

Интеллектуальный анализ спроса и оптимизация распределения оборотного капитала селлера на электронных маркетплейсах: методологическая основа, алгоритм и дизайн экспериментов

Бастанов Артур Эмильевич

Уфимский университет науки и технологий, Россия, Уфа, gradinv@gmail.com

Аннотация. Статья представляет методологический результат первого этапа исследовательской программы, направленной на повышение эффективности управления товарными запасами и оборотным капиталом селлеров на электронных маркетплейсах. Актуальность исследования определяется тем, что задачи распределения ограниченного оборотного капитала между многочисленными товарными позициями на практике решаются в условиях стохастического спроса, выраженной сезонности, неоднородной волатильности и ограниченных вычислительных ресурсов, в то время как традиционные методы управления запасами либо остаются статичными, либо требуют априорного задания параметров спроса и затрат. В работе предложена комплексная методика анализа спроса и распределения оборотного капитала, включающая три взаимосвязанных компонента: интеллектуальный анализ спроса на основе сезонно-трендовой декомпозиции и моделей машинного обучения для временных рядов (DLinear, NLinear, XGBoost); расширенный анализ волатильности спроса с использованием двух вариантов коэффициента вариации и адаптивной кластеризации ассортиментной матрицы; алгоритм распределения оборотного капитала, основанный на интегральном показателе «индекс доходности» и дополненный учётом сезонности и риска. Существенным элементом методики является разделение предсказуемой сезонной компоненты и остаточной волатильности, что позволяет более корректно оценивать риск товарных позиций и использовать эти оценки при формировании решений о распределении оборотного капитала. Методика формирует структурированный вектор признаков, включающий прогнозные, статистические и экономические характеристики товарных позиций, пригодный как для одноэтапных систем поддержки принятия решений, так и в качестве входного пространства состояний для дальнейших стохастических и динамических моделей управления запасами. Научная новизна работы заключается в интеграции известных инструментов прогнозирования, оценки волатильности и распределения оборотного капитала в единую математически согласованную методологическую модель, учитывающую специфику электронных маркетплейсов и специфические ограничения селлеров. Статья обосновывает предложенную методику, описывает её архитектуру и раскрывает дизайн вычислительных экспериментов, предназначенных для последующей эмпирической оценки её эффективности.

Ключевые слова: маркетплейс, селлер¹, прогнозирование спроса, сезонность, коэффициент вариации, индекс доходности, управление запасами, управление оборотным капиталом, методы машинного обучения

Цитирование: Бастанов А.Э. Интеллектуальный анализ спроса и оптимизация распределения оборотного капитала селлера на электронных маркетплейсах: методологическая основа, алгоритм и дизайн экспериментов / А.Э. Бастанов // Информационные и математические технологии в науке и управлении, 2026. – № 3(43). – С. 144-153. – DOI:10.25729/ESI.2026.43.3.012.

Введение. Современный этап развития розничной торговли характеризуется стремительной цифровизацией и ростом доли онлайн-каналов, прежде всего электронных маркетплейсов. Это привело к демократизации доступа на рынок для множества продавцов и одновременно к резкому обострению конкуренции. В таких условиях критически важным для выживания и развития бизнеса селлера становится эффективное управление внутренними ресурсами, прежде всего оборотным капиталом, направляемым на формирование товарных запасов.

Актуальность исследования обусловлена потребностью селлеров в формализованных, но вычислительно недорогих алгоритмах, которые позволяют не только реагировать на

¹ Селлер (от англ. *seller* – продавец) – это предприниматель или компания, которые продают товары через цифровые каналы, чаще всего на маркетплейсах (таких, как Wildberries, Ozon, Яндекс Маркет, Мегамаркет)

рыночные колебания, но и тактически распределять ограниченный оборотный капитал с учётом прогнозируемого спроса, рентабельности и оборачиваемости в условиях риска. Традиционные методы управления запасами и ассортиментом: ABC/XYZ-анализ, матрицы BCG и McKinsey/GE, классические EOQ-модели – решают прежде всего задачи стратегической классификации номенклатуры или опираются на детерминированные зависимости спроса и затрат, слабо учитывая неопределённость и требуя сложных оптимизационных вычислений.

Строгие стохастические модели управления запасами, напротив, учитывают вероятностный характер спроса и позволяют описывать оптимальные политики пополнения (включая (s, S)-политики, политики уровня пополнения и однопериодную модель управления запасами – модель газетчика), но предполагают наличие априорной информации о распределении спроса и параметрах затрат либо отдельного статистического этапа их оценки. На практике продавцы маркетплейсов работают с большим числом SKU (Stock Keeping Unit – уникальный внутренний код товара), неполной и зашумлённой информацией о спросе и ограниченными вычислительными ресурсами, поэтому ни чисто детерминированные, ни классические стохастические постановки в явном виде не закрывают их тактические потребности. В результате формируется методологический разрыв между теоретически строгими моделями управления запасами и прикладными задачами распределения оборотного капитала на маркетплейсах.

