

**ОБ ОДНОМ ПОДХОДЕ К ПРИОРИТИЗАЦИИ СТРАТЕГИЙ
ДИНАМИЧЕСКОГО ЦЕНООБРАЗОВАНИЯ НА МАРКЕТПЛЕЙСАХ****Тхориков Б. А., Семенов Б. В.***Федеральное государственное бюджетное образовательное учреждение высшего образования
«Российский государственный университет имени А. Н. Косыгина», Москва,
Российская Федерация, e-mail: bog.semenov2015@yandex.ru*

Ассортимент крупного маркетплейса неоднороден по двум независимым измерениям, вкладу позиций в выручку и предсказуемости спроса, поэтому единая ценовая политика к нему неприменима. Цель исследования – построить классификацию стратегий динамического ценообразования по сегментам матрицы ABC-XYZ и предложить формализованную методику их приоритизации при ограниченном инженерном и аналитическом ресурсе команды ценообразования. Описаны три стратегии, покрывающие основные типы сегментов: соинвестирование скидок на товары-локомотивы, ценообразование товаров с коротким остаточным сроком годности и ступенчатая уценка deadstock; для каждой указаны источники данных, расчетная логика и условия применимости, построена матрица их соответствия девяти сегментам ABC-XYZ. Для задачи выбора порядка внедрения предложена модифицированная методика ICE-скоринга (Impact, Confidence, Ease) с декомпозицией компонентов на измеримые метрики, привязанные к конкретным системам-источникам, переходом от среднего арифметического к мультипликативной свертке и калибровкой весов на исторических A/B-тестах крупного омниканального маркетплейса. На данных одной товарной категории получено ранжирование трех стратегий; анализ чувствительности к вариации весов в диапазоне $\pm 25\%$ подтвердил устойчивость порядка. Структура расчета переносима между платформами при условии независимой калибровки весов на собственных исторических данных.

Ключевые слова: динамическое ценообразование, маркетплейсы, ABC-XYZ, соинвестирование скидок, deadstock, ICE-скоринг, A/B-тестирование**AN APPROACH TO PRIORITISING DYNAMIC PRICING
STRATEGIES IN E-COMMERCE MARKETPLACES****Tkhorikov B. A., Semenov B. V.***Federal State Budgetary Educational Institution of Higher Education
“Russian State University named after A. N. Kosygin”, Moscow,
Russian Federation, e-mail: bog.semenov2015@yandex.ru*

A large marketplace assortment is heterogeneous along two independent dimensions – revenue contribution and demand predictability – and therefore cannot be managed by a single pricing policy. The purpose of the study is to build a classification of dynamic pricing strategies by segments of the ABC-XYZ matrix and to propose a formalised methodology for their prioritisation under the limited engineering and analytical resources of the pricing team. Three strategies covering the main segment types are described: discount co-investment for flagship items, perishable pricing for goods with a short remaining shelf life, and stepwise deadstock markdown; for each strategy data sources, decision logic, and applicability conditions are specified, and a mapping of strategies to the nine ABC-XYZ segments is built. For the rollout-order problem a modified ICE scoring methodology (Impact, Confidence, Ease) is proposed, involving the decomposition of components into measurable metrics linked to specific source systems, a switch from arithmetic mean to multiplicative aggregation, and calibration of weights on historical A/B tests of a large omnichannel marketplace. Applied to anonymised data of one product category, the method yields a ranking of the three strategies; sensitivity analysis under weight perturbations of $\pm 25\%$ confirms the stability of the order. The calculation structure is portable across platforms provided that weights are independently calibrated on each platform's own historical data.

Keywords: dynamic pricing, e-commerce marketplaces, ABC-XYZ, discount co-investment, deadstock, ICE scoring, A/B testing**Введение**

Электронная коммерция в России и мире развивается интенсивно: годовой оборот ведущих платформ исчисляется триллионами рублей, а доля онлайн-продаж в розничном товарообороте устойчиво растет. В этих условиях ценообразование перестает быть разовой задачей выставления прайс-листа и становится непрерывным управленческим процессом, в котором цена пересчитывается с шагом, близким к реальному времени, и должна одновременно учи-

тывать конкурентную ситуацию, складские запасы, прогноз спроса и коммерческие ограничения [1].

