



УДК 519.8
<https://doi.org/10.37661/1816-0301-2022-19-4-94-110>

Обзорная статья
Review Paper

Модели и методы машинного обучения для решения задач оптимизации и прогнозирования работы морских портов

М. Н. Лукашевич¹✉, М. Я. Ковалев²

¹*Белорусский государственный университет,
пр. Независимости, 4, Минск, 220050, Беларусь*
✉E-mail: mikhail.n.lukashevich@gmail.com

²*Объединенный институт проблем информатики
Национальной академии наук Беларуси,
ул. Сурганова, 6, Минск, 220012, Беларусь*

Аннотация

За последнее десятилетие существенно улучшились методы машинного обучения и расширилась сфера их применения, которая дополнилась рядом операционных задач, возникающих в грузовых портах. Это связано с накоплением и возможностью использования имеющихся в грузовых портах больших объемов данных. Статья посвящена обзору литературы по моделям и методам машинного обучения и их применению к оптимизации портовых операций. Основное внимание уделено планированию и развитию портов, их безопасности и охране, водным и сухопутным портовым операциям.

Ключевые слова: машинное обучение, прогнозирование работы портов, портовые операции, аналитический обзор, управление международными перевозками

Для цитирования. 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. <https://doi.org/10.37661/1816-0301-2022-19-4-94-110>

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 05.09.2022
Подписана в печать | Accepted 07.10.2022
Опубликована | Published 29.12.2022

Machine learning models and methods for solving optimization and forecasting problems of the work of seaports

Mikhail N. Lukashevich^{1✉}, Mikhail Y. Kovalyov²

¹Belarusian State University,
av. Nezavisimosti, 4, Minsk, 220050, Belarus
✉E-mail: mikhail.n.lukashevich@gmail.com

²The United Institute of Informatics Problems
of the National Academy of Sciences of Belarus,
st. Surganova, 6, Minsk, 220012, Belarus

Abstract

Machine learning techniques have made significant advances and expanded application sphere over the past decade to include problems of port operations. This happened due to the growing amount of data available cargo ports. We review the literature on models and methods of machine learning and their application to optimization of port operations. A special attention is paid to the port planning and development a wide range of topics in port operations, including port planning and development, their safety and security, water and land port operations.

Keywords: machine learning, forecasting port forecasting, port operations, analytical review, international transportation management

For citation. Lukashevich M. N., Kovalyov M. Y. *Machine learning models and methods for solving optimization and forecasting problems of the work of seaports*. Informatika [Informatics], 2022, vol. 19, no. 4, pp. 94–110 (In Russ.). <https://doi.org/10.37661/1816-0301-2022-19-4-94-110>

Conflict of interest. The authors declare of no conflict of interest.

Введение. Морская торговля составляет почти девять десятых объема всей мировой торговли [1]. Морские торговые порты способствуют развитию мировой торговли, выступая в качестве перевалочных пунктов. Портовые операции разнообразны и могут быть разделены на следующие группы: планирование и развитие порта, безопасность и охрана, морские операции, операции складского двора и транспортной зоны [2]. Определение наиболее эффективного способа выполнения портовых операций может быть сложной задачей, включающей множество факторов, для которых методы машинного обучения (МО) являются приемлемыми инструментами решения. Однако применение МО для оптимизации портовых операций находится на стадии становления. На данный момент существует небольшое количество соответствующих публикаций, которые будут описаны ниже. Цель настоящей работы – короткий обзор основных методов МО в контексте задач оптимизации портовых операций. Начнем с описания самих задач оптимизации портовых операций и традиционных методов их решения.

Чен и др. [3] сосредоточились на составлении расписания для передачи контейнеров и кодировании проблемы с помощью двухкомпонентного хромосомного подхода, который затем реализуется с помощью модифицированного генетического алгоритма. Дахал и др. [4] объяснили, как моделировать, имитировать и оптимизировать портовые операции (хранение, обработку и отправку различных сыпучих грузов и т. д.) для достижения эффективного управления операциями. Де и др. [5] разработали модель смешанного целочисленного нелинейного программирования для решения проблемы устойчивой маршрутизации судов для ряда сценариев спроса и предложения в различных портах. Гафури и др. [6] предложили модель смешанного целочисленного линейного программирования для размещения гидролокаторов под водой с целью снижения риска терроризма, который может быть спровоцирован со стороны воды в портах и водных путях. Джон и др. [7] предложили новую методологию с использованием теории нечетких множеств, нечеткого аналитического иерархического аппарата и доказательного подхода для определения риска сбоя в работе морского порта с применением разнообразных и неточных данных, чтобы систематически оптимизировать эффективность работы системы. Ли и Ип [8] рассмотрели проблему планирования складских помещений и связанных

с ними домашних причалов в контейнерных терминалах и сформулировали ее в виде модели смешанного целочисленного линейного программирования. Линь и др. [9] проанализировали проблему планирования инвестиций для контейнерного терминала в порту Хумен (англ. Humen), используя моделирование с помощью программного обеспечения «Арена» (англ. Arena). Саид и Эль-Хорбати [10] предложили методику оптимизации обработки контейнеров с помощью генетических алгоритмов. Вентурини и др. [11] предложили модель целочисленного линейного программирования для задачи распределения причалов, интегрирующую оптимизацию скорости судов для нескольких портов на одной линии с учетом экологических соображений. Зейнебу и Абделлатиф [12] разработали математическую модель на основе генетического алгоритма, предлагающую распределение прибывающих судов на набережной таким образом, чтобы минимизировать общее расстояние, пройденное загруженными и разгруженными контейнерами в портовой зоне.

Основные методы машинного обучения. МО известно как область исследований, посвященная разработке вычислительных моделей и методов, интенсивно использующих большие объемы эмпирических данных. Оно берет свое начало от классических результатов в области статистики и искусственного интеллекта. За последние 10 лет МО превратилось в одну из самых популярных областей вычислительной науки благодаря усилиям таких крупных компаний, как Google, Microsoft, Facebook, Amazon и др. Благодаря их бизнес-процессам уже получены и продолжают накапливаться огромные объемы данных. Это дало шанс возродить статистические и вычислительные методы для автоматического создания эффективных моделей на основе данных. Методы МО можно разделить на три категории: обучение с учителем, обучение без учителя и обучение с подкреплением. Ниже описаны основные методы МО в этих трех категориях.

Обучение с учителем. Обучение с учителем использует размеченные обучающие данные и решает задачу построения взаимосвязей между входными и выходными данными. Эта задача называется классификацией, если выходные данные дискретны, и регрессией, если выходные данные непрерывны. Для получения выходных данных (прогнозов) на тестовых наборах, где заданы только входные данные, модели строятся на обучающих данных, состоящих из входов и выходов. Затем выходные данные модели сравниваются с сохраненными целевыми переменными, чтобы определить качество модели. В заключение описываются наиболее часто используемые алгоритмы обучения с учителем: линейная регрессия (англ. Linear Regression, LR), метод k -ближайших соседей (англ. k -nearest neighbors, KNN), искусственные нейронные сети (англ. Artificial Neural Networks, ANN), метод опорных векторов (англ. Support Vector Machine, SVM), случайный лес (англ. Random Forest, RF), градиентный бустинг (англ. Gradient Boosting, GB), байесовские сети и дерево решений (англ. Decision Tree, DT).

LR и KNN – одни из основных методов обучения с учителем. Для того чтобы получить (спрогнозировать) выходные данные, модели линейной регрессии делают предположения о структуре модели, например о значении ошибки и взаимосвязи между выходными и входными данными. KNN – непараметрический подход к обучению в отличие от линейной регрессии. Его идея заключается в том, что определяются k точек данных в обучающих (входных) данных, которые наиболее близки к новой точке входных данных. Для классификации и регрессии предсказание основывается на средней метке и метке большинства соответственно.

ANN – это метод обучения с учителем, который построен по принципу организации и функционирования биологических нейронных сетей (сетей нервных клеток живого организма). Его основная концепция заключается в извлечении линейных комбинаций признаков, а затем моделировании выходных данных как нелинейной функции признаков. Для обработки информации узлы нейронной сети связаны между собой таким образом, что позволяют им обучаться и адаптироваться с течением времени. ANN способны обучать очень сложные модели, но для обучения часто требуется большое количество данных.

