


Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Санкт-Петербургский государственный университет» (СПбГУ)

№ договора ЕД-127143/Ф от 25.04.2023

СОГЛАСОВАНО

Председатель научной комиссии



УТВЕРЖДАЮ
Проректор по научной работе
С.В. Микушев

« » 20__ г.

ОТЧЕТ
О НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЕ, выполненной
в соответствии с техническим заданием по договору
№ ЕД-127143/Ф от 25.04.2023

по теме проекта
«МОДЕЛИРОВАНИЕ ОБМЕНА КРИПТОВАЛЮТЫ»

Руководитель проекта



А.А. Скроботов

Исполнитель



А.В. Семенов

Санкт-Петербург
2023

СОСТАВНАЯ ЧАСТЬ НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЫ ПРОЕКТА «МОДЕЛИРОВАНИЕ ОБМЕНА КРИПТОВАЛЮТЫ»

Цель данной работы - оценить различия по качеству мультиагентного моделирования криптовалютного рынка с применением классических агентов и моделью, где добавлен самообучающийся агент. Задача также заключается в выборе архитектуры модели, и подбора гиперпараметров для нее таким образом, чтобы она генерировала данные рынка, наиболее похожие на реальные.

Этапы работы включают:

1. Применение передовых алгоритмов машинного обучения для моделирования финансовых рынков, в частности рынка криптовалют.
2. Введение агента с самообучающейся стратегией с использованием алгоритмов обучения с подкреплением, а именно глубокого детерминированного градиента политики (DDPG).
3. Разработка мультиагентной модели со следующими стратегиями для оценки основных статистических показателей рынка (стилизованными фактами).
4. Проведение сравнительного анализа результатов для построенной модели с результатами ранее предложенных моделей, а также с характеристиками реального рынка.
5. Обобщение результатов и построение вывода о том, что модель с самообучающимся агентом дает лучшее приближение к реальному рынку, чем модель с классическими агентами.

Содержание

Аннотация.....	4
1 Введение	4
2 Стилизованные факты	5
3 Имитационная модель	6
4 Результаты	6
5 Заключение	8
6 Список литературы	8

Аннотация

В исследовании рассматривается подход к применению современных алгоритмов машинного обучения для моделирования некоторых финансовых рынков. В данном случае мы выбираем рынок криптовалют, исходя из предположения, что такие рынки более активны в настоящее время. Как правило, они имеют большую волатильность, что привлекает более рискованных трейдеров. Помимо классических торговых стратегий, вводится агент со стратегией самообучения. Для моделирования поведения такого агента используются алгоритмы глубокого обучения с подкреплением, а именно градиент глубокой детерминированной политики (DDPG). Далее разрабатывается агентная модель со следующими стратегиями. С помощью этой модели можно оценить основную рыночную статистику, названную стилизованными фактами. Наконец, проводится сравнительный анализ результатов построенной модели с результатами ранее предложенных моделей, а также с характеристиками реального рынка. В результате получен вывод, что предложенная модель с самообучающимся агентом дает лучшее приближение к реальному рынку, чем модель с классическими агентами. В частности, в отличие от модели с классическими агентами, модель с самообучающимся агентом оказывается не такой уж тяжеловесной. Таким образом, показано, что для полного понимания рыночных процессов имитационные модели должны учитывать самообучающиеся агенты, имеющие значительное присутствие на современных фондовых рынках.

1 Введение

Актуальность изучения симуляций криптовалютного рынка не вызывает сомнений. Криптовалюта на данный момент является перспективным направлением в финансовой сфере. Организация новых биржевых площадок и стремительный рост объемов торгов на них подталкивает к изучению криптовалют. Очень важной задачей может быть моделирование криптобиржи с типами агентов, используемых при моделировании обычных рынков. Моделирование позволяет понять не только эмпирическую природу самого рынка, но и научиться получать соответствующие данные для тестирования наших собственных стратегий.

Капитализация мирового рынка криптовалют сегодня составляет 1,18 триллиона долларов. За последние 2 года объем капитализации вырос на 13,72%. Для электронных трейдеров на криптовалютных биржах по оценочным меркам она составляет около 86%. Это более чем на 20% выше, чем на классических рынках.

