Bollinger Bands

Majcan, Borna

Undergraduate thesis / Završni rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of Mathematics / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:126:794352

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Repository of School of Applied Mathematics and Computer Science







Sveučilište J.J. Strossmayera u Osijeku
Odjel za matematiku
Sveučilišni preddiplomski studij matematike i računarstva

Borna Majcan

Bollinger Bands

Završni rad

Osijek, 2021.

Sveučilište J.J. Strossmayera u Osijeku
Odjel za matematiku
Sveučilišni preddiplomski studij matematike i računarstva

Borna Majcan

Bollinger Bands

Završni rad

Mentor: izv. prof. dr. sc. Nenad Šuvak

Osijek, 2021.

Sažetak

U ovom završnom radu proučavat ćemo pokazatelj Bollinger Bands i njegove primjene. Najprije ćemo spomenuti povijesne indikatore koji su se napravili prije i inspirirali Bollinger Bands te onda odrediti kako izražunati indikatore za Bollinger Bands i ostale indikatore izvedene iz Bollinger Bandsa. Te posljednje testirati razne načine investiranja koristeći indikator Bollinger Bands samostalno.

Ključne riječi

Povijesne cijene, candlesticks, pomični prosjek, standardna devijacija, kriptovalute

Abstract

In this final paper, we will study indicator Bollinger Bands and its application. Firstly, we will mention historical indicators that were made before and inspired Bollinger Bands and then determine how to calcualte Bollinger Bands and other indicators derived from Bollinger Bands. Finally, we will test various ways of investment using Bollinger Bands no their own.

Ključne riječi

Historical prices, candlesticks, moving average, standard deviation, cryptocurrencies

Sadržaj

1 Povijest **1**

2 Konstrukcija **4**
2.1 Opis . . . 4
2.2 Centralna traka . . . 4
2.3 Gornja i donja traka . . . 5
2.4 Primjer računanja . . . 5
2.5 Preporučeni parametri . . . 8
2.6 Indikatori izvedeni iz Bollinger Bands-a . . . 8
2.6.1 Konstrukcija indikatora %b . . . 8
2.6.2 Konstrukcija BandWidth . . . 9
2.6.3 Podaci od izvedenih indikatora . . . 9

3 Program **11**
3.1 Pristup vrijednostima kriptovaluta . . . 11
3.2 Prikaz vrijednosti na candlesticksove . . . 12
3.3 Implementacija Bollinger Bandsa . . . 12
3.4 Računanje trenutne vrijednosti . . . 13

4 Korištenje **14**
4.1 Iznad gornje trake . . . 14
4.1.1 Zaključak . . . 16
4.2 Ispod donje trake . . . 16
4.2.1 Izlaz iznad centralne trake . . . 16
4.2.2 Izlaz iznad gornje trake . . . 17
4.2.3 Povratak ispod centralne linije . . . 18
4.2.4 Zaključak . . . 18

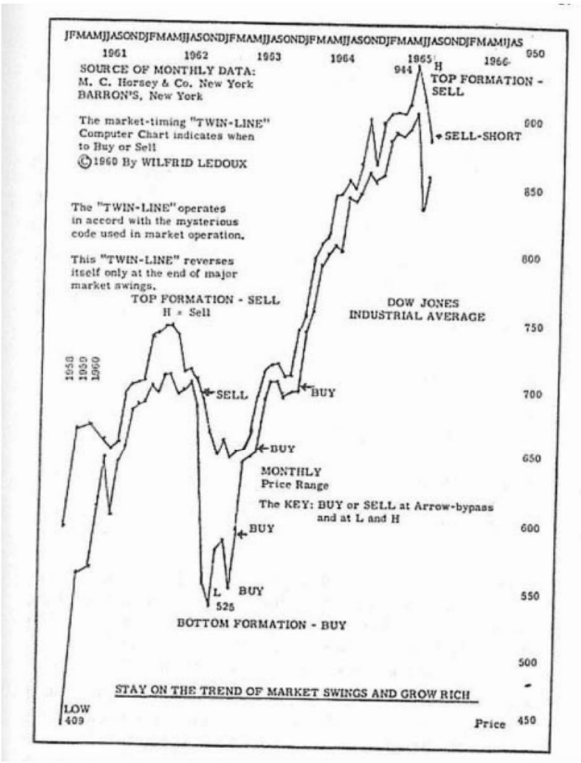
5 Zaključak **19**

6 Izvori **20**
6.1 Dodatno . . . 20

1 Povijest

Twin-Line Chart

Pokazatelj Bollinger Bands je nastao 1983. Iako je nastao u 1983., počeci ovog pokazatelja dolaze još i iz 1960. od metode Twin-Line Chart koju je uveo Wilfrid LeDoux i koja također koristi dva indikatora. Ta dva indikatora su koristila gornju liniju za mjesečni maksimum i donju za mjesečni minimum pa je godišnje bilo samo 12 točaka i koristilo se isključivo za dugotrajnu orjentaciju i ulaganje te već se iz primjera vidi kako je Twin-Line Chart mjerio nestabilnost (engl. volatility) podataka. Slika 1.



Slika 1: Twin-Line Chart
(IZVOR: Bollinger on Bollinger Bands, 37)

Pomični prosjeci temeljeni na periodu od deset dana

Iste godine, 1960. Chester W. Keltner objavljue indikator Pomični prosjeci temeljeni na peridou od deset dana. Za taj indikator potrebna je tipična cijena za svaki dan i raspon za svaki dan. Tipična cijena je zbrojeni maksimum, minimum i zatvarajuća cijena u danu i podijeljeno s 3 pa napraviti 10-dnevni pomični prosjek koristeću tipične cijene. Još su potrebne gornja i donja linija te da bi do njih došli potreban je raspon. Raspon je 10-dnevni pomični prosjek od dnevnog raspona (najviša cijena u danu - najniža cijena u danu, high-low). Gornja linija je 10-dnevnom prosjeku tipične cijene pribrojen 10-dnevni prosjek raspona, a donja je 10-dnevnom prosjeku tipične cijene oduzet 10-dnevni prosjek raspona. Gornja linija predstavlja trenutak za kupiti kada trenutna cijena dođe do nje, a donja za prodati; no postoje i drugi različiti načini upotrebe koji su nekada i malo drugačiji.

