

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra počítačů

Využití strojového učení při obchodování na energetických trzích

Nazariy Shukatka

Vedoucí: Ing. Božena Mannová, Ph.D.
Obor: Softwarové inženýrství a technologie
Srpen 2021

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Shukatka** Jméno: **Nazariy** Osobní číslo: **452873**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra počítačů**
Studijní program: **Softwarové inženýrství a technologie**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Využití strojového učení při obchodování na energetických trzích

Název bakalářské práce anglicky:

Use of machine learning in trading in energy markets

Pokyny pro vypracování:

Prostudujte problematiku strojového učení a možnosti jeho využití při predikci cen. Popište možnosti, které strojové učení k řešení tohoto problému nabízí. Zaměřte se na algoritmy pro klasifikaci dat. Navrhněte systém pro predikci cen plynu na trhu. Navržený systém implementujte a otestujte na dostupných datech z obchodování na energetických trzích. Dosažené výsledky vyhodnoťte.

Seznam doporučené literatury:

- [1] <https://www.dataquest.io/blog/top-10-machine-learning-algorithms-for-beginners/>
- [2] Pressmann R. S.: Software Engineering,
- [3] <https://medium.com/fair-bytes/explaining-machine-learning-predictions-and-building-trust-with-lime-473bf46de61a>
- [4] Peng R., Matsui E.: The Art of Data Science. Leanpub, 2015
- [5] <https://dspace.vutbr.cz/xmlui/bitstream/handle/11012/69619/final-thesis.pdf?sequence=12&isAllowed=y>

Jméno a pracoviště vedoucí(ho) bakalářské práce:

Ing. Božena Mannová, Ph.D., kabinet výuky informatiky FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **11.02.2021**

Termín odevzdání bakalářské práce: **13.08.2021**

Platnost zadání bakalářské práce: **30.09.2022**

Ing. Božena Mannová, Ph.D.
podpis vedoucí(ho) práce

podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Poděkování

Děkuji Ing. Boženě Mannové, Ph.D za vedení mé bakalářské práce, za její čas a poskytnutí podnětných a cenných rad při konzultacích, které umožnily, aby tato práce mohla vzniknout. Také bych chtěl poděkovat své rodině a přátelům za podporu.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s metodickým návodem o dodržování principů při přípravě vysokoškolských závěrečných prací.

V Praze, 13 srpna 2021

Abstrakt

Bakalářská práce je věnována analýze a srovnání statistických algoritmů a algoritmů strojového učení pro obchodování na energetickém trhu. Popisuje, jaké metody, algoritmy a strategie existují v obchodování a jak je správně používat. Jako praktický příklad statistické strategie je použita strategie: obchodování návratu ceny k běžné hodnotě. Pro příklad algoritmu strojového učení se používá klasifikační algoritmus Random Forest Classifier. Na základě výše uvedených strategií a algoritmů byl implementován systém, který se snaží budovat signály nákupu a prodeje na trhu, jinými slovy, k obchodování. Data pro školení a testování algoritmů jsou skutečná, protože byla stažena přímo z energetické burzy.

Klíčová slova: Strojové učení při obchodování, Strojové učení na energetických trzích, Predikce cen plynu, Klasifikační algoritmy, Obchodování návratu ceny k běžné hodnotě

Vedoucí: Ing. Božena Mannová, Ph.D.

Abstract

The bachelor's thesis focuses on the analysis and comparison of statistical and machine learning algorithms for trading in the energy market. It describes what methods, algorithms and strategies exist in trading and how to use them correctly. As a practical example of a statistical strategy is used: mean reversion strategy. For an example of a machine learning algorithm, the Random Forest Classifier is used. Based on the above-mentioned strategies and algorithms, a system was implemented that tries to build buy and sell signals on the market, in other words, to trade. The data for training and testing the algorithms are real, as they were downloaded directly from the energy exchange.

Keywords: Machine learning in trading, Machine learning in energy markets, Gas price prediction, Classification Algorithms, Mean reversion strategy

Title translation: Use of machine learning in trading in energy markets

Obsah

1 Úvod	1
1.1 Motivace	1
1.2 Cíl	1
1.3 Struktura práce	2
2 Teorie obchodování na trhu	3
2.1 Základy obchodování	3
2.2 Obchodování na energetickém trhu	3
2.3 Techniky predikce cen	4
2.4 Dlouhá pozice (Long position) a Krátká pozice (short selling)	5
2.5 Párové obchodování (pair trading)	5
3 Obchodování s využitím statistických strategií	7
3.1 Mean reversion strategy (obchodování návratu ceny k běžné hodnotě)	7
3.1.1 Použití strategie	8
3.1.2 Výhody a nevýhody	10
3.2 Trend following strategy (strategie sledování trendů)	10
3.2.1 Použití strategie	12
3.2.2 Výhody a nevýhody	13
4 Obchodování s využitím strojového učení	15
4.1 Důvody pro použití strojového učení k obchodování	15
4.2 Hlavní kategorie strojového učení	16
4.2.1 Učení s učitelem	16
4.2.2 Učení bez učitele	17
4.2.3 Učení posilováním	17
5 Analýza	19
5.1 Seznámení s problémem	19
5.2 Data	19
5.3 Párové obchodování	20
5.4 Existující projekty	21
6 Návrh a implementace	23
6.1 Výběr technologií	23
6.2 Použité knihovny Pythonu	23
6.3 Průběh realizace projektu	24
7 Testování a vyhodnocení	27
8 Závěr	31
Literatura	33

Obrázky

3.1 Akcie Amazon [1]	8
3.2 Signál k nákupu [2]	9
3.3 Signál prodeje [3]	9
3.4 Akcie Microsoft [4]	12
3.5 Strategie sledování trendů [5] ...	13
7.1 Graf signálů	27
7.2 Graf cen	27
7.3 Graf bez signálů	28
7.4 Heatmapa PnL	28
7.5 Srovnání obou strategií	29

Tabulky

5.1 Cena plynu	19
5.2 Datum dodání produktů	20
6.1 Procento úspěšnosti algoritmu ..	25

Kapitola 1

Úvod

Umělá inteligence se nyní vyvíjí obrovským tempem. Moderní AI (Artificial intelligence = Umělá inteligence) již ví, jak řídit auto bez řidiče, rozumět lidské řeči nebo rozpoznávat člověka podle jeho tváře. Je proto pochopitelné, že se lidé snaží zavést takovou technologii všude, kde je to možné. Státy ji využívají například ke zlepšování rozhodovacích procesů a soukromé společnosti k analýze dat, aby se mohly zaměřit na konkrétní spotřebitelské segmenty. Energetický průmysl není výjimkou, proto se snaží co nejlépe využít velkých objemů dat a strojového učení hlavně k optimalizaci výroby, distribuci energie a obchodování na energetických trzích. Je známo, že pro efektivní fungování AI je v procesu strojového učení zapotřebí obrovské množství dat. Energetický trh je pro tento účel ideální, protože z něj lze extrahovat terabajty informací. Proto je otázka používání umělé inteligence na tomto trhu velmi relevantní.

1.1 Motivace

Hlavní motivací této práce byla zvědavost. Bylo zajímavé odpovědět na otázku, zda model umělé inteligence, který vytvořil neprofesionál ve velmi omezeném čase, bude schopen vykazovat lepší nebo alespoň stejný výsledek predikce jako statistická strategie, která úspěšně funguje v podnicích již mnoho let.

