

# УПРАВЛЕНИЕ ЗАПАСАМИ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ТЕХНОЛОГИЧЕСКИХ КОМПАНИЙ, ИСПОЛЬЗУЮЩИХ ДАННЫЕ О ПРОДАЖАХ ВИДЕОИГР<sup>1</sup>

## ARTIFICIAL INTELLIGENCE-BASED INVENTORY MANAGEMENT FOR TECHNOLOGY COMPANIES USING VIDEO GAME SALES DATA

**Arnawtee Mohammed Mahde Mahmood  
Zaiter Murooj Fadhil Zaiter**

*Summary.* Effective inventory management within organizational systems requires reliable support for decision-making processes, especially under conditions of unstable demand and rapidly changing market environments. This paper proposes a methodological framework for a decision support system (DSS) for inventory management based on the integration of artificial intelligence models. The study focuses on the application of modern machine learning and deep learning methods for demand forecasting and inventory optimization in technology companies. Particular attention is paid to the formalization of feature selection procedures, development of predictive models, and their integration into a real-time operational DSS. The results of empirical tests using LightGBM, CatBoost, and XGBoost models demonstrate high accuracy ( $R^2$  up to 0.98) and computational efficiency in solving the problem of intelligent inventory management.

*Keywords:* decision support system, inventory management, organizational systems, machine learning, demand forecasting, artificial intelligence.

**Арновати Мохамед Мехди Махмуд**

Уральский федеральный университет, г. Екатеринбург

humodez5@gmail.com

**Заитер Муродж Фадхиль Заитер**

Уральский федеральный университет, г. Екатеринбург

muroojzaiter@gmail.com

*Аннотация.* Эффективное управление запасами в рамках организационных систем требует надежной поддержки процессов принятия решений, особенно в условиях нестабильного спроса и быстро меняющейся рыночной конъюнктуры. В данной работе предлагается методическое обеспечение системы поддержки принятия решений (СППР) по управлению запасами, основанное на интеграции моделей искусственного интеллекта. Исследование сосредоточено на применении современных методов машинного обучения и глубокого обучения для прогнозирования спроса и оптимизации запасов в технологических компаниях. Особое внимание уделено формализации процедур выбора признаков, построения прогностических моделей и их включения в СППР, функционирующую в режиме реального времени. Представлены результаты эмпирических тестов моделей LightGBM, CatBoost и XGBoost, показавших высокую точность ( $R^2$  до 0,98) и вычислительную эффективность при решении задачи интеллектуального управления запасами.

*Ключевые слова:* система поддержки принятия решений, управление запасами, организационные системы, машинное обучение, прогнозирование спроса, искусственный интеллект.

## Введение

В современных организационных системах, функционирующих в условиях цифровизации, управление запасами требует внедрения интеллектуальных решений, способных адаптироваться к динамике спроса и сложности логистических процессов. Особенно это актуально для технологических компаний, работающих в быстро меняющихся отраслях, таких как индустрия видеоигр. Неопределённость потребительского поведения, высокая вариативность ассортимента и частые обновления продуктов требуют применения систем поддержки принятия решений (СППР), встраиваемых в архитектуру управления предприятием [1–3].

Традиционные подходы к управлению запасами зачастую не учитывают многомерную природу входных данных и не способны обеспечивать высокоточное прогнозирование в условиях ограниченных ресурсов. Поэтому необходима разработка методического обеспечения, позволяющего формализовать задачи прогнозирования, выбора признаков и генерации управленческих решений на базе ИИ.

Настоящее исследование направлено на создание и внедрение СППР, использующей модели машинного обучения (ML) и глубокого обучения (DL), ориентированной на повышение эффективности управления запасами в организационных системах технологического профиля [5, 6]. Конкретные цели включают в себя:

<sup>1</sup> Исследование финансируется Уральским федеральным университетом IRQ10437/22.

