

доступної площі (900 клітин) вдалося обстежити 896 клітин, водночас виявлено 103 критичні зони. Жоден із дронів не вийшов з ладу, що підтверджує стабільність реалізованої логіки кооперативної роботи.

Розроблена модель демонструє ефективність адаптивного сканування території в умовах обмеженого доступу та змінної обстановки. Впровадження A*-алгоритму дало змогу уникнути значної втрати покриття навіть у випадках із високою щільністю перешкод. Отримані результати підтверджують доцільність застосування моделі в задачах моніторингу, пошуку та рятування, а також як основи для подальшого вдосконалення інтелектуального управління мультиагентними системами.

Список використаних джерел

1. Kobori H., Sekiyama K. Mutual Cooperation System for Task Execution Between Ground Robots and Drones Using Behavior Tree-Based Action Planning and Dynamic Occupancy Grid Mapping. *Drones* 2025. Vol. 9(2), 95. DOI: 10.3390/drones9020095.
2. Яровий О. В. Системи управління безпілотними літальними апаратами для здійснення моніторингу наземних об'єктів. *Системи управління, навігації та зв'язку*. 2018. Вип. 3(49). DOI: 10.26906/SUNZ.2018.3.033.
3. Python 3.13.3 documentation. URL: <https://docs.python.org/3/>

УДК 004.4

*Байраківська В. В., здобувачка вищої освіти
2 курсу спеціальності 122 Комп'ютерні науки,
Потапова Н. А., канд. екон. наук, доцент,
доцент кафедри інформаційних технологій*

МЕТОДИ ОБЧИСЛЕНЬ У МАШИННОМУ НАВЧАННІ

Донецький національний університет імені Василя Стуса, м. Вінниця

Машинне навчання – це потужний інструмент аналізу даних, здатний виявляти закономірності, робити прогнози та приймати рішення на основі статистичних і обчислювальних методів. В основі роботи будь-якої моделі машинного навчання лежить обробка числової інформації, тож точність і ефективність обчислень мають вирішальне значення. Особливо важливими є класичні чисельні методи, що дають змогу аналізувати дані, будувати та навчати моделі, а також оцінювати їх точність [1; 2].

Початковим кроком у створенні моделі є оцінка точності її передбачень, яка базується на понятті похибки. У машинному навчанні похибка – це різниця між передбаченим і фактичним значенням. Похибки бувають різних типів: середньоквадратична похибка (MSE), середня абсолютна похибка (MAE), середня абсолютна процентна похибка (MAPE) тощо. Вони визначають, наскільки добре модель узагальнює закономірності в даних [2]. Наприклад, у задачі регресії модель може давати незначні помилки на тренувальних даних, але водночас сильно помилятися на нових – у цьому випадку аналіз похибок дає змогу виявити проблему перенавчання. У чисельних методах похибка також відіграє критичну роль. Зок-

рема, під час обчислення похідних або інтегралів із кроком h завжди наявні похибки дискретизації, які потрібно враховувати, щоб не накопичити критичних помилок у кінцевому результаті [6].

Наступним елементом є інтерполяція – метод, що дає змогу знаходити проміжні значення функції за заданими точками. У машинному навчанні інтерполяція може використовуватись для заповнення пропущених даних, передобробки сигналів, згладжування або створення синтетичних прикладів. Серед основних методів інтерполяції виділяють поліноміальну інтерполяцію Лагранжа та Ньютона [1; 6]. Інтерполяція Лагранжа дає змогу побудувати єдиний поліном, який точно проходить через усі задані точки. Проте зростання ступеня полінома веде до осциляцій (ефект Рунге), тож цей метод ефективний лише за умови невеликої кількості точок. Натомість інтерполяція Ньютона використовує розділені різниці та дає змогу поступово додавати нові точки без повного перерахунку полінома, що робить її зручнішою для адаптивних обчислень. У системах машинного навчання ідеї інтерполяції використовуються у згладжувальних алгоритмах, як *radial basis functions*, у згорткових мережах для ресемплінгу зображень або під час реконструкції відсутніх значень у часових рядах [3].

З інтерполяцією тісно пов'язана апроксимація, яка не ставить за мету точне проходження через усі точки, а прагне знайти функцію, що наближено описує поведінку об'єкта. Саме апроксимаційна здатність – головна мета будь-якої моделі машинного навчання [2; 4]. Наприклад, лінійна регресія апроксимує зв'язок між вхідними ознаками та цільовою змінною, будуючи гіперплощину в багатовимірному просторі. Інші моделі, як-от дерева рішень, нейронні мережі чи метод опорних векторів, також виконують апроксимацію, але з використанням нелінійних функцій. Ефективна апроксимація часто вимагає зменшення впливу шуму в даних, і саме тут виникає необхідність контролю за рівнем узгодження функції з реальною залежністю. Чим краще метод апроксимації відображає тенденції в даних, тим точнішою буде модель [2; 7].

