

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



ŠTATISTICKÁ ÚSPEŠNOSŤ PREDIKCIE TRHOV
MATEMATICKÝMI METÓDAMI TECHNICKEJ ANALÝZY

DIPLOMOVÁ PRÁCA

2015

Bc. Ján ŠAUŠA

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**ŠTATISTICKÁ ÚSPEŠNOSŤ PREDIKCIE TRHOV
MATEMATICKÝMI METÓDAMI TECHNICKEJ
ANALÝZY**

DIPLOMOVÁ PRÁCA

Študijný program: Ekonomická a finančná matematika
Študijný odbor: 1114 Aplikovaná matematika
Školiace pracovisko: Katedra aplikovanej matematiky a štatistiky
Vedúci práce: RNDr. Igor Odrobina, CSc.

Bratislava 2015

Bc. Ján ŠAUŠA



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Ján Šauša
Študijný program: ekonomická a finančná matematika (Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: 9.1.9. aplikovaná matematika
Typ záverečnej práce: diplomová
Jazyk záverečnej práce: slovenský

Názov: Štatistická úspešnosť predikcie trhov matematickými metódami technickej analýzy / *Veracity of market predictions made by the mathematical methods of the technical analysis*

Cieľ: Úlohou práce bude posúdiť štatistickú úspešnosť predikcie niektorých zo základných matematických metód technickej analýzy. Kvalita metódy bude posudzovaná aj v závislosti od dĺžky časového intervalu. Metódy budú tiež posudzované z hľadiska použitia pri algoritmickej obchodovaní.

Vedúci: RNDr. Igor Odrobina, CSc.
Katedra: FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky
Vedúci katedry: prof. RNDr. Daniel Ševčovič, CSc.
Dátum zadania: 29.01.2014

Dátum schválenia: 10.02.2014
prof. RNDr. Daniel Ševčovič, CSc.
garant študijného programu

.....
študent

.....
vedúci práce

Pod'akovanie

Touto cestou sa chcem poďakovať svojmu vedúcemu diplomovej práce RNDr. Igorovi Odrobinovi, CSc. za cenné rady a pripomienky, ochotu, tpezlivosť a usmernenie pri jej vypracovaní.

Abstrakt

ŠAUŠA, Ján: *Štatistická úspešnosť predikcie trhov matematickými metódami technickej analýzy* [Diplomová práca], Univerzita Komenského v Bratislave, Fakulta matematiky, fyziky a informatiky, Katedra aplikovanej matematiky a štatistiky; školiteľ: RNDr. Igor Odrobina, CSc., Bratislava, 2015, 61 s.

Diplomová práca je venovaná téme štatistickej úspešnosti predikcie trhov matematickými metódami technickej analýzy. Zaoberá sa štatistickými metódami na vyhodnocovanie úspešnosti obchodných pravidiel založených na princípoch technickej analýzy. V teoretickej časti si predstavíme základné predpoklady technickej analýzy a poukážeme na jej výhody a nevýhody. Zadefinujeme si objektívne matematické metódy technickej analýzy. Pomocou technických indikátorov – kľzavých priemerov, MACD a RSI indikátora si zostavíme obchodné pravidlá. Výnosnosť týchto pravidiel budeme spätne testovať na historických dátach vybraného akciového indexu. Štatistickým prístupom k danej problematike budeme následne testovať štatistickú významnosť dosiahnutých výnosov pravidla. Použijeme pri tom metódu Monte Carlo Permutácie a bootstrap metódu. Spätne testovanie bude prebiehať pomocou nami naprogramovanej počítačovej aplikácie. Cieľom práce bude vyhodnotiť, ktoré pravidlá technickej analýzy môžu byť užitočné pri predikcii trhov.

Kľúčové slová: technická analýza, obchodné pravidlá, štatistická významnosť, späté testovanie

Abstract

ŠAUŠA, Ján: *Veracity of market predictions made by the mathematical methods of the technical analysis* [Diploma Thesis], Comenius University in Bratislava, Faculty of Mathematics, Physics and Informatics, Department of Applied Mathematics and Statistics; Supervisor: RNDr. Igor Odrobina, CSc., Bratislava, 2015, 61 p.

This thesis is dedicated to statistical success of market predictions made by the mathematical methods of technical analysis. It deals with statistical methods for evaluating trading rules based on the principles of technical analysis. In the theoretical part we will introduce the basic assumptions of technical analysis and point out its advantages and disadvantages. We define objective mathematical methods of technical analysis. Using technical indicators – moving averages, MACD and RSI indicator we define trading rules. Returns of these rules, will be back-tested on historical data of selected stock index. With statistical approach we will make statistical significance tests of achieved rule returns. We will use Monte Carlo permutation and bootstrap method. Back-testing will be carried out by using a programmed computer applications. The aim of the thesis is evaluation of trading rules in order to decide which rules of technical analysis may be useful in predicting markets.

Keywords: technical analysis, trading rules, statistical significance, back-testing

Obsah

Obsah	6
Úvod.....	8
1 Úvod do technickej analýzy	10
1.1 Predpoklady technickej analýzy.....	10
1.1.1 Trh všetko diskontuje.....	10
1.1.2 Ceny sa pohybujú v trendoch.....	11
1.1.3 História sa opakuje.....	12
1.2 Porovnanie technickej a fundamentálnej analýzy	12
1.2.1 Makroekonomická analýza	13
1.2.2 Odvetvová analýza	13
1.2.3 Mikroekonomická analýza	13
1.3 Silné a slabé stránky technickej analýzy	14
1.3.1 Kritika technickej analýzy	15
1.3.2 Obhajoba technickej analýzy.....	17
2 Matematické metódy technickej analýzy	20
2.1 Kľzavé priemery	21
2.1.1 Jednoduchý kľzavý priemer SMA	22
2.1.2 Lineárne vážený kľzavý priemer WMA.....	23
2.1.3 Exponenciálny kľzavý priemer EMA	23
2.2 Moving average convergence-divergence MACD.....	24
2.3 Relative strength index RSI	25
3 Obchodné pravidlá.....	27
3.1 Definovanie obchodných pravidiel	27
3.2 Binárne obchodné pravidlá	28
3.3 Generovanie obchodných signálov	28
3.3.1 Identifikovanie trendu.....	28
3.3.2 Prechody hraníc	30

3.4	Inverzné obchodné pravidlá	32
3.5	Výpočet výnosov pravidla.....	33
4	Štatistické testovanie významnosti pravidla.....	35
4.1	Bootstrap metóda	38
4.2	Monte Carlo permutácia.....	40
5	Praktická časť práce.....	43
5.1	Počítačová aplikácia.....	43
5.2	Použité vstupné dáta a parametre	45
6	Výsledky.....	48
6.1	Výsledky pre pravidlo prekríženia kľzavého priemeru s Close cenou.....	49
6.2	Výsledky pre pravidlo prekríženia dvoch kľzavých priemerov	50
6.3	Výsledky pre pravidlá prechodov hraníc	50
6.4	Celkové porovnanie pravidiel	51
6.5	Nedostatky nášho výskumu.....	54
6.6	Výhody nášho výskumu	55
	Záver	57
	Zoznam použitej literatúry.....	59
	Zoznam Obrázkov, Tabuliek a grafov	60
	Zoznam príloh na CD	61

Úvod

Finančné trhy ponúkajú v dnešnej dobe široké spektrum možností ako investovať svoje voľné finančné prostriedky a sú motiváciou pre ľudí snažiacich sa zbohatnúť. Počas histórie sa vyvíjalo niekoľko prístupov, ktoré by dávali investorom návod ako prísť na finančných trhoch k zisku. Jedným z takýchto prístupov je aj technická analýza. Jej základným princípom je na základe študovania historických cien o obchodovaného objemu daného aktíva robiť predpovede o budúcom cenovom vývoji. V tejto diplomovej práci sa budeme zaoberať jej matematickými metódami, ktoré by nám mohli takéto predikcie o budúcich cenových pohyboch na trhoch dávať. Cieľom práce bude nájsť také metódy, u ktorých bude úspešnosť predikcií štatisticky podložená.

V prvej časti práce si predstavíme základné princípy technickej analýzy a porovnáme ju s ďalším významným typom investičnej analýzy – fundamentálnou analýzou. Budeme sa snažiť poukázať na rozdiely, ktoré hovoria o výhodách použiteľnosti technickej analýzy ako nástroja na predpovedanie cenových pohybov. Poukážeme aj na jej nedostatky argumentmi teórie efektívnych trhov, ktorá použiteľnosť technickej analýzy spochybňujeme. Následne sa budeme snažiť uviesť protiargumenty, ktoré hovoria v prospech technickej analýzy. V druhej kapitole si zadefinujeme matematické metódy technickej analýzy. Popíšeme si niektoré vybrané technické indikátory, ktoré technickí analytici používajú pri tvorbe svojich obchodných stratégií. V tretej časti práce si zadefinujeme na základe týchto indikátorov obchodné pravidlá, ktoré nám budú signalizovať kedy a akú pozíciu máme na trhu zaujať. Tieto obchodné pravidlá budeme následne spätne testovať na historických dátach vybraného akciového indexu. Na to aby sme posúdili, do akej miery sú zisky dosiahnuté našimi obchodnými pravidlami významné, použijeme štatistický prístup. Popíšeme si testy štatistickej významnosti, ktoré nám pomôžu naše výnosy štatisticky ohodnotiť. Použijeme pri tom dve metódy – Monte Carlo premutácie a bootstrap metódu.

V praktickej časti našej práce pomocou naprogramovanej počítačovej aplikácie následne tieto metódy aplikujeme a vyhodnotíme výsledky. Cieľom práce bude uplatniť štatistický

prístup k danej problematike a vhodným nastavením vstupných parametrov do našich indikátorov nájsť pravidlá, ktoré by mali predpoklad, že nám budú dávať úspešné predikcie aj v budúcnosti.

1 Úvod do technickej analýzy

Technická analýza je študovanie historického vývoja cien a obchodovaného objemu finančných inštrumentov s cieľom predpovedať ich budúci pohyb arobiť na základe toho ziskové investičné alebo obchodné rozhodnutia¹. V tejto kapitole si popíšeme základné predpoklady, na ktorých je technická analýza postavená a porovnáme ju s princípmi fundamentálnej analýzy. Následne poukážeme na silné a slabé stránky technickej analýzy.

1.1 Predpoklady technickej analýzy

Technická analýza je postavená na týchto troch základných predpokladoch²:

- 1.) Trh všetko diskontuje.
- 2.) Ceny sa pohybujú v trendoch.
- 3.) História sa opakuje.

1.1.1 Trh všetko diskontuje

Prvým základným predpokladom technickej analýzy je tvrdenie, že trh všetko diskontuje. Tento predpoklad tvrdí, že všetko, čo môže nejakým spôsobom ovplyvniť cenu nejakého finančného inštrumentu na trhu, je už v tejto cene vyjadrené. Všetky dostupné fundamentálne faktory, akými sú napr. hospodárske a politické informácie, ale aj psychologické faktory, akými sú nálady a očakávania investorov, sú zahrnuté do aktuálnych cien na trhu. Preto nie je dôležité uvažovať o týchto faktoroch, ale stačí sa zameriavať len na sledovanie vývoja cien. Inými slovami, technickí analytici tým v skutočnosti tvrdia, že pohyby trhových cien len reflektujú ponuku a dopyt na trhu. Základná ekonomická teória hovorí, že keď dopyt prevyšuje ponuku, ceny by mali rásť a naopak, keď ponuka prevyšuje dopyt, ceny by mali klesať. Podľa tejto Murphyho úvahy³, technickí analytici interpretujú toto tvrdenie obrátene: ak ceny z akéhokoľvek dôvodu rastú, dopyt musí prevyšovať ponuku a keď ceny klesajú, ponuka musí prevyšovať dopyt. Nepriamo tak tým naozaj študujú fundamentálne faktory.

¹ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 3

² MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 2

³ MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 2-3

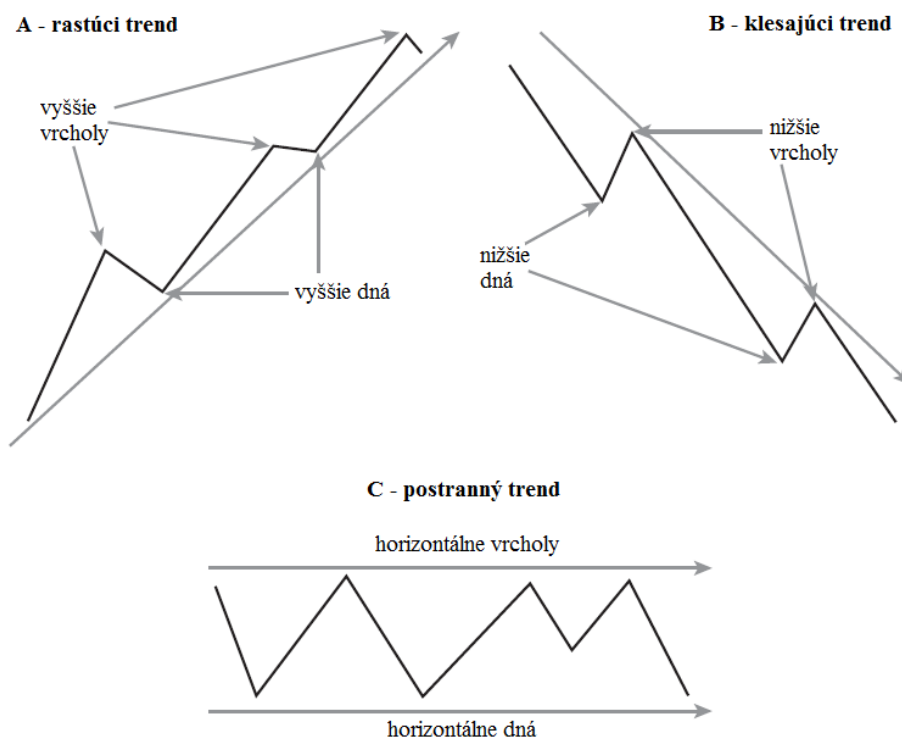
1.1.2 Ceny sa pohybujú v trendoch

Ďalším zo základných troch predpokladov technickej analýzy je tvrdenie, že ceny finančných inštrumentov sa pohybujú v trendoch. Podľa smeru trendu sa rozlišujú 3 základné typy trendov:

- a) Rastúci trend (býčí trend)
- b) Klesajúci trend (medvedí trend)
- c) Postranný trend

Teoretickú konštrukciu trendu si ilustrujeme na Obr. 1. Rastúci trend (Obr. 1 - A) vzniká, keď ceny dosiahnu vyššie vrcholy oproti predchádzajúcim vrcholom a vyššie dná oproti predchádzajúcim dnám. Naopak, klesajúci trend (Obr. 1 - B) vzniká, keď ceny dosiahnu nižšie vrcholy oproti predchádzajúcim vrcholom a nižšie dná oproti predchádzajúcim dnám. V niektorých publikáciách sa môžeme stretnúť aj s pojmom postranný trend, ktorý v podstate vyjadruje situáciu, keď sa ceny pohybujú horizontálne a žiadny výrazný rastúci alebo klesajúci trend nenastáva (Obr. 1 - C).⁴

Obrázok 1 - Základné typy trendov



Zdroj: KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 11, upravené

⁴ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 11

Podľa predpokladu technickej analýzy sa ceny pohybujú v jednom z uvedených trendov a po vytvorení trendu majú tendenciu v ňom určitú dobu zotrvať.⁵ Snahou technických analytikov je pomocou určitých grafických metód a technických indikátorov takýto trend včas rozpoznať a premeniť ho na ziskovú príležitosť.⁶

1.1.3 História sa opakuje

Tretí predpoklad technickej analýzy je založený na idey, že napriek tomu, že finančné trhy sa menia, správanie sa investorov a ich reakcie na zmeny a vývoj na finančných trhoch sa počas histórie opakujú alebo sa podobajú predošlým reakciám na podobný vývoj na trhoch v minulosti. Inými slovami psychika ľudí sa nemení a ľudia sa budú správať podobne ako sa správali v minulosti za podobných okolností. Toto podobné správanie vysvetľujú technickí analytici pomocou grafických vzorov, na základe ktorých predpovedajú budúci vývoj cien na trhoch.⁷

1.2 Porovnanie technickej a fundamentálnej analýzy

V nasledovnej časti diplomovej práce si predstavíme ďalší dôležitý typ investičnej analýzy – fundamentálnu analýzu. Popíšeme jej charakteristiky a porovnáme ich s technickou analýzou. Poukážeme na niektoré výhody technickej analýzy oproti fundamentálnej analýze.

