné z: <https://docs.mql4.com/>
- [34] *MetaTrader 4* [online]. Limassol: MetaQuotes Software Corp., 2016 [cit. 2016-05-21]. Dostupné z: <http://www.metatrader4.com/en/download>
- [35] *MetaTrade 4 Forex trading platform* [online]. Limassol: MetaQuotes Software Corp., 2000 [cit. 2016-05-17]. Dostupné z: <http://www.metatrader4.com/en/trading-platform>
- [36] *Yahoo! Finance* [online]. U.S.: Yahoo!, 2016 [cit. 2016-05-21]. Dostupné z: <http://finance.yahoo.com/>

SEZNAM ZKRATEK A SYMBOLŮ

BB	- Bollinger Bands
CFD	- Contract of difference
C++	- Multiparadigmatický programovací jazyk
CySEC	- Cyprus Securities and Exchange Commission
ČNB	- Česká národní banka
DAX	- Deutscher Aktien-Index 30
EMA	- Exponential moving average
FTSE	- Financial Times Stock Exchange 100
FX	- Forex
GG	- Goldenburg Grupe LTD.
MACD	- Moving Average Convergence Divergence
MQL	- MetaQuotes Language
MT	- MetaTrader
NIKKEI	- Nihon Keizai Shimbun
NYSE	- New York Stock Exchange
OHLC	- open, high, low, close
RSI	- Relative Strength Index
SMA	- Simple moving average
S&P	- The Standard & Poor's 500

SEZNAM OBRÁZKŮ

Obrázek 2.1.1-1: Finanční trh [16], str. 54	11
Obrázek 2.1.1-2: Trh cenných papírů [16], str. 58	11
Obrázek 2.3.1-1: Svíčkový graf [28]	17
Obrázek 2.3.1-2: Dowova teorie určení trendu [28]	18
Obrázek 2.3.1-3: Rozklad Elliottových vln [27]	20
Obrázek 2.3.1-4: Podpora a odpor [20]	21
Obrázek 2.3.1-5: Trendové linie [20]	21
Obrázek 2.3.1-6: Trendové kanály [20]	21
Obrázek 2.3.1-7: Hlava a ramena [20]	22
Obrázek 2.3.1-8: Dvojitý a trojitý vrchol a dno [20]	23
Obrázek 2.3.1-9: Vzestupný a sestupný trojúhelník [20]	23
Obrázek 2.3.1-10: Rostoucí a klesající vlajka [20]	24
Obrázek 2.3.3-1: Portfolio MetaQuotes Software Corp. [31]	26
Obrázek 2.5.1-1: Jednovrstvá neuronová síť [4]	28
Obrázek 2.5.1-2: Aktivační funkce [4]	29
Obrázek 2.5.1-3: Schéma vícevrstvé neuronové sítě [4]	29
Obrázek 2.5.2-1: Schéma reprodukce genetického algoritmu [4]	31
Obrázek 4.1.2-1: Příkazové okno [vlastní zpracování]	42
Obrázek 4.1.2-2: Proces učení neuronové sítě [vlastní zpracování]	43
Obrázek 4.1.2-3: Výstup predikčního modelu v grafu 1 [vlastní zpracování]	44
Obrázek 4.1.2-4: Výstup predikčního modelu v grafu 2 [vlastní zpracování]	44
Obrázek 4.1.2-5: Příkazové okno konec [vlastní zpracování]	45
Obrázek 4.1.3-1: Pracovní plocha prostředí Matlab [vlastní zpracování]	47
Obrázek 4.2.1-1: Graf vývoje ceny se vstupem a výstupem [vlastní zpracování]	56
Obrázek 4.2.2-1: Spuštění automatického obchodního systému [vlastní zpracování]	57

SEZNAM TABULEK

Tabulka 4.1.1-1: Vstupní data [vlastní zpracování].....	38
Tabulka 4.1.1-2: Délka vstupních dat [vlastní zpracování]	39
Tabulka 4.1.1-3: Počet neuronů ve skryté vrstvě [vlastní zpracování].....	41

SEZNAM GRAFŮ

Graf 4.1.1-1: Profit v závislosti na složení vstupních dat [vlastní zpracování]	38
Graf 4.1.1-2: Profit v závislosti na délce vstupních dat [vlastní zpracování]	40
Graf 4.1.1-3: Profit v závislosti na počtu neuronů ve vrstvě [vlastní zpracování]	41
Graf 4.1.4-1: Úspěšnost predikčního modelu [vlastní zpracování]	52
Graf 4.1.4-2: Porovnání zisků predikčního modelu [vlastní zpracování]	52
Graf 4.2.3-1: Srovnání zisků obchodního systému [vlastní zpracování]	58

SEZNAM PŘÍLOH

Příloha 1. PredictPryce.m.....	CD
Příloha 2. yahooDataFetcherSPY.m.....	CD
Příloha 3. PredyctPrice_system.mq4.....	CD
Příloha 4. PredyctPrice_system.ex4.....	CD