

I. А. Ковтун

Національний університет «Одеська політехніка», Україна
пр. Шевченка, 1, Одеса, 65044
i.a.kovtun@op.edu.ua
<https://orcid.org/0009-0007-9368-5289>

**АРХІТЕКТУРА АДАПТИВНОГО ВИБОРУ ПОЛІТИК
ПОПОВНЕННЯ ЗАПАСІВ НА ОСНОВІ ОЦІНЮВАННЯ
ЇХ ОЧІКУВАНОЇ ЕФЕКТИВНОСТІ**

I. Kovtun

Odessa Polytechnic National University, Ukraine
Shevchenko av., 1, Odessa, 65044
i.a.kovtun@op.edu.ua
<https://orcid.org/0009-0007-9368-5289>

**REPLENISHMENT POLICIES BASED ON THEIR EXPECTED
EFFECTIVENESS**

Анотація. У статті розглянуто проблему адаптивного управління запасами в умовах нестабільного попиту, високої варіативності продажів та необхідності оперативного прийняття рішень у логістичних системах. Проведено аналіз сучасних підходів до використання методів машинного навчання та навчання з підкріпленням для підтримки процесів управління запасами. Встановлено, що більшість існуючих рішень орієнтована або на підвищення точності прогнозування попиту з подальшою оптимізацією параметрів поповнення запасів, або на використання наскрізних інтелектуальних моделей, у яких аналіз стану системи та прийняття рішень реалізуються в межах єдиного програмно-алгоритмічного компонента.

Запропоновано концептуальну архітектуру адаптивного вибору політик поповнення запасів, побудовану на принципі функціонального розділення процесів оцінювання альтернативних політик та прийняття рішень. Особливістю підходу є використання архітектури «оцінювання–вибір» (evaluator-selector architecture), у межах якої окремих інтелектуальний компонент здійснює оцінювання очікуваної ефективності альтернативних політик поповнення запасів, тоді як інший компонент забезпечує їх адаптивний вибір відповідно до поточного стану системи.

Показано, що підвищення точності прогнозування попиту не гарантує вибору найбільш ефективної політики поповнення запасів, оскільки результативність управлінських рішень визначається сукупністю економічних, логістичних та операційних чинників. На відміну від більшості сучасних ML- та RL-орієнтованих систем, запропонований підхід забезпечує модульність архітектури, підвищує інтерпретованість процесу прийняття рішень, спрощує інтеграцію з корпоративними інформаційними системами та створює можливість незалежного вдосконалення окремих функціональних компонентів.

Наукова новизна роботи полягає у формуванні концептуальних засад архітектури адаптивного вибору політик поповнення запасів на основі функціонального розділення процесів оцінювання альтернатив та прийняття рішень. Практичне значення дослідження полягає у можливості використання запропонованого підходу як основи для побудови інтелектуальних систем підтримки прийняття рішень в умовах невизначеного попиту та динамічного ринкового середовища.

Ключові слова: адаптивне управління запасами; адаптивний вибір політики; машинне навчання; навчання з підкріпленням; інтелектуальна система підтримки прийняття рішень; evaluator-selector architecture.

Abstract. The paper addresses the problem of adaptive inventory management under conditions of unstable demand, high sales variability, and the need for rapid decision-making in logistics systems. An analysis of contemporary approaches to the application of machine learning and reinforcement learning methods for inventory management support is conducted. It is established that most existing solutions are focused either on improving demand forecasting accuracy followed by optimization of inventory replenishment parameters, or on the use of end-to-end intelligent models in which system state analysis and decision-making are implemented within a single software and algorithmic component.

A conceptual architecture for adaptive inventory replenishment policy selection is proposed. The architecture is based on the principle of functional separation between the processes of evaluating alternative replenishment policies and making replenishment decisions. A distinctive feature of the proposed approach is the use of an evaluator-selector architecture, in which one intelligent component estimates the expected effectiveness of alternative replenishment policies, while another component performs their adaptive selection according to the current state of the system.

It is demonstrated that improving demand forecasting accuracy does not necessarily guarantee the selection of the most effective inventory replenishment policy, since management performance is determined by a combination of economic, logistical, and operational factors. Unlike most contemporary machine learning- and reinforcement learning-based inventory management systems, the proposed approach provides architectural modularity, improves the interpretability of the decision-making process, facilitates integration with enterprise information systems, and enables the independent enhancement of individual functional components.

The scientific novelty of the study lies in the development of conceptual foundations for an adaptive inventory replenishment policy selection architecture based on the functional separation of policy evaluation and decision-making processes. The practical significance of the research is associated with the possibility of using the proposed approach as a foundation for intelligent decision support systems for inventory management under conditions of uncertain demand and a dynamic market environment.

Keywords: adaptive inventory management; adaptive policy selection; machine learning; reinforcement learning; intelligent decision support system; evaluator-selector architecture.

Вступ

Ефективне управління запасами є одним із ключових чинників забезпечення конкурентоспроможності сучасних підприємств. Зростання нестабільності попиту, скорочення життєвого циклу продукції, підвищення вимог до рівня сервісу та необхідність зниження логістичних витрат зумовлюють потребу у впровадженні нових підходів до прийняття рішень щодо поповнення запасів. Традиційні політики управління запасами, такі як EOQ, (s,Q), (S,T) та їх модифікації, демонструють високу ефективність у відносно стабільних умовах, однак їх результативність суттєво знижується за наявності невизначеного попиту та динамічних змін зовнішнього середовища.

Упродовж останніх років значного поширення набули підходи, засновані на методах машинного навчання та навчання з підкріпленням. Більшість досліджень зосереджена на підвищенні точності прогнозування попиту та подальшому налаштуванні параметрів політик поповнення запасів. Інший напрям розвитку пов'язаний із використанням наскрізних інтелектуальних систем, у яких аналіз стану системи та формування управлінських рішень реалізуються в межах єдиного алгоритмічного компонента.

Разом із тим існуючі підходи мають низку обмежень. Зокрема, висока точність прогнозування не завжди забезпечує максимальну економічну ефективність системи управління запасами, а наскрізні інтелектуальні моделі часто характеризуються низькою інтерпретованістю та складністю інтеграції в корпоративні інформаційні системи. У зв'язку з цим актуальним є пошук підходів,

які дозволяють розділити процеси оцінювання ефективності альтернативних управлінських рішень та безпосереднього вибору політики поповнення запасів.

Метою статті є розроблення концептуальної архітектури адаптивного вибору політик поповнення запасів на основі оцінювання їх очікуваної ефективності, що забезпечує модульність, інтерпретованість та можливість інтеграції інтелектуальних компонентів підтримки прийняття рішень у системі управління запасами.

Постановка проблеми

У сучасних умовах функціонування підприємств управління запасами є однією з ключових складових забезпечення ефективності логістичних та бізнес-процесів. Для підприємств роздрібною торгівлі, дистрибуції, електронної комерції та багатоканальних систем постачання саме ефективність управління запасами визначає рівень обслуговування споживачів, швидкість оборотності товарів, обсяг замороженого капіталу та ризик виникнення дефіциту продукції. Особливої актуальності ця проблема набуває в умовах нестабільного попиту, високої мінливості ринку, скорочення життєвого циклу товарів та постійного оновлення асортименту.

Традиційні системи управління запасами переважно базуються на використанні фіксованих політик поповнення запасів, зокрема EOQ, Min-Max, (s,Q) - та (S,T)-моделей. Подібні підходи демонструють прийнятну ефективність за умов відносно стабільного попиту, однак мають обмежену здатність адаптуватися до швидких змін ринкового середовища та поведінки споживачів [1]. У

більшості випадків параметри таких політик визначаються експертно або коригуються вручну, що ускладнює оперативне реагування системи на зміну попиту та призводить до виникнення надлишкових запасів або дефіциту товарів.

Подальший розвиток систем управління запасами був пов'язаний із активним використанням прогнозування попиту та методів машинного навчання. Сучасні дослідження демонструють, що використання ансамблевих моделей, нейронних мереж та інших методів машинного навчання дозволяє підвищити точність прогнозування попиту, враховувати сезонність, часову динаміку продажів, маркетингові впливи та інші фактори, що впливають на формування попиту [2]. У результаті прогнозування стало одним із ключових інструментів підвищення ефективності систем управління запасами.