Podľa Chovancovej⁸ podstatou fundamentálnej analýzy je dať analytikovi odpoveď na otázku, do akej miery trhovú cenu akcie zodpovedá jej vnútornej hodnote. Zástancovia fundamentálnej analýzy vychádzajú z predpokladu, že trhovú cenu len osciluje okolo svojej vnútornej hodnoty. Snažia sa teda určiť, či je akcia podhodnotená (jej trhovú cenu je nižšia ako jej vnútorná hodnota) a oplatí sa ju kúpiť alebo či je akcia nadhodnotená (jej trhovú cenu je vyššia ako jej vnútorná hodnota) a oplatí sa ju predat'. Fundamentálna analýza pritom spracováva množstvo trhových informácií, ktoré majú podľa fundamentálnych analytikov na vnútornú hodnotu akcie vplyv. Podľa toho na akej úrovni sú tieto informácie spracovávané, sa delí fundamentálna analýza na makroekonomickú, odvetvovú a mikroekonomickú analýzu.

⁵ MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 3-4

⁶ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 11

⁷ MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 4-5

⁸ CHOVANCOVÁ, B. et al.: Finančné trhy - nástroje a transakcie, str. 454-504

1.2.1 Makroekonomická analýza

Na makroekonomickej úrovni skúma fundamentálna analýza ukazovatele ako napr. rast HDP, fiškálnu politiku, ponuku peňazí, úrokové sadzby, mieru nezamestnanosti, mieru inflácie, ekonomické a politické šoky a iné. Snahou obchodníka je po zverejnení týchto informácií odhadnúť vnútornú hodnotu určitej akcie a podľa toho sa rozhodnúť, či sa danú akciu oplatí zakúpiť alebo predat.

1.2.2 Odvetvová analýza

Na odvetvovej úrovni prebieha analýza odvetvia, v ktorom pôsobí spoločnosť, do ktorej akcií chce obchodník investovať. Analýza sa zameriava na vplyvy fáz hospodárskeho cyklu na výkonnosť jednotlivých odvetví. Z tohto hľadiska môžeme odvetvia rozdeliť na cyklické, anticyklické a neutrálne. Cyklické odvetvia kopírujú hospodársky cyklus a ich produkcia rastie najmä v čase ekonomického rozmachu. V čase recesie, naopak, ich produkcia klesá kvôli nízkemu odbytú v dôsledku nízkeho dopytu zo strany spotrebiteľov, čo má i negatívny vplyv na ceny akcií. Patria sem odvetvia ako automobilový priemysel, stavebníctvo, predmety dlhodobej spotreby a pod. Anticyklické odvetvia vykazujú dobré výsledky v období hospodárskej recesie a zaradiť sem môžeme napr. televíziu a noviny, prípadne rôzne zdroje náhrady zábavy pri finančne náročnejších iných druhoch zábavy (hracie automaty, stávkové kancelárie a iné). Neutrálne odvetvia nie sú veľmi ovplyvňované zmenami ekonomických cyklov v dôsledku ich nižšej cenovej elasticity (tovary nevyhnutnej dennej spotreby ako potraviny, lieky, ale aj napr. alkohol, cigarety a pod.).

1.2.3 Mikroekonomická analýza

Mikroekonomická úroveň sa zameriava už na analýzu samotnej spoločnosti a porovnanie vnútornej hodnoty akcie s jej trhovou cenou na základe rôznych ukazovateľov vypočítaných napr. z finančných výkazov danej spoločnosti.⁹

Z tohto hľadiska by sme medzi výhody technickej analýzy mohli zaradiť to, že požaduje menej informácií v porovnaní s fundamentálnou analýzou. Zatiaľ čo fundamentálna analýza vyžaduje študovanie aktuálnych makroekonomických správ, analyzovanie hospodárskych odvetví a finančných výkazov, technický analytik získava všetky informácie, ktoré potrebuje, z historických dát. Otázka správneho načasovania, kedy do

⁹ CHOVANCOVÁ, B. et al.: Finančné trhy - nástroje a transakcie, str. 454-504

obchodu vstúpiť, je tak pri použití technickej analýzy podstatne jednoduchšia. Ďalšou svetlou stránkou technickej analýzy je jej použiteľnosť na rôznych typoch trhov. Kým fundamentálna analýza býva rozšíreným nástrojom hlavne na akciových trhoch, rovnaké metódy technickej analýzy môžu byť aplikované pri obchodovaní na rozličných trhoch, či už na akciovom, komoditnom trhu, na Forexe pri obchodovaní s cudzími menami, atď. Investičná stratégia založená na fundamentálnej analýze sa väčšinou vyznačuje ako dlhodobá investičná stratégia kúpy a držania (angl. Buy & Hold). Technická analýza môže byť aplikovaná na rôzne dlhé časové horizonty investovania, pričom skôr hovoríme o obchodovaní ako o investovaní. Z hľadiska doby, počas ktorej sú držané pozície pri obchodovaní, uvidíme nasledovné delenie:

Tabuľka 1 - Štýly obchodovania v závislosti od doby držania pozície

Štýl obchodovania	Časový horizont	Doba držania pozície
Pozičné obchodovanie	dlhodobý	mesiace až roky
Swingové obchodovanie	krátkodobý	dni až týždne
Denné obchodovanie	krátkodobý	v rámci jedného dňa
Scalping	extrémne krátkodobý	sekundy až minúty

Zdroj: FOLGER, J., LEIBFARTH, L.: Make Money Trading, str. 5, upravené

1.3 Silné a slabé stránky technickej analýzy

Zatiaľ čo technická analýza je veľmi rozšíreným a populárnym nástrojom medzi praktikmi, na akademickej úrovni čelí často kritike. Hlavnou vedeckou teóriou, s ktorou je technická analýza v rozpore, je teória efektívnych trhov (angl. Efficient market hypothesis – EMH). V tejto časti práce si uvedieme základné argumenty tejto teórie, ktoré stoja proti technickej analýze a poukážeme tým na jej slabé stránky. Následne uvedieme protiargumenty na obhajobu použiteľnosti technickej analýzy. Podrobné rozoberanie tejto problematiky by bolo nad rámec nášho stanoveného cieľa diplomovej práce a zaslúžilo by si spracovanie v samostatnej téme, preto uvedieme len základné rozdiely.

1.3.1 Kritika technickej analýzy

Teória efektívneho trhu, ktorú rozvinul vo svojej práci Eugene Fama v 60-tych rokoch minulého storočia, tvrdí, že v akomkoľvek časovom okamihu trhové ceny plne odrážajú všetky dostupné informácie. Z toho vyplýva, že aktuálne ceny na trhu budú dobrým odhadom ich vnútornej hodnoty a žiadnou investičnou stratégiou tak nie je možné „poraziť“ trh. Základom je teória súťaživých trhov, ktorá hovorí, že arbitrážni obchodníci medzi sebou na trhu neustále súperia a ich ziskový motív vytvára efektívny trh. Ako náhle sa objaví nová informácia na finančnom trhu, všetkými investormi bude okamžite ocenená, investori zareagujú racionálne a cenu akcie dostanú na jej novú vnútornú hodnotu. Trhová cena môžu náhodne fluktuovať okolo svojej vnútornej hodnoty, arbitrážni obchodníci ju vždy svojim obchodovaním dostanú späť na jej vnútornú hodnotu a trhová cena tak bude v ekvilibriu s jej vnútornou hodnotou. Takýto trh je potom efektívny.¹⁰

Ďalej podľa teórie náhodnej prechádzky (angl. Random walk Hypothesis – RWH) sú cenové zmeny navzájom nezávislé a preto história cien nie je spoľahlivým nástrojom na predikciu budúcich pohybov na trhu. Pohyb cien je náhodný a nedá sa predpovedať.¹¹

Hoci predpoklad, že trhové ceny plne odrážajú všetky dostupné informácie je veľmi blízko tvrdeniu technickej analýzy, že trh všetko diskontuje, rozdiel je v tom ako rýchlo je táto informácia premietnutá do ceny. Podľa technickej analýzy je informácia diskontovaná v cene už dávno predtým, než sa stala známou. Keďže podľa EMH trh zahŕňa novú informáciu okamžite, nie je tu tým pádom možnosť získať z poznatku tejto informácie akúkoľvek výhodu.¹²

V rôznej literatúre sa môžeme stretnúť s rôznymi definíciami efektívneho trhu. Uvedieme delenie podľa Veselej¹³, ktorá popisuje 3 typy efektívnosti:

a) Informačná efektívnosť

O informačnej efektívnosti hovoríme vtedy, keď trhové ceny okamžite reagujú na všetky možné dostupné informácie.

¹⁰ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 41

¹¹ MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 19

¹² MURPHY, J. J.: Technical Analysis of the Financial Markets, str. 21

¹³ VESELÁ, J.: Analýza trhu cenných papírů, str. 234-236

b) Alokačná efektívnosť

Alokačná efektívnosť je dosiahnutá v prípade, že finančné zdroje sú na trhu alokované tak, že je splnený predpoklad ich maximálneho možného využitia. Inými slovami, všetky voľné prostriedky sú investované v cenných papieroch a investorom prinášajú čo najvyšší možný výnos prispôsobený ich averzii k riziku.

c) Operatívna efektívnosť

Operatívna efektívnosť nastáva na trhu vtedy, keď sú transakčné náklady na takej úrovni, pri ktorej nie je možnosť dosahovať nadpriemerné zisky ani poskytovateľmi investičných služieb (akými sú napr. brokeri a dealeri).

Forma efektívnosti môže byť nadobudnutá v týchto troch podobách:¹⁴

a) Slabá forma efektívnosti

Pri slabej forme efektívnosti sú v trhových cenách obsiahnuté všetky informácie, ktoré je možné získať zo súboru historických dát. Preto robiť akékoľvek prognózy budúceho vývoja cien z historických dát nie je možné a cenové pohyby sú náhodné. V analýzach je preto potrebné vychádzať z aktuálnych dát a technická analýza tým pádom stráca svoje opodstatnenie.

b) Stredne silná forma efektívnosti

Pri stredne silnej forme efektívnosti aktuálne trhové ceny obsahujú nielen historické dáta, ale aj aktuálne verejné informácie. Pri tejto forme efektívnosti nie je možné na trhu nájsť nesprávne ocenené (nadhodnotenú alebo podhodnotenú) akcie. V tomto prípade stráca význam nielen technická ale aj fundamentálna analýza, snažiaca sa nájsť práve takéto akcie, ktorých vnútorná hodnota sa líši od trhovej ceny.

c) Silná forma efektívnosti

Pri silnej forme efektívnosti sú v aktuálnych trhových cenách zahrnuté všetky verejné aj neverejné informácie. Pri tejto forme je vylúčené použitie nielen technickej a fundamentálnej analýzy, ale bezcennými sa stávajú aj zákulisné informácie, ktorými disponujú tzv. insiders (napr. manažéri daných firiem). Ani tieto osoby tým pádom nie sú schopné na finančných trhoch dosiahnuť nadpriemerné zisky.

¹⁴ VESELÁ, J.: Investování na kapitálových trzích, str. 501-530

Ďalšia pragmatická kritika technickej analýzy hovorí, že technická analýza sa sama naplní. Ak všetci investori budú používať rovnaké pravidlá technickej analýzy, tak tieto pravidlá prestanú platiť. Dôsledkom tohto tvrdenia je fakt, že pravidlá technickej analýzy, ktoré fungovali v minulosti, nemusia fungovať v budúcnosti.¹⁵

Ďalším problémom je, že veľa pravidiel technickej analýzy si vyžaduje subjektívne posúdenie. Napr. analyzovanie grafov historických cien a hľadanie v nich obrazcov, ktoré by vedeli predpovedať budúce cenové pohyby, je čisto subjektívna záležitosť a je považovaná kritikmi len za nejaký druh „umenia“ alebo „schopnosti“. Dvaja rôzni technickí analytici pri pohľade na rovnaký graf môžu vyvodiť diametrálne odlišné závery. Na druhej strane, matematické metódy technickej analýzy, ktoré si predstavíme neskôr, sú jasne zadefinované a tým pádom môže byť funkčnosť overená použitím štatistických metód za pomoci výpočtovej techniky.¹⁶

1.3.2 Obhajoba technickej analýzy

Na základe popísaných negatív technickej analýzy môže čitateľ nadobudnúť pocit, že je nepoužiteľná. Na podporu opodstatnenosti technickej analýzy uvedieme spochybnenie niektorých predpokladov EMH.

Prvým problémom EMH je predpoklad racionality investorov. Touto problematikou sa zaoberá vedný odbor behaviorálna ekonómia, ktorá skúma do akej miery vplývajú na investičné správanie a rozhodovanie obchodníka jeho vlastnosti, osobnosť, emócie a rozum. Napr. podľa teórie psychológie davu obchodníci nerealizujú svoje investičné rozhodnutia izolovane, ale vždy v pôsobnosti s ostatnými účastníkmi na trhu. Časť z nich takto vytvára isté zoskupenie nazývané dav. Ak investor tomuto davu podľahne, stráca tak svoje individuálne intelektuálne schopnosti a nasleduje často chybné rozhodnutia ostatných investorov.¹⁷ Rozhodnutia účastníkov trhu závisia od toho akým spôsobom jednotlivci spracovávajú informácie. Výsledky štúdií ukázali nežiaduce iracionálne správanie sa investorov ako napr. vyššie spomenutú stádovitú davu, prílišnú sebadôvera na základe nedostatku informácií, nesprávne posúdenie pravdepodobnosti, nesprávne ohodnotenie

¹⁵ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 51

¹⁶ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 51

¹⁷ CHOVANCOVÁ, B. et al.: Finančné trhy - nástroje a transakcie, str. 531-533

rizika, prehnane dlhé držanie prepadávajúcich sa zakúpených akcií a predčasné predávanie rastúcich akcií pod strachom z realizovania straty a mnohé ďalšie odchýlky v ľudskom rozhodovaní sa v čase neistoty.¹⁸

Hoci EMH pripúšťa, že medzi investormi sú aj iracionálni účastníci, ktorí dostanú trhovú cenu mimo jej vnútornej hodnoty, tieto iracionálne odchýlky sú vyvážené inou skupinou racionálnych arbitrážnych obchodníkov, ktorí dostanú cenu späť na jej vnútornú hodnotu. Tu ale nastáva otázka či arbitráž skutočne dokáže vrátiť ceny do ekvilibría. V praxi totiž nie sú vždy splnené podmienky pre bezrizikovú arbitráž v dôsledku nedostatku likvidity, nedostatku kapitálu, transakčných nákladov a pod. V časoch veľkých pohybov na trhoch a emocionálnej paniky, likvidita často chýba a zvyšuje sa riziko, že otvorené pozície arbitrážnych obchodníkov nebudú môcť byť uzavreté. V prípade, že arbitráž nemusí byť dostupná, trhové ceny sa môžu vyvíjať v trende mimo svojej vnútornej hodnoty bez toho aby boli arbitrážnymi obchodníkmi vrátené späť na túto vnútornú hodnotu. To dáva technickým analytikom príležitosť takýto trend zachytiť.¹⁹

Okrem týchto argumentov možno na finančných trhoch pozorovať aj viaceré anomálie, ktoré spochybňujú niektoré tvrdenia EMH. Príkladom je 19. október 1987, známy aj ako „Čierny pondelok“ (Black Monday), charakterizovaný abnormálnym jednodňovým záporným výnosom. Tomuto prepadu predchádzala séria troch po sebe idúcich poklesov trhu v predchádzajúcich troch obchodných dňoch, ktorá nakoniec vyústila do prepadu trhu o zhruba 30%. Takýmto postupným sériám strát sa zvykne hovoriť aj *drawdowns*. Štúdie, ktoré skúmali pravdepodobnosť nastania takýchto po sebe idúcich prepadov, ukázali, že tieto prepady sa objavujú častejšie ako sú štatisticky predpovedané, čo indikuje to, že musí existovať nejaká korelácia medzi dennými výnosmi akcií a tým pádom sa výnosy nepohybujú náhodne.²⁰

Ďalšou anomáliou vyskytujúcou sa na trhoch je tzv. januárový efekt (angl. "The January Effect"). Týka sa hlavne akcií malých firiem, ktoré počas prvých dvoch januárových týždňov vykazujú nadpriemerné výnosy. Spôsobené je to tým, že investori koncom roku vyhodnocujú výkonnosť svojho portfólia a robia nové investičné stratégie pre ďalšie

¹⁸ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 46-47

¹⁹ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 47-48

²⁰ KIRKPATRICK, CH. D., DAHLQUIST, J.: Technical analysis, str. 37

časové obdobie. Portfólio býva doplňované práve akciami malých firiem. Ďalším príkladom môže byť snaha o daňovú optimalizáciu zámerným realizovaním úmyselných stratových obchodov na konci roku.²¹

Empirické štúdie takisto ukázali, že akcie s nízkymi hodnotami ukazovateľa P/E (angl. price to equity – pomer trhovej ceny akcie ku ziskom spoločnosti pripadajúcim na jednu akciu) sú schopné opakovane prinášať nadpriemerný výnos. Na základe informácie o tomto ukazovateli by teda bolo možné trhové ceny predvídať, čo naznačuje, že trh nie je efektívny.²²

Existuje aj množstvo ďalších argumentov pre a proti technickej analýze. Nami uvedenými porovnaniami sme sa snažili poukázať na základné nedostatky technickej analýzy ako aj na opodstatnenosť jej použitia ako nástroja na predpovedanie budúceho vývoja trhov na základe historických dát.

