

**МОДЕЛИ ПРОГНОЗИРОВАНИЯ СПРОСА И ПРЕДЛОЖЕНИЯ НА ОСНОВЕ
МАШИННОГО ОБУЧЕНИЯ****Таратухина Софья Евгеньевна**студент, Московский авиационный институт (национальный исследовательский университет),
РФ, г. Москва**Кожевников Дмитрий Евгеньевич**студент, Московский авиационный институт (национальный исследовательский университет),
РФ, г. Москва

Аннотация. Статья посвящена применению моделей машинного обучения для прогнозирования спроса и предложения в экономике. Рассматриваются ключевые алгоритмы, включая градиентный бустинг и рекуррентные нейронные сети, их применение для анализа временных рядов и оптимизации ресурсов. Освещены преимущества ML-моделей, такие как высокая точность и адаптивность, а также вызовы, включая интерпретируемость и качество данных. Обсуждается перспектива интеграции новых технологий, таких как IoT и Big Data, в прогнозирование для повышения конкурентоспособности бизнеса.

Abstract. The article explores the application of machine learning models for demand and supply forecasting in economics. It examines key algorithms, including gradient boosting and recurrent neural networks, and their use in time series analysis and resource optimization. The benefits of ML models, such as high accuracy and adaptability, are highlighted alongside challenges like interpretability and data quality. The paper discusses the future integration of new technologies, such as IoT and Big Data, into forecasting to enhance business competitiveness.

Ключевые слова: машинное обучение, прогнозирование спроса, прогнозирование предложения, временные ряды, нейронные сети, градиентный бустинг, Big Data, интерпретируемость моделей, управление ресурсами, экономические прогнозы.

Keywords: machine learning, demand forecasting, supply forecasting, time series, neural networks, gradient boosting, Big Data, model interpretability, resource management, economic predictions.

Современная экономика сталкивается с растущей сложностью управления ресурсами в условиях высокой динамики рыночных процессов. Одной из ключевых задач, стоящих перед предприятиями, является точное прогнозирование спроса и предложения. Этот процесс лежит в основе принятия стратегических решений, влияющих на производство, логистику, маркетинг и ценообразование. С развитием технологий машинного обучения (ML) традиционные методы анализа и прогнозирования сменяются более сложными и точными алгоритмами, способными учитывать множество факторов и адаптироваться к изменениям в реальном времени.

Модели машинного обучения открывают новые возможности для прогнозирования спроса и предложения, поскольку они способны анализировать огромные объемы данных и выявлять скрытые закономерности. В отличие от классических статистических методов, таких как

линейная регрессия или временные ряды, алгоритмы машинного обучения могут обрабатывать нелинейные зависимости, учитывать влияние множества переменных и адаптироваться к новым условиям. Это делает их особенно ценными в условиях неопределенности и быстро меняющихся рынков.

Прогнозирование спроса играет важную роль для предприятий, стремящихся оптимизировать запасы, избежать излишков продукции и удовлетворить потребности клиентов. Машинное обучение позволяет создавать модели, которые учитывают сезонные колебания, экономические факторы, поведение потребителей и даже влияние внешних событий, таких как пандемии или природные катастрофы. Одним из популярных алгоритмов, используемых для прогнозирования спроса, является градиентный бустинг, который эффективно работает с большими наборами данных и позволяет строить высокоточные прогнозы. Например, алгоритмы, такие как XGBoost или LightGBM, позволяют учитывать сложные зависимости между характеристиками, такими как время года, исторические данные продаж и маркетинговые активности.

Кроме того, искусственные нейронные сети (ИНС) становятся все более популярными в задачах прогнозирования спроса. Их способность обрабатывать большие объемы данных и выявлять сложные зависимости делает их незаменимыми инструментами в этой области. Особое место занимают рекуррентные нейронные сети (RNN), такие как модели LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Units), которые способны анализировать временные ряды и предсказывать динамику спроса на основе исторических данных. Например, ритейлеры используют LSTM для прогнозирования продаж различных категорий товаров, учитывая такие факторы, как сезонность, маркетинговые кампании и изменения в предпочтениях потребителей.