Ассортимент крупного маркетплейса неоднороден: товары-локомотивы, сезонные позиции, скоропортящиеся товары и неликвиды требуют разной ценовой логики, а единая механика для всех ведет к потере выручки или замораживанию оборотного капитала [1; 2]. В литературе известны отдельные ценовые механики – соинвестирование скидок [3], ценообразование с истека-

ющим сроком годности, ступенчатая уценка неликвидов, однако они рассматриваются изолированно, без процедуры выбора механики под сегмент и формализованной приоритизации внедрения [4; 5]. Отсюда проблема: при наличии нескольких потенциально ценных инициатив команда не имеет воспроизводимой процедуры обоснования квартального плана их внедрения. Применяемые в продуктовой практике методы приоритизации, в том числе ICE-скоринг, создавались для быстрой неформальной оценки и слабо подходят для обоснования крупных решений перед руководством.

Научная новизна подхода состоит в объединении двух ранее не связанных линий работы: сегментации ассортимента методами ABC-XYZ анализа [6] и количественной приоритизации проектов методом ICE-скоринга. В результате формируется единая процедура, отвечающая на два вопроса одновременно: какая ценовая стратегия применима к данному сегменту и в каком порядке стратегии следует внедрять при ограниченных ресурсах команды.

Цель исследования – построить классификацию стратегий динамического ценообразования по сегментам матрицы ABC-XYZ и предложить формализованную методику их приоритизации при ограниченном инженерном и аналитическом ресурсе команды ценообразования.

Материалы и методы исследования

Методика опирается на данные внутренних систем маркетплейса: OMS – история транзакций и маржинальности; WMS – складские остатки и оборачиваемость; CRM – клиентское поведение и пожизненная ценность клиента (LTV) [4]; сервис парсинга конкурентов; платформа A/B-тестирования. Привязка каждого под-

компонента расчета к конкретной системе-источнику обеспечивает воспроизводимость скоринга: два аналитика с доступом к одним и тем же системам получают одинаковые входные значения [7]. Под deadstock понимаются товары, длительно не находящие спроса; под ОСГ – товары с лимитирующим остаточным сроком годности.

В основу дифференциации положена методология ABC-XYZ анализа [6]: ABC распределяет товары по вкладу в выручку (А – локомотивы, В – средний приоритет, С – низкий вклад), XYZ – по прогнозируемости спроса (Х – стабильный, Y – сезонный, Z – спорадический). Прогнозирование сезонной компоненты опирается на методы декомпозиции временных рядов и подходы машинного обучения [8, с. 178–215; 9]. Совмещение двух классификаций дает матрицу из девяти сегментов, служащую основой для назначения дифференцированных ценовых стратегий (табл. 1).

Три стратегии для типичных сегментов ассортимента

Соинвестирование скидок (сегменты AX, AY, частично BX) – конечная цена формируется через совместное распределение затрат на скидку между продавцом и маркетплейсом, что снимает конфликт стимулов: продавец вкладывается в рамках собственной маржинальности, платформа добавляет дисконт за счет собственного скидочного бюджета. Механика опирается на парсинг цен конкурентов, расчет индекса цен и оптимизацию бюджета по критерию максимума прироста выручки на рубль инвестированной скидки [3]. Сходные подходы применяют международные (Amazon, Walmart Marketplace) и российские (Ozon, Wildberries, Яндекс Маркет) площадки [5].

Таблица 1

Соответствие стратегий динамического ценообразования сегментам ABC-XYZ

Сегмент	Характеристика	Приоритетная стратегия
AX	Высокая выручка, стабильный спрос	Соинвестирование скидок
AY	Высокая выручка, сезонные колебания	Соинвестирование с сезонной активацией
AZ	Высокая выручка, непредсказуемый спрос	Соинвестирование с осторожностью
BX	Средняя выручка, стабильный спрос	Соинвестирование (второй приоритет)
BY	Средняя выручка, сезонные колебания	Сезонное соинвестирование
BZ	Средняя выручка, спорадический спрос	Мониторинг перехода в deadstock
CX	Низкая выручка, стабильный спрос	Минимальное вмешательство
CY	Низкая выручка, сезонные колебания	Превентивная уценка deadstock
CZ	Низкая выручка, отсутствие спроса	Активная уценка deadstock

