



VILNIAUS UNIVERSITETAS
DUOMENŲ MOKSLO IR SKAITMENINIŲ
TECHNOLOGIJŲ INSTITUTAS

Didelio dažnio kompiuterizuotų prekybos strategijų inžinerija finansinėse rinkose

4 metų doktorantūros studijų ir mokslinių tyrimų ataskaita

Doktorantas: Mantas Vaitonis

Darbo vadovas: Doc. Dr. Saulius Masteika

2015 – 2017 m. m. išlaikyti egzaminai

Dalyko pavadinimas	Kreditų skaičius	Numatyta atsiskaitymo data	Įvykusio egzamino data	Įvertinimas
Informatikos ir informatikos inžinerijos tyrimo metodai ir metodika	9	2016-06-09	2016-06-09	7
Informacijos poreikių specifikavimas	7	2016-09-27	2016-09-27	9
Duomenų analizės strategijos ir sprendimų priėmimas	7	2016-12-05	2016-12-05	8
Žiniomis grindžiama kompiuterizuota informacijos sistemų inžinerija	7	2017-03-14	2017-03-14	9

Dalyvavimas konferencijose 2015 – 2019 m. m.

1. **2015-12-03 – 2015-12-05 7-oje mokslinėje konferencijoje DAMSS 2015 „Duomenų analizės metodai programų sistemoms“**, Druskininkuose, pristatytas stendinis pranešimas „High frequency statistical arbitrage strategy engineering and algorithm for pairs trading selection“.
2. **2016-10-13 – 2016-10-15 ICIST 2016 22-oje „Tarptautinėje informacijos ir programų technologijų konferencijoje“**, Druskininkuose, skaitytas pranešimas „Research in high frequency trading and pairs selection algorithm with Baltic region stocks“.
3. **2016-12-01 – 2016-12-03 8-oje mokslinėje konferencijoje DAMSS 2016 „Duomenų analizės metodai programų sistemoms“**, Druskininkuose, pristatytas stendinis pranešimas „Computerized high frequency trading of nanoseconds in futures market“.
4. **2017-10-12 – 2017-10-14 ICIST 2017 ICIST 2017 Druskininkai 23-oje „Tarptautinėje informacijos ir programų technologijų konferencijoje“**, Druskininkuose, skaitytas pranešimas „Statistical Arbitrage Trading Strategy in Commodity Futures Market with the Use of Nanoseconds Historical Data“.
5. **2017-11-30 – 2017-12-02 9-oje mokslinėje konferencijoje DAMSS 2017 „Duomenų analizės metodai programų sistemoms“**, Druskininkuose, skaitytas pranešimas „Research in High Frequency Statistical Arbitrage Strategies Applied to Microsecond and Nanosecond Information“.
6. **2018-04-27 IVUS 2018 23-oje tarptautinėje mokslinėje konferencijoje „Information Society and University Studies“**, skaitytas pranešimas „CPU and GPU Implementations for High Frequency Trading in Algorithmic Finance“.
7. **2018-05-29 SYSTEM 2018 23-oje tarptautinėje mokslinėje konferencijoje „Information Society and University Studies“**, skaitytas pranešimas „Algorithmic trading and machine learning based on GPU“.

Publikacijos 2015 – 2019 m. m


1. Masteika S., Vaitonis M., Quantitative Research in High Frequency Trading for Natural Gas Futures Market, Business Information Systems Workshops, Springer International Publishing, Vol. 228,p. 29-35, 2015 m.
2. Vaitonis M., Masteika S. (2016). High frequency statistical arbitrage strategy engineering and algorithm for pairs trading selection. 7th International Workshop on Data Analysis Methods for Software Systems [abstracts book], Druskininkai, Lithuania, December 3-5, 2015. ISBN 978-9986-680-58-1. p. 51.
3. Vaitonis M., Masteika S. (2016). Research in high frequency trading and pairs selection algorithm with Baltic region stocks. Information and Software Technologies. 22nd International Conference, ICIST 2016, Druskininkai, Lithuania, October 13-15, 2016, Proceedings. ISBN 978-3-319-46254-7, p.p. 208 – 217.
4. **Vaitonis M., (2017). Pairs Trading Using HFT in OMX Baltic Market. *Baltic J. Modern Computing*, Vol. 5(2017), No. 1, 37-49**
5. Vaitonis M., Masteika S. (2017) „Statistical Arbitrage Trading Strategy in Commodity Futures Market with the Use of Nanoseconds Historical Data“,Information and Software Technologies: 23rd International Conference, ICIST 2017, Druskininkai, Lithuania, October 12–14, 2017, Proceedings. R. Damaševičius and V. Mikašytė (Eds.): ICIST 2017, CCIS 756, pp. 303–313, ISBN 978-3-319-67642-5
6. **Vaitonis M., Masteika S. (2018). Experimental Comparison of HFT Pair Trading Strategies using Microsecond and Nanosecond Future Commodity Contracts Data. *Baltic J. Modern Computing*, Vol. 6(2018), No. 2, 195-216, ISSN 2255-8950**

Pedagoginė praktika

Studijų metai	Studijų modulis	Studijų pakopa, kursas	Valandos		
			Paskaitų	Pratybų	Iš viso
2016	Finansinių rinkų analizė	VI(F)3	1		1
2017	XML inžinerija	VI, VI(FI)3	32	16	48
2017	Kompiuterių architektūra	ISKS7	32	16	48

Tyrimo objektas


- Šio darbo tyrimo objektas – didelio dažnio statistinio arbitražo algoritminės prekybos sistemos ir didelio dažnio duomenys elektroninėse finansų biržose.



Source: AFM

Tyrimo objektas

- Nors nuomonės apie HFT vis dar skiriasi, galima daryti išvadą, kad HFT suteikia likvidumo ir vidutiniškai pagerina rinkos kokybę, padarydama akivaizdesnį teigiamą poveikį didelio kapitalo akcijoms. Teigiama, kad atsižvelgiant į ribotus empirinius duomenis, kuriais gali naudotis akademiniai tyrėjai, atsakymai į klausimus apie optimalią HFT konfigūraciją, HFT ekonominius nuopelnus ir HFT elgesio reguliavimą toli gražu nėra galutiniai. (Khaloun Khashanah, Ionut Florescu, Steve Yang, High – frequency trading: a white paper, The Investor Responsibility Research Center Institute 2016)



Didelio dažnio prekyba

- Didelio dažnio prekybos sistemos
- Greičiausių elektroninių rinkų atsakymo laikas ~ 100 nanosekundžių
- Elektroninės rinkos gali sukurti virš milijono pranešimų per sekundę.
- CME elektroninė biržai reikia apdoroti ~5 mln. įrašų per sekundę vienai ateities sandorių grupei.
- Piko metu per vieną sekundę gali būti perduodama ~98.18 Mbps duomenų.

