

Жир С. І., кандидат фізико-математичних наук, доцент,
доцент кафедри транспортних технологій та міжнародної
логістики Університету митної справи та фінансів
ORCID: 0009-0006-2410-6792

Шишканова Г. А., кандидат фізико-математичних наук, доцент,
доцент кафедри математики Національного університету
«Запорізька політехніка»
ORCID: 0000-0002-0336-2803

Зайцева Т. А., кандидат технічних наук, доцент,
доцент кафедри комп'ютерних технологій
Дніпровського національного університету імені Олеся Гончара
ORCID: 0000-0002-6346-3390

Слюсарова Т. І., асистент кафедри математики
Національного університету «Запорізька політехніка»
ORCID: 0000-0001-6655-0492

МОДЕЛЮВАННЯ ТА ОПТИМІЗАЦІЯ ДИНАМІЧНОГО КОНТРОЛЮ В СТОХАСТИЧНИХ СИСТЕМАХ НА ОСНОВІ МАШИННОГО НАВЧАННЯ

Розглядається проблема оптимізації функціонування в'їзної групи контейнерного терміналу, що функціонує в умовах стохастичної невизначеності транспортних потоків, спричиненої глобальними логістичними тенденціями і випадковими зовнішніми факторами. Актуальність обраного напрямку зумовлена необхідністю скорочення часу очікування вантажівок, мінімізації операційних витрат та нівелювання негативного екологічного впливу від надлишкової емісії під час простою транспорту в чергах. Вочевидь, просте розширення фізичної інфраструктури часто є економічно недоцільним. Пропонується перехід до інтелектуальної гібридної моделі динамічного управління, яка базується на парадигмі навчання з підкріпленням (RL – Reinforcement Learning), що дозволяє системі адаптивно регулювати кількість активних каналів обслуговування.

В основу розробленої моделі покладено марковський процес прийняття рішень. Для адекватного відтворення реальної динаміки прибуття вантажівок застосовано Пуассонівський розподіл. В'їзна група представлена через дискретну апроксимацію класичної моделі масового обслуговування. Використання Q-learning забезпечує знаходження оптимальної політики керування навіть за умов відсутності вичерпної апріорної інформації, дозволяючи агенту «навчатися» безпосередньо в ході взаємодії з середовищем.

У дослідженні проілюстровано еволюцію навчання агента та підтверджено його збіжність до теоретично обґрунтованої оптимальної стратегії. Результати моделювання свідчать, що впровадження методів RL сприяє ефективному згладжуванню пікових навантажень, суттєвому скороченню довжини черг та загальному зростанню пропускної здатності терміналу. Розглянуто можливості масштабування моделі через інтеграцію глибоких нейронних мереж, що дозволяє оперувати великими масивами даних та складними просторами станів. Рівняння Гамільтона–Якобі–Беллмана, яке визначає межі оптимальності в задачах неперервного керування, є теоретичною верифікацією отриманих стратегій. Запропонований підхід має практичну значущість для розвитку логістичних систем, оскільки дозволяє інтегрувати гібридні інтелектуальні алгоритми в управління інфраструктурою та забезпечує оптимізацію економічних показників.

Ключові слова: моделювання, оптимізаційні методи, Reinforcement Learning, програмне забезпечення, розподіл Пуассона, ймовірність, інтелектуальні логістичні системи, масове обслуговування.

Zhyr S. I., Shyshkanova G. A., Zaytseva T. A., Sliusarova T. I. Modeling and optimization of dynamic control in stochastic systems based on machine learning

The problem of optimizing the functioning of the entry group of a container terminal operating under conditions of stochastic uncertainty of transport flows caused by global logistics trends and random external factors is considered. The relevance of the chosen direction is due to the need to reduce truck waiting time, minimize operating costs and level the negative environmental impact from excess emissions during transport downtime in queues. Obviously, a simple expansion of the physical infrastructure is often economically impractical. A transition to an intelligent hybrid dynamic control model based on the rein-



© С. І. Жир, Г. А. Шишканова, Т. А. Зайцева, Т. І. Слюсарова, 2026

Стаття поширюється на умовах ліцензії відкритого доступу CC BY 4.0

forcement learning (RL) paradigm is proposed, which allows the system to adaptively regulate the number of active service channels. The developed model is based on a Markov decision-making process. To adequately reproduce the real dynamics of truck arrivals, a Poisson distribution is used. The entry group is represented through a discrete approximation of the classical mass service model. The use of Q-learning ensures finding the optimal control policy even in the absence of exhaustive a priori information, allowing the agent to «learn» directly during interaction with the environment.

