



УДК 004.896

DOI: <https://doi.org/10.17721/AIT.2024.1.02>

Наталія АКСАК, д-р техн. наук, проф.

ORCID ID: 0000-0001-8372-8432

e-mail: [nataliia.axak@nure.ua](mailto:nataliia.axak@nure.ua)

Харківський національний університет радіоелектроніки, Харків, Україна

Максим КУШНАРЬОВ, канд. техн. наук

ORCID ID: 0000-0002-3772-3195

e-mail: [maksym.kushnarov@nure.ua](mailto:maksym.kushnarov@nure.ua)

Харківський національний університет радіоелектроніки, Харків, Україна

Юрій ШЕЛІХОВ, асп.

ORCID ID: 0009-0009-8970-6571

e-mail: [yurii.shelikhov@nure.ua](mailto:yurii.shelikhov@nure.ua)

Харківський національний університет радіоелектроніки, Харків, Україна

## ІНТЕЛЕКТУАЛЬНЕ КЕРУВАННЯ МІКРОКЛІМАТОМ СІТИ-ФЕРМИ НА ОСНОВІ АЛГОРИТМУ Q-LEARNING

**Вступ.** У контексті швидкого розвитку ситі-фермерства та зростання інтересу до сталого виробництва харчових продуктів, керування мікрокліматом стає ключовим аспектом для досягнення оптимального вирощування рослин. Оптиміальне керування температурою, вологістю та освітленням може допомогти використовувати обмежений простір ефективніше, збільшуючи врожайність на одиницю площі. Системи контролю клімату, які дозволяють створювати оптимальні умови для рослин, дозволяють збільшити виробництво на обмеженій площі. Метою дослідження є прийняття обґрунтованих рішень у системі контролю клімату, заснованою на алгоритмах підсиленого навчання, зокрема Q-learning, для підвищення продуктивності й ефективності вирощування мікрозелені в ситі-фермерстві.

**Методи.** Для прийняття обґрунтованих рішень у системі контролю клімату досліджено алгоритм навчання з підкріпленням (Q-learning), який складається з таких етапів: визначення різних кліматичних станів системи, вибір дії, яку слід виконати, на основі поточного стану системи й оцінки корисності, яку розраховують на основі рівняння Беллмана. Розроблено та реалізовано модель керування мікрокліматом, яка використовує алгоритм Q-learning для оптимізації параметрів клімату. Методика дослідження включала моделювання різних умов середовища, навчання моделі на основі зібраних даних та експериментального тестування в реальних умовах ситі-фермерства.

**Результати.** Експериментальне моделювання з використанням мови програмування Python із бібліотеками TensorFlow, PyTorch та scikit-learn, підтвердили ефективність застосування алгоритму Q-learning у системі контролю клімату для підвищення продуктивності й ефективності вирощування мікрозелені. Щоб переконатися, що система досягла бажаного стану, використовують такі стратегії, як моніторинг реальних значень параметрів за допомогою IoT-датчиків системи контролю клімату, аналіз отриманих значень Q-таблиці та встановлення критеріїв зупинки навчання. Результати роботи програми передають актуаторам через мережу передачі даних Wi-Fi за допомогою мікроконтролера ESP8266, який використовують як модуль Wi-Fi для мікроконтролера Arduino.

**Висновки.** Застосування системи контролю клімату з алгоритмом Q-learning у ситі-фермерстві сприяє досягненню більшої продуктивності, ефективності та стабільності вирощування рослин, що відображається на покращенні результатів вирощування рослин.

**Ключові слова:** розподілені системи, технології IoT, хмарні обчислення, Q-learning, моніторинг.

### Вступ

Ситі-фермерство, або міське землеробство, має значну актуальність у сучасному світі з огляду на кілька важливих факторів. За даними ООН, до 2050 р. більше 68 % світового населення мешкатиме в урбанізованих зонах. Урбаністичне фермерство здатне надати жителям міст доступ до свіжих продуктів, знижуючи потребу в імпорті з віддалених регіонів. Вирощування продуктів харчування на міських фермах може зменшити вуглецевий слід, пов'язаний із транспортуванням їжі на великі відстані. Це сприяє зменшенню емісій шкідливих газів і покращенню екологічної сталості.

У сучасному контексті ефективність ситі-фермерства значною мірою залежить від упровадження таких технологій, як розподілені системи, технології IoT (інтернет речей), хмарні обчислення та методи штучного інтелекту, як-от Q-learning. Розподілені системи дозволяють керувати різними аспектами міських ферм на віддалених платформах, забезпечуючи взаємодію між численними датчиками та пристроями. Це особливо корисно для автоматизованого моніторингу і контролю параметрів навколишнього середовища (напр., вологості або освітлення), що впливають на ріст рослин.

IoT-технології відіграють ключову роль у моніторингу й оптимізації міських ферм. Датчики можуть збирати інформацію про стан ґрунту, вологість, температуру й інші параметри в режимі реального часу, що дозволяє автоматично регулювати умови вирощування. Ці дані передаються до хмарних обчислювальних систем, де здійснюється їх оброблення для прийняття рішень і керування фермерськими процесами.

Застосування Q-learning дозволяє оптимізувати процеси керування міськими фермами за допомогою автоматичного навчання систем на основі попереднього досвіду та прогнозування найкращих умов для вирощування продуктів. Це знижує необхідність ручного втручання та підвищує ефективність процесів.

Розвиток ситі-фермерства створює нові можливості для підприємців і місцевих фермерів, забезпечуючи робочі місця та стимулюючи економічний розвиток у міських областях. Вирощування продуктів у міських умовах дозволяє контролювати умови вирощування, якість ґрунту, використання пестицидів та інших хімічних речовин, що може привести до покращення якості продуктів. Моніторинг за допомогою IoT допомагає відстежувати ці параметри та гарантувати стабільність вирощування.

Отже, для ефективного розроблення й експлуатації ситі-фермерських систем необхідно потрібно подолати не тільки звичні труднощі, такі як обмежений простір чи фінансування, але й упровадити сучасні технологічні рішення, зокрема розподілені системи, IoT, хмарні обчислення й алгоритми машинного навчання для моніторингу й оптимізації процесів.

© Аксак Наталія, Кушнар'єв Максим, Шеліхов Юрій, 2024



**Постановка проблеми** розроблення й експлуатації сіті-фермерства полягає у забезпеченні оптимального керування температурою та вологістю, що може допомогти ефективніше використовувати обмежений простір, збільшуючи врожайність на одиницю площі. Системи контролю клімату, які дозволяють створювати оптимальні умови для рослин, забезпечують збільшення виробництва в умовах обмеженого простору.

Упровадження передових технологій контролю клімату потребує розроблення та створення відповідної інфраструктури для їхньої ефективної роботи. Нові технології контролю клімату можуть вимагати підтримки й інтеграції з існуючими системами керування сіті-фермерства.

**Мета дослідження** – прийняття обґрунтованих рішень у системі контролю клімату, заснованою на алгоритмах підсиленого навчання, зокрема і Q-learning, для підвищення продуктивності й ефективності вирощування мікрозелені в сіті-фермерстві.

**Завдання дослідження:**

- розробити модель для керування параметрами мікроклімату (температура, вологість, освітлення) на основі алгоритмів підсиленого навчання;
- реалізувати алгоритм Q-learning для автоматизації керування кліматом у сіті-фермі;
- провести експериментальну перевірку ефективності запропонованої системи на основі реальних даних щодо росту мікрозелені;
- оцінити вплив оптимізованого керування мікрокліматом на врожайність та ефективність використання простору.