SVM – еще один метод машинного обучения, в основном используемый для классификации. Расстояние между границами различных классов максимизируется, когда SVM создает линей-

ные границы в преобразованном виде пространства признаков. Метод может обрабатывать большое количество функций и решать проблему переобучения.

Ациклическая связная сеть, называемая деревом решений, используется для разделения набора данных на более управляемые однородные секции. Каждый узел в дереве представляет собой попарное сравнение признаков. Результаты сравнения показаны по каждой ветви. Прогноз можно сделать быстро и концептуально, просто используя дерево решений.

На основе описанных выше методов можно строить более сложные методы, комбинируя их друг с другом. Композитная модель может быть построена на основе данных нескольких отдельных моделей для повышения точности прогнозирования и устойчивости. Для этой цели также было разработано обучение ансамблей (англ. Ensemble Learning). В данном подходе есть два основных компонента: создание популяции базовых моделей на основе обучающих данных и объединение базовых моделей для получения композиционного предиктора. Методы ансамблевого обучения существуют в двух формах – бэггинга (англ. bagging) и бустинга (англ. boosting). В методе бэггинга несколько независимых моделей создаются из подмножеств обучающего набора данных параллельно, чтобы уменьшить дисперсию между моделями. При бустинге последовательные модели создаются упорядоченно, ориентируясь на ошибки предыдущих моделей, чтобы уменьшить ошибку предсказания. Наиболее часто используемыми моделями ансамблевого обучения являются случайные леса и градиентный бустинг. Кроме того, байесовские сети также можно рассматривать как форму ансамблевого обучения.

Обучение без учителя. Обучение без учителя использует немаркированные данные для поиска скрытых закономерностей в данных. Двумя наиболее широко используемыми методами являются метод главных компонент (англ. Principal Component Analysis, PCA) и кластерный анализ. PCA уменьшает размерность набора данных путем преобразования коррелированных переменных в меньшее количество некоррелированных главных компонент, каждая из которых является линейной проекцией данных. Метод используется как для исследовательского анализа данных, так и для прогнозирования, а также для извлечения и синтеза признаков. Концепция кластеризации относится к группированию данных в группы (кластеры) по сходству, но с поиском различий между группами. Анализируя данные в каждой группе, кластеры могут быть помечены. Кластеризацию также можно использовать для повышения производительности контролируемого машинного обучения путем добавления меток кластера в модель.

Обучение с подкреплением. Обучение с подкреплением (англ. Reinforcement Learning, RL) позволяет испытуемой системе (агенту) учиться методом проб и ошибок, используя отзывы о своих действиях и опыте. Целью обучения с подкреплением является максимизация заранее определенного кумулятивного вознаграждения. После того как действие завершено, агент получает вознаграждение, в котором подробно описывается немедленная реакция среды действия. Агент выбирает оптимальный план действий, исходя из вознаграждения и ситуации. В отличие от обучения с учителем, где обучающие данные уже содержат решение, в обучении с подкреплением эта информация отсутствует. Вместо этого агент выбирает, как выполнить конкретную миссию. Популярные методы обучения с подкреплением включают Q-обучение, состояние-действие, вознаграждение-состояние-действие (англ. State-Action, Reward-State-Action, SARSA) и глубокие Q-сети (англ. deep Q networks, DQN).

Сравнение классических методов машинного обучения и методов глубокого обучения. Естественные данные в необработанном формате и большом объеме представляют собой проблему для традиционных методов машинного обучения. Методы глубокого обучения (англ. Deep Learning, DL) позволяют бороться с этой проблемой. В отличие от традиционных подходов они могут различать сложные скрытые структуры в многомерных средах, что часто встречается в реальных условиях. Классические алгоритмы МО решают многие реальные проблемы, но они могут быть не в состоянии показать высокий результат при обработке многомерных или сложных наборов данных. Методы, основанные на искусственных нейронных сетях и глубоком обучении, предназначены для имитации принятия решений человеком посредством использования данных и в отличие от многих других алгоритмов МО могут обрабатывать многомерные данные. Глубокое обучение является представителем большого семейства методов МО и в за-

висимости от характера проблемы может быть классифицировано как обучение с учителем, обучение без учителя и обучение с подкреплением.

В следующих разделах рассмотрены области применения моделей и методов МО в портовых операциях.

Планирование и развитие портов. Планирование и развитие порта включает процесс стратегического планирования порта, сбор данных и прогнозирование, управление отношениями с заинтересованными сторонами и анализ эффективности проектов. Основные мероприятия, рассматриваемые в данном разделе (прогнозирование и прогнозное моделирование), не являются операциями по своей природе, но оказывают на них значительное влияние. Получение правильного прогноза позволяет минимизировать потенциальное недостаточное или избыточное использование мощностей порта, предотвращая финансовые потери и повышая его эффективность.

Авах и др. [13] использовали модели случайного леса и многослойного перцептрона (англ. Multi-Layer Perceptron, MLP) для прогнозирования оптимальной пропускной способности контейнеров, которую порт может физически обработать, учитывая уровень эффективности терминала. Было показано, что модель случайного леса обеспечивает более точный прогноз пропускной способности контейнеров в порту Дуала (англ. Douala), чем модель MLP или гибридная модель на основе оценок коэффициента детерминации, нормализованной среднеквадратичной ошибки, средней абсолютной ошибки и средней абсолютной процентной ошибки.

Чан и Сюй [14] разработали подход к прогнозированию пропускной способности контейнеров на основе метода опорных векторов регрессии (англ. Support Vector Regression, SVR), учитывая потенциальные факторы влияния, чтобы создать интеллектуальный логистический центр для портовых операций. В данной статье используются другие модели прогнозирования: метод опорных векторов и авторегрессионное интегрированное скользящее среднее (англ. Autoregressive Integrated Moving Average, ARIMA) для оценки эффективности предложенного подхода, и результаты показывают, что предложенный подход превосходит сравниваемые модели и может помочь в принятии решений заинтересованными сторонами. Чан и др. [15] сравнили несколько существующих методов прогнозирования временных рядов, а именно: скользящее среднее (англ. Moving Average, MA), многомерные адаптивные регрессионные сплайны (англ. Multivariate Adaptive Regression Splines, MARS), модель Грея (англ. Grey Model, GM), авторегрессионное интегрированное скользящее среднее, метод опорных векторов регрессии и искусственные нейронные сети, чтобы определить лучший метод для прогнозирования пропускной способности контейнеров. По результатам данного исследования метод опорных векторов регрессии представляется перспективным методом для прогнозирования пропускной способности контейнеров, тем более что он использует относительно небольшой размер выборки. Кроме того, исследование подтверждает, что, несмотря на различия в источниках данных, подходы МО все же более точны в прогнозировании, чем некоторые традиционные методы.

Куонг и др. [16] исследовали прогнозирование пропускной способности морских портов и политику восстановления после COVID-19, применяя эффективную стратегию принятия решений. Для прогнозирования пропускной способности портов Вьетнама они разработали ANN-модель, учитывающую динамику сотрудничества и конкуренции. Для обучения модели используются данные за 10 лет по объему контейнерных перевозок. В статье продемонстрирована эффективность предложенной стратегии с помощью системной динамики и теории управления. Согласно результатам моделирования устойчивое управление может поддерживать темпы роста пропускной способности контейнеров до 7,46 %.

Гамасса и Чен [17] предложили модель Грея, модель линейной регрессии, модель двойного экспоненциального сглаживания (англ. Double Exponential Smoothing, DES) и комбинированную модель прогнозирования для точного прогнозирования пропускной способности контейнеров Абиджанского порта (англ. Abidjan Port). Согласно оценке средней абсолютной процентной ошибки модель двойного экспоненциального сглаживания работает лучше, хотя комбинированная модель прогнозирования также хорошо себя зарекомендовала.