В ранее выполненной работе был предложен алгоритм распределения оборотного капитала продавца на основе интегрального показателя «индекс доходности», рассчитываемого, как произведение коэффициента оборачиваемости и маржинальной рентабельности [1]. Алгоритм реализует итерационную процедуру ранжирования номенклатуры по индексу доходности и формирования бюджета закупок в пределах минимальных и целевых уровней запасов. При этом алгоритм остаётся одношаговым и статичным: опирается на точечные оценки оборачиваемости, рентабельности и прогноза продаж и не учитывает динамику спроса, сезонность и риски, связанные с волатильностью.

Цель настоящей работы – формализовать и обосновать методологические аспекты, расширяющие указанный подход за счёт интеграции методов анализа временных рядов и стохастических представлений о спросе.

Обзор литературы и постановка задачи. Распределение оборотного капитала продавца на маркетплейсах, по существу, представляет собой задачу управления запасами в условиях стохастического спроса, осложнённую бюджетными ограничениями. Это определяет необходимость рассмотреть литературные источники в трёх взаимосвязанных направлениях: классические подходы к управлению запасами и практики распределения капитала; методы прогнозирования спроса, обеспечивающие количественные оценки параметров моделей; стохастические модели и модели управления запасами, основанные на данных, задающие теоретическую и вычислительную рамки для разработки искомой методики.

Классические инструменты управления запасами и распределения капитала – это ABC/XYZ-анализ [2], матрицы BCG и McKinsey/GE [3], а также широко известные EOQ-модели и методы математической оптимизации [4, 5]. Эти инструменты решают прежде всего задачи стратегической классификации номенклатуры или оптимизации отдельных товарных позиций при заданных параметрах спроса и затрат. На практике, при распределении оборотного капитала между большим количеством SKU (товарных позиций), продавцы чаще используют простые алгоритмы: приоритизацию по маржинальности [6], по оборачиваемости [7], ABC-классификацию по прибыли [2]). Предложенный ранее алгоритм [1] на основе интегрального индекса доходности объединяет два основных критерия эффективности

(маржинальность и оборачиваемость), что повышает экономическую обоснованность решений. Однако и он остаётся статичным: все решения принимаются на основе точечных, ретроспективных оценок без явного использования прогнозов и без количественного учёта волатильности спроса.

Для того, чтобы перейти от простых статических алгоритмов к более строгим решениям, необходимо иметь модель прогнозирования будущего спроса и оценки степени его неопределённости. Классические модели временных рядов (ARIMA, экспоненциальное сглаживание) обеспечивают приемлемую точность на умеренно волатильных рядах [5], но хуже работают в условиях сильной сезонности, промо-активности и структурных сдвигов. Коэффициент вариации, традиционно применяемый в XYZ-анализе, при наличии сезонности смешивает регулярную сезонную вариацию и остаточный шум, завышая оценку риска для сезонных товаров [8]. Современные исследования показывают, что линейные архитектуры DLinear/NLinear для долгосрочного прогнозирования временных рядов могут конкурировать с трансформерами по точности при меньшей вычислительной сложности [9, 10, 11], а XGBoost остаётся эффективным методом табличного прогнозирования спроса [12, 13, 14]. Сочетание сезонно-трендовой декомпозиции (Seasonal-Trend decomposition using Loess, STL) (для выделения тренда и сезонности), линейных моделей DLinear/NLinear и XGBoost с расширенным анализом коэффициента вариации позволяет разделять предсказуемый сезонный компонент и остаточную волатильность [8]. Тем самым формируется именно тот набор параметров (прогнозы, интервалы, меры волатильности), который потенциально может быть использован в алгоритмах распределения капитала и стохастических моделях запасов.

Классическая теория стохастического управления запасами описывает оптимальные политики при вероятностном спросе и заданной структуре затрат. В дискретном времени при стационарном и независимом по периодам спросе, выпуклых и возрастающих затратах хранения и дефицита и наличии фиксированных затрат заказа доказана оптимальность пороговых (s, S) -политик: существует пара уровней $s < S$, при которой оптимальная политика состоит в заказе до уровня S , если запас ниже s , и отказе от заказа в противном случае. При отсутствии фиксированных затрат естественными являются политики уровня пополнения (base-stock-политики), предусматривающие доведение запаса до постоянного целевого уровня после каждого пополнения. Для однопериодных задач важную роль играет однопериодная модель управления запасами («модель газетчика», newsvendor model), формализующая выбор объёма заказа при асимметричных издержках дефицита и излишка. Современные работы развивают робастные и дистрибуционно-робастные модификации этих постановок, описывая неопределённость спроса через множества допустимых распределений и минимизацию наихудшего ожидаемого риска [15].