The study illustrates the evolution of agent learning and confirms its convergence to a theoretically justified optimal strategy. The modeling results show that the implementation of RL methods contributes to effective smoothing of peak loads, a significant reduction in queue length and an overall increase in terminal throughput. The possibilities of scaling the model through the integration of deep neural networks are considered, which allows operating with large data sets and complex state spaces. The Hamilton–Jacobi–Bellman equation, which determines the optimality limits in continuous control problems, is a theoretical verification of the obtained strategies. The proposed approach has practical significance for the development of logistics systems, as it allows integrating hybrid intelligent algorithms into infrastructure management and ensures optimization of economic indicators.

Key words: modeling, optimization methods, reinforcement learning, software, Poisson distribution, probability, intelligent logistics systems, mass service.

Постановка проблеми. Контейнерні термінали виступають важливими елементами глобальної логістичної інфраструктури, які забезпечують безперервність міжнародних ланцюгів постачання. У сучасних умовах вони функціонують у середовищі підвищеної стохастичної та системної невизначеності [1], що зумовлена не лише природною варіативністю транспортних потоків, а й комплексом зовнішніх чинників, серед яких особливе місце посідають геополітичні конфлікти, торговельні обмеження, енергетичні кризи та інше. Нерівномірність прибуття вантажівок до в'їзних воріт терміналу формує стохастичні черги, які спричиняють низку негативних наслідків, а саме, збільшення часу очікування, надмірне споживання пального під час простою, затримки в обробці контейнерів та зниження загальної пропускної здатності інфраструктури. Ці ефекти посилюються в умовах, спричинених політичними або економічними шоками.

У цьому контексті формуються ключові системні суперечності. З одного боку, існує потреба мінімізувати час очікування вантажівок для підвищення операційної ефективності, конкурентоспроможності терміналу та зменшення екологічного навантаження. З іншого боку, економічні та енергетичні обмеження не дозволяють підтримувати надлишкову кількість активних воріт у періоди низької інтенсивності трафіку, особливо в умовах зростання вартості енергоресурсів та необхідності оптимізації витрат.

Таким чином, сучасні контейнерні термінали функціонують у середовищі, де традиційні методи управління ресурсами втрачають ефективність через зростання стохастичної невизначеності, посиленої геополітичними ризиками та глобальними логістичними дисбалансами. За таких умов виникає потреба у створенні адаптивного алгоритму керування, здатного визначати оптимальну кількість активних смуг обслуговування на основі поточної довжини черги та прогнозованої інтенсивності вхідного потоку.

Аналіз останніх досліджень і публікацій. Моделі теорії черг становлять базовий аналітичний інструментарій для дослідження та оптимізації операційних процесів контейнерних терміналів [2]. Традиційні методи керування чергами, такі як теорія масового обслуговування (Queuing Theory) [3] або лінійне програмування, часто пасують перед стохастичним прибуттям вантажівок.

Стратегії, засновані на статичних розкладах часто виявляються неспроможними адаптуватися до реальних затримок у дорожній мережі, що спричиняє утворення тривалих черг [4, 5]. Більшість терміналів намагаються впроваджувати слоти для візитів, застосовуючи системи запису TAS (Truck Appointment Systems) [6]. Проте вони часто ігноруються через затори на дорогах або затримки в порту [7].

Це тягне за собою ланцюгову реакцію негативних наслідків: від зростання операційних витрат терміналу до значних екологічних збитків через викиди вуглецю під час роботи двигунів на холостому ході (IDLE time) [8, 9]. Нові нормативи змушують термінали мінімізувати час роботи двигунів на холостому ході [10]. Оптимізація черг на воротах може зменшити викиди та холостий хід вантажівок до 42 % [8].

Дослідження показують, що оптимізація лише фізичної інфраструктури без інтелектуальних систем керування не здатна розв'язати проблему пікових навантажень [7]. Інтелектуальні ворота (Smart Gates): Використання OCR та RFID для автоматизації проїзду, що зменшує час обслуговування, але не розв'язує проблему пікових навантажень.

