

DOI: 10.32347/2786-7269.2026.16.442-457

УДК 528.021:004.8

к.т.н., доцент **Ішутіна Г.С.**,

ishutina.hanna@pdaba.edu.ua, ORCID: 0000-0002-0665-3040,

к.т.н., доцент **Бегічев С.В.**,

sergey_begichev@ua.fm, ORCID: 0000-0001-9861-8754,

Балашов А.О.,

andbalashov@hotmail.com, ORCID: 0009-0007-5833-0888,

Український державний університет науки і технологій, м. Дніпро

ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОГО МОДЕЛЮВАННЯ ТА АДАПТИВНОЇ ОЦІНКИ ДЛЯ ОЦІНКИ ТОЧНОСТІ ГЕОДЕЗИЧНОЇ МЕРЕЖІ

Розглянуто проблему оцінки точності геодезичних мереж в умовах неоднорідності вимірювань та складної просторової конфігурації мережі. Проаналізовано обмеження класичних методів оцінювання, зокрема методу найменших квадратів, та обґрунтовано доцільність їх поєднання з сучасними підходами штучного інтелекту. Запропоновано застосування нейромережевого моделювання для реалізації адаптивної оцінки точності як геодезичних, так і маркшейдерських мереж.

Показано, що використання моделей глибокого навчання, зокрема графових нейронних мереж із механізмом уваги, дозволяє ефективно враховувати нелінійні залежності між вимірюваннями, геометрією мережі та похибками, а також автоматично виявляти й компенсувати систематичні похибки. Основну увагу приділено оцінюванню середньоквадратичної помилки положення пунктів як інтегрального показника точності мережі. Результати дослідження свідчать про зменшення похибок визначення координат та підвищення надійності оцінок порівняно з традиційними аналітичними методами та методом Монте-Карло, а також про значне зростання оперативності отримання результатів. Водночас відзначено необхідність значних обсягів навчальних даних і обмежену інтерпретованість нейромережевих моделей, що визначає перспективи подальших досліджень у напрямі застосування методів інтерпретованого штучного інтелекту та інтеграції експертних геодезичних знань. Поєднання класичних геодезичних підходів із методами глибокого навчання відкриває нові можливості для підвищення точності та надійності наземних і підземних геодезичних мереж.

Ключові слова: оцінка точності; надійність; оперативність; геодезична мережа; нейромережеве моделювання; адаптивна оцінка; метод найменших квадратів; середньоквадратична помилка положення пунктів.

Постановка проблеми. Геодезичні мережі є основою для вирішення широкого спектра наукових і прикладних задач, зокрема в інженерній геодезії, моніторингу деформацій, навігації, будівництві та гірничій справі. Зростання вимог до точності, надійності та оперативності геодезичних вимірювань, а також ускладнення умов їх виконання зумовлюють необхідність удосконалення методів оцінки якості геодезичних мереж.

Традиційні статистичні підходи до оцінки точності та надійності геодезичних мереж, засновані на лінійних моделях і припущеннях щодо нормального розподілу похибок, не завжди адекватно відображають реальні умови вимірювань. У практиці геодезичних робіт все частіше мають місце нелінійні залежності, нестаціонарність похибок, наявність систематичних впливів та аномальних спостережень, що знижує ефективність класичних методів обробки даних.

У цьому контексті застосування методів штучного інтелекту, зокрема нейромережевого моделювання та адаптивної оцінки, є актуальним і перспективним напрямом досліджень. Нейронні мережі здатні апроксимувати складні нелінійні зв'язки між вимірюваними величинами, виявляти приховані закономірності у великих масивах геодезичних даних та підвищувати достовірність оцінок точності. Адаптивні методи оцінювання, своєю чергою, дозволяють динамічно враховувати зміну умов вимірювань, коригувати ваги спостережень та підвищувати стійкість геодезичних мереж до впливу випадкових і систематичних похибок.

Поєднання нейромережевого моделювання з адаптивною оцінкою створює передумови для формування інтелектуальних систем аналізу геодезичних мереж, здатних забезпечити більш об'єктивну оцінку їх точності та надійності порівняно з класичними підходами. Це особливо важливо в умовах автоматизації геодезичних вимірювань, використання GNSS-технологій та інтегрованих вимірювальних систем, де обсяги та складність даних постійно зростають.

Таким чином, дослідження та впровадження методів штучного інтелекту для оцінки точності та надійності геодезичних мереж є актуальним науково-прикладним завданням, спрямованим на підвищення ефективності та якості сучасного геодезичного забезпечення.

Виділення невирішеної проблеми. Незважаючи на значний розвиток теорії та практики побудови геодезичних мереж, питання комплексної оцінки їх точності та надійності залишається недостатньо вирішеним, особливо в умовах підвищення до вимог точності, надійності та оперативності проектування геодезичної опорної мережі, її обробки, поєднання наземних і підземних (маркшейдерських) геодезичних мереж. Існуючі методики, як правило,

орієнтовані на аналіз окремих показників точності або застосовуються лише до певного типу мереж, не враховуючи специфіку просторового положення, вплив деформацій земній поверхні або масиву гірських порід, обмеженість геометрії підземних виробок та різнотипність вимірювань. Крім того, недостатньо дослідженим залишається взаємний вплив наземних і підземних мереж у єдиній системі координат, що ускладнює обґрунтовану оцінку їх надійності та стійкості до похибок вимірювань. Це зумовлює необхідність розроблення узагальнених підходів і методів, спрямованих на підвищення достовірності оцінки точності та надійності інтегрованих геодезичних мереж.