Эти модели задают теоретически строгие эталоны управления запасами, но исходно предполагают наличие априорно известного распределения спроса, либо возможность его надёжной оценки на отдельном статистическом этапе. Для селлеров маркетплейсов с большим числом SKU, короткой историей продаж и зашумленными данными это допущение редко выполняется в полной мере, что ограничивает прямое практическое применение классических стохастических методов.

На стыке рассмотренных классических моделей и машинного обучения появились подходы, основанные на данных (data-driven), трёх типов. Во-первых, схемы «прогноз и оптимизация», в которых выходы моделей прогнозирования спроса (статистических или ML-моделей) используются для параметризации классических или робастных задач управления запасами [16, 17]. Во-вторых, методы обучения политики, включая глубокое обучение с подкреплением (Deep Reinforcement Learning, DRL), где стратегия управления

аппроксимируется параметрами обучаемой модели [18, 19, 20]. В-третьих, эвристические алгоритмы, основанные на заранее сконструированных признаках спроса и риска (например, различные варианты ABC/XYZ-классификации по выручке, оборачиваемости и коэффициенту вариации), определяющих правило ранжирования и распределения ресурсов. Сложные DRL-подходы демонстрируют высокий потенциал, но требуют значительных вычислительных ресурсов и больших исторических выборок, что ограничивает их применение в малом и среднем бизнесе, тогда как простые алгоритмы, будучи практически удобными, редко опираются на систематическое использование информации о сезонности и волатильности и слабо связаны с теорией стохастического управления запасами.

Таким образом, анализ трёх групп подходов: классических инструментов управления запасами и распределения капитала, методов прогнозирования спроса и стохастических/основанных на данных моделей управления запасами – выявляет общий методологический разрыв. Теоретически хорошо изучены оптимальные политики при заданном распределении спроса и параметрах затрат, а в практической деятельности селлеры опираются на простые алгоритмы, основанные на ретроспективных показателях и почти не использующие прогнозную и статистическую информацию. При этом отсутствует компактная и формально определённая методика, которая бы одновременно: строила прогнозы спроса и оценки волатильности для множества SKU с учётом сезонности; переводила эти оценки в количественные характеристики риска; интегрировала показатели ожидаемой доходности и риска в алгоритм распределения оборотного капитала на основе экономически интерпретируемого показателя; формировала структурированный вектор признаков, пригодный для последующего использования в более строгих стохастических и динамических моделях.

Решение именно этой задачи, а именно, построение математически согласованной методики, связывающей анализ спроса, оценку неопределённости и алгоритм распределения оборотного капитала для селлеров маркетплейсов, и составляет предмет настоящей статьи.

Методика анализа спроса и распределения оборотного капитала. Исходными данными являются временные ряды продаж по товарным позициям (SKU) селлеров маркетплейсов с горизонтами наблюдений не менее 24 месяцев и шагом дискретизации месяц или неделя. Для каждой SKU доступны данные о фактических продажах, наличии товара, ценах и промо-акциях.

Для выявления сезонности, для каждого ряда y_t применяется STL-декомпозиция [21], разбивающая ряд на три компонента:

$$y_t = T_t + S_t + R_t \quad (1)$$

где T_t – тренд (долгосрочная динамика), S_t – сезонный компонент (регулярные периодические колебания), R_t – остаток (нерегулярные колебания, шум).

Для количественной оценки выраженности сезонности вводится показатель *SeasonShare*:

$$SeasonShare = \frac{Var(S_t)}{Var(y_t)} \quad (2)$$

Значение *SeasonShare* принадлежит отрезку $[0,1]$ и характеризует долю общей дисперсии, объясняемую сезонностью. При малых значениях сезонность незначительна; при значениях выше заданного порога сезонность является значимым фактором вариации спроса.

Дополнительно рассчитывается автокорреляционная функция (Autocorrelation Function, ACF) на сезонном лаге (12 для месячных данных, 52 для недельных). Товарная позиция классифицируется как сезонная, если *SeasonShare* превышает эмпирически подобранный порог $\theta_s \in [0,2; 0,5]$ и значения автокорреляции на сезонном лаге выходят за пределы 95%-доверительного интервала. Порог θ_s рассматривается как настраиваемый параметр, подлежащий последующей калибровке в ходе вычислительных экспериментов.