Разом із тим навіть високоточний прогноз попиту не дозволяє однозначно визначити, яка саме політика поповнення запасів буде найбільш ефективною для конкретного стану системи. У більшості сучасних підходів використовується класична схема «прогнозування → оптимізація», у межах якої прогноз попиту застосовується як вхідний параметр для подальшого розрахунку параметрів замовлення. Однак подібний підхід не враховує, що одна й та сама політика поповнення може демонструвати різну ефективність залежно від структури попиту, рівня запасів, частоти дефіциту, витрат на зберігання та інших характеристик системи.

У зв'язку з цим сучасні дослідження дедалі активніше розглядають управління запасами як задачу адаптивного та послідовного прийняття рішень. Одним із найбільш перспективних напрямів є використання навчання з підкріпленням, у межах якого система поступово навчається обирати рішення на основі результатів попередньої взаємодії із середовищем [3]. Подібні підходи дозволяють формувати адаптивні стратегії поповнення запасів та реагувати на зміни попиту без необхідності жорсткого визначення правил управління.

Водночас більшість сучасних систем на основі навчання з підкріпленням реалізується у вигляді монолітних моделей, у яких одна модель одночасно виконує аналіз стану системи, навчання політики та формування рішень щодо поповнення запасів [4]. Подібні архітектури характеризуються високою складністю, значними вимогами до обсягу навчальних даних, низькою інтерпретованістю та складністю інтеграції в корпоративні інформаційні системи. Крім того, у подібних підходах практично відсутній окремий механізм оцінювання ефективності альтернативних політик поповнення запасів.

Окремий напрям сучасних досліджень пов'язаний із використанням гібридних моделей, які поєднують прогнозування попиту, машинне навчання та адаптивне управління запасами [5]. Такі підходи дозволяють враховувати невизначеність попиту та багатовимірні характеристики системи, однак переважно орієнтовані на безпосередній розрахунок параметрів замовлення, а не на адаптивний вибір між альтернативними політиками поповнення.

Таким чином, аналіз сучасних підходів показує, що існуючі системи управління запасами переважно орієнтовані або на підвищення точності прогнозування попиту, або на безпосередню оптимізацію параметрів поповнення запасів. Водночас недостатньо дослідженою залишається задача адаптивного вибору політики поповнення залежно від поточного стану системи управління запасами. Це обумовлює необхідність розроблення підходу, у межах якого система не лише прогнозує попит або формує параметри замовлення, а й оцінює очікувану ефективність альтернативних політик поповнення та адаптивно обирає найбільш доцільну політику залежно від характеристик поточного стану системи.

Аналіз останніх досліджень і публікацій

Аналіз сучасних досліджень у сфері управління запасами показує, що розвиток наукових підходів відбувається не лінійно, а

через поступове ускладнення моделей прийняття рішень. Спочатку основна увага приділялась підвищенню точності прогнозування попиту, далі - інтеграції прогнозування в задачі планування запасів, а на сучасному етапі - переходу до адаптивних систем, здатних самостійно змінювати рішення залежно від стану середовища. У межах поставленої проблеми особливий інтерес становлять дослідження, які намагаються подолати розрив між прогнозуванням попиту та вибором управлінського рішення щодо поповнення запасів.

Першу групу досліджень становлять роботи, у яких машинне навчання використовується для прогнозування попиту, оцінювання ризиків та підтримки планування запасів. Систематичний огляд Bergsma, de Ruijt та Bhulai [6] показує, що методи машинного навчання в оптимізації управління запасами застосовуються у трьох основних напрямках: прогнозування, статична оптимізація та динамічна оптимізація. Ця робота є важливою для розуміння загальної картини розвитку напрямку, оскільки демонструє, що машинне навчання вже стало повноцінним інструментом у задачах управління запасами. Водночас огляд засвідчує, що в більшості досліджень прогнозування та прийняття рішень залишаються функціонально розділеними: модель прогнозує майбутній попит, а подальший розрахунок параметрів поповнення виконується за окремою логікою.

Проблема нестабільності попиту детально розглянута у роботі Muth, Lingenfelder та Nufer [7], присвяченій застосуванню машинного навчання для прогнозування попиту в умовах макроекономічної волатильності. Автори показують, що за високої мінливості зовнішнього середовища класичні статистичні методи прогнозування втрачають ефективність, а більш гнучкі моделі машинного навчання дозволяють краще враховувати змінність ринкових умов. Для досліджуваної проблеми ця робота важлива тим, що підтверджує необхідність інтелектуального блоку прогнозування або оцінювання. Однак вона

не розв'язує питання вибору політики поповнення запасів, тобто зупиняється на прогностичній складовій.

Подібну логіку продовжує дослідження Samal та Ghosh [8], у якому для багатоканальної торгівлі запропоновано ансамблевий методи прогнозування попиту. Автори доводять, що поєднання кількох моделей дозволяє підвищити стабільність і точність прогнозу, особливо для середовищ із різними каналами продажів. Проте отриманий результат знову стосується переважно якості прогнозування. Питання, яка саме політика поповнення буде найдоцільнішою після отримання прогнозу, у роботі не розглядається.

У дослідженні Wang та Luo [9] запропоновано метод прогнозування продажів багатокатегорійних товарів із використанням механізму оновлення ознак та моделей на основі дерев рішень. Робота є важливою з погляду формування багатовимірного опису товарів і попиту, оскільки автори враховують як кількісні, так і категорійні характеристики продукції. Це наближає прогнозування до реальних умов управління запасами, де поведінка товару залежить не лише від історії продажів, а й від належності до категорії, сезонності та інших характеристик. Водночас у роботі не формується окремий механізм оцінювання альтернативних політик поповнення.

Окремий приклад прикладного використання машинного навчання наведено у роботі Liu, Kalaitzi, Wang та Papagnou [10], де запропоновано підхід до прогнозування дефіциту товарів. Автори показують, що моделі машинного навчання можуть бути ефективними для раннього виявлення ризику дефіциту на великих масивах товарних позицій. Для систем управління запасами це має практичну цінність, оскільки дає змогу виявляти проблемні товари до моменту фактичного порушення рівня сервісу. Однак така модель виконує переважно попереджувальну функцію і не визначає, яку політику поповнення потрібно застосувати для усунення ризику.

Приклад практичного впровадження прогнозних моделей у задачі оптимізації запасів подано у роботі Goulart та співавторів [11]. Автори досліджують використання машинного навчання для прогнозування попиту у дистриб'ютора будівельних матеріалів і демонструють, що прогнозні моделі можуть сприяти зниженню надлишкових запасів та покращенню планування. Однак логіка дослідження залишається в межах підходу «прогнозування - подальша оптимізація», де прогноз є основою для розрахунку рішення, але не для порівняння альтернативних політик.

Другу групу становлять дослідження, у яких машинне навчання вже інтегрується безпосередньо в процес прийняття рішень щодо запасів. Bansal, Bisi та Roy [12] досліджують інтегровані рішення поповнення запасів і розподілу онлайн-попиту для багатоканального ритейлера із моделлю «відправлення зі stores». Робота демонструє, що сучасні задачі управління запасами дедалі частіше виходять за межі ізольованого розрахунку замовлення та потребують спільного розгляду кількох взаємопов'язаних рішень. Однак запропонований підхід орієнтований на аналітичну інтеграцію конкретного рішення, а не на побудову універсального механізму адаптивного вибору між політиками поповнення.

Особливо важливою для аналізу є робота Ren та співавторів [13], у якій прямо критикується класична двоетапна схема «спочатку прогнозування - потім оптимізація». Автори пропонують інтеграцію XGBoost та LightGBM у логіку задачі newsvendor, тобто намагаються зблизити прогнозування та рішення щодо запасів. Цей підхід є суттєвим кроком уперед порівняно з традиційними прогнозними моделями, оскільки машинне навчання використовується не лише для прогнозу, а й для формування рішення. Водночас у роботі йдеться про визначення кількості замовлення, а не про адаптивний вибір між різними класами політик поповнення.

Загальна логіка першої та другої груп досліджень може бути узагальнена у вигляді схеми на рис. 1.

Третю групу становлять дослідження, орієнтовані на використання навчання з підкріпленням для безпосереднього управління запасами. Систематичний огляд Vieira та Frazzon [14] підтверджує, що навчання з підкріпленням розглядається як перспективний інструмент для зниження дефіциту та надлишкових запасів у системах управління готовою продукцією. Цей огляд показує, що дослідницька спільнота дедалі активніше переходить від статичних правил поповнення до адаптивних моделей, здатних навчатися на результатах попередніх рішень. Водночас у більшості розглянутих робіт навчання з підкріпленням використовується як безпосередній механізм формування рішень, а не як окремий блок вибору між інтерпретованими політиками.