²¹ VESELÁ, J.: Analýza trhu cenných papírů, str. 318-331

²² VESELÁ, J.: Analýza trhu cenných papírů, str. 318-331

2 Matematické metódy technickej analýzy

V tejto kapitole si popíšeme vybrané matematické metódy, ktoré používa technická analýza na predikovanie trhov a ktorých úspešnosť budeme neskôr testovať aplikovaním štatistických metód. Metódy technickej analýzy môžeme podľa Arronsonovej²³ definície rozdeliť do dvoch základných kategórií, ktorými sú subjektívne a objektívne metódy.

Ako ďalej uvádza tento autor, subjektívne metódy technickej analýzy nie sú jasne definované a ich analýza je založená na individuálnej interpretácii obchodníka. Rôzni obchodníci používajúci ich na rovnakých dátach, môžu dosiahnuť rozdielne výsledky. Tým pádom nevieme zaručiť, či dávajú spoľahlivé predikcie o budúcom vývoji. Subjektívne metódy nedávajú možnosť ich algoritmizácii, spätnému testovaniu a objektívnemu vyhodnoteniu ich úspešnosti. Inými slovami, nie je možné potvrdiť ani vyvrátiť ich efektívnosť objektívnym prístupom. Do tejto kategórie spadá rozpoznávanie rôznych obrazcov v grafoch historických dát ako sú napr. známe trendové čiary, hlava a ramená, vlajky, trojuholníky a mnohé ďalšie. V tejto práci sa preto týmto metódam nebudeme bližšie venovať.

Objektívne metódy technickej analýzy sú naopak jednoznačne definované procedúry, ktoré dávajú jasné signály, kedy a akú pozíciu má obchodník na trhu zaujať. Sú založené na matematických a logických algoritmoch, vďaka čomu môžu byť spätne testované na historických dátach. Výsledky dosiahnuté spätným testovaním môžu byť následne vyhodnotené štatistickými metódami.²⁴ Obchodovaniu na základe takýchto vopred zadaných matematických a logických algoritmov, ktoré môžu byť implementované pomocou počítačových programov, sa hovorí aj algoritmické obchodovanie.²⁵

Nástrojmi technickej analýzy, ktoré sú založené na objektívnej technickej analýze sú tzv. technické indikátory. Podľa definície prevzatej od J.Folger²⁶, technické indikátory sú nástroje ponúkajúce obchodníkovi náhľad na rôzne pohyby cien na trhoch. Väčšinou sú založené na matematických vzorcoch spracovávajúcich rôzne údaje napr. o cene alebo

²³ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 5-6

²⁴ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 5-6

²⁵ ALDRIDGE, I.: High Frequency Trading, str. 15-26

²⁶ FOLGER, J., LEIBFARTH, L.: Make Money Trading, str. 120-121

objeme obchodovaných aktív na trhu. Pomáhajú obchodníkovi určiť situáciu na trhu a môžu slúžiť na vytvorenie jeho obchodnej stratégie. Základné delenie technických indikátorov je podľa J.Folger²⁷ na:

- a) **Trendové indikátory** - merajú smer a silu trendu. Medzi najpoužívanejšie patria napr. kľzavé priemery, MACD (moving average convergence-divergence)
- b) **Momentum indikátory** – merajú rýchlosť akou sa ceny na trhu menia porovnávaním cenových zmien v čase. Do tejto kategórie sa zaraďujú napr.: RSI (relative strength index), Stochastic indikátor
- c) **Objemové indikátory** – reprezentujú množstvo aktivity obchodníkov na trhu. Najznámejšími sú: OBV (On balance volume), MFI (Money flow index)
- d) **Indikátory založené na volatilitate** – merajú rýchlosť a veľkosť cenových výkyvov smerom nahor a nadol. Patria sem napr. Bolinger bands, CCI (commodity channel index)

V nasledujúcej časti si popíšeme nami vybrané technické indikátory, ktoré budeme používať na predpovedanie budúcich cenových pohybov na trhu. Budú to: kľzavé priemery, MACD a RSI indikátor.

2.1 Kľzavé priemery


Kľzavé priemery (angl. skr. MA – moving averages) sú jedným z najčastejšie používaných typov technických indikátorov. Sú to priemery pohybujúcej sa podmnožiny hodnôt časového radu vypočítané za určitý počet dní. Vstupným parametrom pre výpočet kľzavého priemeru je časový rad napr. cien alebo obchodovaného objemu a počet dní n , za ktorý budeme kľzavý priemer počítať. Toto n sa niekedy zvykne definovať aj ako spätný pohľad.²⁸ Všetky kľzavé priemery majú spoločné dve vlastnosti: vyhladzujú dáta a spôsobujú oneskorenie. Vyhladzovaním dosiahneme to, že eliminujeme krátkodobé fluktuácie v časovom rade. Na druhej strane nevýhodou je spôsobené oneskorenie (angl. lag), t.j. prípadná fluktuácia v pôvodnom časovom rade sa premietne v novom časovom rade získanom pomocou kľzavého priemeru až o niekoľko dní neskôr. Čím dlhší bude

²⁷ FOLGER, J.: Types of Technical Indicators

²⁸ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 398

zvolený počet dní n , za ktorý budeme kľzavý priemer počítať, tým docielime väčšie vyhladenie pôvodného časového radu, ale zároveň o to väčšie bude oneskorenie nového časového radu. Preto vhodným nastavením n je snaha o nájdenie kompromisu medzi požadovanou mierou vyhladenia a tolerovaného oneskorenia.²⁹ Na Obr. 2 môžeme vidieť príklad rozdielu medzi 10-dňovým (modrá farba) a 50-dňovým (červená farba) kľzavým priemerom. 50-dňový kľzavý priemer vyhladzuje dáta viac ako 10-dňový kľzavý priemer, má ale väčšie oneskorenie.

Obrázok 2 - Porovnanie kratšieho 10 dňového a dlhšieho 50 dňového kľzavého priemeru



Zdroj: vlastné spracovanie

Existujú viaceré typy kľzavých priemerov, v nasledovnej časti si predstavíme 3 najpoužívanejšie.

2.1.1 Jednoduchý kľzavý priemer SMA

Jednoduchý kľzavý priemer (ang. skr. SMA – simple moving average) je aritmetický priemer hodnôt časového radu za predchádzajúcich n dní. Všetkým dňom zahrnutých do výpočtu prikladá rovnaké váhy. Vzorec na výpočet je nasledovný:

$$SMA_t = \frac{P_t + P_{t-1} + P_{t-2} + \dots + P_{t-n+1}}{n} = \frac{\sum_{i=1}^n P_{t-i+1}}{n}$$

²⁹ EHLERS, J. F.: Rocket Science for Traders, str. 18

kde: SMA_t = hodnota jednoduchého kĺzavého priemeru v čase t
 P_t = cena aktíva v čase t
 n = počet dní, za ktorý počítame kĺzavý priemer

Ako uvádza Ehlers³⁰, oneskorenie SMA je rovné hodnote $(n - 1)/2$. Napr. ak počítame 7-dňový SMA, jeho oneskorenie bude $(7 - 1)/2 = 3$ dni. To znamená, že prípadná zmena trendu v pôvodnom časovom rade sa v novom časovom rade zobrazí až po troch dňoch.

2.1.2 Lineárne vážený kĺzavý priemer WMA

Oneskorenie SMA môžeme pri udržaní rovnakého stupňa vyhladenia zredukovať použitím lineárne váženého kĺzavého priemeru (angl. skr. WMA – weighted moving average). Ten sa líši od SMA tým, že váhy priradené jednotlivým dňom nie sú konštantné. WMA priradí najvyššiu váhu najaktuálnejšiemu dňu zahrnutému do výpočtu rovnú n a pre každý ďalší deň budú váhy o jednu jednotku lineárne klesať až po najstaršiu hodnotu časového radu, ktorá bude mať váhu rovnú 1. Suma hodnôt časového radu pre násobených príslušnými váhami je potom predelená súčtom váh, čo môžeme popísať nasledovnou rovnicou:

$$WMA_t = \frac{n \times P_t + (n - 1) \times P_{t-1} + \dots + (n - (t - n + 1)) \times P_{t-n+1}}{n + (n - 1) + \dots + (n - (t - n + 1))}$$

Kde:

WMA_t = hodnota lineárne váženého kĺzavého priemeru v čase t
 P_t = cena aktíva v čase t
 n = počet dní, za ktorý počítame kĺzavý priemer

Oneskorenie WMA je rovné hodnote $(n - 1)/3$, čo pri 7-dňovom SMA bude už len $(7 - 1)/3 = 2$ dni, v porovnaní s 3-dňovým oneskorením SMA.³¹

2.1.3 Exponenciálny kĺzavý priemer EMA

Ďalším často používaným kĺzavým priemerom je exponenciálny kĺzavý priemer (angl. skr. EMA – exponential moving average). V literatúre môžeme nájsť aj pomenovanie exponenciálne vážený kĺzavý priemer (angl. skr. EWMA – exponential weighted moving average). Zatiaľ čo SMA a WMA používajú na výpočet priemer z posledných n dát a staršie dáta už nie sú zahrnuté do výpočtu, EMA je kumulatívnym priemerom

³⁰ EHLERS, J. F.: Rocket Science for Traders, str. 27

³¹ EHLERS, J. F.: Rocket Science for Traders, str. 27

zahŕňajúcim všetky dáta. Na rozdiel od WMA nie sú váhy rozložené lineárne, ale exponenciálne. Staršie dáta majú samozrejme znižujúci sa vplyv na hodnotu EMA, aktuálnejším dátam je priradená vyššia dôležitosť a váhy exponenciálne narastajú. EMA je potom definovaný rekurentným predpisom³²:

$$EMA_t = EMA_{t-1} + \alpha \times (P_t - EMA_{t-1})$$

Kde:

EMA_t = hodnota exponenciálneho kľzavého priemeru v čase t
 P_t = cena aktíva v čase t
 α = vyhladzovacia konštanta

Hodnota α sa nazýva aj vyhladzovacia konštanta a vyjadruje mieru, akou váhy priradené jednotlivým dňom klesajú resp. rastú. Nadobúda hodnoty od 0 po 1. V praxi sa najčastejšie používa $\alpha = 2/(n - 1)$.

2.2 Moving average convergence-divergence MACD

MACD (angl. moving average convergence-divergence), je technický indikátor používaný na identifikovanie trendu, ktorý sleduje vzd'alovanie (divergencia) a približovanie (konvergencia) kľzavých priemerov. V rôznych literatúrach ho môžeme nájsť zaradený aj do skupiny tzv. oscilátorov. Autorom je Gerald Appel³³, ktorého konštrukcia MACD pozostáva z rozdielu dvoch kľzavých priemerov s rôznou dĺžkou n . Najčastejšie sa používajú dva exponenciálne kľzavé priemery vypočítané z Close cien. Hodnotu MACD potom dostávame odčítaním dlhšieho EMA od kratšieho EMA.

$$MACD = EMA_{nFast} - EMA_{nSlow}$$

Kde:

EMA_{nFast} = hodnota kratšieho EMA
 EMA_{nSlow} = hodnota dlhšieho EMA

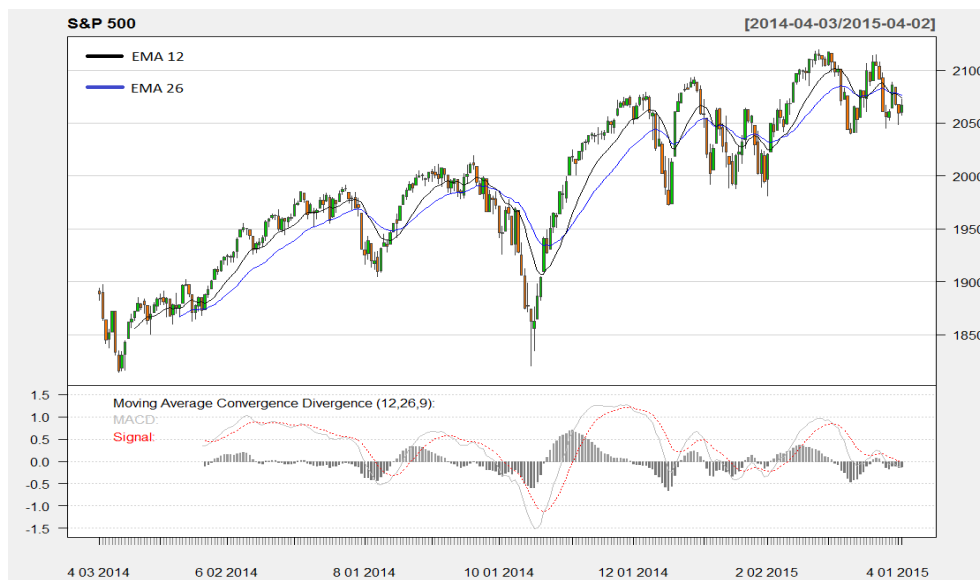
Následným vytvorením ďalšieho EMA z hodnôt MACD dostávame kľzavý priemer nazývaný aj *signálna čiara* (angl. signal line). Celkovo môžeme teda konštrukciu MACD charakterizovať zápisom $MACD(nFast, nSlow, nSig)$, čo vyjadruje aké dĺžky kľzavých priemerov boli použité. Ako príklad uvidíme $MACD(12,26,9)$, čo znamená, že na výpočet MACD bol použitý rozdiel 12-dňového EMA a 26-dňového EMA. Hodnota signálnej čiary bola vypočítaná aplikovaním 9-dňového EMA na MACD hodnoty.

³² EHLERS, J. F.: Rocket Science for Traders, str. 27-29

³³ APPEL, G.: Technical Analysis: Power Tools for Active Investors, str. 165-200

Ilustráciu tohto príkladu uvádzame na Obr.3. MACD hodnoty a signálna čiara sú zakreslené do špeciálneho grafu pod hlavným grafom ceny ako súvislé krivky. Hladina, na ktorej sa hodnoty kratšieho a dlhšieho EMA rovnajú, je znázornené v grafe tzv. *nulovou hladinou*. Rozdiel medzi hodnotou MACD a signálovou čiarou je znázornený histogramom.

Obrázok 3 – MACD (12, 26, 9)



Zdroj: vlastné spracovanie

Názov divergencia v názve MACD je odvodený od situácie, kedy sa hodnoty kratšieho a dlhšieho EMA od seba vzdiaľujú, konvergencia znamená, že hodnoty kratšieho a dlhšieho EMA sa k sebe približujú. Keď trend na trhu rastie, kratší EMA rastie rýchlejšie ako dlhší EMA, čo spôsobí, že hodnota MACD vzrastie. Keď trend stráca silu, kratší EMA má tendenciu sa ustáliť a klesnúť pod hodnotu dlhšieho EMA, pokiaľ pokles pokračuje. MACD hodnota vtedy klesne pod 0. Pri konštrukcii MACD, rozdiel dvoch EMA môže byť vypočítaný z aktuálnych hodnôt EMA alebo môže byť vyjadrený percentuálne (rozdiel dvoch EMA je ešte navyše vydelený hodnotou dlhšieho EMA).

2.3 Relative strength index RSI

RSI – (angl. relative strength index), je indikátor merajúci pomer kladných cenových zmien (nárastov ceny) voči záporným cenovým zmenám (poklesov ceny) daného aktíva za sledované obdobie n dní. Indikátor bol vyvinutý W.Wilderom³⁴ a jeho konštrukcia je nasledovná:

³⁴ WILDER, W., J., Jr.: New concepts in technical trading systems, str. 65

$$RSI(n) = 100 - \frac{100}{1 + RS(n)}$$


$$RS(n) = \frac{U(n)}{D(n)}$$

kde $U(n)$ = priemer nárastov ceny za obdobie n dní
 $D(n)$ = priemer poklesov ceny za obdobie n dní

Wilder v pôvodnej verzii indikátora používal na výpočet priemeru nárastov resp. priemeru poklesov exponenciálny kĺzavý priemer, môže však byť použitý aj iný kĺzavý priemer.