Генг и др. [18] представили робастную модель векторной регрессии (англ. Robust v-Support Vector Regression, RSVR) для прогнозирования пропускной способности порта. Авторы разработали алгоритм хаотического имитационного отжига (англ. Particle Swarm Optimization, PSO) с целью определения оптимальной комбинации параметров для модели RSVR. На основе данных о пропускной способности порта Шанхай с 1978 по 2012 г. этот подход определял инвестиции в основные фонды, импорт и экспорт, объем промышленного производства и ВВП, стоимость промышленной продукции, численность населения, общий объем розничных продаж потребительских товаров, объем грузоперевозок, объем грузоперевозок по шоссе и по железной дороге. Исследование показывает, что предложенная схема прогнозирования пропускной способности порта обеспечивает лучший результат прогнозирования по сравнению с шестью конкурирующими моделями с точки зрения ошибки прогнозирования.

Госасанг и др. [19] изучили проблему прогнозирования морского транспортного потока. Они сравнили многослойную персептронную нейронную сеть и линейную регрессию при прогнозировании количества контейнеров в порту Бангкока на основе исторических данных. Используемые данные охватывали период за 12 лет с 1999 по 2010 г., а выходными данными были количество контейнеров, объем импорта и объем экспорта. По результатам сравнения среднеквадратичной ошибки и средней абсолютной ошибки многослойный персептрон дает лучшие результаты, чем линейная регрессия, но процесс обучения проходит медленнее.

Для прогнозирования контейнерных перевозок в трех крупных морских портах Турции, включая Стамбул, Измир и Мерсин, Гёккуш и др. [20] провели всестороннее исследование. В данной работе были использованы четыре модели: искусственная нейронная сеть с искусственной пчелиной колонией (англ. Artificial Neural Network with Artificial Bee Colony, ANN-ABC), искусственная нейронная сеть, обученная алгоритмом Левенберга – Марквардта (англ. Artificial Neural Network with Levenberg – Marquardt, ANN-LM), множественная нелинейная регрессия с генетическим алгоритмом (англ. Multiple Nonlinear Regression with Genetic Algorithm, MNR-GA) и метод опорных векторов с наименьшим квадратом (англ. Least Square Vector Machine, LSSVM). Набор данных с 1989 по 2015 г. включал ВВП, численность населения, объем экспорта и пропускную способность контейнеров. Сравнение среднеквадратичной ошибки, средней абсолютной процентной ошибки и коэффициента детерминации для портов Измира и Стамбула показало, что LSSVM обеспечивает хорошие результаты, в то время как для порта Мерсин ANN-ABC и ANN-LM показали превосходные результаты.

Лам и др. [21] использовали искусственные нейронные сети для моделирования пропускной способности порта Гонконга. Входные переменные включали национальный ВВП, объемы импорта и экспорта, нераспределенного импорта, реэкспорта, внутреннего экспорта, численность населения, расходы на здания и сооружения, а также потребление электроэнергии в период с 1983 по 2001 г. На основании показателей коэффициента детерминации и средней абсолютной ошибки был сделан вывод, что все разработанные модели на основе искусственных нейронных сетей превосходят регрессионный анализ.

Миленкович и др. [22] предложили нечеткий нейросетевой подход к прогнозированию на основе метаэвристики для прогнозирования контейнерных потоков. Для разработки архитектуры нейронных сетей применялся как имитационный отжиг (англ. Simulated Annealing, SA), так и генетические алгоритмы. Нечеткие правила «если – то» (англ. the fuzzy if-then rules) были использованы в качестве эвристики для выбора между двумя методами. В данном исследовании непараметрические модели сравнивались с классическим параметрическим методом авторегрессионного интегрированного скользящего среднего на примере порта Барселоны.

Москосо-Лопес и др. [23] проанализировали и сравнили прогнозы (в килограммах) грузоперевозок импортных овощей в порту Альхесираса (англ. Algeciras). В своем исследовании ученые разработали и протестировали модели с помощью искусственных нейронных сетей и метода опорных векторов. Оба метода используют исторические данные и показали отличную способность предсказывать будущее на семь дней вперед.

Москосо-Лопес и др. [24] исследовали будущие значения потока скоропортящихся грузов Ro-Ro в порту залива Альхесирас с помощью системы прогнозирования на основе МО. В частности, две базы данных, соответствующие грузопотокам свежих фруктов и овощей в период

с 2010 по 2017 г., анализировались с использованием множественной линейной регрессии, метода опорных векторов и сетей с долговременной краткосрочной памятью (англ. Long Short-Term Memory, LSTM). Результаты анализа показали, что эта система, основанная на МО, достигла на 14,83 % лучшей производительности, чем базовая модель устойчивости, с точки зрения среднеквадратичной ошибки в наборе данных по свежим фруктам и на 11,3 % лучшей производительности в наборе данных по овощам.

Безопасность и охрана. Роль безопасности в работе порта становится все более существенной. Порт – это сложная организация, на которую влияют несколько социально-экономических и экологических факторов. Соответственно, любой инцидент в области безопасности может иметь серьезные экономические, экологические и человеческие последствия, способен потенциально повлиять на конкурентоспособность порта и, возможно, сделать его недоступным.

В портах могут возникнуть серьезные проблемы, если одновременно обслуживается большое количество судов. Следовательно, прогнозирование поступления судов может повысить безопасность порта. Основываясь на данных о погоде и зарегистрированных перемещениях судов с 2015 по 2020 г., Альварельос и др. [25] предложили искусственные нейронные сети и дерево принятия решений по повышению градиента (англ. Gradient Boosting Decision Tree, GBDT) для прогнозирования перемещений судов. Результаты показали, что искусственные нейронные сети достигли наилучших показателей с точки зрения среднеквадратичной ошибки и коэффициента детерминации.

Атак и Арсланоглу [26] применили алгоритмы экстремального повышения градиента (англ. eXtreme Gradient Boosting, XGBoost), машину для повышения светового градиента (англ. Light Gradient Boosted Machine, Light GBM), метод опорных векторов, наивный Байес (англ. Naive Bayes, NB) и метод k -ближайших соседей для прогнозирования аварий на контейнерных терминалах в двух турецких портах, используя информацию о вместимости судов, времени работы, температуре, скорости ветра, влажности и частоте аварий. На основе исследования, представленного в данной работе, было показано, что алгоритмы экстремального повышения градиента, машина для повышения светового градиента и метод k -ближайших соседей дали наилучшие результаты с точностью более 98 %.

Ченг и др. [27] проанализировали проблемы, с которыми сталкиваются современные системы видеонаблюдения при обнаружении безопасности портовых операторов, и систематически исследуют методы извлечения информации и предупреждения поведения оператора. Проанализировав большое количество видеозаписей портовых операций и создав крупномасштабный набор данных сцен портовых операций под названием Harbor Dataset, они предложили алгоритм обнаружения объектов на основе глубокого обучения для определения безопасности оператора в порту. Эксперименты показали, что такой метод дает конкурентоспособный результат на базе данных Harbor Dataset при определении безопасности операторов и калибровке опасных зон работы порта.

Объединив методы МО и исследования операций, Хошино и др. [28] разработали эффективный и простой способ повышения эффективности работы морских портов Канадского агентства пограничных служб (англ. Canada Border Services Agency, CBSA). Авторы использовали концепцию, представленную Драммонд и Холте [29], для разработки кривой улучшения – новой метрики эффективности для прогнозных моделей. Кривые улучшения были использованы для измерения процессов оценки рисков в морских портах Канады. В статье [28] было показано, что даже разработка базовой прогностической модели могла бы повысить эффективность работы CBSA независимо от распределения по классам или затрат на ошибочную классификацию. Кроме того, теории, разработанные в данной статье, описывают простой способ оценки потенциального улучшения от внедрения прогностической модели в общий процесс оценки рисков для лиц, принимающих решения, без необходимости рассчитывать точное количество положительных и отрицательных контейнеров или знать точную стоимость вентиляционного или химического теста.

