

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ В УПРАВЛЕНИИ СКЛАДСКИМИ ЗАПАСАМИ

Логвинович М. В., Коростелёв А. Д., Марков А. Н.
Центр информатизации и инновационных разработок, кафедра информатики,
Белорусский государственный университет информатики и радиоэлектроники
Минск, Республика Беларусь
E-mail: {m.logvinovich, a.korostelev, a.n.markov}@bsuir.by

В условиях растущих объемов данных и постоянно меняющегося рынка стандартные методы управления складскими запасами часто оказываются неэффективными. Данная статья рассматривает, как машинное обучение (ML) может модернизировать эту область, обеспечивая более точное прогнозирование спроса и оптимизацию уровней запасов. В работе анализируются ключевые ML-алгоритмы и их преимущества по сравнению с традиционными статистическими методами.

ВВЕДЕНИЕ

Современные логистические системы и складские хозяйства сталкиваются с растущими объемами информации и необходимостью оптимизации процессов управления запасами. Эффективное управление складом напрямую влияет на снижение издержек, повышение скорости обработки заказов и удовлетворённость клиентов. В условиях нестабильного спроса классические подходы планирования и учёта запасов, основанные на статистических моделях и экспертных оценках, часто оказываются недостаточно точными и адаптивными.

В последние годы наблюдается стремительное развитие методов машинного обучения (Machine Learning, ML), которые позволяют анализировать большие объёмы данных, выявлять скрытые закономерности и строить прогнозы с высокой точностью [1–2]. Использование ML в управлении запасами даёт возможность прогнозировать спрос на товары, оптимизировать уровни запасов, снижать избыточные и недостающие запасы, а также повышать эффективность распределения ресурсов на складе.

I. ПРОБЛЕМАТИКА УПРАВЛЕНИЯ ЗАПАСАМИ

Обычно методы прогнозирования складских запасов опираются в первую очередь на анализ исторических данных и статистические модели временных рядов. Наиболее распространённые подходы включают скользящие средние, экспоненциальное сглаживание и регрессионные модели. Несмотря на простоту, такие методы имеют серьёзные ограничения:

- Недостаточная гибкость. Стандартные модели плохо учитывают резкие изменения спроса, вызванные сезонностью, промоакциями, изменением поведения покупателей или внешними экономическими факторами.
- Линейные зависимости. Методы чаще всего предполагают наличие линейных зависимостей между параметрами, тогда как реальные процессы в логистике гораздо сложнее.

- Отсутствие адаптивности. При изменении рыночной ситуации требуется заново перенастраивать параметры моделей.

В результате компании сталкиваются либо с избыточными запасами, которые увеличивают расходы на хранение и замораживают оборотный капитал, либо с дефицитом товаров, что приводит к потерям клиентов и снижению прибыли.

II. МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В ПРОГНОЗИРОВАНИИ СПРОСА

В отличие от стандартных статистических подходов, методы машинного обучения позволяют строить нелинейные модели, учитывать множество факторов одновременно и адаптироваться к изменяющимся условиям. В практике управления складскими запасами наиболее часто применяются следующие алгоритмы:

1. Решающие деревья и ансамблевые методы (Random Forest, Gradient Boosting, XGBoost). Эти алгоритмы хорошо работают с табличными данными и способны выявлять сложные зависимости между факторами. Они учитывают такие параметры, как сезонность, маркетинговые акции, макроэкономические показатели и поведение покупателей.
2. Нейронные сети (в частности, рекуррентные нейронные сети LSTM). Данный класс моделей особенно эффективен при прогнозировании временных рядов. LSTM-сети способны учитывать долгосрочные зависимости и лучше предсказывать динамику спроса, чем базовые статистические модели.
3. Методы кластеризации (например, k-means). Используются для сегментации ассортимента по характеристикам спроса и оптимизации стратегий управления для каждой группы товаров.
4. Обучение с подкреплением (Reinforcement Learning). Хотя этот подход пока используется ограниченно, он позволяет моделировать адаптивные системы управления запасами, которые принимают решения на основе обратной связи из окружающей среды.

