

doi: 10.32620/oikit.2026.107.16

УДК 004.89

М. О. Кушнар'ов, І. В. Шостак

## Гібридна модель адаптивної пріоритезації енергетичних ресурсів медичного закладу в умовах критичного дефіциту

*Національний аерокосмічний університет «Харківський авіаційний інститут»*

У статті вирішується науково-прикладна задача забезпечення енергетичної стійкості критичної інфраструктури медичних закладів, що функціонують в умовах екстремального дефіциту ресурсів та нестабільності зовнішнього енергопостачання, спричинених цілеспрямованим руйнуванням енергосистеми. На відміну від традиційних систем управління енергією (BEMS), які орієнтовані на економічну ефективність у стабільних умовах, запропонований підхід зміщує фокус на максимізацію часу автономного функціонування життєзабезпечуючого обладнання. Методологічною основою дослідження є розробка гібридної децентралізованої моделі адаптивної пріоритезації енергетичних ресурсів, реалізованої на базі архітектури Edge-Fog Computing. Таке архітектурне рішення гарантує повну автономність системи: моделі TinyML на рівні Edge забезпечують миттєву детекцію аномалій, тоді як стратегічне планування здійснюється DRL-агентом на рівні Fog Node без залежності від хмарних сервісів, що усуває критичну точку відмови та підвищує рівень приватності даних. Наукова новизна роботи полягає у впровадженні етично-орієнтованої функції винагороди для агента глибокого навчання з підкріпленням (Deep Q-Network), яка математично формалізує пріоритет біоетичних принципів Beneficence та Non-Maleficence через інтеграцію категорій ризику стандарту NFPA 99. Модель використовує механізм жорсткої пріоритезації, де безумовне забезпечення критичного навантаження переважає над комфортом пацієнтів та експлуатаційними витратами, а також враховує фізичні обмеження системи, такі як мінімальний заряд акумуляторів, використовуючи елементи підходу Constrained Reinforcement Learning. Валідацію розробленої моделі проведено у симуляційному середовищі HospitalEnergyEnv на прикладі сценарію «Blackout-48». Результати порівняльного моделювання засвідчили, що запропонований DQN-агент забезпечив 100% працездатність критичного обладнання протягом 48 годин автономної роботи завдяки завчасному переходу в режим глибокої економії. Натомість традиційні алгоритми Greedy та Rule-Based вичерпали доступні ресурси на 32-й та 41-й годинах відповідно, що призвело до аварійного знеструмлення обладнання реанімаційного відділення. Практичне значення отриманих результатів полягає у створенні готової до впровадження архітектури автономних енергосистем шпиталів, яка здатна адаптивно розподіляти обмежені ресурси під час тривалих блекаутів, гарантуючи безпеку пацієнтів згідно з міжнародними стандартами.

**Ключові слова:** медичний заклад, розумні енергосистеми, навчання з підкріпленням, адаптивне управління, життєво важливе обладнання, автономне енергозабезпечення, енергетична стійкість, етично обґрунтовані алгоритми, глибоке навчання, системи охорони здоров'я, пріоритет критичних навантажень

### 1. Вступ

Сучасна медична інфраструктура переживає фазу інтенсивної цифровізації, відомої як трансформація у «розумні шпиталі» (Smart Hospitals). Цей процес передбачає широку інтеграцію Інтернету речей (IoT) та рішень на базі штучного інтелекту (AI) для автоматизації клінічних та оперативних процесів, а також для підвищення комфорту пацієнтів та ефективності надання послуг [1]. Проте, функціонування цих високотехнологічних кіберфізичних систем (КФС) критично залежить від стабільного енергопостачання.

В умовах зовнішньої агресії та цілеспрямованого руйнування ключових елементів енергетичної інфраструктури, виникає імперативна потреба у

перегляді пріоритетів управління енергоресурсами. Якщо в мирний час фокус досліджень лежав переважно на енергоефективності та оптимізації витрат [1, 2], то в умовах воєнного стану ключовим пріоритетом стає забезпечення фізичної живучості закладу (resilience) та безперервності надання критичних медичних послуг [1].

Зростання глобальної нестабільності посилює увагу до розробки стійких мікромереж (Resilient Microgrids), особливо для об'єктів охорони здоров'я, що функціонують у зонах конфліктів. Дослідження, проведені на прикладі госпіталів, що розташовані неподалік від зони бойових дій, підтверджують, що системи управління енергоресурсами мають бути оптимізовані не для економічного прибутку, а для максимізації «Днів Автономії» (Days of Autonomy) та мінімізації впливу відключення на місію закладу [3, 4]. Таким чином, вирішення проблеми, що розглядається, потребує створення є унікального гібрида енергетичної інженерії та медичної етики, де інженерні рішення мають бути суворо підпорядковані гуманітарним та регуляторним вимогам.

Обмеження при експлуатації існуючих систем управління енергетичними ресурсами із централізованою архітектурою мають місце внаслідок того, що традиційні системи управління енергією в будівлях (BEMS/HEMS) розраховані, переважно, для роботи у стабільних умовах експлуатації [1]. В них використовуються статичні алгоритми перемикання або прості прогнознi моделі, які орієнтовані на балансування навантаження для досягнення фінансової економії [1, 5]. В екстремальних ситуаціях, таких як раптовий повний блекаут, або при роботі від генераторів з обмеженим ресурсом палива, такі системи демонструють критичну нездатність до адаптивного, прогностичного управління.

Особливою вразливістю таких систем є залежність багатьох інтелектуальних архітектур від централізованих хмарних обчислювальних центрів. Втрата зв'язку з глобальною мережею (Single Point of Failure, SPOF) під час блекауту робить інтелектуальні системи управління повністю нефункціональними, що є неприпустимим для об'єктів критичної інфраструктури [1].

Ряд наукових робіт присвячено застосуванню методів глибокого навчання з підкріпленням (DRL) для оптимізації енергоспоживання [1, 2, 6]. Однак більшість сценаріїв, що описані в цих роботах, сфокусовані на побутовому секторі, комерційних будівлях [1] або загальних мікромережах, з акцентом на зниження витрат [7]. Дослідження, які б містили опис інтегрованих рішень, що поєднують високу адаптивність DRL-агентів із вимогами повної автономності, відмовостійкості та жорсткої пріоритезації навантажень для медичних закладів, залишаються фрагментованими.

### **1.1. Формулювання наукової задачі та обґрунтування наукової новизни**

На основі аналізу обмежень традиційних систем та актуальних загроз, сформульовано ключову науково-прикладну задачу: Розробка гібридної, децентралізованої моделі адаптивної пріоритезації енергетичних ресурсів, яка б забезпечувала автономне та надійне управління критичним обладнанням медичного закладу в умовах екстремального енергетичного дефіциту.