Tyrimo tikslas

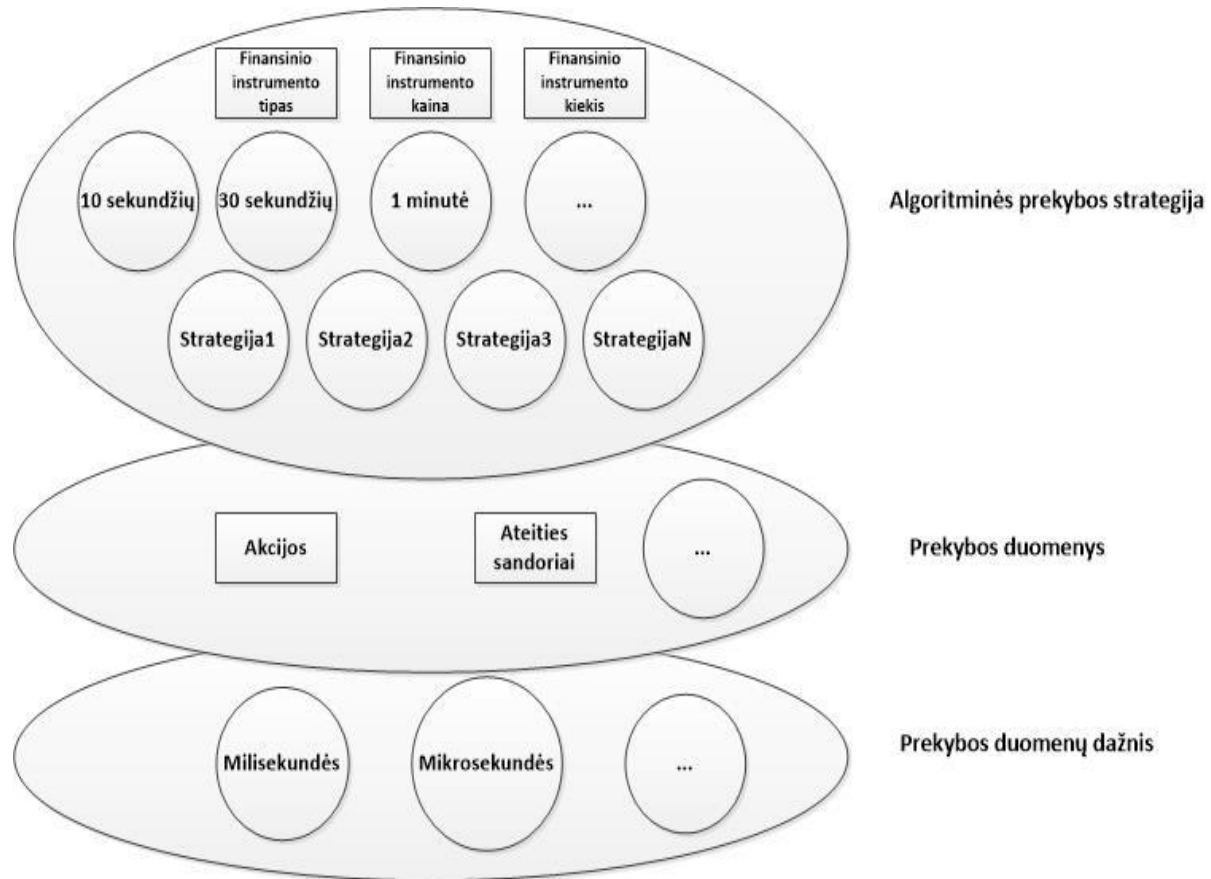
- Šio darbo tikslas – sukurti didelio dažnio statistinio arbitražo prekybos algoritmą ir didelio dažnio duomenų elektroninėse finansų biržose apdorojimo metodą, leidžiančius duomenis apdoroti greičiau, nei jie gaunami iš elektroninės biržos.

Tyrimo uždaviniai

Darbo tikslui pasiekti išsikelti šie uždaviniai:

1. Apžvelgti esamas didelio dažnio algoritmines strategijas, didelio dažnio duomenų apdorojimo metodus ir technologijas ir pritaikyti juos šio darbo tikslui pasiekti.
2. Sukurti didelio dažnio duomenimis paremtą statistinio arbitražo prekybos algoritmą, kuris dirbtų su didelio dažnio tick-by-tick duomenimis, siekiant apdoroti gautus didelio dažnio duomenis greičiau, nei jie atkeliauja iš elektroninės biržos.
3. Pritaikyti sukurtą metodą ir sukurti didelio dažnio statistinio arbitražo prekybos algoritmo prototipą, leidžiantį apdoroti didelio dažnio ir apimties duomenis, gautus iš elektroninių biržų.
4. Aprašyti gautus rezultatus ir pastebėjimus, įvertinti sukurtą didelio dažnio statistinio arbitražo prekybos algoritmo prototipą ir pasirinktą duomenų apdorojimo metodo kūrimo technologiją.

Tyrimo problema

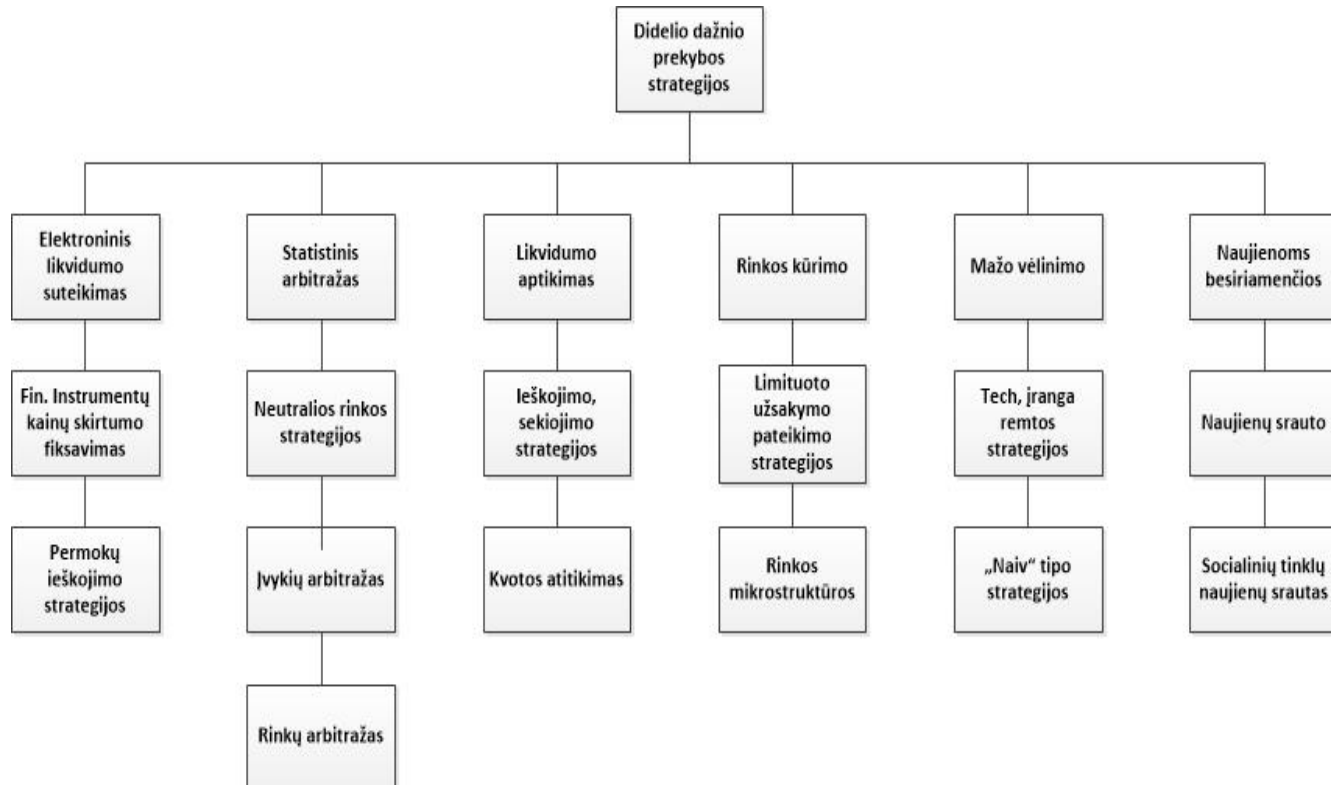


Ginamieji teiginiai

Disertacijoje keliami šie ginamieji teiginiai:

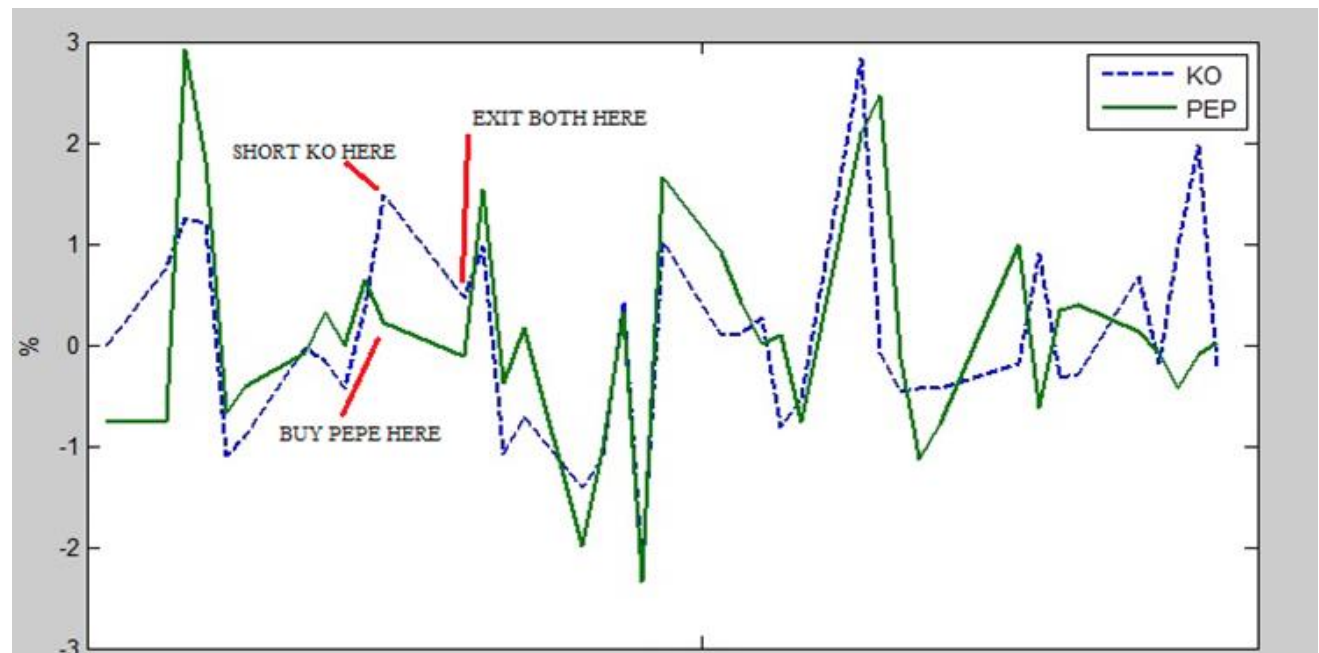
1. Šiame darbe nustatytas būdas apdoroti didelio dažnio ir apimties elektroninės biržos duomenis ir juos pritaikyti didelio dažnio statistinio arbitražo prekyboje pasitelkiant GPU ir CUDA technologijas, kuriomis naudojantis galima tiksliau ir greičiau priimti prekybos sprendimus aplenkiant informaciją, keliaujančią iš elektroninių biržų.
2. Darbe pasiūlytas metodas padeda apdoroti didelio dažnio ir apimties duomenis pasitelkiant lygiagrečius skaičiavimus, daugiamates matricas, GPU CUDA technologiją. Pasitelkiant tas pačias technologijas perkeliama ir didelio dažnio prekybos sistema, kuri atlieka duomenų analizę ir priima prekybos sprendimus GPU CUDA plokštėje, prekybos sprendimo informacija yra siunčiama iš GPU į CPU ir atitinkamai priimti prekybos sprendimai iš CPU gali būti siunčiami į elektronines biržas.
3. Darbe pasiūlytu metodu ir pasinaudojus GPU CUDA technologiniu sprendimu atlikto tyrimo duomenų apdorojimo ir skaičiavimų rezultatai įrodo, kad DDP gali būti efektyvi finansų rinkose, suteikti rinkoms likvidumą ir padidinti finansų rinkų dalyvių prekybos galimybes.

Didelio dažnio prekybos strategijos



Atlikti tyrimai: didelio dažnio statistinio arbitražo prekyba

- Buvo patikrinta ar didesnio dažnio duomenys yra efektyvesni t. y. ar nanosekundiniai duomenys suteikia daugiau informacijos ir to pagalba didelio dažnio statistinio arbitražo strategijos yra efektyvesnės, nei naudojant milisekundinius duomenis.



Porų prekybos strategijų metodologija

- Prekybos ir duomenų normalizavimo lango dydžio parinkimas;
- Duomenų normalizavimas;
- Koreliuotų porų parinkimas;
- Prekybos signalų nustatymas;
- Prekyba;
- Prekybos strategijų efektyvumo nustatymas.

Duomenys naudoti tyrimui

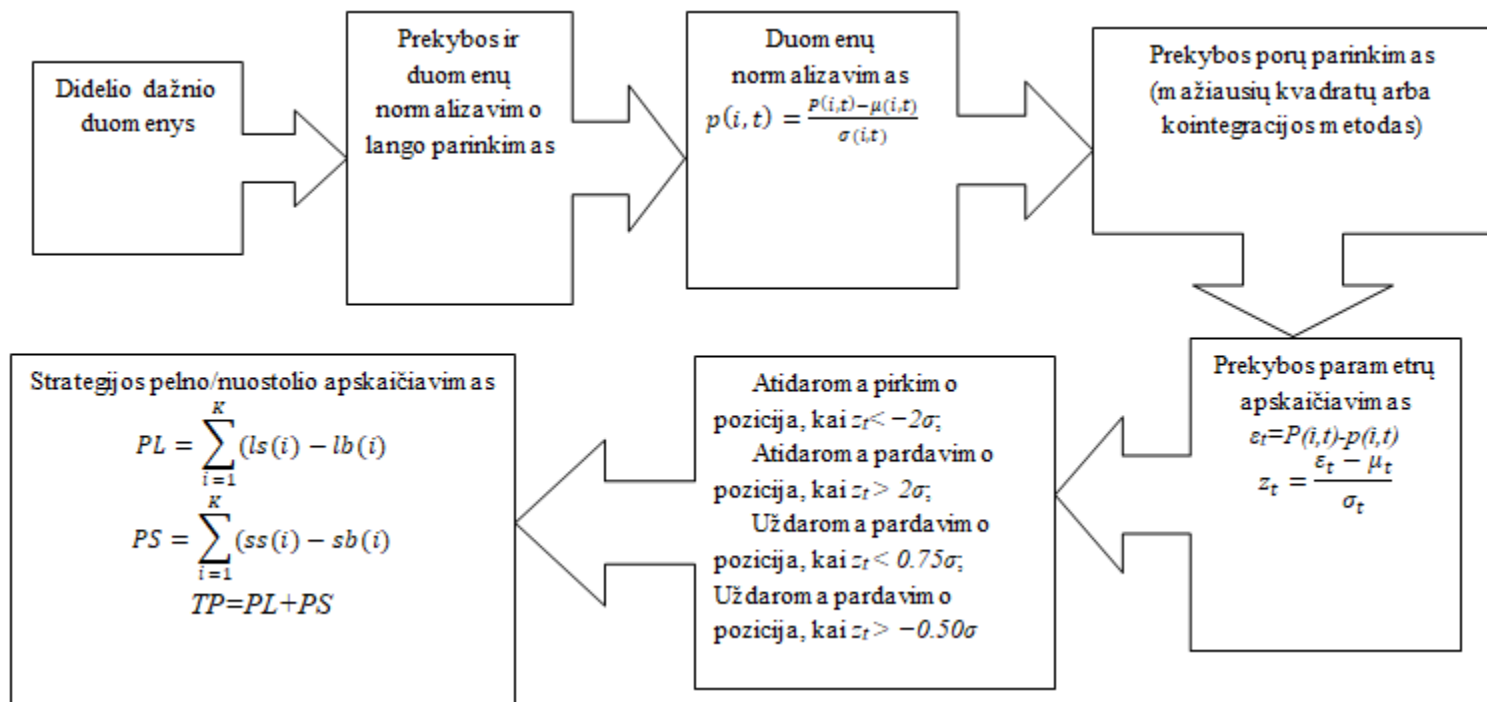
- NANOTICK pateikė milisekundinius ir nanosekundinius duomenis apie 5 ateities sandorius (NG, BZ, CL, HO, RB)
- Duomenys pateikti laikotarpiu nuo 2015-08-01 iki 2015-08-31. Po normalizacijos milisekundiniai duomenys susidėjo iš 24957994 duomenų eilučių ir nanosekundiniai iš 287872500.