4-tjedno pravilo

1960-ih se pojavljuje 4-tjedno pravilo koje uvodi Richard Donchian. U 4-tjednom pravilu se gornja i donja linija određuju tako da je gornja linija maksimalna cijena zadnja 4 tjedna, a donja linija je minimalna cijena u zadnja 4-tjedna. Slika 2[1]



Slika 2: 4 Week Rule
(IZVOR: [1])

Omeđeni kanali konstantne širine

1970. J.M. Hursta su interesirali ciklusi te uvodi "omeđene kanale konstantne širine" da bi pojasnio cikličke uzorke u dionicama.

Postotne trake

William Schmidt u svojoj knjizi "Peerless Stock Market Timing" iz 1981. više je traka napravio, no česte trake koje su korištene su postotne trake. Postotne trake se rade na način da se napravi centralna traka i da je gornja (donja) uvećana (umanjena) za određeni postotak. Npr. 5%:

Gornja traka = Centralna traka· 1.05
Centralna traka = 21-dnevni pomični prosjek
Donja traka = Centralna traka / 1.05

Bomar lines

U ranim 1980-ima Marc Chaikin i Bob Brogan uvode Bombar bands iz imena BOb i MARc; što je isto postotna traka, no napravljena malo drugačije. Gornja (donja) traka umjesto da je za određeni postotak uvećana od centralne; ona je napravljena tako da se između nje i centralne trake nalazi 85% podataka koji su iznad (ispod) središnje trake za zadnjih 250 jedinica vremena.

Gornja linija sadrži 85% podataka iznad centralne linija
Centralna linija = 21-dnevni pomični prosjek
Donja traka sadrži 85% podataka ispod centralne linija

[1] http://hansalytics.com/html/articles/Finance/Trading/Indicators/TechnicalIndicatorIntroduction.html

To je prednost u odnosu na postotne trake jer se pri naglim promjenama gornja i donja linija primjereno proširuju, dok pri običnim gornja i donja su samo za određeni postotak udaljene od centralje trake. Još kod Bomar linija gornja i donja ne moraju biti jednako udaljene od centralje.

The Zone System

U ranim 1980-ima Jim Yates radi zone koje se određuju na temelju implicirane nestabilnosti (implied volatility). Te zone se mogu koristiti za odrediti koje strategije su u kojem trenutku najprikladnije.

Bollinger Bands

1983. John Bollinger stvara Bollinger Bands. Rade se slično kao i postotne trake samo za gornju i donju traku ne koriste postotke, nego standardnu devijaciju.

Gornja traka = Centralna traka + 2 · standardna devijacija zadnjih 20 dana
Centralna traka = 20-dnevni pomični prosjek
Donja traka = Centralna traka - 2 · standardna devijacija zadnjih 20 dana

2 Konstrukcija

2.1 Opis

Za konstrukciju indikatora koji sačinjavaju Bollinger Bands za početak nam treba pomični prosjek (engl. moving average) od 20 dana tj. prosjek od cijena zadnjih 20 dana; Za svaku novu iteraciju koristi novih zadnjih 20 dana.

2.2 Centralna traka

Centralna traka (engl. band, alternativno se može reći linija) se računa kao prosjek zadnjih 20 dana zatvarajućih cijena. U računanju će se skraćeno pisati CT.



Slika 3: Prikaz candlesticksa

Da bismo izračunali vrijednost centralne trake u danu k tj. CT_k trebaju nam P_{k-N+1}, $\cdots$, P_k prije, gdje je P_i zatvarajuća cijena cijena u i-tom danu i N je najčešće 20, no postoje i verzije gdje je N npr. 10 ili 50:

$$\mathrm{CT}_k := \frac{\sum_{i=k-N+1}^{k} \mathrm{P}_i}{\mathrm{N}}. \tag{1}$$



Slika 4: Prikaz pomičnog prosjeka zadnjih 20 dana

2.3 Gornja i donja traka

Za gornju traku (GT) i donju traku (DT) nam treba standardna devijacija cijena (SD) i ona se računa:

$$\mathrm{SD}_k := \sqrt{\frac{1}{\mathrm{N}} \sum_{i=k-N+1}^{k} (\mathrm{P}_i - \mathrm{CT}_k)^2}. \tag{2}$$

Te GT i DT dobivamo:

$$\mathrm{DT}_k := \mathrm{CT}_k + 2 \cdot \mathrm{SD}_k \tag{3}$$

$$\mathrm{GT}_k := \mathrm{CT}_k - 2 \cdot \mathrm{SD}_k. \tag{4}$$



Slika 5: Prikaz sa donjom i gornjom trakom

2.4 Primjer računanja

Za računanje traka za Bollinger Bands uobičajeno se koristi 20-dnevni prosjek i 20-dnevna standardna devijacija cijena zadnjih 20 dana, no kako indikatori nemaju strogo određene parametre, samo za ilustraciju metode i za bolji potpuni opis računanja koristit će se 5-dnevni prosjek i multiplikator 2. Uzet će se podaci koji su prikazani na grafu i zapisani u Tablici 1.