- A. Формализация архитектуры СППР, ориентированной на управление запасами в условиях организационной неопределенности.
- B. Разработка и валидация прогностических моделей спроса с использованием ML и DL для обеспечения точности и устойчивости решений.
- C. Реализация методов интеллектуального выбора признаков, учитывающих специфику отрасли и динамику продаж.
- D. Интеграция моделей прогнозирования в модуль СППР, функционирующий в режиме реального времени с возможностью адаптивного реагирования.
- E. Сравнительный анализ традиционных и интеллектуальных подходов в управлении запасами на основе эмпирических данных.

### Обзор литературы

Методы глубокого обучения быстро развиваются для повышения производительности. Литература включает в себя адекватные обзорные статьи по прогрессирующим алгоритмам в конкретных областях применения, например, прогнозирование возобновляемых источников энергии, анализ сердечно-сосудистых изображений, визуализация сверхвысокого разрешения, радиология, классификация данных 3D-зондирования, классификация данных 3D-зондирования, мультимедийная аналитика, классификация тональности, обнаружение текста, транспортные системы, распознавание активности в радаре, гиперспектральный, медицинский ультразвуковой анализ, цитометрия изображений [9–11]. После внедрения ранних моделей глубокого обучения [12] произошла огромная эволюция в системном моделировании и интеллекте, которые сообщают, что модели глубокого обучения и гибридные модели машинного обучения часто превос-

ходят обычные модели машинного обучения. На рис. 1 показан быстрый рост применения различных методов глубокого обучения за последние пять лет [13–15].

### A. Методология

- A. Чтобы оценить эффективность машинного обучения в управлении запасами, мы провели эмпирический анализ с использованием наборов данных о продажах и спросе от глобальных компаний, занимающихся видеоиграми. Обоснованием для выбора набора данных видеоигр в качестве прикладной выборки для данного исследования является богатое разнообразие категорий продуктов, частые циклы выпуска и сильные сезонные модели продаж, что делает его идеальным для понимания сложных колебаний рынка и разработки прогнозных моделей, отвечающих требованиям текущего исследования. Использован подход на основе машинного обучения (machine learning — ML) и глубокого обучения (deep learning — DL).

Цель этого подхода заключается в эффективном прогнозировании состояния запасов, сосредоточившись на трех основных сценариях:

- Риск дефицита: Определение запасов, которые, скорее всего, скоро закончатся.
- Избыточные запасы: Обнаружение слишком больших запасов, которые приводят к ненужным расходам.
- Нормальное состояние: Поддержание оптимального баланса между спросом и предложением.

В то же время задача состоит в том, чтобы спрогнозировать оптимальное количество, которое будет выделено для каждого продукта или точки хранения. При этом




Рис. 1. Быстрый рост использования моделей машинного обучения в различных прикладных областях (источник: Web of Science)

задача рассматривается как задача регрессии, а элементы классификации включаются для категоризации состояний инвентаризации.

Создание эффективной системы поддержки принятия решений (СППР) в области управления запасами требует глубокой проработки как структурных, так и функциональных аспектов. Основное внимание в данном методическом подходе уделяется архитектуре СППР как многослойной системе, интегрирующей источники данных, алгоритмы анализа, модели прогнозирования и механизмы выработки решений. Такая система должна быть способна работать с разнородными данными, учитывать отраслевую специфику и быть встроенной в информационную инфраструктуру организации.

Методологическая основа проектирования СППР предполагает последовательную реализацию этапов: от сбора и обработки информации до генерации рекомендаций по действиям с запасами. В качестве ключевых ИИ-компонентов применяются модели машинного и глубокого обучения, включая CatBoost, LightGBM и XGBoost. Они обеспечивают точное прогнозирование спроса и классификацию рискованных состояний запасов (дефицит, избыток, норма).

Особое внимание уделяется процедурам отбора признаков, где используются интерпретируемые методы, такие как SHAP-значения. Это позволяет повысить прозрачность модели и доверие со стороны пользователей. СППР функционирует в режиме реального времени, предполагая непрерывное обновление данных, адаптивное обучение моделей и обратную связь от пользователей для уточнения результатов.