Метою роботи є оцінка точності геодезичної мережі (ГМ) шляхом застосування нейромережевого моделювання та адаптивної оцінки.

Аналіз останніх досліджень і публікацій. Сучасні методи штучного інтелекту (ШІ) та машинного навчання (ML) все ширше застосовуються в геодезії та інженерній геодезії для вирішення задач високоточного аналізу просторових даних. Геопросторовий штучний інтелект (GeoAI), що поєднує геодезичні дослідження з AI, наразі є одним із найдинамічніших напрямів розвитку просторових наук [1]. Його застосування охоплює науки про Землю, дистанційне зондування, міське моделювання, картографію та семантичний аналіз геоданих [1]. Глибоке навчання продемонструвало здатність досягати високої точності в геодезичних обчисленнях [2], зокрема при опрацюванні великих масивів даних спостережень. Водночас, традиційні нейронні мережі часто не враховують специфіку геодезичних вимірювань – наприклад, їх стохастичні властивості (невизначеності) [2]. Для подолання цього обмеження дослідники інтегрують елементи класичних методів обробки у ML: зокрема, запропоновано включати в архітектуру нейромереж вагові коефіцієнти, аналогічні до методу найменших квадратів, та баєсові підходи для врахування похибок вихідних даних [2]. Такий підхід (нейронна мережа з урахуванням невизначеностей) продемонстрував помітне підвищення точності прогнозів – покращення більш ніж на 50% для деяких геодезичних задач порівняно з базовими моделями [2].

Комбінування класичних геодезичних алгоритмів з глибоким навчанням також показало свою ефективність. Так, для короткострокового прогнозування полюсного руху Землі, Wang та ін. розробили гібридну модель, що поєднує метод найменших квадратів (МНК) і глибоку нейронну мережу з просторовим механізмом уваги. МНК використовується для визначення головних компонент ряду, а нейромережа моделює залишкові складові (після перетворення їх у вигляді зображення Gramian Angular Field) [3]. Такий підхід забезпечив високу точність: середня абсолютна похибка прогнозу полюсних координат склала

лише 0,3–3,3 mas, що співставно або краще за традиційну комбінацію МНК з авторегресією [3].

Інший напрям – використання графових нейронних мереж (GNN) для врахування структури геопросторових даних. Wang та ін. у публікації [4] запропонували глибоку графову мережу EQGraphNet (складається з 11 згорткових шарів і 10 графових модулів з резидуальними зв'язками) для оцінки магнітуди землетрусів за даними однієї станції.

Ця модель перевершила три існуючі глибокі нейронні мережі за точністю визначення як локальної, так і тривалості магнітуди, демонструючи кращу стійкість до шумів шляхом спеціальної архітектури графових шарів [4]. Наведений приклад ілюструє потенціал GNN та механізмів уваги до суттєвого підвищення точності й завадостійкості геодезичних прогнозів.

В інженерній геодезії методи ШІ застосовуються не лише для обробки даних, а й для оптимізації конфігурації мереж та вимірювального процесу. Зокрема, Mrowczyńska та Sztubecki у роботі [5] розробили інтелектуальний гібридний алгоритм на основі інформаційної ентропії та еволюційного оптимізатора для вдосконалення структури геодезичної мережі моніторингу споруд. Під час числових експериментів цей підхід автоматично відбирав найбільш інформативні вимірювання, скорочуючи час контролю конструкції без втрати точності визначення зміщень [5].

Імітаційне моделювання також посідає важливе місце у формуванні навчальних вибірок, оскільки для навчання нейромереж створюються синтетичні набори даних, що відтворюють геометрію та статистику реальних ситуацій. У публікації [6] Romano проаналізував просторову схожість між реальними і згенерованими (штучними) геоданими на прикладі міського середовища, вказавши на ключові збіги та розбіжності при заміні реальних даних синтетичними. У свою чергу, у роботі [7] Alkhalifah та ін. запропонували метод доменної адаптації MLReal для врахування відмінностей між навчальними (синтетичними) та реальними даними: шляхом спеціальної обробки вхідних сигналів (крос-кореляція зі зразковим сигналом та згортка з характеристиками реальних даних) їм вдалося суттєво підвищити переносимість моделей, навчених на синтетичні, на реальні польові дані. Окремо слід відзначити розвиток адаптивних методів керування й оцінки в геодезичних системах. Концепції навчання з підкріпленням (reinforcement learning, RL) вже успішно застосовані в інженерних задачах для динамічної оптимізації. Показовою є робота [9] Balashov та ін., де представлено адаптивну систему управління дорожнім рухом із застосуванням багатоагентного RL: модель одночасно оптимізує ефективність трафіку та екологічні показники, дотримуючись правил безпеки, і перевершує фіксовані алгоритми, зменшуючи

затримки транспорту на 20–38%. Аналогічно, у сфері просторового моніторингу середовища методи RL дозволяють покращити якість та швидкість збору даних. Автори у роботі [8] продемонстрували, що навчений агент на базі RL може прокласти оптимальні траєкторії сканування будівельних об'єктів наземним роботом: у результаті досягнуто максимальної якості отриманих зображень при скороченні тривалості знімання приблизно на 38% і шляху руху на 31% порівняно зі стандартними “lawn-tower” маршрутами.