Reinforcement Learning (RL) або навчання з підкріпленням активно застосовується для оптимізації операцій контейнерних терміналів [11]. На відміну від статичних алгоритмів, RL дозволяє терміналу «вчитися» на досвіді. RL моделює динаміку терміналу як Марковський процес прийняття рішень (MDP). Агент RL може прогнозувати піки, на основі статистичних даних та поточного стану доріг приймати рішення про відкриття додаткових воріт заздалегідь. Можливість динамічного керування при застосуванні RL дозволяє визначати оптимальну кількість активних смуг, балансує між витратами на персонал/енергію та штрафами за затримку вантажівок. Ще одна перевага RL – це адаптивність. Тобто RL ефективно працює в умовах, де вхідні параметри (час прибуття) постійно змінюються [4, 12]. Дослідження [4] детально розглядає застосування глибокого навчання з підкріпленням для мінімізації часу перебування вантажівок у порту.

Алгоритми засновані на Deep Double Q-Networks (DDQN) [13] покращують планування руху вантажівок і зменшують час очікування обладнання. В багатьох роботах RL розглядається як перспективний підхід у логістиці та управлінні ланцюгами постачання [14].

Актуальність проблематики додатково підсилюється дослідженнями, що зосереджуються на багатоагентних системах для координації роботи в'їзних воріт та внутрішніх перевантажувальних механізмів терміналу [1].

Метою дослідження є наукове обґрунтування та розробка інтелектуальної моделі керування в'їзною групою контейнерного терміналу на основі алгоритмів RL, що забезпечить динамічне регулювання пропускної здатності воріт для мінімізації загальних логістичних витрат та часу очікування вантажівок.

Реалізація цієї мети передбачає формалізацію математичної моделі очікування вантажівок, де цільова функція мінімізує сукупні витрати на обслуговування та штрафи за затримку. Очікується, що впровадження навченого RL-агента дозволить не лише знизити середній час очікування вантажівок у пікові години, а й суттєво покращити екологічні показники терміналу шляхом вирівнювання інтенсивності транспортних потоків, що корелює з сучасними вимогами до декарбонізації логістики, викладеними в останніх роботах з оптимізації морських вузлів [10].

Виклад основного матеріалу. Побудуємо RL-модель динамічного керування воротами контейнерного терміналу, яка описує динамічне відкриття/закриття сервісних каналів для мінімізації часу очікування. Розглядається система в'їзних воріт контейнерного терміналу, де потік вантажівок є нерівномірним у часі.

Потрібно в режимі реального часу визначити кількість відкритих воріт c_t , щоб мінімізувати середній час очікування W_q ; мінімізувати експлуатаційні витрати; уникати перевантаження системи ($\rho < 1$).

Система моделюється як керований стохастичний процес MDP [11], який визначається наступним кортежем:

$$M = (S, A, P, R, \gamma), \quad (1)$$

де S – простір станів, A – простір дій, $P = (s' | s, a)$ – імовірність переходу, $R = (s, a)$ – функція винагороди, $\gamma \in (0, 1)$ – коефіцієнт дисконтування.

Стан системи у момент t :

$$s_t = (L_t, \lambda_t, c_t), \quad (2)$$

де L_t – довжина черги, λ_t – інтенсивність прибуття, c_t – кількість відкритих воріт.

Простір дій

$$A = \{-1, 0, +1\}, \quad (3)$$

де $+1$: відкрити додаткові ворота, -1 : закрити ворота, 0 : залишити без змін.

Обмеження:

$$1 \leq c_t \leq c_{\max}. \quad (4)$$

Опишемо динаміку системи, спираючись на імовірності.

Дискретна апроксимація моделі $M/M/c$ – це спосіб перетворення класичної математичної моделі черги, яка зазвичай описується неперервними диференціальними рівняннями, у покрокову модель з дискретними інтервалами часу Δt . Це дуже важливо для RL, оскільки алгоритми RL приймають рішення через фіксовані проміжки часу [14].

У класичній нотації Кендалла $M/M/c$ означає: перша M (Markovian): вхідний потік вантажівок є Пуассонівським, тобто інтервали між прибуттями розподілені експоненціально; друга M (Markovian): час обслуговування на воротах також розподілений експоненціально; c (Channels): кількість паралельних ліній (воріт), що працюють одночасно.

Суть дискретизації полягає в тому, що замість того, щоб аналізувати чергу в будь-який мікромомент часу, ми розбиваємо процес на кроки довжиною Δt . Дискретна апроксимація описує зміну довжини черги L від кроку t до кроку $t + 1$ за формулою:

$$L_{t+1} = \max \{0, L_t + A_t - D_t\}, \quad (5)$$

де $A_t \approx \text{Poisson}(\lambda_t \Delta t)$ – кількість вантажівок, що прибули за інтервал Δt , $D_t \approx \text{Poisson}(c_t \mu \Delta t)$ – кількість вантажівок, які термінал міг би обслужити за цей час при наявності c_t відкритих воріт. Вони моделюються як випадкові величини з розподілом Пуассона.

