

Методика оценки устойчивости моделей временных рядов, применяемых для управления запасами

М.И. Шибиченко¹, В.А. Павлов²

¹Московский финансово-юридический университет МФЮА, г. Москва

²Национальный исследовательский Московский государственный строительный университет, г. Москва

Аннотация: Статья посвящена разработке и апробации методики количественной оценки устойчивости моделей временных рядов (SARIMA, Prophet, LSTM), используемых для управления запасами в условиях нестабильной внешней среды. Предложен подход, основанный на моделировании сценариев искажений входных данных, включая праздничные всплески, логистические сбои, инфляционные тренды и структурные сдвиги. Введены метрики устойчивости — Индекс устойчивости (RI) и Относительный спад точности (D), позволяющие оценивать деградацию прогнозов. Эксперимент на синтетических данных показал, что высокая точность на чистых данных не гарантирует устойчивости: SARIMA чувствительна к инфляционным трендам, Prophet устойчив к сезонности, а LSTM — к структурным сдвигам. Результаты применимы в логистике и ритейле для оптимизации планирования поставок.

Ключевые слова: управление запасами, временные ряды, устойчивость моделей, прогнозирование спроса, SARIMA, Prophet, LSTM, индекс устойчивости, относительный спад точности, логистические сбои, сезонные колебания

В условиях нестабильной внешней среды задача эффективного управления запасами приобретает всё большую значимость для предприятий, стремящихся поддерживать непрерывность бизнес-процессов и минимизировать издержки. Актуальность исследования подчеркивается тем, что глобальный рынок программного обеспечения для управления запасами демонстрирует устойчивый рост. В 2024 году этот рынок оценивался в 3,9 млрд долларов США, и достигнет 7,3 млрд долларов США к 2034 году, демонстрируя среднегодовой темп роста 6,4% в течение прогнозируемого периода [1].

Однако, существенные колебания спроса, сбои в логистических цепочках, инфляционные процессы, сезонные и праздничные отклонения создают дополнительные риски, требующие высокоточного и адаптивного

прогнозирования объёмов потребления [2]. Модели временных рядов в этих условиях становятся ключевым инструментом стратегического и оперативного управления запасами, особенно с учётом растущей цифровизации складской и логистической деятельности [3,4].

Несмотря на широкое распространение прогностических моделей, оценка их качества в подавляющем большинстве случаев осуществляется на основе традиционных метрик — среднеквадратической ошибки (RMSE), средней абсолютной ошибки (MAE), средней абсолютной процентной ошибки (MAPE) и других. Однако эти показатели отражают лишь среднюю точность модели на заданном множестве данных и не учитывают её поведение при изменении внешних условий. Такая практика приводит к завышенной оценке пригодности моделей, которые в действительности могут оказаться неустойчивыми к неожиданным колебаниям и аномалиям во входных данных [5,6].

Устойчивость модели прогнозирования — способность сохранять приемлемое качество прогноза при воздействии неблагоприятных факторов или изменении структуры входных данных [7]. При управлении запасами устойчивость имеет практическое значение, так как от неё зависит финансовая стабильность предприятия, определяемая надёжностью планирования поставок и уровнем страховых запасов. Исследования показывают, что даже современные нейросетевые модели, такие как LSTM и Prophet, могут демонстрировать высокую чувствительность к небольшим искажениям во входных временных рядах. Следовательно, для оценки практической применимости модели требуется учитывать не только её точность, но и устойчивость к отклонениям и искажениям данных [8].

Статья посвящена разработке и экспериментальной апробация методики количественной оценки устойчивости моделей временных рядов, применяемых для управления запасами.

Теоретические основы прогнозирования временных рядов в задачах управления запасами

Управление запасами — это комплексная задача, направленная на обеспечение бесперебойного функционирования производственно-сбытовой системы при минимальных издержках. Ключевым элементом эффективной системы управления является возможность точно прогнозировать будущие объёмы спроса. В современных условиях такие прогнозы позволяют оптимизировать закупки, снизить уровень избыточных запасов и предотвратить дефицит товаров [9].