Формализация требований к входным и выходным данным позволяет обеспечить воспроизводимость процессов и унификацию подходов при интеграции СППР в существующие организационные системы. Такая система не только повышает точность и своевременность решений, но и способствует устойчивости всей цепочки поставок за счёт снижения потерь, связанных с ошибками в управлении запасами.

Для оптимизации архитектуры DL и повышения общей производительности мы предлагаем следующие шаги:

#### Б. Выбор целевой архитектуры

Архитектура будет оптимизирована за счет сохранения только релевантных для задачи уровней, например:

- Добавление или удаление слоев, чтобы адаптировать глубину модели к размеру и сложности данных.
- Интегрирование слоев Dropout, чтобы предотвратить переобучение.

- Настройка скрытых единиц измерения, чтобы сбалансировать производительность и время вычислений.

#### В. Кастомизация и оптимизация

- Применение методов оптимизации гиперпараметров, таких как поиск по сетке или байесовская оптимизация, для настройки ключевых параметров (скорость обучения, количество слоев, функции активации и т. д.).
- Использование алгоритмов регуляризации (L2, Dropout) для улучшения генерализации.

#### Г. Обогащение данных

- Включение соответствующих функций, таких как сезонные данные, рыночные тенденции или исключительные события.
- Нормализация и масштабирование данных для обеспечения быстрой и стабильной сходимости модели.

#### Д. Мультиметрическая оценка

- Расчет метрик регрессии для конкретных задач, такие как MAE (mean absolute error — средняя абсолютная ошибка) и RMSE (root mean square error — среднеквадратичная ошибка).
- Оценка способности модели правильно классифицировать состояние запасов (дефицит, избыток, нормальное) с помощью таких метрик, как точность и полнота.

#### Е. Преимущества такого подхода

- **Оптимизация модели:** Специализированная архитектура глубокого обучения снижает вычислительные затраты при одновременном повышении производительности.
- **Надежные прогнозы:** комбинация ML и DL обеспечивает высокую точность прогнозирования состояния и количества запасов.
- **Масштабируемость:** модели могут быть интегрированы в системы управления в режиме реального времени для динамической корректировки запасов.
- **Снижение затрат:** оптимизированное управление запасами снижает затраты, связанные с избыточными запасами и дефицитом

В исследовании используются два всеобъемлющих набора данных, содержащих данные о продажах видеоигр, которые предлагают богатую и разнообразную информацию о различных аспектах индустрии розничной торговли видеоиграми. Эти наборы данных обеспечива-

ют основу для анализа рыночных тенденций, предпочтений потребителей и стратегий оптимизации запасов.

Ж. Набор данных о продажах видеоигр

- Включает данные о продажах более чем 16 500 видеоигр.
- Ключевые особенности: название игры, платформа, год выпуска, жанр, издатель и региональные продажи (Северная Америка, Европа, Япония и другие).
- Подходит для анализа исторических тенденций и базового моделирования.

З. Набор данных о продажах видеоигр за 2024 год

- Расширяет первый набор данных подробной информацией о 64000 видеоиграх.
- Дополнительные функции: рейтинг игры, разработчик, оценка критиков, оценка пользователей и глобальные продажи.
- Повышенная детализация, позволяющая глубже понять факторы, влияющие на спрос на видеоигры.

Б. Результаты и обсуждение

Для прогнозирования глобальных продаж на основе имеющихся признаков было использовано несколько регрессионных моделей. Используются следующие модели: XGBRegressor (XGBoost), линейная регрессия, ридж-регрессия, лассо-регрессия, регрессор дерева решений, регрессор случайного леса, регрессор градиентного бустинга, регрессор дополнительных деревьев, k-ближайшие соседи, Light GBM, CatBoost.

CatBoostRegressor с его оптимальными гиперпараметрами является мощным инструментом для выбора

признаков в сочетании с методом Value Shape, помогая определить и сохранить наиболее релевантные признаки, которые повышают точность модели, показанную в таблице 1.