Hodnota RSI indikátora sa pohybuje v rozpätí 0 až 100. Hodnota 50, okolo ktorej hodnota RSI osciluje, sa zvykne označovať pojmom neutrálna línia. Podľa Wildera hodnota nad 70 poukazuje na situáciu, kedy je akcia príliš drahá, tzv. prekúpená (angl. overbought). Vtedy sa očakáva čoskorý pokles ceny. Naopak hodnota pod 30 znamená, že akcia je príliš lacná, tzv. prepredaná (ang. oversold) a očakáva sa nárast ceny. Samotný RSI indikátor sa zakresluje do samostatného grafu pod hlavný cenový graf ako môžeme vidieť na Obr.č. 4, kde je zobrazený RSI indikátor vypočítaný so spätným pohľadom 10 dní. Voľba parametra n závisí od nastavenia obchodníka, platí však, že čím väčší bude počet dní, za ktorý budeme indikátor počítat', tým menej bude oscilácií nad hranicou prekúpenosti a pod hranicou prepredanosti. Naopak, čím menší bude počet dní, za ktorý budeme indikátor počítat', tým častejšie bude dochádzať k prekročeniu týchto hraničných hodnôt.

Obrázok 4 - RSI (10)



Zdroj: vlastné spracovanie

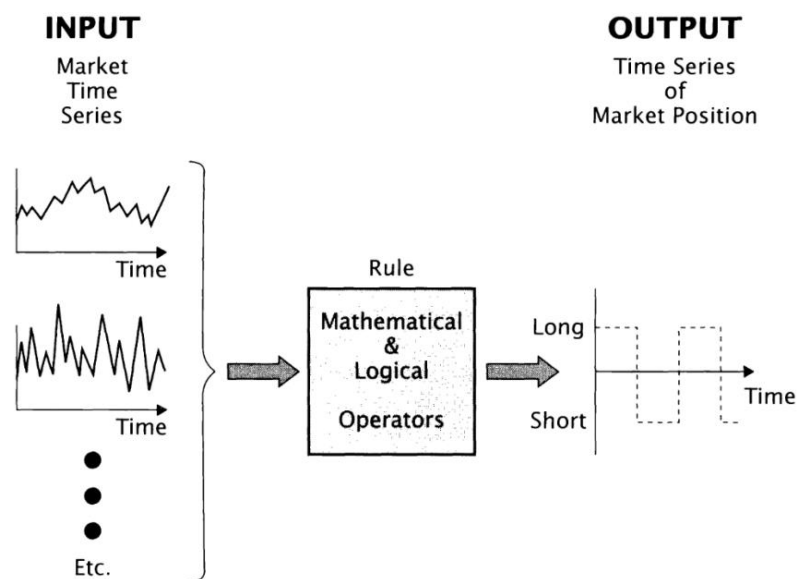
3 Obchodné pravidlá

V tejto kapitole si predstavíme koncepciu tvorby obchodných pravidiel na základe objektívnych matematických metód technickej analýzy. Následne si popíšeme spôsob výpočtu výnosnosti týchto pravidiel. Tieto pravidlá budeme neskôr aplikovať simuláciou na historických dátach pomocou spätného testovania (angl. backtesting).

3.1 Definovanie obchodných pravidiel

Obchodné pravidlá sú funkcie, ktoré transformujú vstupné informácie pomocou matematických a logických algoritmov do výstupu pravidla. Vstupnými informáciami môžu byť rôzne časové rady napr. historických cien alebo obchodovaných objemov daného aktíva na trhu, resp. časové rady z týchto dát odvodené. Tieto vstupné časové rady sú následne transformované do nových časových radov, pozostávajúcich z odporúčaných obchodných pozícií, ktorú máme na trhu zaujať.³⁵ Celý tento vstupno-výstupný proces tvorby obchodných pravidiel ilustrujeme na Obr. 5:

Obrázok 5 - Princíp tvorby obchodného pravidla



Zdroj: ARONSON, D. R.: Evidence-Based Technical Analysis, str. 17, upravené

Základné pozície, ktoré môžeme na trhu zaujať sú long, short a neutral. Long (dlhá pozícia) znamená, že obchodník dané aktívum zakúpil s cieľom predat' ho v budúcnosti za vyššiu cenu a zarobiť tak na náraste ceny. Short (krátka pozícia) znamená, že obchodník

³⁵ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 16-17

predal aktívum bez toho, že by ho vlastnil, ale je pri tom povinný kúpiť ho neskôr späť. Držaním krátkej pozície sa teda obchodník snaží zaradiť na prípadnom poklese cien s tým, že dané aktívum spätne zakúpi neskôr za nižšiu cenu ako ho predal. Pozícia neutral znamená, že obchodník nedrží žiadnu otvorenú pozíciu na trhu.³⁶ Tieto pozície budeme označovať číslami +1 pre long pozíciu, -1 pre short pozíciu a 0 pre neutral pozíciu.

3.2 Binárne obchodné pravidlá

Najjednoduchším typom obchodných pravidiel sú také, ktoré majú tzv. *binárny výstup*. To znamená, že ich výstup môže byť reprezentovaný len dvoma možnými hodnotami napr. +1 a -1. Takéto pravidlo môže byť navrhnuté na odporúčanie napr. long a short pozície, long a neutral pozície alebo short a neutral pozície. Všetky obchodné pravidlá použité v našej práci budú binárne long/short pravidlá s výstupmi z množiny $\{+1, -1\}$. Takýto typ pravidiel sa nazýva aj *reverzný* typ pravidiel, pretože obchodné signály nám hovoria o zmene z long pozície do short pozície a zmene zo short pozície do long pozície. Znamená to, že počas celého sledovaného obdobia našej obchodnej stratégie sa budeme nachádzať buď v long alebo short pozícii. Ak nám naše pravidlo bude signalizovať napr. zmenu z long na short pozíciu, znamená to, že uzavrieme otvorenú long pozíciu a otvoríme novú short pozíciu.³⁷

3.3 Generovanie obchodných signálov

3.3.1 Identifikovanie trendu

Na rozpoznanie trendu budeme v našej práci používať nasledovné pravidlá:

- 1.) Prvý spôsob bude porovnávanie hodnoty zvoleného kľzavého priemeru a uzatváracej Close ceny. Obchodné pravidlo bude stanovené podľa všeobecných odporúčaní nasledovne: kým sa drží cena nad zvoleným kľzavým priemerom, signalizuje to, že sa nachádzame v rastúcom trende a budeme sa držať v long pozícii symbolizovanej číslom +1. Zarábať budeme tým pádom na raste ceny. Signálom, že sa trend bude meniť na opačný, je situácia, keď cena klesne pod svoj kľzavý priemer. Vtedy otáčame pozíciu na opačnú short pozíciu. Pokiaľ sa cena akcie nachádza pod kľzavým priemerom držíme sa v short pozícii reprezentovanej číslom -1 a zarábame na poklese ceny. Keď cena opäť stúpne nad svoj kľzavý

³⁶ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 479

³⁷ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 16-17

priemer, čo signalizuje opäť zmenu trendu z klesajúceho na rastúci, otáčame pozíciu na opačnú long pozíciu.

Všeobecne platí, že čím kratšiu dobu n na výpočet kľzavého priemeru si zvolíme, tým viac zmien pozícií bude signalizovaných. Výhodou použitia kratšieho n je pružnejšie reagovanie na zmenu trendu, nevýhodou je väčšie množstvo falošných signálov spôsobených len drobnými fluktuáciami v hlavnom trende. Naopak pri použití dlhšieho kľzavého priemeru dostaneme lepšie vyhladenie časového radu cien a menšie množstvo falošných signálov, na druhej strane bude zmena trendu signalizovaná s väčším oneskorením. Pravidlo otestujeme pre všetky typy kľzavých priemerov (SMA, WMA, EMA) a pre rôzne dĺžky parametra n .

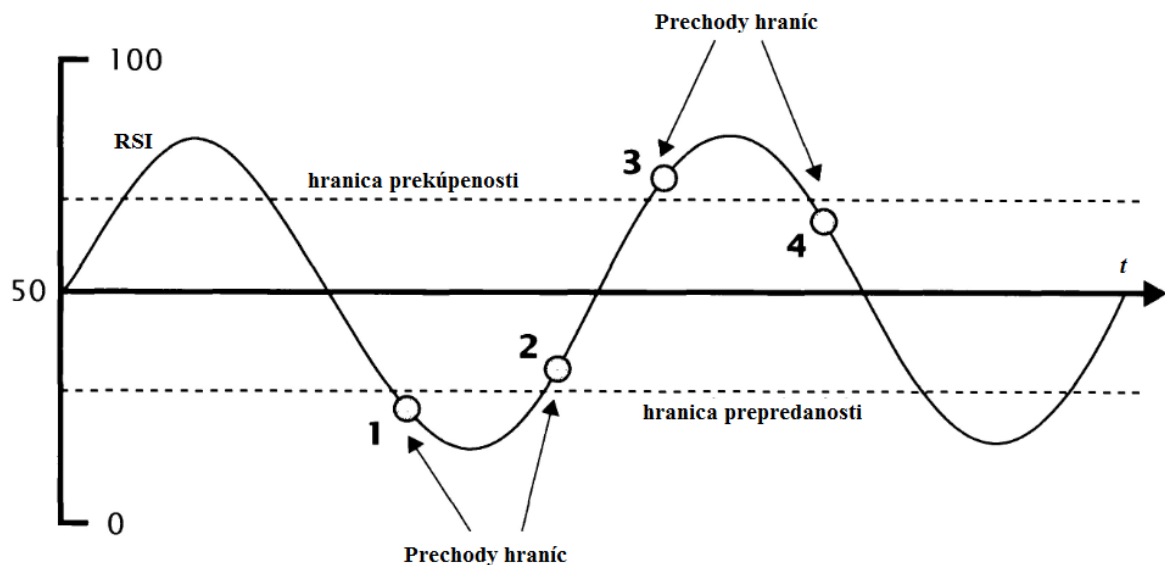
- 2.) Druhým pravidlom, ktoré budeme používať na detekciu trendu, je porovnávanie 2 kľzavých priemerov s rôznou dĺžkou n . Pokiaľ sa bude hodnota kratšieho priemeru nachádzať nad hodnotou dlhšieho priemeru, čo signalizuje rastúci trend, budeme sa držať v long pozícii (+1). Keď sa bude hodnota kratšieho priemeru nachádzať pod hodnotou dlhšieho priemeru, čo znamená, že sa nachádzame v klesajúcom trende, budeme sa držať v short pozícii (-1). Opäť platí, že signálom na zmenu pozície je tzv. prekríženie kriviek daných dvoch kľzavých priemerov, t.j. hodnota kratšieho kľzavého priemeru stúpne nad alebo klesne pod hodnotu dlhšieho kľzavého priemeru. Opäť pravidlo otestujeme pre všetky typy kľzavých priemerov a pre rôzne dĺžky parametra n .
- 3.) Posledné pravidlo na zachytenie trendu bude využívať indikátor MACD, ktorého využitie na tvorbu obchodných signálov je rozmanité. V našej diplomovej práci budeme používať základné pravidlo prekríženia krivky MACD so signálnou čiarou. V prípade, že sa bude hodnota MACD nachádzať nad hodnotou signálnej čiary, budeme sa držať v long pozícii (+1), pokiaľ bude hodnota MACD pod hodnotou signálnej čiary, budeme držať short pozíciu (-1). Otestujeme tak v pravidlo v podobe ako ho definoval samotný autor.³⁸ Kombinácie parametrov pre počítanie EMA na zostrojenie rôznych typov MACD si popíšeme neskôr.

³⁸ APPEL, G.: Technical Analysis: Power Tools for Active Investors, str. 165-200

3.3.2 Prechody hraníc

Kým kľzavé priemery a MACD boli vhodnými indikátormi na určenie trendu, nemusia dávať dobré predikcie v prípadoch, že na trhu momentálne neprevláda žiadny trend a ceny sa pohybujú horizontálne. Vtedy je vhodnejšie použiť obchodné pravidlá založené na prechode určitých pevne stanovených cenových hraníc. Na tieto účely budeme používať indikátor RSI. Tento indikátor má 2 fixne stanovené hranice – spodnú hranicu prepredanosti a hornú hranicu prekúpenosti. Prechody týchto hraníc môžu nastať v 4 prípadoch, ktoré ilustrujeme na Obr.6 prevzatého od Arronsona:

Obrázok 6 - Prechody hraníc



Zdroj: ARONSON, D. R.: Evidence-Based Technical Analysis, str. 422, upravené

- 1.) Hranica prepredanosti je prekročená zhora nadol
- 2.) Hranica prepredanosti je prekročená zdola nahor
- 3.) Hranica prekúpenosti je prekročená zdola nahor
- 4.) Hranica prekúpenosti je prekročená zhora nadol

Na základe toho nám vzniká 6 možných kombinácií binárnych pravidiel, ktoré určujú kedy sa nachádzame v long pozícií a kedy v short pozícií. V skutočnosti je týchto možných kombinácií 12, v prípade, že long a short pozície interpretujeme opačne. Takýto typ pravidiel si popíšeme neskôr. Základných 6 pravidiel vyzerá nasledovne:


1. Prekročenie hranice prepredanosti smerom zhora nadol a prekročenie hranice prepredanosti smerom zdola nahor. Ak klesne hodnota RSI pod hranicu prepredanosti zhora nadol, budeme sa držať v long pozícii, až do momentu prekročenia hranice prepredanosti naspäť smerom zdola nahor. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prepredanosti.
2. Prekročenie hranice prepredanosti smerom zhora nadol a prekročenie hranice prekúpenosti smerom zdola nahor. Ak klesne hodnota RSI pod hranicu prepredanosti zhora nadol, budeme sa držať v long pozícii, až do momentu prekročenia hranice prekúpenosti smerom zdola nahor. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prepredanosti.
3. Prekročenie hranice prepredanosti smerom zhora nadol a prekročenie hranice prekúpenosti smerom zhora nadol. Ak klesne hodnota RSI pod hranicu prepredanosti zhora nadol, budeme sa držať v long pozícii, až do momentu prekročenia hranice prekúpenosti smerom zhora nadol. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prepredanosti.
4. Prekročenie hranice prepredanosti smerom zdola nahor a prekročenie hranice prekúpenosti smerom zdola nahor. Ak vystúpi hodnota RSI nad hranicu prepredanosti, budeme sa držať v long pozícii, až do momentu, pokým RSI vystúpi nad hranicu prekúpenosti. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prepredanosti.
5. Prekročenie hranice prepredanosti smerom zdola nahor a prekročenie hranice prekúpenosti smerom zhora nadol. Ak stúpne hodnota RSI nad hranicu prepredanosti, budeme sa držať v long pozícii, až do momentu, pokým RSI nevystúpi nad hranicu prekúpenosti a následne z nej vystúpi smerom zhora nadol. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prepredanosti.
6. Prekročenie hranice prekúpenosti smerom zdola nahor a následné prekročenie hranice prekúpenosti smerom zhora nadol. Ak stúpne hodnota RSI nad hranicu prekúpenosti zdola nahor, budeme sa držať v long pozícii, až do momentu prekročenia hranice prekúpenosti smerom zhora nadol. Vtedy pozíciu obraciame na short a zotrývame v nej až do ďalšieho prechodu pod hranicu prekúpenosti.

V súvislosti s RSI indikátorom budeme používať ešte jedno pravidlo a to pri prekročení neutrálnej línie. Pokiaľ bude hodnota RSI nad neutrálnou hodnotou 50, budeme sa držať v long pozícii, pokiaľ bude hodnota RSI pod neutrálnou hodnotou 50, bude v short pozícii. Hranice prepredanosti a prekúpenosti nastavíme vo dvoch rôznych fixovaných vzdialenosti od neutrálnej línie a otestujeme RSI indikátor pre rôzne hodnoty parametra n .