Ким и др. [30] исследовали аварии, происходящие в контейнерном порту, и предсказали их с помощью методов МО, включая нейросетевую модель, модель случайного леса и модель градиентного бустинга, используя временные ряды данных операций, аварий и погодных наблюдений в период с 2017 по 2020 г. для порта Пусан (англ. Busan), Республика Корея. Согласно полученным результатам модель глубокой нейронной сети и модель градиентного бустинга с интервалом в 6 ч обеспечивают наилучшую производительность с точки зрения метрик точности (англ. precision), полноты (англ. recall), среднего гармонического (англ. F1 score) и доли правильных ответов алгоритма (англ. accuracy).

Ли и др. [31] разработали стратегию МО для прогнозирования диапазона риска небезопасной скорости швартовки при подходе судна к порту. Чтобы определить, является ли скорость швартовки безопасной, авторы применили девять типов классификационных моделей МО: классификатор дерева решений (англ. Decision Tree Classifier, DTC), классификатор случайного леса (англ. Random Forest Classifier, RFC), бэггинг, классификатор дополнительных деревьев (англ. Extra Trees Classifier, ETC), классификатор повышения градиента (англ. Gradient Boosting Classifier, GBC), гауссовский наивный байесовский метод (англ. Gaussian Naive Bayes, GNB), метод k -ближайших соседей, метод опорных векторов и многослойный перцептрон. Для оценки эффективности моделей классификации МО использовались такие показатели, как доля правильных ответов алгоритма, полнота, точность и среднее гармоническое. В результате оценки классификатор дополнительных деревьев, классификатор случайного леса, бэггинг и классификатор повышения градиента показали наилучшие результаты.

Озгурк и др. [32] представили новую методику оценки риска столкновений на подходах к порту, основанную на МО и нечетких выводах, а также три новые характеристики (расстояние, площадь и скорость), которые могут улучшить модели риска навигационных столкновений, используемые в портовых бассейнах. Проведя эксперименты по имитации управления судном с участием 20 лоцманов-экспертов и проанализировав 140 маневров подхода лоцманов к порту на симуляторе, авторы исследования собрали большой массив данных. В результате применения модели случайного леса на основе полученных данных было установлено, что предложенный метод обеспечивает адекватное взвешивание серьезности маневров подхода к порту, а также относительной важности соответствующих параметров.

Сяо и др. [33] проанализировали детерминанты риска задержания судов, применив бинарную логистическую регрессию и дерево решений для оценки эффективности нового инспекционного режима (англ. New Inspection Regime, NIR). В исследовании использовался набор данных, содержащий 125 259 случаев инспектирования более чем из 20 стран в период с 2015 по 2017 г. Эмпирические результаты показали, что существенными являются следующие факторы: возраст судна, тип судна, показатели государства флага и количество недостатков, которые NIR считает существенными. Также было отмечено, что суда старше шести лет чаще оказываются некондиционными (англ. substandard), а если судно имеет пять и более недостатков, оно с большей вероятностью будет задержано.

Ян и др. [34] предложили модель искусственного интеллекта с учетом дисбаланса данных для отбора судов при контроле состояния порта на основе вероятности задержания. Используя 1600 записей инспекций в порту Гонконга за три года, они разработали модель классификации сбалансированного случайного леса (англ. Balanced Random Forest, BRF) для прогнозирования задержания судов. Численные эксперименты показали, что модель BRF может идентифицировать 81,25 % всех судов с задержанием в тестовом наборе, который содержит еще 400 записей инспекции. По сравнению с текущим методом отбора судов в порту Гонконга модель BRF намного эффективнее и может достичь среднего улучшения на 73,72 % при идентификации задержанных судов.

Территория складского двора. Территория складского двора считается самым сложным элементом контейнерных терминалов и представляет собой временную буферную зону, где контейнеры оставляют на время загрузки назначенного контейнеровоза или в ожидании отправки для распределения внутри порта. Чем больше контейнеровозов обрабатывает порт, тем большая требуется контейнерная складская площадка. Эффективность работы склада иногда

рассматривается как показатель конкурентоспособности терминала, поскольку она влияет на остальные показатели его работы.

Фотухи и др. [35] изучили задачу планирования работы крана на верфи, т. е. определения последовательности, в которой должны работать тягачи, чтобы свести к минимуму время их ожидания. Авторы смоделировали дворовые краны как агенты обучения с подкреплением и учли проблемы с помехами. Согласно экспериментальным результатам данная модель очень эффективно помогает крановщику выбрать следующий лучший ход. В связи с этим предлагаемая модель потенциально может быть интегрирована в существующие системы управления площадкой, чтобы автоматизировать процесс выбора грузовика и улучшить работу верфи.

Гао и др. [36, 37] исследовали прогнозирование объема контейнеров складского двора в порту и предложили модель рекуррентной нейронной сети (англ. Recurrent Neural Network, RNN) с сетями с долговременной краткосрочной памятью. Эти исследования предоставляют складскому двору возможность максимально использовать пространство и снизить скорость переворачивания контейнеров (англ. the rate of turning over containers), что может повысить эффективность работы.

Хотунг и др. [38] предлагают новый метод автоматизации трудоемкой и дорогостоящей разработки эвристики для задачи предварительной сортировки контейнеров (англ. Container Pre-Marshalling Problem, CPMP), который называется поиском эвристического дерева глубокого обучения (англ. Deep Learning Heuristic Tree Search, DLTS). Метод использует глубокие нейронные сети для изучения стратегий решения и нижних границ, настроенных для CPMP, исключительно путем анализа существующих почти оптимальных решений для экземпляров CPMP. Затем сети интегрируются в процедуру поиска по дереву, чтобы решить, какую ветвь выбрать следующей, и сократить дерево поиска. Модель обучена на основе 900 000 экземпляров, созданных Терней и др. [39]. На сегодняшний день DLTS производит эвристические решения высочайшего качества для CPMP с разрывами до оптимальности менее 2 % для экземпляров реального размера.

Канг и др. [40] исследовали проблему планирования мест хранения контейнеров с неопределенным весом и разработали подход на основе SA для ее решения. Новые стратегии, основанные на вычислительных экспериментах, фактически превосходят традиционную стратегию складирования групп одинакового веса (англ. same-weight-group stacking), поскольку значительно сокращают количество трудоемких операций по повторной обработке. Применение алгоритмов МО таких, как наивный Байес, дерево решений, алгоритм построения 1-правил (англ. 1R) и проективная адаптивная теория резонанса (англ. Projective Adaptive Resonance Theory, PART) к процессу создания хороших классификаторов продемонстрировало также возможность достижения более точной оценки веса, что приводит к еще лучшим решениям.

Куруниоти и др. [41] разработали методологическую основу, позволяющую операторам портов прогнозировать время простоя контейнеров и, следовательно, время прибытия грузовиков для вывоза импортных контейнеров. Для этого были использованы искусственные нейронные сети. Авторы проверили точность модели с помощью различных наборов независимых переменных и обнаружили, что ее можно повысить, если учесть больше информации, в то время как измеренная точность 65,17 % была не очень высокой.

Мойни и др. [42] рассмотрели три метода прогнозирования времени простоя в рабочих зонах контейнерного терминала: наивный Байес, дерево решений (C4.5) и гибридное байесовское дерево решений (англ. hybrid Bayesian decision tree). Основываясь на характеристиках C4.5, авторы использовали три сценария для изучения влияния изменений в определяющих факторах на время пребывания контейнера, пропускную способность двора и доход терминала от демеджа (англ. demurrage). Эти сценарии включали в себя изменение статуса контейнера с пустого на полный, закрытие ворот грузовика в условиях малого объема и изменение морского перевозчика. Несмотря на необходимость дальнейшего анализа, было продемонстрировано влияние изменений во времени простоя контейнеров и доходов от платы за демедж.

Сайкия и др. [43] предложили комбинацию эволюционных стратегий и методов обучения с подкреплением, чтобы найти приближенное оптимальное решение проблемы загрузки кон-

тейнера. На основе реальных данных модель была обучена с использованием синтетических данных, максимально приближенных к реальным данным. В данных было 23 слота для кораблей и блок из 49 контейнеров, сложенных в семь рядов по семь контейнеров в каждом штабеле. В этом исследовании модель достигла оптимального решения после приемлемого количества итераций.