Прогнозирование в задачах управления запасами традиционно опирается на методы анализа временных рядов. Временной ряд представляет собой последовательность наблюдений, упорядоченных во времени, и может включать информацию о продажах, отгрузках, остатках товаров и других логистических параметрах. Существует множество моделей временных рядов, применяемых в управлении запасами. Наиболее распространёнными являются классические статистические модели [10]:

- ARIMA (AutoRegressive Integrated Moving Average) — модель, хорошо подходящая для стационарных и слабо нестационарных данных, при условии корректной предобработки (дифференцирование, устранение сезонности);
 - SARIMA (Seasonal ARIMA) — расширение ARIMA с учётом сезонных эффектов;
 - Exponential Smoothing (ETS) — семейство моделей сглаживания, применяемых при выраженных тенденциях и сезонных компонентах;
-

- Prophet — модель, сочетающая регрессию, компонентную декомпозицию и байесовский подход, широко используемая в бизнес-прогнозировании.
- В последние годы стали широко использовать нейросетевые модели:
- LSTM (Long Short-Term Memory) — рекуррентная нейросеть, способная моделировать длинные зависимости во временных рядах;
- TCN (Temporal Convolutional Networks) — архитектура, использующая одномерные свёртки с каузальной структурой;
- Transformer-based models — модели на основе механизмов внимания, демонстрирующие высокую точность при больших объёмах данных.
- Помимо выбора модели, важным аспектом является выбор метрик, используемых для оценки её качества. Наиболее часто применяются:
- MAE (Mean Absolute Error) — средняя абсолютная ошибка.
- RMSE (Root Mean Square Error) — среднеквадратическая ошибка.
- MAPE (Mean Absolute Percentage Error) — средняя абсолютная процентная ошибка.

Однако, эти метрики не отражают степень надёжности модели в нестабильных условиях. Это требует дополнительного рассмотрения критериев устойчивости и соответствующих методик оценки, что и является основной темой данной статьи.

Методика оценки устойчивости моделей временных рядов

Оценка устойчивости моделей прогнозирования временных рядов требует системного подхода, способного зафиксировать отклонения качества прогноза при вариациях внешней среды. Разрабатываемая методика основана на сравнении точности прогноза базовой модели с результатами её работы в условиях искусственно искажённых сценариев. Методика состоит из трёх основных этапов:

формирование сценариев возмущений, запуск моделей и расчёт метрик устойчивости.

Формирование сценарных искажений входных данных

Для анализа устойчивости необходимо создать несколько типов возмущений входных временных рядов, имитирующих реальные сбои и колебания внешней среды. В данной работе рассматриваются пять сценариев:

1. Сценарий праздничного пика спроса — искусственное увеличение значений в определённых временных точках (например, в предновогодние недели):

$$y'_t = y_t \cdot (1 + \alpha), \quad \alpha \in [0.3, 0.7]$$

2. Сценарий логистического сбоя — временное падение объёмов поставок или продаж, отражающее сбой в логистике или закупках:

$$y'_t = y_t \cdot (1 - \beta), \quad \beta \in [0.5, 1.0] \text{ или устанавливаются в ноль: } y'_t = 0.$$

3. Сценарий инфляционного давления — во второй половине ряда вводится линейный или экспоненциальный тренд, отражающий общую инфляционную динамику:

$$y'_t = y_t + \gamma \cdot t \text{ или } y'_t = y_t \cdot e^{\gamma t}, \quad \gamma > 0$$

4. Сценарий инфляционного давления с внешним регрессором — инфляция не встраивается непосредственно в динамику ряда y_t , а поступает в модель в виде экзогенного признака x_t , отражающего влияние инфляционных процессов на спрос. Это соответствует реальной практике моделирования (значения внешней макроэкономической переменной - инфляции известны заранее). Модель прогнозирует y_t , учитывая влияние x_t , по формуле:

$$y_t = f(y_{t-1}, y_{t-2}, \dots; x_t, x_{t-1}, x_{t-2}, \dots),$$

где x_t — недельный индекс инфляции, поступающий в модель как внешний регрессор. Значения y_t не искажаются и соответствуют базовому ряду..

5. Сценарий структурного сдвига — разовое смещение уровня ряда, имитирующее смену потребительского поведения:

$$y'_t = \begin{cases} y_t, & t < t_0 \\ y_t + \Delta, & t \geq t_0 \end{cases}$$

где Δ — постоянное смещение уровня спроса.

