

**РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ МОДЕЛИ УПРАВЛЕНИЯ ЗАПАСАМИ
НА ПРЕДПРИЯТИИ С СЕРИЙНЫМ ПРОИЗВОДСТВОМ**

Наумова Е.М., Метелев В.А., Ксенофонтова О.Л., Смирнова Н.В.

Наумова Елена Михайловна (0009-0000-4759-3366), Метелев Владислав Александрович (0009-0004-8999-0764), Ксенофонтова Ольга Леонидовна 0000-0002-4122-6220),
Смирнова Наталия Владимировна (0000-0002-1873-5334)
Ивановский государственный химико-технологический университет,
г. Иваново, Россия. 153000, Ивановская область, г. Иваново, пр. Шереметевский, д. 7.
E-mail: sonyableid.mk@gmail.com, bckf2012@yandex.ru, olga_izvolova@mail.ru, nataliasmirnova_@mail.ru

В данной статье рассматриваются теоретические и практические аспекты управления запасами готовой продукции на предприятии с серийным производством. Актуальность исследования обусловлена необходимостью повышения эффективности управления ресурсами в условиях расширяющегося ассортимента и нестабильного спроса. В работе анализируются классические методы управления запасами, включая модель Уилсона, ABC–XYZ-анализ и современные подходы, основанные на методах машинного обучения и интеллектуального анализа данных. Разработана комплексная модель прогнозирования спроса и управления запасами, реализованная на языке Python с использованием алгоритмов Prophet и CatBoost, интегрируемая с платформой «1С: Предприятие». Проведен сравнительный анализ эффективности традиционного и интеллектуального подходов, продемонстрировано снижение издержек на хранение и улучшение точности планирования. Модель позволяет адаптивно реагировать на изменения рыночной конъюнктуры и оптимизировать логистические процессы, обеспечивая устойчивость производственной системы.

Ключевые слова: управление запасами, серийное производство, интеллектуальный анализ данных, машинное обучение, ABC–XYZ-анализ, прогнозирование спроса, модель Уилсона, Python, 1С: Предприятие, логистика, производственное планирование, автоматизация управления

**DEVELOPMENT OF AN INTELLIGENT INVENTORY MANAGEMENT MODEL
FOR ENTERPRISES WITH SERIAL PRODUCTION**

Naumova E.M., Metelev V.A., Ksenofontova O.L., Smirnova N.V.

Naumova Elena Mikhailovna (0009-0000-4759-3366), Metelev Vladislav Aleksandrovich (0009-0004-8999-0764), Ksenofontova Olga Leonidovna (0000-0002-4122-6220),
Smirnova Natalia Vladimirovna (0000-0002-1873-5334)
Ivanovo State University of Chemical Technology,
Ivanovo, Russia. 153000, Ivanovo region, Ivanovo, Sheremetevsky ave., 7.
E-mail: sonyableid.mk@gmail.com, bckf2012@yandex.ru, olga_izvolova@mail.ru, nataliasmirnova_@mail.ru

This article discusses the theoretical and practical aspects of the management of finished products at an enterprise with serial production. The relevance of the study is due to the need to improve the efficiency of resource management in the context of an expanding range and unstable demand. The paper analyzes classical inventory management methods, including the Wilson model, ABC-XYZ analysis and modern approaches based on machine learning and data mining methods. A comprehensive demand forecasting and inventory management model has been developed, implemented in Python using the Prophet and CatBoost algorithms, integrated with the «1C:Enterprise» platform. A comparative analysis of the effectiveness of the traditional and intelligent approaches has been carried out, a reduction in storage costs and an improvement in planning accuracy have been demonstrated. The model allows for an adaptive response to changes in market conditions and optimization of logistics processes, ensuring the sustainability of the production system.

Keywords: inventory management, serial production, data mining, machine learning, ABC–XYZ analysis, demand forecasting, Wilson model, Python, 1C: Enterprise, logistics, production planning, control automation

ВВЕДЕНИЕ

Цель эффективного управления производственными запасами заключается в оптимизации процессов, связанных с их использованием и хранением [1-3]. Основными аспектами, которые необходимо учитывать, являются:

- улучшение качества обслуживания клиентов: обеспечение своевременной доступности продукции для удовлетворения потребностей потребителей;
- обеспечение рентабельности инвестиций: оптимизация уровня запасов для максимизации отдачи от вложенного капитала и минимизации связанных с ними издержек;
- устранение избыточных и невостребованных запасов: снижение объема запасов, которые не используются, с целью уменьшения затрат на их хранение и предотвращения потерь.

Эффективное управление запасами позволяет предприятию удовлетворять ожидания потребителей, создавая такие запасы каждого товара, которые максимизируют чистую прибыль, и это задача не простая. Ни одно программное обеспечение само по себе не решит проблем управления запасами, встающих перед большинством организаций. Но предприятия, которые стремятся освоить этот процесс, осознают, что результаты в сфере повышения качества обслуживания покупателей и рентабельности инвестиций перекрывают предпринятые усилия [1].

Цель исследования - разработка комплексной модели управления запасами на предприятии с серийным производством с применением технологий интеллектуального анализа данных и математического моделирования для повышения эффективности управления ресурсами и оптимизации затрат.

Объект исследования - бизнес-процесс управления запасами готовой продукции на предприятии с серийным производством.

Предмет исследования - методы интеллектуального анализа и моделирования процессов управления запасами, включая применение машинного обучения и прогнозирования в контексте серийного производства.

Актуальность исследования связана со сложностью планирования производства выпускаемой продукции в условиях ежегодного роста количества единиц продаваемой продукции. Интеллектуальный анализ и математическое моделирование процесса управления запасами в данной ситуации является эффективным инструментом планирования производства. Интеллектуальный

анализ данных и математическое моделирование становятся все более актуальными в различных сферах деятельности благодаря своей способности обрабатывать большие объемы информации, выявлять закономерности и делать прогнозы [4-7].