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Ценообразование товаров с истекающим ОСГ (FMCG, фармацевтика, косметика) – оптимальная цена определяется не только рыночной ситуацией, но и прогнозируемой убылью стоимости товара по мере приближения даты истечения срока [10]. Алгоритм идентифицирует партии с прогнозируемым переостатком (декомпозиция временного ряда продаж) и рассчитывает скидку с учетом остаточного срока, эластичности спроса и минимально допустимой маржинальности; общая постанова укладывается в рамках оптимизации запасов скоропортящихся товаров [11].

Ступенчатая уценка deadstock (сегменты CY, CZ, BZ) – управление товарами, длительно не находящимися спроса [12]. Неликвиды идентифицируются по комбинации критериев (отсутствие продаж 60–120 дней, дисбаланс остатков и спроса, отрицательная динамика, высокий показатель отказов); далее применяется ступенчатая уценка: 10–15 % на 0–30 дней без продаж; 20–30 % на 30–60 дней; 40–50 % на 60–90 дней с приоритизацией позиции в рекомендательных алгоритмах платформы; 70–80 % свыше 90 дней – ликвидационная уценка для высвобождения складских мощностей [12].

Для товаров с ограничением срока годности поверх сегментации применяется ОСГ-стратегия с приоритетом выше любой другой, поскольку временной фактор в таких категориях создает риск полного списания партии. Назначение стратегии сегменту – необходимое, но недостаточное условие внедрения: на практике возникает задача выбора порядка реализа-

ции нескольких применимых стратегий, что требует отдельной формализованной процедуры.

Модифицированная методика ICE-скоринга

Стандартный ICE-скоринг [13, с. 156–162] ($\text{Impact} \times \text{Confidence} \times \text{Ease}$, среднее арифметическое от 1 до 10) для задачи приоритизации ценовых стратегий имеет три ограничения. Оценки субъективны и плохо воспроизводимы: два аналитика могут поставить разные баллы одной стратегии. Среднее арифметическое не различает «все среднее» и «два высоких компонента и один близкий к нулю», что критично, когда отсутствие данных для одного компонента должно блокировать запуск. Стандартная методика не различает источники уверенности (интуиция против результата A/B-теста), смешивая в одной оценке разный уровень обоснованности [14].

Предлагаемая модификация включает три изменения: декомпозицию каждого компонента на измеримые подкомпоненты, привязанные к конкретным системам-источникам; переход от среднего арифметического к мультипликативной свертке, нелинейно пенализующей стратегии с критически слабым звеном; явный учет качества данных через подкомпоненты Confidence, разделяющие интуитивную и эмпирически подтвержденную уверенность.

Impact (I) – взвешенная сумма четырех нормированных метрик; Confidence (C) – четырех показателей качества данных; Ease (E) – оценка ресурсоемкости:

$$I = \alpha_1 \cdot \Delta \text{Rev} + \alpha_2 \cdot \Delta \text{Margin} + \alpha_3 \cdot \Delta \text{LTV} + \alpha_4 \cdot \Delta \text{Inventory}, \quad (1)$$

$$C = \beta_1 \cdot D(\text{market}) + \beta_2 \cdot D(\text{research}) + \beta_3 \cdot D(\text{pilot}) + \beta_4 \cdot D(\text{benchmark}), \quad (2)$$

где ΔRev (прирост выручки) и ΔMargin (изменение маржинальности) рассчитываются по данным OMS, ΔLTV – по CRM, $\Delta \text{Inventory}$ (эффект на оборачиваемость запасов) – по WMS; все метрики приводятся к шкале [0, 1] методом min-max нормализации внутри сравниваемого набора стратегий. Подкомпоненты Confidence: $D(\text{market})$ – наличие сопоставимой механики у конкурентов (сервис парсинга); $D(\text{research})$ – глубина внутреннего качественного анализа (интервью с категорийными менеджерами); $D(\text{pilot})$ – наличие результатов предварительного A/B-теста сходной механики (платформа A/B); $D(\text{benchmark})$ – публичные кейсы и отраслевые отчеты [14]. Каждый подкомпонент

Confidence оценивается по шкале [0, 1] с дискретными уровнями 0 / 0,5 / 1.