Каждое искажение накладывается на копию исходного ряда с сохранением структуры данных. При этом параметры возмущения задаются вручную или формируются на основе статистических свойств исходных данных.

Алгоритм оценки устойчивости

Алгоритм включает несколько последовательных шагов:

1. Обучение модели на оригинальном временном ряде.
2. Генерация искажённых версий ряда по выбранным сценариям.
3. Прогнозирование по искажённым входным данным без переобучения модели.
4. Сравнение прогноза по искажённым данным с прогнозом по исходному ряду и/или с эталонными значениями.
5. Расчёт метрик устойчивости для каждой модели и сценария.

Метрики устойчивости

Рассмотрим два формальных критерия устойчивости модели:

Индекс устойчивости (RI, Robustness Index) — отражает относительное снижение точности модели при искажении входных данных. Чем ближе значение *RI* к 1, тем меньше деградация прогноза. Рассчитывается по формуле:

$$RI = 1 - \frac{E_{\text{иск}} - E_0}{E_0},$$

где $E_{\text{иск}}$ — значение метрики ошибки (например, MAE или RMSE) на искажённых данных, а E_0 — значение на исходных данных.

Относительный спад точности (D , Degradation Ratio) — характеризует во сколько раз увеличивается ошибка прогноза под воздействием возмущений:

$$D = \frac{E_{\text{иск}}}{E_0},$$

Метрики RI и D разработаны авторами на основе общих принципов оценки устойчивости [11,12], адаптированных для временных рядов в управлении запасами. Метрики могут быть усреднены по всем сценариям или представлены по отдельности для дифференцированной оценки поведения модели.

Экспериментальное исследование

Экспериментальное исследование направлено на верификацию разработанной методики количественной оценки устойчивости моделей временных рядов, применяемых для задач управления запасами в условиях нестабильной внешней среды. Целью эксперимента являлось сравнение поведения моделей в ситуациях искажений входных данных, имитирующих наиболее типовые сбои в экономической и логистической практике.

Подготовка данных

В качестве исходных данных использовался синтетически сгенерированный временной ряд недельного спроса на товар за девятилетний период с 2016 по 2024 год (469 точек). Базовый ряд включал линейную тенденцию роста, годовую сезонность и стохастический шум, что обеспечивает приближение к реальным поведенческим характеристикам спроса. Этот базовый ряд использовался в качестве эталона для расчёта ошибок прогнозирования и оценки устойчивости моделей. Средние абсолютные ошибки на исходных данных составили: SARIMA — 12.5, Prophet — 10.9, LSTM — 9.6.

Для моделирования сценариев искажений к базовому синтетическому ряду применялись следующие преобразования: *сезонный всплеск (сценарий 1)*

имитировался локальным увеличением значений (на 30–70%) в последние 3 недели каждого года; *логистический сбой (сценарий 2)* — снижение значений спроса на 80–100% в течение трёх недель в середине каждого года; *инфляционное давление (сценарий 3)* — экспоненциальный рост ряда $y'_t = y_t \cdot e^{\gamma t}$ при $\gamma = 0.002$. *Инфляция как внешний регрессор (сценарий 4)* — значения инфляции интерполированы по неделям на основе реальных данных Росстата за 2016–2024 гг. [13] и использованы в качестве внешнего признака x_t , подаваемого в модель (при этом сам ряд спроса не модифицируется). *Структурный сдвиг (сценарий 5)* — разовое смещение уровня спроса на $\Delta = 20$, начиная с заранее определённых лет (2020, 2022, 2023), имитируя смену рыночной стратегии или поведения потребителя. Амплитуды 30–70% для пиков и 80–100% для сбоев выбраны на основе типичных колебаний спроса в ритейле [14,15]. В [14] показано, что сезонные всплески спроса достигают 22–27% для медианных продуктов и выше для отдельных категорий, требуя особого планирования. В [15] описаны сбои, вызванные COVID-19, когда спрос на некоторые товары падал на 80–100% из-за логистических проблем, подчёркивая сложности управления цепочками поставок при сочетании пиков и сбоев.

