



ОПРЕДЕЛЕНИЕ ПОДХОДОВ К РАЗРАБОТКЕ НЕЙРОСЕТОВОЙ ПРОГНОСТИЧЕСКОЙ МОДЕЛИ ДЛЯ УПРАВЛЕНИЯ РАБОТОЙ МОРСКИХ ТЕРМИНАЛОВ

О. И. Мазуренко

Государственный университет морского и речного флота имени адмирала С. О. Макарова

Сфера морских грузоперевозок переживает сегодня технологическую трансформацию благодаря внедрению искусственного интеллекта, который позволяет оптимизировать логистику, повысить эффективность портовых операций, сократить издержки и время простоя морских судов и оборудования грузовых терминалов. Искусственный интеллект демонстрирует значительные преимущества в управлении процессами, прогнозировании и адаптации к изменяющимся условиям международной транспортной логистики и торговли, однако, при этом существует проблема в определении приемлемых подходов и методов разработки программных решений и их внедрения, особенно с учетом высоких начальных затрат и сложностей интеграции в оперативную деятельность морских портов. Цель проведенного исследования - определение подходов (методов и методик) к использованию искусственного интеллекта в рамках разработки прогностической нейросетевой модели поступления партий грузов сухопутным транспортом в морские порты для погрузки на суда. В исследовании с использованием методов сравнительного анализа методологий и обобщения установлена критическая важность точного прогнозирования сроков прибытия грузов и флота для эффективной работы стивидорных компаний. Полученные результаты являются базой для дальнейшей разработки нейросетевых моделей управления морскими терминалами с целью повышения производительности и снижения задержек. Предложенный подход универсален и применим к различным типам портовых терминалов, обладая как теоретической значимостью, так и высоким практическим потенциалом. В исследовании определены подходящие методы построения нейросетевой прогностической модели – метод случайных деревьев и метод с использованием градиентного бустинга, а также предложены статистические критерии её оценки - коэффициент детерминации, среднеквадратическая ошибка и средняя абсолютная ошибка. Проведен анализ ключевых сложностей, препятствующих практической реализации модели и использованию в работе морских портов. Сделан вывод, что выбранные методы машинного обучения обладают потенциалом для повышения эффективности управления портами, позволяют прогнозировать работу транспорта, оптимизировать распределение ресурсов, автоматизировать рутинные процессы и поддерживать принятие обоснованных управленческих решений.

Ключевые слова: управление работой морских портов, машинное обучение, нейросетевые модели.

Для цитирования:

Мазуренко, О. И. Определение подходов к разработке нейросетевой прогностической модели для управления работой морских терминалов / О. И. Мазуренко // Системный анализ и логистика. – 2025. – № 4(47). – с. 18-28. DOI: 10.31799/2077-5687-2025-4-18-28.

DEVELOPMENT OF A NEURAL NETWORK PREDICTIVE MODEL FOR MANAGING THE OPERATION OF MARINE TERMINALS

O. I. Mazurenko

Admiral Makarov State University of Maritime and Inland Shipping

The marine freight industry is currently undergoing a technological transformation thanks to the introduction of artificial intelligence, which allows us to optimize logistics, improve the efficiency of port operations, and reduce costs and downtime of vessels and terminal equipment. Artificial intelligence demonstrates significant advantages in process management, forecasting, and adaptation to changing conditions of international transport logistics, however, there is a problem in identifying acceptable approaches and methods for developing software solutions and implementing them, especially given the high initial costs and difficulties in integrating them into the operational activities of seaports. The objective of the study is to identify approaches (methods and techniques) to using artificial intelligence within the framework of a predictive neural network model for the arrival of cargo consignments by land transport to seaports for loading onto vessels. The study, using comparative analysis of methodologies and generalization, established the critical importance of accurately forecasting the arrival times of cargo and fleet for the efficient operation of stevedoring companies. The results became the basis for further development of neural network models for managing sea terminals in order to improve productivity and reduce delays. The proposed approach is universal and applicable to various types of port terminals, possessing both theoretical significance and high practical potential. The study identifies suitable methods for constructing a neural network predictive model - the random tree method and the gradient boosting method,



and proposes statistical criteria for its evaluation - the coefficient of determination, the mean square error, and the mean absolute error. An analysis of the key difficulties that hinder the practical implementation of the model and its use in the operation of seaports is carried out. It is concluded that the selected machine learning methods have the potential to improve the efficiency of port management, allow predicting transport operations, optimizing resource allocation, automating routine processes, and supporting informed management decision-making.