У роботі Geever, van Hezewijk та Mes [15] досліджено використання глибокого навчання з підкріпленням для багаторівневої оптимізації запасів. Автори показують, що такі моделі можуть працювати в складних системах постачання, де рішення на одному рівні впливають на інші рівні. Отримані результати підтверджують можливість зниження витрат утримання запасів і витрат від незадоволеного попиту. Однак архітектура підходу залишається монолітною: агент безпосередньо навчається формувати рішення, а не обирати між попередньо визначеними політиками.

Одним із ключових досліджень у цьому напрямі є робота Gijbrecchts, Boute, Van Mieghem та Zhang [16], у якій перевірено здатність глибокого навчання з підкріпленням покращувати управління запасами в задачах dual sourcing, lost sales та багаторівневих системах. Автори демонструють, що глибоке навчання з підкріпленням може бути конкурентним у складних задачах управління запасами. Водночас ця робота також є прикладом наскрізної архітектури, де модель одночасно виконує аналіз стану і формування рішення. Для практичних

систем підтримки прийняття рішень це створює проблему інтерпретованості та контролю.

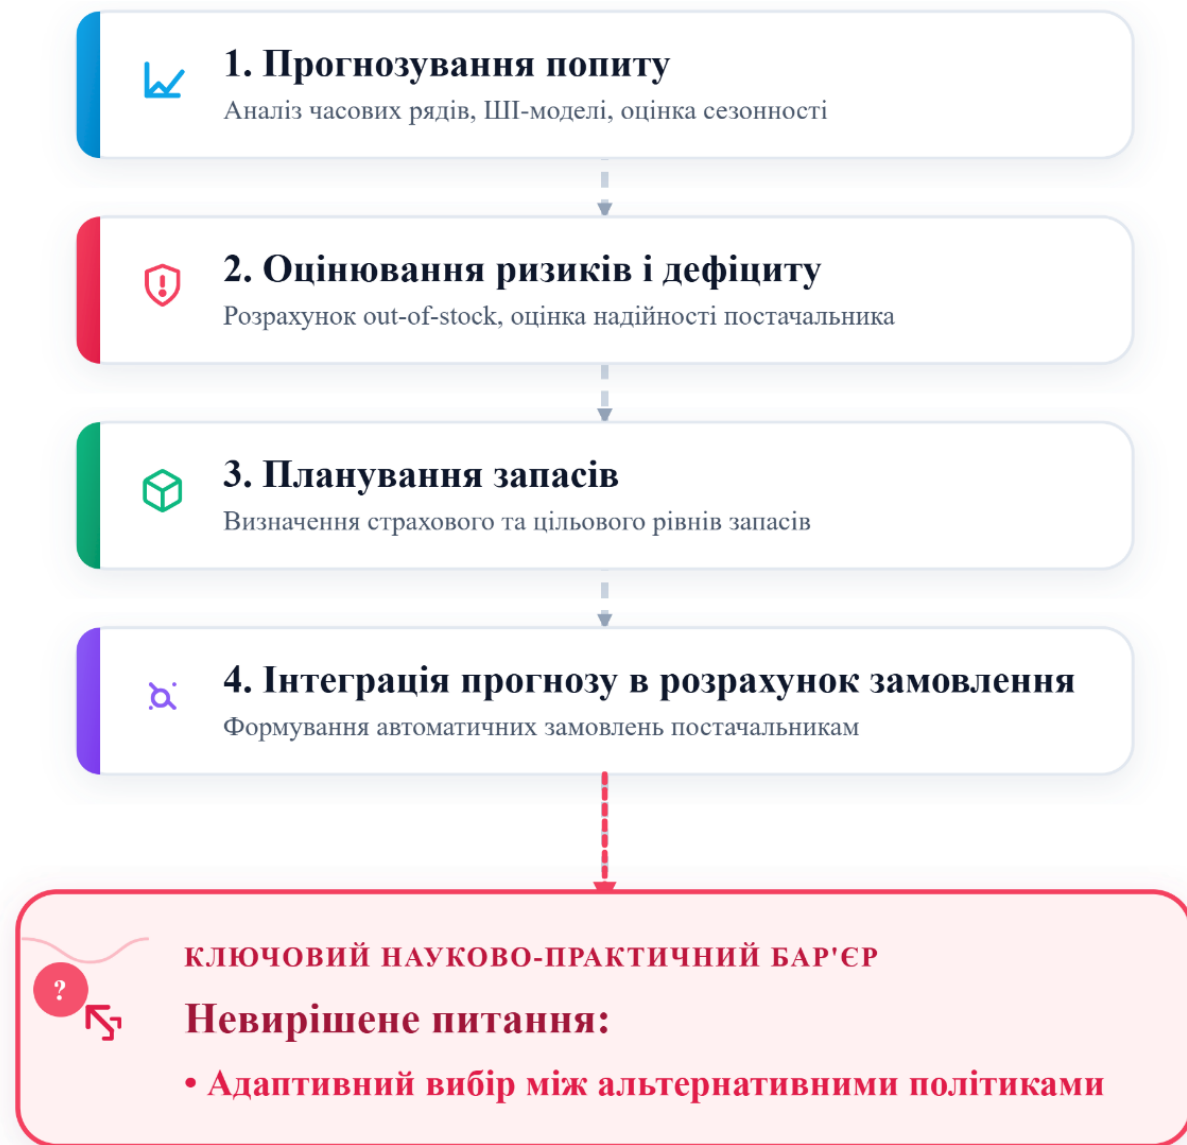


Рис. 1. Узагальнена схема прогнозно-орієнтованого управління запасами

Park, Choi та Min [17] пропонують структуроване навчання з підкріпленням для адаптивного поповнення запасів за умов невідомого та нестаціонарного попиту. Це дослідження є одним із найближчих до проблематики авторського підходу, оскільки автори також намагаються використати структуру політики для підвищення ефективності адаптивного управління. Важливість цієї роботи полягає в тому, що вона демонструє доцільність не повністю відмовлятися від класичних уявлень про політики поповнення. Однак структурованість у цій

роботі реалізується всередині алгоритму навчання, тоді як у запропонованому авторському підході передбачається явне розділення оцінювання альтернативних політик і вибору однієї з них.

Dehaybe та співавтори [18] досліджують глибоке навчання з підкріпленням для оптимізації запасів за нестаціонарного та невизначеного попиту. Важливою особливістю роботи є використання прогнозу як частини вхідного стану агента. Це наближає дослідження до ідеї поєднання прогнозування та адаптивного прийняття рішень. Проте

прогноз у цьому випадку залишається вбудованим елементом єдиної моделі, а не окремим шаром оцінювання очікуваного ефекту альтернативних політик.

Tian та співавтори [19] пропонують модель ІАСРРО для поповнення складських запасів, що базується на поєднанні ідей А2С та РРО. Робота демонструє розвиток складних архітектур глибокого навчання з підкріпленням для задач поповнення запасів. Проте ускладнення алгоритмічної частини водночас посилює проблему інтерпретованості та практичної інтеграції. Такий напрям є перспективним для високотехнологічних середовищ, але може бути надмірно складним для типових корпоративних систем управління.

У роботі Zhang, He та Zheng [20] запропоновано динамічний підхід до поповнення запасів у багаторівневих системах із урахуванням оптимізації витрат. Автори використовують глибоке навчання з підкріпленням для формування рішень у складному середовищі постачання. Дослідження підтверджує здатність адаптивних моделей покращувати економічні показники системи, однак не передбачає окремого рівня оцінювання політик поповнення як альтернатив.

Rizqi та Chou [21] розвивають ще складніший напрям - поєднання нейроеволюції та навчання з підкріпленням для багаторівневої оптимізації запасів з урахуванням варіантів доставки та невизначених знижок. Ця робота демонструє, що сучасні дослідження часто рухаються шляхом алгоритмічного ускладнення. Водночас для практичного використання в системах підтримки прийняття рішень це створює бар'єри: складність навчання, складність пояснення рішення та залежність від великої кількості параметрів.

Demizu, Fukazawa та Morita [22] досліджують модельно-орієнтоване глибоке навчання з підкріпленням для управління запасами нових товарів у роздрібній торгівлі. Ця робота важлива тим,

що розглядає ситуацію нестачі історичних даних, характерну для нових товарів. Автори намагаються структурувати уявлення агента про середовище, однак знову не виділяють окремий блок оцінювання ефекту альтернативних політик поповнення.