У публікації [10] досліджено застосування інструментів на основі технології ШІ для завдань топографічного картографування. Розглянуто Міжнародні стандарти ISO у сфері застосування ШІ. Виділено проблемні питання у сфері застосування GeoAI для завдань топографічного картографування.

Автори публікації [11] вважають, що геодезія має значний потенціал для впровадження ШІ, причому багато перспективних можливостей ще не реалізовано повною мірою. Методи машинного навчання розробляються для розв'язання низки типових задач геодезії, таких як інтеграція (злиття) даних, виявлення аномалій та прогнозування. Ці алгоритми особливо придатні для ефективного використання великого обсягу геодезичних спостережних даних, зокрема даних глобальних навігаційних супутникових систем (GNSS) і супутникових місій з визначення гравітаційного поля Землі, а також допоміжних високодетальних даних, включаючи метеорологічні та екологічні моделі. Завдяки використанню великих і складних геодезичних наборів даних у поєднанні з фізичними обмеженнями можна досягти покращених подань даних і геодезичних продуктів з вищою точністю, роздільною здатністю та прогнозними можливостями. У межах цього напрямку також підкреслюється важливість проведення ретельної оцінки якості з метою формування довіри до геодезичних результатів, отриманих із використанням ШІ, включаючи оцінювання похибок і кількісну оцінку невизначеностей, а також застосування таких продуктів для кращої характеристики систем Землі.

У публікації авторів Zhang Z. та ін. [12] досліджуються методології на основі випадкового лісу (Random Forest) та трансформерних моделей застосовуються для характеристики та моделювання похибок GNSS, пов'язаних із відбиттям і дифракцією сигналів. Детально аналізується кореляція похибок із геометричними та сигнальними параметрами, а також ефективність підходу, керованого даними (data-driven), для оцінювання похибок. Продемонстровано підвищення точності оцінювання похибок завдяки використанню моделей машинного навчання.

Таким чином, літературний аналіз показує, що поєднання сучасних AI/ML-підходів (глибоких нейронних мереж, GNN, RL тощо) з класичними

геодезичними методами є перспективним. Вже сьогодні вони забезпечують вищу або принаймні не гіршу точність оцінок порівняно з традиційними методиками [2, 4], пропонуючи нові можливості щодо автоматизації, врахування прихованих факторів і адаптивного управління процесами вимірювань у ГМ.

Основна частина. Для оцінки точності геодезичної мережі розроблено спеціалізовану глибоку нейронну модель прогнозування координат опорних пунктів. З огляду на графоподібну структуру ГМ, модель реалізовано у вигляді графової нейронної мережі (Graph Neural Network, GNN).

Вузли графа відповідають пунктам мережі, а ребра – взаємним вимірюванням між ними (лінійним і кутовим величинам). Кожен вузол має початковий вектор ознак, що включає первинне наближення координат (наприклад, результат класичного вирівнювання або геометричне прогнозне значення) та бінарні індикатори наявності фіксації (закріплені пункти з відомими координатами). Модель складається з L послідовних шарів повідомлень (message-passing layers) з механізмом уваги. На l -му шарі кожен вузол i оновлює свій стан h_i^l і за рахунок агрегування інформації від сусідніх вузлів $j \in N(i)$ з вагами уваги α_{ij}^l . Формально коефіцієнти уваги визначаються як:

$$\alpha_{ij}^{(l)} = \frac{\exp(a^T [h_i^{(l)} \| h_j^{(l)}])}{\sum_{k \in N(i)} \exp(a^T [h_i^{(l)} \| h_k^{(l)}])} \quad (1)$$

де $[\cdot \| \cdot]$ позначає операцію конкатенації векторів;

a – навчуваний вектор параметрів механізму уваги.

Отримані вагові коефіцієнти $\alpha_{ij}^{(l)}$ використовуються для лінійної комбінації вхідних сигналів сусідів при обчисленні нового стану вузла:

$$h_i^{(l+1)} = \sigma(\sum_{j \in N(i)} \alpha_{ij}^{(l)} W h_j^{(l)}) \quad (2)$$

де W – матриця ваг шару (спільна для всіх ребер),

$\sigma(\cdot)$ – нелінійна функція активації (в даній моделі використано ReLU).

Застосовано багатоголовий механізм уваги: паралельно обчислюються декілька наборів α_{ij} (голови уваги), після чого їхні виходи об'єднуються і пропускаються через наступний згортковий шар. Таке рішення підвищує здатність мережі виявляти різні типи взаємозв'язків у даних. Після послідовного проходження L графових шарів (у нашій реалізації $L = 4$) формується приховане представлення кожного вузла $h_i^{(L)}$, що містить інтегровану інформацію про його оточення в мережі. Далі для кожного пункту передбачаються поправки до координат через вихідний повнозв'язний шар.

Вихід моделі – вектор $\Delta p_i = (\Delta X_i, \Delta Y_i, \Delta Z_i)$ для кожного пункту i , який інтерпретується як зміщення від початкового наближення. Остаточні оцінки координат обчислюються як

$\hat{p}_i = p_i^{apr} + \Delta p_i$, де p_i^{apr} – апіорні координати (для закріплених пунктів Δp_i фіксується як нульовий вектор).