Keywords: seaport management, machine learning, neural network models.

For citation:

Mazurenko, O. I. Development of a neural network predictive model for managing the operation of marine terminals / O. I. Mazurenko // *System analysis and logistics*. – 2025. – № 4(47). – p. 18-28. DOI: 10.31799/2077-5687-2025-4-18-28.

Введение

В сфере морских грузоперевозок, которая охватывает обширный круг процессов: от функционирования и управления работой портов и флота, транспортной логистики и складского хозяйства и до судостроения и производства погрузо-разгрузочного оборудования, сегодня наблюдается серьезный интерес к инновационным решениям, основанным на инновационных возможностях компьютерных технологий. Цель этих решений – оптимизировать управление и планирование процессов для сокращения издержек и получения преимуществ перед конкурентами. Проведенные зарубежными и отечественными авторами исследования различных аспектов применения искусственного интеллекта (далее – ИИ) демонстрируют как его преимущества, так и сложности, возникающие при его интеграции в портовые, судоходные и логистические операции [1].

К основным преимуществам следует отнести возможности внедрения и сочетания таких технологий, как «Интернет вещей» (далее – IoT), блокчейн и машинного обучения (далее – МО) для целей совершенствования операционных процедур, направленных на повышение эффективности работы морских портов и флота, сокращение сроков выполнения грузовых работ и оптимизацию использования ресурсов с целью снижения операционных затрат. Так применение ИИ для целей оптимизации процессов перевалки грузов может существенно ускорить проведение погрузо-разгрузочных операций, что продемонстрировано на примере морского порта Роттердама, где ИИ используется для определения наиболее эффективного плана размещения контейнеров на судах-контейнеровозах. Внедрение технологий на базе ИИ для предиктивного обслуживания позволило контролировать состояние перегрузочного оборудования и предвидеть возможные отказы технических средств в морском порту Лос-Анджелеса, где подобные меры привели к сокращению времени технических простоев и увеличению срока эксплуатации портового оборудования. Цифровизация портовых процессов и документооборота позволяет значительно повысить эффективность операций, сокращая время, которое суда и груз проводят в морских портах [2].

Однако, наряду с этими достоинствами, существуют и достаточно серьезные препятствия повсеместного внедрения систем на базе ИИ, такие как: большие начальные затраты на развертывание и внедрение, постоянная необходимость обновления данных для повышения эффективности работы подобных систем и подготовки обученных специалистов для работы с передовыми технологиями. Внедрение в работу морских портов и терминалов стратегии, нацеленной на использование возможностей ИИ в портовых и логистических операциях, несмотря на существующие сложности интеграции, создаст будущее, где порты будут работать с невиданной до этого точностью и эффективностью [3].

В современных условиях глобальной экономики морской судоходный транспорт остается ключевым элементом международной торговли, позволяя перемещать большие объемы товаров на дальние расстояния. При этом процесс работы морского судоходства и морских портов опирается на решение ряда сложных задач, требующих точного планирования и адаптации к постоянно меняющимся условиям. Изменения погодных условий, конъюнктуры торговли в регионе, задержки в погрузке и выгрузке грузов, сложности во взаимодействии с сухопутным транспортом, все это создает риски непредвиденного увеличения



эксплуатационных расходов. В подобных условиях становится особенно важным эффективно определять даты и сроки прибытия как судов, так и грузов в морские порты и управлять временем, которое суда и грузы проводят в порту для минимизации финансовых издержек. Преимущества внедрения масштабируемых современных компьютерных технологий, таких как ИИ, заключаются в улучшении планируемости и реактивности портовых операций [4].