ТЕОРЕТИЧЕСКИЕ ОСНОВЫ УПРАВЛЕНИЯ ЗАПАСАМИ

В условиях стремительного роста разнообразия выпускаемой продукции и усложнения логистических цепей особенно остро встает проблема эффективного управления производственными запасами. Запасы представляют собой один из ключевых элементов обеспечения непрерывности производственного цикла, влияя как на уровень удовлетворенности потребителей, так и на финансовую устойчивость предприятия. Неэффективная политика управления запасами приводит к избыточному складированию, росту затрат на хранение, порчу продукции и снижению оборачиваемости капитала. В то же время дефицит товарных остатков напрямую влечет за собой простои, потерю клиентов и снижение прибыли. Таким образом, задача оптимального управления запасами требует всестороннего и научно обоснованного подхода, учитывающего как экономические, так и технологические аспекты деятельности производственной организации.

Современные подходы к управлению запасами в производстве опираются как на классические математические модели, такие как модель Уилсона, так и на методы интеллектуального анализа данных, в частности машинное обучение [2, 8, 9]. В контексте серийного производства, где товарный поток непрерывен и разнообразен, особенно важно учитывать как сезонные колебания спроса, так и непредсказуемые изменения в производственном графике. Формирование запаса позволяет обеспечить бесперебойность поставок, сглаживание колебаний спроса и адаптацию к рыночной конъюнктуре, однако всегда сопряжено с рядом издержек: от арендных и страховых до потерь от морального и физического устаревания продукции. Как показывает практика, расходы на поддержание запасов могут достигать 30% от их общей стоимости в год, что требует системной и строго управляемой политики логистики.

Классические подходы к управлению запасами основываются на ряде аналитических моделей, таких как модель экономического размера заказа (EOQ), модель точки повторного заказа (ROP), системы с фиксированным интервалом и фиксированным объемом заказа. Одним из наиболее известных примеров является модель Уилсона, согласно которой существует оптимальный

размер заказа, минимизирующий суммарные издержки на хранение и оформление заказов. Эта модель широко применяется на практике, несмотря на ряд ограничений, таких как предположение о стабильном спросе, постоянных затратах на хранение и точных интервалах поставок. Для учета изменчивости спроса и неопределенностей в поставках все чаще используются стохастические модели, в том числе элементы теории вероятностей, статистики и теории массового обслуживания. Особое значение в логистике имеют методы классификации запасов, позволяющие структурировать ассортимент в зависимости от его значимости и предсказуемости. Наиболее распространенным является ABC-анализ, который группирует номенклатуру в три категории в зависимости от объема продаж или их денежной значимости. В дополнение к нему применяется XYZ-анализ, выделяющий группы товаров по степени стабильности спроса. Совместное применение этих методов дает возможность формировать девятигрупповую матрицу, где для каждой категории могут быть применены различные стратегии управления [9-11]. Так, для группы AX, объединяющей высокосзначимые и предсказуемые товары, целесообразно минимизировать складские запасы, опираясь на регулярные поставки. Напротив, товары из группы CZ, характеризующиеся низкой оборачиваемостью и высоким уровнем неопределенности, требуют либо отказа от хранения, либо особой стратегии, включая формирование страховых запасов. Современные логистические концепции, такие как «точно в срок» (Just-in-Time), планирование потребностей в материалах (MRP) и интегрированное управление цепями поставок (SCM), направлены на минимизацию запасов и максимальную синхронизацию между производственными, складскими и сбытовыми подразделениями [8, 12, 13]. Концепция JIT, изначально разработанная на предприятиях компании Toyota, предполагает поставку материалов строго в момент потребности, исключая создание складских остатков [10, 14]. Для успешной реализации подобного подхода необходимо наличие высоконадежных поставщиков, отлаженных внутренних процессов и развитой IT-инфраструктуры. В российских реалиях, с учетом нестабильности поставок и рыночной неопределенности, подобные подходы требуют адаптации и нередко сочетаются с более консервативными стратегиями.

Нельзя не отметить значимость экономико-математического моделирования в данной области. Математические модели позволяют формализовать процесс управления запасами, учесть

множество параметров - от стоимости единицы хранения до времени поставки и оборачиваемости ассортимента - и найти оптимальные решения с точки зрения минимизации издержек. При этом ключевым фактором становится корректная постановка задачи: определение переменных, целевой функции и ограничений [15, 16]. Особо важны многономенклатурные модели, учитывающие конкуренцию за ресурсы между различными товарами, что позволяет оптимизировать загрузку склада, логистические потоки и финансовые вложения. В последнее десятилетие все более широкое распространение получают методы интеллектуального анализа данных и машинного обучения. Они позволяют не просто формализовать процессы на основе априорных предположений, как это делают классические модели, но и выявлять скрытые закономерности в больших объемах исторических данных. Применение таких моделей позволяет адаптировать процессы управления запасами к изменениям рыночной среды в режиме реального времени. Особенно перспективными являются методы временных рядов, регрессионного анализа, деревьев решений и нейронных сетей. Их интеграция в логистические процессы значительно повышает точность прогнозов и эффективность управления. Таким образом, теоретические основы управления запасами формируют прочную методологическую базу, на основе которой возможно построение комплексной и адаптивной системы логистики. Однако в условиях серийного производства, где количество наименований продукции постоянно растет, а структура спроса меняется, необходим переход к более гибким, интеллектуальным и автоматизированным подходам. Это обуславливает актуальность разработки новых моделей и инструментов, объединяющих проверенные временем экономические методы с возможностями современной аналитики и алгоритмов машинного обучения.

УПРАВЛЕНИЕ ЗАПАСАМИ ПРОИЗВОДСТВЕННОГО ПРЕДПРИЯТИЯ

Объект практического исследования - это высокотехнологичное производственное предприятие, специализирующееся на разработке и производстве диагностического и реабилитационного медицинского оборудования. Разнообразная продуктовая линейка предприятия формирует сложную логистическую задачу, в рамках которой необходимо обеспечить бесперебойное производство, поставки компонентов, контроль качества и хранение готовой продукции. Объемы производства растут с каждым годом.