**Об'єктом дослідження** є процеси контролю мікроклімату в системах сіті-фермерства, зокрема і керування температурою та вологістю в умовах обмеженого простору, з метою підвищення ефективності виробництва мікрозелені через застосування інтелектуальних алгоритмів, таких як Q-learning.

Наукова цінність дослідження полягає в інтеграції алгоритмів підсиленого навчання, таких як Q-learning, у системи контролю мікроклімату, що дозволяє динамічне адаптувати параметри навколишнього середовища для оптимального росту мікрозелені. Використання Q-learning забезпечує можливість самонавчання системи на основі історичних даних і постійного вдосконалення моделей керування температурою, вологістю та освітленням. Такий підхід є новаторським у сфері автоматизації сіті-фермерства і дозволяє підвищити ефективність використання обмеженого простору та ресурсів.

**Огляд літератури.** Концепція мікрозелені є відносно новою і з'явилася в Сан-Франциско наприкінці 1980-х рр. Вирощування мікрозелені швидко набуває популярності, особливо в умовах міського середовища, завдяки обмеженій потребі у ресурсах і можливості вирощування протягом всього року (Enssle, 2020). Проте для оптимізації процесу вирощування мікрозелені критичним є використання передових технологій, зокрема й інтелектуальних і розподілених систем керування та моніторингу (Zhou, 2020), (Ngo, Le-Khac, & Kechadi, 2018).

Міські ферми, які застосовують IoT, дозволяють здійснювати моніторинг параметрів мікроклімату в реальному часі, використовуючи датчики, що збирають інформацію про температуру, вологість, освітлення та інші важливі показники (Lodge, 2019). Дані, отримані з цих сенсорів, обробляються хмарними обчислювальними системами (Ashokkumar, Chowdary, & Sree, 2019) та за допомогою машинного навчання (Ashcraft, & Karra, 2021), що дозволяє вчасно виявляти відхилення та вносити корективи в умови вирощування.

Інтелектуальні алгоритми, такі як Q-learning, можна використовувати для аналізу та прогнозування параметрів клімату, що сприятиме максимальній ефективності використання ресурсів (Ali et al., 2024). Крім того, впровадження автоматизованих систем керування з використанням роботів підвищить точність і швидкість реагування на зміни в умовах виробництва, зменшивши людський фактор і ризики помилок (Chougule, & Mashalkar, 2022).

Для оптимізації теплових умов також використовують теплові моделі та програмне забезпечення для моделювання клімату в теплицях, що сприяє підвищенню врожайності та якості продукції (Choab et al., 2019). Системи на основі штучного інтелекту здатні обробляти великі обсяги даних і передбачати зміни в умовах, що дозволяють забезпечити стабільність виробництва (Alibabaei, Gaspar, & Lima, 2021). Отже, розроблення та експлуатація сіті-фермерського підприємства, яке використовує передові системи контролю клімату, дозволить оптимізувати та стабілізувати виробництво, підвищить економічну ефективність і збереже ресурси.

Хоча системи контролю клімату мають багато переваг, їхнє використання також може супроводжуватися деякими недоліками, багато з них можуть бути подолані завдяки використанню сучасних інтелектуальних технологій:

- встановлення сенсорів та пристроїв IoT у різних ділянках сіті-фермерського господарства дозволяє моніторити параметри клімату та керувати ними в реальному часі (Axak et al., 2020). Це допоможе швидко виявляти проблеми та реагувати на них, зменшуючи ризики витрат і втрат врожаю (Axak, Korablyov, & Ushakov, 2020);
- системи на основі штучного інтелекту можуть аналізувати великі обсяги даних із сенсорів і прогнозувати оптимальні параметри клімату для підтримки росту рослин. Це допоможе оптимізувати використання ресурсів і забезпечувати стабільність виробництва;
- використання автоматизованих систем і роботів для налагодження та керування системами контролю клімату може підвищити ефективність і точність процесів, зменшуючи залежність від людського фактора та ризики помилок;
- технологія блокчейн може використовуватися для створення децентралізованих систем керування даними про параметри клімату та виробництва, що забезпечує надійність і прозорість обміну інформацією між усіма учасниками системи.

Цей огляд показав, що застосування сучасних IT-технологій у системах контролю клімату може забезпечити ефективне сільське господарство, зменшити втрати та покращити якість продукції.

Отже, сучасні технології інтелектуальних і розподілених систем, IoT та хмарні обчислення відіграють ключову роль у покращенні процесів керування міським фермерством, що забезпечує ефективне використання ресурсів і стабільне виробництво.

**Методи**

Мікрозелень вирощується з використанням різних матеріалів і може вироблятися в різних середовищах. Основні матеріали, задіяні у вирощуванні мікрозелені, містять насіння, середовище для вирощування, світло, воду та лотки. Кожен сорт мікрозелені має різну тривалість циклу росту. Мікрозелень можна вирощувати за природного або штучного освітлення. Ідеальна температура мікрозелені залежить від сорту, але зазвичай мікрозелень можна вирощувати за



температури 24 °С. Потік повітря важливий, щоб запобігти накопиченню вологи та появі цвілі на мікрозелені. Вентилятор сприяє циркуляції повітря навколо мікрозеленої зони. Коріння мікрозелені та середовище для вирощування варто підтримувати у вологому стані, щоб максимізувати проростання насіння.

Вирощування мікрозелені відбувається у закритому приміщенні, де контроль за кліматом є ключовим фактором. Пропонована комп'ютеризована система контролю клімату дозволяє керувати критичними параметрами середовища вирощування, такими як температура, вологість, освітлення та циркуляція повітря, що є ключовими факторами для стабільного росту мікрозелені в закритих приміщеннях. Ця система базується на застосуванні датчиків для моніторингу параметрів клімату та використовує математичні моделі, які визначають оптимальні значення мікроклімату.

Комп'ютеризована система контролю клімату використовує алгоритми для автоматизованого регулювання параметрів, таких як температура та вологість, забезпечуючи їх оптимальність для рослин на різних етапах росту. Наприклад, система може автоматично налаштовувати потужність обігрівачів або кондиціонерів для підтримання температури на рівні 24 °С, а також контролювати вологість і циркуляцію повітря, щоб запобігти розвитку плісняви. Крім цього, систему оснащено блоком штучного освітлення, яке працює в тандемі з датчиками освітленості для забезпечення стабільного росту рослин, навіть в умовах нестачі природного світла. Усі дані з датчиків аналізуються за допомогою алгоритмів машинного навчання, що дозволяє оптимізувати роботу системи й адаптувати її до змінних умов середовища.

Завдяки впровадженню таких технологій, система зменшує ризики, пов'язані з неефективним використанням ресурсів і забезпечує стабільний рівень продуктивності сіті-ферм, максимізуючи врожайність на одиницю площі. Структуру комп'ютеризованої системи контролю клімату для сіті-фермерства наведено на рис. 1.