Так, например, современный функционал ИИ уже сегодня способен прогнозировать погодные условия, анализируя исторические и спутниковые (GPS) данные, а также предсказывать движение партий грузов сухопутным транспортом в хинтерленде, что позволяет осуществлять управление работой флота и портов практически в режиме реального времени и минимизировать время их простоя [5]. Помимо этого, с помощью ИИ и аналитики больших данных (big data) можно оптимизировать работу портовых складов, определять суточные планы обработки судов и грузов в порту, что в итоге будет способствовать ускорению непосредственно процессов разгрузки и погрузки, и, в итоге, приведет к снижению переменных затрат. Использование ИИ и других подобных передовых компьютерных технологий позволит повысить устойчивость портовых операций, позволяя портам лучше адаптироваться к изменениям в условиях торговли в регионе и мира, или внутренним изменениям в логистических цепочках. Например, системы на основе ИИ могут отслеживать изменения в спросе на товарных биржах и рынках, и, автоматически корректировать планы доставки и распределения грузов, тем самым позволяя сократить время отклика на изменения в рынке и повысить общую эффективность функционирования портов и флота [6].

Цель исследования заключается в определении подходов (методов и методик) к использованию искусственного интеллекта в рамках прогностической нейросетевой модели поступления партий грузов сухопутным транспортом в морские порты для погрузки на суда. Использование подобной прогностической нейросетевой модели позволит повысить качество управления работой флота и портов. Определение возможностей и направлений внедрения искусственного интеллекта в портовые процессы, даст возможность в дальнейшем определить варианты увеличения прибыльности портов и сокращения их операционных расходов.

Методы и материалы исследования

Исследование выполнено в 2025 г. на базе кафедры коммерческой эксплуатации водного транспорта Государственного университета морского и речного флота им. адмирала С. О. Макарова в г. Санкт-Петербург. В исследовании были использованы теоретические методы: сравнительный анализ методологий и обобщение. В качестве материалов для исследования использовались научные статьи отечественных авторов в области искусственного интеллекта, МО и управления работой транспортных систем и объектов. В работе определено, что проблема эффективного прогнозирования сроков и объемов поступления груза и флота является одной из ключевых для стивидорных компаний, работающих в морских портах. Рациональные прогнозы позволяют эффективно распределять и планировать складские, тыловые и причальные мощности с целью увеличения общей производительности и минимизации задержек грузов и транспорта в порту. Таким образом, данное исследование не только имеет теоретическую значимость, но потенциально является основой для будущих практических результатов в части разработки и имплементации нейросетевой прогностической модели в процесс управления работой морского терминала.

Результаты исследования

Предлагается к рассмотрению следующая ситуация, которая наглядно способна продемонстрировать высокую сложность данного процесса: крупный экспортный портовый морской терминал обрабатывает грузовые суда различных размеров, которые прибывают в течение недели в разные интервалы времени. На терминале ограниченное количество причалов, где суда могут осуществлять швартовку для погрузки. Груз на терминал со стороны хинтерленда доставляется исключительно железнодорожным транспортом и перегружается на



тыловом железнодорожном фронте терминала на склад. Вместимость склада и возможности тылового фронта также ограничены. Таким образом, основная управленческая задача заключается в оптимизации ресурсов причальной линии, склада и тылового фронта для обеспечения их бесперебойной работы и сокращения времени ожидания в очереди судов, железнодорожных составов, а также максимального задействования складских мощностей и технологических ресурсов терминала [7].

В подобной ситуации МО может применяться для прогнозирования времени поступления груза и судов на терминал, а также времени коммерческого хранения и погрузо-разгрузочных работ. В процессе решения подобной задачи также должны учитываться индивидуальные характеристики судов и железнодорожных составов, уникальное для каждого судна и поезда время прибытия, ожидаемое время и интенсивность погрузки/разгрузки, а также уровень приоритета транспортных средств, определяемый на основе типа груза и договорных условий.

