



Identificação de Manipulação no Mercado Financeiro de Ações e Derivativos por Spoofing e Layering

Autores:

Prof. Dr. Nizam Omar

Mateus Saldanha

Mestrado em Engenharia Elétrica e Ciência da Computação


Agenda

- Motivação
- Objetivos
- Metodologia
- Fluxo Operacional
- Resultados
- Trabalhos Futuros
- Referências Bibliográficas



Motivação - Financeira

Volume Médio Diário / R\$ Milhões Reais



B3, Market Data: Histórico *Pessoas Físicas*. Financeiro, São Paulo, 01/09/2017. Disponível em:

http://www.bmfbovespa.com.br/pt_br/servicos/market-data/consultas/historico-pessoas-fisicas . Acesso

em: 05/Ago/2018.

Mateus Saldanha – matsal@ig.com.br



Motivação - Tecnológica



B3, Market Data: Histórico *Pessoas Físicas*. Financeiro, São Paulo, 05/08/2018. Disponível em: http://www.bmfbovespa.com.br/pt_br/servicos/market-data/consultas/historico-pessoas-fisicas. Acesso em: 05/08/2018.



Motivação - Legal

Processos instaurados junto a BSM e CVM

PAD nº15/2016

Status : BSM Finalizado

CVM não julgado

Período: 27/07/2015 a 29/02/2016

PAD nº 05/2016 BSM & CVM

Status : encerrado

Período : 01/08/2014 a 31/03/2015

Não há novos casos registrados junto a BSM



Objetivo

- Desenvolver uma solução, que de maneira autônoma, tomando como referência a regulamentação Americana (EUA), realize a identificação de ordens enviadas no mercado acionário que potencialmente tenham tentado ou manipulado o book de ofertas, devido a utilização de técnicas de negociação duvidosa (Spoofing ou Layering), auxiliando no processo de investigação e acompanhamento do mercado acionário.
- Aumentar o controle sobre o mercado eletrônico de ações, desenvolvendo uma solução para acompanhamento da negociação pelo mercado.



Objetivo

- Lei Dodd-Frank:
 - Deve ser considerado ilegal qualquer pessoa que empregue qualquer negociação, prática ou conduta contra as regras:
 - Violar as ofertas de compra e venda
 - Demonstrar intencional ou imprudente descuido para a execução de negócios durante o período de negociação,
 - É caracterizado como, ou comumente conhecido pelos operadores como “Spoofing” (enviar ordens de compra e vendas com a intenção de cancelar a oferta antes da execução).
- A comissão também prove em seu estatuto, sendo:
 - Submeter ou cancelar ofertas para sobrecarregar o sistema de cotação
 - Submeter ou cancelar ofertas com a intenção de atrasar a execução de outros trades
 - Submeter ou cancelar múltiplas ofertas para criar a aparência de uma profundidade de book que não é real.
 - Submeter ou cancelar ofertas com a intenção e criar movimentos artificiais de preço de aumento ou redução.

Método

- Identificar padrões de composição do book de ofertas de cada instrumento sendo capaz de selecionar o tipo de ordens, compra ou venda, que possam ser classificadas pelos itens da norma americana.

Ferramenta

- Bibliotecas Python (Pandas x Numpy)
- Anaconda



Método

NEG

```
;0000000270; 000000000016.960000;0000000000000000100;10:02:00.001;1;2017-11-03;000082796260713;000000004889230  
;0000000280; 000000000016.960000;0000000000000000100;10:02:00.001;1;2017-11-03;000082796260713;000000004889232  
;0000000290; 000000000016.960000;00000000000000001500;10:02:00.001;1;2017-11-03;000082796260720;000000004889234  
;0000000300; 000000000016.960000;0000000000000000100;10:02:00.001;1;2017-11-03;000082796260720;000000004889236
```

CPA 1.3MM (130 K)

```
;1;000082796515810;000000005667660;004;13:14:20.447000;0000000000; 000000000016.740000;00000000000000001000;  
;1;000082796515817;000000005667679;001;13:14:20.461000;0000000000; 000000000016.740000;00000000000000001000;  
;1;000082796515817;000000005667680;004;13:14:20.461000;0000000000; 000000000016.740000;00000000000000001000;  
;1;000082796515828;000000005667722;001;13:14:20.474000;0000000000; 000000000016.740000;00000000000000001000;  
;1;000082796515780;000000005667729;003;13:14:20.476000;0000000000; 000000000016.720000;00000000000000002000;  
;1;000082796515834;000000005667751;001;13:14:20.488000;0000000000; 000000000016.730000;0000000000000000400;
```

VDA 1.2MM (129 K)

```
;2;000082796703849;000000006272828;011;19:45:00.016000;0000000000; 000000000016.950000;00000000000000000900;  
;2;000082796703861;000000006272830;011;19:45:00.016000;0000000000; 000000000018.000000;00000000000000000500;  
;2;000082796703871;000000006272832;011;19:45:00.016000;0000000000; 000000000017.050000;000000000000000029500;  
;2;000082796703923;000000006272844;011;19:45:00.016000;0000000000; 000000000017.040000;000000000000000012900;  
;2;000082796703924;000000006272845;011;19:45:00.016000;0000000000; 000000000017.090000;000000000000000012900;  
;2;000082796703925;000000006272846;011;19:45:00.016000;0000000000; 000000000017.140000;000000000000000012900;
```

