



Прийнято 26.06.2025. Прорецензовано 06.10.2025. Опубліковано 26.12.2025.

УДК 550.8.05

DOI: 10.31471/1993-9868-2025-2(44)-46-54

ВИКОРИСТАННЯ НЕЙРОМЕРЕЖ ДЛЯ ОЦІНЮВАННЯ ПОРИСТОСТІ ТА ПРОНИКНОСТІ ГІРСЬКИХ ПОРІД

Юрчишин О. В.

Інженер

Управління нафтопромислового сервісу АТ «Укрнафта»

Північний бульвар, 2, м. Івано-Франківськ, 76019, Україна

<https://orcid.org/0009-0005-0733-7612>e-mail: oleh.yurchyshyn@ukrnafta.com**Розловська С. Є.***

Кандидат геологічних наук, доцент

Івано-Франківський національний технічний університет нафти і газу

вул. Карпатська, 15, м. Івано-Франківськ, 76019, Україна

<https://orcid.org/0000-0002-9259-6774>e-mail: svitlana.rozlovska@nung.edu.ua

Анотація. Із появою штучного інтелекту (ШІ) і його застосуванням у різних галузях промисловості з'явилася можливість автоматизувати та оптимізувати багато процесів, в тому числі і в геофізиці. Використання ШІ у геофізичних дослідженнях свердловин (ГДС) може внести революційні зміни у способи збору, обробки та інтерпретації даних. Очікується, що він стане ключовим інструментом у нафтогазовій промисловості для розвитку моделювання та аналізу даних, пропонуючи значні переваги для точності та ефективності процесів. У роботі продемонстровано спробу оцінити пористість та проникність гірських порід на основі результатів ГДС за допомогою нейромережі, як основного інструменту. Пористість і проникність є одними із ключових характеристик пласта-колектора та важливими параметрами для проектних розрахунків та розробки продуктивних горизонтів нафтогазових родовищ. Основні складнощі у їх визначенні полягають в тому, що вони є функцією багатьох параметрів. З появою нових інформаційних технологій відкриваються можливості знаходження складних взаємозв'язків між розрізненими геолого-геофізичними параметрами. Розробка моделі штучної нейронної мережі для прогнозування коефіцієнтів пористості і проникності порід базується на глибокому аналізі даних ГДС. Цей підхід дозволяє виявити приховані взаємозв'язки між параметрами, які залишаються непоміченими при застосуванні традиційних аналітичних методів. У ході дослідження вдалося досягти високої точності прогнозування значень пористості та проникності, що підтверджується їхнім співпадінням із результатами лабораторних експериментів. Це демонструє ефективність використання машинного навчання для автоматизованого аналізу геофізичних даних. Запропонований підхід має значні переваги, зокрема швидкість і точність аналізу, що є особливо важливим у ситуаціях, коли проведення лабораторних досліджень неможливе або обмежене. Використання нейронних мереж сприяє глибшому розумінню впливу різних факторів на пористість та проникність порід, що має велике значення для прийняття рішень у процесі розробки покладів. Новизна цієї роботи полягає у створенні інтегрованого підходу, який об'єднує класичні методи геофізики з інноваційними алгоритмами машинного навчання. Така комбінація забезпечує швидке та ефективне визначення пористості та проникності порід, відкриваючи нові можливості для оптимізації процесів вивчення та розробки родовищ.

Ключові слова: проникність гірських порід; геофізичні дослідження; штучний інтелект; машинне навчання; нейронна мережа; аналіз даних; інтерпретація досліджень.

Запропоноване посилання: Юрчишин, О. В., & Розловська, С. Є. (2025). Використання нейромереж для оцінювання пористості та проникності гірських порід. Нафтогазова енергетика, 2(44), 46-54. doi: 10.31471/1993-9868-2025-2(44)-46-54.