Dan	Cijena
1	66
2	63
3	60
4	63
5	74
6	79
7	75
8	80
9	79
10	76

Tablica 1: Podaci za računanje

Prvo izračunajmo prosjek prvih $N = 5$ dana

$$\mathrm{CT}_5 = \frac{\sum_{i=1}^{5} \mathrm{P}_i}{\mathrm{N}} = \frac{66 + 63 + 60 + 63 + 74}{5} = 65.2, k = 5,$$

$$\mathrm{CT}_6 = \frac{\sum_{i=2}^{6} \mathrm{P}_i}{\mathrm{N}} = \frac{0.63 + 0.60 + 0.63 + 0.74 + 0.79}{5} = 67.8, k = 6,$$

$$\mathrm{CT}_7 = \frac{\sum_{i=3}^{7} \mathrm{P}_i}{\mathrm{N}} = \frac{0.60 + 0.63 + 0.74 + 0.79 + 0.75}{5} = 70.2, k = 7,$$

$$\mathrm{CT}_8 = \frac{0.63 + 0.74 + 0.79 + 0.75 + 0.80}{5} = 74.2, k = 8,$$

$$\mathrm{CT}_9 = \frac{0.74 + 0.79 + 0.75 + 0.80 + 0.79}{5} = 77.4, k = 9,$$

$$\mathrm{CT}_{10} = \frac{0.79 + 0.75 + 0.80 + 0.79 + 0.76}{5} = 77.8, k = 10.$$

Dan	CT
5	65.2
6	67.8
7	70.2
8	74.2
9	77.4
10	77.8

Tablica 2: Vrijednosti za CT

Sada još računamo standardnu devijaciju potrebnu za gornju i donju traku:

$$\mathrm{SD}_5 = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(\mathrm{P}_i - \mathrm{CT}_5)^2} =$$

$$= \sqrt{\frac{1}{\mathrm{N}}((66 - 65.2)^2 + (63 - 65.2)^2 + (60 - 65.2)^2 + (63 - 65.2)^2 + (74 - 65.2)^2)}$$

$$= \sqrt{\frac{1}{\mathrm{N}}(0.8)^2 + (-2.2)^2 + (-5.2)^2 + (-2.2)^2 + (8.8)^2}$$

$$= \sqrt{\frac{1}{\mathrm{N}}(0.64 + 4.84 + 27.04 + 4.84 + 77.44)}$$

$$= \frac{\sqrt{574}}{5} \approx 4.792.$$

Još izračnajmo SD_7. Treba nam $k = 2$ pa će gornja granica sume biti $N + k = 7$, a donja $0 + k = 2$:

$$\mathrm{SD}_7 = \sqrt{\frac{1}{\mathrm{N}} \sum_{i=3}^{7} (\mathrm{P}_i - \mathrm{CT}_7)^2}$$

$$= \sqrt{\frac{1}{\mathrm{N}}((60 - 70.2)^2 + (63 - 70.2)^2 + (74 - 70.2)^2 + (79 - 70.2)^2 + (75 - 70.2)^2)}$$

$$= \frac{\sqrt{1354}}{5} \approx 7.359.$$

Analogno ispunimo tabicu sa svima standardnim devijacijama:

Dan	CT	SD
5	65.2	4.792
6	67.8	7.359
7	70.2	7.359
8	74.2	6.047
9	77.4	2.417
10	77.8	1.939

Tablica 3: Vrijednosti za CT i SD

Te sada možemo dobiti sve potrebne podatke za izračunati gornju i donju traku, npr. za dan 5 imamo:

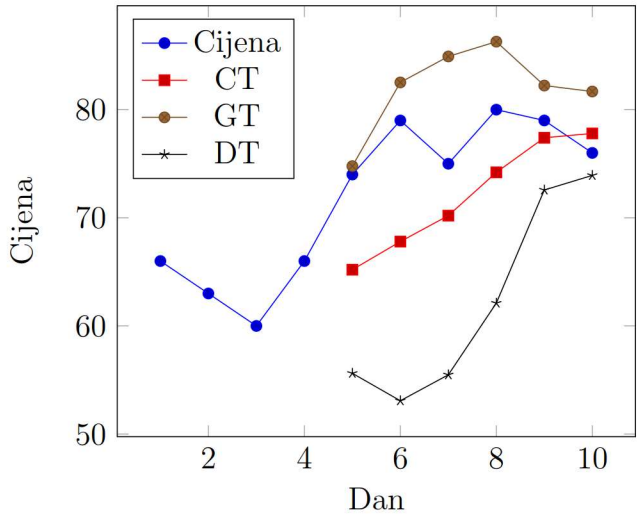
$$\mathrm{GT}_5 = \mathrm{CT}_5 + 2 \cdot \mathrm{SD}_5 = 65.2 + 2 \cdot 4.792 = 74.784$$

$$\mathrm{DT}_5 = \mathrm{CT}_5 + 2 \cdot \mathrm{SD}_5 = 65.2 - 2 \cdot 4.792 = 55.616.$$

Dan	CT	GT	DT
5	65.2	74.78	55.62
6	67.8	82.52	53.08
7	70.2	84.92	55.48
8	74.2	86.29	62.11
9	77.4	82.23	72.57
10	77.8	81.68	73.92

Tablica 4: Vrijednosti za CT, GT i DT

Sada nacrtajmo sve podatke iz Tablice 4 i podatke iz Tablice 1.



Slika 6: Grafički prikaz traka za Bollinger Bands

2.5 Preporučeni parametri

Za računanje parametara je korišten period 5 i multiplikator 2. To je bilo samo za ilustracijske potrebe i nisu dobri parametri za korištenje. Preporučeni parametri za korištenje su:

Period	Multiplikator
10	1.9
20	2.0
50	2.1

Tablica 5: Preporučeni parametri za Bollinger Bands

Pri korištenju perioda 20 i multiplikatora 2, 88-89% cijena se nalaze unutar gornje i donje trake. Kada bi se promijenio period na 10 ili 50 da bi se zadržao isti postotak 88-89% između traka potrebno je prilagoditi multiplikator. Ako se koriste periodi manji od 10 i veći do 50 bilo bi bolje promjeniti veličine perioda umjesto multiplikatore još dodatno smanjivati ili povećavati.

Npr. ako je su periodi u danima (24 sata) i želimo promatrati period od 5 dana, što je sve ukuno 120 sati, onda umjesto da smanjimo multiplikator na npr. 1.8 ili 1.7 bolje smanjiti iznose perioda na 6 sati od 20 perioda pa kako imamo 20 perioda treba se koristiti multiplikator 2. Tako imamo ponovno period od 120 sati te tako imamo preporučene Bollinger Bands parametre.