Все это требует высокого уровня управляемости запасами и постоянного совершенствования логистической стратегии. Компания ведет серийное производство: каждая линейка оборудования выпускается в партиях, а сборка осуществляется на основе предварительно сформированных спецификаций. Это накладывает особые требования к наличию на складе компонентов, полуфабрикатов и готовой продукции.

Управление запасами в компании реализовано с использованием платформы «1С: Предприятие», в которой фиксируются заказы, продажи, остатки, историю движения продукции (рис. 1). Однако, несмотря на наличие цифровой системы, значительная часть решений по управлению запасами принималась на основе экспертных оценок и исторических шаблонов, что снижало гибкость системы при изменении рыночной конъюнктуры.




Рис. 1. Окно «Номенклатура»
Fig. 1. The «Nomenclature» window

Анализ существующих практик показал, что управление запасами в компании ориентировано преимущественно на обеспечение стабильности производственного процесса. Основными приоритетами выступают отсутствие простоев из-за нехватки компонентов и соблюдение сроков поставки оборудования клиентам. Это приводит к формированию значительных страховых и текущих запасов, особенно по номенклатурам с высокой вариативностью спроса. Однако такой подход влечет за собой рост издержек на хранение, замораживание оборотных средств и накопление морально устаревающих позиций. В условиях расширяющегося ассортимента и нестабильности поставок подобная стратегия требует адаптации.

С целью оптимизации логистических издержек и выявления резервов повышения эффективности был проведен анализ данных об управлении запасами готовой продукции. Наиболее значимыми параметрами стали: объем продаж по месяцам, среднее время отгрузки, продолжительность производственного цикла, сезонность спроса и колебания по конкретным товарным группам. На основании анализа было выявлено, что около 30% продукции имеют стабильный спрос, еще 40% - демонстрируют ярко выраженные сезонные или проектные колебания, а оставшиеся 30% характеризуются эпизодическим спросом. Такая структура позволяет применить методы ABC–XYZ-анализа для классификации товарных пози-

ций и назначения для них различных стратегий управления. Для оценки оптимального размера заказа в условиях компании была применена модель Уилсона (EOQ), позволяющая минимизировать суммарные затраты на хранение и оформление заказов. Применение модели показало, что по ряду наименований текущие размеры партий поставок и интервалов между заказами не соответствуют экономически обоснованному уровню. В частности, по продукции категории АХ заказы осуществлялись с избыточной периодичностью, что увеличивало складские издержки. В то же время по товарам категории CZ имел место дефицит на складе (рис. 2) и срывы поставок.

Таким образом, несмотря на наличие цифрового инструментария и базовой автоматизации, в компании отсутствует комплексный аналитический подход к управлению запасами.

Применение классических моделей позволяет выявить первичные резервы оптимизации, однако для более глубокого прогноза и адаптации к изменениям спроса необходимо внедрение интеллектуальных систем, способных обучаться на исторических данных и учитывать многомерные зависимости.

Анализ текущей логистической практики на анализируемом предприятии позволяет сделать вывод о необходимости перехода от экспертной и шаблонной модели управления запасами к системе, основанной на данных и аналитике.

Это становится особенно актуальным в условиях расширения продуктовой линейки, работы с международными рынками и повышения требований к скорости выполнения заказов.

Интеллектуальные методы анализа и прогнозирования способны обеспечить гибкость и устойчивость цепочки поставок, а также повысить точность планирования, минимизируя издержки и повышая удовлетворенность клиентов.

Анализ обеспеченности внутренних заказов										чел																			
Номенклатура (характеристика)	Долги	16.11	17.11	19.11	20.11	21.11	22.11	23.11	24.11	25.11	26.11	27.11	28.11	29.11	30.11	итог нояб	01.12	04.12	05.12	06.12	07.12	08.12	10.12						
Клеанатура функциональная «В-01» (Стандартная комплектация (СР0315.02.01.001.000) ЕС (ЕС))																				1 (2)	3 (3)								
Концентратор USB выходов «М-7-2» (Стандартная комплектация (28.10.2017) (РФ))									19 (40)			2 (2)	7 (7)	1 (1)		29	1 (1)	1 (1)		2 (2)	1 (1)	2 (2)							
НСЭТ 003201.003-011 Блок ПС-ВВ (НСЭТ 003201.003-011 (20210528))								1 (1)	2 (2)					1 (1)		4		3 (3)											
НСЭТ 003204.002 Муфта для проведения пробы Вальсальвы (НСЭТ 003204.002 (20081223))																						11 (20)							
НСЭТ 005302.005 Стимулятор «С-1» (НСЭТ 005302.005 (20210115))																													
НСЭТ 005302.006 Очки светостимулирующие (НСЭТ 005302.006 (20181121))														1 (1)	1 (1)	2				3 (3)	1 (1)								
НСЭТ 005302.006-01 Очки светостимулирующие (НСЭТ 005302.006-01 (20230808))															1 (5)	1													
НСЭТ 009103.011 Перекладки для рентгенофлюоресцентных элементов (НСЭТ 009103.011 (20141210))																				1 (2)									
НСЭТ 008201.013 Пеллетный тестовый (НСЭТ 008201.013 (20110804))																													
НСЭТ 008201.018-010 Блок усилителей USB «Нейро-MBT» (НСЭТ 008201.018-010 (20171109))													3 (3)	1 (1)						1 (1)									
НСЭТ 008201.018-011 Блок усилителей USB «Нейро-ЭРГ» (НСЭТ 008201.018-011 (20171109))													1 (1)			12				1 (1)									
НСЭТ 008201.018-020 Блок усилителей USB «Нейро-MEP» (НСЭТ 008201.018-020 (20171109))							2 (2)													7 (7)									
НСЭТ 008201.018-023 Блок усилителей USB «Нейро-ERG» (НСЭТ 008201.018-023 (20171109))									5 (5)																				
НСЭТ 008221.001 Наконечник к концу ОАЭ (НСЭТ 008221.001 (20161227))													9 (33)		12 (12)	21	3 (3)	6 (6)	3 (3)	12 (12)		4 (4)							
НСЭТ 008355.003 Зонд «ОАЭ-02-2» (НСЭТ 008355.003-01 (20230410))																							2 (4)						
НСЭТ 007103.045 Кабель USB AA-B (НСЭТ 007103.045 (20210413))																													
НСЭТ 010201.022-01 Координатор (НСЭТ 010201.022-01 (20220401))										17 (40)		1 (1)	1 (1)			19	1 (1)					1 (1)							
НСЭТ 011201.016 Блок реографа «Рео-Спектр-2» (НСЭТ 011201.016-010 (20190403))																													
НСЭТ 011211.009 Блок разъемов для крепления электродов (1200 мм) (НСЭТ 011211.009 (20090310))										19 (20)						19													