AMG1L	APG1L	CTS1L	GRD1R	GZE1R	KNF1L	SFG1T	TVEAT	LDJ1L	LES1L	OEG1T	OLF1R	ITAL1T	TEQ1L	Date	Time
0.927	2.770	1.720	6.950	9.400	0.411	1.120	13.900	0.680	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:53:58.640
0.927	2.770	1.720	6.950	9.400	0.411	1.120	13.900	0.680	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:53:58.670
0.927	2.770	1.720	6.950	9.400	0.411	1.120	13.900	0.680	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:54:17.437
0.927	2.770	1.720	6.950	9.400	0.411	1.120	13.900	0.680	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:54:17.450
0.927	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:54:17.513
0.927	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.000	1.920	6.100	0.840	1.050	2015-03-04	15:54:17.530
0.927	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.010	1.920	6.100	0.840	1.050	2015-03-04	15:56:49.607
0.927	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.010	1.920	6.100	0.840	1.050	2015-03-04	15:56:49.733
0.927	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.010	1.920	6.100	0.840	1.050	2015-03-04	15:59:12.607
0.925	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.010	1.920	6.100	0.840	1.050	2015-03-04	15:59:16.310
0.925	2.740	1.730	6.950	9.400	0.400	1.120	14.100	0.710	1.010	1.920	6.100	0.841	1.050	2015-03-04	15:59:16.343

Naudotos strategijos

- Perlin, M. **Evaluation of Pairs Trading Strategy at Brazilian Financial Market.** Journal of Derivatives & Hedge Funds. 2009, Volume 15.
- Caldeira J. F., Moura G. V. **Selection of a portfolio of pairs based on cointegration: A statistical arbitrage strategy.** Revista Brasileira de Financas. 2013, Volume 11, No. 1.
- Herlemont D. **Pairs Trading, Convergence Trading, Cointegration.** Quantitative Finance. 2013, Volume 12, No. 9.

Didelio dažnio statistinio arbitražo prekybos algoritmai



Rezultatai

	M. S. Perlini	D. Herlemont	Caldeira ir Moura
Pelnas su nanosekundėmis	8,74%	19,27%	29,11%
Iš viso sandorių	9878627	5869860	18051372
Pelnas su milisekundėmis	4,01%	3,39%	4,75%
Iš viso sandorių	1491576	2135360	2538979

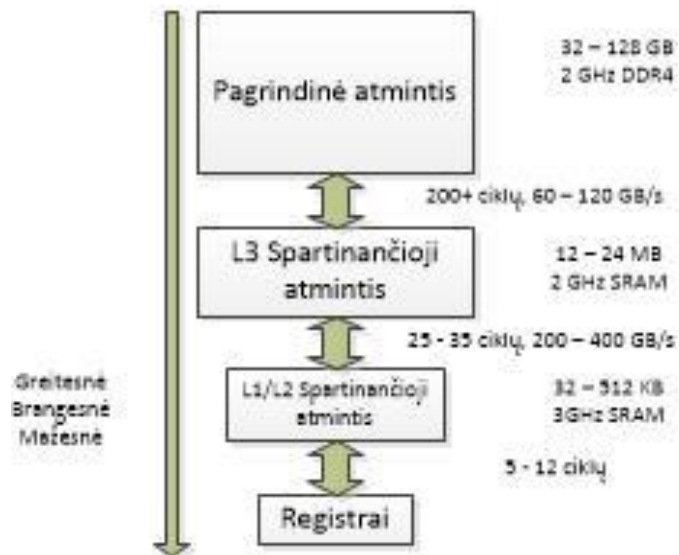
Rezultatai

	M. S. Perlini strategijos Šarpo rodiklis	D. Herlemont strategijos Šarpo rodiklis	Caldeira and Moura strategijos Šarpo rodiklis
Naudojant milisekundes	1,3380	1,4240	1,7651
Naudojant nanosekundes	1,3144	2,6388	2,0442

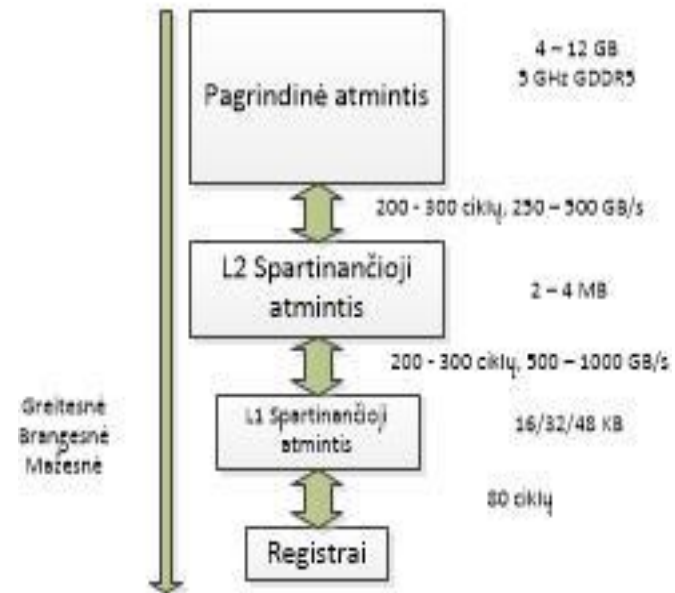
Gavus šiuos rezultatus, toliau atlikti tyrimai ieškant būdo, atlikti prekybos sprendimus greičiau, nei nauja informacija atkeliauja apie finansinį instrumentą iš elektroninės biržos.