2.6 Indikatori izvedeni iz Bollinger Bands-a

Još dva indikatora se mogu izvesti iz Bollinger Bands-a. To su %b i BandWidth. Indikator %b pokazuje kolika je cijena u usporedbi sa trakama, a indikator BandWidth pokazuje koliko su široke trake.

2.6.1 Konstrukcija indikatora %b

Formula za indikator %b je:

$$\frac{P_k - DT_k}{GT_k - DT_k}.$$

Vrijednost indikatora %b iznosi 1 kada je trenutna cijena na GL tj. $P_k = GT_k$, iznad 1 kada je iznad GT, 0 kada trenutna cijena na DT, a ispod 0 kada je trenutna cijena ispod DT.

Da bi izračunali vrijednost indikatora $\%b_5$, iskoristimo podatke iz Tablice 4 i Tablice 1 i izračunajmo:

$$\%b_5 = \frac{P_5 - DT_5}{GT_5 - DT_5}$$
$$= \frac{74 - 55.62}{74.78 - 55.62} \approx 0.959.$$

Kada je %b tako blizu vrijednosti 1 znači da je cijena blizu GT, a to i je tako prikazano na Slici 6

2.6.2 Konstrukcija BandWidth

Formula za izračun indikatora BandWidth je:

$$\frac{GT_k - DT_k}{CT_k} \cdot 100.$$

Za izračun vrijednosti indikatora $BandWitdh_5$ Iskoristimo podatke iz Tablice 4

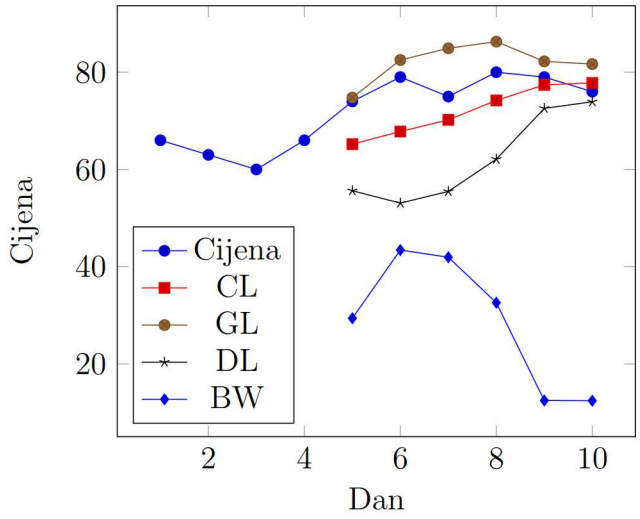
$$BandWidth_5 = \frac{GT_5 - DT_5}{CT_5}$$
$$= \frac{74.78 - 55.62}{65.2} \cdot 100 \approx 29.39.$$

2.6.3 Podaci od izvedenih indikatora

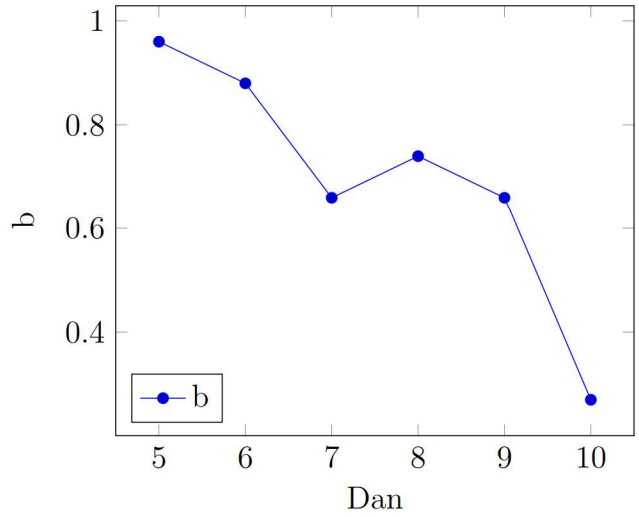
Analogno kako je pokazano napravimo putpunu tablicu podataka sa svim vrijednostima od %b i BandWidth koristeći Tablicu 1 i 4

Dan	CT	GT	DT	%b	BW
5	65.2	74.78	55.62	0.96	29.39
6	67.8	82.52	53.08	0.88	43.42
7	70.2	84.92	55.48	0.66	41.94
8	74.2	86.29	62.11	0.74	32.59
9	77.4	82.23	72.57	0.66	12.48
10	77.8	81.68	73.92	0.27	12.42

Tablica 6: Izračunati podaci od izvedednih indikatora



Slika 7: Grafički prikaz dodatnih traka za Bollinger Bands



Slika 8: Grafički prikaz %b trake za Bollinger Bands

Kako indikator %b pokazuje cijenu u relaciji na dvije glavne trake: GL i DL iz slike 8 se iščitava da je u danu 5 cijena jako blizu gornjoj traci i da se tijekom dana približava donjoj traci što je i tako vidljivo na Slikama 7 i 6.[2]

[2] https://en.wikipedia.org/wiki/Bollinger_Bands#/media/File:BollingerBandsSPX.svg



Slika 9
(IZVOR: footnote [2])

3 Program

Program koji se koristi za testiranje je dostupan na linku [3]. Potpuna dokumentacija programa je dostupna na linku [4]. Ovdje će se opisat dijelovi koji su bitni za testiranje primjera iz Poglavlja Korištenje (Poglavlje 4).

3.1 Pristup vrijednostima kriptovaluta

Za pristup vrijednostima kriptovaluta se koristio API (Application Programming Interface) stranice Coinbase pro [5]. Da bi se pristupilo željenim podacima potrebno napraviti pravilan link koji bi se pozvao i na kojemu bi bili željeni podaci. U podacima se moglo birati koju kriptovalutu pratiti, u kojoj valuti izraziti vrijednost kriptovalute, iz kojeg vremenskog perioda uzeti podatke i koliko velike da jedninice vremena budu (npr. 1 minuta, 30 minuta, 1 sat, 12 sati, 1 dan).