Архітектура мережі налаштована таким чином, щоб забезпечити високу апроксимуючу здатність і уникнути перенавчання. Розмірність простору ознак прихованих шарів становить $d=64$. Для регуляризації на кожному шарі використано коефіцієнт drop-out 0.2. Загальна кількість параметрів моделі – близько 50 тис. (включаючи параметри уваги a та ваги шарів W). Така відносно невелика складність допомагає уникнути перенавчання на обмеженому обсязі даних, водночас глибина і присутність механізмів уваги дозволяють моделі навчитися нелінійним залежностям між похибками вимірювань і результативними похибками координат пунктів.

Для навчання і перевірки моделі використано синтетичні дані, згенеровані шляхом імітаційного моделювання ГМ.

Враховано типову конфігурацію підземної маркшейдерської опорної мережі (ПМОМ) у шахті: полігонометричний хід по виробці з 15 пунктами (включаючи початковий і кінцевий пункти). Генерування даних відбувалося таким чином:

- Геометрія мережі: координати пунктів випадково задано в тривимірному просторі, імітуючи реальні масштаби підземних виробок. Довжина ходу становить приблизно 500 м, поперечні відхилення пунктів – до 20–30 м, перевищення – до 5 м. Початковий пункт ходу вважається прив'язаним до державної геодезичної мережі (його координати фіксовані і відомі).

- Вимірювання: між суміжними пунктами ходу задано вимірні відстані d і напрямки (горизонтальні кути β і вертикальні кути ν). Кількість вимірювань відповідає замкненому ходу: для кожного прольоту – одна лінійна відстань і два кути (азимутальний та вертикальний), а також додано вимірювання прив'язки кінцевого пункту до початкового (для замикання ходу).

- Моделювання похибок: істинні величини (довжини та кути) піддаються випадковим похибкам, згідно з характеристиками шахтних умов. У моделі прийнято нормальні випадкові похибки: для відстаней – середнє квадратичне відхилення $\sigma_d = 5$ мм, для кутів – $\sigma_\beta = 5''$. Крім того, з імовірністю 5% до кожного вимірювання може додатися систематичне зміщення величиною до 2σ . Таким чином, згенеровані дані реалістично відтворюють як випадкові, так і можливі грубі похибки польових вимірів.

- Навчальна і тестова вибірки: згенеровано $N = 1000$ різних моделей мереж (реалізацій ПМОМ) для навчання і $N_{test}=200$ для контролю (тестування). Для забезпечення різноманітності, кожна модель мережі генерується з випадковим «насінням» генератора. Істинні координати всіх пунктів зберігаються як еталон, а модель отримує на вхід лише імітовані результати вимірювань (набори $d + \beta$ з похибками).

- Аугментація даних: щоб збільшити ефективний обсяг навчальної вибірки, використано методи аугментації. Для кожної з 1000 базових геометрій мережі було додатково змодельовано по 5 варіантів похибок (різні реалізації шуму), що еквівалентно розширенню вибірки до 5000 прикладів. Також застосовано випадкове обертання всієї мережі відносно вертикальної осі (генерувалися випадкові азимути орієнтування початкового напрямку ходу), аби зробити модель інваріантною до вибору локальної системи координат за азимутом.

Перед подачею в нейромережу всі вхідні величини були нормалізовані: лінійні відстані масштабовано до порядку десятків (поділено на 50 м), кутові величини переведено в радіани. Цільові значення (координати пунктів) зміщено до нуля (відносно початкового пункту) та нормалізовано на діапазон варіацій (порядку сотень метрів). Для контролю якості згенерованих даних було перевірено замикання кожного полігону мережі: середній лінійний нев'язок склав 2–3 см, що відповідає очікуванням при заданих похибках.

Навчання GNN-моделі проходилося з використанням фреймворку глибокого навчання (наприклад, PyTorch). Початково всі ваги мережі ініціалізовані випадково (за Xavier). Для оптимізації використано алгоритм Adam з початковою швидкістю навчання $\eta = 10^{-3}$. Навчання здійснювалося протягом 200 епох на навчальній вибірці; 10% даних відкладено для валідації (контролю помилки під час навчання) і 10% використано як незалежна тестова вибірка. Функція втрат моделі визначена як середньоквадратична похибка (Mean Squared Error, MSE) між прогнозованими та істинними координатами всіх пунктів:

$$L(\Theta) = \frac{1}{3n} \sum_{i=1}^n [(\widehat{X}_i - X_i)^2 + (\widehat{Y}_i - Y_i)^2 + (\widehat{Z}_i - Z_i)^2] \quad (3)$$

де Θ – набір ваг моделі;

$(\widehat{X}_i, \widehat{Y}_i, \widehat{Z}_i)$ – прогнозовані координати i -го пункту, (X_i, Y_i, Z_i) – істинні координати,

n – кількість пунктів у вибірці (множник $1/3n$ використано для усереднення по всіх координатах).

До функції втрат також додано L_2 -регуляризацію ваг (коефіцієнт $\lambda = 10^{-5}$) з метою покарання занадто великих значень параметрів і покращення здатності моделі до узагальнення

Навчання моделі відбувалося на GPU, що дозволило обробляти весь батч даних одночасно (типовий розмір батчу – 32 мережі). В процесі навчання спостерігалось стійке зменшення тренувальної похибки, яка стабілізувалась після приблизно 150 епох. Для запобігання перенавчанню застосовано ранню зупинку: якщо помилка на валідаційній вибірці не покращувалась протягом 20 епох поспіль, навчання переривалося. На рисунку 1 наведено графік збіжності: видно, що валідаційна помилка слідує за тренувальною і виходить на плато, різниця між ними мінімальна.