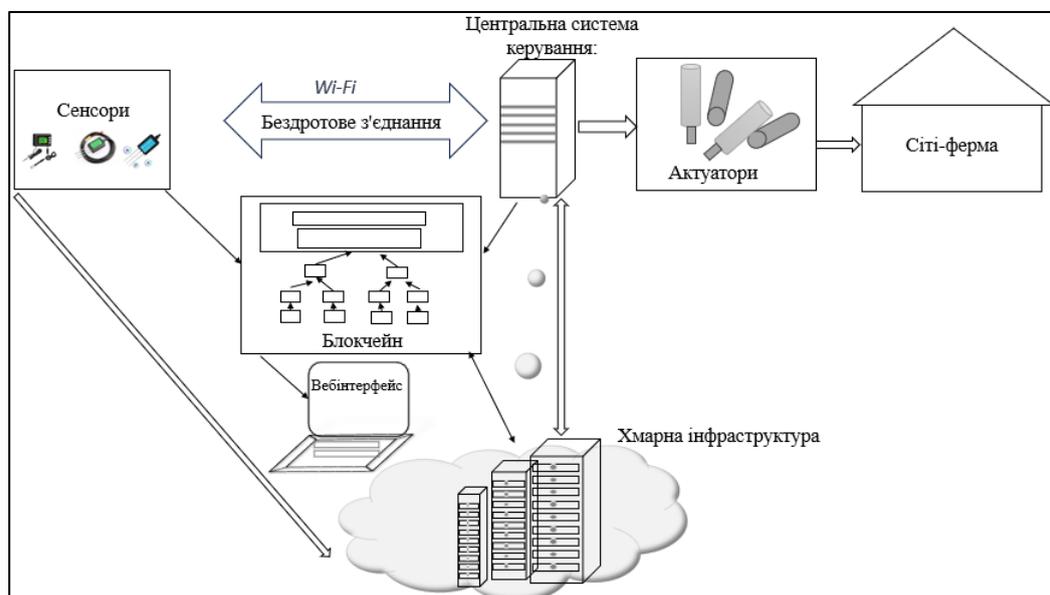


Рис. 1. Структура комп'ютеризованої системи контролю клімату для сіті-фермерства

Сенсори надсилають дані про параметри клімату (температура, вологість, освітленість тощо) до центральної системи через бездротове з'єднання: Wi-Fi або Bluetooth. Дані, що надходять від сенсорів про параметри клімату, можуть бути записані у блокчейн. Блокчейн використовують у системі для забезпечення надійного зберігання даних про параметри клімату, що надходять від сенсорів, та результатів управлінських дій. Однією з основних причин використання блокчейну є гарантія цілісності й автентичності інформації, яка важлива для точного моніторингу умов вирощування та прийняття правильних рішень. У розподіленому реєстрі блокчейну всі записи незмінні, що робить систему стійкою до зловживань або маніпуляцій даними. Це особливо актуально для гарантування того, що всі зміни в параметрах мікроклімату є прозорими і користувачі можуть довіряти інформації, яку вони отримують. Крім того, блокчейн дозволяє створювати автоматизовані процеси через смарт-контракти. Наприклад, як тільки певні кліматичні показники досягають визначених значень, система може автоматично активувати відповідні дії (вмикати обігрів або зрошення), що забезпечує ефективність і швидкість реагування. Використання блокчейну також спрощує аудит даних про виробництво, оскільки всі операції фіксуються у відкритому, але захищеному середовищі, доступному для перевірки. Блокчейн у цій системі не лише підвищує рівень безпеки та прозорості, а й дозволяє автоматизувати процеси керування на основі достовірних даних.

Центральна система отримує дані від сенсорів та аналізує їх, використовуючи алгоритми машинного навчання для прийняття рішень. Вона передає команди до актуаторів на основі аналізу даних, що включають керування системами обігріву, кондиціонування повітря, поливу й освітлення.

Актuatorи приймають команди від центральної системи й автоматично регулюють параметри клімату відповідно до заданих значень. Наприклад, актуатори можуть вмикати або вимикати системи обігріву, системи поливу або регулювати яскравість освітлення. Керування актуаторами й автоматизацією відбувається на основі даних, зафіксованих у блокчейні, що гарантує їхню незмінність і безпеку. Розумні контракти, наприклад, автоматично виконують дії, коли досягаються певні умови в кліматичних даних, записаних у блокчейні.

Хмарна інфраструктура забезпечує зберігання й оброблення великих обсягів даних, які надходять від сенсорів і центральної системи. Вона також може забезпечувати можливість резервного копіювання даних і надійність роботи системи.



Блокчейн-технологію використовують для забезпечення безпеки та цілісності даних, а також для створення децентралізованої системи керування даними про параметри клімату та виробництва. Інформація про статус виробництва, керування даними й інші важливі параметри захищені за допомогою технології блокчейн.

Користувачі можуть взаємодіяти із системою через мобільний додаток або вебінтерфейс, що дозволяє моніторити стан сіті-фермерства, керувати параметрами клімату й отримувати повідомлення про події та статус виробництва. Дані, що доступні для користувачів через мобільний додаток або вебінтерфейс, можуть бути підтверджені та перевірені за допомогою блокчейну. Це дозволяє забезпечити користувачам достовірність і цілісність інформації, яку вони отримують.

Для прийняття рішень у системі контролю клімату пропонується *алгоритм навчання з підкріпленням* (Q-learning), який складається з таких етапів.

**Етап 1.** Визначення різних станів системи – температури, вологості, освітлення тощо. Кожен стан представлено у вигляді вектора ознак.

**Етап 2.** Вибір дії, яку потрібно виконати, на основі поточного стану системи та оцінки корисності (Q-значення) кожної доступної дії:

<i>Поточний стан системи:</i>	<i>Температура в теплиці вища за оптимальне значення для вирощування рослин.</i>
<i>Доступні дії:</i>	<i>Дія 1. Збільшити час роботи люмінесцентних ламп для підвищення рівня освітлення.</i> <i>Дія 2. Зменшити використання системи обігріву або припинити його зовсім.</i> <i>Дія 3. Збільшити вологість у теплиці.</i>
<i>Оцінка корисності (Q-значення):</i>	<i>Q1 = 0,8 (для дії 1).</i> <i>Q2 = 0,5 (для дії 2).</i> <i>Q3 = 0,6 (для дії 3).</i>
<i>Вибір дії:</i>	<i>Обираємо дію з найвищим Q-значенням: дія 1 (збільшення часу роботи люмінесцентних ламп).</i>

Отже, система автоматично виконає дію 1, щоб знизити температуру в теплиці та забезпечити оптимальні умови для росту рослин.

**Етап 3.** Взаємодія із середовищем, щодо регулювання параметрів клімату згідно з обраною дією:

*Отримання поточних значень параметрів клімату (температура, вологість тощо).*  
*Аналіз поточного стану.*  
*Виконання обраної дії (напр., збільшення часу роботи вентиляційної системи).*  
*Моніторинг результатів.*  
*Прийняття подальших рішень.*

Процес взаємодії із середовищем для регулювання параметрів клімату повторюють періодично для підтримання оптимальних умов у теплиці.

**Етап 4.** Отримання нагороди, яка відображає, наскільки добре ця дія відповідає поточному стану системи. Система аналізує отримані дані після виконання дії, включаючи зміни параметрів клімату й ефективність керування. На основі результатів аналізу формується метрика  $kpi$ , що відображає ефективність виконаної дії, якщо ми, наприклад, хочемо оцінити, наскільки добре дія відповідає поточному стану системи (1). Наприклад, це може бути різниця між поточною температурою і оптимальною температурою, або кількість часу, протягом якого параметри клімату перебували в оптимальних межах.

$$kpi = (S_{opt} - S_{cur}) / S_{opt}, \quad (1)$$

де  $S_{opt}$  – оптимальний стан системи – це значення параметра клімату, яке вважається ідеальним для вирощування рослин (напр., оптимальна температура або вологість);  $S_{cur}$  – поточний стан системи – це фактичне значення параметра клімату після виконання дії.