Для прогнозирования спроса автор предлагает использовать три класса моделей:

- 1) линейные архитектуры DLinear и NLinear – модели долгосрочного прогнозирования временных рядов, в которых применяется внутренняя декомпозиция и/или нормализация, а затем линейное отображение на будущие значения;
- 2) XGBoost – реализация градиентного бустинга по деревьям решений, на вход которой подаются лаговые значения продаж, скользящие средние, календарные индикаторы, признаки промо-активности, ценовые переменные, а также показатели сезонности;
- 3) базовые эвристические модели прогнозирования (наивный прогноз, экспоненциальное сглаживание) в качестве эталонных моделей-бенчмарков.

Обучение выполняется по схеме расширяющегося окна для оценки устойчивости моделей во времени. Качество прогнозов предлагается оценивать метриками MAPE, MAE, RMSE с агрегацией по портфелю и подгруппам (сильная сезонность, слабая, стабильный спрос).

Далее, для количественной оценки волатильности, по каждому SKU рассчитываются коэффициенты вариации по исходному ($CV_i^{(orig)}$) и сезонно-скорректированному ($CV_i^{(adj)}$) рядам:

$$CV_i^{(orig)} = \frac{\sigma_i}{\mu_i + \varepsilon} \quad (3)$$

$$CV_i^{(adj)} = \frac{\sigma_i^{(adj)}}{\mu_i^{(adj)} + \varepsilon} \quad (4)$$

где μ_i, σ_i – среднее значение и стандартное отклонение исходного ряда y_t , $\mu_i^{(adj)}, \sigma_i^{(adj)}$ – среднее значение и стандартное отклонение по сезонно-скорректированному ряду $T_t + R_t$, ε – малая константа (например, 10^{-6}) для обеспечения численной устойчивости.

Коэффициент $CV^{(orig)}$ отражает общий разброс исходного ряда с учётом сезонности и полезен прежде всего для несезонных товаров. Коэффициент $CV^{(adj)}$ позволяет оценить остаточную волатильность после исключения регулярного сезонного компонента и более адекватен для сезонных SKU. Таким образом, пара $(CV^{(orig)}, CV^{(adj)})$ отражает различие между общей и истинно случайной вариацией.

Классификация товарных позиций по уровню риска производится путем адаптивной кластеризации:

- для несезонных SKU ($SeasonShare < \theta_s$) используется коэффициент $CV^{(orig)}$;
- для сезонных SKU ($SeasonShare \geq \theta_s$) применяется коэффициент $CV^{(adj)}$.

Кластеризация выполняется методом К-средних в пространстве $\log(CV)$, что позволяет стабилизировать масштаб данных и улучшить свойства выборки.

Мы предлагаем использовать три интуитивно интерпретируемых кластера:

- 1) L (Low) / SL (Seasonal Low) – низкая волатильность;
- 2) M (Medium) / SM (Seasonal Medium) – средняя волатильность;
- 3) H (High) / SH (Seasonal High) – высокая волатильность.

Границы кластеров, определённые по результатам кластеризации, при необходимости могут быть сглажены до удобных порогов (например, $CV < 0.3$ для категории L, $0.3 \leq CV \leq 0.8$ для M, $CV > 0.8$ для H). Параметры кластеризации рассматриваются как настраиваемые и подлежат анализу чувствительности.

В основе предложенного одношагового алгоритма распределения оборотного капитала лежит интегральный показатель – индекс доходности R_i :

$$R_i = T_i \cdot M_i. \quad (5)$$

где T_i – коэффициент оборачиваемости, M_i – маржинальная рентабельность.

Алгоритм распределения оборотного капитала включает следующие шаги [1]:

1. Определяется объём свободных финансовых ресурсов F_0 , заполняется таблица исходных данных: T_i , M_i , прогнозный объём продаж S_i , R_i .
2. Товары упорядочиваются по убыванию R_i .
3. Для каждого товара определяется минимальный запас $N_{i,\min}$, закупочная стоимость единицы товара F_i , вычисляется стоимость минимального запаса $N_{i,\min} \cdot F_i$. Рассчитывается суммарная потребность в финансовых ресурсах на закупку минимального запаса:

$$F_{\min} = \sum_{i=1}^A N_{i,\min} \cdot F_i \quad (6)$$

и остаток ресурсов для распределения:

$$F = F_0 - F_{\min}. \quad (7)$$

4. Для товара с текущим приоритетом i вычисляется количество единиц для дополнительной закупки:

$$w = \text{round}\left(\frac{F}{F_i}\right). \quad (8)$$

Если $w < 1$, алгоритм завершается. Иначе объём закупки определяется по правилу:

$$N_i = \begin{cases} N_{i,\min} + w, & \text{если } N_{i,\min} + w \leq S_i, \\ S_i, & \text{иначе.} \end{cases} \quad (9)$$

5. Обновляется остаток ресурсов по формуле:

$$F = F - F_i \cdot (N_i - N_{i,\min}), \quad (10)$$

после чего переход осуществляется к следующему товару.

