

УДК 004.8:004.832

Жвакина Анна Васильевна, к.т.н., доцент,
Белорусский государственный университет
информатики и радиоэлектроники
Zhvakina Anna Vasilyevna,
Candidate of Engineering Sciences, Associate Professor,
Belarusian State University of Informatics and Radioelectronics

Круговой Владислав Николаевич, магистрант,
Белорусский государственный университет
информатики и радиоэлектроники
Krugovoy Vladislav Nikolaevich, Master's Student,
Belarusian State University of Informatics and Radioelectronics

Сиротко Сергей Иванович, к.ф.м.н., доцент,
Белорусский государственный университет
информатики и радиоэлектроники
Sirotko Sergey Ivanovich,
Candidate of Physical and Mathematical Sciences, Associate Professor,
Belarusian State University of Informatics and Radioelectronics

**ГИБРИДНАЯ МОДЕЛЬ ИНТЕЛЛЕКТУАЛЬНОГО ПРОСТРАНСТВА И ЗАДАЧА
ПРОГНОЗИРОВАНИЯ ВОЛАТИЛЬНОСТИ ФИНАНСОВЫХ АКТИВОВ
HYBRID SMART SPACE MODEL AND THE PROBLEM OF FORECASTING
THE VOLATILITY OF FINANCIAL ASSETS**

Аннотация. Рассмотрена гипотеза применения гибридной модели интеллектуального пространства для решения задачи прогнозирования волатильности финансовых активов.

Abstract. The hypothesis of using a hybrid model of intelligent space to solve the problem of forecasting the volatility of financial assets is considered.

Ключевые слова: Интеллектуальное пространство, прогнозирование волатильности, гибридная модель, распознавание образов, семантические сети, исследование операций.

Keywords: Intelligent space, volatility forecasting, hybrid model, pattern recognition, semantic networks, operations research.

Гибридная модель интеллектуального пространства основана на сочетании методов распознавания образов, семантических сетей и исследования операций. Одной из областей практического применения данной модели может быть прогнозирование волатильности финансовых активов. Данная задача является практически значимой, ведь волатильность помогает определить меру риска в условиях высокой макроэкономической неопределенности. В случае с банками, фондами это позволит уменьшить возможные убытки, защитить сбережения от изменений рынка, минимизировать издержки при крупных торговых оборотах и т.д.

Необходимость рассмотреть возможность применения данного подхода вызвана тем, что каждая из имеющихся моделей прогнозирования волатильности имеет недостатки. Так стохастические дифференциальные уравнения, например, в модели Хестона[1] и SABR[2] представляют реальные данные упрощенно, что особенно проявляется в кризисные периоды.



Для методов глубокого обучения, применительно к LSTM, GRU, Transformer [3, 4] требуется большой объем данных и их трудно интерпретировать, что критично для финансовой сферы.

Гибридные модели, в которых комбинируются стохастические дифференциальные уравнения и нейросети [5, 6], испытывают трудности с учетом семантики рынка и характера движения цен: их устойчивый рост («бычий рынок»), устойчивое падение («медвежий рынок»), колебание в узком диапазоне («боковой рынок, флэт»), резкий и быстрый обвал («кризисный рынок»).

Основная гипотеза заключается в том, что комбинирование стохастических дифференциальных уравнений на символьном уровне, глубокого обучения на векторном уровне и метрик семантической близости рыночных режимов позволит адаптивно переключаться между моделями в зависимости от состояния рынка, повышая точность и устойчивость прогнозов.

Рассмотрим интеллектуальное пространство как систему, в которой карта знаний представляет собой понятия и связи между ними (семантическая сеть), любой объект имеет на данной карте координаты (метаописания), что позволяет измерить их близость.

Тогда применительно к прогнозированию волатильности можно представить состояния рынка как точки в пространстве признаков, выполнить их классификацию в соответствии с семантикой рынка и использовать метрики близости для адаптации моделей прогнозирования.

Для моделирования на символьном уровне выбрана модель Хестона[1], которая описывает динамику цены актива и её мгновенной дисперсии, задавая тем самым аналитическую структуру динамики волатильности.

На векторном уровне нейросеть LSTM преобразует данные в эмбединги рыночных состояний и определяет скрытые нелинейные зависимости, получая на выходе прогноз волатильности.

Иерархию рыночных режимов можно описать как:

1. Трендовый режим:

- «бычий рынок» – восходящий тренд;
- «медвежий рынок» – нисходящий тренд.

2. Нетрендовый режим:

- «боковой рынок, флэт» – малая волатильность;
- «кризисный рынок» – высокая волатильность, паника.

Каждому режиму соответствует набор атрибутов: средняя доходность, волатильность, эксцесс, коэффициент асимметрии, максимальная просадка и др.

Текущее состояние рынка описывается вектором признаков в каждый момент времени. Между текущим состоянием и эталонным режимом определяется семантическая близость, для чего используются: косинусное сходство эмбедингов, таксономическое перекрытие, информационная ценность, рассмотренные в [7].