1. Децентралізована Edge-Fog Архітектура для Автономності: Запропоновано ієрархічну архітектуру, що забезпечує повну функціональну автономність. На відміну від хмарних рішень, обчислювальне навантаження розподілено між вузлами Edge (TinyML для миттєвої детекції аномалій) та Fog Node (DRL для стратегічного планування) [1]. Це архітектурне рішення усуває

критичну точку відмови, пов'язану із зовнішнім зв'язком.

2. Етично-Орієнтований DRL-Агент: Вперше в контексті енергетичного управління критичною медичною інфраструктурою запропоновано функцію винагороди, яка явно кодує медико-етичні принципи (Beneficence та Non-Maleficence) як домінуючий математичний пріоритет. Метою агента є максимізація часу роботи критичного обладнання ( $T_{survival}$ ), а не економічна оптимізація [1].

3. Інтеграція Constrained Reinforcement Learning (C-DRL): Впровадження підходів безпечного навчання з підкріпленням (Safe RL) для забезпечення жорсткого дотримання фізичних та експлуатаційних обмежень системи (наприклад, мінімального заряду акумуляторів  $SoC_{min}$ , що гарантує безпечне розгортання моделі у фізичному середовищі [8, 9].

## 1.2. Нормативно-правова база дослідження

Для забезпечення наукової строгості та можливості практичного впровадження, класифікація енергетичних навантажень має базуватися на загально визнаних міжнародних стандартах, які регулюють роботу систем аварійного живлення у медичних закладах. Ключовими документами є NFPA 99 (Health Care Facilities Code) та Article 517 Національного електричного кодексу США (NEC) [10, 11].

Згідно з NFPA 99, приміщення та обладнання медичних закладів поділяються на чотири категорії ризику, що безпосередньо корелюють із необхідністю безперебійного живлення: Категорія 1 (Критичне Навантаження) – обладнання, відмова якого "ймовірно спричинить серйозні травми або смерть пацієнтів, персоналу або відвідувачів" [12]. Це включає системи життєзабезпечення, хірургічне обладнання, системи моніторингу пацієнтів у реанімації. Для таких зон вимагається система аварійного живлення (EPSS) Level 1, відповідно до NFPA 110 [13]. Це навантаження є еквівалентом вектора  $D_{crit}$  у пропонованій моделі; Категорія 2 та 3 (Гнучке Навантаження) – обладнання, відмова якого спричинить незначні травми, дискомфорт або не матиме суттєвого впливу на догляд [12]. До цієї групи належать загальні системи вентиляції (HVAC), освітлення коридорів, адміністративні ПК. Це навантаження відповідає вектору  $D_{flex}$ . Нормативне розмежування між  $D_{crit}$  та  $D_{flex}$  є фундаментальним для моделювання. Воно надає пряме обґрунтування для встановлення домінуючої ваги  $w_1$  у функції винагороди DRL-агента. Жорстке забезпечення  $D_{crit}$  стає не просто технічною ціллю, а виконанням регуляторної вимоги, яка стосується забезпечення безпеки людського життя. Крім того, стандарт NFPA 110 встановлює вимоги до часу перемикавання навантаження, часто вимагаючи, щоб критичні системи були без живлення не більше 10 секунд, що впливає на моделювання затримок запуску резервного генератора (наприклад, 15 секунд, як у симуляції) [1, 13].

Алгоритми навчання з підкріпленням (Reinforcement Learning, RL) та їх глибокі варіації (DRL) демонструють високу ефективність у вирішенні задач послідовного прийняття рішень у складних стохастичних середовищах [2]. DRL набули широкого застосування в управлінні енергетичними системами, зокрема мікромережами, завдяки своїй здатності до оптимізації режимів функціонування розподілених енергетичних ресурсів (DERs) [7, 14]. Ключова перевага DRL полягає в його моделенезалежності (model-free). На відміну від традиційних методів, таких як Модельне Предиктивне Управління (Model Predictive Control,

MPC), DRL не вимагає попереднього знання точних функцій переходу  $P(s'|s, a)$  або повного математичного опису динаміки системи [15]. Це особливо цінно в умовах кризових сценаріїв, де непередбачуваність, спричинена військовими діями або ланцюговими відмовами обладнання, робить класичне моделювання складним або неможливим. Агенти DRL, як, наприклад, на базі SARSA або DQN, навчаються оптимальної стратегії  $\pi^*(s)$  через ітеративну взаємодію із середовищем [5, 7].

Таблиця 1

## Класифікація критичності навантажень згідно з NFPA 99

Категорія NFPA 99	Опис ризику	Приклади обладнання	Відповідність MDP-моделі	Джерело
Категорія 1	Високий ризик смерті/травм	ШВЛ, монітори, операційні лампи	$D_{crit}$ (Безумовний пріоритет $w_1$ )	[1, 12]
Категорія 2/3	Ризик невеликих травм/дискомфорту	Системи HVAC, освітлення коридорів	$D_{flex}$ (Квадратичний штраф $w_2$ )	[1, 12]
NFPA 110/Level 1	Вимога до EPSS	Резервні генератори та BESS	Жорсткі обмеження $C_{switch}$	[1, 13]

У сфері критичної інфраструктури фокус зміщується від надійності (Reliability) до стійкості (Resilience). Надійність зазвичай вимірюється метриками, такими як System Average Interruption Duration Index (SAIDI) та System Average Interruption Frequency Index (SAIFI) [16]. Однак ці метрики є недостатніми для оцінки наслідків низькоімовірних подій високої значущості (high-consequence events), як-от тривалі блекаути [17]. Дослідження підтверджують, що узагальнення SAIDI/SAIFI до еквівалентних метрик стійкості є проблематичним [18].

Для оцінювання якості процесів управління енергетичними ресурсами госпіталів релевантними є метрики, що оцінюють Абсорбційну здатність (Robustness) та Адаптивну здатність (Adaptive Capacity) системи [19]. Показник Часу Виживання Критичного Обладнання ( $T_{survival}$ ), прийнятий у цій роботі [1], є прямою кількісною мірою стійкості, оскільки відображає, як довго система може підтримувати критичні функції в умовах зовнішнього руйнування, що не є типовим для стандартних BEMS-оптимізацій.