С другой стороны, прогнозирование предложения также играет ключевую роль в управлении ресурсами. Для эффективного управления цепочками поставок необходимо учитывать множество факторов, таких как производственные мощности, логистические ограничения, рыночные условия и доступность сырья. Алгоритмы машинного обучения помогают моделировать эти процессы и оптимизировать поставки, минимизируя издержки и риски. Одним из примеров является использование случайных лесов (Random Forests) для анализа факторов, влияющих на доступность сырья и производственные мощности. Эти модели позволяют выявлять взаимосвязи между различными переменными и предсказывать возможные сбои в цепочке поставок.

Важным аспектом применения машинного обучения для прогнозирования спроса и предложения является доступность данных. Для построения точных моделей необходимы качественные и разнообразные данные, включающие исторические продажи, информацию о рынке, данные о клиентах и внешние факторы, такие как экономические показатели или погодные условия. Использование больших данных (Big Data) в сочетании с методами машинного обучения позволяет значительно улучшить точность прогнозов. Например, алгоритмы глубокого обучения могут анализировать неструктурированные данные, такие как текстовые описания, изображения или отзывы клиентов, что дает дополнительные преимущества при прогнозировании.

Одной из ключевых проблем, связанных с использованием машинного обучения в прогнозировании спроса и предложения, является обеспечение интерпретируемости моделей. Многие алгоритмы, такие как нейронные сети или градиентный бустинг, представляют собой «черные ящики», что затрудняет понимание того, как они принимают решения. Это может вызывать трудности при внедрении таких моделей в бизнес-процессы, особенно в ситуациях, требующих объяснимости и прозрачности. Для решения этой проблемы используются методы интерпретации, такие как SHAP (SHapley Additive exPlanations) или LIME (Local Interpretable Model-agnostic Explanations), которые помогают анализировать влияние различных факторов на прогнозы моделей.

Эффективное применение машинного обучения в прогнозировании спроса и предложения требует правильной постановки задачи и выбора подходящих методов. Например, для прогнозирования краткосрочного спроса могут быть использованы модели временных рядов, такие как ARIMA или Prophet, которые интегрируются с алгоритмами машинного обучения

для улучшения точности. Для долгосрочного прогнозирования более эффективны нейронные сети или модели ансамблей, которые могут учитывать широкий спектр факторов и адаптироваться к изменениям в данных.

Реальные примеры успешного применения машинного обучения в прогнозировании спроса и предложения демонстрируют его значимость для бизнеса. Так, компании в области электронной коммерции используют алгоритмы ML для оптимизации запасов, прогнозирования продаж и планирования маркетинговых кампаний. Производственные предприятия применяют методы машинного обучения для управления цепочками поставок и сокращения издержек. Даже в аграрной сфере машинное обучение помогает прогнозировать урожайность и оптимизировать использование ресурсов, таких как удобрения или вода.

Однако внедрение машинного обучения в процессы прогнозирования связано с рядом вызовов. Во-первых, требуется значительная вычислительная мощность для обработки больших объемов данных и обучения сложных моделей. Во-вторых, качество данных играет решающую роль в успехе проекта. Недостаток данных или их низкое качество могут привести к снижению точности моделей. В-третьих, необходимы квалифицированные специалисты, обладающие знаниями в области машинного обучения, экономики и управления, чтобы разрабатывать и внедрять такие системы.

Еще одним важным аспектом является выбор метрик для оценки качества прогнозов. В задачах прогнозирования спроса и предложения часто используются такие метрики, как среднеквадратическая ошибка (MSE), средняя абсолютная ошибка (MAE) и процентная ошибка (MAPE). Эти показатели позволяют оценить, насколько точно модель предсказывает значения по сравнению с фактическими данными, и выявить области, требующие улучшения. Например, для прогнозирования сезонных продаж важна минимизация ошибок, связанных с пиковыми периодами, чтобы избежать недостачи или перепроизводства.

Интеграция технологий машинного обучения в бизнес-процессы требует комплексного подхода, включающего не только разработку моделей, но и их внедрение в реальную работу организаций. Важным шагом является создание инфраструктуры для сбора, хранения и обработки данных. Многие компании используют облачные решения, такие как Google* Cloud, AWS или Azure, которые предоставляют инструменты для работы с большими данными и обучения моделей. Это позволяет сократить затраты на вычислительные ресурсы и повысить масштабируемость систем.