Рис. 2. Фрагмент таблицы дефицитной ведомости
Fig. 2. Fragment of the deficit statement table

РАЗРАБОТКА КОМПЛЕКСНОЙ МОДЕЛИ УПРАВЛЕНИЯ ЗАПАСАМИ НА ПРЕДПРИЯТИИ С СЕРИЙНЫМ ПРОИЗВОДСТВОМ

Учитывая выявленные ограничения классических методов и специфику деятельности производственного предприятия, была разработана комплексная модель управления запасами, основанная на применении методов машинного обучения. Главной целью разработки стало создание адаптивной аналитической системы, способной прогнозировать потребность в запасах с высокой точностью, учитывая исторические данные, сезонные колебания, рыночную динамику и внутренние логистические параметры.

Серийный характер производства предъявляет особые требования к модели. С одной стороны, необходимо поддерживать постоянный уровень готовности к производству для ряда стабильных изделий, с другой - важно гибко реагировать на нестабильный или эпизодический спрос.

Принципиальное отличие новой модели заключается в переходе от использования агрегированных нормативов (например, фиксированного страхового запаса) к прогнозу спроса в разрезе конкретных номенклатур с опорой на машинные алгоритмы.

Перед началом разработки составим общий алгоритм работы программы и представим его в виде блок-схемы (рис. 3).

Приведенная блок-схема содержит две подпрограммы, которые в свою очередь изобразим в виде блок-схем:

- блок-схема подпрограммы расчета категории ABC (рис. 4);
- блок-схема подпрограммы прогнозирования (рис. 5).

В рамках подготовки к работе в Python требуется подключение дополнительных библиотек и настройка среды программирования (рис. 6) [17-19].




Рис. 3. Блок-схема общего алгоритма работы программы (разработано авторами)

Fig. 3. Block diagram of the general algorithm of the program




Рис. 4. Блок-схема подпрограммы расчета категории ABC (разработано авторами)

Fig. 4. Block diagram of the ABC category calculation subroutine




Рис. 5. Блок-схема подпрограммы прогнозирования (разработано авторами)

Fig. 5. Block diagram of the forecasting subroutine

```
# Импорт стандартных библиотек
import itertools
import logging
# Импорт сторонних библиотек (сортировка по алфавиту)
import numpy as np
import openpyxl
import pandas as pd
import plotly.express as px
import plotly.graph_objs as go
import plotly.io as pio
from plotly.subplots import make_subplots
from plotly.offline import download_plotlyjs, init_notebook_mode, plot, iplot
from catboost import CatBoostRegressor, Pool
from matplotlib import pyplot as plt
from prophet import Prophet
from prophet.diagnostics import cross_validation, performance_metrics
from prophet.plot import plot_cross_validation_metric
from scipy import optimize
from sklearn.metrics import mean_absolute_error, mean_squared_error
from sklearn.model_selection import train_test_split
# Настройка корректного отображения графиков
init_notebook_mode(connected=True)
# Запрет вывода лишних сообщений логов
logging.getLogger('prophet').setLevel(logging.CRITICAL)
logging.getLogger('cmdstanpy').setLevel(logging.ERROR)
# настройка формата отображения чисел с плавающей запятой в DataFrame
pd.options.display.float_format = '{:.2f}'.format
```

Рис. 6. Импорт библиотек и настройка среды
Fig. 6. Importing libraries and setting up the environment

Далее осуществляем требуемые для модели преобразования типов данных и определяем период прогнозирования (рис. 7). Согласно запросам коммерческого департамента предприятия требуется поддерживать запасы на складе в размере их потребности на 1 квартал.

При этом план продаж, на который ориентируется производственный департамент, охватывает период только на 1 месяц вперед. С учетом этого будем делать прогноз на 2 месяца и суммировать с планом продаж на 1 месяц. В итоге получаем потребность на 1 квартал.

```
# Изменим тип данных 'Месяц' с object на datetime64.
all_devices_df['Месяц'] = pd.to_datetime(all_devices_df['Месяц'], format="%d.%m.%Y")
predictions_m = 2 # предсказывать будем 1 квартал (2 месяца предсказываем и 1 месяц известен - это план продаж на 1 месяц)
all_devices_df_ = all_devices_df[all_devices_df['Месяц'] >= '2021-01-01']
all_devices_df_ = all_devices_df[all_devices_df['Месяц'] <= '2023-07-01']
```

Рис. 7. Определение периода прогнозирования (разработано авторами)
Fig. 7. Determining the forecast period

```
# Количество продаж на 1-й месяц прогнозируемого квартала известен, это план продаж на 1 месяц и последний известный месяц в таблице. Выделим в отдельную таблицу этот месяц, как 1-й прогнозируемый месяц
month_sales_plan = pd.DataFrame()
last_month = all_devices_df['Месяц'].max() #определим максимальную дату в таблице продаж
first_pred_month = last_month - pd.DateOffset(months = (predictions_m)) # Находим первый прогнозируемый месяц
month_sales_plan = all_devices_df[all_devices_df['Месяц'] == first_pred_month]
```

Рис. 8. План продаж на 1 месяц (разработано авторами)
Fig. 8. Sales plan for 1 month

В отдельную таблицу сохраняем план продаж на 1 месяц (рис. 8). Также нам необходимо осуществить ABC-анализ по количеству продаж в течение какого-то времени.