## 2. Децентралізована архітектура системи управління енергетичними ресурсами медичного закладу на базі EDGE AI

Для забезпечення абсолютної відмовостійкості, особливо в умовах втрати зв'язку, у пропонуваній моделі здійснено перехід від централізованої хмарної архітектури на користь ієрархічної топології Edge-Fog Computing [1]. В рамках такої архітектури здійснюється розподіл обчислювального навантаження та інтелектуальних засобів управління між трьома функціональними рівнями: сприйняття (Perception Layer / IoT), де відбувається збір «сирих» даних;

периферійних обчислень (Edge Intelligence / TinyML), на цьому рівні здійснюється локальна попередня обробка та оперативна реакція на зміни у режимі функціонування енергетичної інфраструктури медичного закладу; локальної оркестрації (Fog Node / Local Server), де реалізується стратегічне DRL-планування та агрегація.

Такий розподіл на рівні оброблення інформації надає змогу забезпечити баланс між швидкістю реакції на низькому рівні (Edge) та здатністю до складного прогностичного планування на вищому рівні (Fog). Критично важливо, що DRL-агент (який вимагає значних обчислювальних ресурсів) розміщується на Fog Node, забезпечуючи при цьому локальне управління без залежності від зовнішніх мереж.

Ключовим елементом підвищення автономності та реактивності є впровадження інтелекту на найнижчому рівні - рівні периферійних обчислень. Це досягається завдяки технології **Tiny Machine Learning (TinyML)**, яка дозволяє розгортати моделі машинного навчання безпосередньо на пристроях з вкрай обмеженими апаратними ресурсами: зазвичай це мікроконтролери (наприклад, ARM Cortex-M серії) з пам'яттю від 32 до 512 kB SRAM та енергоспоживанням менше 1 mW. Ця мінімальна потреба в енергії критична для забезпечення тривалої роботи сенсорів та контролерів під час блекауту. Основною функцією TinyML на рівні контролерів окремих медичних пристроїв (ШВЛ, кисневих концентраторів, і т. ін.) є попередня обробка даних та детекція аномалій у реальному часі [1, 20, 17]. Наприклад, TinyML-моделі можуть локально фільтрувати шуми, виявляти різке падіння вольтажу або несподівані зміни параметрів роботи обладнання (як-от відмова насоса) з часом відгуку менше ніж 10 мс [1]. Така швидка локальна реакція є необхідною для систем життєзабезпечення. Використання при розробці архітектури системи управління енергоресурсами медичного закладу технології Edge AI забезпечує значне підвищення приватності даних, оскільки машинне навчання виконується безпосередньо біля сенсора, сирі, конфіденційні дані пацієнтів (наприклад, графіки життєвих показників) не передаються до Fog Node чи, тим більше, до хмари. Передаються лише агреговані мета-дані або сигнали про аномалії, що відповідає високим етичним та юридичним стандартам щодо захисту пацієнтських даних (наприклад, у контексті GDPR або HIPAA) .

Зв'язок між Edge-вузлами та Fog Node вимагає використання легковагових протоколів, оптимізованих для мереж інтернету речей з низькою пропускну здатністю та високими вимогами до енергоефективності. У локальних mesh-мережах зазвичай застосовуються протоколи, такі як MQTT-SN (MQTT for Sensor Networks) та CoAP (Constrained Application Protocol). Дослідження показують, що, незважаючи на популярність MQTT, CoAP часто демонструє кращі показники щодо time-to-completion та представлення процесів енергоспоживання у тестових сценаріях IoT [21, 22]. Це робить CoAP або його комбінацію з MQTT-SN ідеальним вибором для забезпечення живучості мережі у випадку виходу з ладу окремих маршрутизаторів.

Рівень Fog Node виконує роль мозку системи управління енергоспоживанням медичного закладу. Це локальний сервер, який забезпечує виконання стратегічного планування та керує розподілом наявних потужностей. На рівні Fog Node реалізуються такі функції: агрегація станів, тобто узагальнення векторів стану  $s_t$  від усіх Edge-вузлів та сенсорів, для формування повної картини стану системи [1]; DRL-Оркестрація, тут функціонує модель глибокого навчання

з підкріпленням (DRL-агент, наприклад, DQN), яка формує стратегічні рішення щодо управління генераторами, BESS та розподілом навантаження  $a_t$ ; прогноз та стратегія, на цьому рівні можлива інтеграція додаткових модулів, таких як прогностичні мережі (наприклад, на базі LSTM) для передбачення майбутнього попиту, можливостей подальшої генерації та зміни погодних умов, що значно покращує довгострокове стратегічне планування DRL-агента [23, 24]; федеративне навчання (Federated Learning, FL) - Fog Node також може виступати агрегатором для FL, дозволяючи оновлювати моделі прогнозування або кібербезпеки, використовуючи при цьому досвід інших автономних об'єктів, без обміну «сирими» даними. Остання із зазначених функцій Fog Node спрямована на підвищення рівню захисту системи від кібератак та забезпечення можливості масштабування системи [1, 25].

### 3. Формальне представлення моделі адаптивної пріоритетизації енергетичних ресурсів медичного закладу

Задачу динамічного управління енергетичними ресурсами медичного закладу в умовах дефіциту доцільно представити у вигляді оптимально сформульовано марковського процесу прийняття рішень (MDP). MDP визначається кортежем  $M = \langle S, A, P, R, \gamma \rangle$ , де кожен елемент кортежу має чітке функціональне значення у процесі управління енергетичними ресурсами медичного закладу:

- $S$  – простір станів, що відображає повний набір енергетичних та медико-контекстуальних параметрів системи у момент часу  $t$ . До складу вектора стану входять: доступна потужність автономних джерел; рівень заряду BESS; критичний попит; гнучкий попит; температура навколишнього середовища; та контекстні сигнали медичного середовища.

- $A$  – простір дій, тобто множина допустимих керуючих команд, які агент може застосувати до енергетичної системи: запуск/зупинка дизель-генератора; зміна режиму роботи груп навантаження (повне живлення, часткове скидання, повне відключення)

- $P(s' | s, a)$  – функція переходів, яка визначає ймовірність переходу системи зі стану  $s$  у стан  $s'$  після виконання дії  $a$ . У реальних умовах медичного закладу ця функція є невідомою та містить стохастичні фактори (погодні умови, випадкові відмови обладнання, нестабільність зовнішньої мережі), тому агент навчається її апроксимувати через взаємодію з симуляційним середовищем.

- $R(s, a)$  – функція винагороди, яка оцінює якість прийнятого рішення. У розробленій моделі вона етично-орієнтована та віддає абсолютний пріоритет забезпеченню критичного навантаження відповідно до NFPA 99.

- $\gamma \in [0; 1)$  – коефіцієнт дисконтування, що визначає баланс між короткостроковими та довгостроковими наслідками керуючих рішень. Високе значення  $\gamma$  забезпечує стратегічну орієнтацію агента на максимізацію виживання критичного обладнання у тривалих сценаріях дефіциту енергії.