Для учёта волатильности и сезонности целевой уровень запаса S_i корректируется в зависимости от класса риска:

$$S_i = N_{i,\min} + k_c \cdot \sigma_i^{(\text{prog})}, \quad (11)$$

где $\sigma_i^{(\text{prog})}$ – оценка стандартного отклонения прогнозного спроса, а k_c – коэффициент, зависящий от кластерной принадлежности (L, M, H).

Вводятся портфельные ограничения на суммарную долю бюджета, направляемого в высоковолатильные кластеры (например, H/SH), что позволяет ограничивать совокупный риск портфеля. Параметры k_c и пороговые доли бюджета рассматриваются как настраиваемые и подлежат последующей калибровке.

С вычислительной точки зрения алгоритм распределения капитала представляет собой однопроходную процедуру по упорядоченному списку товарных позиций. На этапе предварительной сортировки по индексу доходности R_i используется стандартный алгоритм сортировки со сложностью $O(n \log n)$, где n – число SKU; последующие итерации по списку выполняются за линейное время $O(n)$, поскольку каждая SKU обрабатывается не более одного раза. Таким образом, суммарная вычислительная сложность алгоритма составляет $O(n \log n)$. Алгоритм всегда завершается не более чем за n итераций, так как на каждом шаге либо полностью исчерпывается свободный бюджет F , либо индекс позиции i монотонно увеличивается, и при $i > n$ дальнейшее распределение становится невозможным при любом значении F .

На основе описанных процедур для каждой пары (SKU, период) формируется структурированный вектор признаков, объединяющий характеристики спроса, неопределённости и экономические параметры. Он служит единым формальным описанием состояния товарной позиции и используется в алгоритмах распределения оборотного капитала, а также как кандидат на пространство состояний для последующего применения в стохастических и динамических моделях управления запасами. Основные компоненты вектора представлены в таблице 1.

Дизайн вычислительных экспериментов. Поскольку в настоящей статье делается акцент на методологической составляющей, количественная верификация выносится в отдельный этап. Планируется проведение вычислительных экспериментов, включающих:

- сравнение точности прогнозов DLinear, NLinear, XGBoost и базовых статистических моделей на реальных данных селлеров маркетплейсов;
- верификацию корректности классификации сезонности по *SeasonShare* и автокорреляционной функции ACF;
- оценку устойчивости кластеров волатильности при изменении временного окна анализа;
- сравнение алгоритма распределения капитала с альтернативными стратегиями (по маржинальности, по оборачиваемости, по ABC-классификации) по показателям прибыли, рентабельности и дисперсии результата;
- анализ чувствительности по ключевым параметрам методики: порогу *SeasonShare* θ_s , границам кластеров, коэффициентам k_c и портфельным ограничениям.

Таблица 1. Структурированный вектор признаков

Признак	Описание
$\hat{y}$	Прогнозный спрос (точечная оценка)
CI_{low}, CI_{high}	Границы доверительного интервала прогноза
<i>SeasonShare</i>	Доля вариации, объясняемая сезонностью
is_seasonal	Бинарный флаг сезонности (0/1)
$CV^{(orig)}$	Коэффициент вариации исходного ряда
$CV^{(adj)}$	Коэффициент вариации сезонно–скорректированного ряда
cluster_label	Кластер волатильности (L/M/H или SL/SM/SH)
T_i	Оборачиваемость
M_i	Маржинальная рентабельность
R_i	Индекс доходности
$N_{i,min}$	Минимальный уровень запаса
S_i	Целевой (рекомендуемый) уровень запаса

Для оценки статистической значимости различий в качестве прогнозов могут использоваться критерии для сравнения прогнозных моделей, в частности тест Диболда-Мариано, с учётом поправок на множественные сравнения. Для оценки устойчивости кластеризации планируется использовать показатели внутреннего качества кластеров (например, силуэтный коэффициент) и долю сохраняющих кластерную принадлежность позиций при смещении окна анализа.

Обсуждение и заключение. Предложенная методика интегрирует методы анализа временных рядов, стохастические представления о спросе и алгоритм распределения оборотного капитала. Использование STL-декомпозиции, пары коэффициентов вариации и адаптивной кластеризации позволяет отделять регулярный сезонный компонент от остаточной волатильности, что важно для построения устойчивых решений в задачах управления запасами.