Наиболее подходящим периодом определим 1 год до начала прогнозирования. Это позволит избежать некорректных расчетов и исключить устаревшие данные (рис. 9-11).

```
# отрезаем из таблицы продаж 12 месяцев до прогноза
abc_df = pd.DataFrame() # заготовка для таблицы за 1 год
month_before_prediction = last_month - pd.DateOffset(months = predictions_m) # Находим месяц, идущий до предсказания
year_before_prediction = last_month - pd.DateOffset(months = predictions_m + 11) # Находим месяц, идущий за 1 год до
# предсказания
# фильтруем 1 год до предсказания
abc_df = all_devices_df[all_devices_df['Месяц'] >= year_before_prediction]
abc_df = abc_df[abc_df['Месяц'] <= month_before_prediction]
#print(abc_df['Месяц'].max())
#print(abc_df['Месяц'].min())
abc_df['Месяц'].unique()
# Суммируем продажи за 1 год для каждого прибора
abc_df = abc_df.groupby('Номенклатура')['Количество'].sum().reset_index()
# Сортируем по убыванию общего количества
abc_df = abc_df.sort_values(by='Количество', ascending=False)
# Вычисляем процент от общего количества и кумулятивный процент
abc_df['Процент'] = (abc_df['Количество'] / abc_df['Количество'].sum()) * 100
abc_df['кумулятивный_процент'] = abc_df['Процент'].cumsum()
# Классифицируем как A, B или C
def classify(row):
    if row['кумулятивный_процент'] <= 70:
        return 'A'
    elif row['кумулятивный_процент'] <= 90:
        return 'B'
    else:
        return 'C'
abc_df['класс'] = abc_df.apply(classify, axis=1)
display(abc_df.head(10)) # в качестве образца приведем небольшой фрагмент
```

Рис. 9. Выполнение ABC-анализа (разработано авторами)

Fig. 9. Performing ABC analysis

```
# набор гипер-параметров для выбора
season_scale_list = [0.1, 1, 10]
changepoint_scale_list = [0.01, 0.05, 0.1, 0.25]
changepoint_perc_list = [0.8, 0.95]
yearly_seasonality_list = [True, False]
# поиск лучших параметров
def hyper_params_tunning(df_device_m):
    # Создание DataFrame с указанием типов данных для столбцов
    params_df = pd.DataFrame(columns=['params', 'mape'])
    params_df = params_df.astype({'params': 'object', 'mape': 'float64'})
    for sc in season_scale_list:
        for cpc in changepoint_scale_list:
            for cpp in changepoint_perc_list:
                for ys in yearly_seasonality_list:
                    params = {
                        'yearly_seasonality': ys,
                        'changepoint_prior_scale': cpc,
                        'seasonality_prior_scale': sc,
                        'changepoint_range': cpp
                    }
                    prophet_forecast, metrics = prophet_m_work(df_device_m, params, False)
                    # Создаем временный DataFrame для текущей комбинации параметров
                    one_device_metrics_df = pd.DataFrame({'params': [params], 'mape': [metrics['MAPE']]})
                    # Переходим к следующей итерации
                    params_df = pd.concat([params_df, one_device_metrics_df], ignore_index=True)
    # Убедимся, что DataFrame не пустой перед поиском минимального MAPE
    if not params_df.empty:
        best_params = params_df.loc[params_df['mape'].idxmin()]['params']
    else:
        best_params = None
    #print(best_params)
    return best_params
```

Рис. 10. Процедура подбора гиперпараметров модели (разработано авторами)

Fig. 10. Procedure for selecting model hyperparameters

```

# процедура работы модели Prophet по МЕСЯЦАМ
def prophet_m_work(df_device_m, best_params, plots):
    # отрезаем из обучающей выборки последние точки, чтобы измерить на них качество
    train_m_df = df_device_m[:-predictions_m] # тренировочный набор
    test_m_df = df_device_m[-predictions_m:] # тестовый набор
    # Инициализируем модель Prophet с подобранными гиперпараметрами
    model = Prophet(
        daily_seasonality=False,
        weekly_seasonality=False,
        yearly_seasonality = best_params['yearly_seasonality'],
        changepoint_prior_scale = best_params['changepoint_prior_scale'],
        seasonality_prior_scale = best_params['seasonality_prior_scale'],
        changepoint_range = best_params['changepoint_range']
    )
    model.fit(train_m_df) # Обучаем модель Prophet
    # Создаем датафрейм для прогнозирования
    future = model.make_future_dataframe(periods=predictions_m, freq='MS') # прогноз по месяцам
    forecast = model.predict(future)
    # Округление прогноза в большую сторону до целого числа и замена отрицательных значений на ноль
    forecast['yhat'] = forecast['yhat'].apply(lambda x: max(0, np.ceil(x)))
    # график прогноза будем показывать только для выбранных гиперпараметров
    if plots:
        fig = model.plot(forecast) # Рисуем базовый график с помощью Prophet
        plt.plot(test_m_df['ds'], test_m_df['y'], 'r.', label='Test Data') # Добавим тестовые данные на график
        plt.legend() # Добавим легенду
        plt.show()
    # объединяем `forecast` и `df_device_m` по индексам `ds`, добавляем столбец с целевым значением
    forecast = forecast.set_index('ds').join(df_device_m.set_index('ds'))
    # Получим предсказанные значения для тестового набора
    test_predictions = forecast['yhat'][-predictions_m:]
    # вычислим ошибки
    metrics = {}
    metrics['RMSE'] = np.sqrt(mean_squared_error(test_m_df['y'], test_predictions)) # Вычислите RMSE
    metrics['MAE'] = mean_absolute_error(test_m_df['y'], test_predictions) # Вычисляем MAE
    metrics['MAPE'] = mean_absolute_percentage_error(test_m_df['y'], test_predictions) # Вычисляем MAPE
    return forecast, metrics