Нам необхідно мінімізувати час очікування та витрати на ворота. Використаємо наступну функцію винагороди:

$$R_t = -(\alpha W_q(t) + \beta c_t), \quad (6)$$

де $\alpha, \beta > 0$ – вагові коефіцієнти та

$$W_q(t) = \frac{L_t}{\lambda_t}. \quad (7)$$

Оптимальна стратегія максимізує функцію цінності:

$$V^\pi(s) = E_\pi \left[\sum_{t=0}^{\infty} \gamma^t R_t \right]. \quad (8)$$

Оптимальність Беллмана визначається за наступною Формулою:

$$V^*(s) = \max_a \left[R(s, a) + \gamma \sum_{s'} P(s' | s, a) V^*(s') \right]. \quad (9)$$

Далі проводимо Q-learning. Оскільки $P = (s' | s, a)$ невідоме, використовуємо:

$$Q_{t+1}(s_t, a_t) = Q_t(s_t, a_t) + \eta \left[R_t + \gamma \max_a Q_t(s_{t+1}, a) - Q_t(s_t, a_t) \right], \quad (10)$$

де η – швидкість навчання.

Для наглядної демонстрації розглянемо приклади розрахунків. На рис. 1 по горизонтальній осі розташовані епізоди, тобто ітерації навчання, а по вертикальній значення $Q(s, a)$, графік відображає збіжність Q-learning.

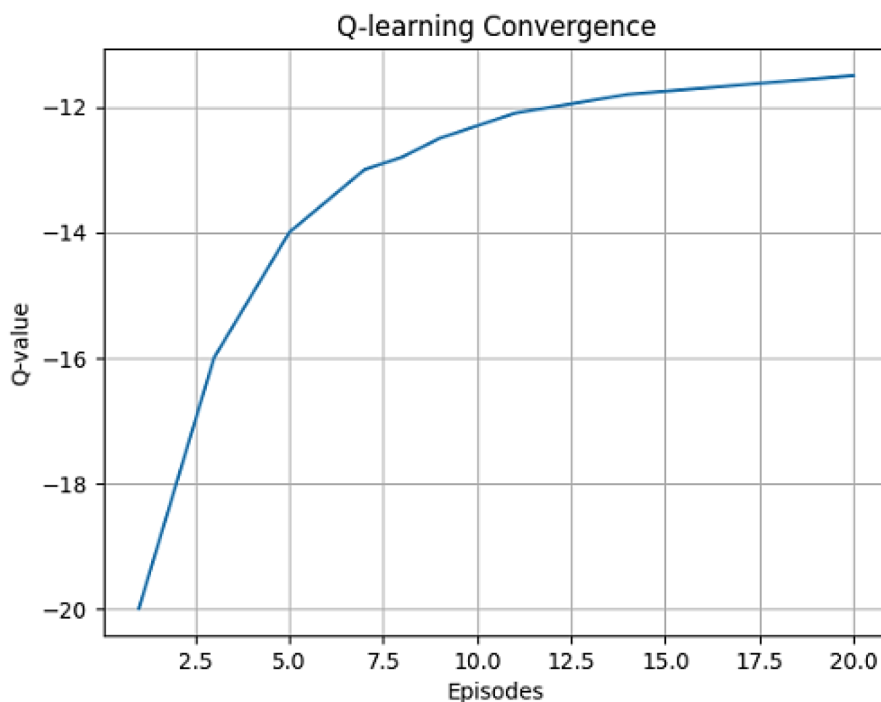


Рис. 1. Графік збіжності Q-learning

З графіку ми бачимо, що початковий етап (1–5 епізоди) відображає різке зростання (менше негативне значення) $Q(s, a)$, тобто RL агент швидко навчається базовій стратегії. Середній етап (6–12) показує, що темп покращення знижується, тобто RL агент уточнює політику. На останньому етапі (13–20) ми бачимо збіжність – значення стабілізується та досягається майже оптимальна стратегія. У реальній задачі графік може бути шумним (через стохастичність).