Компонент Ease (E) формализуется через совокупные нормированные затраты на реализацию по линейной шкале:

$$E = 1 - (\gamma_1 \cdot H + \gamma_2 \cdot T + \gamma_3 \cdot R), \quad (3)$$

где H – нормированные трудозатраты команд разработки и аналитики (человеко-месяцы), T – техническая сложность интеграции (число систем-источников, требующих доработки), R – операционные риски (экспертная оценка вероятности негативного воздействия на смежные процессы); все три величины нормированы на [0, 1], так что E также лежит в [0, 1] и растет по мере снижения затрат.

Три компонента сводятся в единый балл мультипликативно после линейного отображения каждого на шкалу [1, 10]:

$$\text{ICE_score} = I^* \cdot C^* \cdot E^*,$$

$$\text{где } X^* = 1 + 9 \cdot X \text{ для } X \in [0, 1]. \quad (4)$$

Мультипликативная свертка пенализирует стратегии с критически слабым звеном: стратегия с высоким Impact, но околонулевым Confidence получает низкий итоговый балл независимо от простоты реализации, поскольку произведение чувствительно к любому малому сомножителю. Это согласуется с практикой: отсутствие данных для оценки эффекта должно блокировать запуск, а не компенсироваться сильными другими компонентами.

Калибровка весовых коэффициентов

Веса откалиброваны на истории А/В-тестов крупного омниканального маркетплейса за период с января 2022 г. по декабрь 2024 г. (36 месяцев). В обучающую выборку вошли 47 пар «стратегия – категория», по которым за указанный период проводился А/В-тест с корректным дизайном (контрольная и тестовая группы, статистически значимый объем трафика). Для каждой пары рассчитаны постфактумные значения метрик из исторических данных OMS, CRM и WMS, а критерием успеха служила бинарная экспертная метка: тест считался успешным, если по итогам полугодия после запуска целевая метрика категории (выручка или маржинальная прибыль в зависимости от стратегии) показала статистически значимый прирост и решение было закреплено в продуктиве. Веса α , β , γ подобраны минимизацией логистической функции потерь при предсказании метки успешности; для контроля переобучения применялось разбиение train/test в пропорции 70/30 со стратификацией по типу стратегии и пятикратная кросс-валидация на обучающей части. На отложенной выборке коэффициент ранговой корреляции Спирмена между расчетным ICE-баллом и фактической меткой составил $\rho = 0,71$ (95 %-й бутстреп-интервал 0,58–0,82, 2000 итераций). Полученные значения:

$$\alpha_1 = 0,35; \alpha_2 = 0,25; \alpha_3 = 0,25; \alpha_4 = 0,15;$$

$$\beta_1 = 0,20; \beta_2 = 0,15; \beta_3 = 0,40; \beta_4 = 0,25;$$

$$\gamma_1 = 0,45; \gamma_2 = 0,30; \gamma_3 = 0,25.$$

Наибольший вес внутри Confidence получает наличие пилотных данных ($\beta_3 = 0,40$): результат А/В-теста сходной механики предсказывает фактический исход внедрения лучше других источников обо-

снованности [15]. Веса не универсальны и отражают профиль конкретной платформы – ее ассортиментную структуру, исторический портфель ценовых тестов и приоритеты ключевых метрик. При переносе методики на другую платформу веса калибруются заново на ее собственных исторических данных.

Результаты исследования и их обсуждение

Методика применена к данным одной товарной категории крупного федерального омниканального маркетплейса (категория непродовольственных товаров повседневного спроса). По соображениям конфиденциальности наименование категории и абсолютные значения GMV не раскрываются; приведены нормированные значения после min-max нормализации внутри сравниваемого набора. Выборка для расчета: 1842 активных SKU от 213 продавцов, период наблюдения – 18 месяцев (июль 2023 г. – декабрь 2024 г.), около 1,1 млн заказов. Распределение SKU по сегментам ABC-XYZ: на сегменты с высоким вкладом в выручку (AX, AY, AZ) приходится 9,7 % позиций и 61 % выручки категории; доля сегмента AX составляет 4,1 % позиций, BX – 7,3 %; сегменты группы C (CX, CY, CZ) объединяют 58 % позиций при 11 % выручки. Требовалось проранжировать три стратегии: S1 – соинвестирование скидок; S2 – ценообразование товаров с истекающим OCG; S3 – ступенчатая уценка deadstock. Расчет компонентов и итогового ICE-балла приведен в табл. 2; столбец «Источник» указывает, из какой системы получено каждое исходное значение.