1.2 Cíl

Cílem projektu je vytvořit dvě strategie a porovnat jejich účinnost mezi sebou. První strategie je časem prověřená strategie založená na statistice. Bylo nutné vytvořit tuto strategii speciálně pro trh s plynem, vybrat výkonnostní metriky a zkontrolovat, zda bude vykazovat dobré výsledky na tomto trhu. Druhá strategie je strategie vytvořená umělou inteligencí, která bude nejprve předpovídat směr ceny (cena stoupá nebo klesá) pomocí klasifikačního algoritmu a poté pomocí triviální strategie simulovat obchodování. Podrobný popis strategií lze nalézt v kapitole Návrh a implementace.

■ 1.3 Struktura práce

Je tvořena následujícími kapitolami:

- Kapitola 2 - Popisuje základní principy fungování finančních trhů a konkrétně energetických trhů;
- Kapitola 3 - Popisuje statistické techniky, strategie obchodování na trhu;
- Kapitola 4 - Popisuje hlavní kategorie strojového učení, proč používat strojové učení při obchodování a jakým způsobem;
- Kapitola 5 - Popisuje analýzu problému, která řešení již existují a která řešení stojí za implementaci;
- Kapitola 6 - Zabývá se technickým popisováním, jakým způsobem jednotlivé strategie fungují;
- Kapitola 7 - Zobrazuje, jak bylo prováděno testování a která strategie byla nejúspěšnější. Na konci kapitoly je část, která se zabývá analýzou případného vylepšení strategií;
- Kapitola 8 - Shrnuje celý projekt a jeho výstupy;

Kapitola 2

Teorie obchodování na trhu

2.1 Základy obchodování

Než přejdeme k strojovému učení, pojďme se podívat na základy obchodování na trhu. V nejjednodušším případě je obchodování nákup a prodej věcí. Obchodníci přirozeně chtějí z jakékoliv operace získávat. Zůstatek aktiv a zbývající čas určují, jak agresivní můžete být ve svých transakcích (čím méně času a více zdrojů máte, tím více dokážete být asertivní). Naopak, pokud máte více času a spoustu zdrojů, můžete být trpěliví a čekat na lepší ceny. Svět trhu je založen na základních ekonomických zákonech: například pokud je k dispozici více kupujících než položek k prodeji, poptávka se zvýší a ceny začnou růst. Jako obchodník chcete nakupovat věci, u kterých očekáváte, že budou mít vyšší hodnotu. Pokud prodáte něco a hodnota trhu vzroste, přicházíte o peníze, které byste potenciálně mohli vydělat prodejem o něco později. V obchodování vždy existuje vítěz a poražený a tyto role se stále mění. Není možné být vždy na straně vítěze, ale vaším cílem jako obchodníka je být častěji vítězem při zachování zisků. Zaujmout dlouhou pozici (nákup akcie) na trhu je vážné rozhodnutí, které vyžaduje pečlivou analýzu a odborné znalosti, které ochrání před zbytečnými ztrátami.

2.2 Obchodování na energetickém trhu

Svět spoléhá na energii. Používáme ropu na benzín, abychom mohli pohánět naše auta, letadla a lodě. K vytápění našich domovů, provozu elektráren a dodávce elektřiny používáme zemní plyn. Všechny tyto energie se prodávají po celém světě a ceny se liší podle nabídky a poptávky. Dodávky ropy, zemního plynu a dalších energetických zdrojů jsou jedním z nejdůležitějších faktorů ovlivňujících ceny energií. Když se zvyšuje nabídka, ceny energií klesají; když nabídka klesá, ceny rostou. Výkyvy v očekávané produkci ropy mohou také ovlivnit ceny. Například objevení významného nového ropného pole nebo zvýšení produkce země ze stávajících polí může snížit ceny na globálním trhu. Poptávka je druhou stranou cenové rovnice. Když se zvyšuje globální poptávka po energii, roste i cena. A naopak. První věcí, která ovlivňuje poptávku po energii, je globální ekonomický růst. Jak se globální ekonomika

v rozvojových zemích zlepšuje, firmy více vyrábějí a lidé více nakupují. Tyto ekonomické činnosti vyžadují energii, která zvyšuje poptávku a zvyšuje ceny ropy a zemního plynu. Během hospodářského útlumu se tento růst zpomaluje a ceny energií klesají. Koneckonců prakticky vše, co se děje, ať už je to politika, mezinárodní vztahy, změny v ekonomickém výhledu nebo dokonce počasí, ovlivňuje nabídku nebo poptávku po energii. Protože se tato práce věnuje především plynu, je nutné ho podrobněji popsat. Zemní plyn je třetí nejvíce spotřebovávaný zdroj energie po ropě a uhlí. Je to surovina používaná k vytápění domů a budov, vaření a výrobě elektřiny, vozidel, chemikálií a plastů. S rostoucími globálními obavami o životní prostředí je třeba vzít v úvahu, že zemní plyn je mnohem čistší palivo než jiné zdroje energie, jako je uhlí a ropa. Z pohledu trhu je zemní plyn nestabilní komodita s vysokými cenovými výkyvy a dokud bude plyn žádaným zdrojem energie, bude jeho cena kolísat. To znamená, že obchodníci se mohou těšit na významné obchodní příležitosti. Díky všem uvedeným faktorům se stal zemní plyn v posledních letech oblíbenou komoditou pro dlouhodobé investice i denní obchodování. Zemní plyn se vyrábí na různých místech po celém světě a obchoduje se na mezinárodních burzách. Trh se zemním plynem je poháněn dlouhodobými smlouvami mezi vládami a mezinárodními organizacemi. Je silně ovlivněn sezónností, geopolitickými událostmi, počasím, nabídkou a poptávkou, skladováním a celosvětovou produkcí. Produkce plynu je klíčovým faktorem cenových výkyvů, proto by každý obchodník se zemním plynem měl věnovat zvláštní pozornost zprávám o produkci a spotřebě zemního plynu. Ze všeho, co bylo výše napsáno, můžeme usoudit, že energetický trh není pro začínajícího obchodníka nejnějnějším místem. Cenu plynu ovlivňuje mnoho faktorů a je potřeba mít spoustu zkušeností k vybudování strategie, která by byla zisková.

2.3 Techniky predikce cen

Existují dvě techniky predikce cen: Základní analýza - v tomto případě analytici hodnotí informace, které se více týkají společnosti, jejíž akcie jsou obchodovány na burze cenných papírů, než samotných akcií. Rozhodování o určitých akcích na trhu se provádí na základě analýzy předchozích aktivit společnosti, předpovědi výnosů a zisků atd. Technická analýza - v tomto případě jsou identifikovány různé vzory chování akcií (používá se analýza časových řad). V případě použití metod strojového učení pro zpracování obchodních dat se nejčastěji používá metoda technické analýzy - cílem je zjistit, zda algoritmus dokáže přesně určit vzorce chování akcií v čase. Trendy a vzory poskytují pohled na to, kam bude cena akcií směřovat dál. Porozumění vám poskytne statistickou výhodu, která vám umožní vydělat peníze. Strojové učení však lze také použít k vyhodnocení a předpovědi výkonnosti společnosti pro další použití v základní analýze. Nejúčinnější metodou pro automatizovanou predikci cen akcií a generování investičních doporučení je hybridní přístup, který kombinuje základní a technické analytické přístupy.