Método

DS

Estrutura do Dataset

```
1001, 2, 16.94, 16.94, 300, 127, 0, 5082.00, 0.0000, 0.0000, 16.94
1110, 3, 16.93, 16.93, 100, 45, 7, 1693.00, 0.0000, 0.0000, 16.93
1101, 3, 16.95, 16.95, 300, 127, 0, 5085.00, 0.0000, 0.0000, 16.95
1011, 7, 16.94, 16.94, 4500, 8, 0, 76230.00, 0.0000, 0.0006, 16.95
1010, 2, 16.94, 16.94, 4300, 8, 0, 72842.00, 0.0000, 0.0000, 16.94
1001, 4, 16.94, 16.94, 5000, 8, 0, 84700.00, 0.0000, -0.0006, 16.93
```

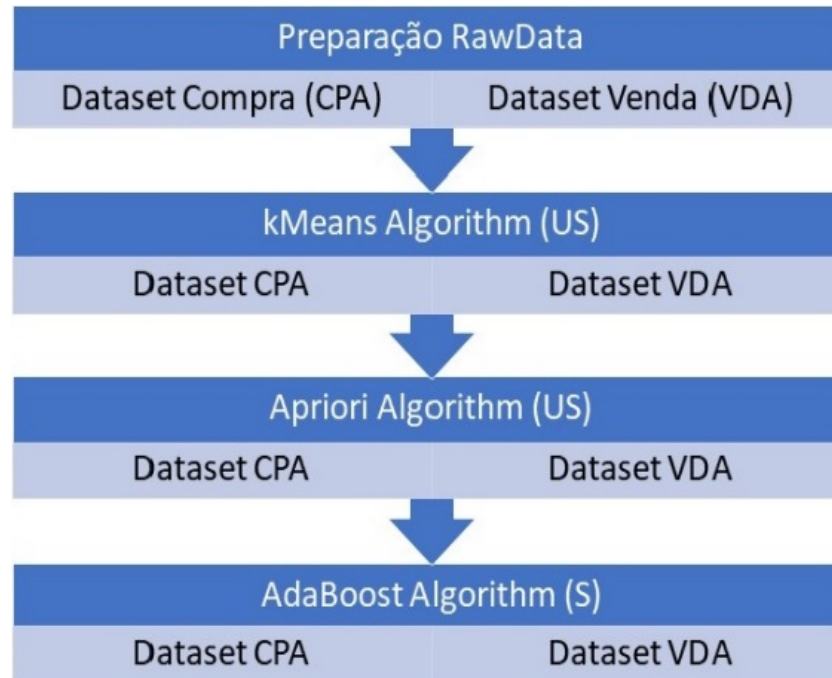


Método

MC





Estrutura do Dataset e processo de análise.

- Python



Método - kMeans

MC



Método - APRIORI

MC

Supports : é definido como a porcentagem da incidência de cada valor por atributo do dataset

Confidence : é calculado pela associação entre as características de cada atributo.



Método - APRIORI

MC

Apriori		
PETR 4 CPA - TotOrder		
Item	Quant.	Support
2	23296	0,8050593
3	4111	0,1420672
4	928	0,0320697
5	329	0,0113695
6	127	0,0043888
7	47	0,0016242
8	23	0,0007948
9	12	0,0004147
10	7	0,0002419
11	8	0,0002765
12	6	0,0002073
13	3	0,0001037
14	1	0,0000346
15	1	0,0000346
16	3	0,0001037
17	5	0,0001728
18	2	0,0000691
19	5	0,0001728
20	2	0,0000691
21	1	0,0000346
22	4	0,0001382
24	1	0,0000346
25	2	0,0000691
28	1	0,0000346
29	2	0,0000691
39	1	0,0000346
40	1	0,0000346
41	2	0,0000691
48	1	0,0000346
63	1	0,0000346
78	1	0,0000346
85	1	0,0000346
143	1	0,0000346
211	1	0,0000346

Apriori		
BEEF3 CPA - Qty		
Item	Quant.	Support
100	578	0,446332
200	168	0,12973
300	159	0,12278
400	21	0,016216
500	9	0,00695
600	15	0,011583
700	10	0,007722
800	5	0,003861
900	1	0,000772
1000	10	0,007722
1100	2	0,001544
1200	1	0,000772
1300	2	0,001544
1500	1	0,000772
1600	1	0,000772
1700	1	0,000772
1800	1	0,000772
1900	2	0,001544
2000	1	0,000772
2400	2	0,001544
4200	1	0,000772
4300	27	0,020849
4400	201	0,155212
4500	71	0,054826
5000	4	0,003089
9000	1	0,000772

