

РАЗРАБОТКА ПРОГНОЗНОЙ МОДЕЛИ ДЛЯ ПРЕДСКАЗАНИЯ ВРЕМЕНИ ПОСТАВОК С ПРИМЕНЕНИЕМ МАШИННОГО ОБУЧЕНИЯ

Исаева Н.А., Сорокина В.Е., Степанов Н.А.

Национальный исследовательский технологический университет "МИСИС", Москва, Россия
n.isaeva@misis.ru, valentina.s2002@yandex.ru, stepanov.na@misis.ru

Аннотация. В статье представлен алгоритм построения модели машинного обучения для определения прогностического времени поставки товарно-материальных ценностей (ТМЦ) на склад. Особое внимание уделено анализу параметров, влияющих на время поставки, включая погодные, транспортные и логистические факторы.

Ключевые слова: машинное обучение, логистика, прогнозирование, поставка, товарно-материальные ценности (ТМЦ), время доставки, модель К-ближайших соседей (KNN), регрессия, цифровизация логистики, оптимизация бизнес-процессов, имитационное моделирование, складская аналитика, предиктивная аналитика.

Введение

Современные предприятия, функционирующие в условиях высокой конкурентной среды и нестабильности поставок, вынуждены стремиться к непрерывному совершенствованию внутренних процессов с целью повышения операционной эффективности. Одной из наиболее критичных функций в производственном цикле крупных промышленных предприятий является управление логистикой и, в частности, процесс приёма товарно-материальных ценностей (ТМЦ) на склад. От своевременности и точности данного этапа зависит бесперебойность снабжения производственных подразделений, а следовательно – и выполнение производственного плана. Для анализа и улучшения подобных процессов всё чаще применяются цифровые методы, среди которых особое значение приобретает имитационное моделирование.

Имитационное моделирование представляет собой метод, позволяющий воспроизводить поведение и функционирование реальных систем с целью анализа их характеристик, взаимодействий и возможных исходов при различных сценариях [1]. Этот подход находит широкое применение в таких сферах, как экономика, управление бизнесом, инженерия, медицина и научные исследования [2]. Он используется для поддержки принятия решений, оптимизации процессов, прогнозирования и проверки гипотез. Преимущество метода заключается в возможности проведения экспериментов и анализа без необходимости вмешательства в реальные объекты, что делает его особенно полезным для изучения сложных и динамично развивающихся систем.

Цель исследования – разработка и обоснование применения методов машинного обучения для предсказания фактического времени поставки товарно-материальных ценностей (ТМЦ) на основе доступных логистических, погодных и исторических данных. Основное внимание уделяется созданию прогностической модели, позволяющей повысить точность планирования приёмки ТМЦ, сократить задержки в логистических процессах и обеспечить устойчивость складских операций за счёт проактивного управления временем прибытия поставщика.

1. Анализ результатов имитации процесса

В рамках исследования был проведён анализ бизнес-процесса приёмки товарно-материальных ценностей (ТМЦ) на складе предприятия трубопроводной арматуры.

Рассматриваемый бизнес-процесс включает 21 этап – от формирования запроса на план приёма до оформления итоговой отчётности. Анализ показал, что наибольшие временные потери приходятся не на выполнение самих операций, а на ожидание их начала.

Обработка товарно-транспортной и товарной накладных – совокупные задержки превышают 2 часа на каждом этапе. Это указывает на систематическое несвоевременное прибытие доставок товарно-материальных ценностей. Ожидание доставки становится основным фактором простоя ресурсов склада.

Разгрузка и приёмка ТМЦ – этапы физического перемещения и проверки сопровождаются значительными очередями. Особенно длительное ожидание наблюдается на этапе качественной приёмки ТМЦ, что может быть связано с недостаточной пропускной способностью контрольной зоны и нехваткой персонала.

Оформление документации (карточки складского учёта, журналы и акты) также сопровождается значительным временем ожидания, что свидетельствует о высокой нагрузке на сотрудников,

ответственных за оформление, и указывает на необходимость оптимизации документооборота.