2.4 Dlouhá pozice (Long position) a Krátká pozice (short selling)

Pozice je dlouhá, pokud se obchodník snaží kupovat za určitou cenu a dosáhnout zisku uzavřením obchodu za vyšší cenu. V takové situaci investor chce využít příležitosti růstu trhu. Otevřením krátké pozice obchodník produkt prodá a očekává snížení. Investor bere zisk z klesajícího trhu.

2.5 Párové obchodování (pair trading)

Tržně neutrální strategie je klíčovým aspektem párového obchodování. Tržně neutrální strategie zahrnují dlouhé a krátké pozice u dvou produktů s pozitivní korelací. Tyto dvě kompenzační pozice tvoří základ pro zajišťovací strategii, která se snaží těžit z pozitivního nebo negativního trendu. Produkty v párovém obchodování musí mít vysokou pozitivní korelaci, což je hlavní hybná síla ziskové strategie. Strategii je nejlepší zařadit, když obchodník identifikuje korelační nesrovnalost. Teorie vychází z předpokladu, který se spoléhá se na historickou představu, že tyto dva produkty budou udržovat specifickou korelaci, což umožňuje to, že obchod s páry může být realizován, v momentě kdy je tato korelace nejslabší. Když se páry z obchodu nakonec odchýlí, investor se může pokusit otevřít odpovídající dlouhou pozici v cenově nevýhodném produktu a krátkou pozici pro produkt, který vykazuje zvýšenou výkonnost. Pokud se produkty vrátí do své historické korelace, zisk se vygeneruje konvergencí cen.

Kapitola 3

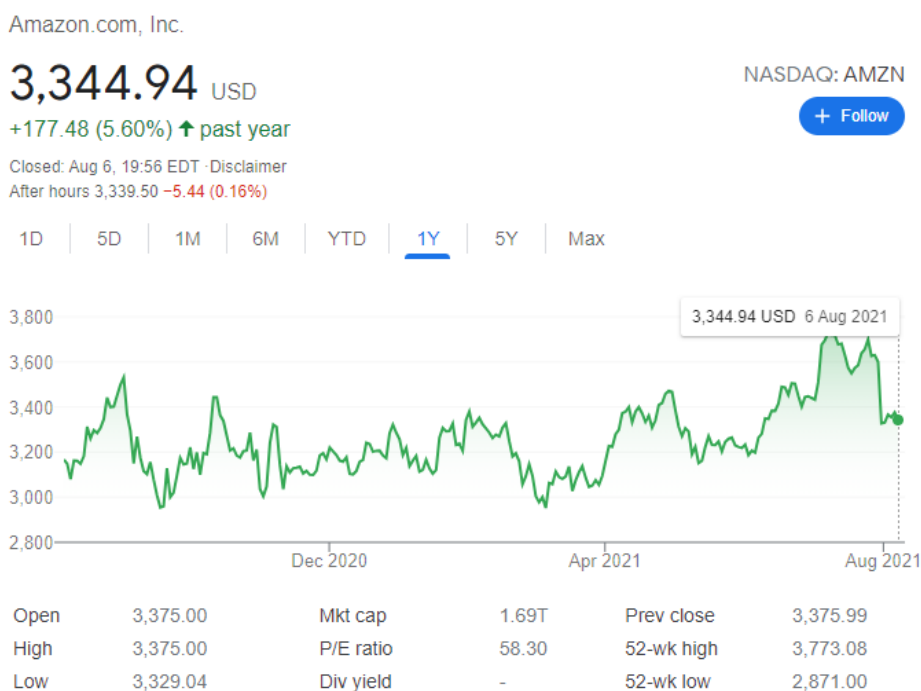
Obchodování s využitím statistických strategií

Obecně trhy mohou být buď ve fázi trendu, nebo ve fázi konsolidace. Trend je stálý pohyb cen nahoru nebo dolů, konsolidace je pohyb do strany (dá se říci, že takový pohyb představuje jakousi cenovou rovnováhu). Většina finančních trhů zpravidla vykazuje trendové chování méně než jednu třetinu času. Po zbytek času se trh obchoduje v některém omezeném rozsahu. Pro oba případy existuje mnoho různých strategií. Proto před obchodováním musíme zanalyzovat aktuální tržní podmínky. Když zjistíme, že ceny v rámci daného nástroje jsou náchylnější k směrovým pohybům cen, pak může být trendový přístup v tomto konkrétním případě výnosnější. Na druhou stranu, pokud zjistíte, že ceny na trhu mají omezenější rozsah, může být vhodnější obchodovat pomocí takzvaných mean reversion metod.

3.1 Mean reversion strategy (obchodování návratu ceny k běžné hodnotě)

Mean reversion strategy je založena na principu, že vysoké nebo naopak nízké ceny jsou nejčastěji krátké v čase a nestabilní a po určité odchylce od průměrné hodnoty se k ní tržní cena stejně vrátí. Pokud je aktuální tržní cena nižší než průměr, aktivum je považováno za atraktivní ke koupi, protože se očekává, že cena v budoucnu poroste. Naopak, když je aktuální tržní cena vyšší než průměr, očekává se, že cena v budoucnu klesne, a proto má smysl aktivum prodat. Jinými slovy, tato strategie je v zásadě pokusem využít extrémních cenových pohybů provedením pozice, která vyhlazuje současný pohyb cen. Je třeba si uvědomit, že neexistuje dokonalá strategie, která by vždy vytvářela zisk. Tato konkrétní strategie dobře funguje při konsolidaci trhu, ale během silného trendu se cena nemusí brzy vrátit do průměru, což může vést ke ztrátám. Ale navzdory tomu asi 70% času trh umožňuje použití přesně této konkrétní strategie. Důvodů je řada. Volatilní pohyb je většinou způsoben určitou přehnanou reakcí obchodníků – například na fundamentální zprávu nebo na samotný trh, kdy řada traderů začíná obchodovat, dokud se nemění cena akcií. Po vyčerpání příkazů ženoucích trh jedním směrem mnoho obchodníků ukončuje obchody a sbírá zisk – což v praxi znamená tlak

na směřování ceny opačným směrem. A k těmto obchodníkům se přidávají i nové objednávky krátkodobých traderů, kteří si tipují, že cena bude mít tendence vrátit se do oblasti „běžné ceny“. Proto při práci s výše uvedenou strategií je důležité analyzovat historická data, především data související s cenovými výkyvy a důvody jejich změn. Podívejme se na příklad chování akcie společnosti Amazon za poslední rok:



Obrázek 3.1: Akcie Amazon [1]


Na grafu je vidět, že v srpnu roku 2020 trh vyrazil vzhůru, aby po rostoucí volatilitě přišel prudký obrát a cena se vrátila zpět a následně dokonce klesla pod průměr, aby se pak opět obrátila vzhůru. A toto se na grafu mnohokrát opakuje. Vybrané úseky jsou samozřejmě jen diskretní ukázkou, v grafu bychom mohli diskutovat o dalších oblastech, ale pointa je snad zřejmá. Po rychlých, nadstandardně velkých pohybech, mají trhy tendence tyto pohyby korigovat.