Cijeloj datoteci koja radi poziv se može pristupiti na linku, a ovdje je prikazan ključni dio koda za api poziv:

```
startTime = datetime.fromtimestamp(int(iso8601start))
startTime = datetime.strftime(startTime, "%Y-%m-%dT%H:%M:%S")
endTime = datetime.fromtimestamp(int(iso8601end))
endTime = datetime.strftime(endTime, "%Y-%m-%dT%H:%M:%S")
api = "https://api.pro.coinbase.com/products/" + market + "/candles?start=" + \
      startTime + "&end=" + endTime + "&granularity=" + str(granularity)

resp = requests.get(api)
```

[3] https://gitlab.com/Bborna/AlgoritamskiInvesticijskiBot
[4] https://www.overleaf.com/read/ssczffgjzrgw
[5] https://api.pro.coinbase.com/products

Te pomoću tog poziva se može dobiti npr. link: https://api.pro.coinbase.com/products/ZRX-EUR/candles?start=2018-10-9&end=2018-11-12&granularity=86400.

Podaci koji se dobiju su lista uređenih 6-torki gdje je prvi element početak promatranog vremenskog perioda izražen u unix vremenu, drugi je najniža doesgnuta vrijednost u promatranom periodu, treći je najviša dosegnuta vrijednost u promatranom periodu, četvrti element je vrijednost na početku promatranog perioda, peti je vrijednost na kraju promatranog perioda i šesti je volumen. Promatrani period je vremenski period između jedne 6-torke do druge 6-torke u nizu. Vrijednosti kriptovaluta se opisuju redosljedom: najniža vrijednost (L), najviša vriejdnost (H), otvarajuća vrijednost (O) i zatvarajuća vrijednost (C) tj. (LHOC). Veličina perioda ovisi o pozivu tj. o varijabli "granularity"; U našem slučaju je 86400 što je period od 24 sata.

[1539388800,0.62,0.67,0.65,0.63,43125.60896],[1539302400,0.63,0.8,0.69,0.66,160076.75404]]

Slika 10: Primjer dvije 6-torke u nizu

3.2 Prikaz vrijednosti na candlesticksove

Za prikaz candlesticksova korišten je modul mplfinance. Za crtanje candlesticsova potrebne su mu, za svaki promatrani period, vrijednost na početku promatranog perioda (Open), najviša vrijednost u periodu (High), najniža vrijedonst u periodu (Low) i zatvarajuća vrijednost u periodu (Close). Redosljed kojime modu prima podatke je (OHLC), što je različito od onoga kako se podaci dobivaju (LHOC) pa je potrebno te podatke prilagoditi da bi ih modul mogao pravilno čitati. Code snippet implementacije pretvaranja (LHOC) u (OHLC):

```
data = {}
dict = []
for price in reversed(resp.json()):
    # time, low, high, open, close, volume
    iso8601 = datetime.fromtimestamp(price[0])
    timestamp = datetime.strftime(iso8601, "%d/%m/%Y")
    timestamp1 = datetime.strptime(timestamp, "%d/%m/%Y")
    """               time     Open     High     Low     Close"""
    data[timestamp] = (date2num(timestamp1), price[3], price[2], price[1],
    price[4])
    dict.append({"date": timestamp, "open": price[3], "high": price[2],
    "low": price[1], "close": price[4]})

CreateCSV(dict)
```

3.3 Implementacija Bollinger Bandsa

Za implementaciju centralne trake Bollinger Bandsa korišten je pandasov ewm, što zapravo računa eksponencijalni težinski pomični prosjek, no kako je spomenuto u knjizi John Bollinger: Bollinger on Bollinger Bands, 54-55, da nema značajne razlike koji se pomični prosjek koristi i da se mogu koristit svi pomični prosjeci pa su rezultati iz Poglavlja Korištenje (Poglavlje 4) dobri.

Implementacija pokazatelja za Bollinger Bands se mogu naći na linku, a ovdje je ključni code snippet implementacije:

```
def __SetBounds(self):
    self.closePrices = self.data['close']
    self.ema20 = self.closePrices.ewm(span=20).mean()
    self.std = []
    for x in self.closePrices.ewm(span=20).std()[0:20]:
        self.std.append(x * 2)
    self.upperBound, self.lowerBound = self.STDCloseEMA20()

def STDCloseEMA20(self):
    diffSQ = []
    for i in range(len(self.closePrices)):
        diff = self.closePrices[i] - self.ema20[i]
        diffSQ.append((diff * diff))
        if i >= 20:
            self.std.append(2 * sqrt(sum(diffSQ[-21:-1]) / 20))
    return self.ema20 + self.std, self.ema20 - self.std
```

3.4 Računanje trenutne vrijednosti

U programu postoje dva računanja trenutne vrijednosti, jedna u kojoj se koristi algoritam za investiciju i druga gdje se računa kolika je vrijednost same kriptovalute u odnosu na početak promatranja. Puni kod se može može vidjeti na linku, a ovdje je ključni code snippet:

```
def MoneyUpdate(self, oldPrice, newPrice, potentialDate, options):
    self.currentMoney_permaTrade *= newPrice / oldPrice
    if self.inTrading:
        self.currentMoney *= newPrice / oldPrice

        if self.currentMoney <= self.sellLow and self.autoEnter:
            options.ExitTrade(self)
        elif self.currentMoney >= self.sellHigh and self.autoEnter:
            options.ExitTrade(self)
```

Kao što je vidljivo iz koda: jedno računanje se odvija cijelo vrijeme, a drugo samo kada smo u tradeu. Koristeći cijene iz Tablice 1 opišimo kako se računa, pretpostavimo počnemo sa vrijednošću 100 i promatrajmo prvih 5 dana:

$$100 \cdot \frac{63}{66} \cdot \frac{60}{63} \cdot \frac{63}{60} \cdot \frac{74}{63} = 100 \cdot \frac{\cancel{63}}{66} \cdot \frac{\cancel{60}}{\cancel{63}} \cdot \frac{\cancel{63}}{\cancel{60}} \cdot \frac{74}{\cancel{63}} = 100 \cdot \frac{74}{66} = 112.\overline{12}.$$

4 Korištenje

Bollinger Bands su tehnički indikator koji pomaže pri određivanju trendova, nestabilnosti (engl. volatility), relativne snage i zamaha cijene promatrane dionice ili kriptovalte.