CPU ir GPU atminties hierarchija

CPU Atminties hierarchija



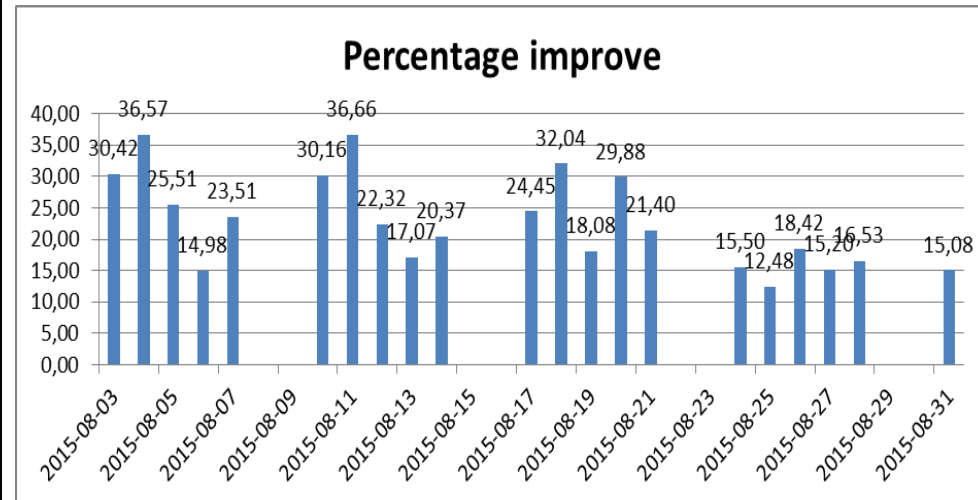
GPU Atminties hierarchija



CPU ir GPU palyginimas

Data	Intel i5 - 3230M 2,6 GHz, 2 cores (sekundėmis)	GeForce 710m, 96 CUDA Cores (sekundėmis)	Apdorotų duomenų skaičius
2015-08-03	2991,80	2081,60	6096505
2015-08-04	2208,10	1400,50	4579465
2015-08-05	2393,70	1783,10	5793525
2015-08-06	3040,90	2585,3	5595770
2015-08-07	2650,10	2027,1	5586360
2015-08-10	4410,80	3080,70	5732355
2015-08-11	4980,30	3154,50	6249980
2015-08-12	2769,20	2151,20	6758875
2015-08-13	4122,60	3419,00	5666900
2015-08-14	1325,90	1055,80	4227335
2015-08-17	1550,00	1171,10	4879990
2015-08-18	1912,10	1299,50	4364540
2015-08-19	4002,30	3278,70	5666700
2015-08-20	4449,00	3119,43	5411145
2015-08-21	4311,70	3389,10	5946205
2015-08-24	4809,40	4064,00	7710745
2015-08-25	3960,20	3466,10	5105175
2015-08-26	3187,60	2600,40	5119660
2015-08-27	5004,90	4244,20	7963320
2015-08-28	5287,10	4413,10	7721975
2015-08-31	5409,70	4594,10	8613445

Šio tyrimo metu naudotas CPU buvo Intel i5 - 3230M 2,6 GHz su 2 branduoliais ir naudotas GPU GeForce 710M su 96 CUDA branduoliais



Toliau tyrime naudotas GPU Nvidia GTX – 1060 6GB, 1280 CUDA branduoliais.

CPU ir GPU palyginimas naudojant vektorizuotą metodą

M. S. Perlini			D. Herlemont			J. Caldeira and G. V. Moura		
Nevektorizuotas CPU	Nevektorizuotas GPU	Vektorizuotas GPU	Nevektorizuotas CPU	Nevektorizuotas GPU	Vektorizuotas GPU	Nevektorizuotas CPU	Nevektorizuotas GPU	Vektorizuotas GPU
3082,01	2212,58	7,56	2991,80	2234,69	7,06	3188,30	2175,46	7,13
2312,21	1866,77	5,92	2208,10	1625,87	5,52	2300,20	1836,70	5,55
2548,00	2275,70	7,41	2393,70	2033,04	6,80	2577,20	2238,40	6,87
3157,23	1980,72	7,02	3040,90	1796,88	6,51	3025,80	1741,62	6,56
2757,20	2020,74	7,01	2650,10	1617,00	6,67	2736,30	2010,04	6,75
4930,11	1723,71	7,12	4410,80	2397,89	6,72	4850,30	2409,41	6,79
5182,32	2513,59	7,58	4980,30	2833,62	7,22	5144,90	2215,78	7,22
2900,12	2174,64	8,21	2769,20	2007,54	7,68	2837,10	2075,58	7,73
4211,10	2082,78	7,08	4122,60	2287,30	6,55	4222,80	2591,05	6,65
1398,00	1208,22	5,52	1325,90	1204,28	5,24	1483,00	1284,10	5,21
1602,56	1491,32	6,21	1550,00	1342,17	5,87	1597,30	1333,63	5,86
2102,70	1455,73	5,66	1912,10	1695,52	5,33	2074,60	1570,07	5,40
4179,40	1633,95	6,92	4002,30	1620,07	6,61	4154,70	1495,48	6,63
4982,20	2130,43	6,65	4449,00	1948,76	6,41	4591,40	2098,70	6,42
4591,80	1883,19	7,26	4311,70	2111,37	7,22	4421,70	1941,67	6,89
5080,60	3185,21	9,07	4809,40	3193,18	8,61	4982,50	3306,48	8,74
4229,10	1810,58	6,44	3960,20	2200,31	5,94	4074,30	2154,72	6,06
3377,20	2266,08	6,38	3187,60	2564,24	6,03	3269,70	2261,87	6,05
5305,40	3110,35	9,42	5004,90	3494,92	8,87	5238,00	3089,66	9,09
5698,10	3186,38	9,07	5287,10	3642,83	8,59	5534,70	3769,10	8,71
5671,80	3835,31	10,08	5409,70	3033,25	9,51	5583,40	3617,43	9,64

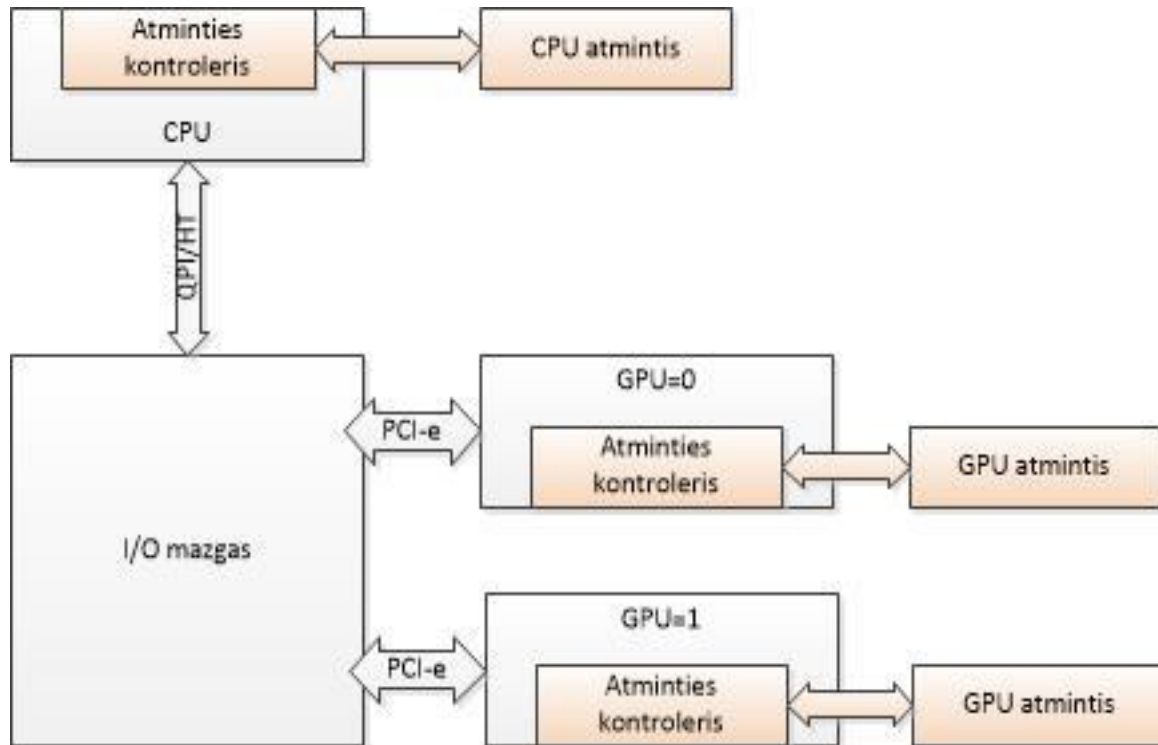
CPU ir GPU palyginimas naudojant vektorizuotą metodą

- Naudotas GPU Nvidia GTX – 1060 6GB, 1280 CUDA branduoliais.
- Naudotas CPU Xeon E5-2650 su 8 branduoliais ir 20 MB spartinančiąja atmintimi.
- Procentinis pagreitėjimas nevektorizuoto algoritmo kodo CPU į GPU nuo 10% iki 60%
- Procentinis pragreitėjimas iš nevektorizuoto algoritmo kodo GPU į vektorizuotą GPU siekia apie 99%.