```

Рис. 11. Процедура работы модели Prophet по месяцам (разработано авторами)

Fig. 11. Prophet model operation procedure by months

Фрагмент программы, приведенный ниже, осуществляет последовательный вызов процедуры подбора гиперпараметров для каждого прибора, подстановку этих параметров в расчет прогноза по модели, принимает таблицу с прогнозом по каждому прибору и добавляет в общую таблицу по всем приборам (рис. 12). Затем вычисляет суммарный прогноз на 1 квартал по каждому прибору и сохраняет его, как квартальный план в отдельной таблице. Первым этапом стала подготовка обучающей выборки на основе выгрузки из системы «1С:Предприятие». В выборку включались следующие параметры: наименование продукции, дата и объем отгрузки, дата заказа, дата запуска в производство, данные по остаткам, уровень сезонности, тип изделия (стандартное, проектное, экспортное), а также временные метки (неделя, месяц, квартал).

Были рассчитаны агрегированные характеристики: средняя скорость потребления, коэффициент вариации спроса, длительность производственного цикла. Для построения прогнозной модели был выбран метод градиентного бустинга (Gradient Boosting), показавший наилучшие результаты в задаче регрессии по предварительным тестам. Данный метод обладает высокой точностью и устойчивостью к выбросам, а также способен учитывать сложные нелинейные зависимости между признаками [20]. Обучение модели осуществлялось на Python с использованием библиотеки XGBoost. В качестве метрики качества модели использовалась ошибка среднего абсолютного отклонения (MAE), а также коэффициент детерминации (R^2). Результаты показали, что модель объясняет до 87% дисперсии спроса по основной номенклатуре [15, 21].

```

# Расчет прогноза по МЕСЯЦАМ
quarter_plan_df = pd.DataFrame() # инициализируем пустой датафрейм для сохранения прогноза на 1 квартал
metrics_df = pd.DataFrame() # инициализируем пустой датафрейм для сохранения метрик прогноза
for device in devices:
    print(device)
    # Фильтруем данные по прибору
    df_device = all_devices_df[all_devices_df['device'] == device]
    df_device = df_device.drop('device', axis=1)
    df_device_m = df_device.reset_index()
    #Выбираем гиперпараметры модели
    best_params = hyper_params_tunning(df_device_m)
    # Выполняем прогноз и сохраняем его в словаре
    prophet_forecast, metrics = prophet_m_work(df_device_m, best_params, True)
    prophet_forecast_df = pd.DataFrame(prophet_forecast) # сохраняем результат прогноза в датафрейм
    prophet_forecast_df.insert(0, 'device', device) # добавляем столбец с названием блока
    one_device_metrics_df = pd.DataFrame(metrics, index=[0]) # сохраняем метрики прогноза в датафрейм
    one_device_metrics_df.insert(0, 'device', device) # добавляем столбец с названием блока
    # в общий датафрейм по всем приборам добавляем прогноз по текущему прибору
    prophet_predictions_df = pd.concat([prophet_predictions_df, prophet_forecast_df])
    # в общий датафрейм с метриками прогноза по всем приборам добавляем метрики по текущему прибору
    metrics_df = pd.concat([metrics_df, one_device_metrics_df])
    # в файл прогноза добавляем прогнозируемый период
    quarter_plan_df = pd.concat([quarter_plan_df, prophet_forecast_df[-predictions_m:]]
# после выхода из цикла считаем сумму по каждому прибору за 3 прогнозируемых месяца
quarter_plan_df['yhat'] = quarter_plan_df['yhat'].astype(int)
quarter_plan_df = quarter_plan_df.groupby('device')['yhat'].sum().reset_index()

```

Рис. 12. Расчет прогноза по всем приборам (разработано авторами)

Fig. 12. Calculation of the forecast for all devices

После получения прогнозных значений спроса на продукцию в разрезе временных интервалов был реализован модуль расчета оптимального уровня запаса. В отличие от классических моделей, где используется фиксированный объем партии, здесь объем заказа адаптируется к прогнозному спросу и возможным логистическим задержкам. Модель учитывает также ограничения по складу, ресурсам и производственной мощности, что позволяет принимать решения в многономенклатурной и многоресурсной среде.

Программная реализация модели осуществлялась в среде Python с интеграцией в систему «1С:Предприятие» через API. Разработанный модуль формирует отчеты по каждой товарной позиции с прогнозом потребности, рекомендуемым объемом заказа и оценкой рисков дефицита или избыточных запасов. Результаты тестирования модели на исторических данных показали снижение издержек на хранение на 15%, улучшение точности поставок (по срокам) на 12% и сокращение объемов неликвидов на 22% по сравнению с текущей системой.

ЗАКЛЮЧЕНИЕ

По замыслу авторов работы наилучший эффект предсказания продаж можно получить, применив в разработке комплексную модель, ко-

торая интегрирует методы прогнозирования временных рядов и ABC-анализа. С одной стороны, ABC-анализ помогает сегментировать продукцию по значимости и объемам продаж, выделяя наиболее критичные позиции, требующие повышенного внимания, с другой стороны модель прогнозирования временных рядов позволяет предсказывать будущие изменения спроса, учитывая сезонные и трендовые компоненты, что способствует более обоснованному и гибкому планированию производства. В серийном производстве колебания спроса сложно предсказуемы и некоторые ошибки неизбежны, как показал расчет. Тем не менее анализ работы модели на реальных числовых данных продемонстрировал ее адекватность и применимость в рассматриваемых практических условиях. Для сглаживания скачков спроса должен служить страховой запас. В контексте рассматриваемого предприятия запас готовой продукции на складе должен обеспечивать потребности ориентировочно на один квартал вперед. Именно поэтому в качестве расчетного периода выбраны три месяца, составляющие один квартал. Расчет позволит максимально быстро учесть все обстоятельства и сформировать наиболее важнейшие заказы на производство недостающей на складе продукции в первую очередь на основе плана продаж на ближайший месяц.