Предложенный алгоритм распределения капитала на основе индекса доходности, дополненный учётом прогнозного спроса, кластеризации по волатильности и портфельных ограничений, не выводится как строго оптимальное решение конкретной стохастической задачи. Его следует рассматривать, как структурированную эвристику, использующую агрегированные показатели доходности и риска, согласованные с классической теорией управления запасами, но адаптированные к ограничениям реальной практики (большое число SKU, ограниченные данные и вычислительные ресурсы). Такая постановка позволяет, с одной

стороны, улучшить качество решений по сравнению с простыми однокритериальными правилами, а с другой – подготовить основу для последующего перехода к более строгим стохастическим и DRL-моделям.

Статья носит методологический характер, она не предъявляет экспериментально подтверждённые выводы об оптимальности предложенного подхода, а задаёт формальную рамку, алгоритмическую структуру и программу последующей верификации. Научная значимость работы состоит в интеграции современных методов анализа временных рядов и идей стохастического управления запасами в прикладной задаче распределения оборотного капитала на маркетплейсах. Практическая значимость заключается в возможности реализации предложенной методики в составе систем поддержки принятия решений для продавцов.

Список источников

1. Бастанов А.Э. Оптимизация распределения оборотного капитала продавца на электронных маркетплейсах: алгоритмический подход на основе интегрального показателя / А.Э. Бастанов, И.В. Ахметов // Информационные технологии интеллектуальной поддержки принятия решений ITIDS'2025: труды XI Международной научной конференции. – Уфа: Уфимский университет науки и технологий, 2025. – Т. 1-2.
2. Дзури К. Управленческий и производственный учет; пер. с англ. – М.: ЮНИТИ-ДАНА, 2002. – 1071 с.
3. Стратегии, которые работают: подход BCG: сб. ст.; пер. с англ.; сост. К. Штерн, Д. Сток-мл. – 2-е изд. – М.: Манн, Иванов и Фербер, 2007. – 496 с.
4. Интрилигатор М.М. Математические методы оптимизации и экономическая теория; пер. с англ. – М.: Айрис-пресс, 2002. – 576 с.
5. Makridakis S., Spiliotis E., Assimakopoulos V. Statistical and machine learning forecasting methods: concerns and ways forward. PLOS ONE, 2018, vol. 13, no. 3, e0194889, DOI: 10.1371/journal.pone.0194889.
6. Хомяченко О.В. Технология маркетинга на фирме. Экономический аспект. – М.: МЦФЭР, 1996.
7. Балашов В.Г. Технологии повышения финансового результата: практика и методы / В.Г. Балашов, В.А. Ириков. – М.: МЦФЭР, 2006. – 672 с.
8. Abolghasemi M. et al. Demand forecasting in supply chain: the impact of demand volatility in the presence of promotion. Computers & Industrial Engineering, 2020, vol. 142, p. 106380, DOI: 10.1016/j.cie.2020.106380.
9. Zeng A., Chen M., Zhang L., Xu Q. Are transformers effective for time series forecasting? Proceedings of the AAAI Conference on Artificial Intelligence, 2023, vol. 37, no. 9, pp. 11121-11128, DOI: 10.1609/aaai.v37i9.26317.
10. Brigato L., Morand R., Strømmen K. et al. Position: there are no champions in long-term time series forecasting. arXiv preprint arXiv:2502.14045, 2025, DOI:10.48550/arXiv.2502.14045.
11. Kim J., Kim H., Kim HG. et al. A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges. Artificial Intelligence Review, 2025, vol. 58, no. 7, p. 216, DOI: 10.48550/arXiv.2411.05793.
12. Sarisa M. et al. An effective predicting e-commerce sales & management system based on machine learning methods. Journal of Artificial Intelligence and Big Data, 2020, vol. 1, no. 1, pp. 75–85, DOI:10.31586/jaibd.2020.1110.
13. Balusani A., Jai Ram Chowdary P., Paruchuri B.V.N. Enhancing retail demand forecasting with Xgboost: a comparative study with machine learning and deep learning models, DOI:10.2139/ssrn.5274510
14. Ji S., Wang X., Zhao W. et al. An application of a three-stage XGBoost-based model to sales forecasting of a cross-border e-commerce enterprise. Mathematical Problems in Engineering, 2019, vol. 2019, p. 8503252 (15 pages), DOI: 10.1155/2019/8503252.
15. Perera S.C., Sethi S.P. A survey of stochastic inventory models with fixed costs: optimality of (s, S) and (s, S)-type policies—continuous-time case. Production and Operations Management, 2023, vol. 32, no. 1, pp. 154-169, DOI:10.1111/poms.13819.
16. Ban G.-Y., Rudin C. The big data newsvendor: practical insights from machine learning. Operations Research, 2018, vol. 67, DOI:10.1287/opre.2018.1757.
17. Shi J. Application of the model combining demand forecasting and inventory decision in feature based newsvendor problem. Computers & Industrial Engineering, 2022, vol. 173, p. 108709, DOI: 10.1016/j.cie.2022.108709.
18. Gijsbrechts J., Boute R., Zhang D. Can deep reinforcement learning improve inventory management? performance on lost sales, dual-sourcing, and multi-echelon problems. Manufacturing & Service Operations Management, 2022, vol. 24, DOI: 10.1287/msom.2021.1064.