Načini korištenja Bollinger Bandsa uvelike varira među trgovcima. Neki kao trenutak za ulazak u kupovanje koriste cijena dotakne donju traku, a za izlazak kada cijena dotakne centralnu traku. Neki kupuju kada cijena prijeđe preko gornje trake ili prodaju kada cijena padne ispod donje trake.

Za razliku od ostalih indikatora Bollinger Bans nisu namijenjeni da se koriste samostalno. Mogu se kombinirati sa drugim indikatorima kao što su npr. MACD, RSI itd..

U sljedećem dijelu poglavlja ćemo isprobavati razne metode investiranja koristeći pokazatelj Bollinger Bands samostalno i uspoređivati vrijednosti s kojima će se završiti pri korištenju pojedine metode na primjerima, ali i uspoređivati i sa vrijednosti same kriptovalute. Isprobavat će se za uključenim granica dobitka i gubitka i isključenima. Granice dobitka i gubitka (osim ako nije drugačije rečeno) iznose ± 20% od vrijednosti pri ulogu.

4.1 Iznad gornje trake

Sljedeća metoda za investirane kupuje kada trenutna cijena prijeđe preko gornje trake Bollinger Bandsa, a prodaje kada trenutna cijena padne ispod centralne trake. Prikaz kako su funkcije za kupovinu i prodaju implementirane:

```
# ival predstavlja redni broj podataka/indeks podataka koji govori
# programu koji da se cita
def TradingStartSignal3_1(self,ival):
    if self.closePrices[ival]>self.upperBound[ival] and not self.inTrade:
        self.inTrade = True
        return True

def TradingStopSignal3_1(self,ival):
    if self.closePrices[ival]<self.ema20[ival] and self.inTrade:
        self.inTrade = False
        return True
    return False
```

Primjer	Period
ZRX-EUR	1.11.2018.-14.9.2021.
LTC-EUR	31.7.2018.-14.9.2021.

Tablica 7: Testni podaci

Investicijsku metodu provjerimo na primjeru Litecoina sa vrijednošću izraženom u Eurima (LTC-EUR) u vremenskom periodu od 31.7.2018. do 14.9.2021. sa uključenim granicama dobitka i gubita. Počeli smo sa vrijednosti 100, sa investicijskim botom smo završili na 307.10, a da nismo koristili investicijski algoritam tj. samo na početku kupili LTC u vrijednosti 100 završili bi na 199.76. A sa isključenim granicama dobitka i gubitka: 262.77. Granice rade tako da se iz tradea izlazi kada trenutna vrijednost je povećana za 20% ili smanjena za 20% tj. ako se ušlo sa vrijednosti 100 izlazi se kada vrijednost dođe na 120 ili 84.

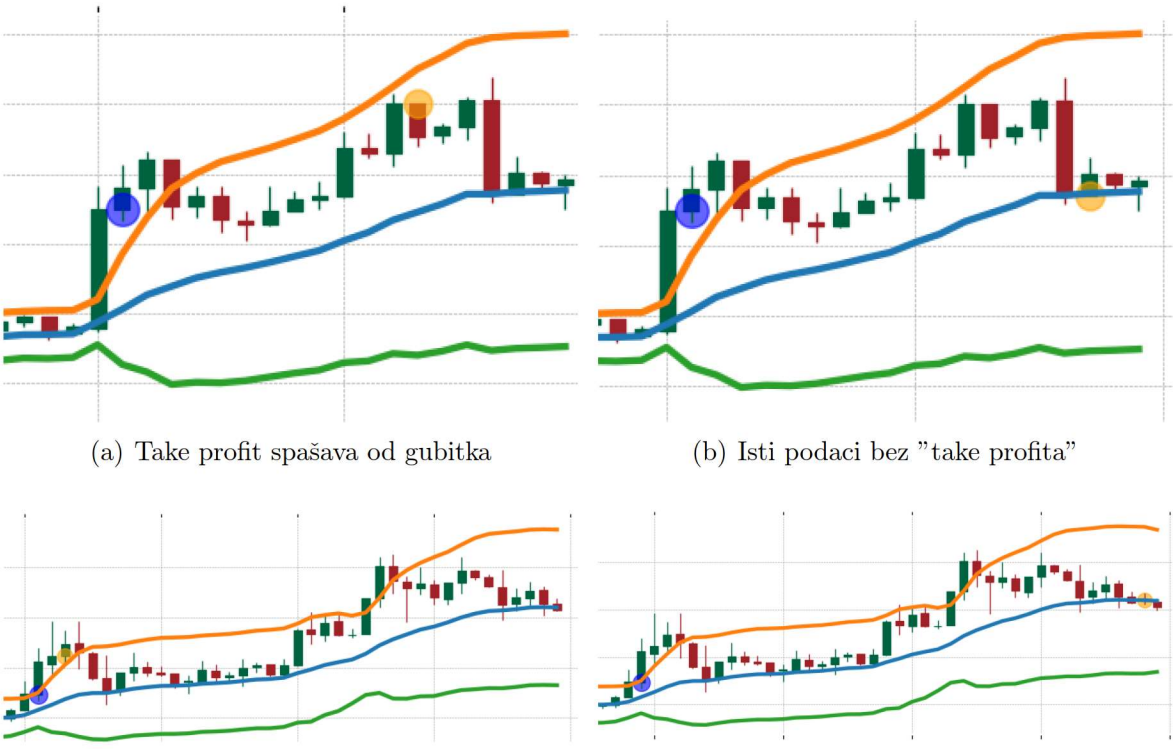
Na istom algoritmu u periodu od 1.11.2018 do 14.9.2021. na primjeru ZRX-EUR vrijednosti uz algoritam je 355.63, bez algoritma 119.90. Bez ugrađenih granica 383.75.