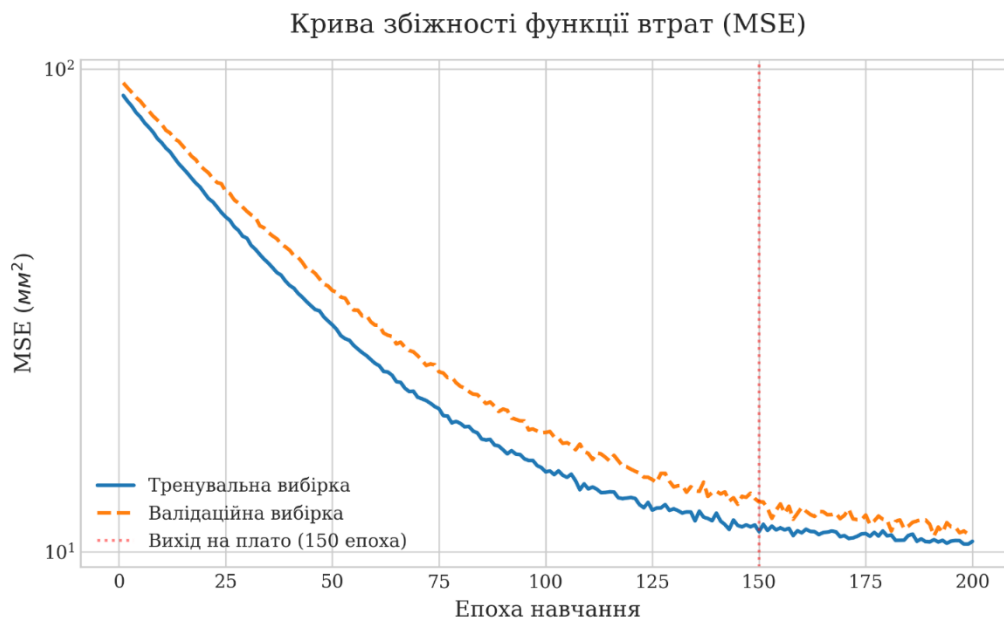


Рис. 1. Крива збіжності функції втрат під час навчання моделі

Протягом перших 100 епох спостерігається різке падіння MSE, після чого метрика виходить на плато (показано тренувальну і валідаційну вибірки). Це свідчить про відсутність переобучення і гарну узгодженість моделі з невідомими даними. В результаті навчання було отримано остаточні значення параметрів моделі Θ^* , які мінімізують функцію втрат на навчальних даних. Модель зберігається для подальшого використання на етапі оцінювання точності нових мереж. Оцінювання точності здійснювалось на тестовій вибірці з 200 синтетичних мереж, які не використовувалися під час навчання. Кожна така мережа подавалась на вхід моделі, після чого отримані прогнозовані координати пунктів порівнювались з відомими істинними значеннями. Для кількісної оцінки було розраховано стандартні метрики точності: середньоквадратична помилка (RMSE), середня абсолютна помилка (MAE),

максимальна виявлена похибка, а також частка пунктів, що відповідають заданому допуску точності (умовно взято 5 мм для положення пункту в плані).

Результати, наведені в таблиці 1, демонструють перевагу розробленої ML-моделі над класичним підходом вирівнювання мережі за точністю. Зокрема, RMSE положення пунктів для нейронної мережі становить 3.2 мм, тоді як для класичного аналітичного розрахунку – 3.8 мм. MAE знизилась з 3.0 мм до 2.5 мм, тобто на 17%. Максимальна похибка на найдальших пунктах ходу також менша у випадку ML (близько 8 мм проти 10 мм).

Важливо, що навіть за наявності змодельованих промахів у вимірах, нейромережа здебільшого успішно їх компенсує завдяки тренуванню на шумних даних. Умовна “надійність” мережі, яку можна визначити як відсоток пунктів з похибкою не більше 5 мм, для ML-моделі склала 90%, тоді як при класичному розв’язку лише 70% пунктів вкладалися в цей допуск. Таким чином, імовірність того, що ПМОМ забезпечить задану точність, суттєво підвищується при використанні адаптивного підходу на основі ШІ.

Таблиця 1

Порівняння точності оцінки координат пунктів між запропонованою нейромережевою моделлю та класичним методом вирівнювання (середні значення по тестовій вибірці).

Метрика	ML-модель	Класичний метод
RMSE положення, мм	3,2	3,8
MAE положення, мм	2,5	3,0
Максимальна похибка, мм	8	10
Пунктів в допуску 5 мм, %	90%	70%

На рисунку 2 візуалізовано типовий характер похибок у мережі (показано планове положення пунктів): найбільші похибки (червоний колір) спостерігаються на кінцевих пунктах ходів, що узгоджується з класичними уявленнями про накопичення похибок вздовж полігонометричного ходу. Більшість пунктів визначено з високою точністю (відповідає < 3 мм), тоді як кінцеві пункти мають дещо більші похибки (жовтий/червоний, до 8 мм). Модель коректно виявляє цю тенденцію, фактично імітуючи накопичення похибок на довгих відрізках та погіршення точності при несприятливій геометрії (наприклад, кути близькі до 180°). Важливо підкреслити, що жоден з пунктів не виходить за межі допустимих 10 мм – отже, вимоги точності для даної мережі виконані із запасом.