3.4 Inverzné obchodné pravidlá

Pravidlá generujúce obchodné signály sú podľa Arronsona³⁹ väčšinou konzistentné s tradičnými princípmi technickej analýzy. Napr. pravidlo prekríženia kľzavého priemeru s cenou generuje odporúčanú obchodnú pozíciu +1, keď je hodnota ceny nad svojim kľzavým priemerom (očakáva rastúci trend) a pozíciu -1, keď je cena pod kľzavým priemerom (očakáva klesajúci trend). Takéto pravidlo je potom definované aj ako *tradičné pravidlo* technickej analýzy. Takáto logika pravidla sa zdá byť prirodzená, ale môže sa stať, že nie vždy môže byť koncept tradičných pravidiel vnímaný správne, preto je zaujímavé otestovať ako by fungovalo pravidlo s obrátenou logikou. Pre tieto účely sa k tradičným pravidlám zvyknú robiť tzv. *inverzné pravidlá*, ktoré interpretujú obchodné signály opačným spôsobom. To znamená, že pokiaľ logika tradičného pravidla odporúča pozíciu +1, inverzné pravidlo generuje pozíciu -1 a naopak, pokiaľ logika tradičného pravidla odporúča pozíciu -1, inverzné pravidlo generuje pozíciu +1. Príklad tvorby inverzného pravidla si ilustrujeme na Obr. 7:

Obrázok 7 - Tradičné a inverné pravidlo



Zdroj: ARONSON, D. R.: Evidence-Based Technical Analysis, str. 22, upravené

³⁹ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 21-22

3.5 Výpočet výnosov pravidla

Výnosy testovaného pravidla vypočítame nasledovným spôsobom. V prvom kroku si na základe logiky nášho pravidla vygenerujeme obchodné signály pre každý deň sledovaného obdobia. Tieto signály budú reprezentované časovým radom pozostávajúcim z hodnôt +1 a -1. Následne tieto denné obchodné signály spárujeme s dennými logaritmickeými zmenami cien daného akciového indexu za sledované obdobie. Tu však nastáva problém s tým, že signály vygenerované z uzatváracích cien aktuálneho dňa, nemôžeme už v daný deň aplikovať. Najbližšia príležitosť nastáva až po otvorení burzy v nasledujúci deň ráno pri otváracích cenách. Prvú logaritmickeú dennú zmenu ceny potom dostaneme až z otváracej ceny o deň neskôr. Denný očakávaný výnos z tohto obchodného signálu bude potom daný vzťahom:⁴⁰

$$ER_t = Pos_t \times \ln\left(\frac{Open_{t+2}}{Open_{t+1}}\right)$$

Kde: ER_t = denný očakávaný výnos nášho pravidla pre deň t
 Pos_t = pozícia pravidla vygenerovaná z Close ceny na konci dňa t
 $Open_{t+1}$ = otváracia cena akciového indexu v deň $t+1$
 $Open_{t+2}$ = otváracia cena akciového indexu v deň $t+2$

Ďalším problémom je, že binárne pravidlo môže vykazovať tzv. *pozičnú odchýlku*, čo znamená náklonnosť k častejšiemu generovaniu jednej z pozícií (long alebo short) ako druhej. Táto náklonnosť sa bude prejavovať, ak podmienka pravidla pre dosiahnutie jednej pozície bude ťažšie splniteľná ako podmienka pre opačnú pozíciu. Napr. ak podmienka pre dosiahnutie long pozície bude ťažšie dosiahnuteľná ako podmienka pre short pozíciu, pravidlo bude mať tendenciu generovať viac short signálov ako long signálov a väčšinu sledovaného obdobia nás bude držať v short pozícii. Ak takéto pravidlo aplikujeme na dáta s rastúcim trendom, bude to mať negatívny vplyv na jeho výnosnosť.⁴¹ Na to aby táto pozičná odchýlka neznemožňovala vzájomné porovnanie rôznych pravidiel, potrebujeme z dát odstrániť trend. To spravíme tak, že od denných logaritmickeých zmien cien akciového indexu odpočítame priemernú logaritmickeú zmenu ceny za sledované obdobie. Dôležité je však poznamenať, že detrendované dáta budú použité len na účel výpočtu denných výnosov pravidla. Generovanie obchodných signálov bude robené z pôvodných

⁴⁰ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 29-30

⁴¹ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 391-392

dát. Vzorec pre výpočet denných výnosov nášho pravidla potom bude vyzerat' nasledovne:⁴²

$$ER_t = Pos_t \times \left(\ln \left(\frac{Open_{t+2}}{Open_{t+1}} \right) - ALR \right)$$

Kde: ER_t = denný očakávaný výnos nášho pravidla pre deň t
 Pos_t = pozícia pravidla vygenerovaná z Close ceny na konci dňa t
 $Open_{t+1}$ = otváracia cena akciového indexu v deň $t+1$
 $Open_{t+2}$ = otváracia cena akciového indexu v deň $t+2$
 ALR = priemerný logaritmický výnos za sledované obdobie (average log return)

Tieto denné výnosy pravidla následne vypočítame z našich dát spätne za celé naše sledované obdobie. Z týchto denných výnosov pravidla vypočítame priemerný denný výnos, ktorý následne prevedieme na priemerný ročný výnos. Tento priemerný ročný výnos nášho pravidla budeme neskôr štatisticky testovať, aby sme zistili štatistickú významnosť nášho pravidla.

Ďalším faktorom, ktorý by mohol skresliť porovnanie testovaných pravidiel, sú transakčné náklady. Poplatky za obchodovanie by mohli značným spôsobom negatívne ovplyvniť výnosnosť našich pravidiel, najmä v situáciách, kedy nám pravidlá signalizovali časté zmeny pozície. Pre zjednodušenie porovnania pravidiel, preto transakčné náklady nebudeme brať do úvahy.

⁴² ARONSON, D. R.: Evidence-Based Technical Analysis, str. 27-30

4 Štatistické testovanie významnosti pravidla

Obchodné pravidlá môžu dosahovať rôznu výnosnosť pri ich aplikovaní na rôzne typy dát a pri použití rôznych parametrov. Na to aby sme vedeli rozhodnúť, ktoré pravidlá sú naozaj užitočné, je vhodné použiť štatistickú analýzu. V tejto časti si vysvetlíme metodológiu, pomocou ktorej budeme vyhodnocovať štatistickú významnosť výsledkov pravidiel získané spätným testovaním na historických dátach.

Na to aby sme mohli vyhlásiť výnosnosť niektorého pravidla za významnú, musíme ho porovnať s nejakým benchmarkom. Možností, ako stanoviť vhodný benchmark pre výnosnosť nášho pravidla, je viacero. Väčšinou to závisí od očakávaní konkrétneho obchodníka. Napr. pre niekoho môže byť významným pravidlom pravidlo, ktoré dosiahne ročný výnos 5 % p.a, niekto môže naopak zamietnuť pravidlo, ktoré dosiahne ročný výnos 20 % p.a. V našej práci si ako základný benchmark stanovíme výkonnosť pravidla, ktoré nemá žiadnu prediktívnu silu. Bude to také pravidlo, ktoré generuje obchodné signály náhodne a jeho očakávaný výnos na detrendovaných dátach je nulový. Tento prístup je používaný pri štatistickom vyhodnocovaní významnosti aj v iných vedných oblastiach. Napr. v medicíne musí nový testovaný liek najskôr prekonať v štatistických testoch významnosti placebo, aby mohol byť vyhlásený za užitočný.⁴³


Pri testoch štatistickej významnosti sa testuje nejaké tvrdenie o hodnote parametra základného súboru (populácie). Keďže výskum celého základného súboru väčšinou nie je možný, robí sa z neho výber (vzorka), z ktorej sa vypočíta testovacia štatistika. Základom pre tvorbu vzorky je náhodný výber. Pri testovaní štatistickej významnosti sa postupuje tak, že sa najskôr stanoví nulová hypotéza (H_0) a alternatívna hypotéza (H_1), ktorú chceme testovať. Hypotézy sa stanovujú tak, aby bolo našim cieľom zamietnuť nulovú hypotézu a nepriamym dôkazom tým potvrdiť platnosť alternatívnej hypotézy. Hypotézy testujeme na stanovenej hladine významnosti α , ktorá vyjadruje pravdepodobnosť chyby I. druhu, ktorú spravíme v prípade, ak zamietneme nulovú hypotézu, ktorá je v skutočnosti platná. Testovacia štatistika má za predpokladu platnosti nulovej hypotézy určité pravdepodobnostné rozdelenie. Pravdepodobnosť, že testovacia štatistika nadobudne za predpokladu platnosti H_0 aspoň takú extrémnu hodnotu akou je hodnota vyráтанá zo

⁴³ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 23

vzorky, sa nazýva p-hodnota (angl. p-value). Iné pomenovanie pre p-hodnotu testovacej štatistiky je aj štatistická významnosť. Čím nižšia je p-hodnota, tým je výsledok testu štatistiky významnejší. Ak je p-hodnota menšia ako hladina významnosti α , nulovú hypotézu zamietame. To znamená, že zistený rozdiel vo vzorke je priveľký na to, aby bol spôsobený len náhodou. Medzi testovanými premennými tak existuje určitý vzťah.⁴⁴

P-hodnota má aj svoju grafickú interpretáciu ako môžeme vidieť na Obr.8.

Obrázok 8 - P-hodnota



A **p-value** (shaded green area) is the probability of an observed (or more extreme) result assuming that the null hypothesis is true.

Zdroj: <http://en.wikipedia.org/wiki/P-value>, upravené

V súvislosti s testovaním štatistickej významnosti našich obchodných pravidiel aplikujeme tieto štatistické pojmy na našu situáciu. Parametrom základného súboru bude očakávaný ročný výnos náhodného pravidla, ktoré nemá prediktívnu silu, výberovú vzorku bude predstavovať množina denných výnosov pravidla za sledované obdobie a testovacou štatistikou bude skutočný priemerný ročný výnos, ktorý naše pravidlo dosiahlo počas backtestingu za sledované obdobie. Hypotézy budú definované nasledovne:

Nulová hypotéza H_0 : „Všetky naše testované pravidlá nemajú žiadnu prediktívnu silu.“

To znamená, že prípadné dosiahnuté zisky pravidla v backtestovanom období, boli len dielom náhody (výberovej disperzie) a očakávaný výnos pravidla je nulový.

⁴⁴ RIMARČÍK, M.: Testy štatistických hypotéz (testy štatistickej významnosti)

Alternatívna hypotéza H1: „Naše pravidlo má skutočnú prediktívnu silu“.

Inými slovami, výsledkom profitability pravidla v backtestingu je efektívne párovanie obchodných signálov s dennými trhovými zmenami ceny. Efektívne pravidlo má tendenciu spárovať long (+1) pozície s kladnými dennými zmenami ceny a short (-1) pozície so zápornými dennými zmenami ceny.⁴⁵

Hladina významnosti, na ktorej budeme hypotézu testovať, bude stanovená na tradične používanú hodnotu $\alpha = 0,05$. Znamená to, že keď dosiahneme v testovaní p-hodnotu nižšiu ako 0,05, nulovú hypotézu zamietneme.

Výberové rozdelenie (angl. sample distribution) bude reprezentované strednou hodnotou priemerného výnosu pravidla a jeho náhodnou disperziou, pokiaľ by bolo testované na rôznych nezávislých vzorkách dát (angl. data samples). Nezávislé vzorky dát budú generované metódami, ktoré si predstavíme neskôr. Výberové rozdelenie je centrovane okolo nuly, čo vyjadruje predpoklad nulovej hypotézy, že očakávaný výnos pravidla, ktoré nemá prediktívnu silu, je nulový.⁴⁶

Testovanie hypotéz vyžaduje metódu na odhad výberového rozdelenia testovacej štatistiky. Problémom však je, že k dispozícii máme len jednu vzorku dát (jeden časový rad denných výnosov pravidla) a len jednu hodnotu testovacej štatistiky (jeden skutočný ročný výnos pravidla). Riešením je použitie metód, ktoré náhodne prevzorkujú (angl. resampling) pôvodnú vzorku pozorovaní a vygenerujú z nej tak novú vzorku dát. Priemerný ročný výnos pravidla je potom vypočítaný pre každú takto vygenerovanú novú vzorku dát. Dostatočne veľkým počtom opakovaní tohto procesu by sme podľa centrálnej limitnej vety mali dostať rozdelenie, ktoré sa bude približovať normálnemu rozdeleniu. Mali by sme tak dostať dostatočne veľký súbor hodnôt na odhadnutie výberového rozdelenia výnosov pravidla.⁴⁷

⁴⁵ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 392-393

⁴⁶ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 227-228

⁴⁷ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 234-235

Z takto získanej vzorky potom budeme vedieť zistiť jej strednú hodnotu, s ktorou budeme môcť porovnať skutočný dosiahnutý výnos nášho pravidla. Takýmto spôsobom potom budeme môcť otestovať štatistickú významnosť tohto pravidla. V našej diplomovej práci budeme používať na testovanie štatistickej významnosti pravidla dve takéto metódy – bootstrap metódu a monte carlo permutáciu.

4.1 Bootstrap metóda

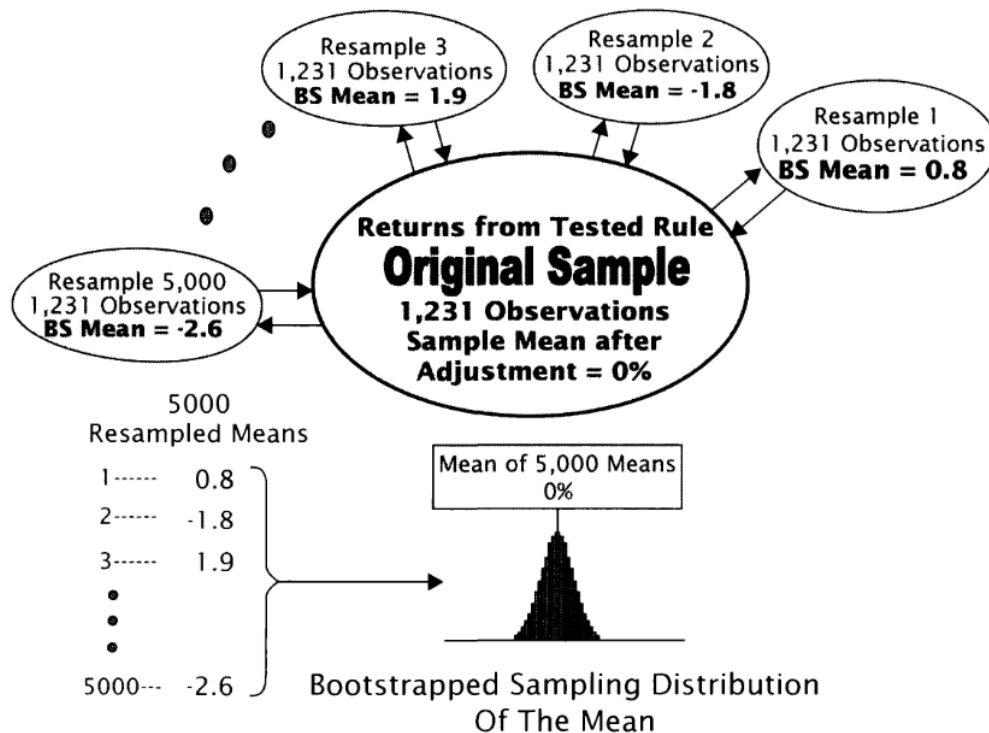
Táto metóda odvodí výberové rozdelenie testovacej štatistiky prevzorkovaním pôvodnej vzorky s výberom s návratom (angl. resample with replacement). Pôvodnou vzorkou dát, s ktorou bude bootstrap metóda začínať, budú denné výnosy pravidla dosiahnuté počas sledovaného obdobia na detrendovaných dátach. Pred začiatkom procedúry sú tieto denné výnosy pravidla vycentrované, aby bol ich denný priemerný výnos nulový. To docielime tak, že od každého denného výnosu pravidla odčítame priemerný denný výnos za celé sledované obdobie. Takto máme pripravenú pôvodnú vzorku na generovanie výberového rozdelenia spĺňajúcu predpoklad hypotézy H_0 , že ich priemerná hodnota je 0.

Ďalšia podmienka, ktorá musí byť pri aplikovaní bootstrap metódy splnená, je, že počet pozorovaní v každej novej vygenerovanej vzorke musí byť rovnaký ako počet pozorovaní v pôvodnej vzorke.

Posledný predpoklad je, že každá nová vzorka je tvorená výberom s návratom, to znamená, že potom, čo bol nejaký denný výnos náhodne vybraný zo vzorky, je umiestnený náhodne do tejto vzorky naspäť. To umožňuje niektorým denným výnosom byť vybratým viac krát, zatiaľ čo iné výnosy nemusia byť vybraté ani raz. Ilustráciu tejto metódy je možné vidieť na Obr. 8. Znázorňuje tvorbu 5 000 nových vzoriek z pôvodnej vzorky. Každá vzorka obsahuje 1 231 pozorovaní. Priemerný výnos je vypočítaný pre každú jednu vzorku. Týchto 5 000 priemerných výnosov je použitých na tvorbu výberového rozdelenia priemerného výnosu pravidla⁴⁸.

⁴⁸ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 236-238

Obrázok 9 – Bootstrap metóda



Zdroj: ARONSON, D. R.: Evidence-Based Technical Analysis, str. 236

Na základe tohto princípu sme si zostrojili tento modifikovaný algoritmus pre potreby vyhodnotenia štatistickej významnosti našich obchodných pravidiel:

- 1.) Po obdržaní vzorky denných výnosov pravidla dosiahnutých počas backtestingu na detrendovaných dátach za sledované obdobie vypočítame priemerný denný výnos pravidla z týchto dát.
- 2.) Vycentrujeme denné výnosy odpočítaním priemerného denného výnosu od každého denného výnosu pravidla za sledované obdobie.
- 3.) Z vycentrovanej vzorky denných výnosov pravidla vygenerujeme novú vzorku výnosov výberom s návratom.
- 4.) Vypočítame priemerný denný výnos tejto novej vzorky výnosov.
- 5.) Tento priemerný denný výnos prevedieme na priemerný ročný výnos, ktorý si uložíme.
- 6.) Kroky 3 – 5 opakujeme dostatočne veľký počet krát (1 000 krát)
- 7.) Dostaneme tak vektor 1 000 náhodne generovaných priemerných ročných výnosov. Príslušným štatistickým testom normality overíme, či sú tieto dáta z normálneho

rozdelenia. Pokiaľ dáta nie sú z normálneho rozdelenia, opakujeme kroky 3 – 5 dostatočne veľký počet krát, pokiaľ nedosiahneme normálne rozdelenie.