3.1.1 Použití strategie

Na základě konceptu „Návrat k průměru“ bylo vytvořeno mnoho podobných obchodních strategií, které používají různé nástroje k vyhledávání obchodních signálů. Celkově ale téměř všechny mean reversion strategie se skládají ze tří hlavních prvků - trendového indikátoru, který symbolizuje „férovou“ cenu a používá se spíše k opuštění pozice, indikátoru odchylky od této ceny (například Bollingerova pásma nebo klouzavé průměrné obálky) a různých vstupních filtrů. Technické ukazatele jako například Bollinger Bands, Relative

3.1. Mean reversion strategy (obchodování návratu ceny k běžné hodnotě)

Strength Index RSI, Stochastic jsou příklady technických indikátorů, které poskytují překoupené a přeprodané signály. Tyto překoupené a přeprodané signály nám v podstatě říkají, kdy se pohyb ceny na konkrétním trhu nadměrně rozšiřuje nahoru v případě překoupené hodnoty, nebo dolů v případě přeprodané hodnoty. Zvažme obchodní signály založené na strategii pomocí Bollingerových pásem. Indikátor pásem se zobrazuje přímo v cenovém grafu a tvoří jakýsi cenový kanál, ve kterém se graf cen pohybuje většinu času. Pro krátkodobé obchodování můžeme použít cenový obrat od horních a dolních hranic indikátoru, abychom vrátili cenu do středové linie.



Obrázek 3.2: Signál k nákupu [2]

Cena klesá dolů pod spodní okraj kanálu a otočila se zpatky nahoru. Otevře se pozice nákupu. Zisk je uzavřen, když cena dosáhne střední linie indikátoru.



Obrázek 3.3: Signál prodeje [3]

Cenový graf stoupá nad horní hranici kanálu a tvoří odrazový můstek. Otevře se pozice prodeje. Zisk lze fixovat, když cena klesne na střední rádek indikátoru.

■ 3.1.2 Výhody a nevýhody

Jako každá jiná strategie má mean reversion určité výhody a nevýhody.

Výhody:

- Trvání relevance
Tato strategie funguje dobře, když na trhu není výrazný vzestupný nebo sestupný trend. Trendy se obvykle vyvíjejí přibližně 30% času, zatímco 70% času trh zůstává v nějaké formě konsolidace, ve které tato strategie funguje.
- Krátké období držení pozice
Na rozdíl od trendových strategií, kdy pozice jsou drženy týdny až měsíce, se obchody konají zpravidla na krátkou dobu, konkrétně od dvou dnů do dvou týdnů.
- Nejlepší procento výher
Jednou z charakteristik mnoha reverzních metod je, že jsou konzervativní, pokud jde o poměr rizika a odměny.

Nevýhody:

- Možné ztráty během trendu
Během působení silného směrového trendu na trhu dává signály proti trendu, což může vést ke ztrátám, pokud trend pokračuje bez korekce a návratu k průměrným cenám.
- Menší zisk na obchod ve srovnání s trendovými strategiemi
Ačkoli můžeme dosáhnout vyššího počtu vítězných obchodů, na oplátku můžeme dostat nižší výnosy než od strategie sledující trend.
- Trhy mohou zůstat iracionální
Trhy mohou zůstat iracionální déle, než vy můžete zůstat solventní. Jinými slovy, bez ohledu na to, jak jste si jistí svými tržními předpoklady, neměli byste ignorovat skutečnost, že trhy mohou a často obchodují v rozporu s tím, co se zdá rozumné.

■ 3.2 Trend following strategy (strategie sledování trendů)

Pojem „trend“ lze nazvat základním kamenem veškeré technické analýzy. Je tvořen postupně aktualizovanými extrémy v jednom směru.

Rozlišují se následující trendy:

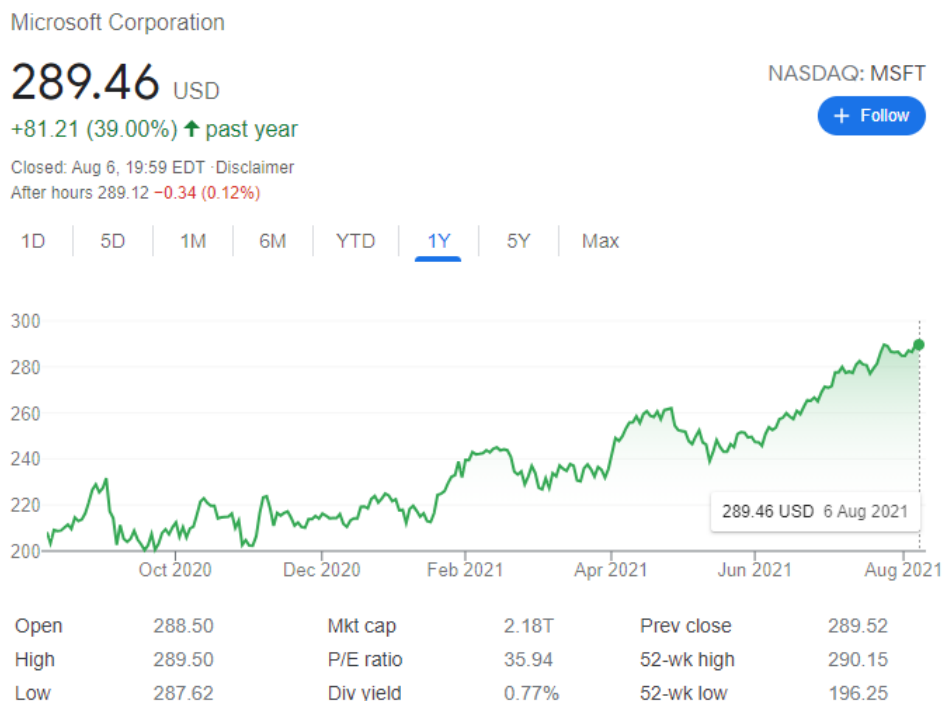
- Sestupný (downtrend) - postupně klesající minima a maxima (každé nové minimum je nižší než předchozí a každé nové maximum je také nižší než předchozí). V takovém případě bychom měli hledat pouze signály prodeje.
- Vzestupný (uptrend) - postupně rostoucí maxima a minima (každé následující maximum je vyšší než předchozí a každé následující minimum je také vyšší než předchozí). V takovém případě aktivum kupujeme.

Je třeba říci, že většinu času je trh plochý. To je stav, kdy se cena neustále pohybuje v určitém horizontálním koridoru. Trendy můžeme také kategorizovat podle různých časových rámců obchodování. Existují trendy, které fungují během jednoho dne, několika hodin nebo dokonce několika minut, důležité je rozpoznat trend včas. Jsou také dlouhodobé trendy, které budou relevantní několik dní nebo týdnů. Většina obchodníků s trendy preferuje používání dlouhodobých strategií, protože makro trendy lze snáze sledovat, a proto je snazší z nich profitovat. Strategie sledování trendů je proces analýzy směrové dynamiky trhu a účast na jeho pohybu. Teoreticky je to docela jednoduché, jakmile trh začne stoupat nebo klesat, obchodníci a investoři se okamžitě připojí k tomuto hnutí a čím je hnutí silnější, tím více účastníků se do procesu zapojí. Umění trendového obchodování je zachytit trend co nejdříve.

Trend lze rozdělit do následujících fází:

- Fáze 1
Počáteční fáze trendu, která se nazývá akumulací fáze. Toto je optimální doba pro nákup (uptrend) nebo prodej (downtrend).
- Fáze 2
Další fáze - stabilizace, kdy se začínají přidávat profesionální hráči, kteří vystihli trend a jsou připraveni vydělat peníze.
- Fáze 3
Poslední fáze dokládá vzrušení na trhu. Je spojen se vstupem do hry obchodníků, kteří se řídí výhradně davovým chováním. Toto je nejnepravděpodobnější okamžik pro obchod, protože pravděpodobnost obratu trendu je nejvyšší.