Teck, Pham, Rousseau та Vansteenwegen [23] застосовують глибоке навчання з підкріпленням до задачі розміщення та поповнення запасів у роботизованих складських системах. Робота підтверджує прикладну результативність навчання з підкріпленням для складних операційних задач. Однак її фокус зміщено на рівень складської операційної оптимізації, тоді як проблема вибору політики поповнення на рівні системи підтримки прийняття рішень залишається поза межами дослідження.

Kolyaei, Zhang та Blom [24] розглядають використання навчання з підкріпленням для спільного прийняття рішень щодо поповнення та виконання замовлень в омніканальній торгівлі. Дослідження є важливим прикладом розширення задачі управління запасами до комплексної операційної системи. Проте запропонований підхід спрямований на сумісну оптимізацію replenishment-fulfilment, а не на формування інтерпретованого механізму вибору між класами політик поповнення.

Четверту групу становлять дослідження, пов'язані з послідовним прийняттям рішень і методами багаторуких бандитів. An, Li, Moseley та Ravi досліджують нестационарну задачу newsvendor з прогнозами та без них [25]. Ця робота важлива тим, що безпосередньо розглядає поєднання прогнозування, нестационарності та послідовного прийняття рішень. Автори показують, що в умовах невизначеності важливо враховувати не лише прогноз, а й адаптивність рішення до змін середовища. Проте робота зосереджена на окремій постановці newsvendor, а не на виборі між різними політиками поповнення.

Таблиця 1. Узагальнення основних груп досліджень у сфері адаптивного управління запасами

Група досліджень	Основна ідея	Типові результати	Невирішені питання
Прогнозування попиту	Підвищення точності прогнозу	Краща точність оцінювання майбутнього попиту	Не визначається політика поповнення
Прогнозування дефіциту	Раннє виявлення ризику нестачі товару	Попередження про можливий дефіцит	Не формується управлінське рішення
Інтеграція прогнозу в оптимізацію	Використання прогнозу для розрахунку замовлення	Покращення параметрів поповнення	Немає вибору між політиками
Навчання з підкріпленням	Навчання рішення через взаємодію із середовищем	Адаптивність і покращення витрат	Низька інтерпретованість
Гібридні підходи	Поєднання прогнозування та адаптивного управління	Гнучкіші рішення	Немає чіткого розділення оцінювання і вибору

Zhang, Li, Qin, Xu та Zhu досліджують використання Thompson Sampling у повторюваній задачі newsvendor [26]. Це джерело є важливим для обґрунтування можливості застосування методів імовірнісного послідовного вибору в задачах управління запасами. Автори показують, що Thompson Sampling може бути ефективним у середовищі з неповним спостереженням попиту. Однак і тут метод використовується для вибору рішення щодо кількості замовлення, а не для адаптивного вибору між різними класами політик поповнення.

Узагальнюючи розглянуті дослідження, можна виділити загальну еволюцію підходів до управління запасами, візуалізовану на рис. 2.

Проведений аналіз дозволяє зробити висновок, що сучасні дослідження поступово наближаються до потреби побудови модульних адаптивних систем управління запасами. З одного боку, прогнозні моделі машинного навчання забезпечують якісніше оцінювання попиту, ризику дефіциту та нестабільності середовища. З іншого боку, навчання з підкріпленням забезпечує механізм адаптації рішень до змін середовища. Однак між цими двома напрямками залишається невирішений розрив: прогнозування не переходить у самостійне оцінювання політик, а навчання з підкріпленням переважно реалізується як монолітна модель прямого прийняття рішень.

Отже, аналіз останніх досліджень і публікацій показав, що наявні підходи забезпечують вагомий результати в окремих напрямках: підвищенні точності прогнозування, зниженні ризику дефіциту, прямій оптимізації параметрів замовлення та адаптивному навчанні рішень. Разом із тим недостатньо дослідженою залишається задача побудови такої архітектури, у якій один інтелектуальний компонент виконує оцінювання очікуваної ефективності альтернативних політик поповнення, а інший компонент здійснює адаптивний вибір політики залежно від поточного стану системи. Саме ця наукова ніша визначає доцільність розроблення авторського підходу на основі архітектури «оцінювання–вибір», що поєднує можливості машинного навчання з механізмами послідовного адаптивного прийняття рішень.

Мета дослідження

Метою дослідження є розроблення концептуальних засад архітектури адаптивного вибору політик поповнення запасів на основі оцінювання їх очікуваної ефективності, що забезпечує функціональне розділення процесів оцінювання альтернативних політик та прийняття управлінських рішень в умовах невизначеного попиту.

Для досягнення поставленої мети виконано аналіз сучасних підходів до управління запасами, досліджено можливості використання методів машинного навчання та навчання з

підкріпленням у задачах підтримки прийняття рішень, виявлено обмеження існуючих прогнозно-орієнтованих, гібридних та адаптивних рішень і сформовано

концептуальні принципи побудови архітектури адаптивного вибору політик поповнення запасів.