В то же время начальные этапы процесса, связанные с планированием и подготовкой, выполняются без задержек, что демонстрирует их устойчивость и автоматизированную поддержку.

Для количественной оценки указанных отклонений и выявления критических узких мест было проведено имитационное моделирование текущего процесса. Во всех функциях, включённых в имитационное моделирование процесса приёма товарно-материальных ценностей (ТМЦ), было использовано нормальное распределение времени выполнения операций. Такой подход позволяет учитывать естественные вариации, возникающие в ходе выполнения логистических и учетных процедур, при этом предполагая наличие среднего (ожидаемого) значения времени и симметричного распределения отклонений вокруг него. Результаты имитационного моделирования представлены в виде диаграммы на рис. 1.




Рис. 1. Имитационная модель процесса приема товарно-материальных ценностей

Результаты анализа наглядно демонстрируют неравномерную нагрузку на элементы процесса и выявляют узкие места, вызывающие значительные задержки. Это создаёт объективную необходимость в разработке и внедрении системы прогнозирования прибытия ТМЦ на основе методов машинного обучения. Такая система позволит своевременно корректировать расписание приёмки, управлять загрузкой ресурсов склада и минимизировать простои. Дополнительно следует рассмотреть возможность автоматизации процессов документооборота, а также оптимизацию логистики в зонах разгрузки и контроля.

2. Анализ параметров, влияющих на целевую переменную

Для обеспечения прогнозируемости и управляемости поставок требуется не просто построить модель машинного обучения, но и корректно выбрать факторы, которые влияют на целевую переменную.

Для анализа были выбраны следующие признаки: количество ТМЦ, осадки, скорость ветра, тип транспорта, перегруз, время отправки, день недели, пробки, состояние дороги, инциденты в пути, факт-план поставки.




Рис. 2. Корреляционная матрица зависимости показателей

Цветовая шкала: значение 1.0 (ярко-красный) указывает на сильную положительную связь между переменными. Значение 0.5 (светло-красный) соответствует умеренной положительной связи. При значении 0.0 (белый) корреляция между переменными отсутствует. Значение -0.5 (светло-синий) обозначает умеренную отрицательную связь, а -1.0 (тёмно-синий) – сильную отрицательную связь.

Анализ матрицы показывает, что наибольшую корреляционную связь с отклонением поставки демонстрируют следующие переменные:

- осадки (коэффициент корреляции $r = 0.74$);
- скорость ветра ($r = 0.71$);
- пробки ($r = 0.60$);
- инциденты в пути ($r = 0.55$);
- состояние дорожного покрытия ($r = 0.45$);
- перегруз транспортного средства ($r = 0.50$).

В то же время ряд факторов, таких как объём поставки ($r = -0.12$), день недели ($r = 0.10$) и время отправки ($r = 0.20$), оказались менее значимыми либо потенциально недоступными на момент прогнозирования.

Дальнейший выбор признаков был основан на трёх ключевых критериях:

- Доступность данных до момента предсказания (операционная применимость);
- Статистическая значимость по отношению к целевой переменной;
- Отсутствие мультиколлинеарности и избыточности информации.

Следует учитывать, что при построении модели предсказания времени прибытия поставщика на склад не все параметры известны заранее. Время отправки, пробки, инциденты, фактический маршрут

и т. п. – доступны только на стороне поставщика и, как правило, не могут быть интегрированы в оперативный прогноз.

Модель должна опираться на доступные до момента прибытия признаки, которые можно получить из:

- погодных сервисов (осадки, ветер);
- логистической заявки (тип транспорта, вид груза, наличие перегруза);
- истории взаимодействий (среднее отклонение по поставщику, надёжность, средняя скорость поставки).

Процесс подбора признаков базировался на сочетании статистического, логического и практического анализа. Были исключены признаки:

- с высокой корреляцией, но недоступные в реальном времени (например, факт пробки, факт инцидента);
- с нулевой или отрицательной предсказательной способностью.