Соинвестирование скидок (S1) получило наиболее высокий итоговый балл – 240,5 против 110,0 для S2 и 95,7 для S3. Лидерство S1 объясняется тремя факторами: наибольшим ожидаемым приростом выручки ($\Delta \text{Rev} = 0,85$, поскольку категория содержит существенную долю товаров-локомотивов), относительной простотой технической реализации (механика опирается на действующий сервис парсинга конкурентов и не требует глубокой интеграции с WMS) и доступностью внешних бенчмарков. S2 и S3 уступают S1 по всем трем компонентам; различие между ними определяется распределением сильных сторон: S2 имеет более высокий ΔMargin и более низкие риски запуска, тогда как S3 дает максимальный эффект на оборачиваемость, но требует большего объема исторических данных для калибровки индекса неликвидности.

Таблица 2

Расчет ICE-скоринга для трех стратегий в одной товарной категории

Параметр	S1: Соинвест.	S2: OCG	S3: Deadstock	Источник
ΔRev (норм.)	0,85	0,40	0,30	OMS, регрессия по истории акций
$\Delta Margin$ (норм.)	0,60	0,70	0,50	OMS, аналитика P&L категории
ΔLTV (норм.)	0,70	0,30	0,20	CRM, когортная витрина
$\Delta Inventory$ (норм.)	0,20	0,80	0,90	WMS, оборачиваемость и списания
Impact (I)	0,65	0,51	0,42	Свертка с весами α
D(market)	0,80	0,50	0,40	Сервис парсинга конкурентов
D(research)	0,50	0,50	0,30	Интервью с менеджерами
D(pilot)	0,00	0,00	0,00	Платформа A/B (пилоты не проводились)
D(benchmark)	0,80	0,50	0,50	Отраслевые отчеты, кейсы
Confidence (C)	0,44	0,30	0,25	Свертка с весами β
H (трудозатраты, норм.)	0,40	0,60	0,50	Оценка ресурс-менеджера
T (тех. сложность, норм.)	0,30	0,50	0,40	Оценка архитекторов
R (риски, норм.)	0,20	0,40	0,30	Оценка категорийной команды
Ease (E)	0,68	0,48	0,58	1 – свертка затрат с весами γ
I* (шкала 1–10)	6,87	5,59	4,74	Линейное отображение
C* (шкала 1–10)	4,92	3,70	3,25	Линейное отображение
E* (шкала 1–10)	7,12	5,32	6,22	Линейное отображение
ICE score	240,5	110,0	95,7	Произведение I* · C* · E*

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Для проверки устойчивости результата проведен анализ чувствительности: каждый весовой коэффициент α , β , γ независимо варьировался в диапазоне $\pm 25\%$ от калиброванного значения с шагом 5% (11 уровней на коэффициент), после каждой вариации веса внутри своей группы заново нормировались к сумме 1, чтобы сохранить интерпретируемость свертки. Всего рассчитана 1331 комбинация. Порядок ранжирования $S1 > S2 > S3$ сохранился в 100% комбинаций; минимальный относительный разрыв между $S1$ и $S2$ по итоговому баллу не опускался ниже 78% . Команда ценообразования может опираться на полученное ранжирование, не опасаясь, что небольшие изменения калибровки весов на свежих данных приведут к перестановке стратегий.