- 8.) Vypočítame si pomer koľko náhodne generovaných priemerných ročných výnosov je väčších ako náš skutočný ročný výnos pravidla. Toto bude naša p-hodnota. Ak bude menšia ako 0,05, hypotézu H_0 zamietneme a vyhodnotíme toto pravidlo za štatisticky významné. Znamená to, že má v takom prípade prediktívnu silu.
- 9.) Vypočítame obojstranný 95 %-ný interval spoľahlivosti vzorky 1 000 náhodne generovaných priemerných ročných výnosov. Použijeme na to tzv. percentilovú metódu. Tá spočíva v tom, že si najprv zoradíme všetkých 1 000 náhodne generovaných priemerných ročných výnosov od najmenšieho po najväčší. Odstránime 2,5 % najmenších a 2,5% najvyšších hodnôt (v našom prípade teda 25 najnižších a 25 najvyšších). Z takto nového získaného vektora náhodných ročných výnosov bude nový najnižší výnos tvoriť dolnú hranicu intervalu spoľahlivosti a nový najvyšší výnos bude tvoriť hornú hranicu intervalu spoľahlivosti.

4.2 Monte Carlo permutácia

Monte Carlo simulácia je všeobecne známa simulačná metóda používajúca náhodný výber. Monte Carlo permutácia je metóda vyvinutá Dr. Mastersom, ktorý ju použil na testovanie obchodných pravidiel. Jej myšlienka vychádza z predpokladu, že pravidlo, ktoré nemá prediktívnu silu, len náhodne páruje detrendované denné zmeny cien na trhu s generovanými obchodnými pozíciami. Permutáciou týchto denných cenových zmien, tak generuje metóda novú vzorku podobne ako bootstrap metóda. Dôležitý rozdiel je v tom, že Monte Carlo permutácia náhodne prevzorkuje detrendované denné zmeny cien s výberom bez návratu (resampling without replacement). Následne tieto permutované denné zmeny spáruje s rovnakými obchodnými pozíciami ako pôvodná vzorka. Vznikne tak nová vzorka, ale už náhodne generovaných denných výnosov pravidla. Opakovanie tohto procesu dostatočne veľký počet krát je použité na tvorbu výberového rozdelenia náhodného priemerného ročného výnosu pravidla. Z neho sa potom určí stredná hodnota, s ktorou budeme skutočný výnos pravidla porovnávať.⁴⁹

⁴⁹ ARONSON, D. R.: Evidence-Based Technical Analysis, str. 238-240

Na základe autorovho popisu sme si prispôsobili túto metódu pre potreby vyhodnotenia štatistickej významnosti našich obchodných pravidiel, pričom postup je nasledovný:

- 1.) Obdržíme vzorku denných cenových zmien na trhu za sledované obdobie backtestingu pravidla, z ktorých sme odstránili trend.
- 2.) Získame časový rad denných obchodných signálov nášho pravidla za sledované obdobie.
- 3.) Náhodne permutujeme denné zmeny cien s výberom bez návratu.
- 4.) Novovzniknutý náhodný časový rad denných cenových zmien spárujeme z pôvodným časovým radom denných obchodných signálov. Dostaneme tak novú vzorku denných výnosov pravidla, ale už náhodne generovanú.
- 5.) Vypočítame z nej priemerný denný výnos a z neho následne priemerný ročný výnos.
- 6.) Kroky 3-5 opakujeme dostatočne veľký počet krát (1 000 krát)
- 7.) Dostaneme tak vektor 1 000 náhodne generovaných priemerných ročných výnosov. Príslušným štatistickým testom normality overíme, či majú tieto dáta normálne rozdelenie. Pokiaľ dáta nie sú z normálneho rozdelenia, opakujeme kroky 3 – 5 dostatočne veľký počet krát, pokiaľ nedosiahneme normálne rozdelenie.
- 8.) Z tohto vektora 1 000 náhodne generovaných priemerných ročných výnosov si vypočítame strednú hodnotu a disperziu.
- 9.) Štatistickú významnosť pravidla určíme pomocou p-hodnoty, ktorú si v tomto teste vypočítame pre porovnanie iným spôsobom ako pri bootstrap metóde. Použijeme pri tom všeobecne známu Z-štatistiku:

$$Z = \frac{\bar{X} - \mu}{\sigma}$$

Kde: \bar{X} = výnos nášho pravidla

μ = stredná hodnota vzorky 1 000 náhodných ročných výnosov

σ = štandardná odchýlka vzorky 1 000 náhodných ročných výnosov

Potom p-hodnotu vypočítame ako pravdepodobnosť, že niektorý výnos z zo vzorky 1 000 náhodne generovaných priemerných ročných výnosov bude väčší ako skutočný dosiahnutý ročný výnos nášho pravidla:

$$P(z > Z) = 1 - P(z = Z)$$

Ak bude p-hodnota menšia ako 0,05, tak hypotézu H_0 zamietneme a vyhodnotíme toto pravidlo za štatisticky významné. Znamená to, že má naozaj prediktívnu silu.

10.) Nakoniec vypočítame obojstranný 95 %-ný interval spoľahlivosti vzorky 1 000 náhodne generovaných priemerných ročných výnosov. Použijeme na to kritické hodnoty normálneho rozdelenia:

$$\left(\bar{X} - u\left(\frac{\alpha}{2}\right)\sigma, \bar{X} + u\left(\frac{\alpha}{2}\right)\sigma \right)$$

V tejto kapitole sme si zadefinovali benchmark, voči ktorému budeme naše pravidlá porovnávať. Stanovili sme hypotézy, ktoré budeme testovať. Ukázali sme si akým spôsobom sa vysporiadať s problémom, keď máme k dispozícii len jednu výberovú vzorku a jednu testovaciu štatistiku. Umožní nám to vyhodnocovať štatistickú významnosť každého pravidla samostatne. Uviedli sme si teda 2 štatistické metódy, ktoré budeme používať na vyhodnocovanie významnosti všetkých našich obchodných pravidiel. Keďže obidve metódy sú založené na podobnom princípe, očakávame, že budú pri aplikovaní na obchodné pravidlá dávať aj podobné výsledky. Preto sme aj p-hodnotu a intervaly spoľahlivosti počítali dvoma rôznymi spôsobmi, aby sme toto porovnanie spravili zaujímavejším. Môže sa stať, že niektorá z metód ukáže štatistickú významnosť pravidla, kým druhá ju zamietne. Pokiaľ štatistickú významnosť potvrdia obidva testy, môžeme si byť o niečo istejší, že testované pravidlo má naozaj prediktívnu silu. Máme teda zadefinovaný metodický postup k tomu aby sme mohli uvedené kroky aplikovať na historických dátach konkrétneho aktíva a vyvodit' zo získaných reálnych výsledkov závery.

5 Praktická časť práce

5.1 Počítačová aplikácia

Výpočtovú časť našej diplomovej práce sme robili v počítačovom programe R. Dôvody, prečo sme sa tak rozhodli, sú nasledovné pozitíva, ktoré toto programovacie prostredie prináša:

- 1.) Softvér R je voľne dostupná aplikácia stiahnuteľná na internete
- 2.) Pozitívne skúsenosti s programovaním v tomto prostredí z minulosti
- 3.) Jednoduché používateľské rozhranie
- 4.) Vhodný nástroj na prácu s časovými radmi
- 5.) Vhodný nástroj na testovanie štatistických hypotéz
- 6.) V stiahnuteľných balíkoch tohto programu môžeme nájsť mnohé užitočné preddefinované funkcie, ktoré sme k výpočtom použili.

Kompletná výpočtová časť tejto práce sa nachádza v šiestich priložených súboroch – *funcie.R*, *testy.R*, *MA.R*, *RSI.R*, *MACD.R*, *Buy_and_Hold.R*. V nasledujúcej časti si popíšeme jednotlivé súbory a použité funkcie, aby sme čitateľovi uľahčili zorientovať sa v priložených súboroch.

Súbor ***funcie.R*** obsahuje nami zadefinované pomocné funkcie, ktoré sú v jednotlivých častiach programu volané.

Funkcia *init <- function()* slúži ako inicializačná funkcia na začiatku práce s našimi súborami. Vymaže premenné z pamäte a načíta príslušné knižnice, ktoré budeme potrebovať. Ich spustenie si vyžaduje mať nainštalované nasledovné balíky:

- 1.) (*xlsx*) a (*XLConnect*) – slúžia na načítavanie a zapisovanie údajov do excelu, s ktorým je naša aplikácia prepojená
- 2.) (*TTR*) – uľahčuje prácu s finančnými časovými radmi, obsahuje preddefinované funkcie na výpočet indikátorov technickej analýzy a ich analyzovanie a množstvo ďalších funkcií.
- 3.) (*quantmod*) – poskytuje napr. načítavanie vstupných burzových dát priamo z internetu, prepojením napr. z *Finance Yahoo*, poskytuje možnosť vykreslovať špeciálne grafy technických indikátorov
- 4.) (*graphics*) – grafický balík poskytujúci pokročilé nástroje potrebný pri tvorbe grafov

5.) (stats) – štatistický balík slúžiaci napr. na testovanie hypotéz s množstvom preddefinovaných štatistických testov

Výstupom funkcie *init* je premenná *myNumber*, ktorú používame na označenie poradového čísla riadku výstupného excelovského súboru, kam exportujeme naše výsledky. Na začiatku práce s našimi súbormi je preto nastavená jej hodnota na 0.

Funkcia *LoadmyData <- function(ImportFile)* načíta dáta zo vstupného súboru, ktorý si používateľ špecifikuje nastavením premennej *ImportFile*. My sme načítavali historické dáta uložené v .csv súbore stiahnuté zo stránky finance.yahoo.com. Keďže tieto historické dáta sú zoradené od najaktuálnejšieho dátumu po najstarší, vo funkcii *LoadmyData* sme ich obrátili v opačnom poradí, aby sme s nimi mohli ďalej pracovať.

Ďalšími funkciami, ktoré sme si zadefinovali sú funkcie na generovanie obchodných signálov. Pomocou funkcie *GenerateSignals <- function(a, b)* generujeme obchodné signály pre 3 typy pravidiel na identifikáciu trendu a to: prekríženie Close ceny a zvoleného kľzavého priemeru, prekríženie dvoch kľzavých priemerov a nakoniec prekríženie hodnoty MACD indikátora s jeho signálnou čiarou. Ďalej nasleduje funkcia *GenerateSignalsTTO <- function(a, Cent)*, ktorá generuje signály pre pravidlo prechodu cez neutrálnu líniu u indikátora RSI. Nasledujúcich 6 funkcií typu *GenerateSignalsTTI <- function(a, Down, Up)* pre pravidlo prechodu hraníc, ktoré testujeme použitím indikátora RSI. Označujeme ich skratkou TT1 – TT6 (angl. skratka treshhold transition). Ako sú definované tieto pravidlá sme si popísali v kapitole (3.3) tejto práce. Funkcia *GenerateSignalsInverse <- function(a)* slúži pri tvorbe inverzných pravidiel, priradí každému pravidlu opačné pozície (short namiesto long a long namiesto short).

Funkcie *myMonteCarloPermutation <- function(permutates, myTradingSignal, k)* a *myBootstrap <- function(permutates,k)* používame na tvorbu vzorky náhodne generovaných priemerných ročných výnosov Monte Carlo permutáciami a metódou Bootstrap. V rámci týchto dvoch funkcií vytvárame pri metóde Monte Carlo náhodnú vzorku s výberom bez návratu pomocou vstavanej funkcie *sample(permutates, replace=False)* a pri bootstrap metóde *sample(permutates, replace=TRUE)*. Poslednou nami definovanou funkciou je *Export <- function(ExportFile, data, myNumber)*, pomocou ktorej zapisujeme získané výsledky do výstupného excelovského súboru.

V ďalších priložených súboroch na CD: *MA.R*, *MACD.R*, *RSI.R* nastavujeme rôzne parametre pre príslušné testované indikátory. Pomocou funkcií na generovanie obchodných signálov popísaných vyššie dostávame časové rady odporúčaných obchodných pozícií reprezentovaných hodnotami $\{+1, -1\}$ v premennej *myTradingSignal*.

Samotný backtesting jednotlivých pravidiel potom prebieha v súbore *testy.R*. Vypočítame v ňom priemerný ročný výnos, ktoré by pravidlo dosiahlo v sledovanom období podľa postupu popísanom v kapitole (3.5). Následne aplikujeme funkcie Monte Carlo permutácií a bootstrap na tvorbu vzorky náhodne generovaných priemerných ročných výnosov. Či sú tieto dáta z normálneho rozdelenia, testujeme štatistickými testami normality a tými sú konkrétne *Kolmogorov-Smirnov test* a *Shapiro-Wilkov test normality*. Postupom definovaným v kapitole (4) následne vypočítame p-hodnotu pre obidve spomenuté metódy, na základe ktorej určujeme štatistickú významnosť našich pravidiel. Výstupom našej aplikácie je napokon excelovský súbor so zaznamenanými výsledkami.

Snažili sme sa používať intuitívne názvy premenných pre lepšiu prehľadnosť nášho programu. Ostatné použité funkcie a premenné sú popísané v komentároch v priložených súboroch, preto ich tu nebudeme podrobne rozoberať.

5.2 Použité vstupné dáta a parametre

Na účely spätného testovania našich pravidiel sme ako historické dáta použili denné dáta akciového indexu Standard & Poor's 500 (skr.S&P 500). Dáta sme stiahli z internetovej stránky Yahoo! Finance⁵⁰. Za sledované obdobie sme si zvolili obdobie posledných 10 rokov a to konkrétne od 04.04.2005 po 02.04.2015. Typy obchodných pravidiel a použitých indikátorov sme si predstavili v kapitole (3.3). Zostáva nám už len zadefinovať si vstupné parametre týchto indikátorov.

Pri pravidlách, pomocou ktorých sa snažíme identifikovať trend, sme používali hlavne kĺzavé priemery. Ako sme už uviedli v časti (2.1), kĺzavé priemery majú jeden vstupný parameter a to počet dní n , z ktorých sú kĺzavé priemery počítané. Čím väčšie n zvolíme, tým dosiahneme väčšieho vyhladenia dát, ale naše signály budú generované s väčším

⁵⁰ YAHOO! FINANCE. Dostupné na internete (3.4.2015): <http://finance.yahoo.com>

oneskorením. Naopak pri menšom n môžeme očakávať pružnejšie reagovanie na cenové pohyby, o to viac však bude falošných signálov spôsobených dočasnými fluktuáciami. Určiť tento optimálny počet dní n nie je jednoduché a práve to bolo jedným z cieľov nášho výskumu. Aby sme otestovali aj krátke aj dlhé časové obdobia, z ktorých sú kľzavé priemery počítané, použili sme na nastavenie vstupného parametra 3, 5, 8, 10, 12, 15, 20, 26, 30, 40, 50, 60, 100, 150, 200 a 250– dňové kľzavé priemery. Snažili sme sa tak výpočty tohto parametra prispôbiť tradičným počtom obchodných dní na burze na horizonte približne pol týždňa, týždeň, jeden a pol týždňa, 2 týždne, 3 týždne, 1 mesiac, mesiac a pol, 2 mesiace 2 a pol mesiaca, štvrt'roka, polroka a posledná hodnota by mala predstavovať približne jeden obchodný rok. Máme tak zastúpené krátkodobé aj dlhodobé horizonty na výpočet kľzavých priemerov. Niektoré nastavenia ako napr. 12 dní alebo 26 dní sme použili preto, že sú často technickými analytikmi alebo samotnými autormi indikátorov odporúčané ako optimálne nastavenia.

Pri prvom pravidle prekríženia sa kľzavého priemeru s Close cenou sme testovali obchodné pravidlá pre všetky tieto počty dní pre všetky typy nami uvedených kľzavých priemerov, čiže SMA, WMA a EMA. To nám dalo možnosť otestovať spolu $3 \times 16 = 48$ obchodných pravidiel.

Pri pravidle prekríženia sa dvoch kľzavých priemerov sme testovali všetky možné kombinácie kratšieho a dlhšieho kľzavého priemeru zostavené z uvedených počtov dní a opäť pre všetky typy kľzavých priemerov SMA, WMA, EMA. Takto sme dostali $3 \times \binom{16}{2} = 360$ obchodných pravidiel.

Na nastavenie parametrov indikátora MACD sme použili 3, 5, 8, 10, 12, 20, 26, 30, 40, 50, 100, 150, 200, 250 dňové kľzavé priemery. Všetkými kombináciami kratšieho a dlhšieho kľzavého priemeru sme dostali $\binom{14}{2}$ možností. Na výpočet signálnej čiary sme použili 3, 5, 9, 20 dňové kľzavé priemery, čím sme dostali $91 \times 4 = 364$ obchodných pravidiel.