Podívejme se na graf akcie společnosti Microsoft za poslední rok:



Obrázek 3.4: Akcie Microsoft [4]

Na grafu vidíme krásný příklad vzestupného trendu, který trval téměř celý rok.

■ 3.2.1 Použití strategie

Trend following strategií může být obrovské množství. Hlavním úkolem obchodníka, který chce začít obchodovat ve směru trendu, je identifikovat právě tento trend. Jak již víme, pokud stoupají maxima a minima ceny, jsme v uptrendu. Pokud klesají maxima a minima, pak jsme v downtrendu. Ve všech ostatních případech nemáme trendové podmínky. Ukažme si jednu z mnoha možných strategií. Každé dva body v grafu lze spojit přímkou. Pokud je však třetí bod na stejné přímce, pak máme trend. Potvrzení trendu tedy obvykle přichází po cenovém testu trendu na třetí dotek a odráží se od něj. Když uvidíte odraz, můžete vstoupit na trh a pokusit se zachytit nový trend.



Obrázek 3.5: Strategie sledování trendů [5]

První dvě šipky ukazují na vrcholy trendu. Toto jsou první dva body použité k vykreslení trendové čáry. Nyní budeme čekat na třetí cenovou interakci. Dále si všimneme silné reakce trendové linie. To se bude počítat jako naše potvrzení trendu a připraví nás na krátkou pozici. Čtvrtá šipka potvrzuje trend. Návratnost a odražení trendu nám tedy dává další obchodní příležitost.

■ 3.2.2 Výhody a nevýhody

Výhody:

- Jednoduchost
Podle většiny obchodníků není zvláštní potřeba používat těžké ukazatele. Jejich používání navíc v některých případech pouze přináší zbytečný zmatek a vede ke zbytečným průtahům v rozhodování.
- Potenciálně velký zisk
Pokud se podaří vstoupit na začátku trendu, bude dosaženo velmi dobrého zisku.

Nevýhody:

- Vzácnost signálů
Signály pro obchodování s trendy z denního grafu se budou generovat jen zřídka a je třeba se naučit kombinovat několik časových intervalů pro lepší hledání signálů a nápadů ve směru hlavního trendu.
- Trvání relevance
Trendy se obvykle vyvíjejí na trhu přibližně 30% času. To znamená, že pokud signál trendu zmeškáme, můžeme dlouho čekat na další dobře ziskový trend.

Kapitola 4

Obchodování s využitím strojového učení

4.1 Důvody pro použití strojového učení k obchodování

Na rozdíl od většiny programů, které používají logiku stanovenou inženýry, například obchodního robota, který dělá pouze to, co povolíte bez ohledu na kontext, umělá inteligence se může učit, zlepšovat a poskytovat lepší výsledky. Funguje nejen podle písemného algoritmu, ale může neustále sbírat a zpracovávat obrovské množství dat, analyzovat cenovou historii a trendy. Složitější systémy mohou dokonce přijít s obchodními strategiemi. Dokáže zohlednit tržní trendy, aby se zlepšila s nově získanými znalostmi. To znamená, že AI je schopna napodobit myšlení analytiků. Níže bych chtěl uvést některé vlastnosti strojového učení, které by měly potvrdit skutečnost, že AI by měla být součástí obchodování.

- Multitasking

Vyškolené stroje jsou schopné zpracovat nespočetné množství dat během několika minut. Stejným způsobem mohou vyhledávat a zpracovávat historická data a opakuje se vzorce pro inteligentní obchodování, které jsou lidem často skryté, nepřístupné nebo jim nejsou zřejmé.

- Analýza a predikce sentimentů

Studiem titulků článků, zpráv, příspěvků na sociálních sítích, blozích a dalších tematických zdrojích může umělá inteligence předvídat pohyb cen akcií a možné kroky dalších obchodníků. Provádí analýzu sentimentu - proces kategorizace názorů (nebo sentimentů), které lidé aktivně sdílejí na internetu.

- Samostudium

AI není dokonalá od prvních dnů práce, ale je schopna zlepšit své dovednosti. Poučí se ze svých vlastních chyb a bude se neustále zlepšovat. K tomu existují automatizovaní obchodní poradci, pomocí nichž AI pracuje na zlepšení výkonu, a to nejen vyladěním stávajících dat, ale také přidáním a analýzou nových.

■ 4.2.2 Učení bez učitele

Dokonale označené a čisté údaje není snadné získat. Proto někdy algoritmus stojí před úkolem najít dříve neznámé odpovědi. Tady přichází na řadu učení bez učitele. V bezobslužném učení má model datovou sadu a neexistuje žádný výslovný údaj o tom, co s ní dělat. Umělá neuronová síť se pokouší nezávisle najít korelace v datech, extrahuje užitečné funkce a analyzuje je.

Typy a příklady použití algoritmů typu učení bez učitele:

- Shlukování

Algoritmus sbírá podobná data, najde společné rysy a seskupuje je.

- Detekce anomálií

Banky mohou odhalit podvodné transakce identifikováním neobvyklého chování při nakupování zákazníků. Je například podezřelé, pokud je stejná kreditní karta použita v Kalifornii a Dánsku ve stejný den. Podobně se učení bez učitele používá k vyhledání odlehlých hodnot v datech.

- Sdružení

Vyberete si z internetového obchodu plenky, jablečné pyré a šálek s dítětem a stránka vám doporučí, abyste k objednávce přidali bryndáček a chůvičku. Toto je příklad asociací: některé charakteristiky objektu koreluje s jinými charakteristikami. Zvažováním několika klíčových atributů objektu může model předvídat ostatní, se kterými je spojení.

- Autoencoders

Autoencoders vezme vstup, zakóduje ho a poté se pokusí znovu vytvořit původní data z výsledného kódu. V reálném životě není mnoho situací, kdy se používá jednoduchý autoencoder. Ale přidejte vrstvy a možnosti se rozšíří: Použitím hlučných a originálních verzí obrázků pro trénink mohou autoencodery odstranit šum z video dat, obrázků nebo lékařských skenů a zlepšit tak kvalitu dat.

Při učení bez dohledu je obtížné vypočítat přesnost algoritmu, protože v datech chybí „správné odpovědi“ nebo štítky. Označená data jsou však často nespolehlivá nebo příliš drahá na získání. V takových případech, když dáte modelu svobodu k hledání závislosti, můžete dojít k dobrým výsledkům.

■ 4.2.3 Učení posilováním

AI se snaží najít nejlepší způsob, jak dosáhnout cíle nebo zlepšit výkon pro konkrétní prostředí. Když agent přijme opatření k dosažení cíle, obdrží odměnu. Globálním cílem je předpovědět další kroky, aby bylo nakonec možné získat maximální odměnu. Při rozhodování agent studuje zpětnou vazbu, nové taktiky a řešení, která mohou vést k vyšším ziskům. Toto je iterační proces. Čím více úrovní zpětné vazby, tím lepší je agentova strategie. Tento přístup je obzvláště užitečný pro výcvik robotů, kteří provozují autonomní vozidla nebo pracují se zásobami ve skladu.