Функція нагороди враховує базові параметри і визначає значення нагороди для кожної виконаної дії (2).

$$Q = w_1 p_1 + w_2 p_2 + \dots + w_n p_n, \quad (2)$$

де  $w_1, w_2, \dots, w_n$  – вагові коефіцієнти, які відображають важливість кожного параметра  $p_i$ , такого як ефективність дії, ступінь відповідності поточного стану системи до оптимального, або будь-які інші критерії, що характеризують успішність виконаної дії.

Після виконання дії в середовищі з'являється зворотний зв'язок у вигляді нагороди за цю дію. Ця нагорода може бути збережена або акумульована з попередніми нагородами. Наприклад, якщо намагатися максимізувати загальну нагороду протягом певного періоду часу, то може зберігатися поточна сума нагороди та додаватися до неї отримана нагорода за кожну дію.



Після отримання нагороди за виконану дію, оновлюється відповідне Q-значення в Q-таблиці. Цей процес оновлення здійснюється за допомогою формули оновлення Q-значень в алгоритмі Q-learning (3):

$$Q^{new}(s, a) = Q^{old}(s, a) + \alpha \cdot (r + \gamma \cdot \max_{a'} Q(s', a')), \quad (3)$$

де  $Q(s, a)$  – поточне значення Q-функції для стану  $s$  та дії  $a$ ;  $\alpha$  – коефіцієнт навчання (learning rate), який визначає, наскільки значущим є нова інформація (нагорода);  $r$  – нагорода, яку агент отримав за виконану дію;  $\gamma$  – дисконтний фактор (discount factor), який визначає, наскільки значущими є майбутні нагороди;  $s'$  – наступний стан, в який перейшов агент після виконання дії  $a$ ;  $a'$  – можлива дія в наступному стані  $s'$ .

Отримавши нагороду використовують для оновлення Q-значень, які потім застосовує агент для вибору наступної дії в майбутній взаємодії із середовищем. Цей процес дозволяє навчатися і вдосконалювати свої стратегії, щоб досягти максимальної нагороди в майбутньому.

**Етап 5.** Оновлення Q-значень для поточного стану й обраної дії, з використанням формули оновлення Q-значень (4):

$$Q^{new}(s, a) = (1 - \alpha) \cdot Q^{old}(s, a) + \alpha \cdot (r + \gamma \cdot \max_{a'} Q(s', a')). \quad (4)$$

**Етап 6.** Продовження навчання протягом багатьох ітерацій, з оновленням Q-значення на кожному кроці з метою максимізації загальної нагороди в майбутньому.

Цей процес навчання дозволяє системі контролю клімату вибирати оптимальні дії для забезпечення оптимальних умов для росту рослин у системі сіті-фермерства. Із часом система навчається оптимальних стратегій керування кліматом із метою максимізації врожаю або інших бажаних цілей.

### Результати

Для реалізації алгоритму навчання з підкріпленням (Q-learning) в системі контролю клімату використовують Python – це одна з найпопулярніших мов програмування для реалізації алгоритмів машинного навчання, включаючи Q-learning. У Python існують бібліотеки, такі як TensorFlow, PyTorch, scikit-learn, які містять реалізації Q-learning.

Створено клас QLearningAgent, який містить методи для вибору дії та оновлення таблиці Q-значень. Потім ми створюємо екземпляр цього агента й використовуємо його для вибору дій та оновлення Q-таблиці в кожній ітерації (рис. 2).

```

Q-Table:
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
[0. 0. 0.]
  
```

Рис. 2. Приклад вмісту Q-таблиці на етапі ініціалізації

Після кожного оновлення Q-таблиці, ми можемо бачити, як змінюються значення Q-функції для кожного стану та дії. Найбільше значення Q-функції для кожного стану вказує на те, яка дія найвигідніша. Високі значення Q-функції свідчать про перевагу певних дій у поточному стані системи, що сприяють досягненню оптимальних умов мікроклімату.

Наприклад, якщо поточний стан системи представлений вектором  $s_{cur} = [19, 70, 3500]$ , де зазначені відповідні значення температури, вологості й інтенсивності освітлення, то алгоритм Q-learning відреагує таким способом.

Оскільки вказана температура (19 °C) нижча за оптимальну, алгоритм Q-learning обирає дії, спрямовані на підвищення температури, коли поточний стан системи потребує підвищення цього параметра для досягнення оптимальних умов для росту рослин, наприклад, увімкнувши систему опалення в теплиці. Вологість, яка вказана у векторі стану (70 %), незначно перевищує оптимальну вологість (60 %). Однак ця різниця не є критичною, тому алгоритм може залишити вологість без змін або, залежно від його налаштувань, може виконати додаткові заходи для підтримки оптимального рівня вологості. Вказана інтенсивність освітлення (3500 люкс) нижча за оптимальний рівень (5000 люкс). Тому алгоритм може вирішити збільшити інтенсивність світла, увімкнувши більше світлодіодних ламп або збільшивши час їхньої роботи. Нульові значення в таблиці свідчать про те, що поки не здійснено жодну дію та не отримано нагороду.

Навчання алгоритму Q-learning відбувається за допомогою таких кроків.

1. Ініціалізація Q-таблиці нульовими значеннями.
2. Вибір дії на основі вивчених значень Q-таблиці.
3. Виконання дії у поточному стані та вибір нагороди на основі взаємодії із середовищем.
4. Оновлення Q-значень.
5. Повторення кожного кроку до досягнення критерію зупинки.
6. Експлуатація навченої стратегії.

Щоб прийняти рішення для вектора стану системи заданого як  $s_{cur} = [19, 70, 3500]$ , ми використовуємо навчену Q-таблицю, щоб визначити, яку дію вибрати. Спочатку порівнюємо поточний стан системи з оптимальним станом,



тобто  $s_{opt} = [24, 60, 5000]$ . Для кожного параметра визначаємо, чи потрібно збільшувати, зменшувати або залишати його незмінним, та визначаємо дію, яку потрібно вибрати на основі значень Q-таблиці. У Q-таблиці кожен стан подано рядком, а кожну дію – стовпцем. В цьому прикладі є три можливі дії (збільшення, зменшення та залишати без змін) для трьох параметрів (температура, вологість та інтенсивність освітлення), кожен елемент  $[i, j]$  представляє Q-значення для дії  $j$  у стані  $i$  (табл. 1).