Принимая во внимание данные, упомянутые выше, считается, что применение такого подхода к криптовалютным рынкам может быть весьма полезным.

Существует множество подходов к моделированию поведения рынка. Ключевые из них — дискретно-событийный и агентный подходы, которые используются в данной работе.

Было разработано пять типов агентов-трейдеров, совместное взаимодействие которых должно имитировать процесс обмена. К ним относятся агент-трейдер маркет-мейкера, трейдер-потребитель ликвидности, трейдер-возврат к среднему и импульсный агент-трейдер. Все эти модели имеют логику, характерную для стратегий трейдеров каждого типа. В дополнение к этим агентам были добавлены шум-трейдеры, которые должны были имитировать неконтролируемые шумы, и самообучающийся агент, развивающийся на алгоритме обучения с подкреплением, основанном на политиках — DDPG (Глубокий детерминированный политический градиент). Задача этого агента — попытаться описать всех трейдеров, которые торгуют на бирже по стратегиям с самообучающимися алгоритмами.

Основная цель исследования — оценить разницу в качестве моделирования рынка между моделью с классическими агентами и моделью, в которую добавлен самообучающийся агент. Также стоит задача подобрать модель и гиперпараметры для нее, чтобы она генерировала рыночные данные максимально похожие на реальные.

2 Стилизованные факты

Под стилизованными фактами понимается набор статистических данных, которые помогают оценить различные показатели для данных временных рядов. Этот набор статистики позволяет достаточно качественно описать поведение всего рынка в целом. В исследовании используются стилизованные факты для достижения двух целей. Во-первых, с их помощью можно сравнивать разные рынки друг с другом. Итак, будут сравниваться классический рынок, рынок криптовалют, а также агентская симуляция рынка без обучающего агента и вместе с ним соответственно. Во-вторых, используется функция ошибок, основанная на различиях в статистике стилизованных фактов. С ее помощью подбираются оптимальные параметры имитационной модели агента, чтобы она наилучшим образом моделировала нужный нам рынок. В исследовании рассматриваются такие статистические данные, как значение распределения доходности с толстым хвостом, значение автокорреляции доходности, значения графика Q-Q, построение графика ECDF и оценка Хилла.

3 Имитационная модель

Во взятой за основу биржевой модели за основу были взяты минутные данные о котировках биткойна на платформе Bitfinex.

Использовался многоагентный подход, предложенный С. Oesch, как основа реализации. Основная идея метода состоит в том, чтобы представить каждый класс агентов как репрезентативных агентов в рамках текущей модели. Таким образом, всего в модели шесть типов агентов, каждый из которых имеет свою стратегию. Такой подход позволяет избежать реализации большого набора агентов со схожими стратегиями и параметрами принятия решений, но не влияет на отслеживаемые в модели статистические показатели. В исследовании описаны допустимые случаи использования репрезентативных агентов в рамках построения мультиагентных систем. Изучив содержание, можно сделать вывод, что использование репрезентативных агентов приемлемо для целей исследования. Это позволяет значительно сократить использование вычислительных ресурсов, что в дальнейшем позволит лучше обучать модель.

4 Результаты

После проведения экспериментов были получены статистические результаты. Общие результаты позволяют сделать вывод, что подход с агентом DDPG лучше в рыночном приближении. Также с помощью этих агентов в модели получается больше ликвидности и волатильности обмена. Но и этот обмен имеет значительно меньшую автокорреляцию любого порядка.

1. Распределение доходов с толстыми хвостами

Таблица 1

результаты	mean	median	min	max
Базовая модель	45.221	44.288	36.912	63.001
Модель с DDPG-агентом	40.51	37.264	27.227	58.267
Реальные данные	26.264	22.355	12.272	45.118

2. Автокорреляция доходности

Таблица 2 Lags of autocorrelation function

результаты	1-й лаг	max	min
Базовая модель	0.0294	0.1925	0.0024
Модель с DDPG-агентом	0.0097	0.081	0.0006
Реальные данные	0.0122	0.0875	0.0256

3. Автокорреляция квадратов доходности

Таблица 3

результаты	1-й лаг	max	min
Базовая модель	0.0068	0.0871	-0.0004
Модель с DDPG-агентом	0.0036	0.0548	-0.0001
Реальные данные	0.0002	0.0334	-0.0001

4. График ECDF




Рис. 1 Эмпирическая кумулятивная функция распределения (ECDF) с логарифмическим масштабированием по вертикальной оси. На графиках сплошной линией показаны хвосты эмпирического распределения доходности. Пунктирный график показывает значения нормального распределения с аналогичным средним значением и дисперсией. На этих графиках хорошо видно асимптотическое поведение хвостов и их тяжесть относительно нормального распределения.