У контексті розробленої моделі агентом виступає програмний керуючий модуль Fog Node, який виконує функції стратегічного планування енергорозподілу. Агент отримує вектор стану  $s_t$  і обирає дію  $a_t$  – тобто конкретну команду керування генераторами, BESS або групами навантаження. Таким чином, агент є інтелектуальним програмним компонентом, що приймає рішення в реальному часі на основі DRL-політики. Мета агента – навчитися оптимальної

політики  $\pi^*(s)$ , яка максимізує очікувану дисконтовану сумарну винагороду.

Простір станів  $S$  є багатовимірним вектором  $s_t$ , що містить як енергетичні, так і контекстуальні медичні параметри, необхідні агенту для прийняття прогностичних рішень [1, 7, 15]:

$$s_t = [P_{gen}(t), SoC(t), D_{crit}(t), D_{flex}(t), T_{amb}(t), \xi(t)]$$

де  $P_{gen}(t)$  – доступна потужність, тобто це обсяг електроенергії, доступної від усіх автономних джерел (дизельних генераторів (ДГ), сонячних панелей, зовнішньої мережі, якщо вона функціонує). Для довгострокового планування агент повинен враховувати не лише поточну потужність, а й обмежений запас палива ДГ, що є неявним параметром, який впливає на майбутній стан  $s_{t+1}$ ;  $SoC(t)$  (State of Charge) – рівень заряду Системи Накопичення Енергії (BESS). Це критично важливий буферний ресурс, для якого встановлюються жорсткі обмеження  $SoC_{min} \leq SoC_t \leq SoC_{max}$  [1];

$D_{crit}(t)$  – (Критичний Попит): Сумарний попит на енергію від життєзабезпечуючого обладнання (Категорія 1 NFPA 99). Відключення цього навантаження є неприпустимим [1, 12];

$D_{flex}(t)$  – (Гнучкий Попит): Сумарний попит від менш критичного навантаження (освітлення, вентиляція загальних зон). Це навантаження є цільовим для Load Shedding [1];

$T_{amb}(t)$  – температура навколишнього середовища, яка впливає на ефективність акумуляторів BESS (деградація при екстремальних температурах) та на потреби в опаленні/охолодженні (що може перевести HVAC-системи у категорію  $D_{crit}$  або  $D_{flex}$ , залежно від сезону) [1];

$\xi(t)$  – контекстний вектор пріоритетності, що містить набір неенергетичних параметрів, які визначають медичний контекст. Наприклад, бінарний сигнал "Повітряна тривога" (вимагає максимальної живучості та можливого перемикавання операційних процесів) або кількість активних операційних втручань для пацієнтів, які перебувають у реанімації [1]. Цей вектор дозволяє DRL-агенту інтегрувати медичні пріоритети безпосередньо у процес формування рішень.

Простір дій  $A$  є дискретним вектором управляючих сигналів  $a_t$ , який подається на комутаційне обладнання (автоматичні вимикачі, перемикачі навантаження, контролери генерації):

$$a_t = [u_{gen}, u_{load_1}, u_{load_2}, \dots, u_{load_N}]$$

•  $u_{gen} \in \{0, 1\}$  команда на запуск (1) або зупинку (0) резервного генератора [1].

•  $u_{load_i} \in \{0, 0.5, 1\}$  коефіцієнт потужності для  $i$ -ї групи споживачів [1].

• 1: повна потужність.

• 0.5: економ-режим або часткове скидання навантаження (Partial Load Curtailment).

• 0: повне відключення (Load Shedding).

Використання дискретних рівнів спрощує простір пошуку рішень для DQN-агента і відповідає фізичним можливостям більшості комутаційних пристроїв.

Функція винагороди  $R(s, a)$  є ключовим елементом новизни розробленої моделі, оскільки вона математично кодує етичні принципи, а не лише економічні чинники. Мета агента – максимізація очікуваного часу виживання критичного навантаження ( $T_{survival}$ ) [1].

Функція винагороди  $R_t$  у даному випадку визначається як:

$$R_t = w_1 \cdot I_{D_{crit}^{sup} \geq D_{crit}^{req}} - w_2 \cdot (D_{flex}^{req} - D_{flex}^{sup})^2 - w_3 \cdot C_{switch} - w_4 \cdot P_{violation}$$

де  $w_1$  – величина нагороди за критичне забезпечення,  $I_{D_{crit}^{sup} \geq D_{crit}^{req}}$  – індикатор, що дорівнює 1, якщо постачання критичної потужності ( $D_{crit}^{sup}$ ) повністю задовольняє необхідний попит ( $D_{crit}^{req}$ ), інакше – дорівнює 0,

$w_2$  – штраф за дефіцит гнучкого навантаження, при цьому обчислюється квадратичний штраф  $(D_{flex}^{req} - D_{flex}^{sup})^2$  за незадоволення гнучкого попиту. Квадратична форма забезпечує, що невеликі відхилення штрафуються менше, ніж повне відключення. Цей терм дозволяє агенту мінімізувати дискомфорт пацієнтів, але лише після забезпечення  $D_{crit}$ ;

$w_3$  – експлуатаційний штраф за перемикання;

$C_{switch}$  – штраф за надмірну кількість циклів увімкнення/вимкнення дизель-генератора або BESS. Цей штраф вводиться для підвищення довгострокової надійності системи та запобігання прискореному зносу обладнання, що є особливо важливим для систем EPSS Level 1 [1, 13];

$w_4$  – штраф за порушення фізичних обмежень;

$P_{violation}$  – підвищений штраф за порушення жорстких фізичних обмежень, таких як глибокий розряд акумуляторів ( $SoC_t < SoC_{min}$ ) або порушення балансу потужності. Хоча у стандартному DQN такий штраф є основним інструментом уникнення небезпечних станів, для критичної інфраструктури цього виявляється недостатнім.

Важливо зазначити, що вага коефіцієнту  $w_1$  є домінуючою ( $w_1 \gg w_2, w_3, w_4$ ); це гарантує, що пріоритет виживання критичного обладнання завжди переважає над усіма іншими цілями (комфорт, експлуатаційні витрати) [1]. Це є математичним втіленням принципів Beneficence (сприяння благу пацієнта) та Non-Maleficence (незаподіяння шкоди) в етичних рамках застосування AI у медицині.

Стандартний DRL (наприклад, DQN) є алгоритмом максимізації винагороди і не дає математичних гарантій, що агент не потрапить у небезпечні стани під час фази дослідження (exploration) або експлуатації (exploitation) [8, 26]. У медичних застосунках, де порушення  $SoC_{min}$ , або повне відключення  $D_{crit}$  є неприпустимими, необхідно перейти до парадигми Constrained Reinforcement Learning (C-DRL) [13].