Apriori*		
DOLZ17 CPA - Deltatime		
Item	Quant.	Support
0	47867	0,604786
1	6273	0,079258
2	3615	0,045675
3	2521	0,031852
4	1760	0,022237
5	1412	0,01784
6	1053	0,013304
7	967	0,012218
8	762	0,009628
9	680	0,008592
10	594	0,007505
11	559	0,007063
12	530	0,006696
13	503	0,006355
14	397	0,005016
15	368	0,00465
16	352	0,004447
17	325	0,004106
18	337	0,004258
19	266	0,003361
20	302	0,003816
21	286	0,003614
22	279	0,003525
23	214	0,002704
24	237	0,002994
25	202	0,002552
26	223	0,002818
27	180	0,002274
28	199	0,002514
29	167	0,00211
30	138	0,001744
31	170	0,002148
32	137	0,001731
33	136	0,001718



* Apresentados 34 valores de 120

Mateus Saldanha – matsal@ig.com.br

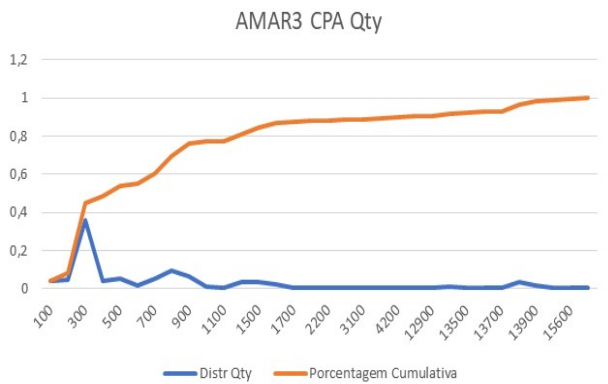



Método - APRIORI

MC



Ocorrência



Ocorrência



Método - ADABOOST

MC

AMAR3					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	28	0,0502693	1	24	0,027874564
-1	529	0,9497307	-1	837	0,972125436

DOLZ17					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	101	0,00118649	1	44	0,000504761
-1	85024	0,99881351	-1	87126	0,999495239

POMO4					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	50	0,045620438	1	16	0,013816926
-1	1046	0,954379562	-1	1142	0,986183074

BGIZ17					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	0	0	1	0	0
-1	5	1	-1	13	1

AMAR3					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	600	0,6	1	600	0,6
-1	400	0,4	-1	400	0,4

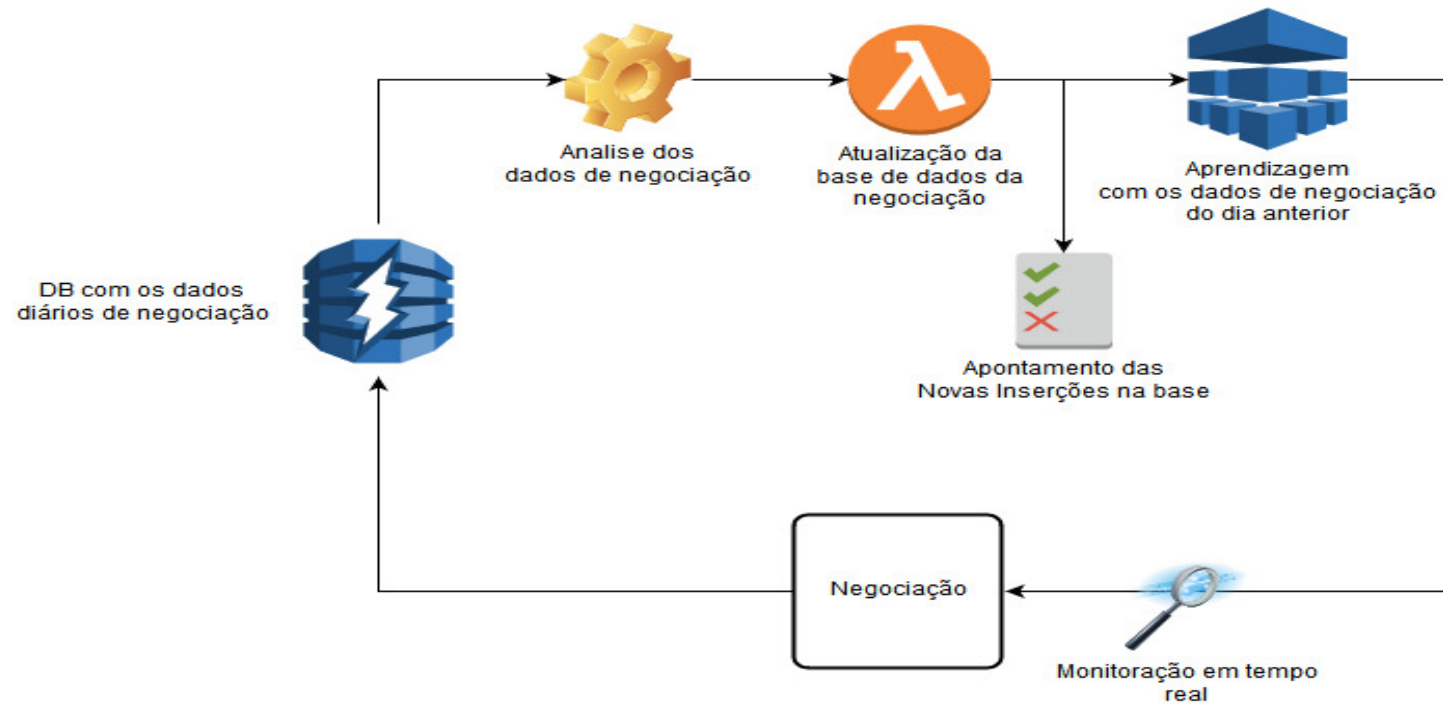
DOLZ17					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	6000	0,6	1	6000	0,6
-1	4000	0,4	-1	4000	0,4