Таблиця 1

**Q-таблиця для системи з трьома параметрами та трьома можливими діями для кожного параметра**

State	Action 1 (Decrease)	Action 2 (Unchanged)	Action 3 (Increase)
1 Low Temp, Low Humidity, Low Light	$Q_{11}$	$Q_{12}$	$Q_{13}$
2 Low Temp, Low Humidity, Unchanged Light	$Q_{21}$	$Q_{22}$	$Q_{23}$
3 Low Temp, Low Humidity, High Light	$Q_{31}$	$Q_{32}$	$Q_{33}$
4 Low Temp, Unchanged Humidity, Low Light	$Q_{41}$	$Q_{42}$	$Q_{43}$
5 Low Temp, Unchanged Humidity, Unchanged Light	$Q_{51}$	$Q_{52}$	$Q_{53}$
6 Low Temp, Unchanged Humidity, High Light	$Q_{61}$	$Q_{62}$	$Q_{63}$
7 Low Temp, High Humidity, Low Light	$Q_{71}$	$Q_{72}$	$Q_{73}$
8 Low Temp, High Humidity, Unchanged Light	$Q_{81}$	$Q_{82}$	$Q_{83}$
9 Low Temp, High Humidity, High Light	$Q_{91}$	$Q_{92}$	$Q_{93}$
10 Unchanged Temp, Low Humidity, Low Light	$Q_{10\ 1}$	$Q_{10\ 2}$	$Q_{10\ 3}$
11 Unchanged Temp, Low Humidity, Unchanged Light	$Q_{11\ 1}$	$Q_{11\ 2}$	$Q_{11\ 3}$
12 Unchanged Temp, Low Humidity, High Light	$Q_{12\ 1}$	$Q_{12\ 2}$	$Q_{12\ 3}$
13 Unchanged Temp, Unchanged Humidity, Low Light	$Q_{13\ 1}$	$Q_{13\ 2}$	$Q_{13\ 3}$
14 Unchanged Temp, Unchanged Humidity, Unchanged Light	$Q_{14\ 1}$	$Q_{14\ 2}$	$Q_{14\ 3}$
15 Unchanged Temp, Unchanged Humidity, High Light	$Q_{15\ 1}$	$Q_{15\ 2}$	$Q_{15\ 3}$
16 Unchanged Temp, High Humidity, Low Light	$Q_{16\ 1}$	$Q_{16\ 2}$	$Q_{16\ 3}$
17 Unchanged Temp, High Humidity, Unchanged Light	$Q_{17\ 1}$	$Q_{17\ 2}$	$Q_{17\ 3}$
18 Unchanged Temp, High Humidity, High Light	$Q_{18\ 1}$	$Q_{18\ 2}$	$Q_{18\ 3}$
19 High Temp, Low Humidity, Low Light	$Q_{19\ 1}$	$Q_{19\ 2}$	$Q_{19\ 3}$
20 High Temp, Low Humidity, Unchanged Light	$Q_{20\ 1}$	$Q_{20\ 2}$	$Q_{20\ 3}$
21 High Temp, Low Humidity, High Light	$Q_{21\ 1}$	$Q_{21\ 2}$	$Q_{21\ 3}$
22 High Temp, Unchanged Humidity, Low Light	$Q_{22\ 1}$	$Q_{22\ 2}$	$Q_{22\ 3}$
23 High Temp, Unchanged Humidity, Unchanged Light	$Q_{23\ 1}$	$Q_{23\ 2}$	$Q_{23\ 3}$
24 High Temp, Unchanged Humidity, High Light	$Q_{24\ 1}$	$Q_{24\ 2}$	$Q_{24\ 3}$
25 High Temp, High Humidity, Low Light	$Q_{25\ 1}$	$Q_{25\ 2}$	$Q_{25\ 3}$
26 High Temp, High Humidity, Unchanged Light	$Q_{26\ 1}$	$Q_{26\ 2}$	$Q_{26\ 3}$
27 High Temp, High Humidity, High Light	$Q_{27\ 1}$	$Q_{27\ 2}$	$Q_{27\ 3}$

Оцінити ефективність Q-алгоритму можна за допомогою середнього значення нагороди (Average Reward). Ця статистична метрика використовується для оцінювання продуктивності алгоритму Q-навчання і вимірює середню нагороду, отриману агентом під час взаємодії із середовищем протягом певного періоду часу або кількості епох. Середнє значення нагороди обчислюють як суму всіх отриманих нагород протягом епізодів, поділену на загальну кількість епізодів (5):

$$\text{Average Reward} = \frac{\sum_{i=1}^N R_i}{N}, \tag{5}$$

де  $R_i$  – нагорода, отримана в  $i$ -му епізоді, обчислюється як сума нагород за кожен крок у межах епізоду:  $R_i = \sum_{t=1}^T r_t$ , з кількістю кроків  $T$ ;  $N$  – загальна кількість епізодів.

Ця метрика дозволяє оцінити ефективність алгоритму. Якщо середнє значення нагороди збільшується із часом і наближається до максимально можливої нагороди в середовищі, це може свідчити про успішність навчання.

На рис. 3 показано результати, що представляють оновлені значення Q-таблиці після виконання алгоритму Q-learning для кількох можливих станів системи контролю клімату.

Кожен рядок таблиці відповідає певному стану системи, який визначається значеннями температури, вологості й інтенсивності освітлення. Наприклад, State [19, 70, 3500] вказує на температуру 19 °C, вологість 70 % та інтенсивність освітлення 3500 люкс.

Кожен стовпець у рядку відповідає можливій дії, яку можна виконати в даному стані. Значення у кожному стовпці вказує на очікувану користь (Q-значення) від вибору цієї дії у цьому стані. Чим більше значення Q, тим більшою вважають користь від цієї дії.



Вказані результати свідчать про те, які дії є найвигіднішими для кожного стану системи контролю клімату (рис. 4).

```
Updated Q-table:
State [19, 70, 3500]: [0.00400059 0.00022393 0.00139468]
State [19, 70, 5000]: [0.10177931 0.33295297 0.08988007]
State [19, 70, 6500]: [0.0039214 0.00111762 0.001602 ]
State [19, 71, 3500]: [0.00058998 0.00397421 0.00107031]
State [19, 71, 5000]: [0.32373891 0.07093993 0.03967545]
State [19, 71, 6500]: [0.00394546 0.0010813 0.00102636]
State [19, 72, 3500]: [0.00399532 0.00123542 0.00059964]
State [19, 72, 5000]: [0.30560804 0.06571434 0.04555891]
State [19, 72, 6500]: [0.00404674 0.00072275 0.00056592]
State [20, 70, 3500]: [0.00402911 0.00069436 0.00067158]
State [20, 70, 5000]: [0.36408993 0.08154069 0. ]
State [20, 70, 6500]: [0.00408011 0.00056451 0.00069816]
State [20, 71, 3500]: [0.00400059 0.00065257 0.00105252]
State [20, 71, 5000]: [0.33295297 0.10713358 0.07394444]
State [20, 71, 6500]: [0.0039214 0.00081124 0.00143449]
State [20, 72, 3500]: [0.00412466 0.00036807 0.00011707]
State [20, 72, 5000]: [0.31962577 0.07806135 0.04194357]
State [20, 72, 6500]: [0.00402381 0.00133344 0.00035919]
State [21, 70, 3500]: [0.0040828 0.00027964 0.00048318]
State [21, 70, 5000]: [0.38443995 0.06160556 0.04187721]
State [21, 70, 6500]: [0.00405741 0.00059012 0.00070884]
State [21, 71, 3500]: [0.0041301 0. 0.0006573]
State [21, 71, 5000]: [0.35953887 0.06642935 0.10167183]
State [21, 71, 6500]: [0.00400322 0.00099791 0.00068689]
State [21, 72, 3500]: [0.00389447 0.00192507 0.00078557]
State [21, 72, 5000]: [0.33738276 0.08290635 0.04949187]
State [21, 72, 6500]: [9.49334355e-05 4.07742346e-03 8.81331386e-04]
```

Рис. 3. Приклад вмісту Q-таблиці після виконання алгоритму Q-learning

```
Final Q-table:
[[0.00658762 0.00658762 0.00658762]
 [0.00658762 0.00658762 0.00658762]
 [0.00658762 0.00658762 0.00658762]]
```

Рис. 4. Оновлені значення Q-таблиці після завершення навчання

Результати в табл. 1 показують оновлені значення Q-таблиці під час навчання за допомогою Q-learning алгоритму. Для стану  $s_{cur} = [19, 70, 3500]$  значення Q-таблиці  $[0.00658762 \ 0.00658762 \ 0.00658762]$  показують корисність вибору кожної з трьох можливих дій. Тут значення Average Reward = 0.001976284584980403 визначає середнє значення нагороди, яке отримують за кожен епізод під час навчання алгоритму Q-learning. Це значення обчислюють як середнє арифметичне з усіх нагород за епізоди. У цьому випадку, вибіркова нагорода за кожен епізод обчислюється як обернена відстань між поточним станом системи й оптимальним станом  $[24, 60, 5000]$ , а потім підсумовується для кожного епізоду. На початку навчання, якщо середнє значення нагороди залишається низьким або стабільним, це може означати, що алгоритм не зміг навчитися ефективно пристосовуватися до середовища і потребує подальшого налагодження.