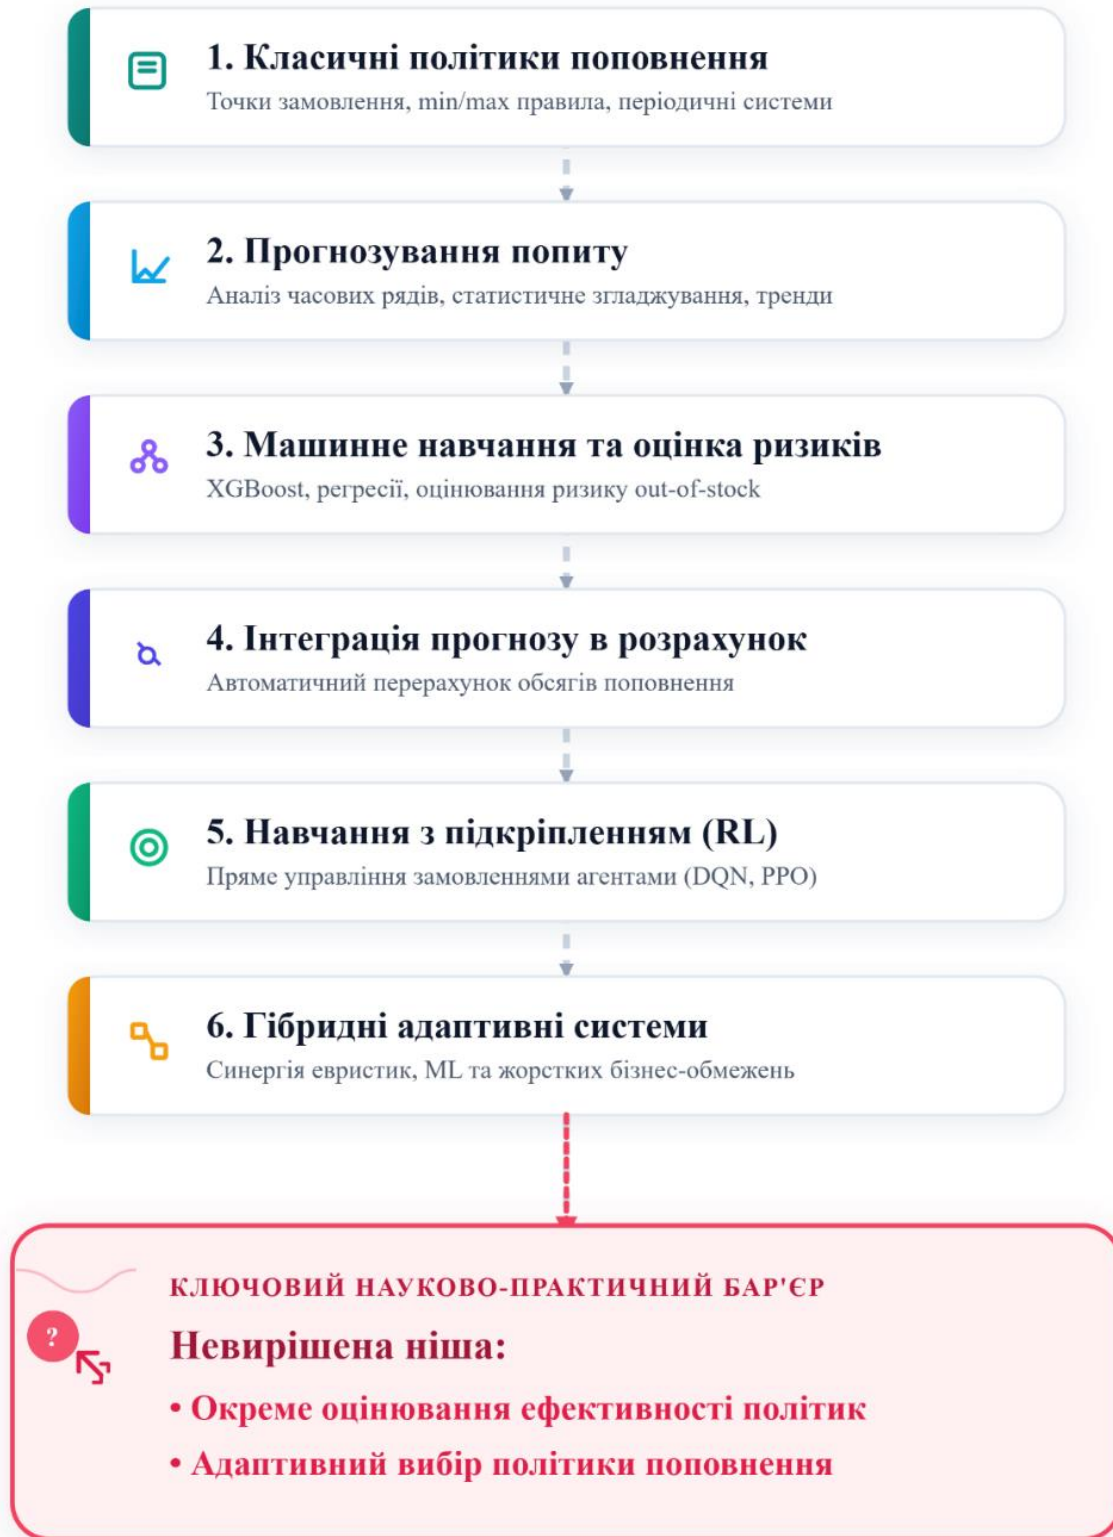


Рис. 2. Еволюція підходів до адаптивного управління запасами

Таблиця 2. Порівняння сучасних підходів із позиції поставленої проблеми

Підхід	Що вирішує	Що залишається поза увагою
Прогнозні моделі машинного навчання	Прогноз попиту, ризик дефіциту	Вибір політики поповнення
Інтегровані моделі прогнозування й оптимізації	Розрахунок параметрів замовлення	Порівняння альтернативних політик
Наскрізнi моделі навчання з підкріпленням	Адаптивне формування рішень	Інтерпретованість і модульність
Структуроване навчання з підкріпленням	Часткове використання структури політик	Окремий блок оцінювання політик
Методи послідовного вибору	Баланс між дослідженням і використанням рішень	Вибір між класами політик поповнення

Виклад основного матеріалу

Проведений аналіз сучасних досліджень показав, що більшість існуючих підходів до управління запасами орієнтована або на підвищення точності прогнозування попиту, або на безпосередню оптимізацію параметрів поповнення запасів. При цьому як у прогнозно-орієнтованих системах, так і в сучасних адаптивних моделях недостатньо уваги приділяється задачі вибору політики поповнення запасів як самостійному об'єкту управління.

У класичних системах управління запасами політика поповнення зазвичай визначається на етапі налаштування системи та надалі використовується протягом тривалого часу. Проте практика функціонування сучасних логістичних систем свідчить, що ефективність окремої політики значною мірою залежить від поточного стану середовища. Політика, яка забезпечує високі результати в умовах стабільного попиту, може виявитися недостатньо ефективною за різких змін ринку, сезонних коливань або появи нових товарів. Аналогічно політика, орієнтована на мінімізацію витрат на зберігання запасів, не завжди забезпечує необхідний рівень обслуговування споживачів.

У зв'язку з цим доцільно розглядати процес управління запасами не як задачу пошуку єдиної універсальної політики поповнення, а як задачу адаптивного вибору найбільш доцільної політики залежно від поточного стану системи. Подібний підхід дозволяє враховувати зміну характеристик попиту, рівня запасів, структури витрат та інших факторів, що

впливають на ефективність функціонування системи.

Концептуально процес адаптивного управління запасами можна представити на рис. 3 як послідовність взаємопов'язаних етапів, що починаються зі збору та аналізу даних і завершуються оцінюванням результатів прийнятого рішення.

На відміну від традиційних схем типу «прогнозування - оптимізація», запропонований підхід передбачає оцінювання не лише майбутнього попиту, а й очікуваного результату використання різних політик поповнення запасів. Таким чином, рішення приймається не на основі окремого прогнозу попиту, а на основі порівняння потенційної ефективності кількох альтернативних варіантів управління.

Для реалізації такої логіки доцільно використовувати архітектуру «оцінювання–вибір», у якій процес аналізу альтернативних політик та процес прийняття рішення виконуються різними функціональними компонентами.

Перший компонент відповідає за оцінювання альтернативних політик поповнення запасів. Його завданням є аналіз поточного стану системи та визначення очікуваних наслідків використання різних варіантів управління. Фактично система повинна відповісти на запитання: які результати може забезпечити кожна з доступних політик за поточних умов функціонування? На відміну від традиційних моделей прогнозування, які зосереджені переважно на оцінюванні майбутнього попиту, запропонований підхід передбачає комплексне оцінювання майбутнього стану системи.

У процесі такого оцінювання доцільно враховувати не лише характеристики попиту, а й параметри

запасів, економічні показники, рівень обслуговування та стабільність роботи системи.