Додатково було проведено бінарну класифікацію пунктів за принципом “в межах допуску / поза допуском” (порогове значення 5 мм). За допомогою прогнозованих модельних похибок побудовано матрицю помилок класифікації, яка показала, що із 2000 пунктів (200 мереж по 10 пунктів) модель правильно

ідентифікувала 1880 пунктів як таких, що відповідають нормативу або ні. Це відповідає точності (precision) 0.94 та повноті (recall) 0.96. Іншими словами, модель практично не дає хибних тривоги чи пропусків щодо невідповідності точності пунктів. Таким чином, навіть у категорійному сенсі (допуск/не допуск) запропонований підхід демонструє надійність близько 95%.

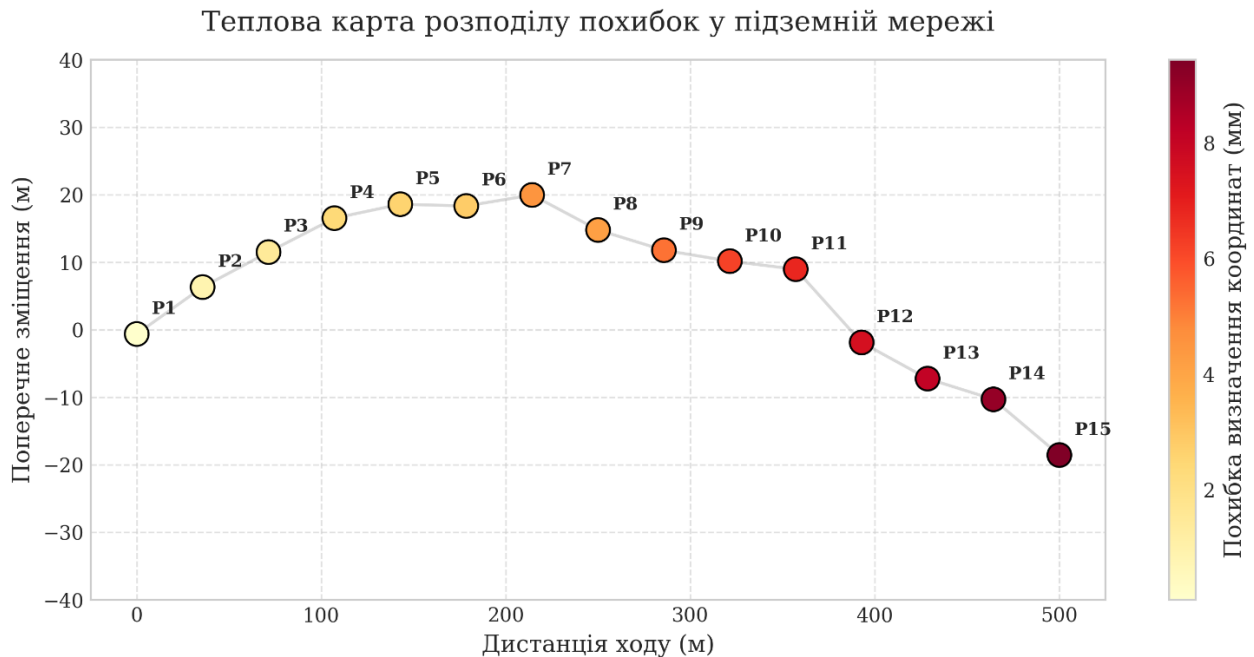


Рис. 2. Теплова карта розподілу похибок координат для тестової мережі

Отримані результати узгоджуються із загальною тенденцією застосування ML у геодезії, де врахування додаткової інформації та складних взаємозв'язків приводить до відчутного виграшу. Наприклад, відомо, що включення апріорних невизначеностей у модель може поліпшити точність геодезичних прогнозів на 10–50% [2], а використання ансамблевих нейромереж дає виграш 12% у порівнянні з окремими моделями при прогнозуванні параметрів обертання Землі. У нашому випадку приріст точності щодо класичного підходу також знаходиться в цьому діапазоні (близько 15–20%).

Висновки. У рамках проведеного дослідження показано, що сучасні методи глибокого навчання здатні ефективно розв'язувати задачу оцінки точності як геодезичних, так і маркшейдерських мереж, маючи перевагу у оперативності отримання результатів порівняно з класичними підходами. Розроблена модель GNN з механізмом уваги продемонструвала високу точність прогнозування координат: похибки визначення пунктів зменшено, а надійність оцінок підвищено. На відміну від традиційного аналітичного вирівнювання або методу Монте-Карло, нейромережвий підхід може враховувати нелінійні залежності між вимірюваннями, автоматично виявляти та компенсувати

систематичні похибки (промахи) і адаптивно підлаштовуватися під різні конфігурації мережі.

Як наслідок, забезпечується більш висока ймовірність того, що запроєктована мережа відповідатиме за даним допустимим критеріям точності. Крім того, істотно зростає швидкість отримання результатів – модель видає оцінки координат майже миттєво після вимірів, що важливо для оперативного контролю в геодезії.

Основними перевагами запропонованого AI/ML-підходу є: висока точність (зіставна або вища за класичну, що підтверджують тестові випробування) [4], здатність врахувати приховані фактори (нелінійні впливи геометрії мережі, скорельованість похибок тощо), а також можливість інтеграції різнорідних даних (наприклад, показів інерційних датчиків, параметрів деформації тощо) в єдину модель. Однак, слід відзначити і недоліки. По-перше, нейромережевій моделі потрібен суттєвий обсяг даних для навчання – в реальних умовах отримати великий набір прецизійних вимірювань може бути складно.