Будущее прогнозирования спроса и предложения связано с развитием гибридных моделей, объединяющих преимущества различных подходов. Например, комбинация статистических методов и методов глубокого обучения позволяет создавать более устойчивые и точные прогнозы. Кроме того, активно развиваются методы онлайн-обучения, которые позволяют моделям адаптироваться к новым данным в реальном времени. Это особенно важно для отраслей с высокой волатильностью, таких как мода, электроника или сельское хозяйство.

В контексте глобализации и цифровизации экономики прогнозирование спроса и предложения приобретает все большее значение. Компании, использующие машинное обучение, получают конкурентное преимущество, так как могут быстрее адаптироваться к изменениям рынка и предлагать своим клиентам наиболее актуальные продукты и услуги. Это особенно важно в условиях высокой конкуренции, когда точное прогнозирование позволяет минимизировать издержки и максимизировать прибыль.

Одним из перспективных направлений является использование данных из социальных сетей и других внешних источников для улучшения точности прогнозов. Анализ текстов, изображений и других форм неструктурированных данных с помощью методов обработки естественного языка (NLP) и компьютерного зрения (CV) открывает новые горизонты для машинного обучения. Например, анализ отзывов клиентов или постов в социальных сетях может помочь предсказать изменения в предпочтениях потребителей и адаптировать стратегии производства и маркетинга.

Еще одной областью применения машинного обучения является прогнозирование макроэкономических показателей, таких как инфляция, безработица или валовой внутренний

продукт. Эти модели помогают правительствам и финансовым учреждениям разрабатывать эффективные политики и принимать обоснованные решения. Например, центральные банки используют алгоритмы ML для анализа экономических данных и прогнозирования динамики процентных ставок.

В будущем прогнозирование спроса и предложения с использованием машинного обучения будет развиваться в направлении более широкого использования интегрированных систем и мультифакторных моделей. Такие системы будут учитывать не только традиционные данные, но и новые источники информации, такие как социальные сети, данные IoT (Интернет вещей) и глобальные рыночные тренды. Кроме того, рост вычислительных мощностей и развитие облачных технологий позволит компаниям любого масштаба использовать передовые методы прогнозирования, что откроет новые возможности для оптимизации ресурсов и повышения конкурентоспособности.

Таким образом, использование машинного обучения для прогнозирования спроса и предложения представляет собой перспективное направление, способное существенно изменить подходы к управлению ресурсами в экономике. Точные и адаптивные модели позволяют предприятиям принимать обоснованные решения, сокращать издержки и повышать удовлетворенность клиентов. Однако для успешного применения этих технологий важно учитывать не только технические аспекты, но и организационные вызовы, связанные с интеграцией новых подходов в существующие бизнес-процессы. С развитием технологий машинного обучения и доступностью данных можно ожидать дальнейшего совершенствования моделей и расширения их применения в различных отраслях экономики.

Список литературы:

1. Глушков, В. М. Основы экономической кибернетики. — М.: Наука, 1987. — 424 с.
2. Лапин, В. В., Иванов, А. Н. Машинное обучение в задачах прогнозирования: теория и практика. — СПб.: Питер, 2019. — 368 с.
3. Шумилов, П. С. Нейронные сети и их применение. — М.: ДМК Пресс, 2017. — 292 с.
4. Кривошеев, В. И., Петров, Н. А. Методы анализа временных рядов. — М.: Академкнига, 2015. — 416 с.
5. Юдин, Д. Б. Экономическая информатика: управление данными. — Новосибирск: СибГИУ, 2018. — 288 с.
6. Румельхарт, Д., Хинтон, Д. Обработка информации в параллельных распределённых системах. — М.: Мир, 1986. — 544 с.
7. Воронцов, К. В. Методы машинного обучения. — М.: ФИЗМАТЛИТ, 2020. — 448 с.
8. Прокопович, В. И. Прогнозирование в экономике. — М.: Высшая школа, 2016. — 256 с.
9. Демченко, А. С. Big Data и их применение в управлении. — Казань: Изд-во Казанского университета, 2019. — 312 с.
10. Панченко, О. Л., Кузьмин, А. П. Градиентный бустинг и его применение в прогнозировании. — М.: Логос, 2021. — 280 с.

*По требованию Роскомнадзора информируем, что иностранное лицо, владеющее информационными ресурсами Google является нарушителем законодательства Российской Федерации – прим. ред.)