Нулевые значения подкомпонента D(pilot) во всех строках расчета отражают то, что на момент анализа в данной категории не был проведен ни один A/B-тест рассматриваемых ценовых механик – типичная ситуация для категорий, где ранее не запускались сложные ценовые инициативы. Методика прямо указывает, что любое из трех решений будет приниматься без подтвержденной эмпирики; первой задачей команды должно стать не масштабное развертывание победившей стратегии, а проведение ее A/B-теста на ограниченной доле трафика. После пилота D(pilot) для $S1$ поднимется

с 0 до 0,5 или 1, Confidence пересчитается, и итоговый ICE-балл вырастет, что даст основания для дальнейшего расширения.

Практические и правовые ограничения

Применение методики ограничено рядом отраслевых и правовых факторов. Для FMCG и особенно фармацевтики уценка по остаточному сроку годности допустима только в пределах, разрешенных санитарными и отраслевыми нормами; реализация лекарственных средств подлежит дополнительному регулированию, а ряд позиций не допускает дисконтных механик в принципе. Использование LTV и клиентских данных CRM для дифференциации цен ограничено законодательством о персональных данных (в России – Федеральным законом № 152-ФЗ) и требованиями к недискриминированному ценообразованию: персонализированные скидки не должны превращаться в ценовую дискриминацию защищенных групп потребителей. Приоритизация уценяемых позиций в рекомендательных алгоритмах платформы должна быть прозрачна и не вводить покупателя в заблуждение относительно оснований показа. Наконец, соинвестирование скидок между продавцом и маркетплейсом требует корректного договорного оформления распределения затрат во избежание претензий со стороны продавцов и антимонопольных рисков. Перечис-

ленные ограничения не отменяют методику, но задают границы ее применимости и должны учитываться на этапе внедрения.

Заключение

Предложена классификация стратегий динамического ценообразования по сегментам матрицы ABC-XYZ и формализованная методика их приоритизации на базе модифицированного ICE-скоринга. Декомпозиция компонентов на измеримые подкомпоненты, привязанные к OMS, WMS, CRM, сервису парсинга конкурентов и платформе A/B-тестов, обеспечивает воспроизводимость оценки; мультипликативная свертка нелинейно штрафует стратегии со слабым звеном; явный учет качества данных через подкомпоненты Confidence отделяет уверенность, основанную на пилоте, от интуитивной.

Весы α , β , γ откалиброваны на 47 A/B-тестах крупного омниканального маркетплейса за 2022–2024 гг. с ранговой корреляцией $\rho = 0,71$ между расчетным баллом и фактической меткой успешности на отложенной выборке. На приведенном анонимизированном примере методика дала порядок $S1 > S2 > S3$, сохранившийся во всех (1331) комбинациях при вариации весов $\pm 25\%$; для подтверждения вывода требуются пилотные A/B-тесты, на что указывают нулевые значения $D(\text{pilot})$. Структура расчета переносима между платформами при условии независимой калибровки весов на собственных исторических данных. Дальнейшие направления: расширение состава стратегий (персонализированные скидки, динамические купоны, перекрестные продажи) и автоматизация пересчета ICE-балла по данным внутренних систем с сохранением ручной только экспертной части оценки.