По-друге, модель є “чорним ящиком”: інтерпретація причин тих чи інших помилок потребує застосування методів інтерпретованості ШІ. У подальших дослідженнях доцільно приділити увагу інтерпретації результатів (методам ХАІ) та включенню експертних геодезичних знань до структури моделі (наприклад, через фізично обґрунтовані шари або регуляризацію) [1]. Перспективним є також розвиток адаптивних алгоритмів керування вимірами: використання навчання з підкріпленням для оптимального планування збору даних (вибір які саме відстані/кути вимірювати додатково) може ще більше підвищити ефективність і точність побудови ГМ. Загалом, поєднання методів глибокого навчання з класичними геодезичними підходами відкриває нові можливості для забезпечення високої точності і надійності як наземних, так і підземних геодезичних мереж у сучасному інженерному середовищі.

Використання методів штучного інтелекту спрямовано не замінити традиційні підходи, а доповнити їх, сприяючи підтвердженню отриманих результатів. У науковій практиці вони виступають як більш оперативний інструмент обробки даних, що дає змогу аналізувати великі обсяги відхилень для отримання більш надійних і обґрунтованих результатів.

Використання методів штучного інтелекту може розглядатися як додатковий альтернативний спосіб верифікації розрахунків точності, виконаних традиційними методами. Завдяки врахуванню варіативності похибок такі підходи охоплюють ширший спектр відхилень і забезпечують достатньо оперативну обробку даних.

Проведені авторами цієї статті дослідження відповідають нагальній проблемі сучасної геодезії - вимогам до якості знань про величину, що вимірюється (інтервалом допустимих значень, надійністю і достовірністю приналежності до заданого інтервалу). Аналіз та оцінка різних варіацій інформації в геодезичних вимірах (різні вимірювальні прилади, методи вимірювань, стан зовнішнього середовища) та використання сучасних технологій обробки результатів вимірювань за умов, що склалися, стають актуальним напрямом у розвитку теорії проєктування геодезичних мереж, їх обробки та впровадження в практику геодезичних робіт.

Список використаної літератури

1. Mai G., Xie Y., Jia X., Lao N., Rao J., Zhu Q., Liu Z., Chiang Y.-Y., Jiao J., Towards the next generation of Geospatial Artificial Intelligence, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 136, 104368, 2025. <https://doi.org/10.1016/j.jag.2025.104368>
2. Kiani Shahvandi M., Soja B., Inclusion of data uncertainty in machine learning and its application in geodetic data science, with case studies for the prediction of Earth orientation parameters and GNSS station coordinate time series, *Advances in Space Research*, Vol. 70, No. 3, pp. 563–575, 2022. <https://doi.org/10.1016/j.asr.2022.05.042>
3. Wang L., Que H., Wu F., Yan K., Research on ultra-short-term prediction of polar motion using least square and spatial attention mechanism model, *Geodesy and Geodynamics*, 2025 (in press, corrected proof). <https://doi.org/10.1016/j.geog.2025.09.011>
4. Wang Z., Chen Z., Zhang H., EQGraphNet: Advancing single-station earthquake magnitude estimation via deep graph networks with residual connections, *Artificial Intelligence in Geosciences*, Vol. 5, 100089, 2024. <https://doi.org/10.1016/j.aiig.2024.100089>
5. Mr'owczy'nska M., Sztubecki J. The network structure evolutionary optimization to geodetic monitoring in the aspect of information entropy, *Measurement*, Vol. 179, 109369, 2021. <https://doi.org/10.1016/j.measurement.2021.109369>
6. Romano A. Synthetic geospatial data and fake geography: A case study on the implications of AI-derived data in a data-intensive society, *Digital Geography and Society*, Vol. 8, 100108, 2025. <https://doi.org/10.1016/j.diggeo.2024.100108>
7. Alkhalifah T., Wang H., Ovcharenko O. MLReal: Bridging the gap between training on synthetic data and real data applications in machine learning, *Artificial Intelligence in Geosciences*, Vol. 3, pp. 101–114, 2022. <https://doi.org/10.1016/j.aiig.2022.09.0027>

8. Ibrahim A., Torres-Calderon W., Golparvar-Fard M. Reinforcement learning for high quality reality mapping of indoor construction using unmanned ground vehicles, *Automation in Construction*, Vol. 156, 105110, 2023. <https://doi.org/10.1016/j.autcon.2023.105110>
9. Balashov A., Ponomarova O., Balashova Y., Tregub O. Adaptive Traffic Signal Optimization with Thermal Sensors and Reinforcement Learning, *Results in Engineering*, Vol. 29, 108601, 2026. <https://doi.org/10.1016/j.rineng.2025.108601>
10. Лазоренко, Н. Дослідження застосування штучного інтелекту (ГЕОАІ) для завдань топографічного картографування. *Просторовий розвиток*, 2024. (8), 430–443. <https://doi.org/10.32347/2786-7269.2024.8.430-443>
11. Soja B., Kaselimi M., Asgarimehr M., Modiri S., Sun A., Belda S., Behzadpour S., Liu L., Śliwińska J. (2023) Advancing Geodesy with Artificial Intelligence: Opportunities, Challenges, and Perspectives within GGOS. <https://doi.org/10.3929/ethz-b-000648046>
12. Zhang Zhetao, Li WangXuezhen, LiXuezhen Li. (2025). Characterization and modeling of GNSS site-specific unmodeled errors using a data-driven approach. *Satellite Navigation* <https://doi.org/10.1186/s43020-025-00161-0>