Tyrimas naudojant GPU

- GPU galima naudoti skaičiavimams „gilyn“, kaip atliktame tyrime GPU naudojamas apskaičiuoti kiekvienos strategijos pelningumą atskirai su istoriniais duomenimis.
- GPU galima naudoti skaičiavimas „į plotį“ pasitelkiant paralelizmą, kuris naudojamas tolimesniame tyrime, atlikti daug skaičiavimų vienu metu, realiu laiku milieskundiniu ar nanosekundiniu greičiu.

CPU-GPU sistemos architektūra



Reikalavimai tyrimo įgyvendinimui

- Siūlomas statistinio arbitražo didelio dažnio prekybos algoritmas turi kelias dalis, kurias galima skaičiuoti lygiagrečiai perkėlus jį į GPU. Galimybė padidinti šio algoritmo našumą priklauso nuo paties algoritmo ir jo kodo, bei nuo techninės įrangos, kurioje jis veikia. Šio tyrimo metu naudotis dvi grafinės plokštės: NVIDIA GeForce GTX 1060 6GB ir NVIDIA GeForce GTX 1070 Ti 8GB.

Reikalavimai tyrimo įgyvendinimui

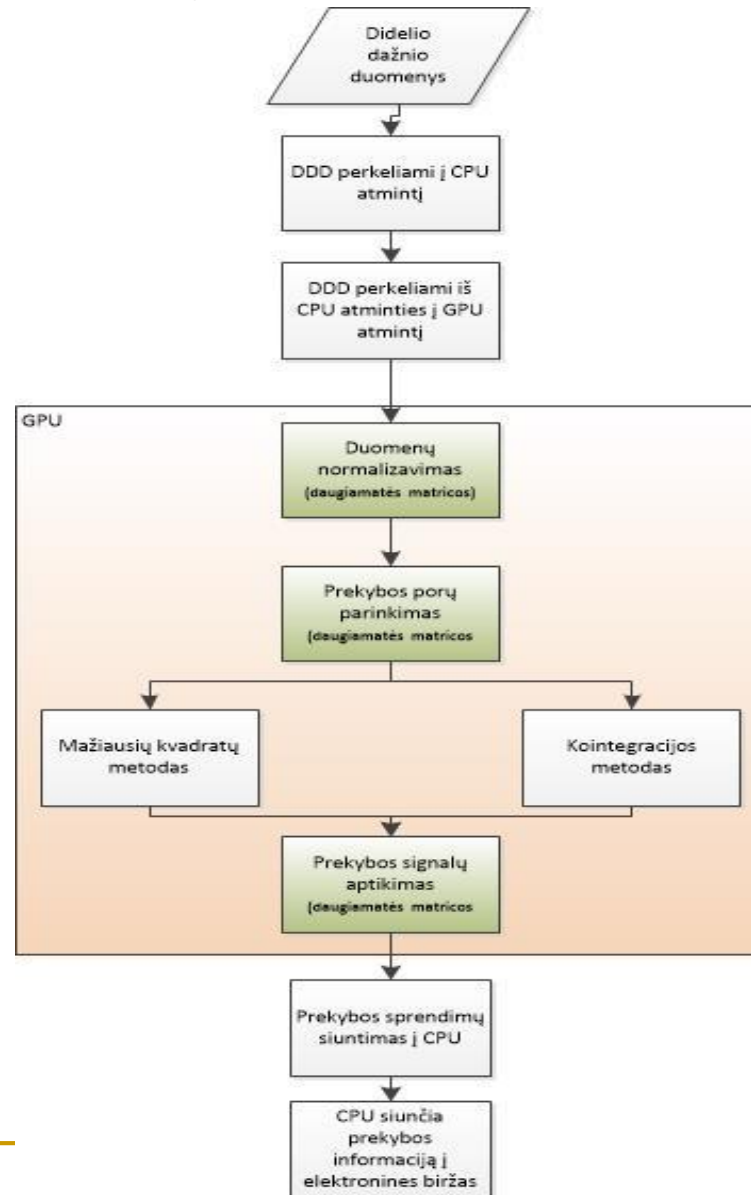
- Tyrimo metu naudojama 130 skirtingų ateities sandorių *tick-by-tick* duomenys, kurie yra pateikti 100 nanosekundžių tikslumu NANOTICK kompanijos, kur nauja informacija vidutiniškai atkeliauja kas 0,000322683 sekundės, šiuos duomenis sudaro ateities sandoriai kurie susideda iš ME grupės, kuriai priklauso NYMEX, COMEX ir CBOT. Laikotarpis, kurio metu simuliuojama prekyba su naudojamo didelio dažnio algoritmu, yra nuo 2018-04-30 iki 2018-08-03, o tai yra 69 prekybos dienos.

Reikalavimai tyrimo įgyvendinimui

Vidutiniškai kiekviena prekybos diena turėjo 536909612 duomenų 130 ateities sandorių.

Data	Laikas	ID	Simbolis	Fin. instrumentas	Grupė	Tipas	Kaina
20180604	16:45:00.024776853	15144	GE:PS M1-M2	GE	GE	A	0,75
20180604	16:45:00.024794969	15144	GE:PS M1-M2	GE	GE	A	0,5
20180604	16:45:00.024810037	15144	GE:PS M1-M2	GE	GE	A	0,25
20180604	16:45:00.024827526	15144	GE:PS M1-M2	GE	GE	A	0,25
20180604	16:45:00.024827526	15144	GE:PS M1-M2	GE	GE	B	0,25