* Відповідальний автор



Copyright © The Author(s). This is an open access article distributed under the terms of the Creative Commons Attribution License 4.0 (<https://creativecommons.org/licenses/by/4.0/>)

Вступ

Пористість і проникність є ключовими характеристиками пластів-колекторів та важливими параметрами для ефективної розробки нафтогазових родовищ. Можна їх уявити як функцію дуже багатьох інших параметрів, що викликає додаткові складнощі під час їхнього визначення. З метою врахування тих факторів, що впливають на ці характеристики, проводять вивчення структури пустотного простору порід, їхньої анізотропії, моделюють умови залягання тощо. Пористість гірських порід характеризує обсяг порового простору до загального об'єму породи і визначає, скільки рідини чи газу може міститися в породі. Проникність гірських порід визначає динаміку руху рідин та газів, яка має велике значення для розрахунків та моделювання різних процесів. Пористість показує лише загальний обсяг пор, але не визначає, наскільки ці пори сполучені між собою. Проникність визначає здатність рідини чи газу рухатися через породу, що залежить не лише від пористості, а й від форми, розміру та взаємозв'язку пор. Висока пористість, але низька проникність характерна для глинистих порід, де пори дуже малі, але не сполучені. Низька пористість, але висока проникність спостерігається у тріщинуватих породах, де рідина рухається переважно через тріщини.

Отримати точні дані про пористість та проникність можна за допомогою лабораторних досліджень керна. Це дозволяє врахувати анізотропію гірських порід, що забезпечує надійність результатів. Нерідко це визначення є складним завданням через обмеженість безпосередніх вимірів. Щодо дистанційних вимірів, пористість та проникність можна визначити під час ГДС та оцінити (опосередковано) за допомогою гідродинамічних методів, аналізуючи фільтраційні властивості порід під час випробувань свердловин. Спосіб визначення коефіцієнтів пористості та проникності гірських порід, який базується на використанні результатів ГДС, пов'язаний з труднощами математичного моделювання, обумовленими неоднорідністю мінерального скелету порід і мінливістю параметрів структури порового простору. На цей час є багато спроб встановлення деяких закономірностей, однак усі вони мають досить обмежені можливості через анізотропію, складність геометрії пористих середовищ та складні процеси руху флюїду чи газу в породі. Беручи до уваги величезне значення цих параметрів для ефективного вилучення вуглеводнів, точність визначення стає критичною у процесі розробки родовищ [1].

Аналіз сучасних закордонних і вітчизняних досліджень та публікацій

Чимало досліджень присвячено проблемі визначення пористості і проникності порід різними методами, способами та підходами. У роботі [2] продемонстровано, що певному значенню пористості можуть відповідати різні значення проникності через різний гранулометричний склад порід та вміст і розподілу у породі глинистого матеріалу. Аналіз попередніх наукових досліджень із проблеми прогнозування фільтраційних властивостей нафтогазових пластів-колекторів показав, що багато чинників впливають на проникну здатність гірських порід, і це відображено в математичних моделях, які адаптовані до особливостей кожного пласта [3]. Багато спроб було зроблено для опису зв'язку між різними параметрами та проникністю [4, 5].

Із останніми технологічними проривами, вирішення складних завдань стає більш доступним. Машинне навчання дозволяє виявляти складні взаємозв'язки між параметрами на основі наявних даних, що може значно полегшити процес. За останні роки опубліковано низку цікавих робіт із визначення пористості та проникності за допомогою технологій штучного інтелекту, які дають обнадійливі результати успішного застосування цього підходу [6, 7, 8, 9, 10]. Це відкриває нові можливості для більш точних та надійних розрахунків у геологічній науці та індустрії видобутку нафти та газу. Окремо слід відзначити дисертаційну роботу В.В. Антонюка [11], у якій методи машинного навчання (зокрема штучні нейронні мережі) застосовано для реконструкції відсутніх коротажних кривих і класифікації порід-колекторів за фільтраційно-ємнісними властивостями. Крім того, оглядова стаття І.С. Дмитрієвої та А.М. Дмитренка [12] узагальнює сучасні підходи штучного інтелекту до інтерпретації 3D-сейсмічних даних і прогнозування резервуарних властивостей (пористості, проникності, літології), що додатково підтверджує актуальність використання таких методів у задачах оцінки фільтраційно-ємнісних параметрів.