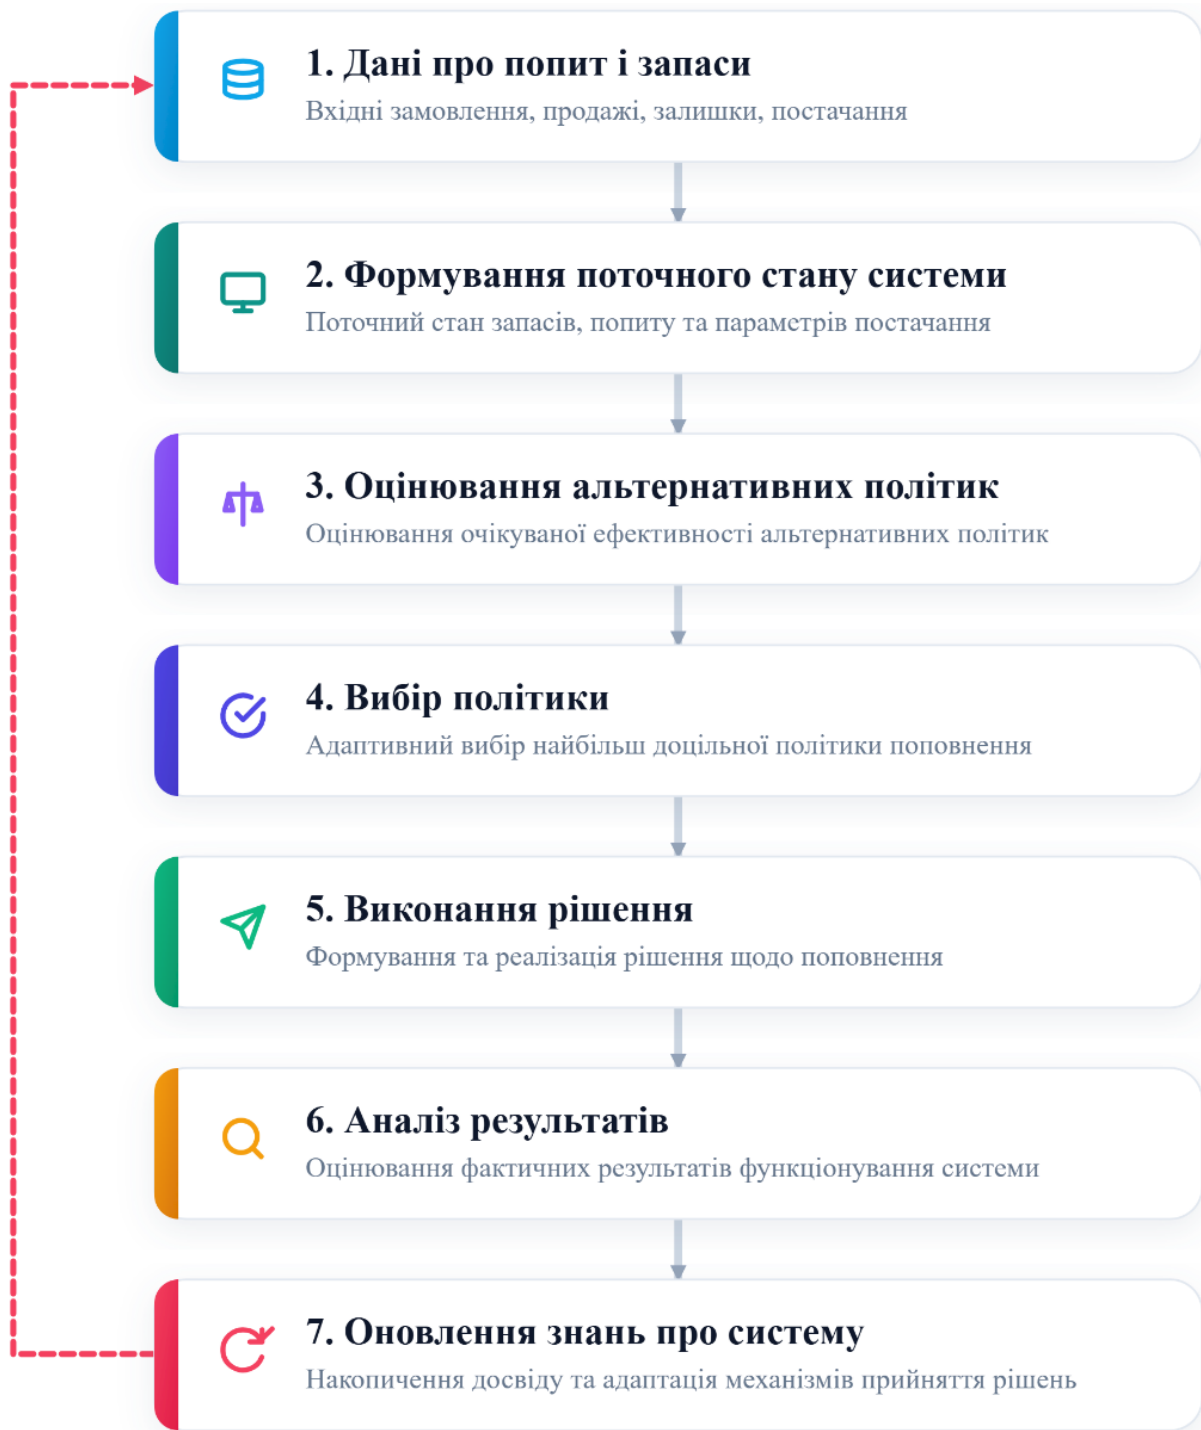


Рис. 3. Концептуальна схема адаптивного управління запасами

Таблиця 3. Основні групи параметрів для оцінювання альтернативних політик поповнення запасів

Група параметрів	Приклади показників	Призначення
Характеристики попиту	Мінливість попиту, сезонність, тенденції продажів	Оцінювання невизначеності середовища
Характеристики запасів	Поточний запас, страховий запас, оборотність	Оцінювання забезпеченості товаром
Економічні показники	Витрати на зберігання, витрати дефіциту, витрати замовлення	Оцінювання економічної ефективності
Показники сервісу	Рівень обслуговування, частота дефіциту	Оцінювання якості обслуговування споживачів
Показники стабільності	Коливання рівня запасів, частота коригування рішень	Оцінювання стійкості політики

Таким чином, оцінювання політики поповнення повинно враховувати комплекс взаємопов'язаних показників, а не окремі локальні характеристики системи. Це пояснюється тим, що покращення одного показника не завжди супроводжується загальним покращенням роботи системи. Наприклад, зменшення запасів може позитивно впливати на витрати зберігання, але одночасно збільшувати ризик виникнення дефіциту. Аналогічно підвищення рівня сервісу часто супроводжується зростанням середнього обсягу запасів.

Другим ключовим компонентом архітектури є механізм вибору політики поповнення. Його призначення полягає у виборі найбільш доцільного варіанта управління на основі результатів попереднього оцінювання.

Принциповою особливістю такого підходу є відмова від використання єдиної фіксованої політики. Система розглядає набір альтернативних політик поповнення та адаптивно визначає, яка з них найбільше відповідає поточному стану середовища. У результаті одна й та сама товарна позиція може обслуговуватися різними політиками на різних етапах свого життєвого циклу або за різних характеристик попиту.

Додатковою перевагою адаптивного вибору є можливість накопичення досвіду функціонування системи. У процесі роботи система отримує інформацію про результати використання різних політик та поступово формує знання про умови, за яких кожна з них демонструє найкращі результати. Це створює передумови для безперервного вдосконалення процесу

прийняття рішень без необхідності постійного ручного коригування параметрів.

Концептуальну структуру запропонованої архітектури наведено на рис. 4.

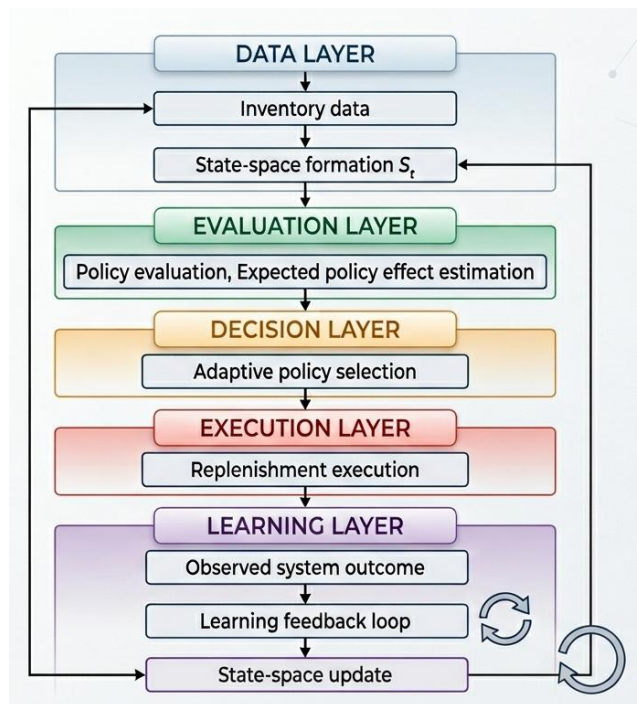


Рис. 4. Архітектура адаптивного вибору політик поповнення запасів.

Рівень даних забезпечує збір та підготовку інформації про функціонування системи управління запасами.

Рівень оцінювання виконує аналіз поточного стану системи та формує оцінки очікуваної ефективності альтернативних політик поповнення.

Рівень прийняття рішень здійснює вибір політики, яка найбільше відповідає поточним умовам функціонування.

Рівень виконання забезпечує реалізацію обраної політики у процесі поповнення запасів.

Рівень навчання та зворотного зв'язку аналізує отримані результати та формує нові знання щодо ефективності різних політик управління.

Важливою перевагою запропонованого підходу є функціональне розділення процесів оцінювання та прийняття рішень. На відміну від більшості сучасних адаптивних систем, де всі функції реалізуються в межах єдиної моделі,

запропонована архітектура дозволяє незалежно вдосконалювати окремі компоненти системи. Це спрощує супроводження, модернізацію та інтеграцію рішення з корпоративними інформаційними системами.

Крім того, розділення функцій оцінювання та вибору підвищує рівень інтерпретованості системи. У такому випадку можливо не лише визначити, яка політика була обрана, але й пояснити причини її вибору через результати оцінювання альтернативних варіантів.

Таблиця 4. Порівняння сучасних архітектур управління запасами

Характеристика	Прогнозно-орієнтовані системи	Наскрізні системи навчання з підкріпленням	Архітектура «оцінювання-вибір»
Прогнозування попиту	Так	Частково	Так
Адаптивність	Обмежена	Висока	Висока
Інтерпретованість	Середня	Низька	Висока
Модульність	Частково	Низька	Висока
Інтеграція з ERP та DSS	Середня	Ускладнена	Спрощена
Адаптивний вибір політик	Ні	Частково	Так

Отже, запропонований підхід передбачає перехід від безпосереднього формування параметрів поповнення запасів до адаптивного вибору політики управління на основі оцінювання її очікуваної ефективності. Подібна логіка дозволяє поєднати переваги сучасних методів аналізу даних, адаптивного прийняття рішень та класичних політик управління запасами, забезпечуючи при цьому модульність, інтерпретованість і практичну придатність для побудови інтелектуальних систем підтримки прийняття рішень у сфері управління запасами.