С помощью применения инновационных компьютерных технологий, таких как МО, возможно полное преобразование традиционного подхода к управлению портовыми операциями. В потенциальной прогностической нейросетевой модели приемлемо использовать как имеющиеся статистические данные о графиках прибытия судов и поступления железнодорожных составов за прошлые аналогичные периоды, так и реальные индикативы, такие как данные из АИС (Автоматизированных информационных систем) ж/д перевозчиков, сведения с GPS маячков, данные о погодных условиях, сведения о текущем уровне загрузки терминала и операционных ограничениях. Эти данные возможно обработать с применением различных алгоритмов МО [8].

Интеграция прогнозов, полученных с применением алгоритмов МО, является ключевым отличием нейросетевой модели от традиционных методов управления, которые зачастую основываются на интуитивных и эвристических подходах. Использование прогностической нейросетевой модели как основы для принятия управленческих решений позволит не только снизить время простоя транспорта в ожидании обработки, но и минимизировать затраты непосредственно на портовые операции, т.к. имея на руках более точные прогнозы можно разрабатывать оптимальные суточные и недельные планы работ [9].

Но важно отметить, что комплексный подход с применением алгоритмов МО включает в себя не только прогнозирование, но и динамическое управление ресурсами, что позволяет адаптировать операционные планы в реальном времени. Если модель, к примеру, предсказывает, что железнодорожный состав или судно задерживается, то терминал может оперативно изменить очередность приема судов/поездов и поменять график работы грузовых фронтов и склада, чтобы максимально сократить время простоя.

В конечном итоге, только интеграция прогнозирования и управления ресурсами приводит к более скоординированной и эффективной системе [10]. Научные исследования в области применения МО в портовых и логистических операциях не только расширяют границы научного познания, но и могут подтвердить тезис о том, что использование нейросетей и технологий МО в процессах управления портами вскоре станут критически важными для успешного функционирования.

Ключевым достоинством прогностической нейросетевой модели является её способность адаптироваться и учиться на предыдущих данных. По мере накопления информации о движении транспорта – судов и железнодорожных составов, а также о портовых операциях и работе грузовых фронтов обучаемая модель становится все более точной и может с высокой степенью сходимости прогнозов и фактов предсказывать будущие тенденции и проблемы. Подобные прогностические модели могут быть адаптированы как для импортных, так и для экспортных терминалов различных типов – наливных, навалочных, контейнерных и пр. Это позволяет портовым операторам находить именно те решения, которые возможно применить к их конкретным потребностям и условиям работы.



Определены основные подходы МО, которые могут быть применены для построения перспективной прогностической нейросетевой модели [11], а именно:

Метод случайного леса (Random Forest, далее – RF), в котором использует ансамбль из N решающих деревьев, $\{T_1, T_2, \dots, T_N\}$. При этом каждое из деревьев T_i создаётся с использованием так называемой бутстрап-выборки (англ. – bootstrap sample) из обучающих данных D , которая представляет собой выборку с возвратом из исходного набора данных размером M . Этот подход также известен как бэггинг (англ. – bagging) или бутстрап-агрегация (англ. – bootstrap aggregating). Кроме того, когда осуществляется разделение узла в процессе построения дерева, вместо нахождения наиболее подходящего разделения среди всех доступных признаков выбирается случайное подмножество из k признаков из общего количества K признаков. После этого оптимальное разделение определяется только для этого подмножества. Такой подход минимизирует необходимость в поиске наилучшего деления среди всех признаков. Элемент случайности в этом методе повышает надёжность модели и помогает избежать переобучения.

Процесс обучения при использовании метода RF строится следующим образом – рассматривается некий объем исходных данных (формула 1):

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_M, y_M)\}, \quad (1)$$

где: x_i — вектор признаков, y_i — целевая переменная для каждого экземпляра i .

Главной целью регрессора случайного леса (RF) является создание такой модели, которая способна предсказывать значение y для новых экземпляров на основе их признаков x . Процесс обучения для каждого дерева T_i в модели RF включает несколько важных этапов. Во-первых, создаётся бутстрап-выборка D_i из исходного набора данных D . После этого происходит рекурсивное разделение выборки D_i в каждом узле, начиная с корневого, и продолжается до тех пор, пока не будут достигнуты заданные критерии остановки, такие как максимальная глубина дерева или минимальное количество образцов в листе. При этом в каждом шаге для нахождения наилучшего разделения выбирается оптимальный вариант из случайно выбранного подмножества k признаков.