Щоб оцінити залежність між змінними, часто застосовується коефіцієнт кореляції. Класичним прикладом є коефіцієнт Пірсона, який показує ступінь лінійної залежності між двома числовими змінними [1; 5]. Якщо ознака має високу кореляцію з цільовою змінною, її можна вважати корисною для навчання моделі. Якщо ж кореляція близька до нуля, ця ознака, ймовірно, не має значення. У машинному навчанні це використовується під час етапу вибору ознак, а також для зменшення розмірності. До того ж кореляційний аналіз дає змогу виявляти мультиколінеарність – ситуацію, коли дві або більше ознак надто подібні одна до одної, що погіршує точність моделей регресії.

Усі вищезгадані методи неможливо реалізувати без активного використання лінійної алгебри та матричних операцій. Машинне навчання у своїй основі – це робота з векторами, матрицями та тензорами. Наприклад, тренування лінійної моделі регресії з використанням методу найменших квадратів зводиться до розв'язання системи лінійних рівнянь, яка у матричній формі виглядає як

$$w = (X^T X)^{-1} X^T y, \quad (1)$$

де X – матриця ознак;

u – вектор відповідей;

w – вектор ваг [4].

У більш складних моделях, як-от нейронні мережі, використовуються десятки та сотні матричних операцій під час кожної ітерації навчання. Вміння ефективно працювати з матрицями – ключ до швидкого навчання моделей, особливо за умови великої кількості даних. Тому використовуються методи LU-, QR- та SVD-розкладів для обчислювальної оптимізації, стабілізації рішень та зниження розмірності даних [4; 5].

Нарешті, важливе місце в аналітичній частині займає чисельне інтегрування. У машинному навчанні воно застосовується, зокрема, в баєсівських моделях, де необхідно обчислювати апостеріорні розподіли, очікування та ймовірності [3]. Класичні методи прямокутників, трапецій, Сімпсона використовуються для наближеного обчислення інтегралів, коли неможливо знайти точне аналітичне значення [6]. До того ж у класифікаційних задачах оцінка AUC (area under the ROC curve) – це, по суті, обчислення площі під кривою, що також виконується чисельно. Сучасні методи, як-от Монте-Карло інтегрування, дають змогу оцінювати складні багатовимірні інтеграли в задачах високої складності [2; 3].

Отже, усі перелічені методи обчислень – похибки, інтерполяція, апроксимація, кореляція, робота з матрицями та чисельне інтегрування – мають тісний зв'язок із машинним навчанням. Вони є не лише фундаментальною основою для створення моделей, а й практичними інструментами для їх оптимізації та аналізу. Розуміння цих методів дає змогу будувати ефективні алгоритми, які точно працюють із реальними даними, виявляють закономірності та формують прогнози. Саме тому класичні методи обчислень і надалі залишаються актуальними в епоху інтелектуальних технологій.

Список використаних джерел

1. Чисельні методи (для студентів факультету комп'ютерних наук та кібернетики, ОП «Системний аналіз»): навч. посіб. / К. М. Голубєва, О. Ф. Кашпур, Д. А. Ключин. Київ: 2022. 145 с.
2. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2nd ed. O'Reilly Media, 2019. 812 p.
3. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016. 775 p.
4. Strang G. Introduction to Linear Algebra. 5th ed. Wellesley-Cambridge Press, 2016. 584 p.
5. Математичні методи аналізу даних: навч. посіб. / В. М. Бондарчук, Р. М. Головня, О. А. Громовий, І. В. Давидова, А. Г. Ткачук. Житомир: Державний університет «Житомирська політехніка», 2023. 145 с.
6. Burden R. L., Faires J. D. Numerical Analysis. 10th ed. Cengage Learning, 2015. 888 p.
7. Метод інтерполяції для прогнозування метрик використання хмарних обчислень в статистичному навчанні / Н. А. Потапова, Л. О. Волонтир, І. П. Чостоколенко, М. С. Григоренко. *Наука і техніка сьогодні*. 2024. № 4(32). С. 1192–1205. URL: <https://perspectives.pp.ua/index.php/nts/article/view/10943>