	LTC-EUR	ZRX-EUR
Bez algoritma	199.76	119.90
S algoritmom s granicama	307.10	355.63
S algortimom bez granica	262.77	282.75

Tablica 8: Rezultati testa algoritma "iznad gornje trake"

Na primjeru ZRX-EUR je vidljivo da vrijednost ZRX se u periodu nije značajno povećala, ali da smo ukupnu vrijednost povećali. Iako razlika u vrijednosti ZRX sa vrijednošću izraženom u eurima u danom periodu nije puno povećana ZRX tijekom tog perioda ima veliku nestabilnost (engl. volatility) pa time i puno trenutaka kada kroz produžene periode rasta.

Vidljivo je da je sa ugrađenim granicma u primjeru LTC-EUR test rezultirao većom vrijednošću, nego bez granica, a kod ZRX-EUR test rezultirao manjom vrijednošću. To se interpretira tako jer ZRX ima veću nestabilnost pa i time češće dugotrajne periode rasta gdje na čijem je početku trenutna cijena prešla gornju traku se češće događa da granica za "take profit" spriječi dodatni profit; Slika 11(c) i Slika 11(d). U primjeru LTC-EUR se suprotno od primjera ZRX-EUR češće događa da nakon što cijena naglo poraste i prijeđe gornju trake da se dogodi povratak cijene (engl. retracement) na cijenu bližu početnoj, umjesto dugotrajnog rasta.



(a) Take profit spašava od gubitka

(b) Isti podaci bez "take profita"

(c) Primjer kada "take profit" sprječeva daljnji dobitak

(d) Isti podaci sa "take profitom"

Slika 11: Primjeri djelovanja ugrađenih granica "take profit" i "stop loss"

4.1.1 Zaključak

Bez obzira što Bollinger Bands nisu osmišljeni kao indikator koji bi se trebao koristiti samostalno; Algoritam za investiranje koji kao za kupvinu koristi trenutak kada trenutna cijena prijeđe gornju traku implementiran kao u poglavlju 4.1 pokazuje dobre rezultate.

4.2 Ispod donje trake

Sljedeći algoritam za investiranje radi tako da se kupuje kada trenutna cijena padne ispod donje trake Bollinger Bandsa, a trenuci prodaje će se mijenjati. Funkcija kupovine je ovako implementirana:

```
def TradingStartSignal3_2(self,ival):
    if self.closePrices[ival]<self.lowerBound[ival] and not self.inTrade:
        self.inTrade = True
        return True
```

Česti problem uz ovaj način kupovanja je da vrijednost nakon naglog pada nastavi padati i da ju tek zaustavi "stop loss" granica nakon gubitka od 20%. Slika 12



Slika 12: Primjer nastavka pada nakon naglog pada

4.2.1 Izlaz iznad centralne trake

U ovoj verziji algoritma trenutak prodaje je kada trenutna cijena prijeđe iznad centralne trake. Ovaj algoritam pretpostavlja da će se cijeni nakon naglog pada vratiti na prijašnje vrijednosti te na taj način kupiti kada je lokalno najniže, npr. Slika 13(a) i Slika 13(b). Rezultati testa na podacima Tablice 7.

Funkcija za prodaju je implementirana:

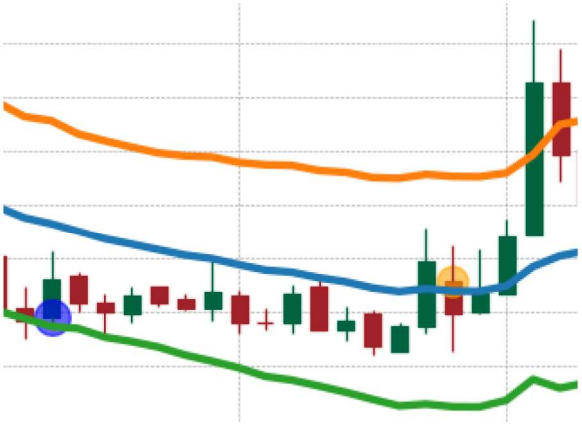
```
def TradingStopSignal3_2_1(self,ival):
    if self.closePrices[ival]>self.ema20[ival] and self.inTrade:
        self.inTrade = False
        return True
    return False
```

	LTC-EUR	ZRX-EUR
Bez algoritma	199.76	119.90
Algoritam s granicama	21.75	130.43
Algortiam bez granica	39.04	112.20
Algoritam donja granica	21.75	143.39

Tablica 9: Rezultati testa algoritma "ispod donje trake"

U zadnji test je uveden algoritam gdje je isključena samo gornja granica, a donja ostaje uključena. To je inspirirano algoritmom koji očekuje vraćanje vrijednosti (engl. retracement) da ako se dogodi slučaj da cijena raste polako kroz duže vrijeme da pokupi malo više profita od retracementa.

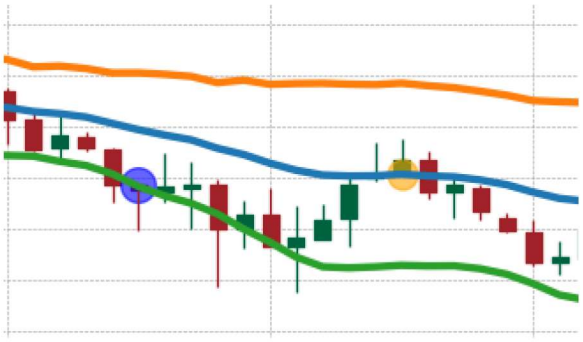
Ovaj algoritam bez obzira na isključenu gornju granicu ima centralnu liniju koja se ponaša kao gornja granica pa se puni retracenemnt ni ne može pokupiti. Slika 13(a).



