

Література

1. **Psanis C.** Modelling and experimentation on air hybrid engine concepts for automotive applications. 2007. P. 32–36.
2. **Verma S. S.** Latest Developments of a Compressed Air Vehicle: A Status Report / C. Psanis. 2013.
3. **Trajkovic S.** The Pneumatic Hybrid Vehicle: A New Concept for Fuel Consumption Reduction. 2010.

УДК 621.311.1

ПІДВИЩЕННЯ ЕНЕРГОЕФЕКТИВНОСТІ ПРОМИСЛОВИХ ЕЛЕКТРОМЕРЕЖ ШЛЯХОМ ІНТЕЛЕКТУАЛЬНОГО КЕРУВАННЯ НАКОПИЧУВАЧАМИ

Петренко Андрій Володимирович, канд. техн. наук, доцент кафедри інженерії енергосистем, Національний університет біоресурсів і природокористування України, *e-mail: petrenko@nubip.edu.ua*,
ORCID ID 0000-0002-8246-4911

Забіяка Денис Олександрович, аспірант,
Національний університет біоресурсів і природокористування України,
e-mail: denis19z19@gmail.com,
ORCID ID 0009-0003-2363-097X

У сучасних промислових електромережах активно впроваджуються відновлювані джерела енергії, зокрема сонячні та вітрові електростанції. Зростання частки генерованої електроенергії від відновлюваних джерел призводить до значної непередбачуваності як виробництва, так і споживання електроенергії. У таких умовах ефективно використання систем накопичення енергії BESS стає ключовим для забезпечення стабільності електроенергії в мережі, зниження витрат на електроенергію та зменшення пікового навантаження [1, 2, 5].

Традиційні методи керування, засновані на фіксованих правилах або модельно-прогнозованому підході, мають суттєві обмеження, та не достатньо адаптовані до змінних тарифів, високої невизначеності прогнозів та вимог роботи в реальному часі. Крім того, такі методи часто не враховують одночасно деградацію акумуляторів, пікові навантаження та економічні показники [2, 6, 7].

Алгоритми глибокого навчання з підкріпленням DRL пропонують принципово інший підхід. Вони не потребують точної математичної моделі системи, а навчаються безпосередньо через взаємодію з середовищем. Агент такого навчання формує адаптивну стратегію керування, оптимізуючи функцію винагороди, яка може включати кілька цілей одночасно: мінімізацію вартості

електроенергії, згладжування пікових навантажень, зменшення зносу акумуляторів та зниження викидів вуглецю [3, 4, 8].

Типова структура керування є ієрархічною. На верхньому рівні застосовуються нейронні мережі для прогнозування: рекурентні мережі або моделі на базі трансформерів прогнозують навантаження, генерування від відновлюваних джерел енергії та ціни на електроенергію. На нижньому рівні працює агент глибокого навчання з підкріпленням у рамках марковського процесу прийняття рішень. До складу стану входять поточний рівень заряду акумулятора SoC, прогнози на наступні періоди, час доби, поточні тарифи та інші параметри. Дії агента – це неперервна величина потужності заряду або розряду. Функція винагороди зазвичай комбінована: негативна вартість електроенергії плюс штрафи за перевищення пікового навантаження та за інтенсивний знос акумуляторів (наприклад, за допомогою підрахунку еквівалентних циклів або методу Rainflow) [3, 9, 10].

Таблиця 1 – Порівняння ключових DRL-алгоритмів для керування BESS (за результатами 2023–2025 рр.)

Алгоритм	Переваги	Недоліки	Типові результати (економія витрат, інші ефекти)
DQN	Простота, добре для дискретних дій	Обмежений у неперервних просторах	10–22 % зниження витрат, стабільне пікове гоління
DDPG	Неперервні дії, стабільність	Чутливість до гіперпараметрів	15–25 % економії, добра адаптація до стохастичності
PPO	Стабільне навчання, sample-efficient	Повільніша збіжність	14–30 % зниження витрат, 10–20 % подовження життя батарей
SAC	Максимізація ентропії, стохастичні середовища	Вища обчислювальна складність	20–40 % економії, краща стійкість до невизначеності, 10–25 % зниження деградації

Алгоритм PPO забезпечує стабільне навчання та ефективне використання даних, SAC добре працює в умовах високої непередбачуваності завдяки механізму максимізації ентропії, тоді як інші алгоритми підходять для неперервних або дискретних дій [4, 8, 11].

У гібридних системах, де системи накопичення енергії працюють разом з газовими турбінами, глибоке навчання з підкріпленням значно знижує кількість пусків турбін, що зменшує витрати на обслуговування та подовжує ресурс обладнання [5, 12].

Особливий інтерес становлять мультиагентні підходи. Наприклад, Multi-Agent Proximal Policy Optimization з Pareto-оптимізацією дозволяє одночасно оптимізувати кілька конфліктуючих цілей: один агент мінімізує витрати на електроенергію, інший – частоту перемикачів для збереження «здоров'я» акумуляторів.

Таблиця 2 – Практичні результати застосування DRL для керування BESS у мікромережах (2023–2025 рр.)