POMO4					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	656	0,599634369	1	694	0,599827139
-1	438	0,400365631	-1	463	0,400172861

BGIZ17					
CPA			VDA		
Classific.	Total	%	Classific.	Total	%
1	0	0	1	0	0
-1	0	0	-1	0	0



Fluxo Operacional



Resultados

Instrumentos Estudados



PETROBRAS

PETR4



DOLZ17



POMO4



marisa

AMAR3

Minerva Foods

BEEF3





BGIZ17

Resultados





Resultados – PETR4

Dist.





Preço

Dist.


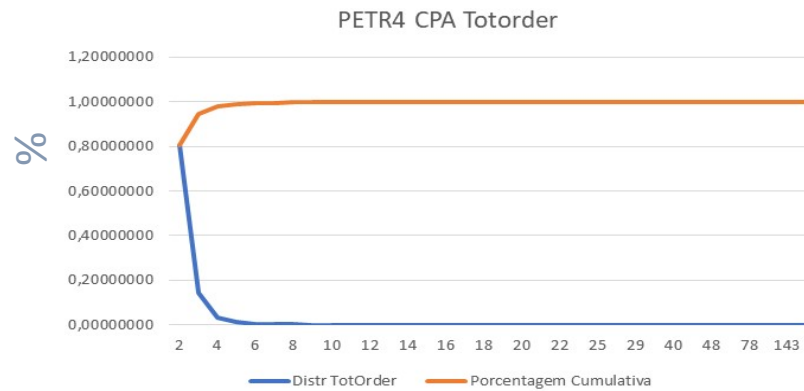


Qtde

Resultados – PETR4




Var. Preço



Ocorrência

Resultados – PETR4






Resultados – PETR4

	exectype	numorder	sprice	price	qty	broker	deltatime	asprice	ostradeprice	fprice	cluster	apriori
caso A	1010.0	2.0	16.88	16.88	15000.0	A	54.0	1.0	0.0018	16.91	1.0	1.0
caso B	1010.0	2.0	16.82	16.82	14800.0	B	0.0	1.0	0.0	16.82	1.0	1.0
caso C	1110.0	41.0	16.91	16.89	400.0	C	12.0	1.0	0.0024	16.93	1.0	1.0
caso D	1110.0	143.0	16.89	16.89	600.0	D	4.0	1.0	0.0012	16.91	1.0	1.0