На рис. 2 змодельована динаміка черги (5). По горизонтальній осі розташовані ітерації навчання, а по вертикальній значення сумарної винагороди за ітерацію (6).

Стохастичність (ключова особливість) рис. 2. Графік не гладкий (на відміну від попереднього рис. 1): це через випадкові потоки Пуассона; реальні логістичні системи поведуться саме так. Тренд тут є головним. Попри шум винагорода зростає, тобто RL агент навчається; система покращується та черги зменшуються.

У випадку, коли простір станів великий рекомендовано використовувати нейромережу Deep Q Network (DQN) $Q(s, a; \theta)$, з вихідними параметрами якої $x = [L_p, \lambda_p, c_p, t_{day}]$. Архітектура – вхід: 4 нейрони; прихований шар: 64 ReLU; прихований шар: 64 ReLU; вихід: 3 Q-значення.

Цільову функцію запишемо у наступному вигляді:

$$y = R + \gamma \max_{a'} Q(s', a', \theta^-), \quad (11)$$

а функцію втрат:

$$L(\theta) = E[(y - Q(s, a; \theta))^2]. \quad (12)$$

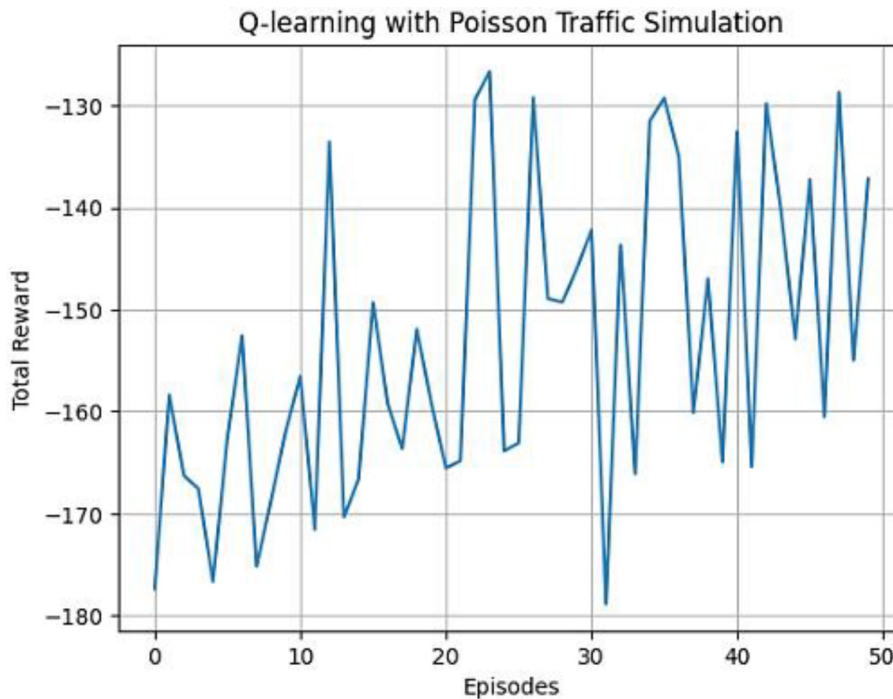
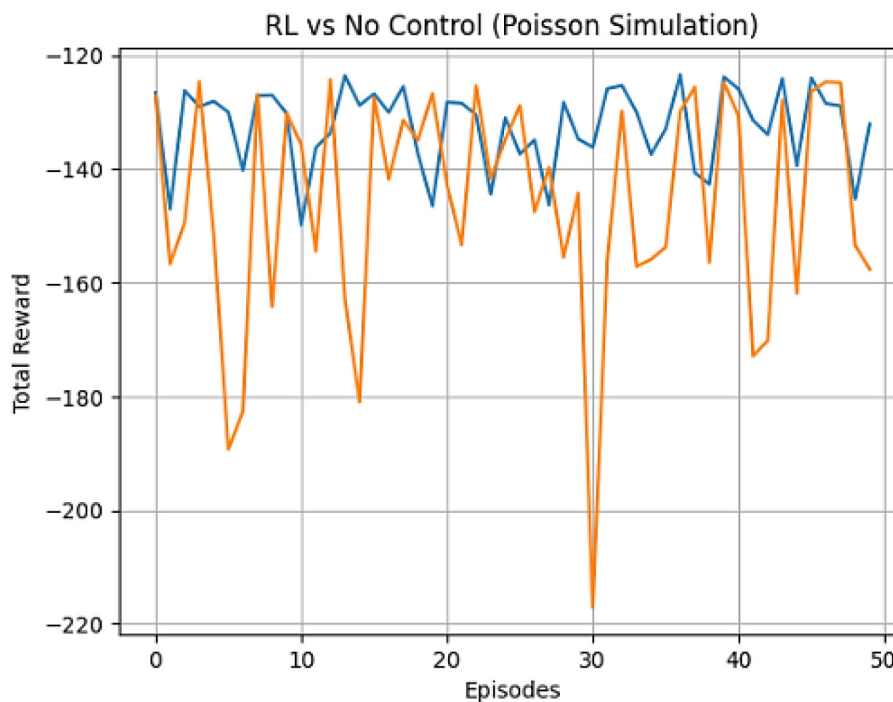