Список литературы

1. Kopalle P. K., Pauwels K., Akella L. Y., Gangwar M. Dynamic pricing: Definition, implications for managers, and future research directions // *Journal of Retailing*. 2023. Vol. 99. Is. 4. P. 580–593. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0022435923000544> (дата обращения: 15.05.2026). DOI: 10.1016/j.jretai.2023.11.003.
2. Neubert M. A Systematic Literature Review of Dynamic Pricing Strategies // *International Business Research*. 2022. Vol. 15. Is. 4. P. 1–17. URL: <https://www.ccsenet.org/journal/index.php/ibr/article/view/0/46903> (дата обращения: 15.05.2026). DOI: 10.5539/ibr.v15n4p1.
3. Schlosser R., Boissier M. Dynamic Pricing Under Competition on Online Marketplaces: A Data-Driven Approach // *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2018. P. 705–714. URL: <https://dl.acm.org/doi/10.1145/3219819.3219833> (дата обращения: 15.05.2026). DOI: 10.1145/3219819.3219833.
4. Чачис Д. Ю. Искусственный интеллект в динамическом ценообразовании и разработке персонализированных предложений // *Вестник науки* 2025. Т. 3. № 12 (93). С. 1423–1427. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-dinamicheskom-tsenoobrazovanii-i-razrabotke-personalizirovannyh-predlozheniy> (дата обращения: 15.05.2026).
5. Устинов Д. А., Емельянец Д. О., Дуров И. В., Татаринов А. С. Автоматизация ценообразования в ритейле с применением машинного обучения // *Univsum: технические науки*. 2024. № 6 (123). С. 20–26. URL: <https://univsum.com/ru/tech/archive/item/17762> (дата обращения: 15.05.2026).
6. Lagoda L., Klumpp M. Efficient Warehouse and Inventory Management: The Modified ABC XYZ Analysis as a Framework to Integrate Demand Forecasting and Inventory Control // *Dynamics in Logistics*. LDIC 2024. Springer, Cham, 2024. P. 390–405. URL: https://link.springer.com/chapter/10.1007/978-3-031-56826-8_30 (дата обращения: 15.05.2026). DOI: 10.1007/978-3-031-56826-8_30.
7. Antipov E. A., Pokryshevskaya E. B. Interpretable machine learning for demand modeling with high-dimensional data using Gradient Boosting Machines and Shapley values // *Journal of Revenue and Pricing Management*. 2020. Vol. 19. Is. 5. P. 355–364. URL: <https://link.springer.com/article/10.1057/s41272-020-00236-4> (дата обращения: 15.05.2026). DOI: 10.1057/s41272-020-00236-4.
8. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021. 442 p. URL: <https://otexts.com/fpp3/> (дата обращения: 15.05.2026). ISBN 978-0-9875071-3-6.
9. Lim B., Zohren S. Time-series forecasting with deep learning: a survey // *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2021. Vol. 379. Is. 2194. Art. 20200209. URL: <https://royalsocietypublishing.org/doi/10.1098/rsta.2020.0209> (дата обращения: 15.05.2026). DOI: 10.1098/rsta.2020.0209.
10. Macías-López A., Cárdenas-Barrón L. E., Peimbert-García R. E., Mandal B. An Inventory Model for Perishable Items with Price-, Stock- and Time-Dependent Demand Rate considering Shelf-Life and Non-linear Holding Costs // *Mathematical Problems in Engineering*. 2021. Vol. 2021. Art. 6630938. URL: <https://onlinelibrary.wiley.com/doi/10.1155/2021/6630938> (дата обращения: 15.05.2026). DOI: 10.1155/2021/6630938.
11. Mohammadi Z., Barzinpour F., Teimoury E. A location-inventory model for the sustainable supply chain of perishable products based on pricing and replenishment decisions: A case study // *PLOS ONE*. 2023. Vol. 18. Is. 7. Art. e0288915. URL: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0288915> (дата обращения: 15.05.2026). DOI: 10.1371/journal.pone.0288915.
12. Loh E., Khandelwal J., Regan B., Little D. A. Pro-motheus: An End-to-End Machine Learning Framework for Optimizing Markdown in Online Fashion E-commerce // *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2022. P. 3447–3457. URL: <https://dl.acm.org/doi/10.1145/3534678.3539148> (дата обращения: 15.05.2026). DOI: 10.1145/3534678.3539148.
13. Эллис Ш., Браун М. Взрывной рост. Как современные быстрорастущие компании совершают успешный прорыв. М.: Библос, 2018. 301 с. ISBN 978-5-905641-44-2.
14. Awais M. Optimizing dynamic pricing through AI-powered real-time analytics: the influence of customer behavior and market competition // *Qlantic Journal of Social Sciences*. 2024. Vol. 5. Is. 3. P. 99–108. URL: <https://qjss.com.pk/index.php/qjss/article/view/149> (дата обращения: 15.05.2026). DOI: 10.55737/qjss.370771519.
15. Huber J., Stuckenschmidt H. Daily retail demand forecasting using machine learning with emphasis on calendar special days // *International Journal of Forecasting*. 2020. Vol. 36. Is. 4. P. 1420–1438. URL: <https://www.sciencedirect.com/science/article/pii/S0169207020300224> (дата обращения: 15.05.2026). DOI: 10.1016/j.ijforecast.2020.02.005.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.

Финансирование: Авторы заявляют об отсутствии внешнего финансирования.

Financing: The research was performed without external funding.