Процесс прогнозирования при использовании метода RF строится следующим образом: когда приходит время делать прогноз для нового экземпляра x , итоговое значение определяется как среднее предсказаний, полученных от всех деревьев, входящих в лес по формуле 2:

$$\hat{Y} = \frac{1}{N} \sum_{i=1}^N T_j(x), \quad (2)$$

где: $T_j(x)$ – прогноз по дереву для x , а общее количество деревьев обозначается как N .

Метод случайного леса обладает доказанной эффективностью для снижения количества ошибок при осуществлении прогнозирования за счет снижения дисперсии без сколь-либо ощутимого увеличения смещения. Больше деревьев N в целом снижают дисперсию прогнозных значений. Ансамблевое обучение позволяет объединять прогнозы из нескольких RF, что дает существенных прирост точности. Блок-схема алгоритма метода случайного леса представлена на рис. 1:




Рис. 1. Блок-схема алгоритма метода случайного леса (Составлен автором по результатам данного исследования)

Синергетический эффект от предсказаний нескольких RF позволяет получать более точные итоговые результаты и даёт возможность работать с широким набором исходных данных и выполнять анализ пропущенных значений.

Метод с использованием градиентного бустинга достаточно широко применяется в МО благодаря своей высокой скорости и производительности. Одной из наиболее распространенных реализаций этого метода является *Экстремальное градиентное усиление* (*eXtreme Gradient Boosting* или *XGBoost*), которое представляет собой улучшенную версию традиционного градиентного усиления. В отличие от случайного леса (RF), который строит и комбинирует множество деревьев решений параллельно, которые не взаимодействуют между собой, XGBoost создает деревья решений последовательно. Каждое новое дерево разрабатывается с целью исправления ошибок, допущенных предыдущими деревьями, что позволяет значительно повысить общую эффективность модели МО. Использование XGBoost делает прогностическую модель более оптимизированной и способной справляться как со сложными задачами регрессии, так и с задачами классификации на гораздо более высоком уровне. Целевая функция XGBoost состоит из двух ключевых компонентов: функции потерь и параметра регуляризации.

Функция потерь позволяет оценить потери между предсказанными и фактическими значениями, тогда как член регуляризации отвечает за управление сложностью модели, что помогает предотвратить переобучение. Соответственно целевая функция XGBoost направлена на минимизацию общей ошибки, которая учитывает как точность предсказаний, так и сложность модели. Блок-схема алгоритма работы XGBoost, иллюстрирующая его процесс и структуру представлена на рис. 2.




Рис. 2. Блок-схема алгоритма метода с использованием XGBoost (Составлен автором по результатам данного исследования)

При наличии набора данных $D = \{(x_i, y_i)\}_{i=1}^n$, в случаях, когда x_i – это вектор признака экземпляра i , а y_i – это соответствующее ему целевое значение, целевая функция оптимизации при итерации t может быть выражена как 3:

$$Obj^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t), \quad (3)$$

где: $y_i, \hat{y}_i^{(t-1)} + f_t(x_i)$ – специфичная функции потерь, $\Omega(f_t)$ – регуляризатор для каждого из t деревьев, f_t – прогноз t -ого дерева.

Процесс обучения. Метод обучения XGBoost представляет собой итеративный процесс, при котором к ансамблю деревьев добавляются новые деревья, каждое из которых нацелено на исправление ошибок, оставшихся от предыдущих деревьев. В этом процессе модель подстраивается с помощью функции f_t , которая оптимизирует целевую функцию. Это требует вычисления градиента и гессиана функции потерь, что в свою очередь используется для определения направления, в котором должно развиваться дерево.