19. Dehaybe H., Catanzaro D., Chevalier P. Deep reinforcement learning for inventory optimization with non-stationary uncertain demand. *European Journal of Operational Research*, 2023, vol. 314, DOI: 10.1016/j.ejor.2023.10.007.
20. Хайндман Р. Прогнозирование: принципы и практика / Р. Хайндман, Д. Атанасопулос. – Москва: ДМК Пресс, 2023. – 459 с.

Бастанов Артур Эмилевич. Кандидат экономических наук, преподаватель кафедры экономики предпринимательства, Уфимский университет науки и технологий. AuthorID: 1329354, SPIN: 8314-0561, ORCID: 0009-0000-5922-2220, gradinv@gmail.com, Россия, Республика Башкортостан, Уфа, ул. Карла Маркса, 12.

UDC 658.7

DOI:10.25729/ESI.2026.43.3.012

Intelligent demand analysis and working capital allocation optimization for sellers on electronic marketplaces: methodological foundation, algorithm and design of experiments

Arthur E. Bastanov

Ufa University of Science and Technology, Russia, Ufa, gradinv@gmail.com

Abstract. The article presents the methodological outcome of the first stage of a research program aimed at improving inventory and working capital management for sellers operating on electronic marketplaces. The relevance of the study stems from the fact that practical tasks of allocating limited working capital across numerous product items are solved under conditions of stochastic demand, pronounced seasonality, heterogeneous volatility and constrained computational resources, whereas traditional inventory management methods either remain static or require a priori specification of demand and cost parameters. The paper proposes a comprehensive methodology for demand analysis and working capital allocation that comprises three related components: intelligent demand analysis based on seasonal-trend decomposition and machine learning models for time series (DLinear, NLinear, XGBoost); extended analysis of demand volatility using two variants of the coefficient of variation and adaptive clustering of the assortment matrix; and a working capital allocation algorithm built on an integral «profitability index» and supplemented by seasonality- and risk-aware adjustments. A key element of the methodology is the separation of predictable seasonal variation from residual volatility, which enables more accurate assessment of the risk associated with individual product items and the use of these risk estimates in working capital allocation decisions. The methodology yields a structured feature vector that includes forecast, statistical and economic characteristics of product items and is suitable both for one-step decision-support systems and as a state-space representation for subsequent stochastic and dynamic inventory control models. The scientific contribution of the work lies in integrating known tools for forecasting, volatility assessment and working capital allocation into a single mathematically consistent methodological model that accounts for the specifics of electronic marketplaces and the particular constraints faced by sellers. The article substantiates the proposed methodology, describes its architecture and presents the design of computational experiments intended for subsequent empirical evaluation of its effectiveness.

Keywords: marketplace, seller, demand forecasting, seasonality, coefficient of variation, profitability index, inventory management, working capital management, machine learning methods

References

1. Batanov A.E., Akhmetov I.V. Optimizatsiya raspredeleniya oborotnogo kapitala seller na elektronnykh marketpleysakh: algoritmicheskiy podkhod na osnove integral'nogo pokazatelya [Optimization of seller's working capital allocation on e-marketplaces: an algorithmic approach based on an integral indicator]. *Informatsionnyye tekhnologii intellektual'noy podderzhki prinyatiya resheniy ITIDS'2025: Trudy XI Mezhdunarodnoy nauchnoy konferentsii* [Information Technologies for Intelligent Decision Support ITIDS'2025: Proceedings of the XI International Scientific Conference]. Ufa, Ufa University of Science and Technology Publ., 2025, vols. 1-2.
2. Drury C. Upravlencheskiy i proizvodstvennyy uchet [Management and cost accounting]. Trans. from English. Moscow, UNITI-DANA Publ., 2002, 1071 p.