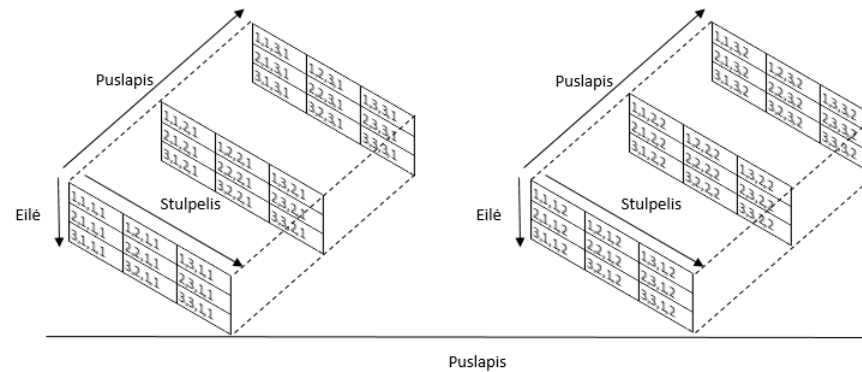
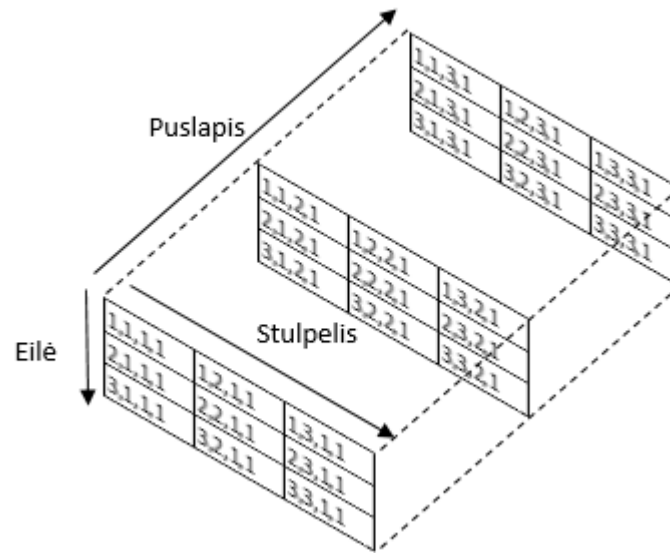
Tyrimo metodas



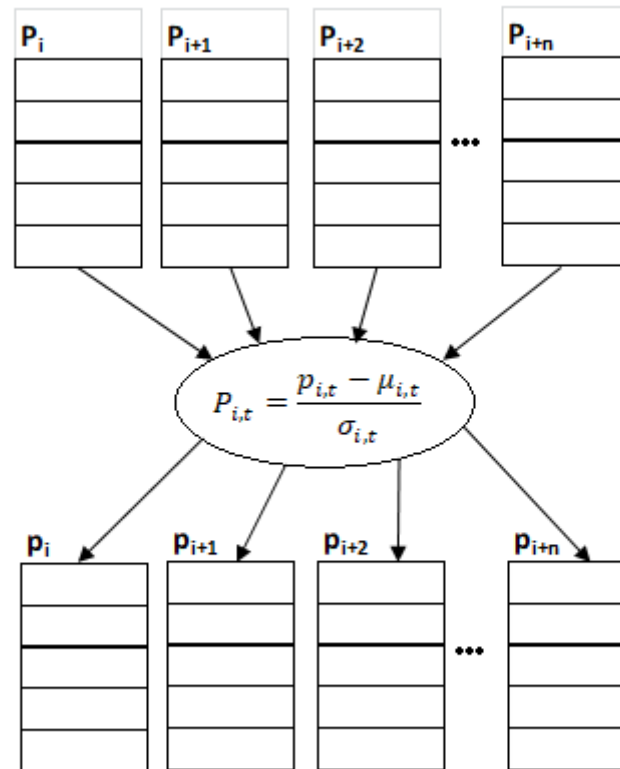
Tyrimo metodas

- Galima paralelizuoti duomenų normalizavimą. Šioje didelio dažnio prekybos sistemos dalyje vidurkis ir standartinis nuokrypis yra skaičiuojamas visiems 130 ateities sandorių. Tai lėmė, kad buvo galima iš viso paralelizuoti 16900 skaičiavimų. Kita algoritmo dalis, kur galima taikyti lygiagrečius skaičiavimus yra prekybos porų paieška. Norint rasti, kiek yra galimų porų, visi ateities sandoriai turi būti lyginami vienas su kitu. Todėl iš viso yra $n(n-1)$ galimų prekybos porų ir šiame tyrime jų gali būti 16770. Tyrime galima naudoti vieną iš pasirinktų arba abu porų parinkimų metodus vienu metu, dėl šios priežasties gali būti iš viso $16770*2=33400$ galimų porų variantų apskaičiuoti lygiagrečiai. Toliau yra naudojami trijų statistinio arbitražo strategijų prekybos signalų aptikimo metodai ir galima naudoti vieną, du ar visus tris metodus lygiagrečiai. Galiausiai naudojant visus tris metodus yra $33400*3*2*1=200400$ galimų lygiagrečių skaičiavimų. Viską susumavus, šiame tyrime maksimaliai buvo galima lygiagrečiai atlikti 217300 skaičiavimus.

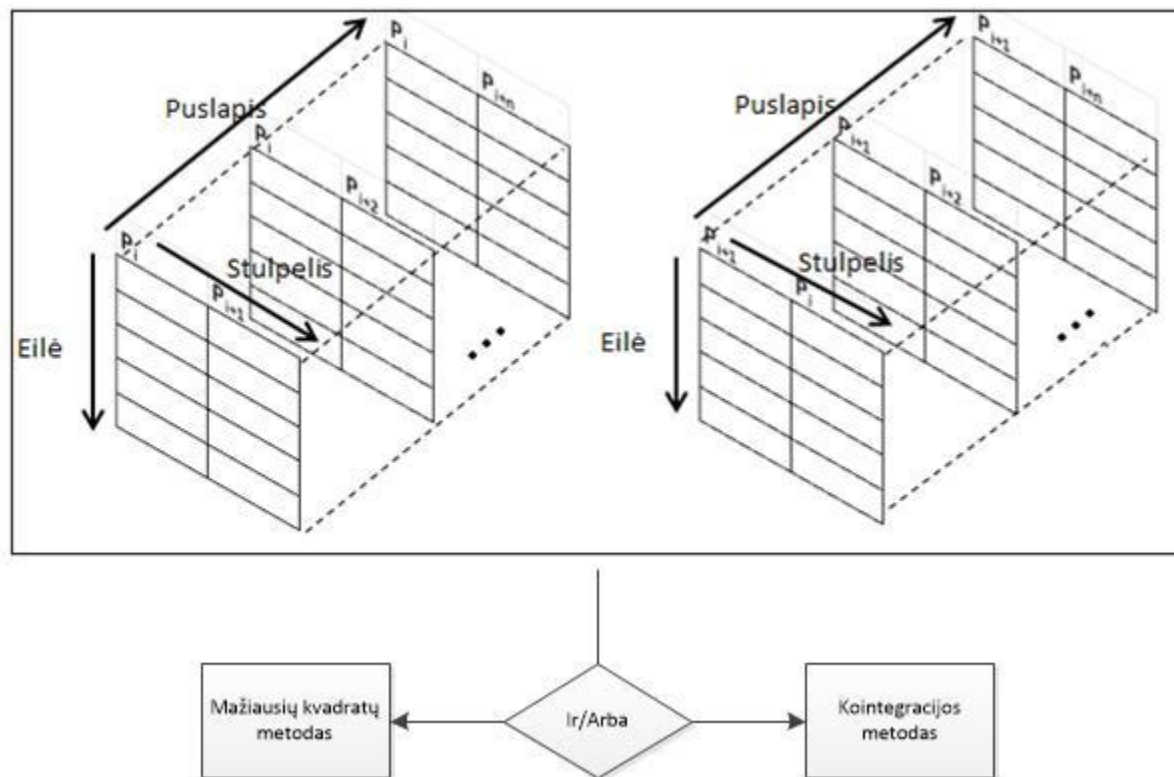
3D ir 4D masyvai




Didelio dažnio duomenų normalizavimas



Didelio dažnio duomenų konvertavimas į 3D GPU masyvą ir perdavimas į pasirinktą porų prekybos strategiją



3D GPU masyvas su pasirinktomis ateities sandorių poroms perduodamas prekybos signalų parinkimui



Mažiausių kvadratų ar kointegracijos metodas prekybos porų parinkimui

- Vidutinis atsakymo laikas kiekvieną prekybos dieną naudojant mažiausių kvadratų atstumo ir kointegracijos metodus prekybos porų parinkimui