Эти сценарии были реализованы программно, с сохранением формы и длины временного ряда. На рис.1 представлены четыре сценария искажений недельного спроса за 9 лет. На графике-врезке представлена реальная динамика инфляции за период 2016–2024 гг., подаваемая в модель как внешний регрессор (сценарий 4). Эти значения использовались только моделью SARIMAX как объясняющий признак, влияющий на предсказание спроса, но не искажающий сам временной ряд.




Рис.1. Типовые сценарии нестабильности спроса с учётом инфляции

Данные были нормализованы и разбиты на обучающую и тестовую выборки (соотношение 70/30).

Выбор моделей и условия обучения

Для оценки устойчивости были выбраны три модели прогнозирования:

SARIMA — сезонная авторегрессионная модель с интегрированной скользящей средней (параметры (1,1,1));

Prophet — с включёнными сезонными и праздничными компонентами.

LSTM — двухслойная сеть с 64 нейронами в каждом слое, обученная на 100 эпохах при batch size = 16.

Все модели обучались на «чистых» данных без искажений. Затем каждая модель использовалась для прогнозирования на тестовой выборке, к которой были поочерёдно применены указанные сценарии искажений. Для сценария 4 модель SARIMA использовалась с внешним регрессором (инфляция по неделям). Метрики рассчитывались только на тестовом интервале (последние 52 недели).

Результаты оценки устойчивости

Для количественного анализа устойчивости прогнозных моделей в условиях внешних искажений были использованы следующие метрики:

1. MAE (Mean Absolute Error) — средняя абсолютная ошибка прогноза, рассчитываемая на «чистых» и искажённых данных.

2. RI (Robustness Index) — индекс устойчивости, отражающий относительное снижение точности под действием искажения:

$$RI = 1 - \frac{MAE_{иск} - MAE_0}{MAE_{иск}}$$

3. D (Degradation Ratio) — коэффициент деградации, определяющий, во сколько раз увеличилась ошибка по сравнению с исходной:

$$D = \frac{MAE_{иск}}{MAE_0}$$

Использование MAE, RI и D в совокупности позволяет получить как абсолютную, так и относительную картину реакции модели на сценарные возмущения.

Результаты анализа показывают, что устойчивость моделей прогнозирования временных рядов существенно различается в зависимости от характера внешнего искажения и архитектурных особенностей модели.

Наиболее выраженное снижение точности наблюдается у модели SARIMA в сценарии инфляционного давления, встроенного в прогнозируемый ряд (сценарий 3): значение $RI = -27.69$ и $D = 29.69$ указывают на полную деградацию качества прогноза. Однако при использовании инфляции в качестве внешнего регрессора (сценарий 4) устойчивость SARIMA значительно возрастает ($RI = 0.15$, $D = 1.85$), что подчёркивает важность учёта экзогенных факторов в моделях авторегрессии.

В таблице 1 приведены значения MAE и индексов RI и D для всех моделей и сценариев.

Таблица №1

Результаты устойчивости моделей

	Сценарий 1 (праздники)	Сценарий 2 (сбой)	Сценарий 3 (инфл. в y)	Сценарий 4 (инфл. <i>exog</i>)	Сценарий 5 (сдвиг)
SARIMA — MAE	18.2	19.1	371.1	23.1	22.4
SARIMA — RI	0.54	0.47	−27.69	0.15	0.21
SARIMA — D	1.46	1.53	29.69	1.85	1.79
Prophet — MAE	14.5	17.8	12.3	—	19.2
Prophet — RI	0.67	0.37	0.87	—	0.24
Prophet — D	1.33	1.63	1.13	—	1.76
LSTM — MAE	11.7	13.9	11.2	—	15.6
LSTM — RI	0.78	0.55	0.83	—	0.38
LSTM — D	1.22	1.45	1.17	—	1.62

Модель Prophet демонстрирует сбалансированную устойчивость, особенно в условиях сезонных колебаний и плавного тренда (сценарии 1 и 3), что объясняется её компонентной структурой. Однако при логистических сбоях и структурных изменениях (сценарии 2 и 5) устойчивость снижается, что выражается в уменьшении RI и росте D .