Висновки

У статті досліджено сучасні підходи до управління запасами в умовах невизначеності та нестаціонарного попиту. Проведений аналіз показав, що розвиток систем управління запасами відбувається у напрямі поступового переходу від класичних політик поповнення до інтелектуальних систем, які використовують методи машинного

навчання та навчання з підкріпленням для підтримки процесу прийняття рішень.

На основі аналізу наукових публікацій встановлено, що прогнозно-орієнтовані підходи забезпечують підвищення точності оцінювання майбутнього попиту, тоді як адаптивні моделі на основі навчання з підкріпленням дозволяють формувати рішення з урахуванням динамічних змін середовища. Водночас більшість існуючих підходів орієнтована або на прогнозування попиту, або на безпосереднє формування рішень щодо поповнення запасів, що обмежує можливості адаптивного вибору між альтернативними політиками управління.

У результаті проведеного дослідження обґрунтовано доцільність розгляду політики поповнення запасів як самостійного об'єкта адаптивного вибору. Показано, що в умовах змінного попиту та невизначеності зовнішнього середовища використання єдиної фіксованої політики не завжди забезпечує необхідний рівень ефективності функціонування системи управління запасами.

Для усунення виявлених обмежень запропоновано концептуальну архітектуру адаптивного вибору політик поповнення запасів, побудовану на принципі функціонального розділення процесів оцінювання альтернативних політик та прийняття управлінських рішень. Запропонована архітектура включає рівень даних, рівень оцінювання, рівень прийняття рішень, рівень виконання та рівень навчання із замкненим контуром зворотного зв'язку, що забезпечує можливість адаптації системи до змін умов функціонування.

Порівняльний аналіз показав, що запропонований підхід поєднує переваги прогнозно-орієнтованих систем і сучасних адаптивних моделей управління запасами, забезпечуючи при цьому модульність, інтерпретованість та придатність до інтеграції із корпоративними системами підтримки прийняття рішень.

Отримані результати формують концептуальне підґрунтя для подальших досліджень, спрямованих на розроблення методів оцінювання очікуваної ефективності альтернативних політик поповнення запасів, механізмів їх адаптивного вибору та моделей інтелектуального управління запасами в умовах нестационарного попиту.

Література

1. Silver E. A., Pyke D. F., Thomas D. J. *Inventory and Production Management in Supply Chains*. 4th ed. Boca Raton : CRC Press, 2016. 664 p. DOI: 10.1201/b10463.
2. Mohammed Z., Chafi A., El Hammoumi M. A hybrid learning framework for forecasting uncertainty and adaptive inventory planning in retail supply chains // *Supply Chain Analytics*. 2025. Vol. 13. Article 100180. DOI: 10.1016/j.sca.2025.100180.
3. Rolf B., Jackson I., Müller M., Lang S., Reggelin T., Ivanov D. A review on reinforcement learning algorithms and applications in supply chain management // *International Journal of Production Research*. 2023. Vol. 61, No. 20. P. 7151–7179. DOI: 10.1080/00207543.2022.2140221.
4. Boute R. N., Gijsbrechts J., van Jaarsveld W., Vanvuchelen N. Deep reinforcement learning for inventory control: A roadmap // *European Journal of Operational Research*. 2022. Vol. 298, No. 2. P. 401–412. DOI: 10.1016/j.ejor.2021.07.016.
5. Cuartas C., Aguilar J. Hybrid algorithm based on reinforcement learning for smart inventory management // *Journal of Intelligent Manufacturing*. 2023. Vol. 34. P. 123–149. DOI: 10.1007/s10845-022-01982-5.
6. Bergsma R., de Ruijt C., Bhulai S. A systematic review of machine learning approaches in inventory control optimization // *Operations Research Perspectives*. 2025. Vol. 15. Article 100367. DOI: 10.1016/j.orp.2025.100367.
7. Muth M., Lingenfelder M., Nufer G. The application of machine learning for demand prediction under macroeconomic volatility: a systematic literature review // *Management Review Quarterly*. 2025. Vol. 75. P. 2759–2802. DOI: 10.1007/s11301-024-00447-8.
8. Samal T., Ghosh A. Ensemble-based predictive analytics for demand forecasting in multi-channel retailing // *Expert Systems with Applications*. 2026. Vol. 299, Part D. Article 130212. DOI: 10.1016/j.eswa.2025.130212.
9. Wang J., Luo L. A forecasting method of multi-category product sales: analysis and application // *Management System Engineering*. 2023. Vol. 2. Article 2. DOI: 10.1007/s44176-023-00012-9.
10. Liu Y., Kalaitzi D., Wang M., Papanagnou C. A machine learning approach to inventory stockout prediction // *Journal of Digital Economy*. 2025. Vol. 4. P. 144–155. DOI: 10.1016/j.jdec.2025.06.002.
11. Goulart D. D., de Carvalho R. B., Henriques M. A., Nunes Carvalho B. K. G. Predictive models for inventory optimization: a machine learning application for demand forecasting at a construction supplies distributor // *Future Business Journal*. 2026. Vol. 12. Article 92. DOI: 10.1186/s43093-026-00807-8.
12. Bansal V., Bisi A., Roy D. Integrated inventory replenishment and online demand allocation decisions for an omnichannel retailer with ship-from-store strategy // *European Journal of Operational Research*. 2024. Vol. 316. P. 1085–1100. DOI: 10.1016/j.ejor.2024.02.027.
13. Ren X. et al. Data-driven analysis on inventory problem for anticipatory shipping // *Computers & Industrial Engineering*. 2025. Article 111038. DOI: 10.1016/j.cie.2025.111038.
14. Vieira B. P., Frazzon E. M. Application of Reinforcement Learning to Improve Finished Goods Inventory Management: A Systematic Review // *IFAC-PapersOnLine*. 2025. Vol. 59, No. 10. P. 841–846. DOI: 10.1016/j.ifacol.2025.09.143.
15. Geevers K., van Hezewijk L., Mes M. R. K. Multi-echelon inventory optimization using deep reinforcement learning // *Central European Journal of Operations Research*. 2024. Vol. 32. P. 653–683. DOI: 10.1007/s10100-023-00872-2.
16. Gijsbrechts J., Boute R. N., Van Mieghem J. A., Zhang D. J. Can Deep Reinforcement Learning Improve Inventory Management? Performance on Lost Sales, Dual-Sourcing, and Multi-Echelon Problems // *Manufacturing & Service Operations Management*. 2022. Vol. 24, No. 3. P. 1349–1368. DOI: 10.1287/msom.2021.1064.
17. Park H., Choi D. G., Min D. Adaptive inventory replenishment using structured reinforcement learning by exploiting a policy structure // *International Journal of Production Economics*. 2023. Vol. 266. Article 109029. DOI: 10.1016/j.ijpe.2023.109029.
18. Dehaybe H., Catanzaro D., Chevalier P. Deep Reinforcement Learning for inventory optimization with non-stationary uncertain demand // *European Journal of*

Operational Research. 2024. Vol. 314, No. 2. P. 433–445. DOI: 10.1016/j.ejor.2023.10.007.

19. Tian R., Lu M., Wang H., Wang B., Tang Q. IACPPPO: A deep reinforcement learning-based model for warehouse inventory replenishment // *Computers & Industrial Engineering*. 2024. Vol. 187. Article 109829. DOI: 10.1016/j.cie.2023.109829.

20. Zhang Y., He L., Zheng J. A Deep Reinforcement Learning-Based Dynamic Replenishment Approach for Multi-Echelon Inventory Considering Cost Optimization // *Electronics*. 2025. Vol. 14, No. 1. Article 66. DOI: 10.3390/electronics14010066.

21. Rizqi Z. U., Chou S.-Y. Neuroevolution reinforcement learning for multi-echelon inventory optimization with delivery options and uncertain discount // *Engineering Applications of Artificial Intelligence*. 2024. Vol. 134. Article 108670. DOI: 10.1016/j.engappai.2024.108670.

22. Demizu T., Fukazawa Y., Morita H. Inventory management of new products in retailers using model-based deep reinforcement learning // *Expert Systems with Applications*. 2023. Vol. 229. Article 120256. DOI: 10.1016/j.eswa.2023.120256.