Data	Kointegracijos metodas	Mažiausių kvadratų metodas
2018.04.30	0,0034562	0,000009446
2018.05.01	0,004118	0,000003017
2018.05.02	0,0025312	0,000022312
2018.05.03	0,0038186	0,000003018
2018.05.04	0,0072642	0,000008264
2018.05.05	0	0
2018.05.06	0	0
2018.05.07	0,0053142	0,0000067142
2018.05.08	0,0068887	0,0000088587
2018.05.09	0,0083038	0,0000080938
2018.05.10	0,0073156	0,0000080156
2018.05.11	0,0057107	0,0000040101

Rezultatai

Abiejų porų parinkimo metodų pelno Šarpo rodiklis			
Porų parinkimo metodas	Vidurkis	Standartinis nuokrypis	Šarpo rodiklis
Mažiausių kvadratų metodas	2060,55	2039,217237	1,010461819
Kointegracijos metodas	951,514	1332,581485	0,714038351

Rezultatai

- Duomenų eilučių kiekis kiekvieną prekybos dieną




Rezultatai

Data	Vid. Atsakymo laikas	Data	Vid. Atsakymo laikas	Data	Vid. Atsakymo laikas	Data	Vid. Atsakymo laikas
2018-04-30	0,000024462	2018-05-24	0,000038678	2018-06-17	0	2018-07-11	0,000034147
2018-05-01	0,00003017	2018-05-25	0,000035423	2018-06-18	0,000032476	2018-07-12	0,000061415
2018-05-02	0,000022312	2018-05-26	0	2018-06-19	0,00003683	2018-07-13	0,000048985
2018-05-03	0,000030186	2018-05-27	0	2018-06-20	0,000036387	2018-07-14	0
2018-05-04	0,000082642	2018-05-28	0,00002539	2018-06-21	0,000037368	2018-07-15	0
2018-05-05	0	2018-05-29	0,00003944	2018-06-22	0,000030742	2018-07-16	0,000027459
2018-05-06	0	2018-05-30	0,000039225	2018-06-23	0	2018-07-17	0,000057754
2018-05-07	0,000067142	2018-05-31	0,000029806	2018-06-24	0	2018-07-18	0,000031432
2018-05-08	0,000088587	2018-06-01	0,000066666	2018-06-25	0,000033835	2018-07-19	0,000087509
2018-05-09	0,000080938	2018-06-02	0	2018-06-26	0,000051361	2018-07-20	0,000091102
2018-05-10	0,000080156	2018-06-03	0	2018-06-27	0,000054207	2018-07-21	0
2018-05-11	0,000040107	2018-06-04	0,000028535	2018-06-28	0,000093594	2018-07-22	0
2018-05-12	0	2018-06-05	0,000034473	2018-06-29	0,000084256	2018-07-23	0,000092927
2018-05-13	0	2018-06-06	0,000032577	2018-06-30	0	2018-07-24	0,000046558
2018-05-14	0,000040107	2018-06-07	0,000033356	2018-07-01	0	2018-07-25	0,000030627
2018-05-15	0,000042817	2018-06-08	0,000036191	2018-07-02	0,000082269	2018-07-26	0,000071994
2018-05-16	0,000044323	2018-06-09	0	2018-07-03	0,000069462	2018-07-27	0,000030083
2018-05-17	0,000047552	2018-06-10	0	2018-07-04	0,000025665	2018-07-28	0
2018-05-18	0,000040972	2018-06-11	0,000033909	2018-07-05	0,00008235	2018-07-29	0
2018-05-19	0	2018-06-12	0,000032737	2018-07-06	0,000077866	2018-07-30	0,000032189
2018-05-20	0	2018-06-13	0,000034487	2018-07-07	0	2018-07-31	0,000030102
2018-05-21	0,000041618	2018-06-14	0,000033861	2018-07-08	0	2018-08-01	0,000061255
2018-05-22	0,000042161	2018-06-15	0,000036434	2018-07-09	0,000043309	2018-08-02	0,000075291
2018-05-23	0,000038858	2018-06-16	0	2018-07-10	0,000057039	2018-08-03	0,000074165

Rezultatai

- Didelio dažnio statistinio arbitražo strategijos vidutinis atsakymo laikas ir duomenų eilučių skaičius nurodytą prekybos dieną



Išvados

- Išanalizavus didelio dažnio prekybą ir peržiūrėjus galimus būdus, kaip pasiekti užsibrėžtą tikslą, buvo prieita išvada, kad literatūroje nėra aprašyta, kaip taikyti didelio dažnio statistinio arbitražo prekybos strategijas realioje aplinkoje, kaip jas testuoti ir kokie metodai naudojami įgyvendinant šį sprendimą. Pagrindinis DDP strategijų tikslas yra aplenkti kitus rinkos dalyvius priimant ir pateikiant prekybos sprendimus greičiau nei kiti, reaguojant į rinkos pasikeitimus greičiausiu galimu būdu. Pateikto sprendimo išskirtinė savybė yra būdas, kaip yra aprašytas pats prekybos algoritmas, ir tai, kaip jis išnaudoja turimą techninę įrangą.

Išvados

- Atliekant didelio dažnio statistinio arbitražo dienos prekybos strategijų analizę buvo nustatyta, kad keturias šio prekybos algoritmo dalis galima perkelti į lygiagrečius skaičiavimus pasitelkiant GPU. Šias keturias dalis sudaro: ateities sandorių kainų normalizavimas, prekybos porų parinkimas, prekybos signalų aptikimas ir prekybos pozicijų pateikimas bei uždarymas. Aprašytas dienos prekybos algoritmo kodas buvo pakeistas perkeliant šiuos skaičiavimus į MATLAB aplinką, kurioje jie vykdomi lygiagrečiai. Tai pasiekama vektorizuojant turimą algoritmo kodą, pasitelkiant daugiamačius masyvus ir integruotas MATLAB GPU funkcijas – `arrayfun`, `bsxfun`, `pagefun`, `gpuarray` ir kitas.

Išvados

- Tyrimo pabaigoje buvo įrodyta, jog naudojant GPU su CUDA bei pasitelkiant jos globalią atmintį kartu su daugiamačiais masyvais ir vektorizuojant kodą, ir skaičiavimus vykdant lygiagrečiai pasitelkiant GPU branduolius stipriai sumažėja skaičiavimų greitis. Pasiūlytas metodas ne tik greičiau apdoroja duomenis, bet gali apdoroti ir 26 kartus daugiau duomenų bei priimti prekybos sprendimus dešimt kartų greičiau palyginti su metodu, netaikančiu daugiamačių masyvų, kurio rezultatas dabar buvo lygus 0,0000071111 sekundės. Visos trys naudotos statistinio arbitražo prekybos strategijos su mažiausių kvadratų atstumo prekybos porų parinkimo metodu galėjo išanalizuoti elektroninės biržos duomenis ir priimti prekybos sprendimus greičiai, nei nauji duomenys buvo gaunami iš tos pačios elektroninės biržos (kurių greitis buvo lygus 0,000322683 sekundės).

Išvados

- Pasiūlytas DDP statistinio arbitražo prekybos strategijos metodas, kuris naudoja GPU su CUDA pasitelkdamas vektorizuotą kodą su daugiamačiais masyvais, vykdant skaičiavimus GPU branduoliuose lygiagrečiai, geba greičiau atlikti skaičiavimus, nei kiti sprendimai, kurie naudoja tik CPU arba CPU su GPU, bet be daugiamačių masyvų.

Ačiū už dėmesį