Висвітлення невирішених раніше частин загальної проблеми

Актуальність роботи полягає у розробці інтегрованого підходу, який поєднує класичні методи геофізики з інноваційними алгоритмами машинного навчання для швидкого та ефективного визначення пористості та проникності порід.

Мета та завдання досліджень

Метою цієї роботи є визначення пористості та проникності порід на основі ГДС з використанням машинного навчання, як основного інструменту. Для досягнення поставленої мети планується вирішити наступні завдання: розробити методологію застосування технологій машинного навчання для оцінки коефіцієнтів пористості та проникності, включаючи автоматизацію збору, аналізу даних та прогнозування; здійснити практичне застосування розробленого підходу на конкретних прикладах.

Висвітлення основного матеріалу дослідження

Використання машинного навчання у ГДС надає нові можливості для аналізу, інтерпретації та оптимізації результатів. Сучасні методи геофізичного дослідження мають свої проблеми, які технології ШІ можуть допомогти вирішити. Виокремимо дві з них:

- складність аналізу даних: сучасні ГДС генерують величезний обсяг даних, аналіз яких вручну є часозатратним і суб'єктивним. ШІ може автоматизувати процес аналізу, виділяючи ключові показники та забезпечуючи більш об'єктивний підхід;

- необхідність прогнозування: для оптимальної розробки родовищ потрібно передбачити фізико-хімічні властивості пластів, їхню продуктивність та інші параметри – технології ШІ, особливо глибокі нейронні мережі, можуть значно підвищити якість такого прогнозування.

Для ефективного збору та підготовки даних для тренування моделей штучних нейронних мереж важливо послідовно пройти кілька етапів. Потрібно ідентифікувати надійні та релевантні джерела даних, такі як спеціалізовані бази даних. Потім необхідно провести аналіз геофізичних даних, включаючи результати свердловинних досліджень, зокрема акустичні, радіоактивні й електричні вимірювання. Наступним кроком є збір необхідних даних за результатами дослідження керна матеріалу. Ці дані можуть бути у різноманітних форматах та масштабах, тому важливо врахувати це при плануванні подальшої обробки. Наступним етапом є підготовка даних, яка включає очищення, нормалізацію та розділення їх. Очищення даних включає видалення шуму та корекцію помилкових значень, виявлення аномальних значень. Нормалізація даних потрібна для приведення їх до єдиного масштабу. Розділення даних на навчальний та тестовий набори даних. Такий підхід дозволяє забезпечити

якість вхідних даних для подальшого тренування моделей нейромереж.

Нашими вхідними даними слугували результати ГДС та прийняті значення пористості та проникності на основі лабораторних досліджень керна матеріалу. Створення бази вхідних даних і, відповідно, навчального набору даних було проведено завдяки написаному програмному коду. У подальшому зібрані дані використовувалися для навчання нейронної мережі з метою прогнозування коефіцієнтів пористості та проникності за результатами геофізичних досліджень.

Штучні нейронні мережі — це обчислювальні моделі, здатні досліджувати складні залежності в даних завдяки ієрархічним рівням нелінійних перетворень. Машинне навчання дає змогу системам самостійно вдосконалюватись, “навчаючись” на прикладах. Об'єднання цих підходів дає змогу розв'язувати завдання прогнозування навіть у випадках, коли фізична або аналітична модель взаємодії між вхідними та вихідними даними є складною або невідомою. Для тренування нейронної мережі було написано програмний код і створено інтерфейс користувача для роботи з натренованою моделлю. Мета цієї задачі – прогноз коефіцієнтів пористості та проникності у кожному фрагменті даних (500 замірів для кожного 50-метрового інтервалу з кроком у 0,1 м).