Щоб досягнути стабільного стану, де значення параметрів температури, вологості й інтенсивності освітлення набули оптимальних значень ( $s_{opt} = [24, 60, 5000]$ ), оцінюємо стабільність за допомогою функції `check_stable_state`, тобто порівнюємо значення параметрів стану моделі з оптимальними значеннями. Перевіряємо середнє значення Q-таблиці. Після того, як програма виконала 5000 епох навчання, був досягнутий стабільний стан і Average Reward набув значення більше 0,9, то вважаємо, що досягнуто бажаного стабільного стану, тобто значення параметрів досягли оптимальних значень, навчання зупиняється.

Ці значення оновлюють у процесі навчання з урахуванням отриманих нагород і максимального очікуваного Q-значення для наступного стану, що допомагає вибрати найоптимальнішу дію для кожного стану системи контролю клімату.

Щоб переконаватися, що система досягла бажаного стану, використовують кілька стратегій:

1. Моніторинг реальних значень параметрів. Якщо контрольовані параметри зближаються або залишаються в межах бажаних значень (напр., температура наближається до 24 °C, вологість до 60 %, інтенсивність світла до 5000 люкс), то це свідчить про досягнення стабільного стану.

2. Аналіз значень Q-таблиці. Після навчання моделі і вдосконалення Q-таблиці аналізують значення Q-функції для кожного можливого стану та дії. Якщо значення Q-функції для кожної дії в кожному стані наближається до максимального значення, то це свідчить про досягнення стабільного стану.

3. Встановлення критеріїв зупинки навчання. В програмі встановлено критерії зупинки навчання, коли значення Q-таблиці досягли певного діапазону або коли зміни параметрів системи вже не дуже великі. Коли ці критерії виконуються, навчання вважають завершеним, і систему можна вважати стабільною.

Після аналізу Q-таблиці можна виявити можливості для подальшого вдосконалення алгоритму. Наприклад, якщо деякі стани мають низькі значення Q-функції, може виникнути потреба у додатковому навчанні для виявлення оптимальних дій у цих станах.



Результати роботи програми передають актуаторам через мережу передачі даних Wi-Fi за допомогою мікроконтролера ESP8266, який використовують як Wi-Fi-модуль для мікроконтролера Arduino. Мікроконтролер ESP8266 налаштовується як вебсервер, який слухає запити на своїй локальній IP-адресі через порт 80. Arduino, що підключений до мережі Wi-Fi, відправляє GET-запит на IP-адресу ESP8266, отримує результати роботи програми з мікроконтролера ESP8266 і може виконати відповідні дії з актуаторами.

### Дискусія і висновки

1. *Вплив системи контролю клімату на вирощування рослин.* Метою реалізації системи контролю клімату ситі-ферми є максимізація загальної швидкості росту мікрозелені за допомогою прийняття обґрунтованих рішень щодо регулювання кліматичних факторів (температура, вологість, освітлення) (Nikolaou et al., 2019) та характеристиками врожаю (висота, колір, вміст вологи, площа листя). Оптимальна температура та день збирання мікрозелені для отримання максимального врожаю становить від 24 до 28 °C, а найкращий період їх збирання – це 6–13-й день, відносна вологість від 65 % до 75 % (Dhaka et al., 2023). Кількість світла і якість впливають на ріст і фізіологію рослин і взаємодіють з іншими параметрами навколишнього середовища й факторами культивування, визначаючи поведінку рослин. Світло не лише забезпечує енергію для фотосинтезу, але й регулює розвиток, формування та метаболізм рослин у складному явищі фотоморфогенезу, керованого світлом кольорів (Paradiso, & Proietti, 2022).

2. *Застосування алгоритмів прийняття рішень.* Q-learning є одним з алгоритмів із підсиленого навчання, який використовують для прийняття рішень в умовах невизначеності та змінюваних середовищ. У контексті системи контролю клімату для ситі-фермерства, Q-learning може бути використаний для розроблення оптимальної стратегії керування параметрами клімату, такими як температура, вологість, освітлення тощо, з метою максимізації врожаю або зниження споживання енергії. Також Q-learning застосовують для сприйняття навколишнього середовища для продовження терміну служби мереж моніторингу птахофабрик (Wu et al., 2021), для ефективного підвищення точності керування сільськогосподарським зрошенням (Zhou, 2020), для моделювання напівзакритої теплиці в Нью-Йорку, яка споживає на 61 % менше енергії (Ajagekar, & You, 2022). Використання Q-learning у системі контролю клімату для ситі-фермерства має кілька переваг порівняно з традиційними методами: а) Q-learning може адаптуватися до змін у середовищі, оскільки він навчається в реальному часі, використовуючи інформацію про винагороди, отримані після кожної дії. Це робить його ефективним для систем, які піддаються варіаціям у внутрішніх і зовнішніх умовах, що є типовим для ситі-фермерства; б) Q-learning спроможний знаходити оптимальні стратегії керування системою контролю клімату для максимізації врожаю або зменшення споживання енергії. Він може знаходити рішення, які підходять для конкретних обмежень і цілей, визначених фермером чи оператором системи; в) системи контролю клімату у ситі-фермерстві можуть бути дуже складними, з великою кількістю змінних і взаємодіючих параметрів. Алгоритм Q-learning може ефективно керувати такими складними системами, здатний до розв'язання задачі оптимізації навіть у складних і невизначених середовищах; г) Q-learning може бути ефективно використаний у системах різних розмірів. Він може пристосовуватися до різних масштабів виробництва, від невеликих ферм до великих агропромислових комплексів.

3. *Узагальнення результатів дослідження* показує, що використання системи контролю клімату з використанням алгоритму Q-learning дозволяє досягати більшої продуктивності й ефективності вирощування у ситі-фермерстві. Система контролю клімату забезпечує точне регулювання параметрів середовища, таких як температура, вологість та освітлення, що сприяє оптимальному росту рослин. Завдяки адаптивному навчанню та постійному вдосконаленню стратегій керування, система може ефективно використовувати енергію та воду, зменшуючи витрати на виробництво. Завдяки оптимізації умов середовища для росту рослин і зменшення стресу на них, система контролю клімату сприяє підвищенню врожайності та якості продукції. Алгоритм Q-learning дозволяє системі автоматично адаптуватися до змін у зовнішніх умовах, таких як зміни погоди або сезонні зміни, забезпечуючи стабільність і надійність у вирощуванні культур. За допомогою ефективного керування умовами вирощування, система допомагає знизувати втрати та ризики для фермерів.

Отже, використання системи контролю клімату з Q-learning у ситі-фермерстві сприяє досягненню більшої продуктивності, ефективності та стабільності вирощування рослин, що веде до покращення результатів господарювання та забезпечення сталого розвитку аграрного сектору.