Сценарій / Джерело	Базо-вий метод	DRL-метод	Зниження витрат	Зниження пікового навантаження / інші ефекти	Примітка
Промислова мікромережа з ВДЕ та BESS (MDPI, 2025)	Rule-based / No-ESS	MAPPO	14.68 % (загальна економія)	Зменшення перемикань батарей	Порівняно з TD3/SAC/PP O
Динамічні тарифи, BESS контроль (ScienceDirect, 2025)	Gradient-based	SAC	До 40 %	Стабільний SoC >50 %, подовження життя	Реальні профілі навантаження
Off-grid HRES з dual-battery (Sage, 2025)	Rule-based / static	DQN	>20 % LCC	До 30 % CO ₂ , >10 % деградації	Гібридні батареї
Економічний диспетч + peak shaving (ScienceDirect, 2025)	Rule-based	PPO/SAC	15–35 %	20–50 % пікове гоління	З урахуванням деградації
Федеративне навчання для будівель/мікромереж (ScienceDirect, 2025)	Локальне RL	FRL (PPO/DDPG)	5–5.5 %	4.6–5.55 % CO ₂	Збереження приватності

В умовах України впровадження таких технологій є особливо актуальним. Промисловим підприємствам доводиться взаємодіяти з високими тарифами в години пік, нестабільністю електропостачання та активним розвитком відновлюваних джерел енергії. Пілотні проекти з інтеграцією систем накопичення енергії та інтелектуальним керуванням на базі глибокого навчання з підкріпленням можуть значно підвищити енергоефективність, знизити залежність від імпорту енергоносіїв та сприяти декарбонізації промисловості [13].

Важливим є створення національних наборів даних реальних профілів навантаження та генерування електроенергії для навчання моделей, адаптованих до умов споживачів в Україні [7].

Висновки

Інтелектуальне керування системами накопичення енергії на базі глибокого навчання (зокрема PPO, SAC та інші) може забезпечити підвищення енергоефективності промислових електромереж на 15 – 40 %, шляхом зниження операційних витрат, згладжуванню пікового навантаження (до 50 %), зменшенню зносу акумуляторів (10 – 25 %) та адаптації до непередбачуваності генерування відновлюваних джерел енергії й змінних тарифів. Результати сучасних досліджень підтверджують перевагу цих методів над традиційними підходами. В Україні такі технології мають значний потенціал для промислових об'єктів, особливо в умовах зростання частки відновлюваних джерел та потреби в енергетичній незалежності.

Література

1. **Jung S. W. et al.** Multi-Agent Deep Reinforcement Learning for Scheduling of Energy Storage System in Microgrids. *Mathematics*. 2025. Vol. 13, iss. 12. 1999. DOI: <https://doi.org/10.3390/math13121999>.
2. **Selim A. et al.** Adaptive optimization of BESS and grid set points: A model-free framework for energy management under dynamic tariff pricing. *Energy*. 2026. Vol. 346. 140148. DOI: <https://doi.org/10.1016/j.energy.2025.140148>.
3. **Sage M. et al.** Deep reinforcement learning for joint dispatch of battery storage and gas turbines in renewable-powered microgrids. *Energy and AI*. 2025. Vol. 22. 100653. DOI: <https://doi.org/10.1016/j.egyai.2025.100653>.
4. **Sievers J. et al.** Federated reinforcement learning for sustainable and cost-efficient energy management. *Energy and AI*. 2025. 100521. DOI: <https://doi.org/10.1016/j.egyai.2025.100521>.
5. **Khan W. et al.** Deep reinforcement learning-based energy management for design and control of off-grid renewable microgrids with dual-battery storage. *Energy Exploration & Exploitation*. 2025. DOI: <https://doi.org/10.1177/01445987251387368>.
6. **Kang H. et al.** Reinforcement learning-based optimal scheduling model of battery energy storage system at the building level. *Renewable and Sustainable Energy Reviews*. 2024. Vol. 190, part A. 114054. DOI: <https://doi.org/10.1016/j.rser.2023.114054>.
7. **Yang J. et al.** Physics-shielded deep reinforcement learning for safe energy management of microgrids with battery health consideration. *Journal of the Franklin Institute*. 2025. DOI: <https://doi.org/10.1016/j.jfranklin.2025>.
8. **Xiong B. et al.** Deep reinforcement learning for optimal microgrid energy management with renewable energy and electric vehicle integration. *Applied Soft Computing*. 2025. DOI: <https://doi.org/10.1016/j.asoc.2025>.
9. **Wu J. et al.** Deep reinforcement learning-based multi-objective energy management system for microgrids under flexible energy market. *Applied Energy*. 2026. DOI: <https://doi.org/10.1016/j.apenergy.2025>.
10. **Kumar K. et al.** Deep reinforcement learning-based control strategy for integration of a hybrid energy storage system in microgrids. *Journal of Energy Storage*. 2025. DOI: <https://doi.org/10.1016/j.est.2025>.
11. **Esan A. B. et al.** Augmented deep reinforcement learning for the energy management of microgrids considering renewable stochastic parameters. *Engineering Applications of Artificial Intelligence*. 2025. DOI: <https://doi.org/10.1016/j.engappai.2025>.
12. **Hosseini E. et al.** Reinforcement learning-based energy management system for lithium-ion battery storage in multilevel microgrid. *Journal of Energy Storage*. 2025. DOI: <https://doi.org/10.1016/j.est.2025>.
13. Четверта промислова революція: зміна напрямів міжнародних інвестиційних потоків : монографія / **А. І. Крисоватий та ін.** ; за наук. ред. А. І. Крисоватого, О. М. Сохацької. Тернопіль : Осадца Ю. В., 2018. 480 с.