Шен и др. [44] предложили метод на основе глубоких Q-сетей для решения проблем планирования загрузки судов. В этом методе используются восьмиуровневые глубокие Q-сети, которые обучаются на 19 слотах и 19 соответствующих контейнерах из четырехъярдовых отсеков в двух блоках в порту Нинбо (англ. Ningbo). Глубокие Q-сети в среднем тратят всего 0,131 с на планирование загрузки по сравнению с 237 с у портовых операторов. Таким образом, предложенный метод сопоставим с конкурентами-людьми и требует гораздо меньше времени.

Водные (морские) портовые операции. Стандартные задачи распределения причалов и кранов, прогнозирования времени прибытия судов, а также погрузки и выгрузки контейнеров на суда обычно решаются в рамках оптимизации морских операций на контейнерных терминалах. Сложность задачи возрастает по мере увеличения размера судна и роста ожиданий операторов морских перевозок в отношении качества и своевременности портовых услуг. Чтобы успешно конкурировать на глобальном уровне и достичь разумного времени вычислений для решения крупномасштабных задач, необходимо оптимизировать морские операции порта.

АбуАлхаол и др. [45] представили три показателя загруженности морских портов (англ. Port Congestion Indicators, PCI), а именно пространственную сложность, пространственную плотность и временную критичность, на основе статических и динамических сообщений автоматической идентификационной системы AIS. PCI были извлечены и рассчитаны на основе статических и динамических данных Big AIS. Используя три геопространственных алгоритма: площадь геохеша, площадь выпуклой части корпуса и среднюю близость судна, PCI для 2015 г. рассчитывались ежемесячно, а уровни перегрузки портов характеризовались с помощью кластеризации k -средних. По словам авторов, это первое исследование, в котором аналитика больших данных AIS применялась для оценки уровней загруженности морских портов.

Де Леон и др. [46] исследовали повышение производительности терминалов за счет управления такими ограниченными ресурсами, как причалы. Проблема распределения причалов (англ. Bulk Berth Allocation Problem, Bulk-BAP) была исследована с помощью системы на основе KNN, которая также позволяет неявно решать проблему выбора алгоритма (англ. Algorithm Selection Problem, ASP), когда доступно несколько алгоритмов. Оцениваются 12 подходов к решению, в основном жадный рандомизированный алгоритм, эвристический алгоритм «первым пришел – первым обслужен» и различные конфигурации метаэвристического поиска по большому соседству. Согласно исследованию качество решений улучшалось в случае, когда используемый алгоритм выбирался с учетом характеристик экземпляра, а не просто в случае применения наилучшего алгоритма.

Фанчелло и др. [47] исследовали прогнозирование времени прибытия и распределения человеческих ресурсов для контейнерных терминалов. Авторы статьи представили два алгоритма: алгоритм динамического обучения на основе нейронных сетей и алгоритм оптимизации распределения ресурсов. Использование этих алгоритмов позволяет судам прибывать в порт с меньшей неопределенностью и оптимизировать распределение операторов на весь день с учетом фактического спроса и работы терминала. Кроме того, поскольку эти алгоритмы основаны на общих переменных, их можно применять к любому перегрузочному терминалу.

Ким и др. [48] предложили объектно-ориентированные модели рассуждений на основе прецедентов (англ. Case-Based Reasoning framework, CBR) для раннего обнаружения задержек судов с использованием данных отслеживания S-AIS в режиме реального времени вместе с историческими данными (такими, как погрузочные данные). Этот подход позволяет обнаруживать задержки и прогнозировать схемы движения судов в режиме реального времени до их прибытия. Кроме того, авторы подчеркивают возможность улучшения прогнозов с помощью данных в реальном времени.

Сутрисновати и др. [49] обсудили использование байесовских сетей для анализа вероятности задержки при обработке контейнеров с учетом различных факторов. На основе журналов собы-

тий, созданных в системах управления портами, предлагаемая модель строится путем декомпозиции графа зависимостей. Предложенную модель можно использовать для определения достоверных вероятностей задержек операций и предоставления менеджерам портов предложений по улучшению существующих операций.

Верма и др. [50] описали структуру обучения с подкреплением для выбора и упорядочивания контейнеров для загрузки на корабли и сравнили ее эффективность с двумя метаэвристическими подходами, основанными на имитации отжига и генетических алгоритмах. Используя реальные оперативные данные из трех независимых наборов данных, авторы обучили предложенную модель на слоты в количестве 130–1391 и на контейнеры в количестве 25 000–7 000 000. Полученные результаты продемонстрировали, что предлагаемый подход решает вариант загрузки одного крана для целых судов с лучшими объективными значениями, чем подходы, которые используют стандартную метаэвристику.

Ван и др. [51] предложили модель, основанную на реляционном анализе Грея (англ. Gray Relational Analysis, GRA) и методе опорных векторов, для прогнозирования распределения контейнеров между контейнеровозами для рейса. Вначале в этой модели веса влияющих факторов определяются с помощью GRA. Взвешенные факторы служат входными данными модели метода опорных векторов, а параметры модели оптимизируются с помощью генетического алгоритма. Согласно полученным результатам предложенная модель может эффективно прогнозировать количество контейнеров для рейса контейнеровоза и демонстрирует высокую способность к обобщению и точность.

Ю и др. [52] изучили оценку времени прибытия судов и ее влияние на ежедневные операции контейнерного терминала. Авторы использовали три подхода к интеллектуальному анализу данных: нейронная сеть обратного распространения (англ. Back-Propagation Neural Network, BPNN), дерево классификации и регрессии (англ. Classification and Regression Tree, CART) и случайный лес. Результаты исследования показывают, что модель случайного леса превосходит модели BPNN и CART с точки зрения планирования работы терминала.

Сухопутные портовые операции (транспортная зона). Объем контейнерных перевозок значительно вырос во всем мире, что требует от крупных портов инвестиций и развития своих транспортных зон для повышения производительности.

Аль-Дик [53] представил два метода разработки моделей генерации грузовых рейсов в портах Майами и Джексонвилля, США: регрессионный анализ и нейронные сети с обратным распространением. Эти модели применяются для прогнозирования уровней входящего и исходящего потоков грузовых автомобилей в морских портах. Исследование продемонстрировало потенциал применения нейронных сетей для моделей генерации рейсов и модального разделения. Однако следует отметить, что набор данных был недостаточно большим для проведения исследования нейронных сетей.

Чу [54] проанализировал различные объекты порта с целью выявления факторов, оказывающих существенное влияние на формирование грузовых поездов в порту Гаосюн (англ. Kaohsiung), Тайвань. Было проведено сравнение точности прогнозирования модели множественной регрессии и нескольких моделей временных рядов (например, авторегрессионное интегрированное скользящее среднее, модели экспоненциального сглаживания и искусственной нейронной сети с обратным распространением). Результаты средних абсолютных процентных ошибок, средних абсолютных отклонений и средних квадратичных отклонений показали, что модель искусственной нейронной сети имеет наилучшую точность прогнозирования, за ней следуют модели регрессии и авторегрессионного интегрированного скользящего среднего, причем различия между ними относительно невелики.

Хилл и Бозе [55] описали систему поддержки принятия решений, которая предоставляет прогнозный анализ одновременно логистическим узлам и сотрудничающим автотранспортным компаниям. Авторы предложили гибкий облачный сервис, включающий искусственные нейронные сети для прогнозирования времени ожидания грузовых транспортных средств на складе пустых контейнеров. Исследователи обнаружили, что исключение ночных периодов и учет будних и праздничных дней при расчете входных переменных повышают точность модели.

Хьюн и Хатсон [56] изучили причины задержки движения грузовых транспортных средств на контейнерных терминалах, чтобы определить причины их аномально длительного времени оборота. В статье используются три модели дерева решений: автоматический детектор взаимодействия Хи-квадрат (англ. Chi-squared Automatic Interaction Detector, CHAID), дерево классификации и регрессии, и дерево решений (C4.5). Было продемонстрировано, что портовые власти и операторы терминалов могут эффективно использовать деревья решений для выявления причин аномально большого времени оборота грузовых транспортных средств за относительно короткий промежуток времени по сравнению с проведением исчерпывающего исследовательского анализа исторических данных.