Рис. 2. Q-learning з пуассонівськими потоками

Experience Replay буфер: (s, a, r, s') . Навчання на випадкових батчах стабілізує процес.

Переваги DQN виявляються в тому, що вона працює з безперервними даними, адаптується до сезонності та масштабується на великі термінали.

Рівняння Гамільтона–Якобі–Белмана (HJB) – це фундаментальне рівняння в теорії оптимального керування, яке визначає умови оптимальності для системи в неперервному часі. Власне, сучасне навчання з підкріпленням є чисельним методом розв’язання саме цього рівняння, коли ми не знаємо точних параметрів системи. Розв’язання цього рівняння дає ідеальну стратегію керування. Оскільки для складних терміналів розв’язати його аналітично майже неможливо, пропонується використовувати Deep RL, щоб нейромережа апроксимувала його розв’язок.



Рисю 3. Порівняння: RL-керування vs система без керування

На рис. 3 зображено дві криві: одна померанчова – без керування (фіксовано $c = 2$); друга синя – RL (адаптивна зміна кількості воріт).

По горизонтальній осі розташовані ітерації навчання, а по вертикальній значення сумарної винагороди за ітерацію, яка чим вище (менш негативне), тим краще. RL-крива вище у більшості епізодів, що означає менші черги, менший час очікування та кращий баланс ресурсів.

У лінії без керування видно сильні провали – значення падають до ~ -200 . Це відповідає ситуаціям, коли $\rho \approx 1 \Rightarrow W_q \rightarrow \infty$, система «захлинається».

Висновки. У результаті проведеного дослідження встановлено, що використання методів навчання з підкріпленням є ефективним інструментом для динамічного керування логістичними системами з високим рівнем невизначеності. Запропонована RL-модель забезпечує адаптивне регулювання кількості активних сервісних каналів, що дозволяє суттєво зменшити середній час очікування вантажівок, уникати перевантаження системи та оптимізувати експлуатаційні витрати. Важливою перевагою є здатність моделі навчатися на основі взаємодії з середовищем без необхідності повного знання його параметрів.

Порівняльний аналіз показав, що RL-підхід перевершує традиційні статичні методи керування, особливо в умовах пікових навантажень. Алгоритм Q-learning демонструє хорошу збіжність і простоту реалізації, тоді як використання Deep Q Networks дозволяє масштабувати систему та враховувати складні нелінійні залежності. Теоретична основа у вигляді рівняння Беллмана підтверджує оптимальність отриманих стратегій.

Перспективи розвитку запропонованої моделі пов'язані з розширенням її функціональних можливостей та адаптацією до більш складних умов реальних контейнерних терміналів. Подальші дослідження можуть бути спрямовані у розвитку багатоагентних систем керування, зокрема врахування взаємодії вантажівок, залізничних платформ та внутрішньотермінальних перевантажувальних засобів, що дозволить моделювати систему як багаторівневу багатоагентну структуру. Розробка багатоагентних RL-систем, де окремі агенти керують воротами, кранами, складуванням та внутрішньою логістикою, забезпечать глобальну оптимізацію всього термінального комплексу.

Важливим є врахування геополітичних та макроекономічних факторів, які впливають на сезонність та інтенсивність транспортних потоків. Це дозволить створювати прогностичні моделі, здатні адаптуватися до різких змін у глобальних ланцюгах постачання. Доцільним є також інтегрування моделей у цифрові двійники логістичних об'єктів, що забезпечить можливість тестування політик керування в умовах, максимально наближених до реальних операцій.

Для відповідності сучасним вимогам декарбонізації портової інфраструктури є включення екологічних показників, зокрема викидів CO₂, у функцію винагороди, що сприятиме сталому розвитку транспортної інфраструктури.