5. Оценка Хилла




Рис. 2 Сравнение коэффициентов Хилла с порядковой статистикой. Как видно из сравнительного анализа, оценки Хилла для обычной модели имеют большую плотность распределения.

5 Заключение

В рамках исследования вводятся агенты для модельного подхода, который вместо этого был основан на подходе с новой оценкой алгоритмов. Основной мотивацией внедрения этого агента является предположение о распространенности на современном рынке агентов производства типовых моделей. Ключевой вклад исследования заключается в том, чтобы проверить гипотезу об обоснованности включения агентов типов в современных Агентных моделях. Обучая стандартную модель на фьючерсных данных SP500, сообщается, что включение агентов DDPG улучшает большую часть статистики модели.




Рис. 3 10%, 5% и 2,5% оценка Хилла для каждой модели. Модели: модель по умолчанию, модель с агентом DDPG, реальные данные фьючерсного индекса S&P 500.

Результат продемонстрирован на рынке криптовалют, на бирже биткойнов значения с биржи Binance. Дальнейшие исследования могут быть направлены на изучение более общее применение таких моделей к рынкам криптовалют.

6 Список литературы

1. Kirill Mansurov, A.S.A.R.R.I. Dmitry Grigoriev: Impact of self-learning based high-frequency traders on the stock market 33 (2022). <https://doi.org/10.1609/aaai.v33i01.33014213>
2. Siyun He, R.I.: Predictability of cryptocurrency returns: evidence from robust tests 20 (2022). <https://doi.org/10.1515/demo-2022-0111>
3. Linda Ponta, S.C.: Traders' networks of interactions and structural properties of financial markets: An agent-based approach. Complexity 9 (2018) <https://doi.org/10.1155/2018/9072948>. <https://doi.org/10.1155/2018/9072948>
4. E Samanidou, D.S. E Zschischang, Lux, T.: Agent-based models of financial markets. Reports on Progress in Physics 40 (2007). <https://doi.org/10.1088/0034-4885/70/3/R03>
5. Serban, A.F.: Combining mean reversion and momentum trading strategies in foreign exchange markets. Journal of Banking Finance 34, 2720–2727 (2010). <https://doi.org/10.1016/j.jbankfin.2010.05.011>
6. Balvers, R.J., Wu, Y.: Momentum and mean reversion across national equity markets. Journal of Empirical Finance 13(1), 24–48 (2006). <https://doi.org/10.1016/j.jempfin.2005.05.001>