Процесс прогнозирования новых экземпляров x при использовании метода XGBoost следующий: после T этапов построения это сумма прогнозов от всех T деревьев 4:

$$y_i(x) = \frac{1}{N} \sum_{i=1}^T f_i(x), \quad (4)$$

Возможности оптимизации. Метод XGBoost позволяет использовать различные способы оптимизации, что способствует повышению его эффективности и скорости работы. Например, метод градиентной односторонней выборки (GOSS) снижает объем обрабатываемых данных для улучшения производительности, при этом сохраняя эффективность алгоритма. В целях снижения риска переобучения в целевую функцию включены термины L1 (лассо-регрессия) и L2 (гребневая регрессия) регуляризации. Подход к поиску разделения с учётом разреженности позволяет эффективно справляться с



недостающими данными, либо выявляя оптимальные способы их обработки на этапе обучения, либо назначая им определённые значения.

Методы оценки модели. Далее были определены основные статистические показатели, которые могут быть применены для оценки качества разрабатываемой прогностической нейросетевой модели [12]. Основными показателями, которые сегодня используются для оценки эффективности регрессионных моделей являются коэффициент детерминации (R^2), среднеквадратическая ошибка (RMSE) и средняя абсолютная ошибка (MAE). Данные показатели определяют, насколько хорошо модель соответствует исходным данным и какова точность её предсказаний. Коэффициент детерминации (R^2) позволяет определить, насколько хорошо вариация зависимой переменной объясняется с помощью независимых переменных. Значение R^2 лежит в интервале от 0 до 1. Большие значения свидетельствуют о более точном соответствии модели и получаемых прогнозных данных. Математически выразить R^2 можно следующим образом: чем больше значение R^2 , тем больше вариации зависимой переменной объясняется моделью, при этом единица указывает на идеальное соответствие. Коэффициент детерминации определяется по следующей формуле 5:

$$R^2 = 1 - \frac{SSE}{SST}, \quad (5)$$

где: SSE – сумма квадратов ошибок регрессии, а SST – сумма квадратов отклонений точек данных от среднего значения.

Корень среднеквадратической ошибки (RMSE) – средняя разница между реальными и предсказанными значениями. Этот показатель демонстрирует, насколько сильно отклоняются прогнозы от фактических данных, при этом более низкие значения указывают на лучшее качество модели. RMSE можно выразить следующей формулой 6, где меньшие значения свидетельствуют о более высокой производительности модели:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (6)$$

где: n – количество наблюдений, y_i – фактическая координата наблюдения, а $\hat{y}_i$ – предсказанная координата наблюдения.

Средняя абсолютная ошибка (MAE) – отличается от корня среднеквадратической ошибки (RMSE), где применяется квадрат разности между фактической и предсказанной координатой. MAE представляет собой линейную оценку, вследствие чего вес разностей одинаков и не зависит от диапазона данных. При этом более низкие значения также указывают на более высокое качество модели. MAE можно выразить следующей формулой 7:

$$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (7)$$

Средняя абсолютная ошибка (MAE) и среднеквадратическая ошибка (RMSE) — это два статистических показателя, которые оценивают точность прогнозирования. Как уже отмечалось, более низкие значения обоих показателей указывают на лучшую производительность модели. Корень среднеквадратической ошибки (RMSE) более точно определяет крупные ошибки вычислений, вследствие чего используется чтобы избежать значительных ошибок в прогнозе. Этот показатель полезен, когда любые значительные ошибки в прогнозах могут привести к серьезным последствиям для итоговых вычислений в модели [13]. Выбор того или иного статистического показателя зависит от поставленной задачи и характеристик исходных данных. С их помощью в работе над прогностическими



нейросетевыми моделями можно выбрать более пригодный алгоритм или же откорректировать принципы работы самой модели, определить части и области модели, которые требуют улучшения. При этом не всегда целесообразно выбирать только один из них, ведь использование нескольких показателей сразу даст более полное представление о работе разрабатываемой модели и позволит с намного большей эффективностью адаптировать её и улучшать в зависимости от поставленной цели и задач.