Задача розроблення DRL з урахуванням обмежень може бути подана як процедура оптимізації за принципом Лагранжа, а саме максимізації очікуваної винагороди за умови, що очікувана сумарна вартість не перевищує допустимого порогу  $\alpha$ :

$$\max_{\pi} E_{\pi} \left( \sum_{t=0}^{\infty} \gamma^t R(s_t, a_t) \right) \text{ subject to } E_{\pi} \left( \sum_{t=0}^{\infty} \gamma^t C(s_t, a_t) \right) \leq \alpha$$

Тут  $C(s_t, a_t)$  – функція вартості, що набуває значення 1, якщо порушується будь-яке жорстке обмеження (наприклад,  $SoC < 30\%$ ), і 0 в іншому випадку [19].

Використання таких алгоритмів, як Constrained Policy Optimization (CPO) [8, 27], є фундаментальним для безпечного розгортання системи управління енергоресурсами медичного закладу. У CPO використано підхід траст-регіону (trust-region optimization), який забезпечує гарантії near-constraint satisfaction на

кожній ітерації навчання. Альтернативним підходом є інтеграція шару безпеки (Safety Layer) поверх політики агента, як у DistFlow safe reinforcement learning (DF-SRL), який калібрує небезпечні дії до безпечних доменів, використовуючи квадратичне програмування [9]. Це гарантує, що навіть у реальному часі агенту буде заборонено виконувати дії, які призведуть до фізичного пошкодження обладнання або знеструмлення  $D_{crit}$ .

Для апроксимації оптимальної функції  $Q^*(s, a)$ , яка визначає очікувану дисконтовану сумарну винагороду при виборі дії  $a$  у стані  $s$ , використано алгоритм Deep Q-Network (DQN) [1].

$$Q(s, a; \theta) \approx E$$

$Q$ -функція апроксимується глибокою нейронною мережею (DNN) з ваговими параметрами  $\theta$ . Вона отримує на вхід вектор стану  $s_t$  (7-10 параметрів) і видає  $Q$ -значення для всіх можливих дискретних дій  $a \in A$  [1].

Для вирішення проблеми кореляції між послідовними станами системи управління енергоресурсами медичного закладу, що часто призводить до нестабільності в DRL, застосовано механізм Experience Replay Buffer [1]. Цей буфер зберігає кортежі перехідних станів системи  $\langle s_t, a_t, r_t, s_{t+1} \rangle$  і дозволяє агенту навчатися на випадкових вибірках з історії. Це є особливо критичним для рідкісних, але важливих подій, таких як блекаути, забезпечуючи накопичення агентом достатньої кількості прецедентів для ефективного управління енергетичними ресурсами в екстремальних режимах. Оскільки натурні випробування на діючих об'єктах критичної інфраструктури несуть неприпустимі ризики для пацієнтів медичного закладу, валідація моделі була проведена методом комп'ютерного моделювання [1].

Симуляційне середовище HospitalEnergyEnv реалізовано на мові Python з використанням бібліотек, сумісних зі стандартом OpenAI Gym [1, 28, 29]. Вибір цього фреймворку є загальноприйнятим для досліджень DRL у мікромережах, що підтверджується розробкою аналогічних інструментів, таких як OpenModelica Microgrid Gym (OMG) [30, 28]. Ключові параметри симуляції: Вхідні параметри базувалися на реальних профілях навантаження типового хірургічного корпусу районної лікарні [1].

Для демонстрації адаптивної переваги DRL-агента було проведено порівняльний аналіз із двома поширеними традиційними підходами в BEMS [1] - Rule-Based (RB) Algorithm - детермінованим алгоритмом, що використовує жорсткі порогові значення (наприклад "Якщо  $SoC < 30\%$ , відключити вентиляцію"), та з Greedy Algorithm. Було встановлено, що RB Algorithm є реактивним і не здатний до прогностичного планування, в той час Greedy Algorithm формує стратегію задоволення максимального поточного попиту на електроенергію у кожен момент часу, повністю ігноруючи при цьому прогноз майбутнього дефіциту ресурсів.

Для визначення ефективності цих алгоритмів у ході дослідження було застосовано сценарій "Blackout-48", згідно з яким імітувалось раптове повне відключення зовнішньої електромережі тривалістю 48 годин. Цей період був обраний спеціально, оскільки він перевищує гарантований ресурс палива для дизель-генератора (24 години). Це змушує будь-який ефективний алгоритм управління не просто реагувати, а розробити довгострокову стратегію економії палива та заряду акумуляторів, починаючи з перших годин блекауту.

Таблиця 2

## Ключові параметри та характеристики симуляційного середовища

Компонент/ Параметр	Номінальне Значення	Характеристика та обмеження
Дизель-Генератор (ДГ)	$P_{nom} = 100$ кВт	Обмежений запас палива на 24 години безперервної роботи. Затримка запуску: 15 секунд (NFPA 110 Level 1 Type)
Система Накопичення (BESS)	$E = 200$ кВт · год	Виконує роль буфера. Жорстке обмеження мінімального заряду: $SoC_{min} = 30\%$ .
Критичне Навантаження ( $D_{crit}$ )	Змінне	Обладнання життєзабезпечення. Вищий пріоритет ( $w_1$ ).
Гнучке Навантаження ( $D_{flex}$ )	Змінне	Вентиляція, освітлення коридорів. Допустиме скидання навантаження.
Зовнішня Мережа	$P_{ext}$	Моделюється як нестабільне джерело з імовірністю відмови $P_{fail}$ .

## 4. Експериментальна перевірка результатів дослідження

Валідацію запропонованої моделі проведено методом комп'ютерного моделювання, оскільки натурні випробування на діючих об'єктах критичної інфраструктури пов'язані з неприпустимими ризиками для пацієнтів та обладнання.

Для моделювання динаміки функціонування енергосистеми медичного закладу розроблено спеціалізоване середовище HospitalEnergyEnv, реалізоване на мові Python, із використанням бібліотек OpenAI Gym для навчання агента та PyTorch для побудови нейронних мереж. Вхідні параметри симуляції базувалися на реальних профілях навантаження хірургічного корпусу типової районної лікарні. Характеристики енергосистеми були визначені так: джерела живлення - зовнішня електромережа (моделюється як нестабільне джерело з імовірністю відмови  $P_{fail}$ ); дизель-генератор номінальною потужністю 100 кВт (із затримкою запуску 15 секунд та обмеженим запасом палива на 24 години безперервної роботи); система накопичення енергії (BESS) ємністю 200 кВт·год, що виконує роль буфера. Було здійснено також класифікацію споживачів електроенергії наступним чином: *Критичні (Critical Load)* - апарати штучної вентиляції легень (ШВЛ), монітори пацієнта, безтіньові лампи операційних (для цієї групи встановлено пріоритет найвищого рівня ( $w_1$ ), їх відключення вважається неприпустимим), та *Гнучкі (Flexible Load)* - системи припливно-витяжної вентиляції загальних зон, освітлення коридорів, зарядні станції персоналу (для цієї групи є допустимим зниження потужності або тимчасове відключення (Load

Shedding)).