Вторым приоритетом по мере освобождения производственных ресурсов должно осуществляться пополнение страхового запаса на ближайший квартал. Процесс прогнозирования должен повторяться каждый раз при поступлении в производство нового плана продаж на месяц. С учетом новых данных прогнозирования в план производства должны вноситься оперативные корректировки. Интеграция разработанной методики позволит обеспечить более точное распределение ресурсов, минимизацию излишков и недостатка продукции, а также приоритизацию производственных заказов в соответствии с актуальными бизнес-приоритетами. В результате, предприятие, взявшее ее на вооружение, сможет не только улучшить эффективность управления запасами и удовлетворение клиентского спроса, но и оптимизировать затраты, связанные с хранением и оборотом продукции.

В заключение отметим, что представленная программа служит лишь первым шагом в направлении повышения эффективности производственного планирования и управления запасами

готовой продукции. После завершения этапа тестирования и оценки точности расчетов программы в реальных условиях эксплуатации, рекомендуется переход к автоматизации процесса ежемесячного планирования на один квартал вперед. Для достижения этой цели необходимо интегрировать программу в платформу «1С: Предприятие» с учетом будущих корректировок и дополнений. Такая интеграция обеспечит высвобождение дополнительных ресурсов и существенное уменьшение числа ошибок, улучшая тем самым общую эффективность и точность управленческих процессов.

Настоящее исследование не только обогащает теоретическую базу, но и предоставляет практические рекомендации и перспективные направления для улучшения систем управления запасами в организациях с применением современных технологий.

Авторы заявляют об отсутствии конфликта интересов, требующего раскрытия в данной статье.

The authors declare the absence a conflict of interest warranting disclosure in this article.

ЛИТЕРАТУРА

1. Трофимов Ю.В., Ксенофонтова О.Л. Эффективное управление запасами - ключевой фактор успешной деятельности предприятия. *Сборник научных трудов вузов России "Проблемы экономики, финансов и управления производством"*. 2023. № 53. С. 72-75.
2. Трофимов Ю.В., Ксенофонтова О.Л. Машинное обучение в управлении запасами на предприятии. *Сборник научных трудов вузов России "Проблемы экономики, финансов и управления производством"*. 2024. № 55. С. 202-206.
3. Свиридова В.В., Кудряшова Т.С. Совершенствование системы управления запасами на торговом предприятии. *Beneficium*. 2019. №1 (30). <https://cyberleninka.ru/article/n/sovershenstvovanie-sistemy-upravleniya>.
4. Миролюбова А.А., Сяотун Я., Ксенофонтова О.Л. Эконометрический анализ взаимосвязи ВВП Китая с макроэкономическими показателями. *Известия высших учебных заведений. Экономика, финансы и управление производством [Ивэкофин]*. 2024. № 1(59). С. 61-69. DOI 10.6060/ivecofin.2024591.675.
5. Миролюбова, А.А., Ворошин Д.А., Ксенофонтова О.Л. Опыт интеллектуального анализа и прогнозирования рынка акций. *Известия высших учебных заведений. Экономика, финансы и управление производством [Ивэкофин]*. 2024. № 4(62). С. 55-63. DOI 10.6060/ivecofin.2024624.702.
6. Ксенофонтова О.Л., Миролюбова А.А., Фокин С.А. Использование методов интеллектуального анализа данных в банковской сфере. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 4(76). С. 76-83. DOI 10.6060/snt.20237604.00010.
7. Васильев Д.В. Системы и модели управления запасами предприятия. Проблемы развития социально-экономических систем: Материалы VIII Международной научной конференции молодых учёных и студентов. Донецк, 18 апреля 2024 года. Донецк: Донецкий национальный университет, 2024. С. 181-184.

REFERENCES

1. Trofimov Yu.V., Ksenofontova O.L. Effective inventory management is a key factor in the successful operation of the enterprise. *Collection of scientific papers of Russian universities "Problems of economics, finance and production management"*. 2023. N 53. P. 72-75.
2. Trofimov Yu.V., Ksenofontova O.L. Machine learning in inventory management at the enterprise. *Collection of scientific papers of Russian universities "Problems of economics, finance and production management"*. 2024. N 55. P. 202-206.
3. Sviridova V.V., Kudryashova T.S. Improvement of the inventory management system at a trading enterprise. *Beneficium*. 2019. N 1 (30). <https://cyberleninka.ru/article/n/sovershenstvovanie-sistemy-upravleniya>.
4. Mirolubova A. A., Xiaotong Ya., Ksenofontova O.L. Econometric analysis of the relationship of China's GNP with macroeconomic indicators. *Ivecofin*. 2024. N 1(59). P. 61-69. DOI 10.6060/ivecofin.2024591.675
5. Mirolubova, A. A., Voroshin, D.A., Ksenofontova, O.L. The experience of intellectual analysis and forecasting of the stock market. *Ivecofin*. 2024. N 4(62). P. 55-63. DOI 10.6060/ivecofin.2024624.702.
6. Ksenofontova O. L., Mirolubova A.A., Fokin S.A. The use of data mining methods in the banking sector. *Modern high technology. Regional application*. 2023. N 4(76). P. 76-83. DOI 10.6060/snt.20237604.00010.
7. Vasiliev D. V. Systems and models of enterprise inventory management. Problems of development of socio-economic systems: Proceedings of the VIII International Scientific Conference of Young Scientists and Students. Donetsk, April 18, 2024. Donetsk: Donetsk National University, 2024. P. 181-184.
8. Dyatlova V. O., Syroizhko V. V. Models and methods of inventory management of the enterprise. *International Journal of Humanities and Natural Sciences*. 2021. N 3-1. <https://cyberleninka.ru/article/n/modeli-i-metody-upravleniya-zapasami-predpriyatiya>.