Чон и др. [57] применили Q-обучение для маршрутизации автоматически управляемых транспортных средств (англ. Automated Guided Vehicles, AGV) на портовых контейнерных терминалах. В статье метод пытается найти маршруты с кратчайшим временем в пути для каждого заказа на доставку. Посредством моделирования производительность алгоритма обучения сравнивалась с эффективностью подхода, использующего маршруты с наименьшим расстоянием. Было обнаружено, что применение маршрутов на основе обучения вместо маршрутов кратчайшего расстояния может сократить время в пути на 17,3 %.

Фам и др. [58] исследовали оценку времени ожидания грузовиков в очереди у ворот морского терминала. Авторы статьи оценили и сравнили четыре метода регрессии для прогнозирования времени ожидания грузовиков в терминале: множественную линейную регрессию, нечеткую регрессию, нечеткую кластерную регрессию и метод опорных векторов. Результаты показателей производительности среднеквадратичной и средней абсолютной процентной ошибок показали, что модели нечеткой регрессии, метода опорных векторов и множественной линейной регрессии имеют сравнимую производительность, которая лучше, чем у модели регрессии с нечеткой кластеризацией.

Сарваредди и др. [59] изучили прогноз движения грузовых перевозок нефти, цитрусовых и пиломатериалов, которые не считаются контейнерными грузами. Кроме того, набор данных содержит сведения о количестве грузовиков и грузовых перевозках за год. Чтобы прогнозировать ежедневное количество грузовиков в порту Канаверал (англ. Canaveral), штат Флорида, были разработаны модели нейронной сети обратного распространения и полностью рекуррентной нейронной сети (англ. Fully Recurrent Neural Network, FRNN). Модель нейронной сети обратного распространения показала точность около 95 %, а модель полностью рекуррентной нейронной сети не имела достаточных данных для получения надежных результатов.

Ван Риссен и др. [60] изучили правила принятия решений в режиме реального времени для распределения контейнеров для внутренних перевозок. В статье был представлен общий четырехэтапный метод: сборка исторических данных, оптимизация исторических наборов, вывод дерева решений и применение дерева решений в режиме реального времени. Для решения исторических транспортных задач предлагаемый метод использует автономный подход к оптимальному планированию. Результаты переводятся в дерево решений с помощью метода логического вывода. Кроме того, математическая модель используется для получения нескольких автономных оптимальных значений с одинаковыми целевыми значениями в качестве входных данных для алгоритма обучения.

Цзэн и др. [61] предложили метод планирования, ориентированный на несколько кранов, для маршрутизации и диспетчеризации транспортных средств контейнерного терминала. Были разработаны две модели: одна для метода совместного использования частот между судами (англ. the inter-ship-based sharing method), другая – для метода совместного использования ресурсов судами (англ. the ship-based sharing method). Двухфазный алгоритм поиска Табу (англ. Tabu) и алгоритм Q-обучения предназначены для решения этих двух моделей соответственно. Численные результаты показали, что метод, основанный на межсудовых перевозках, может уменьшить порожний пробег трейлеров на верфи, оптимизировать работу трейлеров на верфи и тем самым повысить эффективность работы контейнерных терминалов. С помощью метода совместного использования судов можно уменьшить неравновесие различных рабочих линий и тем самым повысить эффективность погрузки или разгрузки.

Карта рассматриваемых в работе задач и методов МО

A map of the tasks and methods of MO considered in the work

Методы МО <i>MO methods</i>	Рассматриваемые в работе задачи <i>Tasks considered in the work</i>				
	БПиПА	МиУТС	ОМО	ОРСД	ППС
IR	-	-	-	+	-
ANN	+	+	+	+	+
ARIMA	-	+	-	-	+
Bagging	+	-	-	-	-
BPNN	-	+	+	-	-
BRF	+	-	-	-	-
CART	-	-	+	-	-
CBR	-	-	+	-	-
DES	-	-	-	-	+
DL	+	-	-	-	-
DLTS	-	-	-	+	-
DT	-	+	-	+	-
DTC	+	-	-	-	-
ETC	+	-	-	-	-
FRNN	-	+	-	-	-
GB	+	-	-	-	-
GBC	+	-	-	-	-
GBDT	+	-	-	-	-
GM	-	-	-	-	+
GNB	+	-	-	-	-
GRA	-	-	+	-	-
KNN	+	-	+	-	-
Light GBM	+	-	-	-	-
LR	+	+	-	-	+
LSSVM	-	-	-	-	+
LSTM	-	-	-	-	+
MA	-	-	-	-	+
MARS	-	-	-	-	+
MLP	+	-	-	-	+
MNR-GA	-	-	-	-	+
NB	+	-	+	+	-
PART	-	-	-	+	-
RF	+	-	+	-	+
RFC	+	-	-	-	-
RL	-	+	+	+	-
RNN	-	-	-	+	-
RSVR	-	-	-	-	+
SVM	+	+	-	-	+
SVR	-	-	-	-	+
XGBoost	+	-	-	-	-

Заключение. Все большее число практических задач решается с помощью методов МО. Не является исключением и портовая индустрия – отрасль, которая кажется консервативной и устойчивой к инновациям. Основные причины этого явления – прогресс в информационных технологиях и растущий спрос на портовые операции.

В настоящей статье представлен краткий обзор литературы по методам МО для улучшения портовых операций. Данная область быстро развивается, о чем свидетельствует ежегодный рост соответствующих публикаций. В таблице представлена карта рассмотренных в работе задач портовых операций и примененных к ним методов МО. В ней используются следующие сокращения: БПиПА – безопасность порта и прогнозирование аварий, МиУТС – маршрутизация и управление транспортными средствами, ОМО – оптимизация морских операций, ОРСД – оптимизация работ складского двора, ППС – прогнозирование пропускной способности. Знаком «+» отмечены задачи, для решения которых применялся указанный в таблице метод; знаком «-» – задачи, к которым данный метод не применялся.

References

1. Cheraghchi F., Abualhaol I., Falcon R., Abielmona R., Raahemi B., Petriu E. Big-data-enabled modelling and optimization of granular speed-based vessel schedule recovery problem. *2017 IEEE International Conference on Big Data (Big Data), Boston, USA, 11–14 December 2017*, pp. 1786–1794. <https://doi.org/10.1109/bigdata.2017.8258122>
2. Mekkaoui S. E., Benabbou L., Berrado A. A systematic literature review of machine learning applications for port's operation. *5th International Conference on Logistics Operations Management (GOL), Rabat, Morocco, 28–30 October 2020*, pp. 1–5. <https://doi.org/10.1109/GOL49479.2020.9314756>
3. Chen G., Govindan K., Yang Z. Managing truck arrivals with time windows to alleviate gate congestion at container terminals. *International Journal of Production Economics*, 2013, vol. 141, iss. 1, pp. 179–188. <https://doi.org/10.1016/J.IJPE.2012.03.033>
4. Dahal K., Galloway S., Hopkins I. Modelling, simulation and optimisation of port system management. *International Journal of Agile Systems and Management*, 2007, vol. 2, no. 1, pp. 92–108. <https://doi.org/10.1504/ijasm.2007.015683>
5. De A., Mamanduru V. K. R., Gunasekaran A., Subramanian N., Tiwari M. K. Composite particle algorithm for sustainable integrated dynamic ship routing and scheduling optimization. *Computers and Industrial Engineering*, 2016, vol. 96, pp. 201–215. <https://doi.org/10.1016/j.cie.2016.04.002>
6. Ghafoori A., Altiock T. A mixed integer programming framework for sonar placement to mitigate maritime security risk. *Journal of Transportation Security*, 2012, vol. 5, iss. 4, pp. 253–276. <https://doi.org/10.1007/s12198-012-0095-6>
7. John A., Paraskevadakis D., Bury A., Yang Z., Riahi R., Wang J. An integrated fuzzy risk assessment for seaport operations. *Safety Science*, 2014, vol. 68, pp. 180–194. <https://doi.org/10.1016/j.ssci.2014.04.001>
8. Li M. K., Yip T. L. Joint planning for yard storage space and home berths in container terminals. *International Journal of Production Research*, 2013, vol. 51, iss. 10, pp. 3143–3155. <https://doi.org/10.1080/00207543.2012.760852>
9. Lin J., Gao B., Zhang C. Simulation-based investment planning for Humen Port. *Simulation Modelling Practice and Theory*. 2014, vol. 40, pp. 161–175. <https://doi.org/10.1016/j.simpat.2013.09.009>
10. Said G. A. E.-N. A., El-Horbaty E.-S. M. An optimization methodology for container handling using genetic algorithm. *Procedia Computer Science*, 2015, vol. 65, pp. 662–671. <https://doi.org/10.1016/j.procs.2015.09.010>
11. Venturini G., Iris Ç., Kontovas C. A., Larsen A. The multi-port berth allocation problem with speed optimization and emission considerations. *Transportation Research Part D: Transport and Environment*, 2017, vol. 54, pp. 142–159. <https://doi.org/10.1016/j.trd.2017.05.002>
12. Zeinebou Z., Abdellatif B. Development of a model of decision support for optimization of physical flows in a container terminal. *2013 International Conference on Advanced Logistics and Transport, Tunisia, 29–31 May 2013*, pp. 421–426. <https://doi.org/10.1109/icadlt.2013.6568496>
13. Awah P. C., Nam H., Kim S. Short term forecast of container throughput: new variables application for the Port of Douala. *Journal of Marine Science and Engineering*, 2021, vol. 9, iss. 7, p. 720. <https://doi.org/10.3390/jmse9070720>
14. Chan H. K., Xu S. Intelligent port data management systems to improve capability. *2017 International Conference on Service Systems and Service Management, Tokyo, Japan, 26–30 November 2017*, pp. 1–3. <https://doi.org/10.1109/icsssm.2017.7996283>