III. ПРИМЕНЕНИЕ ML В ПРОЕКТИРОВАНИИ И ОПТИМИЗАЦИИ СКЛАДА

Помимо прогнозирования спроса, машинное обучение активно применяется для поддержки стратегических решений в области проектирования и планирования склада. Анализ больших объёмов данных из систем управления складом (WMS) позволяет создавать классификаторы, которые могут предсказывать оптимальные параметры для различных компонентов системы. К таким компонентам относятся:

- Технология хранения (ST). Алгоритмы ML могут рекомендовать подходящую систему хранения, например, автоматизированные системы хранения и поиска (AS/RS), консольные стеллажи или стеллажи для поддонов.
- Система обработки материалов (MHS). Машинное обучение помогает выбрать оптимальный набор ресурсов для перемещения товаров, таких как вилочные погрузчики или операторы.
- Стратегия размещения товаров (SAS). ML-модели могут определять наилучшие политики размещения, например, дублирование мест хранения для одного и того же SKU (Stock Keeping Unit, единица складского учёта) с целью ускорения операций комплектации.
- Политика комплектации (PP). Алгоритмы прогнозируют, как следует организовывать операции по комплектации заказов (например, по одному заказу или по нескольким).

Этот подход, основанный на анализе данных из реальных складских систем, позволяет оптимизировать процессы, повысить производительность и снизить затраты.

IV. ПРАКТИЧЕСКИЕ РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ ML

Ряд исследований подтверждает эффективность внедрения алгоритмов машинного обучения в управление складскими запасами. Так, в работе [3] проведено сравнение устоявшихся методов прогнозирования с современными ML-алгоритмами на основе исторических данных о продажах, включая сезонность, праздничные периоды и маркетинговые акции. Результаты показали, что ансамблевые методы, такие как Random Forest и XGBoost, позволили сократить избыточные запасы примерно на 20% по сравнению с классическими статистическими подходами. Использование LSTM-сетей обеспечило наибольшую точность прогнозов в условиях резких изменений спроса. Внедрение ML-моделей в систему управления запасами также способствовало снижению частоты дефицита товаров и повышению уровня обслуживания клиентов.

Кроме того, в исследовании [4] показано, что методы машинного обучения могут применяться не только для прогнозирования спроса, но и для поддержки стратегических решений в проектировании склада. Алгоритмы позволяют предсказывать подходящие конфигурации систем хранения и обработки материалов, что повышает эффективность планирования логистической инфраструктуры.

V. ВЫВОДЫ

Применение методов машинного обучения в управлении складскими запасами открывает новые возможности для повышения эффективности логистических процессов. В отличие от традиционных статистических моделей, ML-алгоритмы способны учитывать множество факторов, выявлять скрытые зависимости и адаптироваться к изменяющимся условиям рынка.

Практические исследования показывают, что использование таких моделей, как Random Forest, XGBoost и LSTM, позволяет существенно увеличить точность прогнозов спроса и снизить издержки, связанные с хранением избыточных запасов. Кроме того, ML-подход может быть использован для решения стратегических задач проектирования склада, таких как выбор оптимальных технологий хранения и систем комплектации, что способствует переходу от реактивного управления к проактивному, основанному на данных.

Перспективными направлениями дальнейших исследований являются применение методов глубокого обучения для интеграции различных источников данных, а также использование методов обучения с подкреплением для построения адаптивных систем управления складом.

VI. СПИСОК ЛИТЕРАТУРЫ

1. Иващенко, М. Г. Эффективное использование нейронных сетей в решении задач автоматизации в логистике / М. Г. Иващенко, С. Н. Нестеренков, А. В. Ситников // BIG DATA и анализ высокого уровня = BIG DATA and Advanced Analytics : сб. науч. ст. X Междунар. науч.-практ. конф. (Республика Беларусь, Минск, 13 марта 2024 года). В 2 ч. Ч. 1 / редкол. : В. А. Богущ [и др.]. – Минск : БГУИР, 2024. – С. 368–372.
2. Furlan de Assis, R., Frias, A. F., Thomasset-Laperrière, V., Santa-Eulalia, L. A., Ouhimmou, M., de Paula Ferreira, W. (2024). Machine Learning in Warehouse Management: A Survey. *Procedia Computer Science*, 232, 2790-2799. doi:10.1016/j.procs.2024.03.364
3. Bendhi, M. R. (2023). Inventory Management: Machine Learning Predicts Demand, Reducing Excess Stock by up to 20%. *International Journal of Artificial Intelligence, Data Science, and Machine Learning*, 4(2), 67-83. doi:10.63282/3050-9262.IJAIDSML-V4I2P108
4. Tufano, A., Accorsi, R., Manzini, R. (2022). A machine learning approach for predictive warehouse design. *The International Journal of Advanced Manufacturing Technology*, 119, 2369-2392. doi:10.1007/s00170-021-08035-w