**Внесок авторів:** Наталія Аксак – концептуалізація; Максим Кушнар'ов – програмне забезпечення; Юрій Шеліхов – збір емпіричних даних та їхня валідація, аналіз джерел, підготовка огляду літератури.

### Список використаних джерел

- Ajagekar, A., & You, F. (2022). Deep Reinforcement Learning Based Automatic Control in Semi-Closed Greenhouse Systems. In L. Ricardez-Sandoval, J. Pico, J. H. Lee, J. M. Lee (Eds.), *IFAC-PapersOnLine*, 55(7), 406–411. <https://doi.org/10.1016/j.ifacol.2022.07.477>
- Ali, N., Wahid, A., Shaw, R., & Mason, K. (2024). A Reinforcement Learning Approach to Dairy Farm Battery Management using Q Learning. In T. Dietterich, K. Apt, R. Boisvert (Eds.), *Journal of Energy Storage*, 93, 112031. <https://doi.org/10.48550/arXiv.2403.09499>
- Alibabaei, K., Gaspar, P. D., & Lima, T. M. (2021). Crop yield estimation using deep learning based on climate big data and irrigation scheduling. In José A. Afonso, R. Barbosa, A. Bielecki (Eds.), *Energies*, 14(11), 3004. <https://doi.org/10.3390/en14113004>
- Ashcraft, C., & Karra, K. (2021). Machine learning aided crop yield optimization. In T. Dietterich, K. Apt, R. Boisvert (Eds.), arXiv preprint arXiv:2111.00963. <https://doi.org/10.48550/arXiv.2111.00963>
- Ashokkumar, K., Chowdary, D. D., & Sree, C. D. (2019, October). Data analysis and prediction on cloud computing for enhancing productivity in agriculture. In *IOP Conference Series: Materials Science and Engineering* (Vol. 590, No. 1, p. 012014). IOP Publishing. doi 10.1088/1757-899X/590/1/012014
- Axak, N., Korablyov, M., Ushakov, M. (2020). Cloud Architecture for Remote Medical Monitoring. *IEEE Proceedings of the 15th International conference "Computer Sciences and Information Technologies" (CSIT-2020)*. 1 (pp. 344–347). Zbarazh-Lviv. <https://doi.org/10.1109/CSIT49958.2020.9321927>
- Axak N., Serdiuk N., Ushakov M., Korablyov M. (2020). Development of System for Monitoring and Forecasting of Employee Health on the Enterprise. In V. Lytvyn, V. Vysotska, T. Hamon, N. Grabar, N. Sharonova, O. Cherednichenko, O. Kanishcheva (Eds.), *Proceedings of the 4th International Conference on Computational Linguistics and Intelligent Systems* (COLINS 2020), April 23–24, I: Main Conference (pp. 979–992), Lviv. <https://ceur-ws.org/Vol-2604/paper65.pdf>
- Choab, N., Allouhi, A., El Maakoul, A., Kousksou, T., Saadeddine, S., & Jamil, A. (2019). Review on greenhouse microclimate and application: Design parameters, thermal modeling and simulation, climate controlling technologies. In R. Pitchumani, X. Xia (Eds.), *Solar Energy*, 191, 109–137. <https://doi.org/10.1016/j.solener.2019.08.042>
- Chougule, M. A., & Mashalkar, A. S. (2022). A comprehensive review of agriculture irrigation using artificial intelligence for crop production. In K. Kumar, G. Kakandikar, & J. Paulo Davim (Eds.), *Computational Intelligence in Manufacturing*, 187–200. <https://doi.org/10.1016/B978-0-323-91854-1.00002-9>



- Dhaka, A. S., Dikshit, H. K., Mishra, G. P., Tontang, M. T., Meena, N. L., Kumar, R. R., Ramesh, S. V., Narwal, S., Aski, M., Thimmegowda, V., Gupta S., Nair, & R. M., Praveen, S. (2023). Evaluation of Growth Conditions, Antioxidant Potential, and Sensory Attributes of Six Diverse Microgreens Species. In Rosario Paolo Mauro (Eds.), *Agriculture*, 13(3), 676. <https://doi.org/10.3390/agriculture13030676>
- Enssle, N. (2020). *Microgreens: Market Analysis, Growing Methods and Models*. In N. Enssle (Eds.). California State University San Marcos.
- Lodge, J. (2019). Controlled Environment Agriculture: using Intelligent Systems on the next level. In A. Muñoz, J. Park (Eds.), *Agriculture and Environment Perspectives in Intelligent Systems* (pp. 1–33). IOS Press. <https://doi.org/10.3233/AISE190002>
- Ngo, V. M., Le-Khac, N. A., & Kechadi, M. (2018). An efficient data warehouse for crop yield prediction. In T. Dietterich, K. Apt, R. Boisvert (Eds.), *arXiv preprint arXiv:1807.00035*. <https://doi.org/10.48550/arXiv.1807.00035>
- Nikolaou, G., Neocleous, D., Katsoulas, N., & Kittas, C. (2019). Irrigation of greenhouse crops. In A. Koukounaras (Eds.), *Horticulturae*, 5(1), 7. <https://doi.org/10.3390/horticulturae5010007>
- Paradiso, R., Proietti, S. (2022). Light-Quality Manipulation to Control Plant Growth and Photomorphogenesis in Greenhouse Horticulture: The State of the Art and the Opportunities of Modern LED Systems. In J. Ludwig-Müller (Eds.), *J. Plant Growth Regul.* 41, 742–780. <https://doi.org/10.1007/s00344-021-10337-y>
- Wu, Z., Pan, P., Liu, J., Shi, B., Yan, M., & Zhang, H. (2021). Environmental Perception Q-Learning to Prolong the Lifetime of Poultry Farm Monitoring Networks. In V. Varadarajan (Eds.), *Electronics*, 10(23), 3024. <https://doi.org/10.3390/electronics10233024>
- Zhou, N. (2020). Intelligent control of agricultural irrigation based on reinforcement learning. *Journal of Physics Conference Series*, 1601(5), 052031. IOP Publishing. <https://doi.org/10.1088/1742-6596/1601/5/052031>