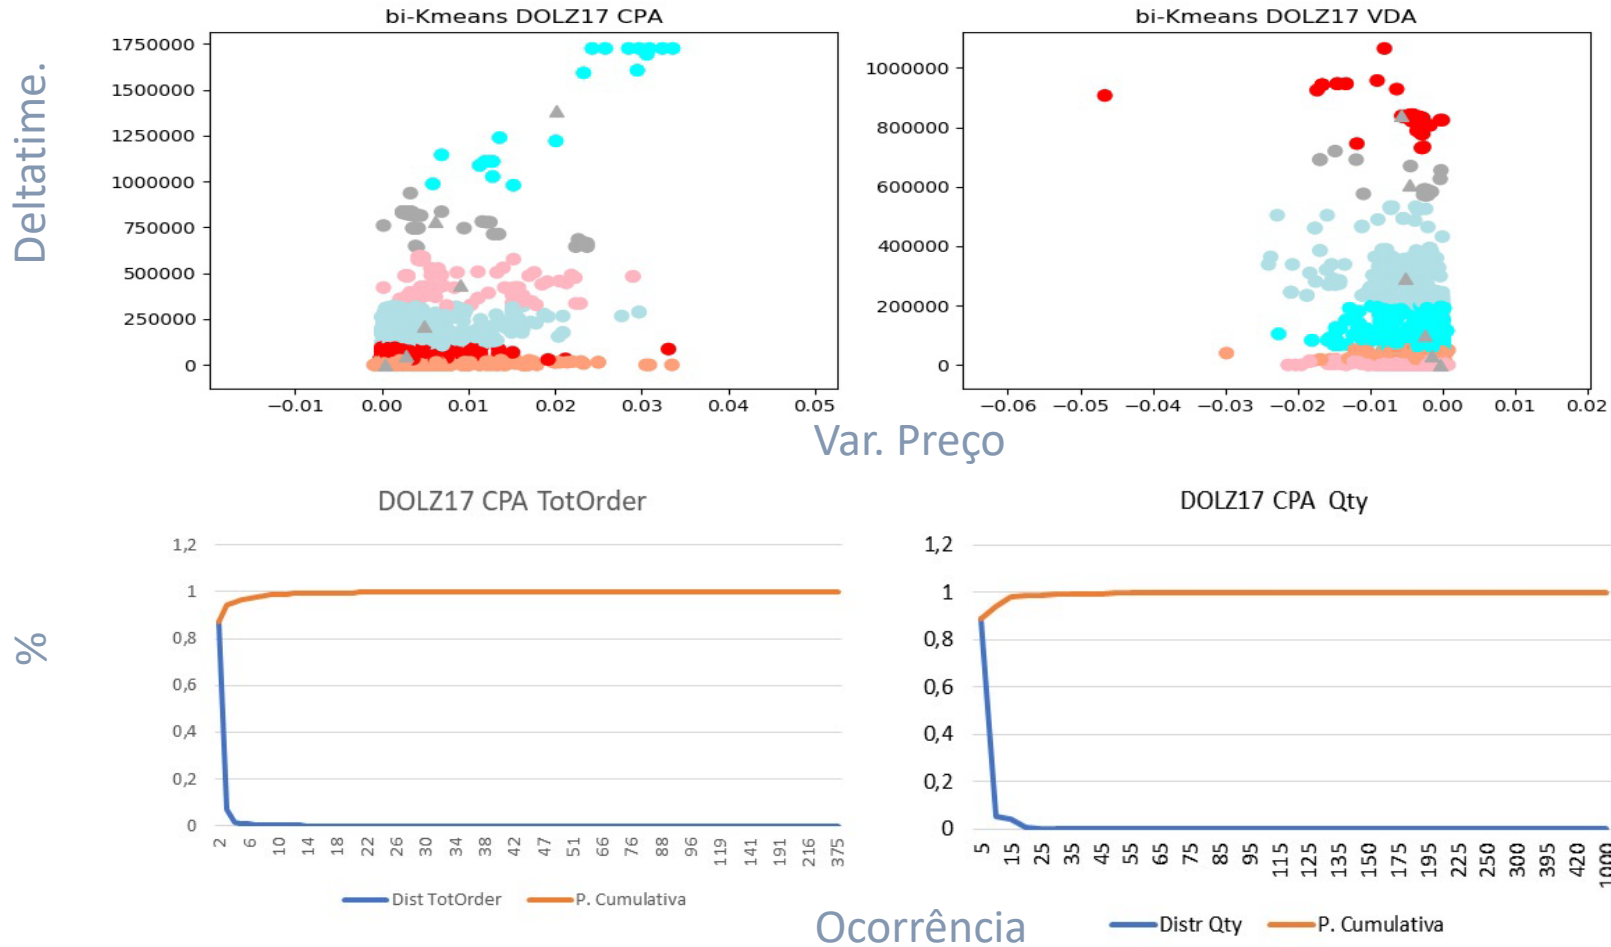
Resultados – DOLZ17



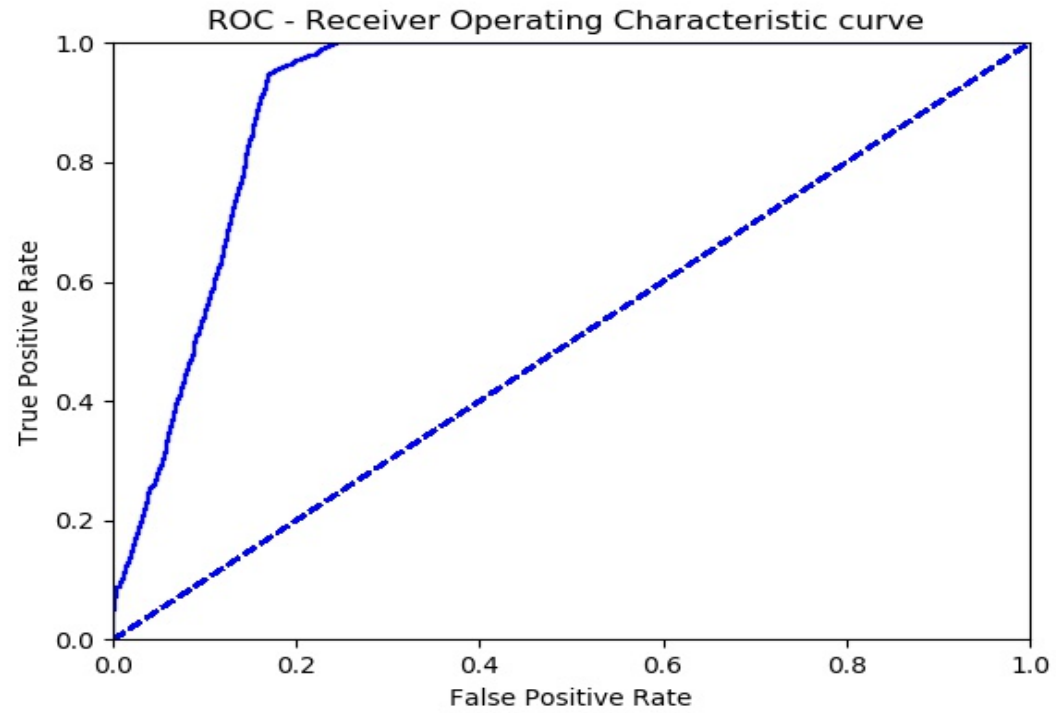
Resultados – DOLZ17



Resultados – DOLZ17



Resultados – DOLZ17



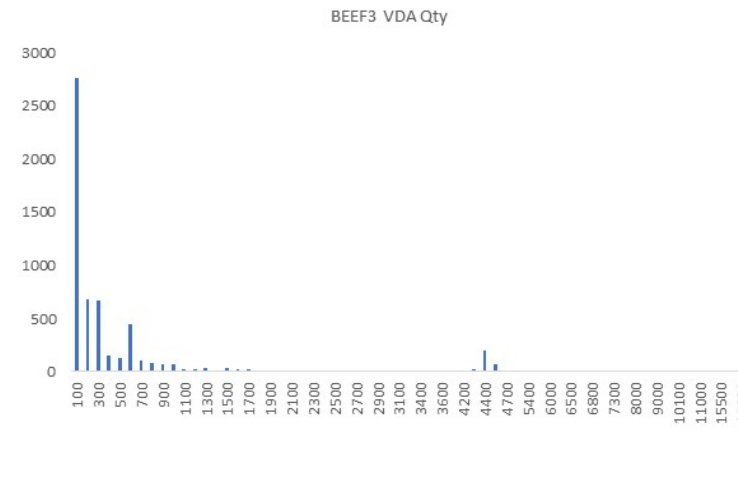



Resultados – DOLZ17

	exectype	numorder	sprice	price	qty	broker	deltatime	asprice	ostradeprice	fprice	cluster	apriori
caso A	1010.0	2.0	3275.0	3275.0	195.0	A	0.0	1.0	0.0002	3275.5	2.0	1.0
caso B	1010.0	2.0	3301.0	3301.0	500.0	B	41.0	1.0	0.0021	3308.0	2.0	1.0
caso C	1110.0	295.0	3271.0	3332.5	5.0	C	24.0	1.0	0.0004	3334.0	2.0	1.0
caso D	1110.0	375.0	3270.5	3273.0	5.0	D	1.0	1.0	0.0002	3273.5	2.0	1.0




Resultados – BEEF3

Minerva Foods


Resultados – BEEF3



Resultados – BEEF3





Var. Preço



Ocorrência

Resultados – BEEF3



Resultados – BEEF3

	exectype	numorder	sprice	price	qty	broker	deltatime	asprice	ostradeprice	fprice	cluster	apriori
caso A	1010.0	2.0	11.43	11.43	4300.0	A	59.0	1.0	0.0104	11.55	1.0	1.0
caso B	1010.0	2.0	11.19	11.19	2400.0	A	0.0	1.0	0.0009	11.2	1.0	1.0
caso C	1010.0	2.0	11.1	11.1	4400.0	A	59.0	1.0	0.0116	11.23	1.0	1.0
caso D	1110.0	22.0	11.24	11.09	5000.0	B	59.0	1.0	0.0107	11.21	1.0	1.0

Conclusão

- A metodologia adotada, apresentou uma abordagem técnica utilizando algoritmos sem supervisão, trabalhando em conjunto com algoritmo supervisionado, de forma que algoritmos sem supervisão, identificando padrões atípicos a negociação, montassem uma base de aprendizado para que um algoritmo supervisionado identificasse padrões com agilidade de forma satisfatória. Observou-se que o método é sensível ao volume de dados da amostra de atualização das ordens de cada instrumento.
- Os resultados obtidos neste estudo, apesar de apresentarem ordens com um comportamento muito diferenciado em relação ao book de cada ativo, não refletem investigações formais de conhecimento público para comprovar a veracidade das manipulações, porém estes resultados podem contribuir para que órgãos reguladores ou mesmo participantes do mercado acionário passem a utilizar estes dados como referencia para investigações futuras.