Обсуждение результатов

После выбора основных методов, применяемых для построения нейросетевой прогностической модели, а также статистических критериев оценки её качества, предлагается оценить основные проблемы и препятствия к её потенциальной реализации и прикладному применению в процессах управления работой морских портов и терминалов, а именно:

Во-первых, важно наличие качественных и доступных исходных статистических данных, служащих основой для тестирования модели. Процесс предварительной обработки статистических данных по каждому сегменту модели, направленный на обеспечение их надежности и качества, зачастую является трудоемким и требует значительных ресурсов.

Во-вторых, операции в транспортных узлах, которыми являются морские порты и портовые терминалы, отличаются так называемой динамической сложностью, т.к. включают в себя множество комплексных и перекрёстно влияющих друг на друга процессов (прибытие/убытие морских судов и сухопутного транспорта, погрузка/выгрузка, изменяющиеся экономические условия, погодные факторы в работе порта и пр.). Для корректного моделирования подобной сложной динамики необходимо применять высокоэффективные методы МО, способные фиксировать нелинейные взаимодействия и временные зависимости между различными компонентами.

В-третьих, несмотря на преимущества алгоритмов МО, возможности корректной интерпретации получаемых с их помощью данных вызывает значительные затруднения как среди рядовых исследователей, так и среди опытных практиков нейросетевого моделирования. Роль интерпретируемости заключается в необходимости предоставления конечным пользователям чётких объяснений полученных прогностических результатов, что становится особенно актуальным в контексте принятия решений в портовых и транспортных операциях, где неточности могут иметь серьёзные последствия. Модель должна в итоге давать ясные и понятные выводы, что способствует принятию более качественных и рациональных управленческих решений на основе надежной информации.

Основные выводы

По результатам оценки возможностей использования МО для разработки нейросетевой прогностической модели работы морских терминалов, в том числе по итогам анализа пригодных для её построения методов и статистических критериев оценки её качества, сделаны следующие выводы:

1. МО позволяет внедрять *предиктивную аналитику* процесс управления работой морских портов в части прогнозирования времени прибытия судов и железнодорожных составов, распределение места на складе с учетом возможного времени хранения партий, а также в части прогнозирования обработки грузов и времени оборота морского и сухопутного транспорта. Используя модели МО, можно анализировать как статистические данные, так и информацию, поступающую в режиме реального времени, что помогает предсказать будущие события и оптимизировать распределение портовых ресурсов. Это, в свою очередь, способствует повышению эффективности и снижению итоговых задержек.
2. Применение методов *оптимизации* на основе МО позволит улучшить планирование работы грузовых фронтов терминала и оптимизировать распределение технических ресурсов, что, в свою очередь, повысит общую эффективность портовых операций.



Алгоритмы МО способны разрабатывать оптимальные решения, учитывая различные ограничения и цели, такие как минимизация времени ожидания и улучшение пропускной способности, что позволяет находить баланс между противоречивыми требованиями.

3. Методы МО позволяют *автоматизировать* рутинные процессов, характерные для морских терминалов, включая мониторинг состояния и планирование технического обслуживания портового оборудования. Они также способствуют сокращению потребности в ручном труде и частично устраняют человеческий фактор.
4. *Системы поддержки принятия управленческих решений*, основанные на методах МО, позволяют предоставлять руководству стивидорных компаний обоснованные рекомендации. Ведь процесс их работы основан на интеграции и анализе данных из разнородных источников, а также на моделировании множества возможных сценариев развития событий. Организация подобных процессов силами персонала требует больших финансовых вложений и порой трудно реализуема.

Заключение

Несмотря на определенные сложности, связанные с применением моделей, основанных на МО, такие как – проблемы качества исходных данных и масштабируемости, ограниченной интерпретируемости результатов и вычислительной сложности, использование подобных моделей для управления работой морских портов и терминалов имеет огромный потенциал за счёт предиктивной аналитики, оптимизации процессов, автоматизации и интеллектуальной поддержки принятия управленческих решений.