Модель LSTM показывает наивысшую точность на исходных данных, однако проявляет чувствительность к длительным искажениям структуры, особенно в сценарии 5 (структурный сдвиг). Значения RI в пределах 0.38–0.83 и D до 1.62 свидетельствуют о необходимости адаптации или регулярного переобучения модели при изменении внешней среды.

Таким образом, различные модели по-разному реагируют на сценарные возмущения входных данных. Использование метрик RI (Robustness Index) и D (Degradation Ratio) позволяет комплексно оценивать устойчивость: RI отражает относительное снижение точности, а D характеризует кратность увеличения

ошибки прогноза под воздействием искажений. Значения RI и D близкие к единице, свидетельствуют о высокой устойчивости модели к возмущениям. В то же время отрицательные значения RI или значения D , превышающие 2, указывают на существенную деградацию качества прогнозирования и могут служить основанием для пересмотра архитектуры модели или корректировки её параметров. Такой подход обеспечивает более объективную и информативную оценку надёжности моделей в условиях нестабильных или изменяющихся данных.

В статье приведены результаты апробации методики оценки устойчивости моделей временных рядов, применяемых для задач управления запасами в условиях нестабильной внешней среды. Обоснована актуальность перехода от традиционной оценки прогностического качества к более комплексному подходу, включающему устойчивость моделей к различного рода искажениям данных.

Предложенная методика основана на формализации сценариев внешних возмущений, в том числе праздничных всплесков, логистических сбоев, инфляционных трендов и структурных сдвигов. Метрики RI и D эффективно выявляют деградацию моделей, но требуют дальнейшего сравнения со стандартными метриками устойчивости.

Экспериментальное исследование показало, что высокая точность на «чистых» данных не гарантирует надёжность модели в реальных условиях эксплуатации. Модель SARIMA оказалась устойчивее к структурным искажениям, Prophet — к сезонным и праздникам, а LSTM — наиболее точной, но чувствительной к трендовым деформациям. Результаты исследования могут быть использованы в системах поддержки принятия решений при планировании поставок, в логистике и ритейле.

Литература

1. Inventory Management Software Market Size, Share & Industry Analysis / Fortune Business Insights. 2024. – URL: fortunebusinessinsights.com/inventory-management-software-market-108589 (дата обращения: 07.05.2025).
2. Демержиба А. А. Оптимизация цепей поставок потребительского рынка региона на основе совершенствования системы управления запасами // Инженерный вестник Дона. 2013. № 2. URL: ivdon.ru/ru/magazine/archive/n2y2013/1770 (дата обращения: 11.05.2025).
3. Seyedan M., Mafakheri F., Wang C. Order-up-to-level inventory optimization model using time-series demand forecasting with ensemble deep learning // Supply Chain Analytics. [Amsterdam]: Elsevier, 2023. Vol. 3. Article 100024. 12 p.
4. Rakholia K. R., Chandraprabh C., Ramesh R., Rao K. S., Punitha S., Kumar M. G. V. Optimizing Inventory Management Through Demand Forecasting: A Data-Driven Approach for Enhanced Supply Chain Efficiency // Proceedings of the 3rd International Conference on Optimization Techniques in the Field of Engineering (ICOFE-2024). 2024. 10 p.
5. Bontempi G., Ben Taieb S., Le Borgne Y. A. Machine Learning Strategies for Time Series Forecasting // Business Intelligence. eBISS 2012 / ed. M. A. Aufaure, E. Zimányi. – Berlin; Heidelberg: Springer, 2013. – Lecture Notes in Business Information Processing, vol. 138. P. 62–77.
6. Lawrence N. D. Deep Probabilistic Modelling with Gaussian Processes // Neil Lawrence's Talks. 2017. URL: inverseprobability.com/talks/notes/deep-gaussian-processes.html (дата обращения: 08.05.2025).
7. Yoon T., Park Y., Ryu E., Wang Y. Robust Probabilistic Time Series Forecasting // arXiv. – arXiv, 2022. DOI: 10.48550/arXiv.2202.11910.