Pri indikátore RSI sme hranice prepredanosti a prekúpenosti nastavili vo fixovaných vzdialenostiach 10 a 20 od neutrálnej línie. To znamená, že okrem tradičného rozloženia hraníc na hodnotách 30 a 70 podľa autora tohto indikátoru Wildera, sme použili aj

nastavenie hraníc na hodnotách 40 a 60. Počet dní, za ktorý sme RSI indikátor počítali, bol 3, 5, 8, 10, 12, 14, 15, 20, 26, 30, 40 a 50 dní. To nám dalo $2 \times 12 \times 6 = 144$ možností pre 6 pravidiel prechodov cez hranice prepredanosti a prekúpenosti a $2 \times 12 = 24$ možností pre pravidlo prechodu cez nulovú líniu. Spolu sme tak pre indikátor RSI otestovali $144 + 24 = 168$ kombinácií obchodných pravidiel.

Ku každému testovanému pravidlú sme vytvorili aj tzv. inverzné pravidlo, ktoré generuje obchodné signály protichodne k tradičnému pravidlu.

Vopred však upozorňujeme, že pre výpočtovú náročnosť sa nám nepodarilo spracovať výsledky ku MACD pravidlu v dostatočnom rozsahu, preto ich nebudeme vo výsledkovej časti uvádzať. Aj napriek tomu sa nám podarilo dohromady otestovať 576 tradičných obchodných pravidiel a k nim prislúchajúcich 576 inverzných pravidiel, čo nám dáva dostatočne veľkú množinu výsledkov, aby sme otestovali ich použiteľnosť.

6 Výsledky

Výsledky získané z testovania 576 tradičných obchodných pravidiel a 576 inverzných pravidiel uvádzame priložené na CD v excelovských súboroch *vysledky_MA.xlsx*, *vysledky_2MA.xlsx*, *vysledky_RSI.xlsx* a *vysledky_all.xlsx*. V súbore *vysledky_MA.xlsx* sa nachádzajú výsledky pre pravidlo prekriženia kľzavého priemeru a Close ceny, v súbore *vysledky_2MA.xlsx* výsledky pre pravidlo prekriženia dvoch kľzavých priemerov a v súbore *vysledky_RSI.xlsx* pravidlá prechodov hraníc aplikované na indikátor RSI. Každý jeden súbor obsahuje rozdelené výsledky pre tradičné a inverzné pravidlá, ako aj spoločné porovnanie tradičných a inverzných pravidiel. V súbore *vysledky_all.xlsx* je vzájomné porovnanie všetkých testovaných pravidiel dokopy. V každom priloženom súbore s výsledkami sú v jednotlivých stĺpcoch uvedené nasledovné údaje:

- 1.) Názov testovaného pravidla
- 2.) Priemerný ročný výnos pravidla dosiahnutý v sledovanom období
- 3.) Priemerný ročný výnos vzorky 1 000 náhodne generovaných priemerných ročných výnosov pravidla metódou Monte Carlo Permutácie
- 4.) 95%-ný interval spoľahlivosti vzorky 1 000 náhodne generovaných priemerných ročných výnosov pravidla metódou Monte Carlo Permutácie
- 5.) P-hodnota testovanej hypotézy H_0 vypočítaná metódou Monte Carlo permutácie
- 6.) Priemerný ročný výnos vzorky 1 000 náhodne generovaných priemerných ročných výnosov pravidla metódou bootstrap
- 7.) 95%-ný interval spoľahlivosti vzorky 1 000 náhodne generovaných priemerných ročných výnosov pravidla metódou bootstrap
- 8.) P-hodnota testovanej hypotézy H_0 vypočítaná metódou bootstrap

V stĺpcoch, kde sa nachádza p-hodnota, sú bledozelenou farbou rozlíšené tie výsledky pravidiel, kde p-hodnota vyšla menšia ako 0,05. U týchto pravidiel sme teda hypotézu H_0 , že pravidlo nemá žiadnu prediktívnu silu, zamietli a môžeme jeho výnos považovať za štatisticky významný. V 2. stĺpci, kde sa nachádza priemerný ročný výnos pravidla dosiahnutý v sledovanom období, sú bledozelenou farbou vyznačené tie pravidlá, u ktorých bola štatistická významnosť ich výnosu podporená len jednou z dvojice metód (Monte Carlo permutácií a bootstrap), tmavozelenou farbou sú vyznačené tie pravidlá, u ktorých bola štatistická významnosť ich výnosu podporená oboma metódami.

V priložených súboroch sa teda nachádzajú kompletne údaje z nášho testovania, v nasledovnej časti si uvedieme v tabuľkách vždy skrátenú výsledkovú verziu obsahujúcu

názov pravidla, jeho dosiahnutý priemerný ročný výnos a p-hodnoty pre príslušne dva typy štatistických metód – Monte Carlo permutáciu a bootstrap.

Na výsledky sa budeme pozerat' z viacerých hľadísk a to z hľadiska optimálnej dĺžky nastavených parametrov, z hľadiska porovnania výnosnosti jednotlivých typov pravidiel medzi sebou a z hľadiska porovnania rozdielu v úspešnosti medzi tradičnými a inverznými pravidlami.

6.1 Výsledky pre pravidlo prekríženia kĺzavého priemeru s Close cenou

Toto technickými analytikmi bežne používané pravidlo neprinieslo ani ju jedného z použitých typov kĺzavých priemerov štatisticky významný výnos pre rôzne nastavené dĺžky parametra n . Pravidlo s najvyšším dosiahnutým výnosom bolo pravidlo prekríženia 60-dňového EMA s Close cenou, ktoré dosiahlo priemerný ročný výnos 2,90 % p.a. Oveľa zaujímavejšie však v tejto kategórii pravidiel dopadli výsledky inverzných pravidiel. Štatisticky významný výnos u oboch metód (Monte Carlo permutácia a bootstrap) dosiahlo 15 zo 48 testovaných pravidiel a 4 pravidlá dosiahli štatisticky významný výnos u jednej z metód. Najvyšší výnos dosiahlo inverzné pravidlo k pravidlu prekríženia 8-dňového jednoduchého kĺzavého priemeru s Close cenou. Prvých 10 najúspešnejších pravidiel uvádzame v Tabuľke 2:

Tabuľka 2 - Výsledky pre pravidlo prekríženia kĺzavého priemeru s Close cenou

Názov pravidla	Priemerný ročný výnos pravidla	P-hodnota Monte Carlo permutácia	P-hodnota Bootstrap
INV-SMA 8 vs. Close	0,18799714	0,000855486	0
INV-EMA 5 vs. Close	0,180354737	0,001151583	0,001
INV-SMA 5 vs. Close	0,170121405	0,001478451	0,003
INV-WMA 8 vs. Close	0,166937627	0,00331683	0,006
INV-EMA 8 vs. Close	0,147711818	0,008143793	0,006
INV-WMA 5 vs. Close	0,150259668	0,007717129	0,007
INV-WMA 10 vs. Close	0,160282921	0,004293236	0,008
INV-SMA 10 vs. Close	0,144499659	0,008970884	0,009
INV-WMA 3 vs. Close	0,141269465	0,011170771	0,009
INV-EMA 10 vs. Close	0,141199816	0,008948931	0,01

Zdroj: vlastné spracovanie

Z hľadiska optimálnej dĺžky počtu dní na nastavenie parametra pre kĺzavý priemer sa javí obdobie 5 alebo 8 dní.

6.2 Výsledky pre pravidlo prekríženia dvoch kĺzavých priemerov

Ani pri tomto type pravidla nevykázalo žiadne z tradičných pravidiel štatisticky významný výnos. Hoci najvyšší dosiahnutý výnos pravidlom prekríženia SMA 40 a SMA 150 bol 9,88 % p.a., ani jedna z metód neukázala, že by toto pravidlo malo skutočnú prediktívnu silu. Opäť však lepšie výsledky dosiahli inverzné pravidlá k tomuto typu pravidla. Z 360 testovaných pravidiel 18 dosiahlo štatisticky významný výnos u oboch metód a ďalšie 3 pravidlá len u jednej z metód. Najvyšší výnos dosiahlo inverzné pravidlo prekríženia 8 a 10 dňového WMA a to 15,38 % p.a. Z hľadiska nastavenia optimálnej dĺžky kĺzavých priemerov, dosiahli v testoch najlepšie výsledky kombinácie krátkodobých kĺzavých priemerov od 5 do 12 dní. Prvých 10 najúspešnejších pravidiel uvádzame v Tabuľke 3:

Tabuľka 3 - Výsledky pre pravidlo prekríženia dvoch kĺzavých priemerov

Názov pravidla	Priemerný ročný výnos pravidla	P-hodnota Monte Carlo permutácia	P-hodnota Bootstrap
INV-WMA 8 vs. WMA 10	0,153781019	0,005117048	0,004
INV-SMA 5 vs. SMA 10	0,149066757	0,007021933	0,009
INV-WMA 3 vs. WMA 8	0,14258377	0,009092486	0,01
INV-WMA 8 vs. WMA 12	0,13267803	0,014582334	0,013
INV-EMA 3 vs. EMA 5	0,152222825	0,005081039	0,017
INV-SMA 8 vs. SMA 10	0,124481328	0,019705923	0,017
INV-WMA 5 vs. WMA 10	0,126705079	0,016343787	0,017
INV-SMA 3 vs. SMA 10	0,124885805	0,022273274	0,02
INV-EMA 5 vs. EMA 12	0,122738077	0,028627032	0,023
INV-WMA 5 vs. WMA 12	0,118880541	0,022814454	0,025

Zdroj: vlastné spracovanie

6.3 Výsledky pre pravidlá prechodov hraníc

V tejto skupine pravidiel bolo testovaných 168 tradičných pravidiel, z ktorých štatisticky významný výnos dosiahlo 26 pravidiel u oboch metód a 10 pravidiel u jednej metódy. Najvyšší výnos dosiahlo pravidlo signalizujúce long pozíciu po prechode RSI indikátora vypočítaného so spätným pohľadom 3 dní pod hranicu prepredanosti zhora na dol a short pozíciu po prechode hranice prekúpenosti zdola nahor, pri nastavení hraníc na hodnoty 40

a 60. Toto pravidlo je v súlade s logikou technickej analýzy, že sa aktívum oplatí nakúpiť keď je „príliš“ lacné a predat', keď je „príliš drahé“. Dosiahnutý výnos bol 19,38 %. Ako môžeme vidieť aj v Tabuľke 4, kde uvádzame zmiešané výsledky tradičných aj inverzných pravidiel, pre výpočet RSI indikátora je vhodnejšie použiť kratšiu dĺžku parametra n a to 3 alebo 5 dní ako dlhšie časové obdobia. K nastaveniu hodnôt prechodových hraníc sa nedá jednoznačne určiť, ktoré nastavenie je najoptimálnejšie. U pravidiel používajúceho ako obchodný signál prechod cez neutrálnu líniu, boli úspešnejšie inverzné pravidlá, ktoré sú v rozpore s odporúčanými obchodnými pravidlami. Zaujímavosťou je, že napríklad pôvodné pravidlo na použitie indikátora RSI, ktoré bolo definované jeho autorom W.Wilderom s použitím 14-dňového spätného pohľadu a nastavením prechodových hraníc na úrovni 30 a 70, dosiahlo záporný výnos -0,71 % p.a.

Tabuľka 4 - Výsledky pre pravidlá prechodu hraníc

Názov pravidla	Priemerný ročný výnos pravidla	P-hodnota Monte Carlo permutácia	P-hodnota Bootstrap
TT2(30 , 70) - RSI 3	0,1879659	0,001151569	0
INV-TT0(50) - RSI 5	0,179386639	0,001860569	0,001
TT2(40 , 60) - RSI 3	0,193755085	0,000784022	0,003
INV-TT0(50) - RSI 5	0,179386639	0,001877631	0,004
INV-TT6(40 , 60) - RSI 3	0,169633246	0,00241525	0,006
TT1(40 , 60) - RSI 5	0,158460575	0,003201819	0,008
TT1(40 , 60) - RSI 3	0,160148703	0,002784151	0,01
INV-TT0(50) - RSI 8	0,149034641	0,006553451	0,011
TT1(30 , 70) - RSI 3	0,146917568	0,004841106	0,014
TT2(40 , 60) - RSI 5	0,158236928	0,004644097	0,014

Zdroj: vlastné spracovanie

6.4 Celkové porovnanie pravidiel

Na záver uvádzame celkové porovnanie 576 testovaných tradičných pravidiel medzi sebou. Z tohto počtu zaznamenalo 26 z nich štatistickú významnosť výnosu u oboch metód a 14 z nich u jednej metódy. Celkovo najvyšší výnos dosiahlo už spomínané pravidlo odporúčanej long pozície pri prechode pod hranicu prepredanosti zhora na dol a short pozície po prechode hranice prekúpenosti zdola nahor s hranicami na úrovni 40 a 60 vypočítané z indikátora RSI so spätným pohľadom 3 dní. Medzi najúspešnejšími pravidlami dominovali hlavne pravidlá prechodu hraníc 1. a 2. typu s kratším nastavením parametra n . Prehľad prvých 10 uvádzame v Tabuľke 5:

Tabuľka 5 - Výsledky porovnania všetkých 576 tradičných testovaných pravidiel

Názov pravidla	Priemerný ročný výnos pravidla	P-hodnota Monte Carlo permutácia	P-hodnota Bootstrap
TT2(30 , 70) - RSI 3	0,1879659	0,001151569	0
TT2(40 , 60) - RSI 3	0,193755085	0,000784022	0,001
TT1(40 , 60) - RSI 5	0,158460575	0,003201819	0,003
TT1(40 , 60) - RSI 3	0,160148703	0,002784151	0,004
TT1(30 , 70) - RSI 3	0,146917568	0,004841106	0,006
TT2(40 , 60) - RSI 5	0,158236928	0,004644097	0,008
TT1(30 , 70) - RSI 10	0,140911384	6,5946E-05	0,01
TT1(30 , 70) - RSI 8	0,147847317	0,000354353	0,011
TT1(30 , 70) - RSI 5	0,13352892	0,003975049	0,014
TT2(30 , 70) - RSI 50	0,13977629	0,007315451	0,014

Zdroj: vlastné spracovanie

Ako posledné uvedieme celkové porovnanie všetkých 1152 testovaných pravidiel, ktoré zahŕňa všetky tradičné aj inverzné pravidlá. V Tabuľke 6. je uvedených prvých 10 pravidiel, u ktorých sme hypotézu H_0 zamietli a ich výnos môže byť spôsobený skutočnou prediktívnou silou pravidiel. Celkovo sa štatistická významnosť výnosu ukázala na základe oboch použitých štatistických metód (Monte Carlo permutácie a bootstrap) u 77 pravidiel a u ďalších 23 na základe jednej z týchto dvoch metód.

Tabuľka 6 - Výsledky porovnania všetkých 1152 testovaných pravidiel

Názov pravidla	Priemerný ročný výnos pravidla	P-hodnota Monte Carlo permutácia	P-hodnota Bootstrap
INV-SMA 8 vs. Close	0,18799714	0,000855486	0
TT2(30 , 70) - RSI 3	0,1879659	0,001151569	0
INV-TT0(50) - RSI 5	0,179386639	0,001860569	0
INV-EMA 5 vs. Close	0,180354737	0,001151583	0,001
TT2(40 , 60) - RSI 3	0,193755085	0,000784022	0,001
INV-SMA 5 vs. Close	0,170121405	0,001478451	0,003
TT1(40 , 60) - RSI 5	0,158460575	0,003201819	0,003
INV-TT0(50) - RSI 5	0,179386639	0,001877631	0,003
INV-TT6(40 , 60) - RSI 3	0,169633246	0,00241525	0,003
INV-WMA 8 vs. WMA 10	0,153781019	0,005117048	0,004

Zdroj: vlastné spracovanie

Celkovo štatisticky najvýznamnejší výnos 18,80% p.a. dosiahlo inverzné pravidlo prekriženia 8-dňového jednoduchého kľzavého priemeru s Close cenou. Podľa logiky tohto inverzného pravidla by mal obchodník zaujať pozíciu long ak je Cena pod svojim 8-dňovým SMA a naopak pozíciu short, ak je cena nad svojim 8-dňovým SMA. Najvyšší dosiahnutý výnos bol 19,38 % u spomínaného pravidla TT2(40 , 60) - RSI 3.