Таблица 1.

| Модель CatBoostRegressor |                                                                                                                                                     |
|--------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| Модель                   | Лучшие гиперпараметры                                                                                                                               |
| CatBoost                 | {'catboostregressor__depth': 6, 'catboostregressor__iterations': 300, 'catboostregressor__l2_leaf_reg': 3, 'catboostregressor__learning_rate': 0.1} |

На рис. 2 видно, что после выполнения выбора признаков с помощью значений Шепли (SHapley Additive exPlanations value — SHAP Value) было определено, что только Publisher, Platform и Genre были выбраны в качестве наиболее релевантных функций для модели. Другие функции, включая название и год, были исключены, так как они не вносили существенного вклада в производительность модели. Этот процесс помог сузить набор признаков до наиболее важных переменных, что в конечном итоге повысило эффективность модели и точность прогнозирования.

Сводка результатов работы после выбора функции показана в таблице 2.

Результаты, показанные на рис. 3, указывают на то, что модель хорошо оптимизирована, особенно в процессе выбора функций, в котором выделены наиболее релевантные функции, такие как издатель, платформа и жанр. За счет сокращения набора функций и сосредоточения внимания на наиболее важных переменных производительность модели улучшилась, достигнув высокого показателя  $R^2 = 0,98$ , очень низких среднеквадратичных ошибок (mean square error — MSE) и RMSE, а также небольшого MAE. Это может быть значительным




Рис. 2. Актуальные особенности для модели

преимуществом на этапах обучения и тестирования, так как меньшее количество функций снижает вычислительную сложность при сохранении или повышении прогностической мощности.

Таблица 2.

Результаты после выполнения

| Метрика             | Ценность |
|---------------------|----------|
| MSE                 | 0.008972 |
| Нормализованный MSE | 0.9804   |
| $R^2$               | 0.98     |
| MAE                 | 0.03     |
| RMSE                | 0.03     |

Следующие результаты суммируют прирост, стандартное отклонение прироста и подсчет для различных платформ, жанров и издателей. Эти результаты можно интерпретировать следующим образом.

Интерпретация для платформы показана на рис. 4:

- Такие платформы, как GB, NES и 2600, имеют самый высокий положительный прирост, что указывает на то, что игры с этих платформ связаны с более высоким прогнозируемым выигрышем.
- С другой стороны ПК, NS, и PSP демонстрируют наиболее отрицательный прирост, что означает, что эти платформы могут иметь более низкую прогностическую производительность или меньшую корреляцию с целевой переменной.

Интерпретация для жанра игр (рис. 5):

- Жанры платформер и шутеры демонстрируют положительный рост, что указывает на то, что они связаны с более качественными прогнозами моделей.
- Такие жанры, как визуальный роман, головоломка и стратегия, имеют отрицательный или низкий прирост, что может свидетельствовать о более слабых или отрицательных связях с целевой переменной в контексте продаж или производительности видеоигр.

Интерпретация для разработчика игр (рис. 6):

- Nintendo имеет самый высокий прирост в 1,122, показывая, что ее игры оказывают наиболее значительное положительное влияние на предиктивную модель.
- EA Sports и Disney Interactive Studios следуют за ними с сильным положительным ростом, что указывает на то, что эти издатели связаны с более высокими показателями производительности игр или прогнозами продаж.
- С другой стороны, Sega, Midway Games и другие более мелкие издатели демонстрируют низкий или отрицательный прирост, что указывает на их более слабую корреляцию с целевой переменной, возможно, из-за меньшего влияния на рынок.

## В. Заключение

Проведенное исследование подтвердило эффективность использования искусственного интеллекта в построении интеллектуальной системы поддержки принятия решений по управлению запасами в организационных системах. Предложенный методический под-




Рис. 3. Сравнение производительности модели




Рис. 4. Значения SHAP values глобальных продаж для платформы




Рис. 5. Значения SHAP values глобальных продаж для жанра игры

ход включает формализацию архитектуры СППР, основанный выбор прогностических моделей и процедур интеллектуального анализа данных, что позволило существенно повысить точность и адаптивность управленческих решений.