7. Shihui Li, X.C.H.D.F.F.S.R. Yi Wu: Robust multi-agent reinforcement learning via minimax deep deterministic policy gradient 33 (2019).
<https://doi.org/10.1609/aaai.v33i01.33014213>
8. Oesch, C.: An agent-based model for market impact. In: 2014 IEEE Conference on Computational Intelligence for Financial Engineering Economics (CIFEr), pp. 17–24 (2014). <https://doi.org/10.1109/CIFEr.2014.6924049>
9. McGroarty, F., Booth, A., Gerding, E.e.a.: High frequency trading strategies, market fragility and price spikes: an agent based model perspective. *Annals of Operations Research* 282, 217–244 (2019). <https://doi.org/10.1007/s10479-018-3019-4>
10. Eric M. Aldrich, K.L.V.: Experiments in high-frequency trading: comparing two market institutions. *Experimental Economics* 23, 322–352 (2019).
<https://doi.org/10.1007/s10683-019-09605-2>
11. Grilli, R., Tedeschi, G.: Modeling financial markets in an agent-based framework, 103–155 (2016). <https://doi.org/10.1007/978-3-319-44058-33>
12. Charles Packer, J.K.P.K.V.K.D.S. Katelyn Gao: Assessing generalization in deep reinforcement learning 17 (2019). <https://doi.org/10.48550/arXiv.1810.12282>
13. Sharma, J., Andersen, P.-A., Granmo, O.-C., Goodwin, M.: Deep qlearning with q-matrix transfer learning for novel fire evacuation environment. *IEEE Transactions on Systems, Man, and Cybernetics: Systems* 51(12), 7363–7381 (2021).
<https://doi.org/10.1109/TSMC.2020.2967936>
14. Lillicrap, T.P., Hunt, J.J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D.: Continuous control with deep reinforcement learning. *arXiv:1509.02971* (2015). <https://doi.org/10.48550/ARXIV.1509.02971>
15. Appel, G., Dobson, E.: Understanding MACD vol. 34. Traders Press, ??? (2007)
16. Aguirre, A.A.A., Medina, R.A.R., M'endez, N.D.D.: Machine learning applied in the stock market through the moving average convergence divergence (macd) indicator. *Investment Management & Financial Innovations* 17(4), 44 (2020)
17. Rosillo, R., De la Fuente, D., Brugos, J.A.L.: Technical analysis and the Springer Nature 2021 LATEX template Article Title 19 spanish stock exchange: testing the rsi, macd, momentum and stochastic rules using spanish market companies. *Applied Economics* 45(12), 1541–1550 (2013)
18. Tsang, W.W.H., Chong, T.T.L., et al.: Profitability of the on-balance volume indicator. *Economics Bulletin* 29(3), 2424–2431 (2009)
19. Cont, R.: Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance* 1(2), 223–236 (2001) <https://doi.org/10.1080/713665670>
<https://doi.org/10.1080/713665670>
20. Smith, E., Farmer, J.D., Gillemot, L., Krishnamurthy, S.: Statistical theory of the continuous double auction 3(6), 481–514 (2003). <https://doi.org/10.1088/1469-7688/3/6/307>
21. Marie, K., I, R.S.: The qq-estimator and heavy tails. *Communications in Statistics. Stochastic Models* 12, 366 (1996). <https://doi.org/10.1080/15326349608807407>
22. Hill, B.M.: A simple general approach to inference about the tail of the distribution. *The Annals of Statistics* 3(6), 1163–1174 (1975). <https://doi.org/10.1088/1469-7688/3/6/307>

23. Tim Bollerslev, K.F.K. Ray Y.Chou: Arch modeling in finance: A review of the theory and empirical evidence. *Journal of Econometrics* 52, 5–59 (1992).
[https://doi.org/10.1016/0304-4076\(92\)90064-X](https://doi.org/10.1016/0304-4076(92)90064-X)
24. Christofersen, P.: *Elements of Financial Risk Management*.
<https://doi.org/10.1016/B978-0-12-374448-7.00008-7>
25. Huber, J., Kleinlercher, D., Kirchler, M.: The impact of a financial transaction tax on stylized facts of price returns—evidence from the lab. *Journal of economic dynamics control* 36, 1248–1266 (2012). <https://doi.org/10.1016/j.jedc.2012.03.011>
26. Ro, su, I.: A Dynamic Model of the Limit Order Book. *The Review of Financial Studies* 22(11), 4601–4641 (2009)
<https://academic.oup.com/rfs/articlepdf/22/11/4601/24429168/hhp011.pdf>.
<https://doi.org/10.1093/rfs/hhp011>
27. Gal'an, J.M., Izquierdo, L.R., Izquierdo, S.S., Santos, J.I., del Olmo, R., L'opez-Paredes, A., Edmonds, B.: Errors and artefacts in agent-based modelling. *Journal of Artificial Societies and Social Simulation* 12(1), 1 (2009)
28. Plerou, V., Stanley, H.E.: Stock return distributions: Tests of scaling and Based on Springer Nature LATEX template 20 Article Title universality from three distinct stock markets. *Phys. Rev. E* 77, 037101 (2008).
<https://doi.org/10.1103/PhysRevE.77.037101>
29. Wagner, F.: Estimation of agent-based models: The case of an asymmetric herding model. *Computational Economics* 26 (2005). <https://doi.org/10.1007/s10614-005-6415-1>