Результати чисельного експерименту продемонстрували суттєву перевагу запропонованого адаптивного підходу над традиційними методами, для цього було використано показник виживання (Survival Rate). Згідно даного показника, при керуванні на основі Greedy Algorithm ресурси системи (паливо та заряд акумуляторів) було вичерпано вже на 32-й годині експерименту. Це призвело до аварійного знеструмлення критичного обладнання в реанімаційному відділенні, що в реальних умовах означало б загрозу життю пацієнтів. Використання Rule-Based Algorithm надало змогу підтримувати роботу системи до 41-ї години, після чого також стався колапс через вичерпання ресурсів. Управління енергоресурсами хірургічного відділення з використанням агента DQN-Agent забезпечило 100% працездатності критичного обладнання протягом усього 48-годинного періоду. Аналіз дій агента показав, що він завчасно (починаючи з 12-ї години блекауту) перейшов у режим "глибокої економії", суттєво знизивши при цьому енергоспоживання гнучкого обладнання, оскільки спрогнозував неможливість покриття дефіциту в майбутньому.

Стабільність роботи обладнання є важливим технічним показником, оскільки кількість циклів увімкнення/вимкнення дизель-генератора, часті запуски призводять до прискореного зносу стартерів та механічних частин. Завдяки введенню штрафу ( $C_{switch}$ ) у функцію винагороди, DQN-агент здійснив на 24% менше циклів перемикання порівняно з алгоритмом Rule-Based. Це підтверджує здатність моделі враховувати не лише енергетичні, а й експлуатаційні обмеження обладнання.

## 5. Обговорення результатів дослідження

Ключовим показником ефективності моделі є час виживання критичного навантаження ( $T_{survival}$ ), що є прямою мірою стійкості системи. Результати моделювання за сценарієм "Blackout-48" продемонстрували наступне: при використанні Greedy Algorithm наявні енергетичні ресурси були вичерпані вже на 32-й годині. Оскільки цей алгоритм не враховував вичерпність ресурсів, він підтримував гнучке навантаження надто довго, що призвело до аварійного знеструмлення  $D_{crit}$  та колапсу системи енергоспоживання хірургічного відділення; Rule-Based Algorithm, завдяки простим пороговим правилам, забезпечив роботу системи до 41-ї години, однак також не зміг витримати повний 48-годинний період; DQN-Agent забезпечив 100% працездатність—критичного обладнання  $D_{crit}$  протягом усього 48-годинного періоду.

Суттєва перевага DQN-агента обумовлена його прогностичною здатністю, яка інтегрована у процес максимізації дисконтованої сумарної винагороди. Агент, використовуючи  $Q$ -функцію, прогнозує, що штраф  $w_1$  (за відключення  $D_{crit}$ ) у майбутньому стане нескінченно високим через вичерпання палива. Тому він формує стратегічне рішення про переведення системи вже на 12-й годині блекауту режим "глибокої економії", суттєво знизивши або повністю відключивши при цьому гнучке навантаження ( $D_{flex}$ ), тоді як використання Rule-Based алгоритму призвело до ситуацій, в яких рівень SoC або об'єм наявного палива дизель генератора досягав мінімально допустимого порогового значення. Ця здатність до довгострокового, антиципованого передбачення Load Shedding є фундаментальним доказом переваги адаптивного DRL над традиційними, статичними системами управління енергоресурсами.

Введення показника штрафу  $w_3 \cdot C_{switch}$  у функцію винагороди

продемонструвало прямий позитивний вплив на експлуатаційні характеристики системи. DQN-агент здійснив на 24% менше циклів увімкнення/вимкнення дизель-генератора порівняно з Rule-Based алгоритмом [1]. Це свідчить про те, що розроблена модель здатна враховувати не лише негайний баланс потужності, а й довгострокові фактори зносу обладнання, що значно підвищує загальну надійність резервної системи живлення.

Успішне підтримання життєзабезпечуючого обладнання (100%  $D_{crit}$ ) протягом усього 48-годинного кризового періоду є емпіричним підтвердженням ефективності етично-орієнтованої функції винагороди. Математичний пріоритет  $w_1$  дозволив агенту ефективно вирішувати етичні дилеми пріоритезації (наприклад, між вентиляцією загальних палат та підтримкою операційної) на користь принципу Non-Maleficence. Відсутність випадків аварійного знеструмлення критичного обладнання підтверджує, що модель є етично прийнятною для застосування у медичних закладах [29].

Розроблена модель децентралізованої архітектури Edge-Fog Computing продемонструвала свою актуальність для управління енергоресурсами медичних закладів в екстремальних режимах. Розподіл обчислювальної потужності в рамках даної технології дозволяє: забезпечення живучості, оскільки система продовжує функціонувати навіть за умови повної втрати зв'язку із зовнішньою мережею та хмарними сервісами; підвищення реактивності - використання TinyML на Edge-вузлах системи забезпечує миттєву, локальну детекцію аномалій, тоді як Fog Node виконує стратегічне, прогностичне планування; посилення конфіденційності внаслідок того, що обробка «сирих» даних на периферії мінімізує ризики, пов'язані з передачею закритої медичної інформації, що є одним із головних етичних викликів при використанні AI у сфері охорони здоров'я.

## Висновки

У роботі представлено вирішення актуальної науково-прикладної задачі, що полягає у забезпеченні енергетичної стійкості критичної інфраструктури медичних закладів в умовах екстремальної нестабільності, за рахунок розробки спеціальної моделі децентралізованої архітектури управління ресурсами.

Вперше для управління енергоресурсами медичного закладу в умовах блекауту запропоновано та обґрунтовано архітектуру Edge-Fog Computing, яка гарантує повну автономність функціонування системи та відмовостійкість, що є ключовою перевагою над традиційними централізованими хмарними рішеннями.

1. Сформульовано етично-орієнтовані аспекти впровадження моделі розподілу енергетичних ресурсів, як задачу адаптивної пріоритезації у вигляді марковського процесу, що надало змогу інтегрувати домінуючий ваговий коефіцієнт  $w_1$  у функцію винагороди. Це забезпечило математичне втілення безумовного пріоритету нормативних (NFPA 99) та етичних вимог щодо безумовного пріоритету при створенні систем життєзабезпечення над усіма іншими вимогами.