- A tratativa de métodos de manipulação por uma ferramenta, estimula os detratores a utilizar novos métodos e formas, de forma a burlar a identificação de tais operações, tornando a abordagem adotada desatualizada, por isso o acompanhamento por um humano deste processo é recomendável.
- A aplicação da Lei Dodd-Frank[13], escolhida como norte regulatório deste estudo técnico no Market data brasileiro, não há torna uma referência para todo e qualquer mercado, podendo esta metodologia se adaptar a outras regulações legais relacionadas ao mercado acionário

Trabalhos Futuros

- Implementar a solução consumindo os dados diretamente do feed Market data da Bolsa, através de um desenvolvimento do software mais otimizado.
- Avaliar a manipulação entre ativos diferentes, que possuem correlação muito forte.
- Determinar o tamanho ótimo das amostras dos datasets de cada instrumento.

Referências Bibliográficas

[1] Decision Support Systems; Computational intelligent hybrid model for detecting disruptive trading activity, Zhai, Jiz ; Cao, Yi ; Ding, Xuemei, Ding ; Yuhua, Li ; ELSIVIER ; Journal

[2] BLOOMBERG, Bloomberg do Brasil, 2017 em : <https://www.bloomberg.com/news/articles/2017-05-03/exchanges-still-dreaming-of-deals-after-lse-deutsche-boerse-dies> - Two Market Giants Tried to Create a \$75 Billion Mega-Exchange, Matthew Leising, 3 de maio de 2017 06:00 BRT Updated on 3 de maio de 2017 11:29 BRT. Acesso em : 13/05/2018

[3] B3, Market Data: Histórico Pessoas Físicas. Financeiro, São Paulo, 01/09/2017. Disponível em: http://www.bmfbovespa.com.br/pt_br/servicos/market-data/consultas/historico-pessoas-fisicas . Acesso em: 05/08/2018.