Kapitola 5

Analýza

5.1 Seznámení s problémem

Pokud dříve na trhu obchodovali pouze zkušení obchodníci, kteří předávali své znalosti začátečníkům, dnes se situace radikálně mění. Lidé se postupně vzdalují od ručního obchodování a všechny operace jsou přesunuty na stroje. Říct přesné procento transakcí, které jsou prováděny pomocí umělé inteligence, samozřejmě nelze. Pokud ale vezmeme v úvahu všechny možnosti, které umělá inteligence pro obchodování nabízí, je jasné, že nyní není ruční obchodování příliš potřeba. Většina obchodních společností má již několik let týmy datových analytiků, inženýrů strojového učení, aby mohli shromažďovat data a stavět na jejich základě modely, které by obchodovaly na trhu, předpovídaly ceny nebo hledaly úspěšné strategie. Proto absolutně nemá cenu obcházet umělou inteligenci. Ale zároveň to vůbec neznamená, že všechny statistické strategie přestaly fungovat nebo jsou nutně horší než strategie UI. Tato práce existuje proto, aby odpověděla na otázku relevance jednoduchých statistických strategií proti AI.

5.2 Data

Data použitá v tomto projektu jsou velmi jednoduchá a téměř se svou podstatou neliší od dat jiných trhů. Pokud nepůjdeme do velkých podrobností a budeme uvažovat čistě technicky, známe pouze datum a cenu.

Timestamp	Trade Close
30.12.2010	24,57
29.12.2010	24,04
24.12.2010	23,04
23.12.2010	22,85
22.12.2010	22,84

Tabulka 5.1: Cena plynu

Cena závisí na mnoha faktorech, které již byly popsány v Kapitole 2. Ale protože nás zajímá technická analýza, ne fundamentální, pak jsou všechna naše data omezena pouze na ceny za konkrétní den. Další údaje (například počasí, nabídka a poptávka) mohou naši strategii výrazně zlepšit, zejména strategii založenou na predikci cen umělou inteligencí, protože budou existovat nové „features“, které dokáže analyzovat. Náš systém bude simulovat obchodování pomocí námi vytvořených strategií a na základě speciálních metrik popsaných v další kapitole určí, zda byla strategie úspěšná.

5.3 Párové obchodování

Již jsme definovali koncept párového obchodování. Zbývá určit, co to znamená pro naše data a jak budeme obchodovat. Nejprve si ale řekněme, co je termín dodání (delivery date). Datum dodání je konečné datum, do kterého musí být dodána podkladová komodita, aby byly splněny smluvní podmínky. Můžeme taktéž obchodovat s nefyzickými produkty (to jest které nám ještě nebyly dodány), avšak pouze pokud provádíme tyto operace před delivery date. V našem případě existují dva produkty. První je měsíční produkt. To znamená, že jeho dodací lhůta trvá měsíc a začíná na začátku konkrétního měsíce. Například datum dodání produktu January-2021 je 1. ledna 2021.

V tabulce je uvedeno datum dodání různých produktů.

	Maturities	Trading start date	Trading end date	Delivery start	Delivery end
Month	January-21	30.06.2020	30.12.2020	01.01.2021	01.02.2021
Month	February-21	31.07.2020	28.01.2021	01.02.2021	01.03.2021
Month	March-21	31.08.2020	25.02.2021	01.03.2021	01.04.2021
Month	April-21	30.09.2020	30.03.2021	01.04.2021	01.05.2021
Month	May-21	30.10.2020	29.04.2021	01.05.2021	01.06.2021
Month	June-21	30.11.2020	28.05.2021	01.06.2021	01.07.2021
Month	July-21	31.12.2020	29.06.2021	01.07.2021	01.08.2021
Month	August-21	29.01.2021	29.07.2021	01.08.2021	01.09.2021
Month	September-21	26.02.2021	30.08.2021	01.09.2021	01.10.2021
Month	October-21	31.03.2021	29.09.2021	01.10.2021	01.11.2021
Month	November-21	30.04.2021	28.10.2021	01.11.2021	01.12.2021
Month	December-21	31.05.2021	29.11.2021	01.12.2021	01.01.2022
Quarter	Q1 2021	28.03.2018	29.12.2020	01.01.2021	01.04.2021
Quarter	Q2 2021	28.06.2018	29.03.2021	01.04.2021	01.07.2021
Quarter	Q3 2021	27.09.2018	28.06.2021	01.07.2021	01.10.2021
Quarter	Q4 2021	28.12.2018	28.09.2021	01.10.2021	01.01.2022
Season	Summer 2021	28.03.2018	29.03.2021	01.04.2021	01.10.2021
Season	Winter 2021	27.09.2018	28.09.2021	01.10.2021	01.04.2022
Calendar	Calendar 2021	30.12.2014	29.12.2020	01.01.2021	01.01.2022

Tabulka 5.2: Datum dodání produktů

Druhý produkt je roční produkt, to znamená, že jeho dodání je jeden rok. Oba produkty mají jiný termín dodání, i přesto budeme analyzovat cenu zemního plynu ve stejný den u obou produktů, což nám určuje, že mezi našimi produkty existuje velká korelace nebo vztah. Budeme sledovat pohyby cen obou produktů a reagovat na změny ve velikosti poměru těchto párů. Nikdy nekupujeme ani neprodáváme pouze jeden produkt. Vždy jeden koupíme, druhý prodáme a naopak. Tento princip se používá v obou strategiích zde popsaného systému.

■ 5.4 Existující projekty

Níže je uveden seznam podobných projektů, které se mi podařilo najít. Odkaz na každý projekt lze najít v literatuře.

Oil & Gas - prognóza cen ropy a zemního plynu pomocí ARIMA (autoregresní integrovaný klouzavý průměr) a neuronových sítí.

House Price - predikce cen domů pomocí lineární regrese a GBR.

Stock prediction hybrid model - Hybrid modelů ANN, RNN a Regression pro odhad cen akcií.

Po analýze těchto projektů můžeme dojít k závěru, že se jedná spíše o prototypy velkých systémů, které lze na jejich základě implementovat. Každý má svá specifika, výhody a nevýhody, ale rozhodně to jsou systémy, které by bylo možné zlepšit. Nevýhodou těchto systémů byla také absence srovnání statistických algoritmů a algoritmů strojového učení, což je cílem této práce.

Kapitola 6

Návrh a implementace

6.1 Výběr technologií

Systém predikce cen na energetickém trhu lze implementovat jako knihovnu, kterou lze volat z konzole v programovacím jazyce Python.

Hlavním důvodem, proč budeme používat Python, je to, že má mnoho knihoven, které zjednodušují proces zpracování dat, programování a zkracují dobu vývoje.

Nástroje, které lze použít pro vývoj:

- vývojové prostředí Pycharm
- sada knihoven Anaconda
- systém pro správu verzí Git

6.2 Použité knihovny Pythonu

Projekt využívá mnoho knihoven. Nevidím však důvod specifikovat všechny, protože většina knihoven je potřebná pro nějaký konkrétní malý úkol nebo se nedotýkají jádra projektu. Níže popíšu knihovny, které v projektu hrají důležitou roli a které mi velmi usnadnily práci.

- Scikit-learn

Scikit-learn je jednou z nejpoblárnějších knihoven strojového učení. Podporuje mnoho supervizních a nekontrolovaných algoritmů učení. Například lineární a logistické regrese, rozhodovací stromy, shlukování, k-means atd. Je postaven na dvou hlavních knihovnách Python: NumPy a SciPy.

- Numpy

NumPy je knihovna, která přidává podporu pro velká, vícerozměrná pole a matice, spolu s velkou sbírkou matematických funkcí, které na těchto polích fungují. Matematické algoritmy implementované v interpretovaných jazycích (jako je Python) jsou často mnohem pomalejší než

koncept používám nejen pro algoritmus strojového učení, ale dokonce i pro statistický algoritmus.