15. Chan H. K., Xu S., Qi X. A comparison of time series methods for forecasting container throughput. *International Journal of Logistics Research and Applications*, 2019, vol. 22, iss. 3, pp. 294–303. <https://doi.org/10.1080/13675567.2018.1525342>
16. Cuong T. N., Kim H. S., You S. S., Nguyen D. A. Seaport throughput forecasting and post COVID-19 recovery policy by using effective decision-making strategy: A case study of Vietnam ports. *Computers and Industrial Engineering*, 2022, vol. 168, p. 108102. <https://doi.org/10.1016/j.cie.2022.108102>
17. Gamassa P. K. P., Chen Y. Application of several models for the forecasting of the container throughput of the Abidjan Port in Ivory Coast. *International Journal of Engineering Research in Africa*, 2017, vol. 28, pp. 157–168. <https://doi.org/10.4028/www.scientific.net/JERA.28.157>
18. Geng J., Li M. W., Dong Z. H., Liao Y. S. Port throughput forecasting by MARS-RSVR with chaotic simulated annealing particle swarm optimization algorithm. *Neurocomputing*, 2015, vol. 147, pp. 239–250. <https://doi.org/10.1016/j.neucom.2014.06.070>
19. Gosasang V., Chandraprakaikul W., Kiattisin S. A comparison of traditional and neural networks forecasting techniques for container throughput at Bangkok Port. *The Asian Journal of Shipping and Logistics*, 2011, vol. 27, no. 3, pp. 463–482. [https://doi.org/10.1016/s2092-5212\(11\)80022-2](https://doi.org/10.1016/s2092-5212(11)80022-2)
20. Gökkuş Ü., Yıldırım M. S., Aydın M. M. Estimation of container traffic at seaports by using several soft computing methods: a case of Turkish seaports. *Discrete Dynamics in Nature and Society*, 2017, vol. 2017, pp. 1–15. <https://doi.org/10.1155/2017/2984853>
21. Lam W. H. K., Ng P. L. P., Seabrooke W., Hui E. C. M. Forecasts and reliability analysis of port cargo throughput in Hong Kong. *Journal of Urban Planning and Development*, 2004, vol. 130, pp. 133–144. [https://doi.org/10.1061/\(asce\)0733-9488\(2004\)130:3\(133\)](https://doi.org/10.1061/(asce)0733-9488(2004)130:3(133))
22. Milenkovic M., Milosavljevic N., Bojovic N., Val S. Container flow forecasting through neural networks based on metaheuristics. *Operational Research*, 2021, vol. 21, iss. 2, pp. 965–997. <https://doi.org/10.1007/s12351-019-00477-1>
23. Moscoso-Lopez J. A., Turias I. T., Come M. J., Ruiz-Aguilar J. J., Cerban M. Short-term forecasting of intermodal freight using ANNs and SVR: case of the Port of Algeciras Bay. *Transportation Research Procedia*, 2016, vol. 18, pp. 108–114. <https://doi.org/10.1016/J.TRPRO.2016.12.015>
24. Moscoso-Lopez J. A., Urda D., Ruiz-Aguilar J. J., Gonzalez-Enrique J., Turias I. J. A machine learning-based forecasting system of perishable cargo flow in maritime transport. *Neurocomputing*, 2020, vol. 452, pp. 487–497. <https://doi.org/10.1016/j.neucom.2019.10.121>
25. Alvarellós A., Figuero A., Carro H., Costas R., Sande J., Guerra A., Rabuñal J. Machine learning based moored ship movement prediction. *Journal of Marine Science and Engineering*, 2021, vol. 9, iss. 8, p. 800. <https://doi.org/10.3390/jmse9080800>
26. Atak Ü., Arslanoğlu Y. Machine learning methods for predicting marine port accidents: a case study in container terminal. *Ships and Offshore Structures*, 2021, pp. 1–8. <https://doi.org/10.1080/17445302.2021.2003067>
27. Cheng G., Wang S., Guo T., Han X., Cai G., Gao F., Dong J. Abnormal behavior detection for harbour operator safety under complex video surveillance scenes. *2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC), Harbin Institute of Technology (Shenzhen), China, 15–17 December 2017*, pp. 324–328. <https://doi.org/10.1109/spac.2017.8304298>
28. Hoshino R., Coughtrey D., Sivaraja S., Volnyansky I., Auer S., Trichtchenko A. Applications and extensions of cost curves to marine container inspection. *Annals of Operations Research*, 2009, vol. 187, iss. 1, pp. 159–183. <https://doi.org/10.1007/s10479-009-0669-2>
29. Drummond C., Holte R. C. Cost curves: an improved method for visualizing classifier performance. *Machine Learning*, 2006, vol. 65, pp. 95–130. <https://doi.org/10.1007/s10994-006-8199-5>
30. Kim J. H., Kim J., Lee G., Park J. Machine learning-based models for accident prediction at a Korean container port. *Sustainability*, 2021, vol. 13, iss. 16, p. 9137. <https://doi.org/10.3390/su13169137>
31. Lee H. T., Lee J. S., Son W. J., Cho I. S. Development of machine learning strategy for predicting the risk range of ship's berthing velocity. *Journal of Marine Science and Engineering*, 2020, vol. 8, iss. 5, p. 376. <https://doi.org/10.3390/jmse8050376>
32. Ozturk U., Birbil S. I., Cicek K. Evaluating navigational risk of port approach manoeuvres with expert assessments and machine learning. *Ocean Engineering*, 2019, vol. 192, p. 106558. <https://doi.org/10.1016/j.oceaneng.2019.106558>
33. Xiao Y., Wang G., Lin K. C., Qi G., Li K. X. The effectiveness of the New Inspection Regime for Port State Control: Application of the Tokyo MoU. *Marine Policy*, 2020, vol. 115, p. 103857. <https://doi.org/10.1016/j.marpol.2020.103857>