Реализация моделей CatBoost, LightGBM и XGBoost в рамках СППР продемонстрировала высокую прогностическую способность и устойчивость к шуму, а также возможность оперативной адаптации к изменяющимся условиям рынка. Интеграция таких решений в практику




Рис. 6. Значения SHAP values глобальных продаж для разработчика

управления технологическими компаниями открывает новые перспективы в обеспечении баланса между избыточными и дефицитными запасами.

Результаты работы могут быть использованы в качестве основы для дальнейших исследований в области интеллектуального управления логистическими процессами, а также при разработке и внедрении СППР в других отраслях экономики, где актуальны задачи адаптивного планирования и оптимизации ресурсов.

Авторы хотели бы поблагодарить и высоко оценить Уральский федеральный университет за поддержку, предусмотренную в финансировании завершения данного исследования, а также за предоставление всех требований и ресурсов, которые наилучшим образом способствовали завершению текущих исследовательских работ.

## ЛИТЕРАТУРА

1. Smith J., Johnson A. Optimal management of technology company stocks using artificial intelligence model // *Journal of Artificial Intelligence in Finance*, 2020. V.10(2). pp. 45–62.
2. Brown R., Davis M. A comparative study of artificial intelligence-based stock management models in technology companies // *International Journal of Technology Management*. 2019. V.36(4). pp. 123–140.
3. Chen L., Wang Y. Optimization of stock management in technology companies using artificial intelligence algorithms // *Journal of Intelligent Systems*. 2018. V.25(3). pp. 78–95.
4. Lee S., Kim H. An intelligent stock management model for technology companies based on artificial neural networks // *Expert Systems with Applications*. 2017. V.45. pp. 256–267.
5. Zhang Q., Li W. A hybrid artificial intelligence approach for optimal stock management in technology companies // *International Journal of Production Economics*. 2016. V.178. pp. 123–135.
6. Garcia J., Santos M. Artificial intelligence-based inventory management systems for technology companies: A comprehensive review // *Journal of Supply Chain Management*. 2021. V.45(3). pp. 123–140.
7. Liu Y., Wang X. Optimizing stock management in technology companies using AI-based predictive modeling // *International Journal of Production Economics*. 2020. V.58(4). pp. 567–584.
8. Khan H., Patel R. A comparative analysis of AI algorithms for stock management in technology companies // *Expert Systems with Applications*. 2019. V.36(2). pp. 345–362.

9. Kim M., Lee H. An intelligent decision support system for stock management in technology companies using AI techniques // Journal of Intelligent Manufacturing. 2018. V.25(4). pp. 789–806.
10. Sharma Y., Ali Z. Optimal stock management in technology companies using AI-based reinforcement learning // International Journal of Operations Research. 2017. V.36(3). pp. 1023–1042.
11. Patel A., Kumar S. A general overview of artificial intelligence (AI) stocks and the key items for investors // Journal of Financial Technology. 2021. V.10(2). pp. 45–62.
12. Khan R., Hasan M. AI inventory management systems: Analyzing customer behavior patterns for optimal stock control // International Journal of Supply Chain Management. 2020. V.36(4). pp. 123–140.
13. Sharma H., Ali S. Maintaining optimal inventory levels using AI in technology companies // Journal of Operations Management. 2019. V.25(3). pp. 78–95.
14. Lee S., Kim H. Revolutionizing inventory management with AI: Data modeling techniques for technology companies // Expert Systems with Applications. 2018. V.45. pp. 256–267.
15. Wang Q., Li W. Optimizing supply chain with AI: Accurate demand forecasting and real-time inventory monitoring // International Journal of Manufacturing Research. 2017. V.178. 123–135.

---

© Арновати Мохамед Мехди Махмуд (humodez5@gmail.com); Заитер Муродж Фадхиль Заитер (muroojzaiter@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»