[4] VALOR, Valor Econômico, disponível em: <http://www.valor.com.br/valor-investe/casa-das-caldeiras/5058252/os-donos-da-bolsa>. Angela Bittencourt, 28/07/2017 às 11h19. Acesso em: 13/05/2018

[5] VALOR, Valor Econômico, disponível em: <http://www.valor.com.br/financas/3025114/bmfbovespa-inicia-migracao-de-negocios-com-acoes-para-plataforma-puma>, Vinicius Pinheiro 27/02/2013 às 14h53. Acesso em:13/05/2018.

[6]B3, PUMA Trading System BM&FBOVESPA, disponível em: http://www.bmfbovespa.com.br/pt_br/servicos/negociacao/puma-trading-system-bm-fbovespa/. Acesso em: 15/05/2018

[7]EXAME, disponível em: <https://exame.abril.com.br/mercados/bovespa-estreia-sistema-mais-rapido-que-1-milesimo-de-segundo/> - Bovespa estreia sistema mais rápido que 1 milésimo de segundo, Marcel Salim, 24/08/2011 às 22h56. Acesso em 13/05/2018.

[8]ESMA, European Securities and Markets Authority, <https://www.esma.europa.eu/about-esma/who-we-are>, ESMA. Acesso em 13/05/2018

[9]ESMA, MIFID II disponível em: <https://www.esma.europa.eu/policy-rules/mifid-ii-and-mifir>, ESMA. Acesso 13/05/2018

[10]BSM, Instrução CVM 8, <http://www.cvm.gov.br/legislacao/instrucoes/inst008.html>, CVM. Acesso 13/05/2018.

Referências Bibliográficas

- [11] SEC, US Securities And Exchange Commission, <https://www.sec.gov/answers/about-lawsshtml.html#secexact1934>, The Laws That Govern the Securities Industry Securities Exchange Act of 1934
- [12] CFTC, Antidisruptive Practices Authority No. 3038-AD96, Commodity Exchange Act Release, May 20, 2013.
- [13] Dodd-Frank Wall Street Reform and Consumer Protection Act § 753 (Anti-Manipulation Authority) 7 U.S.C. § 9.1 (2016).
- [14] INVESTOPEDIA, <https://www.investopedia.com/terms/d/dodd-frank-financial-regulatory-reform-bill.asp>, Dodd-Frank Wall Street Reform and Consumer Protection Act, Acesso em 13/05/2018.0
- [15] Montgomery, John, Spoofing, Market Manipulation, and the Limit-Order Book, May 3, 2016, Navigant
- [16] Hafiz, Kosemani Temitayo, Aghili, Dr. Shaun, Zavorsky, Dr. Pavol ; The use of Predictive Analytics Technology to Detect Credit Card Fraud in Canada, Department of Information Systems Security and Assurance management. Concordia University of Edmonton ; Edmonton, Canada
- [17] Sun, Xiao-Qian ; Shen, Hua-Wei ; Cheng, Xue-Qi ; Zhang, Yuqing ; Detecting anomalous traders using multi-slice network analysis ; ELSEVIER ; Journal
- [18] F. Allen, D. Gale, Stock-price manipulation, Rev. Financ. Stud. 5 (3) (1992) 503–529.
- [19] R.A. Jarrow, Market manipulation, bubbles, corners, and short squeezes, J. Financ. Quant. Anal. 27 (03) (1992) 311–336.
- [20] X. Sun, X. Cheng, H. Shen, Z. Wang, Statistical properties of trading activity in Chinese stock market, Phys. Procedia 3 (5) (2010) 1699–1706.
- [21] R.A. Jarrow, Market manipulation, bubbles, corners, and short squeezes, J. Financ. Quant. Anal. 27 (03) (1992) 311–336.
- [22] G.K. Palshikar, A. Bahulkar, Fuzzy temporal patterns for analysing stock market databases, in: Proceedings of the International Conference on Advances in Datamanagement, (COMAD), Tata-McGraw Hill, Pune, India, 2000, pp. 135–142.
- [23] X.-Q. Sun, X.-Q. Cheng, H.-W. Shen, Z.-Y. Wang, Distinguishing manipulated stocks via trading network analysis, Physica A 390 (20) (2011) 3427–3434.