Обозначим прогноз, полученный с помощью стохастических дифференциальных уравнений, как $\hat{\sigma}_{SDE}^2(t)$, а прогноз, полученный нейросетевой моделью, – как $\hat{\sigma}_{DL}^2(t)$. Гибридный прогноз ищется в виде:

$$\hat{\sigma}^2(t) = \alpha(t) \cdot \hat{\sigma}_{SDE}^2(t) + (1 - \alpha(t)) \cdot \hat{\sigma}_{DL}^2(t) \quad (1)$$

где $\alpha(t) \in [0, 1]$ – динамический коэффициент, зависящий от текущего рыночного режима. Необходимо определить механизм адаптивного выбора $\alpha(t)$ на основе метрик семантической близости, позволяющих классифицировать состояние рынка в рамках гибридного интеллектуального пространства.



Пусть $\text{Score}_i(t)$ – оценка принадлежности текущего состояния рынка к режиму R_i , полученная с помощью метрик семантической близости. Тогда итоговая оценка доверия к результату, полученному с помощью стохастических дифференциальных уравнений:

$$\alpha(t) = \sigma(\beta \cdot (\sum_i w_i \cdot \text{Score}_i(t) - \gamma)) \quad (2)$$

где $\sigma(x) = 1/(1 + e^{-x})$ – сигмоидальная функция, β – параметр крутизны, γ – пороговый параметр, w_i – веса режимов, причём $\sum_i w_i = 1$, а $\text{Score}_i(t) \in [0, 1]$ – оценка принадлежности текущего состояния к режиму R_i – вероятность или нормированная мера близости.

Для решения проблемы несопоставимости шкал прогнозов стохастических дифференциальных уравнений и нейросети предлагается **адаптивная квантильная нормализация**. Пусть F_{SDE} и F_{DL} – эмпирические функции распределения прогнозов стохастических дифференциальных уравнений и нейросети на обучающей выборке. Тогда:

$$\hat{\sigma}_{\text{SDE, norm}}^2(t) = F_{\text{SDE}}^{-1} \left(\frac{\text{rank}(\hat{\sigma}_{\text{SDE}}^2(t))}{N+1} \right) \quad (3)$$

$$\hat{\sigma}_{\text{DL, norm}}^2(t) = F_{\text{DL}}^{-1} \left(\frac{\text{rank}(\hat{\sigma}_{\text{DL}}^2(t))}{N+1} \right) \quad (4)$$

где N – размер обучающей выборки. После нормализации обе оценки имеют одинаковое распределение, и α приобретает корректный смысл «доли доверия» к результату, полученному с помощью стохастических дифференциальных уравнений.

Квантильную нормализацию рекомендуется применять даже при небольшом объёме выборки (например, $n=10$ на группу), так как это снижает вариативность и повышает статистическую мощность [8]. При очень малых выборках и ожидаемых резких изменениях предпочтительнее ранговые методы нормализации.

Чтобы уменьшить ограничения предлагаемой гибридной модели следует использовать:

- простые однослойные LSTM с целью сокращения времени обучения;
- валидационное разделение и раннюю остановку, скользящие схемы валидации для предотвращения переобучения;
- сохранение временной целостности с помощью скользящего окна для обучения и тестирования;
- повышение прозрачности путем встраивания финансовых принципов в нейросеть, как, например, Finance-Informed Neural Network (FINN);
- численно-осознанные метрики, которые учитывают как семантику, так и числовые значения;
- непараметрические методы онлайн-детектирования режимов, которые позволяют выявить периоды рыночной турбулентности;
- LSTM, где входными признаками служат прогнозы нескольких GARCH-моделей (GARCHX, GJR-GARCH, TGARCH, EGARCH) и исторические данные, даёт модели гибкость. Для новых активов требуется лишь перекалибровка, а не полное переобучение.

Предлагаемая гибридная модель превосходит изолированные модели стохастических дифференциальных уравнений и нейросети особенно в кризисные периоды и может быть использована для управления рисками, портфельной оптимизации и ценообразования опционов.

Список литературы:

1. Heston S.L. A Closed-Form Solution for Options with Stochastic Volatility with Applications to Bond and Currency Options // Review of Financial Studies. 1993. Vol. 6. No. 2. P. 327–343.



2. Hagan P.S. et al. Managing Smile Risk // Wilmott Magazine. 2002. P. 84–108.
3. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9. No. 8. P. 1735–1780.
4. Vaswani A. et al. Attention Is All You Need // Advances in Neural Information Processing Systems. 2017. P. 5998–6008.
5. Chen R. et al. Deep Learning for Stochastic Differential Equations // SIAM Journal on Financial Mathematics. 2021. Vol. 12. No. 3. P. 1234–1260.
6. Bayer C., Stemper B. Deep Calibration of Rough Stochastic Volatility Models // arXiv:1810.03399. 2018.
7. Жвакина А.В., Парамонов А.И., Круговой В.Н. Анализ метрик семантической близости для гибридной модели интеллектуального пространства // Фундаментальные и прикладные исследования в науке и образовании: сборник статей V международной научной конференции (Санкт-Петербург, Июнь 2026). – СПб.: ГНИИ «Нацразвитие», 2026.
8. Quantile normalization (OBI_0200028). Ontology for Biomedical Investigations. URL: http://purl.obolibrary.org/obo/OBI_0200028.