2. Методом чисельного моделювання доведено, що DRL-агент, навчений на основі пропонованої моделі, здатний забезпечити 100% функціональність критично важливого навантаження протягом 48 годин у сценарії повного енергетичного колапсу, значно перевершуючи Rule-Based та Greedy алгоритми. Здатність агента до прогностичної економії підтверджує його адаптивну природу.

Для подальшого розвитку та безпечного розгортання пропонованої моделі визначено децентралізовану архітектуру управління ресурсами наступні

напрямки досліджень:

1. Інтеграція Safe Reinforcement Learning (SRL), для чого необхідно реалізувати перехід від використання показника величини штрафу  $w_4$  до повної інтеграції алгоритмів Constrained Policy Optimization (CPO) або DistFlow Safe RL [9, 27]. Це дозволить забезпечити абсолютні гарантії дотримання жорстких фізичних обмежень (наприклад,  $SoC_{min}$ ), що є обов'язковою умовою для сертифікації та впровадження у критичну медичну інфраструктуру.

2. В умовах, коли DRL-агент формує рішення про Load Shedding, які можуть впливати на комфорт або навіть некритичні медичні процеси, ці рішення мають бути прозорими та зрозумілими для операторів, що може бути досягнуто шляхом використання пояснюваного штучного інтелекту (Explainable AI, XAI). Подальші дослідження повинні включати впровадження методів інтерпретованого RL або використання Reward Machines для явного кодування та пояснення часових властивостей політики [26, 24, 1].

3. Масштабування до Multi-Agent DRL (MARL): Подальше масштабування отриманих рішень на великі госпітальні комплекси вимагатиме переходу до багатоагентної архітектури. У такій системі кожен підрозділ (операційна, реанімація, діагностичний центр) може мати свій локальний DRL-агент, що управляє своїми ресурсами та координує дії з Fog Node для оптимізації загального енергетичного балансу системи. Це підвищить стійкість та ефективність управління на великих об'єктах.

## References

1. Saleem A. A., Hassan M. M., Ali I. A. "Smart Homes Powered by Machine Learning: A Review." 2022 IEEE International Conference on Computer Science and Software Engineering (CSASE), 2022, pp. 355–361. DOI: 10.1109/CSASE51777.2022.9759682; Link: IEEE Xplore.
2. El Hussein F., Noura H. N., Salman O., Chahine K. "Machine Learning in Smart Buildings: A Review of Methods, Challenges, and Future Trends." Applied Sciences, 2025, 15(14): 7682. DOI: 10.3390/app15147682; Link: MDPI (Appl. Sci.).
3. Chakraborty A., Islam M., Shahriyar F., Islam S., Zaman H. U., Hasan M. "Smart Home System: A Comprehensive Review." Journal of Electrical and Computer Engineering, 2023, 2023: 1–30. DOI: 10.1155/2023/7616683; Link: Hindawi/Wiley.
4. Latoń D., Grela J., Ożadowicz A. "Applications of Deep Reinforcement Learning for Home Energy Management Systems: A Review." Energies, 2024, 17(24): 6420. DOI: 10.3390/en17246420; Link: MDPI (Energies).
5. Sikandar H. S., Waheed H., Tahir S., Malik S. U. R., Rafique W. "A Detailed Survey on Federated Learning Attacks and Defenses." Electronics, 2023, 12(2): 260. DOI: 10.3390/electronics12020260; Link: MDPI (Electronics).
6. Thakur P., Goel S., Puthooran E. "Edge AI Enabled IoT Framework for Secure Smart Home Infrastructure." Procedia Computer Science, 2024, 235: 3369–3378. DOI: 10.1016/j.procs.2024.04.317; Link: ScienceDirect.
7. Reis M. J. C. S., Serôdio C. "Edge AI for Real-Time Anomaly Detection in Smart Homes." Future Internet, 2025, 17(4): 179. DOI: 10.3390/fi17040179; Link: MDPI (Future Internet).
8. Khan L. U. et al. "Recent Advancements in Federated Learning: State of the Art, Fundamentals, Principles, IoT Applications and Future Trends." (Published in Future Internet 2024, 16(11): 415.) DOI: 10.3390/fi16110415; Link: MDPI (Future Internet).

9. Kushnarov M. O., Averin Y. S., Shostak I. V. "Gibridna model adaptivnoyi prioritezaciyi energetichnih resursiv medichnogo zakladu v umovah kritichnogo deficitu" (Hybrid Model of Adaptive Prioritization of a Medical Facility's Energy Resources under Critical Deficit). KhAI (National Aerospace University), 2024. DOI: 10.32620/oikit.2025.105.19; Link: [KhAI](#).

10. Jin M. et al. "An Online Reinforcement Learning-Based Energy Management Strategy for Microgrids With Centralized Control." IEEE Transactions on Industry Applications, 2025, 61(1): 1501–1510. DOI: 10.1109/TIA.2024.3430264; Link: IEEE Xplore.

11. Mottahedi S. Reinforcement Learning Safe Reinforcement Learning Energy Management Systems Constrained Differentiable Cross-Entropy Method. Ph.D. Dissertation, Pennsylvania State University, 2022. DOI: N/A; Link: Penn State ETD.

12. Gholami A., Shekari T., Grijalva S. "Proactive Management of Microgrids for Resiliency Enhancement: An Adaptive Robust Approach." IEEE Transactions on Sustainable Energy, 2019, 10(1): 470–480. DOI: 10.1109/TSTE.2017.2740433; Link: IEEE Xplore.

13. Nuno Silva. "MQTT vs. CoAP for IoT in Edge/Mesh Networks." HiveMQ Blog, Oct. 18, 2022. Link: HiveMQ Blog.

14. Silva D., Carvalho L. I., Soares J., Sofia R. C. "A Performance Analysis of Internet of Things Networking Protocols: Evaluating MQTT, CoAP, OPC UA." Applied Sciences, 2021, 11(11): 4879. DOI: 10.3390/app11114879; Link: MDPI (Appl. Sci.).

15. Avsystem (Contributor). "TinyML: Intelligence in Small Packages – Ultra-low Power Consumption, Real-time Inference." IoT For All (Blog), Last Updated: Dec 2, 2024. Link: IoT For All.

16. Sugumar B. K. et al. "Empowering Resilient Hospital Microgrids in Gaza with a Novel Toolbox for Sustainable Energy Solutions." 2024 IEEE 24th International Conference on Environment and Electrical Engineering (EEEIC) & I&CPS Europe, 2024, pp. 1–6 (Paper no. 1187). DOI: 10.1109/EEEIC/ICPSEurope61470.2024.10751299; Link: IEEE Xplore.