Referências Bibliográficas

- [24] X.-Q. Sun, H.-W. Shen, X.-Q. Cheng, Z.-Y. Wang, Degree-strength correlation reveals anomalous trading behavior, PLoS One 7 (10) (2012) e45598.
- [25] H. Öğüt, M.M. Doganay, R. Aktas, Detecting stock-price manipulation in an emerging market: The case of turkey, Expert Syst. Appl. 36 (9) (2009) 11944–11949.
- [26] Leangarun, Teema ; Tangamchit Poj ; Thachayapong, Suttipong ; Stock Price Manipulation Detection using a computational Neural Network Model, 2016
- [27] Fonooni, Benjamin ; Moghadam, S. J. Mousavi ; Applying induced Aggregation Operator in Designing Intelligent Monitoring System for Financial Market.
- [28] Ai, Xiao-Wei ; Hu, Tianming ; Li, Xi ; Xiong, Hui ; Clustering High-frequency Stock Data for Trading Volatility Analysis ; 2010 ; Ninth International Conference on Machine Learning and Applications.
- [29] Tsantekidis, Avraam; Passalis; Nikolaos; Tefas, Anastasios; Kannianen, Juho ; Gabbou, Moncef; Iosifidis, Alexandros ; Forecasting Stock prices from limit order book using Convolutional neural networks.
- [30] D.J. Cumming, F. Zhan, M.J. Aitken, High frequency trading and end-of-day price dislocation, October 28, 2013 Retrieved from Social Science Research Network, http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2145565.
- [31] F. Allen, D. Gale, Stock price manipulation, The Review of Financial Studies 5 (3) (1992) 503–529.
- [32] Y. Cao, Li, Coleman, Belatreche, McGinnity, Detecting wash trade in financial market using digraphs and dynamic programming, IEEE Transactions on Neural Networks and Learning Systems (2015), <http://dx.doi.org/10.1109/TNNLS.2015.2480959>.
- [33] Y. Cao, Y. Li, S. Coleman, A. Belatreche, M. McGinnity, Adaptive hidden Markov model with anomaly states for price manipulation detection
- [34] R. Ghazali, A.J. Hussain, N.M. Nawawi, B. Mohamad, Non-stationary and stationary prediction of financial time series using dynamic ridge polynomial neural network, Neurocomputing 72 (10–12) (2009) 2359–2367.

Referências Bibliográficas

- [35] KELLER, John D. ; NAMEE, Brian Mac ; ARCY, Aoife D' ; Fundamentals of Machine Learning for Predictive Data Analytics Algorithms, Worked Examples and case studies. MIT Press, Cambridge Massachusetts
- [36] Equity Market Structure Literature Review, Part II High Frequency Trading by Staff of the Division of Trading and Markets, 03/18/2014, Staff of U.S. Securities and Exchange Commission.
- [37] CME, Rule 575, August 2014 Retrieved from U.S. Commodity Futures Trading Commission, <http://www.cftc.gov/filings/orgrules/rule082814cmedcm001.pdf>.
- [38] Wang, X ; Wellman P. ; Michael, Spoofing the Limit Order Book : An Agent-Based Model ; Computer Science & Engineering, University of Michigan ; Michigan
- [39] E. Mart´inez-Miranda, P. McBurney, and M. Howard. ;Learning unfair trading: A market manipulation analysis from the reinforcement learning perspective. ; In IEEE International Conference on Evolving and Adaptive Intelligent Systems, pages 103–109, 2016.
- [40] Lee, J. Eun ; Eom, S. Kyong ; Park, K. Suh ; Microstructure-based manipulation : Strategic behavior and performance of spoofing traders ; ELSEVIER ; Journal of Financial Markets 16 (2013), pages 227-252 ; 2012
- [41] Market Data BMFBOVESPA : <ftp://ftp.bmf.com.br/MarketData/>, Origem dos Dados.
- [42] Harrington, Peter; Machine Learning in Action; Manning; Manning Publications Co.; United States, 2012
- [43] Yang Q., Fu Qunchao, Wang, Cong, Yang, J, A Matrix-Based Apriori Algorithm Improvement 2018 IEEE Third International Conference on Data Science in Cyberspace (DSC) (2018), Guangzhou, China. Jun 18, 2018 to Jun 21, 2018, ISBN: 978-1-5386-4210-8, <http://doi.ieeecomputersociety.org/10.1109/DSC.2018.00132>
- [44] Maximizing the Efficiency of Parallel Apriori Algorithm (2009) to ISSN: ISBN: pp: 107-109 DOI Bookmark: <http://doi.ieeecomputersociety.org/10.1109/ARTCom.2009.73> Ketan Shah Sunita Mahajan
- [45] Cohen, N., Data Mining: Nagging that it really adds up, 2000, URL http://www.open-mag.com/features/Vol_16/datamining/datamining.htm

Referências Bibliográficas

[46] Schapire, Robert E.; Freund, Yoav; Boosting Foundations and Algorithms; MIT Press; United States; 2014

[47] B3, http://www.b3.com.br/pt_br/solucoes/plataformas/puma-trading-system/para-desenvolvedores-e-vendors/entrypoint-entrada-de-ofertas/; EntryPoint; EntryPoint: Interface de Envio de Ordens - Regras - versão 2.9.5 (em Inglês); 28/12/2018

[48] Zhang, Jian; Public Governance and Corporate Fraud: Evidence from Recent Anti-corruption Campaign in China; Received: 1 September 2015 / Accepted: 12 January 2016 / Published online: 20 January 2016 Springer Science+Business Media Dordrecht 2016

Autores:
Prof. Dr. Nizam Omar
Mateus Saldanha

Mestrado em Engenharia Elétrica e Ciência da Computação