При отборе признаков для включения в модель учитывались переменные с высокой корреляцией (значения r от 0.7 и выше) и умеренной корреляцией (r в диапазоне 0.4–0.7), поскольку они обеспечивают как объяснительную силу модели, так и достаточную вариативность признаков для её дообучения и настройки. Кроме того, структура модели учитывает экспертную значимость факторов, даже если корреляция ниже условного статистического порога.

Таким образом, в модель были включены только те переменные, которые доступны на момент предсказания и имеют подтверждённую корреляционную и логическую связь с целевой переменной.

3. Обучение модели машинного обучения для предсказания

Для решения задачи прогнозирования фактического времени поставки товарно-материальных ценностей (ТМЦ) была сформулирована задача регрессии. В качестве целевой переменной выступало отклонение между фактическим и плановым временем поставки, выраженное в минутах.

Для построения предсказательной модели были выбраны три популярных алгоритма машинного обучения: линейная регрессия, дерево решений и метод k -ближайших соседей (KNN). Подход, аналогичный применяемому в настоящем исследовании, был также рассмотрен в [3], где авторы сравнивали различные регрессионные модели для предсказания дат доступности продукции в условиях логистических сбоев. Модели обучались на обучающей выборке (80% данных) и тестировались на отложенной выборке (20%).

Для оценки качества модели использовались следующие метрики:

- среднеквадратичная ошибка (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (1)$$

где n – количество наблюдений;

y_i – фактическое (реальное) значение целевой переменной для i -го наблюдения;

\hat{y}_i – предсказанное моделью значение для i -го наблюдения.

- средняя абсолютная ошибка (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

n – количество наблюдений;

y_i – фактическое (реальное) значение целевой переменной для i -го наблюдения;

\hat{y}_i – предсказанное моделью значение для i -го наблюдения.

- коэффициент детерминации (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

R^2 – коэффициент детерминации, отражает долю объяснённой дисперсии;

n – количество наблюдений;

y_i – фактическое значение целевой переменной для i -го наблюдения;

\hat{y}_i – предсказанное моделью значение для i -го наблюдения;

\bar{u}_i – среднее значение всех фактических u_i .

В таблице 1 отражено сравнение моделей машинного обучения по определенным ранее критериям.

Таблица 1. Оценка параметров выбранной модели

Модель	MSE	MAE	R^2
Линейная регрессия	0.65	0.60	0.92
Дерево решений	0.35	0.16	0.97
K-ближайших соседей	0.33	0.13	0.98

Модель KNN показала наилучшие показатели точности и устойчивости. Наибольшую точность она продемонстрировала при числе соседей $k = 3$, использовании евклидовой метрики расстояния и весов, обратно пропорциональных расстоянию.

Алгоритм обучения модели представлен на рисунке 3.