4. Vytváření statistického algoritmu

Systém používá výše popsaný “mean reversion strategy”. Nejprve tato strategie na tréninkových datech iterativně zkouší různé kombinace vstupních argumentů, které náš algoritmus potřebuje. Toto se provádí za účelem pochopení, která kombinace bude fungovat nejlépe. Na výstupu prvního kroku se vygeneruje velké množství grafů. Konkrétně se jedná o grafy cen produktů pro každou jejich kombinaci, grafy signálů pro nákup a prodej na poměru těchto produktů a heatmapy metrik. Dalším krokem je použití nejlepší kombinace na datech pro testování.

5. Vytváření machine learning algoritmu Myšlenkou algoritmu je předpověď cenovou dynamiku aktiva. Pomocí klasifikačního algoritmu, konkrétně Random Forest Classifier, systém předpovídá produktové změny cenových rozdílů. Toto je nezbytné, abychom mohli definovat jednoduchou strategii na základě predikce. Na základě nárůstu rozdílu v ceně produktů koupíme produkt číslo jedna, u kterého předpokládáme, že cena stoupla, a prodáme produkt, u kterého cena klesla. Systém funguje podobným způsobem, kdy dochází ke snižování rozdílu cen produktů. Chtěl bych poznamenat, že změny rozdílu v ceně produktů mohou znamenat něco jiného, než předpokládá systém. Je to jedna z mnoha věcí, kterou je zapotřebí zlepšit. Při provádění předpovědí, systém každý den nakupuje nebo prodává v závislosti na předpovědi na další den. Jako vstupní argumenty pro popisovaný model jsou použity historické ceny za posledních 12 dní.

Prediction accuracy depending on the number of days					
Number of days	First	Second	Third	Fourth	SUM
1	49,7382	50,882	51,3832	51,4714	203,4748
2	50,9941	51,3473	50,9076	51,8825	205,1315
3	50,536	51,743	51,2271	52,4952	206,0013
4	50,3943	51,4416	52,6632	51,9913	206,4904
5	51,4258	51,7472	51,2861	52,2994	206,7585
6	50,9225	52,2766	52,594	51,3828	207,1759
7	51,5395	52,3708	52,1829	52,8561	208,9493
8	51,057	52,1297	52,5622	52,7539	208,5028
9	51,4112	51,9186	53,1969	53,187	209,7137
10	51,932	51,8496	52,8606	52,8388	209,481
11	52,0119	52,5661	53,1664	52,5163	210,2607
12	52,5902	52,4977	53,3308	52,2371	210,6558
13	52,3276	51,5598	52,4631	52,213	208,5635
14	51,6315	51,9611	53,0728	52,489	209,1544
15	52,9673	51,215	52,5731	52,3767	209,1321
16	52,5039	52,1302	52,8232	52,0874	209,5447
17	51,6826	52,215	52,855	52,4084	209,161
18	51,0935	51,6723	53,2298	52,5527	208,5483
19	51,5531	51,7259	53,1858	52,9725	209,4373
20	51,365	52,0995	52,6261	52,3716	208,4622

Tabulka 6.1: Procento úspěšnosti algoritmu

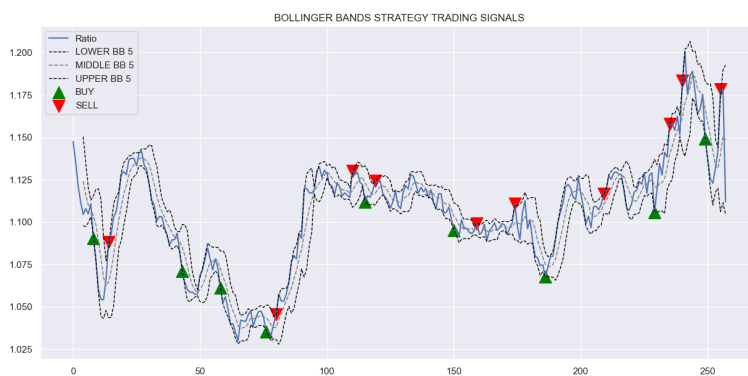
Číslo 12 vzešlo po provedení analýzy zaměřené na procento úspěšnosti algoritmu pro různý počet dní.

Kapitola 7

Testování a vyhodnocení

Na základě metrik a výstupů obou strategií můžeme vyvodit, který princip fungoval nejlépe. Prvním krokem je vygenerování cenových grafů a heatmap. Podívejme se na několik příkladů.

Toto je graf poměru cen pro pár 11. dubna - Cal rok 12:




Obrázek 7.1: Graf signálů

Červená označuje prodej páru, zelená - nákup páru. Nesmíme zapomenout, že provádíme taktéž reverzní transakci po dosažení průměrné ceny. Abychom tomuto grafu lépe porozuměli, podívejme se nyní na cenový graf dvou produktů stejného páru.




Obrázek 7.2: Graf cen

Zde jasně vidíme dvojnásob signálů. Důvodem je, že jeden podnět reprezentuje signál, který je uveden na předchozím grafu, a druhý signál je obchod, když poměr ceny v prvním grafu dosáhl průměrné hodnoty. Zajímavým grafem může být také graf stejného páru, ale pro jiné kombinace vstupních argumentů pro strategii mean reversion.



Obrázek 7.3: Graf bez signálů

Vidíme, že nebyly odhaleny žádné signály. V takovém případě systém neprovede žádný obchod. Na konci prvního kroku systém vytvořil hitmapu pro různé metriky. Pojďme se podívat na hitmapu PnL:



Obrázek 7.4: Heatmapa PnL

Z tohoto grafu můžeme usoudit, že nejúspěšnější kombinací vstupních argumentů je kombinace 1,5 pro Stddev Multiple a 10 pro Moving average. Tato kombinace je použita v dalším kroku, který ji otestuje na datech pro testování.

Na konci můžete vidět srovnání obou strategií. Porovnání se provádí za čtyři roční čtvrtletí.

```
REPORT FOR 1 QUARTER (STATISTICAL STRATEGY):  
SUM OF PNL: 61.58999999999833  
REPORT FOR 2 QUARTER (STATISTICAL STRATEGY):  
SUM OF PNL: 23.02599999999984  
REPORT FOR 3 QUARTER (STATISTICAL STRATEGY):  
SUM OF PNL: 23.23899999999776  
REPORT FOR 4 QUARTER (STATISTICAL STRATEGY):  
SUM OF PNL: 79.1810000000005  
REPORT FOR 1 QUARTER (MACHINE LEARNING STRATEGY):  
PREDICTION ACCURACY: 52.5902%  
SUM OF PNL: -6006.459000000034  
REPORT FOR 2 QUARTER (MACHINE LEARNING STRATEGY):  
PREDICTION ACCURACY: 52.4977%  
SUM OF PNL: -94.21899999999694  
REPORT FOR 3 QUARTER (MACHINE LEARNING STRATEGY):  
PREDICTION ACCURACY: 53.3308%  
SUM OF PNL: 290.87300000000306  
REPORT FOR 4 QUARTER (MACHINE LEARNING STRATEGY):  
PREDICTION ACCURACY: 52.2371%  
SUM OF PNL: -3005.661000000046
```

Obrázek 7.5: Srovnání obou strategií

Jak vidíme, statistická strategie byla mnohem úspěšnější. Je to dáno především tím, že její algoritmus je mnohem složitější a byla provedena mnohem lepší analýza vstupních argumentů pro algoritmy této strategie.