17. Peterson C. J., Van Bossuyt D. L., Giachetti R. E., Oriti G. "A method to model, analyze, and design military microgrids with the objective to improve their resilience in the face of disconnections from the larger electrical grid." Systems (MDPI), 2021, 9(3): 69. DOI: 10.3390/systems9030069; Link: MDPI (Systems).

18. NFPA 110 – Standard for Emergency and Standby Power Systems (2022 Edition). National Fire Protection Association. (Covers performance requirements for emergency power in buildings based on system risk.) DOI: N/A; Link: NFPA Official Page.

19. HITRUST Alliance. "The Ethics of AI in Healthcare: Safety and Liability, Patient Privacy, Transparency and Accountability." (HITRUST AI Ethics content, summarized in Meditab Blog). DOI: N/A; Link: Meditab Blog (citing HITRUST).

20. Nuno Silva. "The Ethical and Social Implications of Using AI for Energy Management." Energy Central (Intelligent Utility), 2023. Link: Energy Central.

21. UPB-LEA Group. OpenModelica Microgrid Gym (OMG) Toolbox. GitHub Repository, 2020–2023. Link: GitHub – upb-lea/openmodelica-microgrid-gym.

22. Prism Sustainability Directory. "Fundamental Categories of Grid Resilience Metrics." Prism – Sustainability Directory (Scenario Term), 2025. Link: Prism Directory.

23. Achiam J., Held D., Tamar A., Abbeel P. "Constrained Policy Optimization (CPO)." Proceedings of ICML, 2017, pp. 22–31. DOI: N/A (preprint available). Link: ResearchGate.

24. Yuan X. (Jenny) et al. "Ethical Frameworks for Resource Allocation in Disaster Scenarios (AI4People framework)." *Safety (MDPI)*, 2023, 5(3): 21. DOI: 10.3390/safety5030021; Link: MDPI (Safety).

25. Zhao B. et al. "Deep Reinforcement Learning Microgrid Energy Scheduling Problem." *PubMed Central (NIH)*, 2022, PMC8950638. DOI: N/A; Link: PMC Article.

26. Zhao B. et al. "Conventionally, the state of a MDP represents the information or observation... (on MDP State Representation)." *Journal of Artificial Intelligence Research*, 2023. DOI: N/A; Link: arXiv preprint.

27. NFPA 99 – Health Care Facilities Code (2021 Edition). National Fire Protection Association. (Defines risk-based categories of health care facility systems based on patient/staff risk.) DOI: N/A; Link: NFPA 99 Overview.

28. Shengren H., Fu A., Salazar E. M., Palensky P., Chen Q., Vergara P. P. "DistFlow Safe Reinforcement Learning (DF-SRL) for Real-Time Voltage Magnitude Regulation in Distribution Networks." *IEEE PES Conference Paper / Journal of Modern Power Systems*, 2024 (to appear in Vol. 13, No. 1, pp. 300–311). DOI: 10.35833/MPCE.2024.000253; Link: TU Delft Repository.

Надійшла до редакції 10.12.2025, розглянута на редколегії 02.02.2026

## **Hybrid Model of Adaptive Prioritization of Energy Resources in a Medical Facility under Critical Deficit Conditions**

This paper addresses a scientific and applied problem of ensuring the energy resilience of critical medical infrastructure operating under conditions of extreme resource scarcity and instability of external power supply caused by deliberate destruction of the energy system. Unlike conventional Building Energy Management Systems (BEMS), which are primarily focused on economic efficiency in stable environments, the proposed approach shifts the focus toward maximizing the autonomous operation time of life-support equipment.

The methodological foundation of the study is the development of a hybrid decentralized model for adaptive energy resource prioritization implemented within an Edge–Fog Computing architecture. This architectural design ensures full system autonomy: TinyML models deployed at the Edge level provide real-time anomaly detection, while strategic decision-making is performed by a Deep Reinforcement Learning (DRL) agent at the Fog node level, without reliance on cloud services. This eliminates a critical single point of failure and significantly enhances data privacy.

The scientific novelty of the work lies in the introduction of an ethically oriented reward function for a Deep Q-Network (DQN) agent, which mathematically formalizes the prioritization of the bioethical principles of Beneficence and Non-Maleficence through the integration of risk categories defined by the NFPA 99 standard. The model employs a hard prioritization mechanism in which the unconditional supply of critical loads prevails over patient comfort and operational costs, while also accounting for physical system constraints, such as minimum battery charge levels, by incorporating elements of Constrained Reinforcement Learning.

The proposed model was validated in the simulation environment HospitalEnergyEnv using the "Blackout-48" scenario. Comparative simulation results demonstrated that the proposed DQN agent maintained 100% operational availability of critical medical equipment throughout 48 hours of autonomous operation by proactively switching to a deep energy-saving mode. In contrast, traditional Greedy

and Rule-Based algorithms depleted available resources at the 32nd and 41st hours, respectively, resulting in emergency power loss in the intensive care unit.

The practical significance of the obtained results lies in the development of a deployment-ready architecture for autonomous hospital energy systems capable of adaptively allocating limited resources during prolonged blackouts while ensuring patient safety in accordance with international standards.

**Key words:** medical facility, smart energy systems, reinforcement learning, adaptive control, life-support equipment, autonomous power supply, energy resilience, ethically grounded algorithms, deep learning, healthcare systems, critical load prioritization.

#### **Відомості про авторів:**

**Кушнар'ов Максим Олександрович** – аспірант, Національний аерокосмічний університет «ХАІ», м. Харків, Україна, [maksimkushnarov@gmail.com](mailto:maksimkushnarov@gmail.com), ORCID: 0009-0003-6322-1740

**Шостак Ігор Володимирович** – професор, доктор технічних наук, професор кафедри 603 «Інженерії програмного забезпечення», Національний аерокосмічний університет «ХАІ», м. Харків, Україна, [i.shostak@khai.edu](mailto:i.shostak@khai.edu), ORCID: 0000-0002-3051-0488

#### **About the authors:**

**Maksym KUSHNAROV** – PhD Student, National Aerospace University «KhAI», Kharkiv, Ukraine, [maksimkushnarov@gmail.com](mailto:maksimkushnarov@gmail.com), ORCID: 0009-0003-6322-1740

**Ihor SHOSTAK** – Professor, Doctor of Technical Sciences, Professor of the Department of Software Engineering, National Aerospace University "KhAI", Kharkiv, Ukraine, [i.shostak@khai.edu](mailto:i.shostak@khai.edu), ORCID: 0000-0002-3051-0488