3. Stern C., Stalk G. (eds.). Strategii, kotoryye rabotayut: podkhod BCG [Strategies that work: the BCG approach]. Trans. from English. 2nd ed. Moscow, Mann, Ivanov i Ferber Publ., 2007, 496 p.
4. Intriligator M.M. Matematicheskiye metody optimizatsii i ekonomicheskaya teoriya [Mathematical optimization and economic theory]. Trans. from English. Moscow, Ayris-press Publ., 2002, 576 p.
5. Makridakis S., Spiliotis E., Assimakopoulos V. Statistical and machine learning forecasting methods: concerns and ways forward. PLOS ONE, 2018, vol. 13, no. 3, e0194889, DOI: 10.1371/journal.pone.0194889.
6. Khomyachenko O.V. Tekhnologiya marketinga na firme. Ekonomicheskiy aspekt [Marketing technology in a firm. Economic aspect]. Moscow, MTsFER Publ., 1996.
7. Balashov V.G., Irikov V.A. Tekhnologii povysheniya finansovogo rezul'tata: praktika i metody [Technologies for improving financial performance: practice and methods]. Moscow, MTsFER Publ., 2006, 672 p.
8. Abolghasemi M. et al. Demand forecasting in supply chain: the impact of demand volatility in the presence of promotion. Computers & Industrial Engineering, 2020, vol. 142, p. 106380, DOI: 10.1016/j.cie.2020.106380.
9. Zeng A., Chen M., Zhang L., Xu Q. Are transformers effective for time series forecasting? Proceedings of the AAAI Conference on Artificial Intelligence, 2023, vol. 37, no. 9, pp. 11121-11128, DOI: 10.1609/aaai.v37i9.26317.
10. Brigato L., Morand R., Strømmen K. et al. Position: there are no champions in long-term time series forecasting. arXiv preprint arXiv:2502.14045, 2025, DOI:10.48550/arXiv.2502.14045.
11. Kim J., Kim H., Kim HG. et al. A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges. Artificial Intelligence Review, 2025, vol. 58, no. 7, p. 216, DOI: 10.48550/arXiv.2411.05793.
12. Sarisa M. et al. An effective predicting e-commerce sales & management system based on machine learning methods. Journal of Artificial Intelligence and Big Data, 2020, vol. 1, no. 1, pp. 75–85, DOI:10.31586/jaibd.2020.1110.
13. Balusani A., Jai Ram Chowdary P., Paruchuri B.V.N. Enhancing retail demand forecasting with Xgboost: a comparative study with machine learning and deep learning models, DOI:10.2139/ssrn.5274510
14. Ji S., Wang X., Zhao W. et al. An application of a three-stage XGBoost-based model to sales forecasting of a cross-border e-commerce enterprise. Mathematical Problems in Engineering, 2019, vol. 2019, p. 8503252 (15 pages), DOI: 10.1155/2019/8503252.
15. Perera S.C., Sethi S.P. A survey of stochastic inventory models with fixed costs: optimality of (s, S) and (s, S)-type policies—continuous-time case. Production and Operations Management, 2023, vol. 32, no. 1, pp. 154-169, DOI:10.1111/poms.13819.
16. Ban G.-Y., Rudin C. The big data newsvendor: practical insights from machine learning. Operations Research, 2018, vol. 67, DOI:10.1287/opre.2018.1757.
17. Shi J. Application of the model combining demand forecasting and inventory decision in feature based newsvendor problem. Computers & Industrial Engineering, 2022, vol. 173, p. 108709, DOI: 10.1016/j.cie.2022.108709.
18. Gijbrecchts J., Boute R., Zhang D. Can deep reinforcement learning improve inventory management? performance on lost sales, dual-sourcing, and multi-echelon problems. Manufacturing & Service Operations Management, 2022, vol. 24, DOI: 10.1287/msom.2021.1064.
19. Dehaybe H., Catanzaro D., Chevalier P. Deep reinforcement learning for inventory optimization with non-stationary uncertain demand. European Journal of Operational Research, 2023, vol. 314, DOI: 10.1016/j.ejor.2023.10.007.
20. Hyndman R., Athanasopoulos G. Prognozirovaniye: printsipy i praktika [Forecasting: principles and practice]. Moscow, DMK Press Publ., 2023, 459 p.

Bastanov Artur Emilievich. PhD in economics of the department of economics of entrepreneurship, Ufa university of sciences and technologies, gradinv@gmail.com. AuthorID: 1329354, SPIN: 8314-0561, ORCID: 0009-0000-5922-2220, gradinv@gmail.com, Russia, Republic of Bashkortostan, Ufa, Karl Marx St., 12.

Статья поступила в редакцию 23.01.2026; одобрена после рецензирования 11.03.2026; принята к публикации 02.08.2026.

The article was submitted 01/23/2026; approved after reviewing 03/11/2026; accepted for publication 08/02/2026.