Для визначення коефіцієнтів пористості та проникності нейромережа була навчена не тільки на параметрах, що традиційно вважаються основними для таких задач, але й на тих, які можуть мати опосередкований вплив, надаючи додаткову або уточнюючу інформацію. Таким чином, результуючий перелік геофізичних параметрів включав: глибину, тип породи, нормовані значення гамма-каротажу та нейтронного гамма-каротажу, вміст водню за даними нейтрон-нейтронного каротажу, показники кавернометрії, акустичного каротажу, бокового каротажу, потенціал-зонду та індукційного каротажу.

Безпосереднього лінійного чи простого функціонального зв'язку між геофізичними даними свердловини (електричні, радіоактивні, акустичні тощо) та коефіцієнтами пористості та проникності немає. Більше того, на результати геофізичних методів впливають як геологічні чинники (тип насичення, мінералізація флюїдів), так і технічні (параметри промивальних розчинів, зона проникнення). Через це кожен набір геофізичних досліджень унікальний, що ускладнює моделювання традиційними методами. Щоб підвищити узагальнювальну зда-

тність моделі, вхідні дані (так само послідовності з багатьох вимірювань) попередньо приводяться до нормалізованого діапазону: таким чином усуваються відмінності в абсолютних масштабах різних каналів (наприклад, самочинна поляризація, показники гамма-каротажу та нейтронного гамма-каротажу). Така нормалізація дає змогу мережі концентруватись на відносних коливаннях величин.

У ході досліджень було оброблено дані з восьми родовищ Дніпровсько-Донецької западини. Для навчання моделі використовували інтервали глибин, у яких виконано лабораторні дослідження керну, представленого пісковиками та алевролітами. Для коректної прив'язки кернових точкових вимірів до каротажного розрізу ми виконали калібрування глибин: глибини лабораторних проб були згруповані з відліками у замірах шляхом зіставлення маркерних піків. Спочатку дані були вивантажені в окремі CSV-файли (сформовані в результаті обробки LAS-файлів), де кожен файл містить глибинний ряд геофізичних показників та значення пористості й проникності на основі лабораторних досліджень. Зібрані дані були масштабовані за допомогою алгоритму, який зводить їх до єдиного інтервалу. Додатково оброблялися відсутні значення (створювалася відповідна «маска»), щоб відсутність вимірювання не сприймалося як нульове значення та не спотворювало результат.

Була створена обчислювальна модель на основі глибинної мережі. Спочатку мережа виконує послідовну обробку вхідних даних згортковими блоками, які мають додаткові з'єднання, відомі як резидуальні, щоб полегшити поширення градієнтів та ефективніше засвоювати патерни. Такі блоки спеціально пристосовані для аналізу послідовних даних, коли важливо зберігати локальні деталі та залежності. Кожен шар перетворює дані з попереднього рівня, поступово «витагуючи» та узагальнюючи суттєві риси інформації. Такі багатшарові архітектури дозволяють моделі засвоювати більш складні залежності в даних порівняно з традиційними підходами.

Наступний етап – це застосування механізмів самоуваги, які використовують у моделях трансформерах. Цей механізм надає моделі здатність «звертати увагу» на різні ділянки ряду та ефективно узгоджувати як близькі, так і віддалені точки. Завдяки спеціально підбраному завершальному шару мережа на виході формує два канали: перший відповідає за коефіцієнт пористості, другий – за проникність (із логарифмічним перетворенням, щоби краще

працювати з широким діапазоном значень проникності). Модель навчається методом зворотного поширення помилки, при цьому використовується функція втрат на основі середньоквадратичного відхилення. Для перевірки здатності узагальнювати, дані розділено на навчальний і перевіірочний набір даних (в пропорції 85% – навчальна вибірка, 15% – перевіірочна вибірка), а під час кожної епохи (повне проходження усіх навчальних даних через нейромережу) відстежуються середні втрати та кілька метричних показників помилки. Наприкінці кожної епохи модель зберігається у файл, також зберігаються налаштовані масштабувальники, щоб надалі застосовувати ті самі перетворення під час практичного використання на нових даних вже з інших свердловин.