СПИСОК ЛИТЕРАТУРЫ

1. Белоногова А. Д. Применение методов машинного обучения для обеспечения качества спецификаций требований / А. Д. Белоногова, П. А. Огнянович, К. И. Гайдамака // International Journal of Open Information Technologies. – 2021. – Т. 9, № 8. – С. 30-35.
2. Борисенко Г. А. Использование нейронных сетей для прогнозирования стоимости акций на основе новостных данных / Г. А. Борисенко // Вестник Института экономики Российской академии наук. – 2024. – №5. – С. 211-232.
3. Богатых Н. В. Перспективы применения и развития автоматизированной информационной системы мониторинга акватории морского порта / Н. В. Богатых // Перспективы науки. – 2019. – № 6 (117). – С. 29-31.
4. Лукашевич М. Н. Модели и методы машинного обучения для решения задач оптимизации и прогнозирования работы морских портов / М. Н. Лукашевич, М. Я. Ковалев // Информатика. – 2022. – Т. 19, № 4. – С. 94-110.
5. Завгородний А. И. Портовая техносфера, как платформа функциональности нейросети ИИ / А. И. Завгородний // Транспортное дело России. – 2024. – № 5. – С. 86-91.
6. Комендантов К. И. Искусственный интеллект в управлении морскими портами: реальность, перспективы и проблемы / К. И. Комендантов // Океанский менеджмент. – 2024. – № 2 (26). – С. 43-47.
7. Киселенко А. Н. Методы прогнозирования развития транспортных систем в современных условиях / А. Н. Киселенко, Е. Ю. Сундуков, Н. А. Тарабукина // Мир транспорта. – 2022. – Т. 20, № 3 (100). – С. 40-49.
8. Левченко Н. Г. Построение нечеткой нейросетевой модели информационной системы управления транспортно-логистическим процессом / Н. Г. Левченко, С. В. Глушков, Ю. Ю. Почесуева, Е. М. Коньков // Вестник государственного университета морского и речного флота им. адмирала С.О. Макарова. – 2013. – № 3 (22). – С. 100-111.



9. *Левченко Н. Г.* Применение нечеткой нейросетевой модели в управлении транспортно-логистическим процессом / Н. Г. Левченко, Ю. Ю. Почесуева, Е. М. Коньков // Вестник Морского государственного университета. – 2014. – № 65. – С. 42-49.
10. *Казангапова Б. А.* Разработка интеллектуальной информационной системы для транспортной задачи с использованием нечетких нейросетевых технологий / Б. А. Казангапова, Е. К. Социалов, А. С. Нургулжанова // Вестник Казахской академии транспорта и коммуникаций им. М. Тынышпаева. – 2020. – № 1(112). – С. 306-316.
11. *Петров С. В.* Использование метода "Случайный лес" при построении моделей надежности // Информатика, моделирование, автоматизация проектирования (ИМАП-2022): XIV Международная научно-практическая конференция студентов, аспирантов и молодых ученых: сборник научных трудов. – Ульяновск, 2022. – С. 84-88.
12. *Пономарев И. В.* Об оценке параметров трехмерной равномерно-регрессионной модели / И. В. Пономарев // Известия Алтайского государственного университета. – 2020. – № 4(114). – С. 108-111.
13. *Сапкина Н. В.* Оценка качества нечеткой регрессионной модели // Актуальные проблемы прикладной математики, информатики и механики: сборник трудов международной научно-технической конференции. – Воронеж, 2016. – С. 276-277.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Мазуренко Ольга Игоревна

Кандидат технических наук, доцент

ФГБОУ ВО «Государственный университет морского и речного флота имени адмирала С.О. Макарова»

198035, Россия, Санкт-Петербург, ул. Двинская, д. 5/7

E-mail: mazyrenko.olga@gmail.com

INFORMATION ABOUT THE AUTHOR

Mazurenko Olga Igorevna

PhD, Associate Professor

Admiral S.O. Makarov State University of Maritime and Inland Shipping

5/7 Dvinskaya Street, St. Petersburg, 198035, Russian Federation

E-mail: mazyrenko.olga@gmail.com

Дата поступления: 20.08.2025

Дата принятия: 29.09.2025