Список використаних джерел:

1. Chargui, K., Zouadi, T., Sreedharan, V. R., Fallahi, A. & Reghioui, M. (2023). A novel robust exact decomposition algorithm for berth and quay crane allocation and scheduling problem considering uncertainty and energy efficiency. *Omega*, 118, 102868, <https://doi.org/10.1016/j.omega.2023.102868>
2. Cheng, T. T. (2014). Queuing Model of Container Terminal Logistics System in Event Scheduling. *Advanced Materials Research*, 971–973, 2358–2360. <https://doi.org/10.4028/www.scientific.net/amr.971-973.2358>
3. Hall, R. W. (2003). Transportation Queueing. In: Hall, R. W. (eds) *Handbook of Transportation Science*. International Series in Operations Research & Management Science, vol 56. Springer, Boston, MA. https://doi.org/10.1007/0-306-48058-1_5
4. Wang, T., Tian, X. & Wang, Y. (2020). Container slot allocation and dynamic pricing of time-sensitive cargoes considering port congestion and uncertain demand. *Transportation Research Part E: Logistics and Transportation Review*, 144, 102149, <https://doi.org/10.1016/j.tre.2020.102149>
5. Dvignun, A., Datsii, O., Levchenko, N., Shyshkanova, G., Platonov, O., & Zalizniuk, V. (2022). Increasing Ambition to Reduce the Carbon Trace of Multimodal Transportation in the Conditions of Ukraine's Economy Transformation Towards Climate Neutrality. *Science and Innovation*, 18(1), 96–111. <https://doi.org/10.15407/science18.01.096>
6. Bouyahia, F., Belaqziz, S., Meliani, Y., Lissane Elhaq, S. & Boukachour, J. (2025). A Novel Truck Appointment System for Container Terminals. *Sustainability*, 17(13), 5740. <https://doi.org/10.3390/su17135740>
7. Silva, M. R. F., Agostino, I. R. S. & Frazzon, E. M. (2023). Integration of machine learning and simulation for dynamic rescheduling in truck appointment systems. *Simulation Modelling Practice and Theory*, 125, 102747. <https://doi.org/10.1016/j.simpat.2023.102747>
8. Abeysooriya, H., Weerasinghe, B. A. & Perera, H. N. (2024). Optimizing Gate Queuing at Container Terminals to Facilitate Green Operations. *IFAC-PapersOnLine*, 58(19), 307-312. <https://doi.org/10.1016/j.ifacol.2024.09.201>
9. Datsii, O., Levchenko, N., Shyshkanova, G., Platonov, O. & Abuselidze, G. (2021). Creating a Regulatory Framework for the ESG-investment in the Multimodal Transportation Development. *Rural Sustainability Research*, 46(341), 39-52. <https://doi.org/10.2478/plua-2021-0016>

-
10. Zhang, L., Zeng, Q. & Wang, L. (2024). How to Achieve Comprehensive Carbon Emission Reduction in Ports? A Systematic Review. *Journal of Marine Science and Engineering*, 12(5), 715. <https://doi.org/10.3390/jmse12050715>
 11. Çolak, M., Heilig, L. & Voß, S. (2025). Reinforcement learning in the context of container terminals. *Flexible Services and Manufacturing Journal*. <https://doi.org/10.1007/s10696-025-09643-4>
 12. Kiseleva, E.M., Prytomanova, O.M., Hart, L.L., Zaytseva, T.A. & Kuzenkov O.O. (2024). Application of mathematical methods of artificial intelligence to solve problems of optimal set partitioning. *Питання прикладної математики та математичного моделювання*, 27, 89-98. <https://doi.org/10.15421/32242401>
 13. Cheng, S., Liu, Q., Jin, H., Zhang, R., Ma, L. & Kwong, C. F. (2025). Collaborative optimization of truck scheduling in container terminals using graph theory and DDQN. *Scientific reports*, 15(1), 6950. <https://doi.org/10.1038/s41598-025-91140-7>
 14. Yan, Y., Chow, A.H.F., Ho, C. P., Kuo, Y.-H., Wu, Q. & Ying Ch. (2022). Reinforcement learning for logistics and supply chain management: Methodologies, state of the art, and future opportunities, *Transportation Research Part E: Logistics and Transportation Review*, 162, 102712, <https://doi.org/10.1016/j.tre.2022.102712>

References:

1. Chargui, K., Zouadi, T., Sreedharan, V. R., Fallahi, A. & Reghioui, M. (2023). A novel robust exact decomposition algorithm for berth and quay crane allocation and scheduling problem considering uncertainty and energy efficiency. *Omega*, 118, 102868, <https://doi.org/10.1016/j.omega.2023.102868>
2. Cheng, T. T. (2014). Queuing Model of Container Terminal Logistics System in Event Scheduling. *Advanced Materials Research*, 971–973, 2358–2360. <https://doi.org/10.4028/www.scientific.net/amr.971-973.2358>
3. Hall, R.W. (2003). Transportation Queuing. In: Hall, R.W. (eds) *Handbook of Transportation Science. International Series in Operations Research & Management Science*, vol 56. Springer, Boston, MA. https://doi.org/10.1007/0-306-48058-1_5
4. Wang, T., Tian, X. & Wang, Y. (2020). Container slot allocation and dynamic pricing of time-sensitive cargoes considering port congestion and uncertain demand. *Transportation Research Part E: Logistics and Transportation Review*, 144, 102149, <https://doi.org/10.1016/j.tre.2020.102149>
5. Dvigun, A., Datsii, O., Levchenko, N., Shyshkanova, G., Platonov, O., & Zalizniuk, V. (2022). Increasing Ambition to Reduce the Carbon Trace of Multimodal Transportation in the Conditions of Ukraine's Economy Transformation Towards Climate Neutrality. *Science and Innovation*, 18(1), 96–111. <https://doi.org/10.15407/scine18.01.096>
6. Bouyahia, F., Belaqziz, S., Meliani, Y., Lissane Elhaq, S. & Boukachour, J. (2025). A Novel Truck Appointment System for Container Terminals. *Sustainability*, 17(13), 5740. <https://doi.org/10.3390/su17135740>
7. Silva, M. R. F., Agostino, I. R. S. & Frazzon, E. M. (2023). Integration of machine learning and simulation for dynamic rescheduling in truck appointment systems. *Simulation Modelling Practice and Theory*, 125, 102747. <https://doi.org/10.1016/j.simpat.2023.102747>
8. Abeysooriya, H., Weerasinghe, B. A. & Perera, H. N. (2024). Optimizing Gate Queuing at Container Terminals to Facilitate Green Operations. *IFAC-PapersOnLine*, 58(19), 307-312. <https://doi.org/10.1016/j.ifacol.2024.09.201>
9. Datsii, O., Levchenko, N., Shyshkanova, G., Platonov, O. & Abuselidze, G. (2021). Creating a Regulatory Framework for the ESG-investment in the Multimodal Transportation Development. *Rural Sustainability Research*, 46(341), 39-52. <https://doi.org/10.2478/plua-2021-0016>
10. Zhang, L., Zeng, Q. & Wang, L. (2024). How to Achieve Comprehensive Carbon Emission Reduction in Ports? A Systematic Review. *Journal of Marine Science and Engineering*, 12(5), 715. <https://doi.org/10.3390/jmse12050715>
11. Çolak, M., Heilig, L. & Voß, S. (2025). Reinforcement learning in the context of container terminals. *Flexible Services and Manufacturing Journal*. <https://doi.org/10.1007/s10696-025-09643-4>
12. Kiseleva, E. M., Prytomanova, O. M., Hart, L. L., Zaytseva, T. A., & Kuzenkov, O. O. (2024). Application of mathematical methods of artificial intelligence to solve problems of optimal set partitioning. *Issues of Applied Mathematics and Mathematical Modeling*, 27, 2024, pp. 89–98. <https://doi.org/10.15421/32242401>
13. Cheng, S., Liu, Q., Jin, H., Zhang, R., Ma, L. & Kwong, C. F. (2025). Collaborative optimization of truck scheduling in container terminals using graph theory and DDQN. *Scientific reports*, 15(1), 6950. <https://doi.org/10.1038/s41598-025-91140-7>
14. Yan, Y., Chow, A.H.F., Ho, C. P., Kuo, Y.-H., Wu, Q. & Ying Ch. (2022). Reinforcement learning for logistics and supply chain management: Methodologies, state of the art, and future opportunities, *Transportation Research Part E: Logistics and Transportation Review*, 162, 102712, <https://doi.org/10.1016/j.tre.2022.102712>

Дата першого надходження статті до видання: 23.03.2026

Дата прийняття статті до друку після рецензування: 19.04.2026

Дата публікації (оприлюднення) статті: 30.05.2026