23. Teck S., Phạm T.-S., Rousseau L.-M., Vansteenwegen P. Deep reinforcement learning for the real-time inventory rack storage assignment and replenishment problem // *European Journal of Operational Research*. 2025. Vol. 327, No. 2. P. 606–622. DOI: 10.1016/j.ejor.2025.05.008.

24. Kolyaei M., Zhang L., Blom M. Inventory replenishment and fulfilment decisions for an omnichannel retailer: a reinforcement learning-based method // *International Journal of Production Research*. 2025. Vol. 63, No. 24. P. 9571–9592. DOI: 10.1080/00207543.2025.2520596.

25. An L., Li A. A., Moseley B., Ravi R. The Nonstationary Newsvendor with (and Without) Predictions // *Manufacturing & Service Operations Management*. 2025. Vol. 27, No. 3/4. DOI: 10.1287/msom.2024.1168.

26. Zhang W., Li C., Qin H., Xu Y., Zhu R. Thompson Sampling for Repeated Newsvendor // *CoRR/arXiv*. 2025. DOI: 10.48550/arXiv.2502.09900.

References

1. Silver E. A., Pyke D. F., Thomas D. J. *Inventory and Production Management in Supply Chains*. 4th ed. Boca Raton : CRC Press, 2016. 664 p. DOI: 10.1201/b10463.

2. Mohammed Z., Chafi A., El Hammoumi M. A hybrid learning framework for forecasting uncertainty and adaptive inventory planning in retail supply chains // *Supply Chain Analytics*. 2025. Vol. 13. Article 100180. DOI: 10.1016/j.sca.2025.100180.

3. Rolf B., Jackson I., Müller M., Lang S., Reggelin T., Ivanov D. A review on reinforcement learning algorithms and applications in supply chain management // *International Journal of Production Research*. 2023. Vol. 61, No. 20. P. 7151–7179. DOI: 10.1080/00207543.2022.2140221.

4. Boute R. N., Gijsbrechts J., van Jaarsveld W., Vanvuchelen N. Deep reinforcement learning for

inventory control: A roadmap // *European Journal of Operational Research*. 2022. Vol. 298, No. 2. P. 401–412. DOI: 10.1016/j.ejor.2021.07.016.

5. Cuartas C., Aguilar J. Hybrid algorithm based on reinforcement learning for smart inventory management // *Journal of Intelligent Manufacturing*. 2023. Vol. 34. P. 123–149. DOI: 10.1007/s10845-022-01982-5.

6. Bergsma R., de Ruijt C., Bhulai S. A systematic review of machine learning approaches in inventory control optimization // *Operations Research Perspectives*. 2025. Vol. 15. Article 100367. DOI: 10.1016/j.orp.2025.100367.

7. Muth M., Lingenfelder M., Nufer G. The application of machine learning for demand prediction under macroeconomic volatility: a systematic literature review // *Management Review Quarterly*. 2025. Vol. 75. P. 2759–2802. DOI: 10.1007/s11301-024-00447-8.

8. Samal T., Ghosh A. Ensemble-based predictive analytics for demand forecasting in multi-channel retailing // *Expert Systems with Applications*. 2026. Vol. 299, Part D. Article 130212. DOI: 10.1016/j.eswa.2025.130212.

9. Wang J., Luo L. A forecasting method of multi-category product sales: analysis and application // *Management System Engineering*. 2023. Vol. 2. Article 2. DOI: 10.1007/s44176-023-00012-9.

10. Liu Y., Kalaitzi D., Wang M., Papanagnou C. A machine learning approach to inventory stockout prediction // *Journal of Digital Economy*. 2025. Vol. 4. P. 144–155. DOI: 10.1016/j.jdec.2025.06.002.

11. Goulart D. D., de Carvalho R. B., Henriques M. A., Nunes Carvalho B. K. G. Predictive models for inventory optimization: a machine learning application for demand forecasting at a construction supplies distributor // *Future Business Journal*. 2026. Vol. 12. Article 92. DOI: 10.1186/s43093-026-00807-8.

12. Bansal V., Bisi A., Roy D. Integrated inventory replenishment and online demand allocation decisions for an omnichannel retailer with ship-from-store strategy // *European Journal of Operational Research*. 2024. Vol. 316. P. 1085–1100. DOI: 10.1016/j.ejor.2024.02.027.

13. Ren X. et al. Data-driven analysis on inventory problem for anticipatory shipping // *Computers & Industrial Engineering*. 2025. Article 111038. DOI: 10.1016/j.cie.2025.111038.

14. Vieira B. P., Frazzon E. M. Application of Reinforcement Learning to Improve Finished Goods Inventory Management: A Systematic Review // *IFAC-PapersOnLine*. 2025. Vol. 59, No. 10. P. 841–846. DOI: 10.1016/j.ifacol.2025.09.143.

15. Geevers K., van Hezewijk L., Mes M. R. K. Multi-echelon inventory optimization using deep reinforcement learning // *Central European Journal of Operations Research*. 2024. Vol. 32. P. 653–683. DOI: 10.1007/s10100-023-00872-2.

16. Gijsbrechts J., Boute R. N., Van Mieghem J. A., Zhang D. J. Can Deep Reinforcement Learning Improve Inventory Management? Performance on Lost Sales, Dual-Sourcing, and Multi-Echelon Problems // *Manufacturing & Service Operations Management*. 2022. Vol. 24, No. 3. P. 1349–1368. DOI: 10.1287/msom.2021.1064.

17. Park H., Choi D. G., Min D. Adaptive inventory replenishment using structured reinforcement learning by exploiting a policy structure // *International Journal of Production Economics*. 2023. Vol. 266. Article 109029. DOI: 10.1016/j.ijpe.2023.109029.

18. Dehaybe H., Catanzaro D., Chevalier P. Deep Reinforcement Learning for inventory optimization with non-stationary uncertain demand // *European Journal of Operational Research*. 2024. Vol. 314, No. 2. P. 433–445. DOI: 10.1016/j.ejor.2023.10.007.

19. Tian R., Lu M., Wang H., Wang B., Tang Q. IACPPPO: A deep reinforcement learning-based model for warehouse inventory replenishment // *Computers & Industrial Engineering*. 2024. Vol. 187. Article 109829. DOI: 10.1016/j.cie.2023.109829.

20. Zhang Y., He L., Zheng J. A Deep Reinforcement Learning-Based Dynamic Replenishment Approach for Multi-Echelon Inventory Considering Cost Optimization // *Electronics*. 2025. Vol. 14, No. 1. Article 66. DOI: 10.3390/electronics14010066.

21. Rizqi Z. U., Chou S.-Y. Neuroevolution reinforcement learning for multi-echelon inventory optimization with delivery options and uncertain discount // *Engineering Applications of Artificial Intelligence*. 2024. Vol. 134. Article 108670. DOI: 10.1016/j.engappai.2024.108670.

22. Demizu T., Fukazawa Y., Morita H. Inventory management of new products in retailers using model-

based deep reinforcement learning // *Expert Systems with Applications*. 2023. Vol. 229. Article 120256.

DOI: 10.1016/j.eswa.2023.120256.

23. Teck S., Phạm T.-S., Rousseau L.-M., Vansteenwegen P. Deep reinforcement learning for the real-time inventory rack storage assignment and replenishment problem // *European Journal of Operational Research*. 2025. Vol. 327, No. 2. P. 606–622. DOI: 10.1016/j.ejor.2025.05.008.

24. Kolyaei M., Zhang L., Blom M. Inventory replenishment and fulfillment decisions for an omnichannel retailer: a reinforcement learning-based method // *International Journal of Production Research*. 2025. Vol. 63, No. 24. P. 9571–9592.

DOI: 10.1080/00207543.2025.2520596.

25. An L., Li A. A., Moseley B., Ravi R. The Nonstationary Newsvendor with (and Without) Predictions // *Manufacturing & Service Operations Management*. 2025. Vol. 27, No. 3/4.

DOI: 10.1287/msom.2024.1168.

26. Zhang W., Li C., Qin H., Xu Y., Zhu R. Thompson Sampling for Repeated Newsvendor // *CoRR/arXiv*. 2025. DOI: 10.48550/arXiv.2502.09900.

The article has been sent to the editors 08.06.26.

After processing 18.06.26.

Submitted for printing 30.06.26

Copyright under license CCBY-SA4.0.