Pre úplnosť nášho výskumu ešte porovnáme výnosnosť našich testovaných pravidiel s výnosom stratégie buy and hold. Na nami sledovanom 10-ročnom období by sme touto stratégiou kúpy a držania dosiahli priemerný ročný výnos 5,6378 % p.a. Porovnanie koľko nami testovaných pravidiel dokázalo poraziť túto stratégiu uvádzame v tabuľke 7. Vidíme, že aj keď niektoré naše pravidlá dosiahli vyšší výnos ako buy & hold stratégia, neboli našimi metódami označené za štatisticky významné a tento ich výnos mohol byť spôsobený len náhodou. Náš stanovený benchmark a metódy na určenie štatistickej významnosti výnosov testovaných pravidiel sa teda ukázali byť prísnejším kritériom ako porovnanie výnosov so stratégiou buy and hold.

Tabuľka 7 - Porovnanie pravidiel so stratégiou buy & hold

Porovnanie výsledkov testovaných pravidiel	Tradičné pravidlá	Inverzné pravidlá	Všetky pravidlá
Celkový počet testovaných pravidiel	576	576	1 152
Počet pravidiel s dosiahnutým výnosom vyšším ako buy & hold stratégiou	99	115	214
Počet pravidiel s výnosom štatisticky významným na základe oboch metód (Monte Carlo permutácie a bootstrap)	26	51	77
Počet pravidiel s výnosom štatisticky významným na základe len jednej z metód (Monte Carlo permutácie a bootstrap)	14	9	23

Zdroj: vlastné spracovanie

Na základe našich nameraných výsledkov môžeme usúdiť, že najúspešnejšie boli v predikovaní cenových pohybov na trhu inverzné pravidlá k pravidlám typu prekriženia kľzavého priemeru s cenou alebo dvoch kľzavých priemerov navzájom a pravidlá založené na prechode hraníc prekúpenosti a prepredanosti s kratším nastavením parametra n (počtu

dni). Naopak tradičné pravidlá na predpovedanie trendu založené na kľzavých priemeroch nevykazovali nijaké štatisticky významné výnosy. Môže to byť spôsobené napr. tým, že keď rovnaké základné pravidlá používa veľké množstvo obchodníkov, tieto pravidlá strácajú svoju platnosť. Tradičné vnímanie logiky pravidiel nemusí byť vždy správne a môže sa stať, že nejakú chybnú úvahu po sebe kopíruje mnoho obchodníkov. Pokiaľ toto správanie iní jednotlivci predvídajú a idú akoby „proti trhu“, môžu dosiahnuť vyšších výnosov. Komplexné porovnanie pravidiel však nie je jednoduché, keďže pravidlá sú rozdielne a na rôznych typoch dát môžu dosahovať rôzne výsledky. Použitím sofistikovanejších metód na vyhodnocovanie úspešnosti obchodných pravidiel by sme mohli dospieť k iným záverom. Preto je dôležité poukázať aj na niektoré nedostatky nášho výskumu. Zhrnieme si teda základné výhody a nevýhody nášho prístupu.

6.5 Nedostatky nášho výskumu

1.) Testovanie len samostatných indikátorov

Pri tvorbe obchodných pravidiel sme testovali len samostatné indikátory. V dôsledku časovej a výpočtovej náročnosti sme otestovali len malú vzorku indikátorov z potenciálne veľkého množstva možností. Kombinovaním týchto indikátorov medzi sebou a použitím ďalších indikátorov by bolo možné vytvoriť komplexnejšie pravidlá, ktoré by mohli dosiahnuť väčšie výnosy. Taktiež zakomponovaním riadenia rizika do našej stratégie by sa dala vylepšiť robustnosť použitých obchodných pravidiel.

2.) Pravidlá sme testovali len na dátach indexu S&P 500

Pravidlá, ktoré výkazali štatistickú významnosť výnosov na tomto akciovom indexe, nemusia byť úspešné po aplikovaní na dátach iného indexu alebo finančného inštrumentu. Naopak, pravidlá, ktorých prediktívna sila bola našimi testami zamietnutá, môžu na iných dátach dosiahnuť štatisticky významné výnosy

3.) Použitie len jedného časového obdobia na testovanie pravidiel

Pravidlá, ktoré výkazali štatistickú významnosť výnosov v danom 10-ročnom časovom období, nemusia byť úspešné po aplikovaní na dátach v inom časovom období alebo na rôzne dlhom časovom období.

4.) Použitie jednoduchých binárnych pravidiel

Tieto pravidlá značne zjednodušujú našu rozhodovaciu situáciu, keďže počas celého sledovaného obdobia sa rozhodujeme len medzi dvoma pozíciami – long a short. Stoja na

predpoklade, že trh je neustále neefektívny a kontinuálne ponúka ziskové príležitosti. V čase veľkých fluktuácií na trhu prerábame v dôsledku množstva falošných signálov. Používaním aj neutrálnej pozície by sme mohli docieľiť to, že v čase týchto výkyvov by sme mohli z otvorených pozícií vystúpiť a držať sa mimo trhu, pokiaľ sa situácia na trhu ukludní a indikátori nám budú znova signalizovať nový profilujúci sa trend.

5.) Používanie predaja na krátko

Tým, že v našej práci používame short pozície, uvažujeme tým o neobmedzenej možnosti tzv. predaja na krátko (angl. shortselling). V praxi je však často pri obchodovaní na burzách tento typ predaja zakázaný.

6.) Neuvažovanie transakčných nákladov

Poplatky za obchodovanie by mohli značným spôsobom negatívne ovplyvniť výnosnosť našich pravidiel, najmä pri pravidlách, ktoré nám generovali časté signály na zmenu pozície.

7.) Rozdiely medzi otváracími a uzatváracími cenami

Neuvažovali sme nad stratami spôsobenými prípadným väčším rozdielom medzi uzatváracou cenou v deň t , na základe ktorej sme generovali obchodný signál a otváracou cenou pre deň $t+1$, na ktorú sme tento obchodný signál aplikovali.

6.6 Výhody nášho výskumu

- 1.) Použitie benchmarku na stanovenie štatistickej významnosti našich pravidiel. Výnosnosť pravidla je relevantná len vo vzťahu k nejakému benchmarku. Absolútna výnosnosť je relatívny pojem. Použili sme síce najnižší rozumný benchmark a to výnos pravidla, ktoré nemá prediktívnu silu. Pravidlo sme teda mohli vyhlásiť za efektívne len vtedy, ak porazilo svojou výnosnosťou výnosnosť náhodne generovaného pravidla bez prediktívnej sily na danej 95 %-nej hladine významnosti. Pre praktickú významnosť pravidiel sa ako benchmark často používa výnos pravidla stratégiou Buy & Hold. Hoci niektorým našim pravidlám sa podarilo poraziť stratégiu Buy & Hold, v štatistických testoch bola ich prediktívna sila zamietnutá. To znamená, že aj v takom prípade mohol byť ich výnos len dielom náhody.
- 2.) Štatistické testy sme aplikovali na každé jedno pravidlo samostatne.

- 3.) Odstránenie trendu z dát, z ktorých boli vypočítané denné výnosy pravidiel. Zabezpečili sme tým to, aby sme mohli medzi sebou relevantne porovnať pravidlá s rôznou náklonnosťou k long a short pozíciám.
- 4.) Aplikovanie obchodného signálu vygenerovaného na základe zatváracej ceny až na otváraciu cenu nasledujúceho dňa. Keďže v praxi nie je možné realizovať obchod po zatvorení burzy, najbližšia príležitosť, kedy môžeme aplikovať obchodný signál obdržaný na konci obchodného dňa z uzatváracej ceny, je až pri otvorení burzy v nasledujúci deň.
- 5.) Testovanie inverzných pravidiel. Ako sme už spomínali, niektoré tradičné pravidlá môžu byť technickými analytikmi vyhlasované za úspešné len vďaka svojej popularite a tým, že ich používa veľké množstvo obchodníkov, strácajú prediktívnu silu. Testovaním inverzných pravidiel sme poukázali na to, že tradičné vnímanie pravidiel nemusí byť vždy správne a logika týchto pravidiel môže byť presne opačná.
- 6.) Vytvorenie vlastnej počítačovej aplikácie na spätné testovanie pravidiel a vyhodnocovanie ich štatistickej úspešnosti.

Záver

V našej diplomovej práci sme skúmali štatistickú úspešnosť predikcie trhov matematickými metódami technickej analýzy. V teoretickej časti práce sme v prvej kapitole uviedli základné princípy technickej analýzy a porovnali sme ju s princípmi fundamentálnej analýzy. Poukázali sme na rozdiely týchto dvoch prístupov a na výhody použitia technickej analýzy. Ďalej sme predložili základy teórie efektívnych trhov, ktorá je v rozpore s princípmi technickej analýzy. Poukázali sme na nedostatky technickej analýzy tvrdeniami, na ktorých je teória efektívnych trhov založená. Následne sme uviedli protiargumenty na obhajobu použiteľnosti technickej analýzy ako nástroja na predikovanie budúceho vývoja trhov.

V druhej kapitole sme si zadefinovali matematické metódy technickej analýzy ako objektívne metódy, ktoré sú založené na jasných vopred definovaných matematických a logických algoritmoch. Uviedli sme tým do súvisu tieto metódy s algoritmickým obchodovaním. Popísali sme si vybrané technické indikátory a to kľzavé priemery, MACD a RSI indikátor, ktoré sme neskôr používali na tvorbu našich obchodných pravidiel.

Obchodné pravidlá a princíp ich tvorby sme si popísali v tretej kapitole. Použili sme binárne obchodné pravidlá. Pomocou kľzavých priemerov a MACD sme si stanovili obchodné pravidlá na identifikovanie trendu na trhu na základe tradičnej logiky technickej analýzy. Použili sme aj 6 typov pravidiel prechodu hraníc prekúpenosti a prepredanosti a jedno pravidlo prechodu neutrálnej línie u RSI indikátoru. K vybraným tradičným obchodným pravidlám sme zostavili aj inverzné pravidlá, ktoré generovali obchodné pozície v obrátenej logike k tradičným pravidlám. Uviedli sme spôsob výpočtu výnosov našich pravidiel.

V ďalšej kapitole sme uviedli základné štatistické princípy testovania hypotéz. Stanovili sme si benchmark, s ktorým sme porovnávali výnosy nášho pravidla. Týmto benchmarkom bol výnos pravidla, ktoré nemá prediktívnu silu a jeho očakávaný výnos na detrendovaných dátach je nulový. Stanovili sme si nulovú a alternatívnu hypotézu, ktorú sme testovali. Uviedli sme dve štatistické metódy – Monte Carlo permutáciu a bootstrap metódu na tvorbu vzorky náhodne generovaných výnosov pravidla, s ktorými sme

porovnávali skutočný výnos nášho pravidla dosiahnutí počas spätného testovania na historických dátach. Na základe vypočítanej p-hodnoty sme určovali štatistickú významnosť pravidla. Ak nám vyšla p-hodnota menšia ako 0,05, nulovú hypotézu H_0 , že pravidlo nemá prediktívnu silu, sme zamietli.

Hlavným cieľom práce bolo demonštrovať použitie štatistického prístupu na vyhodnocovanie štatistickej významnosti obchodných pravidiel a to použitím dvoch štatistických metód – Monte Carlo permutácie a bootstrap metódy.

V praktickej časti sme v nami naprogramovanej počítačovej aplikácii podľa tejto metodiky spätne testovali výnosnosť pravidiel na historických dátach akciového indexu S&P 500. Cieľom bolo nájsť vhodným nastavením parametrov také pravidlá, ktorých výnos by bol na sledovanom období štatisticky významný. Takéto pravidlá by mali mať predpoklad byť úspešné v predikcii trhov aj v budúcnosti. Hlavný prínos práce vidíme vo vlastnej naprogramovanej počítačovej aplikácii, pomocou ktorej sme backtestovali dokopy 576 tradičných a 576 inverzných obchodných pravidiel. Na základe získaných výsledkov našich testov sme ukázali, že matematické metódy technickej analýzy môžu slúžiť v určitých prípadoch na predpovedanie pohybov na trhoch. Výsledky nášho výskumu však nemusia platiť pri aplikovaní na iné dáta. Preto je štatistická analýza obchodných pravidiel dôležitým nástrojom.

Keďže táto práca zasahuje svojím rozsahom do viacerých oblastí, použitá terminológia môže byť v niektorých častiach ťažšie zrozumiteľná. Snažili sme sa uplatniť vedecký prístup k danej problematike. Na možné nedostatky nášho výskumu sme upozornili v záverečnej časti práce. Na druhej strane sme ukázali na niektoré pozitívne výsledky. Ukázali sme, tradičné chápanie logiky technickej analýzy nemusí vždy fungovať v súlade so všeobecnými odporúčaniami. Potvrdzovali to aj výsledky testovaných inverzných pravidiel, ktoré dosahovali štatisticky vyššiu úspešnosť ako testované inverzné pravidlá.

Zoznam použitej literatúry

ALDRIDGE, I.: *High Frequency Trading. A Practical Guide to Algorithmic Strategies and Trading Systems*. John Wiley & Sons, Inc., Hoboken, New Jersey, 2010, 339 s., ISBN: 978-0-470-56376-2

APPEL, G.: *Technical Analysis: Power Tools for Active Investors*. Financial Times, Prentice Hall, 2005, 241 s., ISBN: 0-13-1-47902-4

ARONSON, D. R.: *Evidence-Based Technical Analysis: Applying the Scientific Method and Statistical Inference to Trading Signals*. John Wiley & Sons, Inc., Hoboken, New Jersey, 2007, 544 s., ISBN: 978-0-470-00874-4

EHLERS, J. F.: *Rocket Science for Traders: Digital Signal Processing Applications*
John Wiley & Sons, Inc., New York, 2001, 264 s., ISBN: 978-0-471-40567-2

FOLGER, J., LEIBFARTH, L.: *Make Money Trading. How to Build a Winning Trading Business*. Marketplace Books, Inc., 2007, ISBN: 1-59280-308-3

FOLGER, J.: *Types of Technical Indicators*. Dostupné na internete (10.03.2015):

<http://traderkingdom.com/trading-futures-education-topics/trading-futures-basics/5379-types-of-technical-indicators>

CHOVANCOVÁ, B. et al.: *Finančné trhy - nástroje a transakcie*, Wolters Kluwer, Bratislava, 2014, 661 s., ISBN: 978-80-8168-006-9

KIRKPATRICK, CH. D., DAHLQUIST, J.: *Technical analysis: the complete resource for financial market technicians*. 2. Vydanie. Financial Times Press., New Jersey, 2010, 704 s., ISBN-13: 978-0-13-705944-7

MURPHY, J. J.: *Technical Analysis of the Financial Markets. A comprehensive guide to trading methods and applications*, New York Institute of Finance, New York, 1999, 531 s., ISBN 0-7352-0066-1

RIMARČÍK, M.: *Testy štatistických hypotéz (testy štatistickej významnosti)*, Dostupné na internete (21.03.2015): <http://rimarcik.com/navigator/hypotezy.html>

VESELÁ, J.: *Investování na kapitálových trzích*. Vyd. 1., ASPI, Praha, 2007, 703 s., ISBN: 978-80-7357-297-6

VESELÁ, J.: *Analýza trhu cenných papírů*, I. díl. 2. vydanie, VŠE, Praha, 1999, 522 s., ISBN: 80-7079-563-8

WILDER, W., J., Jr.: *New concepts in technical trading systems*. Hunter Publishing Company, Winston-Salem, North Carolina, 1978, 118 s., ISBN: 0-89459-0278

YAHOO! FINANCE. Dostupné na internete (3.4.2015): <http://finance.yahoo.com>

Zoznam Obrázkov, Tabuliek a grafov

Obrázok 1 - Základné typy trendov	11
Obrázok 2 - Porovnanie kratšieho 10 dňového a dlhšieho 50 dňového kĺzavého priemeru	22
Obrázok 3 – MACD (12, 26, 9)	25
Obrázok 4 - RSI (10)	26
Obrázok 5 - Princíp tvorby obchodného pravidla.....	27
Obrázok 6 - Prechody hraníc	30
Obrázok 7 - Tradičné a inverzné pravidlo	32
Obrázok 8 - P-hodnota.....	36
Obrázok 9 – Bootstrap metóda	39
Tabuľka 1 - Štýly obchodovania v závislosti od doby držania pozície	14
Tabuľka 2 - Výsledky pre pravidlo prekríženia kĺzavého priemeru s Close cenou.....	49
Tabuľka 3 - Výsledky pre pravidlo prekríženia dvoch kĺzavých priemerov	50
Tabuľka 4 - Výsledky pre pravidlá prechodu hraníc	51
Tabuľka 5 - Výsledky porovnania všetkých 576 tradičných testovaných pravidiel.....	52
Tabuľka 6 - Výsledky porovnania všetkých 1 152 testovaných pravidiel.....	52
Tabuľka 7 - Porovnanie pravidiel so stratégiou buy & hold	53

Zoznam príloh na CD

Buy_and_Hold.R

funkcie.R

MA.R

MACD.R

RSI.R

testy.R

vysledky_2MA.xlsx

vysledky_all.xlsx

vysledky_MA.xlsx

vysledky_RSI.xlsx