8. Ayachi L. Assessing Forecasting Model Robustness Through Curvature-Based Noise Perturbations // Proceedings of the 16th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2024). SciTePress, 2024. P. 488–495.
9. Константинов Р. В. Проектирование оптимальной складской сети // Инженерный вестник Дона. 2011. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2011/581 (дата обращения: 11.05.2025).
10. Альчаков В. В., Крамарь В. А. Оценка методов машинного обучения для прогнозирования сезонных временных рядов // Известия Южного федерального университета. Технические науки. Ростов-на-Дону: Южный федеральный университет. 2023. № 2 (232). С. 250–263.
11. Ben Braiek H., Khomh F. Machine Learning Robustness: A Primer // arXiv, 2024. 26 p.
12. Hendrycks D., Dietterich T. Benchmarking Neural Network Robustness to Common Corruptions and Perturbations // arXiv, 2019. 12 p.
13. Таблица уровня инфляции по месяцам в годовом исчислении. URL: уровень-инфляции.рф/таблицы-инфляции (дата обращения: 10.05.2025).
14. Butters R., Sacks D., Seo B. Why Do Retail Prices Fall During Seasonal Demand Peaks? // The RAND Journal of Economics. Hoboken: Wiley, 2025. Vol. 56, № 1. pp. 35–54.
15. Retail supply chains: Learning lessons from disruption / The Economist Intelligence Unit. – London: The Economist Intelligence Unit Limited, 2020. 17 p.

References

1. Inventory Management Software Market Size, Share & Industry Analysis / Fortune Business Insights. 2024. URL: fortunebusinessinsights.com/inventory-management-software-market-108589 (date assessed: 07.05.2025).
 2. Demerzhiba A. A. Inzhenernyj vestnik Dona. 2013. № 2. URL: ivdon.ru/ru/magazine/archive/n2y2013/1770 (date assessed: 11.05.2025).
 3. Seyedan M., Mafakheri F., Wang C. Supply Chain Analytics. [Amsterdam]: Elsevier, 2023. Vol. 3. Article 100024. 12 p.
 4. Rakholia K. R., Chandraprabh C., Ramesh R., Rao K. S., Punitha S., Kumar M. G. V. Proceedings of the 3rd International Conference on Optimization Techniques in the Field of Engineering (ICOFE-2024). 2024. 10 p.
 5. Bontempi G., Ben Taieb S., Le Borgne Y. A. Business Intelligence. eBISS 2012 / ed. M. A. Aufaure, E. Zimányi. – Berlin; Heidelberg: Springer, 2013. Lecture Notes in Business Information Processing, vol. 138. 62–77.
 6. Lawrence N. D. Neil Lawrence's Talks. 2017. URL: inverseprobability.com/talks/notes/deep-gaussian-processes.html (date assessed: 08.05.2025).
 7. Yoon T., Park Y., Ryu E., Wang Y. arXiv. – arXiv, 2022. DOI: 10.48550/arXiv.2202.11910.
 8. Ayachi L. Proceedings of the 16th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2024). SciTePress, 2024. 488–495.
 9. Konstantinov R. V. Inzhenernyj vestnik Dona. 2011. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2011/581 (date assessed: 11.05.2025).
 10. Al'chakov V. V., Kramar' V. A. Izvestiya YUzhnogo federal'nogo universiteta. Tekhnicheskie nauki. Rostov-na-Donu: YUzhnyj federal'nyj universitet. 2023. № 2 (232). pp. 250–263.
-



11. Ben Braiek H., Khomh F. arXiv, 2024. 26 p.
12. Hendrycks D., Dietterich T. arXiv, 2019. 12 p.
13. Tablica urovnya inflyacii po mesyacam v godovom ischislenii [Table of inflation rates by month on an annualized basis. URL: level-of-inflation. rf/tables-of-inflation]. URL: uroven'-inflyacii.rf/tablicy-inflyacii (data obrashcheniya: 10.05.2025).
14. Butters R., Sacks D., Seo B. The RAND Journal of Economics. Hoboken: Wiley, 2025. Vol. 56, № 1. pp. 35–54.
15. Retail supply chains: Learning lessons from disruption. The Economist Intelligence Unit. – London: The Economist Intelligence Unit Limited, 2020. 17 p.

Дата поступления: 20.05.2025

Дата публикации: 25.08.2025