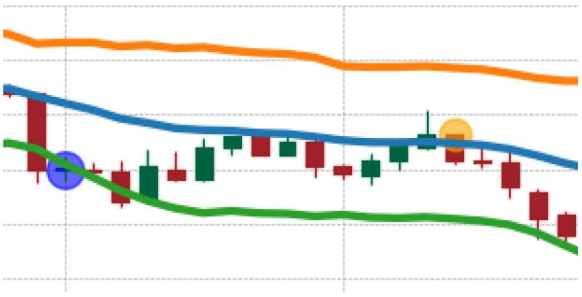
(a) Primjer kupovine pri lokalnom minimumu i primjer rane prodaje u retracementu



(b) Primjer kupovine sa uzimanjem punog retracementa



(c) Primjer retracementa do centralne linije prije ponovnog pada



(d) Primjer retracementa do centralne linije prije ponovnog pada

Slika 13

4.2.2 Izlaz iznad gornje trake

Malo promjenjeni algoritam gdje je trenutak izlaska kada trenutna cijena prijeđe gornju traku. Tako će se izgubiti manji retracemensi npr. Slika 13(c) i Slika 13(d) u kojima se

centralna linija malo okrznula, no veći retracementsi će se većim dijelom pokupiti; Slika 13(b). Kako se žele pokupiti veliki retracementsi gornja granica u svim primjerima će biti isključena. Funkcija za izlazak je ovako implementirana:

```
def TradingStopSignal3_2_2(self,ival):
    if self.closePrices[ival]>self.upperBand[ival] and self.inTrade:
        self.inTrade = False
        return True
    return False
```

	LTC-EUR	ZRX-EUR
Bez algoritma	199.76	119.90
Algoritam donja granica	34.49	119.76

Tablica 10: Rezultati algoritma "ispod donje trake"

4.2.3 Povratak ispod centralne linije

Jedan od problema s ovim algoritmom je što se zna dogoditi da nakon naglog pada cijena prijeđe centralnu traku, ali se onda vrati; 13(c) i Slika 13(d). Pa pokušajmo to eliminirati tako da kada cijena prijeđe centralnu traku nakon povratka ispod centralne trake se izađe iz tradea.

```
    def TradingStopSignal3_2_3(self, ival):
        if self.closePrices[ival] > self.ema20 and self.inTrade:
            self.leaveWhenUnderEMA20 = True
        if self.closePrices[ival] < self.ema20 and self.leaveWhenUnderEMA20\
            and self.inTrade:
            self.inTrade = False
            self.leaveWhenUnderEMA20 = False
            return True
        if self.closePrices[ival] > self.upperBound[ival] and self.inTrade:
            self.inTrade = False
            self.leaveWhenUnderEMA20 = False
            return True
        return False
```

	LTC-EUR	ZRX-EUR
Bez algoritma	199.76	119.90
Algoritam donja granica	28.29	106.52

¿

Tablica 11: Rezultati algoritma "povratak ispod centralne linije"

4.2.4 Zaključak

Algoritam koji za ulazak koristi trenutak kada je trenutna cijena pala ispod donje trake (Poglavlje 4.2) ne pokazuje dobre rezultate bez obzira na trenutak izlaska (Potpoglavlja 4.2.1, 4.2.2, 4.2.3). I taj se ulazak nebi trebao koristiti samostalno.

5 Zaključak

Bollinger Bands imaju dugu povijest. Prije Bollinger Bands je bilo puno indikatora koji su mjerili nestabilost (engl. volatitlity) podataka. Indikatori Bollinger Bands su prvi indikatori koji za mjerenje nestablinosti koriste standardnu devijaciju. Za razliku od drugih indikatora, Bollinger Bands nisu namijenjeni da se koriste samostalno. Bez obzira što nisu namijenjeni da se koriste samostalno, kao trenutak kupovine kada trenutna cijena prijeđe preko gornje trake, kao što je opisano u poglavlju Iznad gornje trake (poglavlje 4.1), pokazuje dobre rezultate na testiranim primjerima, a kao trenutak kupovine kada trenutna cijena padne ispod donje trake, kao što je opisano u poglavlju Ispod donje trake (poglavlje 4.2), ne pokazuje dobre rezultate bez obzira na koji trenutak prodaje se koristi te se taj trenutak za kupovinu, nebi trebao koristiti samostalno, nego u kombinaciji sa drugim indikatorima.

6 Izvori

1. John Bollinger : Bollinger on Bollinger Bands
   ISBN 0-07-137368-3, 2002.
   - 35-49 za povijest
   - 50-59 za konstrukciju.
2. https://school.stockcharts.com/doku.php?id=technical_indicators:moving_averages - Računanje SMA
3. https://www.earnforex.com/guides/bollinger-bands/ - Računanje standardne devijacije, iako je jedan dio krivo napisan na ovoj stranici
4. http://eng.yax.su/finlab/ir002/22/index.shtml - druga web stranica uz koju se može doći do knjige
5. https://school.stockcharts.com/doku.php?id=technical_indicators:bollinger_band_width - za formulu od BandWidth-a
6. https://en.wikipedia.org/wiki/Bollinger_Bands#/media/File:BollingerBandsSPX.svg - slika za indikatore %b i BandWidth
7. https://www.fidelity.com/viewpoints/active-investor/understanding-bollinger-bands - uvodni dio u poglavlju Korištenje
8. https://www.investarindia.com/blog/how-to-use-bollinger-bands/ - Korištenje
9. https://www.coingecko.com/en/coins/0x - podaci o ZRX
10. https://docs.pro.coinbase.com/#get-historic-rates - o coinbase api

6.1 Dodatno

1. Program
   - https://gitlab.com/Bborna/AlgoritamskiInvesticijskiBot
   - https://gitlab.com/Bborna/AlgoritamskiInvesticijskiBot/-/blob/main/historicaldata.py
   - https://gitlab.com/Bborna/AlgoritamskiInvesticijskiBot/-/blob/main/classes/BollingerBands.py
   - https://www.overleaf.com/read/sszffgjzrgw