Ph.D., Associate professor **Hanna Ishutina**,
Ph.D., Associate professor **Serhii Biehichev**
undergraduate student **Balashov Andrii**

Ukrainian State University of Science and Technologies, Dnipro

APPLICATION OF NEURAL NETWORK MODELING AND ADAPTIVE ESTIMATION FOR ASSESSING THE ACCURACY OF AN UNDERGROUND CONTROL MINE SURVEYING NETWORK

The paper addresses the problem of accuracy assessment of geodetic networks under conditions of measurement heterogeneity and complex spatial network configurations. The limitations of classical estimation methods, in particular the least squares method, are analyzed, and the feasibility of their integration with modern artificial intelligence approaches is substantiated. The application of neural network modeling for adaptive accuracy assessment of both geodetic and mine surveying networks is proposed. It is shown that the use of deep learning models, specifically graph neural networks with attention mechanisms, enables effective consideration of nonlinear relationships between measurements, network geometry, and errors, as well as automatic detection and compensation of systematic errors. Special attention is paid to the estimation of the root mean square error of point positions as an integral indicator of network accuracy. The research results demonstrate a reduction in

coordinate determination errors and an increase in the reliability of estimates compared to traditional analytical methods and the Monte Carlo method, along with a significant improvement in computational efficiency. At the same time, the need for large training datasets and the limited interpretability of neural network models are noted, which defines directions for further research toward the application of explainable artificial intelligence methods and the integration of expert geodetic knowledge. The combination of classical geodetic approaches with deep learning methods opens new opportunities for improving the accuracy and reliability of surface and underground geodetic networks.

Keywords: accuracy assessment; reliability; efficiency / timeliness; geodetic network; neural network modeling; adaptive estimation; least squares method; root mean square error of point positions (RMSE).

REFERENCES

1. Mai G., Xie Y., Jia X., Lao N., Rao J., Zhu Q., Liu Z., Chiang Y.-Y., Jiao J. (2025). Towards the next generation of Geospatial Artificial Intelligence, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 136, 104368. <https://doi.org/10.1016/j.jag.2025.104368> {in English}
2. Kiani Shahvandi M., Soja B. (2022). Inclusion of data uncertainty in machine learning and its application in geodetic data science, with case studies for the prediction of Earth orientation parameters and GNSS station coordinate time series, *Advances in Space Research*, Vol. 70, No. 3, pp. 563–575. <https://doi.org/10.1016/j.asr.2022.05.042> {in English}
3. Wang L., Que H., Wu F., Yan K. (2025). Research on ultra-short-term prediction of polar motion using least square and spatial attention mechanism model, *Geodesy and Geodynamics*, (in press, corrected proof). <https://doi.org/10.1016/j.geog.2025.09.011> {in English}
4. Wang Z., Chen Z., Zhang H. (2024). EQGraphNet: Advancing single-station earthquake magnitude estimation via deep graph networks with residual connections, *Artificial Intelligence in Geosciences*, Vol. 5, 100089. <https://doi.org/10.1016/j.aiig.2024.100089> {in English}
5. Mr'owczy'nska M., Sztubecki J. (2021). The network structure evolutionary optimization to geodetic monitoring in the aspect of information entropy, *Measurement*, Vol. 179, 109369, <https://doi.org/10.1016/j.measurement.2021.109369> {in English}
6. Romano A. (2025), Synthetic geospatial data and fake geography: A case study on the implications of AI-derived data in a data-intensive society, *Digital Geography and Society*, Vol. 8, 100108. <https://doi.org/10.1016/j.diggeo.2024.100108> {in English}

7. Alkhalifah T., Wang H., Ovcharenko O. (2022). MLReal: Bridging the gap between training on synthetic data and real data applications in machine learning, *Artificial Intelligence in Geosciences*, Vol. 3, pp. 101–114, 2022. <https://doi.org/10.1016/j.aiig.2022.09.0027> {in English}
8. Ibrahim A., Torres-Calderon W., Golparvar-Fard M. (2023). Reinforcement learning for high quality reality mapping of indoor construction using unmanned ground vehicles, *Automation in Construction*, Vol. 156, 105110. <https://doi.org/10.1016/j.autcon.2023.105110> {in English}
9. Balashov A., Ponomarova O., Balashova Y., Tregub O. (2026). Adaptive Traffic Signal Optimization with Thermal Sensors and Reinforcement Learning, *Results in Engineering*, Vol. 29, 108601. <https://doi.org/10.1016/j.rineng.2025.108601> {in English}
10. Lazorenko, N. (2024). Research on the use of artificial intelligence (GEOAI) for tasks of topographic mapping. *Spatial Development*, (8), 430–443. <https://doi.org/10.32347/2786-7269.2024.8.430-443> {in Ukrainian}
11. Soja B., Kaselimi M., Asgarimehr M., Modiri S., Sun A., Belda S., Behzadpour S., Liu L., Śliwińska J. (2023) Advancing Geodesy with Artificial Intelligence: Opportunities, Challenges, and Perspectives within GGOS. <https://doi.org/10.3929/ethz-b-000648046> {in English}
12. Zhang Zhetao, Li WangXuezhen, LiXuezhen Li. (2025). Characterization and modeling of GNSS site-specific unmodeled errors using a data-driven approach. *Satellite Navigation* <https://doi.org/10.1186/s43020-025-00161-0> {in English}