8. Дятлова В.О., Сыройжко В.В. Модели и методы управления запасами предприятия. *Международный журнал гуманитарных и естественных наук*. 2021. № 3-1. <https://cyberleninka.ru/article/n/modeli-i-metody-upravleniya-zapasami-predpriyatiya>.
9. Ксенофонтowa О.Л., Новосельская Н.А. Моделирование деятельности торговой организации с помощью ABC-XYZ - анализа. *Современные наукоемкие технологии. Региональное приложение*. 2013. № 10-1. С. 20-22.
10. Стерлигова А.Н. Управление запасами в цепях поставок: учебник. М.: ИНФРА-М, 2008. 430 с.
11. Гонова О.В., Гонова В.А. Техничко-экономическое обновление инвестиционного проекта создания упаковочного производства пивоваренной компании. *Современные наукоемкие технологии. Региональное приложение*. 2022. № 2(70). С. 22-28. DOI 10.6060/snt.20227002.0003.
12. Гонова О.В. Диагностика риска банкротства предприятия на основе финансового моделирования. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 3(75). С. 13-19. DOI 10.6060/snt.20237503.0002.
13. Гонова О.В., Мalyгин А.А., Лукина В.А. Совершенствование модели управления бизнес-процессами в картофелеводстве. *Известия высших учебных заведений. Экономика, финансы и управление производством [Ивэкофин]*. 2023. № 1(55). С. 47-57. DOI 10.6060/ivecofin.2023551.634.
14. Крисанова В.А. Внедрение бережливых технологий с использованием подхода «точно в срок» в пищевой перерабатывающей промышленности. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 1(77). С. 78-85. DOI 10.6060/snt.20247701.00010.
15. Рычихина Н.С. Большие данные и искусственный интеллект как основа реализации региональных цифровых проектов. В сборнике: Наука о данных. Материалы международной научно-практической конференции. 2020. С. 264-265.
16. Сизова О.В., Савченко О.В., Рычихина Н.С. Внедрение цифровых технологий в системе учета продаж розничного магазина. *Современные наукоемкие технологии. Региональное приложение*. 2022. № 4 (72) С. 62-68.
17. Берман Кеннеди Основы Python для Data Science. СПб.: Питер, 2023. 272 с.: ил.
18. Метрики в машинном обучении: понимание, применение и интерпретация. <https://shakhbanov.org/metriki-v-mashinnom-obuchenii/?ysclid=m4ylpc4chr723334976>.
19. Предсказываем будущее с помощью библиотеки Facebook Prophet. <https://habr.com/ru/companies/ods/articles/323730>.
20. Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г., Гримицкий П.Н. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2(78). С. 50-58. DOI 10.6060/snt.20247802.0007.
21. Гонова О.В., Гонова В.А. Оценка эффективности внедрения автоматизированной системы краткосрочного прогнозирования для перерабатывающего предприятия пищевой промышленности. *Сборник научных трудов вузов России «Проблемы экономики, финансов и управления производством»*. 2022. № 50. С. 177-181.
9. Ksenofontova O.L., Novoselskaya N.A. Modeling the activities of a trade organization using ABC-XYZ analysis. *Modern high technology. Regional application*. 2013. N 10-1. P. 20-22.
10. Sterligova A.N. Inventory management in supply chains: textbook. Moscow: INFRA-M. 2008. 430 p.
11. Gonova O.V., Gonova V.A. Feasibility study of the investment project for the creation of a packaging production of a brewing company. *Modern high technology. Regional application*. 2022. N 2(70). P. 22-28. DOI 10.6060/snt.20227002.0003.
12. Gonova O.V. Diagnostics of the bankruptcy risk of an enterprise based on financial modeling. *Modern high technology. Regional application*. 2023. N 3(75). P. 13-19. DOI 10.6060/snt.20237503.0002.
13. Gonova O.V., Malygin A.A., Lukina V.A. Improving the business process management model in potato growing. *Ivecofin*. 2023. N 1(55). P. 47-57. DOI 10.6060/ivecofin.2023551.634.
14. Krisanova V.A. Introduction of lean technologies using the "just-in-time" approach in the food processing industry. *Modern high technology. Regional application*. 2024. N 1(77). P. 78-85. DOI 10.6060/snt.20247701.00010.
15. Rychikhina N.S. Big data and artificial intelligence as a basis for the implementation of regional digital projects. In the collection: Data Science. Proceedings of the international scientific and practical conference. 2020. P. 264-265.
16. Sizova O.V., Savchenko O.V., Rychikhina N.S. Implementation of digital technologies in the sales accounting system of a retail store. *Modern high technology. Regional application*. 2022. N 4 (72) P. 62-68.
17. Berman Kennedy Fundamentals of Python for Data Science. St. Petersburg: Peter, 2023. 272 p.: ill.
18. Metrics in machine learning: understanding, application, and interpretation. <https://shakhbanov.org/metriki-v-mashinnom-obuchenii/?ysclid=m4ylpc4chr723334976>.
19. Predicting the future using the Facebook Prophet library. <https://habr.com/ru/companies/ods/articles/323730>.
20. Astrakhanseva I.A., Kotenev T.E., Gorev S.V., Astrakhansev R.G., Grimenitsky P.N. Gradient boosting method for predicting management decisions in a multilayer cryogenic system. *Modern high technology. Regional application*. 2024. N 2(78). P. 50-58. DOI 10.6060/snt.20247802.0007.
21. Gonova O.V., Gonova V.A. Evaluation of the effectiveness of the implementation of an automated short-term forecasting system for a food processing enterprise. *Collection of scientific papers of Russian universities "Problems of Economics, Finance and Production Management"*. 2022. N 50. P. 177-181.

Поступила в редакцию(Received) 16.03.2025
Принята к опубликованию (Accepted) 12.04.2025