#### References

- Ajagekar, A., & You, F. (2022). Deep Reinforcement Learning Based Automatic Control in Semi-Closed Greenhouse Systems. In L. Ricardez-Sandoval, J. Pico, J. H. Lee, J. M. Lee (Eds.), *IFAC-PapersOnLine*, 55(7), 406–411. <https://doi.org/10.1016/j.ifacol.2022.07.477>
- Ali, N., Wahid, A., Shaw, R., & Mason, K. (2024). A Reinforcement Learning Approach to Dairy Farm Battery Management using Q Learning. In T. Dietterich, K. Apt, R. Boisvert (Eds.), *Journal of Energy Storage*, 93, 112031. <https://doi.org/10.48550/arXiv.2403.09499>
- Alibabaei, K., Gaspar, P. D., & Lima, T. M. (2021). Crop yield estimation using deep learning based on climate big data and irrigation scheduling. In José A. Afonso, R. Barbosa, A. Bielecki (Eds.), *Energies*, 14(11), 3004. <https://doi.org/10.3390/en14113004>
- Ashcraft, C., & Karra, K. (2021). Machine learning aided crop yield optimization. In T. Dietterich, K. Apt, R. Boisvert (Eds.), *arXiv preprint arXiv:2111.00963*. <https://doi.org/10.48550/arXiv.2111.00963>
- Ashokkumar, K., Chowdary, D. D., & Sree, C. D. (2019, October). Data analysis and prediction on cloud computing for enhancing productivity in agriculture. In *IOP Conference Series: Materials Science and Engineering* (Vol. 590, No. 1, p. 012014). IOP Publishing. doi 10.1088/1757-899X/590/1/012014
- Axak, N., Korablyov, M., Ushakov, M. (2020). Cloud Architecture for Remote Medical Monitoring. *IEEE Proceedings of the 15th International conference "Computer Sciences and Information Technologies" (CSIT-2020)*. 1 (pp. 344–347). Zbarazh-Lviv. <https://doi.org/10.1109/CSIT49958.2020.9321927>
- Axak N., Serdiuk N., Ushakov M., Korablyov M. (2020). Development of System for Monitoring and Forecasting of Employee Health on the Enterprise. In V. Lytvyn, V. Vysotska, T. Hamon, N. Grabar, N. Sharonova, O. Cherednichenko, O. Kanishcheva (Eds.), *Proceedings of the 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2020)*, April 23–24, I: Main Conference (pp. 979–992), Lviv. <https://ceur-ws.org/Vol-2604/paper65.pdf>
- Choab, N., Allouhi, A., El Maakoul, A., Kousksou, T., Saadeddine, S., & Jamil, A. (2019). Review on greenhouse microclimate and application: Design parameters, thermal modeling and simulation, climate controlling technologies. In R. Pitchumani, X. Xia (Eds.), *Solar Energy*, 191, 109–137. <https://doi.org/10.1016/j.solener.2019.08.042>
- Chougule, M. A., & Mashalkar, A. S. (2022). A comprehensive review of agriculture irrigation using artificial intelligence for crop production. In K. Kumar, G. Kakandikar, & J. Paulo Davim (Eds.), *Computational Intelligence in Manufacturing*, 187–200. <https://doi.org/10.1016/B978-0-323-91854-1.00002-9>
- Dhaka, A. S., Dikshit, H. K., Mishra, G. P., Tontang, M. T., Meena, N. L., Kumar, R. R., Ramesh, S. V., Narwal, S., Aski, M., Thimmegowda, V., Gupta S., Nair, & R. M., Praveen, S. (2023). Evaluation of Growth Conditions, Antioxidant Potential, and Sensory Attributes of Six Diverse Microgreens Species. In Rosario Paolo Mauro (Eds.), *Agriculture*, 13(3), 676. <https://doi.org/10.3390/agriculture13030676>
- Enssle, N. (2020). *Microgreens: Market Analysis, Growing Methods and Models*. In N. Enssle (Eds.). California State University San Marcos.
- Lodge, J. (2019). Controlled Environment Agriculture: using Intelligent Systems on the next level. In A. Muñoz, J. Park (Eds.), *Agriculture and Environment Perspectives in Intelligent Systems* (pp. 1–33). IOS Press. <https://doi.org/10.3233/AISE190002>
- Ngo, V. M., Le-Khac, N. A., & Kechadi, M. (2018). An efficient data warehouse for crop yield prediction. In T. Dietterich, K. Apt, R. Boisvert (Eds.), *arXiv preprint arXiv:1807.00035*. <https://doi.org/10.48550/arXiv.1807.00035>
- Nikolaou, G., Neocleous, D., Katsoulas, N., & Kittas, C. (2019). Irrigation of greenhouse crops. In A. Koukounaras (Eds.), *Horticulturae*, 5(1), 7. <https://doi.org/10.3390/horticulturae5010007>
- Paradiso, R., Proietti, S. (2022). Light-Quality Manipulation to Control Plant Growth and Photomorphogenesis in Greenhouse Horticulture: The State of the Art and the Opportunities of Modern LED Systems. In J. Ludwig-Müller (Eds.), *J. Plant Growth Regul.* 41, 742–780. <https://doi.org/10.1007/s00344-021-10337-y>
- Wu, Z., Pan, P., Liu, J., Shi, B., Yan, M., & Zhang, H. (2021). Environmental Perception Q-Learning to Prolong the Lifetime of Poultry Farm Monitoring Networks. In V. Varadarajan (Eds.), *Electronics*, 10(23), 3024. <https://doi.org/10.3390/electronics10233024>
- Zhou, N. (2020). Intelligent control of agricultural irrigation based on reinforcement learning. *Journal of Physics Conference Series*, 1601(5), 052031. IOP Publishing. <https://doi.org/10.1088/1742-6596/1601/5/052031>

Отримано редакцією журналу / Received: 15.08.24  
 Прорецензовано / Revised: 24.09.24  
 Схвалено до друку / Accepted: 06.10.24



Natalia AXAK, DSc (Engin.), Prof.  
ORCID ID: 0000-0001-8372-8432  
e-mail: nataliia.axak@nure.ua  
Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

Maksym KUSHNARYOV, PhD (Engin.)  
ORCID ID: 0000-0002-3772-3195  
e-mail: maksym.kushnarov@nure.ua  
Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

Yurii SHELIKHOV, PhD Student  
ORCID ID: 0009-0009-8970-6571  
e-mail: yurii.shelikhov@nure.ua  
Kharkiv National University of Radio Electronics, Kharkiv, Ukraine

## THE INTELLIGENT CONTROL OF THE CITY-FARM MICROCLIMATE BASED ON THE Q-LEARNING ALGORITHM

**B a c k g r o u n d .** *In the context of the rapid development of urban farming and the growing interest in sustainable food production, microclimate management is becoming a key aspect to achieve optimal plant cultivation. Optimum management of temperature, humidity and light can help use limited space more efficiently, increasing yield per unit area. Climate control systems that allow you to create optimal conditions for plants allow you to increase production in a limited area. The purpose of the study is to make informed decisions in the climate control system based on reinforcement learning algorithms, in particular Q-learning, to increase the productivity and efficiency of growing microgreens in urban farming.*

**M e t h o d s .** *In order to make informed decisions in the climate control system, the article examines the Q-learning algorithm, which consists of such stages as determining different climatic states of the system; selecting the action to be performed based on the current state of the system and a utility estimate that is calculated based on the Bellman equation. A microclimate management model was developed and implemented, which uses the Q-learning algorithm to optimize climate parameters. The research methodology included simulation of various environmental conditions, model training based on collected data and experimental testing in real conditions of urban farming.*

**R e s u l t s .** *Experimental simulations using the Python programming language with TensorFlow, PyTorch and scikit-learn libraries confirmed the effectiveness of applying the Q-learning algorithm in the climate control system to increase the productivity and efficiency of growing microgreens. To ensure that the system has reached the desired state, strategies such as monitoring the actual parameter values using IoT sensors of the climate control system, analyzing the obtained Q-table values, and setting learning stopping criteria are used. The results of the program are transmitted to the actuators via the Wi-Fi data network using the ESP8266 microcontroller, which is used as a Wi-Fi module for the Arduino microcontroller.*

**C o n c l u s i o n s .** *The use of a climate control system with the Q-learning algorithm in urban farming contributes to the achievement of greater productivity, efficiency and stability of plant cultivation, which is reflected in the improvement of the results of plant cultivation.*

**K e y w o r d s :** *distributed systems, IoT technologies, cloud computing, Q-learning, monitoring.*

Автори заявляють про відсутність конфлікту інтересів. Спонсори не брали участі в розробленні дослідження; у зборі, аналізі чи інтерпретації даних; у написанні рукопису; в рішенні про публікацію результатів.

The authors declare no conflicts of interest. The funders had no role in the design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript; in the decision to publish the results.