Kapitola 8

Závěr

Energetický trh je velmi konkurenční svět. Umělá inteligence, která se již téměř používá jako univerzální zbraň na cokoliv, si však našla uplatnění i v obchodování. Ačkoli AI postupně vyhrává konkurenci s lidmi, stále se nemůže stát hlavním hráčem v této hře. Prvním problémem je to, že je velmi obtížné napsat složitý systém, který by přinesl velké zisky. Vytvořit systém, který by byl schopen obchodovat lépe než obchodníci pomocí statistických strategií, které jsou na trhu desítky let, vyžaduje hodně času a tým velmi dobrých specialistů. Druhým problémem je to, že často nestačí pouze technická analýza. Trh reaguje na různé novinky. Pro AI to znamená, že je musí umět zpracovávat, což vůbec není jednoduchý úkol. Porozumění článkům není totéž co porozumění číslům. Umělá inteligence je proto stále vhodnější jako nástroj než úplná náhrada za člověka. V této práci jsem vytvořil koncept aplikace, který se skládá z několika částí. Na začátku systém zformuje statistickou strategii, pomocí tréninkových dat a různých vstupních hodnot. Poté dochází ke generování grafů pro různé metriky, k docílení úspěchu strategie. Toto je nezbytné, aby si systém mohl vybrat nejziskovější kombinaci vstupních hodnot, které jsou potřebné pro statistické strategie. Následně musíme tyto grafy zanalyzovat a vybrat si, která strategie nám nejlépe vyhovuje. Poté na datech pro testování systém zkouší statistickou strategii s těmito konkrétními vstupy. Další velkou fází je konstrukce modelu umělé inteligence, která se pomocí klasifikačních algoritmů pokouší předpovědět směr budoucí ceny. Na základě tohoto předpokládaného směru systém nakupuje nebo prodává páry. Protože byly použity dva zcela odlišné přístupy, lze je porovnávat a analyzovat samostatně. V mém případě, statistická strategie fungovala mnohem lépe. Důvodů je několik. Za prvé, statistická strategie je mnohem podrobnější a používá složitější obchodní logiku. Za druhé, soudě podle malého procenta úspěšnosti prognózy, model nenalezl skoro žádné zákonitosti v cenové historii. Jsem si však jistý, že výsledné procento lze výrazně zlepšit, a to přidáním historie počasí a dalších vstupních dat do modelu. Závěr, že statistické strategie fungují na energetickém trhu lépe než strategie strojového učení, rozhodně není správný. Aby bylo srovnání těchto strategií více korektní, je zapotřebí výrazně zlepšit strategii strojového učení.



Literatura

- [1] *Amazon stock* [online] [cit. 03.03.2021]. Dostupné z: <https://www.google.com/search?q=amazon+stock>
- [2] Gryazin, Viktor. *Bollinger bands - buy signal* [online] [cit. 11.03.2021]. Dostupné z: <https://blog.roboforex.com/ru/blog/2021/02/11/kak-torgovat-po-strategii-vozvrat-k-srednemu/>
- [3] Gryazin, Viktor. *Bollinger bands - buy signal* [online] [cit. 11.03.2021]. Dostupné z: <https://blog.roboforex.com/ru/blog/2021/02/11/kak-torgovat-po-strategii-vozvrat-k-srednemu/>
- [4] *Microsoft stock* [online] [cit. 14.03.2021]. Dostupné z: <https://www.google.com/search?q=microsoft+stock>
- [5] *Trend strategy* [online] [cit. 28.03.2021]. Dostupné z: <https://traderblog.net/strategija-torgovli-po-trendu/>
- [6] *Mean reversion strategy* [online] [cit. 01.05.2021]. Dostupné z: <https://www.cmcmarkets.com/en/trading-guides/mean-reversion>
- [7] *Mean reversion strategy - cmcmarkets* [online] [cit. 01.05.2021]. Dostupné z: <https://www.cmcmarkets.com/en/trading-guides/mean-reversion>
- [8] *Mean reversion strategy - investopedia* [online] [cit. 03.05.2021]. Dostupné z: <https://www.investopedia.com/terms/m/meanreversion.asp>
- [9] *Mean reversion strategy - decodingmarkets* [online] [cit. 03.05.2021]. Dostupné z: <https://decodingmarkets.com/mean-reversion-trading-strategy/>
- [10] *Mean reversion strategy - medium* [online] [cit. 17.05.2021]. Dostupné z: <https://medium.com/auquan/mean-reversion-simple-trading-strategies-part-1-a18a87c1196a>
- [11] *Pair trading - investopedia* [online] [cit. 28.05.2021]. Dostupné z: <https://www.investopedia.com/terms/p/pairstrade.asp>

- [12] *Pair trading - medium* [online] [cit. 28.05.2021]. Dostupné z: <https://medium.com/swlh/creating-and-back-testing-a-pairs-trading-strategy-in-python-caa807b70373>
- [13] *Pair trading - betterprogramming* [online] [cit. 06.06.2021]. Dostupné z: <https://betterprogramming.pub/do-pair-trading-with-16-lines-of-python-code-d1b0fed9ad22>
- [14] *Metody umělé inteligence pro motivační herní prostředí* [online] [cit. 01.07.2021]. Dostupné z: <https://dspace.cvut.cz/bitstream/handle/10467/69661/F8-BP-2017-Sochor-Matej-thesis.pdf?sequence=1&isAllowed=y>
- [15] *Neuronové sítě pro SŠ* [online] [cit. 01.07.2021]. Dostupné z: <https://dspace.cvut.cz/bitstream/handle/10467/69661/F8-BP-2017-Sochor-Matej-thesis.pdf?sequence=1&isAllowed=y>
- [16] *Využití strojového učení pro predikci vývoje trhu* [online] [cit. 11.07.2021]. Dostupné z: <https://dspace.vutbr.cz/xmlui/bitstream/handle/11012/69619/final-thesis.pdf?sequence=12&isAllowed=y>
- [17] *Trend trading - investopedia* [online] [cit. 13.07.2021]. Dostupné z: <https://www.investopedia.com/terms/t/trendtrading.asp>
- [18] *Trend trading - tandfonline* [online] [cit. 20.07.2021]. Dostupné z: <https://www.tandfonline.com/doi/full/10.1080/14697688.2020.1716057>
- [19] *Trend trading - ig* [online] [cit. 23.07.2021]. Dostupné z: <https://www.ig.com/en/trading-strategies/supertrend--a-trend-following-indicator-to-use-in-your-trading--210730>
- [20] *Bollinger bands - fidelity* [online] [cit. 28.07.2021]. Dostupné z: <https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/bollinger-bands>
- [21] *Bollinger bands - investopedia* [online] [cit. 28.07.2021]. Dostupné z: <https://www.investopedia.com/terms/b/bollingerbands.asp>
- [22] *Bollinger bands - medium* [online] [cit. 05.08.2021]. Dostupné z: <https://medium.com/codex/algorithmic-trading-with-bollinger-bands-in-python-1b0a00c9ef99>
- [23] *Bollinger bands with python - medium* [online] [cit. 05.08.2021]. Dostupné z: <https://medium.com/codex/how-to-calculate-bollinger-bands-of-a-stock-with-python-f9f7d1184fc3>
- [24] *Bollinger bands with python - codingandfun* [online] [cit. 10.08.2021]. Dostupné z: <https://codingandfun.com/bollinger-bands-pyt/>