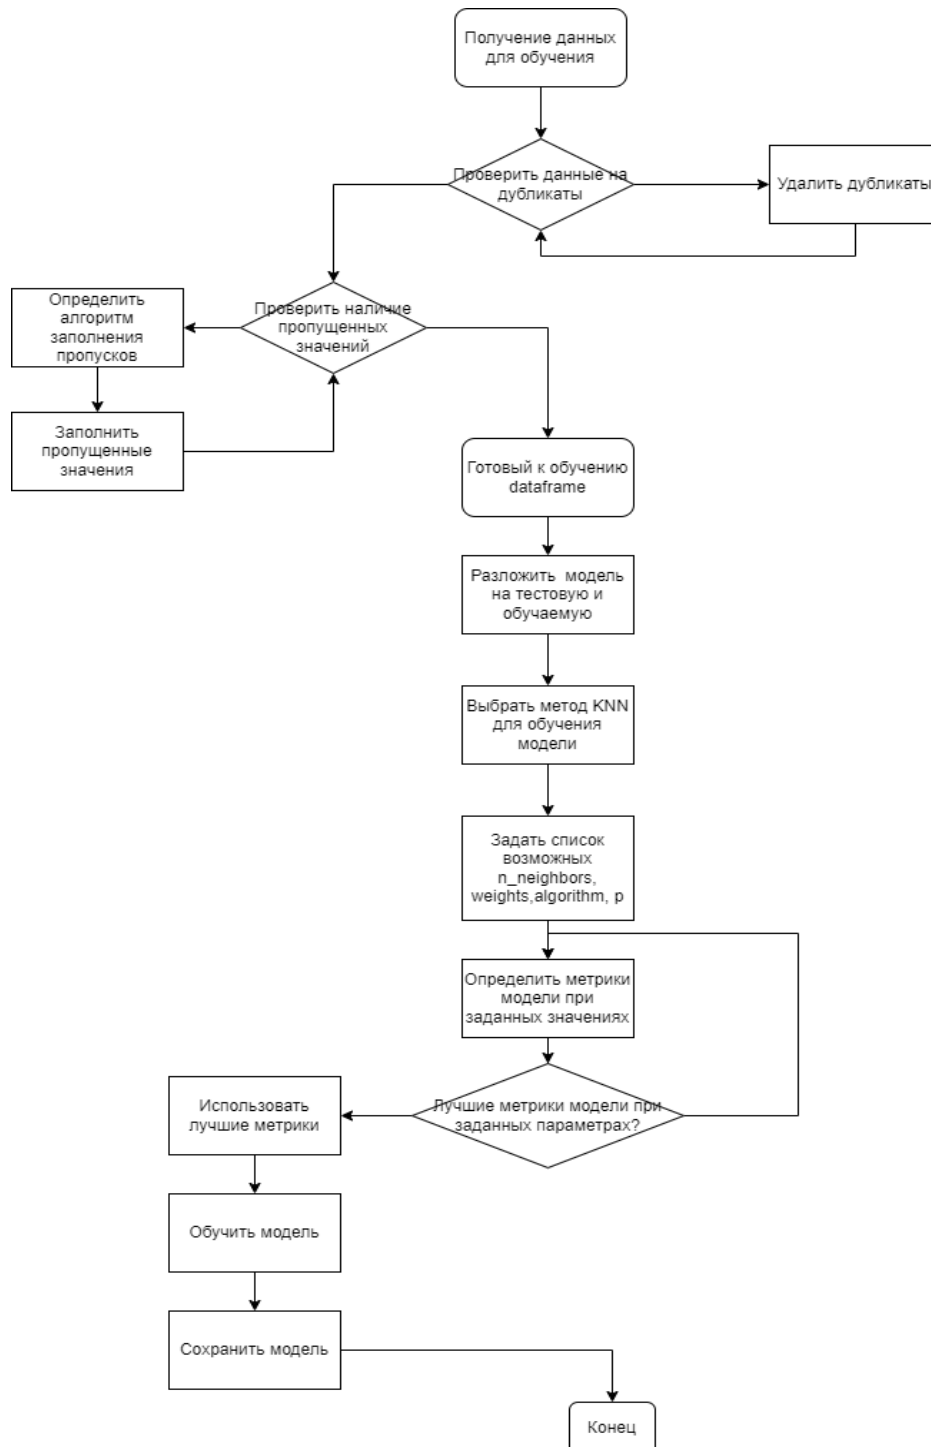


Рис. 3. Алгоритм обучения модели

Для визуальной оценки точности модели была построена диаграмма рассеяния. Как видно из рисунка 4, предсказанные значения хорошо коррелируют с фактическими, что свидетельствует о высоком уровне точности модели. Красная пунктирная линия соответствует идеальному совпадению предсказаний с реальными данными.




Рис. 4. Диаграмма рассеяния

Таким образом, были определены оптимальные параметры для обучения модели.

4. Разработка веб-приложения для использования модели машинного обучения

С помощью библиотеки streamlit было разработано веб-приложение, которое позволяет подать через интерфейс данные на вход модели, после чего она возвращает прогностическое время фактической поставки.

На рисунке 5 видно, что были поданы такие входные данные как: наличие осадков, плановое время поставки, скорость ветра и наименование поставщика.