34. Yan R., Wang S., Peng C. An artificial intelligence model considering data imbalance for ship selection in port state control based on detention probabilities. *Journal of Computational Science*, 2021, vol. 48, p. 101257. <https://doi.org/10.1016/j.jocs.2020.101257>
35. Fotuhi F., Huynh N., Vidal J. M., Xie Y. Modeling yard crane operators as reinforcement learning agents. *Research in Transportation Economics*, 2013, vol. 42, iss. 1, pp. 3–12. <https://doi.org/10.1016/j.retrec.2012.11.001>
36. Gao Y., Chang D., Chen C. H., Fang T. Deep learning with long short-term memory recurrent neural network for daily container volumes of storage yard predictions in port. *International Conference on Cyberworlds (CW), Singapore, 3–5 October 2018*, pp. 427–430. <https://doi.org/10.1109/cw.2018.00083>
37. Gao Y., Chang D., Fang T., Fan Y. The daily container volumes prediction of storage yard in port with long short-term memory recurrent neural network. *Journal of Advanced Transportation*, 2019, vol. 2019, pp. 1–11. <https://doi.org/10.1155/2019/5764602>
38. Hottung A., Tanaka S., Tierney K. Deep learning assisted heuristic tree search for the container pre-marshalling problem. *Computers and Operations Research*, 2020, vol. 113, p. 104781. <https://doi.org/10.1016/j.cor.2019.104781>
39. Tierney K., Pacino D., Voß S. Solving the pre-marshalling problem to optimality with A* and IDA*. *Flexible Services and Manufacturing Journal*, 2016, vol. 29, iss. 2, pp. 223–259. <https://doi.org/10.1007/s10696-016-9246-6>
40. Kang J., Ryu K. R., Kim K. H. Deriving stacking strategies for export containers with uncertain weight information. *Journal of Intelligent Manufacturing*, 2006, vol. 17, iss. 4, pp. 399–410. <https://doi.org/10.1007/s10845-005-0013-x>
41. Kourouniotti I., Polydoropoulou A., Tsiklidis C. Development of models predicting Dwell Time of import containers in port container terminals – an Artificial Neural Networks application. *Transportation Research Procedia*, 2016, vol. 14, pp. 243–252. <https://doi.org/10.1016/j.trpro.2016.05.061>
42. Moini N., Boile M., Theofanis S., Laventhal W. Estimating the determinant factors of container dwell times at seaports. *Maritime Economics and Logistics*, 2012, vol. 14, iss. 2, pp. 162–177. <https://doi.org/10.1057/mel.2012.3>
43. Saikia S., Verma R., Agarwal P., Shroff G., Vig L., Srinivasan A. Evolutionary RL for container loading. *ESANN 2018 Proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, Belgium, 25–27 April 2018*. <https://doi.org/10.48550/arXiv.1805.06664>
44. Shen Y., Zhao N., Xia M., Du X. A Deep Q-Learning Network for ship stowage planning problem. *Polish Maritime Research*, 2017, vol. 24, no. s3, pp. 102–109. <https://doi.org/10.1515/pomr-2017-0111>
45. AbuAlhaol I., Falcon R., Abielmona R., Petriu E. Mining Port Congestion Indicators from Big AIS Data. *The 2018 International Joint Conference on Neural Networks (IJCNN 2018), Brazil, 8–13 July 2018*, pp. 1–8. <https://doi.org/10.1109/ijcnn.2018.8489187>
46. De Leon A. D., Lalla-Ruiz E., Melian-Batista B., Marcos Moreno-Vega J. A Machine Learning-based system for berth scheduling at bulk terminals. *Expert Systems with Applications*, 2017, vol. 87, pp. 170–182. <https://doi.org/10.1016/j.eswa.2017.06.010>
47. Fancello G., Pani C., Pisano M., Serra M., Zuddas P., Fadda P. Prediction of arrival times and human resources allocation for container terminal. *Maritime Economics and Logistic*, 2011, vol. 13, iss. 2, pp. 142–173. <https://doi.org/10.1057/mel.2011.3>
48. Kim S., Kim H., Park Y. Early detection of vessel delays using combined historical and real-time information. *Journal of the Operational Research Society*, 2017, vol. 68, iss. 2, pp. 182–191. <https://doi.org/10.1057/s41274-016-0104-4>
49. Sutrisnowati R. A., Bae H., Song M. Bayesian network construction from event log for lateness analysis in port logistics. *Computers and Industrial Engineering*, 2015, vol. 89, pp. 53–66. <https://doi.org/10.1016/j.cie.2014.11.003>
50. Verma R., Saikia S., Khadilkar H., Agarwal P., Shroff G., Srinivasan A. A reinforcement learning framework for container selection and ship load sequencing in ports. *Proceedings of the Fourth International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS 4), Montreal, 13–17 May 2019*, pp. 2250–2252.
51. Wang Y., Shi G., Sun X. A forecast model of the number of containers for containership voyage. *Algorithms*, 2018, vol. 11, no. 12, p. 193. <https://doi.org/10.3390/a11120193>
52. Yu J., Tang G., Song X., Yu X., Qi Y., Li D., Zhang Y. Ship arrival prediction and its value on daily container terminal operation. *Ocean Engineering*, 2018, vol. 157, pp. 73–86. <https://doi.org/10.1016/j.oceaneng.2018.03.038>
53. Al-Deek H. Which method is better for developing freight planning models at seaports-neural networks or multiple regression? *Transportation Research Record: Journal of the Transportation Research Board*, 2001, vol. 1763, iss. 1, pp. 90–97. <https://doi.org/10.3141/1763-14>

54. Chu C. H. Empirical method for predicting internal-external truck trips at a major port. *Journal of Transportation Engineering*, 2010, vol. 137, no. 7, pp. 496–508. [https://doi.org/10.1061/\(asce\)te.1943-5436.0000233](https://doi.org/10.1061/(asce)te.1943-5436.0000233)
55. Hill A., Bose J. W. A decision support system for improved resource planning and truck routing at logistic nodes. *Information Technology and Management*, 2017, vol. 18, iss. 3, pp. 241–251. <https://doi.org/10.1007/s10799-016-0267-3>
56. Huynh N., Hutson N. Mining the sources of delay for dray trucks at container terminals. *Transportation Research Record: Journal of the Transportation Research Board*, 2008, vol. 2066, iss. 1, pp. 41–49. <https://doi.org/10.3141/2066-05>
57. Jeon S. M., Kim K. H., Kopfer H. Routing automated guided vehicles in container terminals through the Q-learning technique. *Logistics Research*, 2010, vol. 3, iss. 1, pp. 19–27. <https://doi.org/10.1007/s12159-010-0042-5>
58. Pham Q., Huynh N., Xie Y. Estimating truck queuing time at marine terminal gates. *Transportation Research Record: Journal of the Transportation Research Board*, 2011, vol. 2222, iss. 1, pp. 45–53. <https://doi.org/10.3141/2222-06>
59. Sarvareddy P., Al-Deek H., Klodzinski J., Anagnostopoulos G. Evaluation of two modeling methods for generating heavy-truck trips at an intermodal facility by using vessel freight data. *Transportation Research Record: Journal of the Transportation Research Board*, 2005, vol. 1906, iss. 1, pp. 113–120. <https://doi.org/10.1177/0361198105190600114>
60. Van Riessen B., Negenborn R. R., Dekker R. Real-time container transport planning with decision trees based on offline obtained optimal solutions. *Decision Support Systems*, 2016, vol. 89, pp. 1–16. <https://doi.org/10.1016/j.dss.2016.06.004>
61. Zeng Q., Yang Z. Z., Lai L. Models and algorithms for multicrane oriented scheduling method in container terminals. *Transport Policy*, 2009, vol. 16, iss. 5, pp. 271–278. <https://doi.org/10.1016/J.TRANPOL.2009.08.006>

Информация об авторах

Лукашевич Михаил Николаевич, аспирант, факультет прикладной математики и информатики, Белорусский государственный университет.
E-mail: mikhail.n.lukashevich@gmail.com

Ковалев Михаил Яковлевич, член-корреспондент НАН Беларуси, Объединенный институт проблем информатики Национальной академии наук Беларуси.
E-mail: kovalyov_my@newman.bas-net.by

Information about the authors

Mikhail N. Lukashevich, Postgraduate Student, the Faculty of Applied Mathematics and Computer Science, Belarusian State University.
E-mail: mikhail.n.lukashevich@gmail.com

Mikhail Y. Kovalyov, Corresponding Member of the National Academy of Sciences of Belarus, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.
E-mail: kovalyov_my@newman.bas-net.by