Предсказание времени поставки

Осадки (Да/Нет)

Да

Дата поставки

2025/05/29

Плановое время поставки

15:00

Скорость ветра

6

Выберите наименование поставщика

ОАО «Тулачермет»

Предсказать время поставки

Прогностическое время поставки: 2025-05-29 16:30:00

Рис. 5. Веб-приложение для предсказания

Таким образом, применение искусственного интеллекта для предсказания времени поставки товарно-материальных ценностей на склад позволяет оптимизировать процессы управления запасами и планирование производства, улучшает точность прогнозирования спроса и сокращает издержки за

счет снижения затрат на хранение и перестановку товаров. Разработанная и обученная на исторических данных модель поможет безошибочно предсказывать время поставки, что позволит оптимизировать складскую логистику и наиболее грамотно выстраивать приемки товарно-материальных ценностей без временных задержек.

При этом информация о погодных условиях (осадки, скорость ветра и др.) автоматически поступает через погодный API, в зависимости от географического местоположения поставщика. Это позволяет системе работать в автоматическом режиме и учитывать актуальные погодные риски при расчёте прогноза.

Использование искусственного интеллекта также позволяет улучшить общую эффективность управления цепочкой поставок и снизить вероятность ошибок в расчетах и планировании в рамках складской логистики (WMS). Автоматизация процессов предсказания времени поставки и управления запасами помогает компаниям работать более эффективно, быстрее реагировать на изменения в спросе и улучшать обслуживание клиентов.

5. Заключение

Проведенное исследование подтвердило эффективность применения алгоритмов машинного обучения для прогнозирования времени прибытия поставщика на склад. В результате имитационного моделирования и анализа бизнес-процесса приемки ТМЦ были выявлены ключевые точки задержек, связанные преимущественно с ожиданием документации и проверки качества товара. Построение прогностической модели на основе метода *K*-ближайших соседей продемонстрировало высокую точность ($R^2 = 0.98$) при использовании релевантных, доступных до прибытия признаков, таких как погодные условия, тип груза, средние задержки поставщика и пр. Интеграция модели в виде веб-приложения обеспечивает её практическую применимость в операционной деятельности логистических и складских подразделений. Таким образом, предложенный подход позволяет не только повысить точность планирования приёмки, но и улучшить управление складскими ресурсами, минимизировать простои и повысить устойчивость логистической цепочки в условиях неопределенности.

Современные исследования [4] показывают, что наилучшие результаты в оптимизации логистических процессов достигаются при объединении методов имитационного моделирования с алгоритмами машинного обучения. Такой гибридный подход позволяет не только выявлять проблемные участки в логистических цепочках, но и адаптивно управлять процессами в реальном времени, учитывая динамику внешней среды.

В результате внедрения прогностической модели и веб-приложения на базе Streamlit в логистический процесс приёмки ТМЦ были достигнуты следующие оценимые улучшения:

- снижение времени ожидания разгрузки на 18–25% за счёт более точного прогнозирования прибытия транспорта;
- снижение простоев ресурсов склада (персонала и техники) в среднем на 15%, особенно в пиковые периоды поставок.

Литература

1. Анисимова Г.Б., Ярош Д.А. Имитационное моделирование деятельности логистического центра // Информационные технологии и системы управления. – Таганрог, 2022. – № 3. – С. 18–22. DOI: 10.23947/itse.2022.18-22.
2. Куликовский М.А., Макаров В.В. Имитационное моделирование как инструмент оптимизации технологического процесса // XIV всероссийское совещание по проблемам управления ВСПУ-2024. – 2024. – 1856 с.
3. Samur M.C., Ravi S.K., Saleh S. Enhancing Supply Chain Resilience: A Machine Learning Approach for Predicting Product Availability Dates Under Disruption // arXiv:2304.14902 [cs.LG]. 2023. <https://arxiv.org/abs/2304.14902> (дата обращения: 23.08.2025).
4. Неупкоева Е.О., Быстров В.В., Шишаев М.Г. Гибридная технология синтеза транспортно-логистических систем на основе машинного обучения и имитационного моделирования // Экономика. Информатика. – 2024. – № 3. – С. 670–681.