Таким чином, код реалізує повний цикл побудови, навчання та збереження моделі глибинної нейронної мережі, що здатна вивчати закономірності з геофізичних даних для прогнозування двох властивостей колектора. Поєднання згорткових (для локальних ознак) і трансформерних (для глобальних залежностей) підходів дає змогу мережі навчитися комплексним взаємозв'язкам у послідовностях і забезпечити потрібний прогноз пористості та проникності.

Графіки втрат під час тренування (рис. 1) дозволяють візуально відслідковувати ефективність навчання моделі. Вони відображають, як швидко або повільно модель навчається, чи спостерігається перенавчання. Для навчальних даних ми очікуємо, що втрати будуть зменшуватися з кожною ітерацією (епохою), для тестових даних (які модель не бачила під час навчання) вони також повинні зменшуватися, але можуть стабілізуватися або навіть збільшуватися (якщо модель починає перенавчатися). У нашому випадку ми спостерігаємо зменшення втрат з кожною ітерацією, а потім їх умовну стабілізацію.

Збереження моделі відбувається тоді, коли показники саме на тестових даних досягають мінімальних значень. Модель зберігається в форматі файлу, який включає в себе архітектуру мережі та ваги її параметрів. Таку модель можна використовувати для подальших прогнозувань на нових даних.

У функції втрат використано десятковий логарифм, що особливо важливо для коефіцієнтів проникності з дуже великими або малими значеннями. Додатково застосовано невелику зсувну константу для коректної обробки нульового значення. Таке логарифмічне перетворення зменшує втрату точності та робить




Рисунок 1 – Візуалізація втрат при навчанні та перевірці

Таблиця 1 – Числові характеристики статистичної обробки результатів

	Коефіцієнт пористості	Коефіцієнт проникності
Кількість точкових значень	1593	1593
Середнє фактичне значення	0.171(частки одиниці)	298.76 мД
Середнє прогнозоване значення	0.173 (частки одиниці)	302.12 мД
Коефіцієнт детермінації (R^2)	0.968	0.871
Коефіцієнт кореляції Пірсона (r)	0.979	0.947
Корінь з середньоквадратичної помилки MSE (RMSE)	0.008	36.87
Середня абсолютна помилка (MAE)	0.006	18.84
Середня абсолютна відсоткова помилка MAPE, %	4.21	11.47
Тест Андерсона-Дарлінга	0.1283	0.6254

навчання більш стійким та надійним. Після завершення повного циклу навчання нейронної мережі було здійснено оцінку якості її роботи. Для цього ми згенерували синтетичні криві прогнозних значень пористості та проникності, та виконали їхню статистичну обробку (табл. 1). Аналіз проводився окремо для коефіцієнта пористості (рис. 2) та коефіцієнта проникності (рис. 3). З цієї метою було здійснено порівняння результатів лабораторних досліджень керну (тип породи – пісковик) з відповідними прогнозами, отриманими за допомогою нейронної мережі.

Отримані результати свідчать, що застосована неймережева модель є досить якісною для поставленої задачі. Середні прогнозні значення пористості проникності дуже близькі до фактичних значень, отриманих лабораторно, що підтверджує відсутність суттєвого систематичного зміщення. Коефіцієнти детермі-

нації (R^2) для обох параметрів є високими, однак прогнозування пористості ($R^2 = 0.968$) є більш точним у порівнянні з проникністю ($R^2 = 0.871$). Також спостерігається дуже сильний лінійний зв'язок між фактичними та прогнозними значеннями, про що свідчать високі значення коефіцієнтів кореляції Пірсона (для пористості 0.979, для проникності 0.947). Проте знову ж таки прогнозування пористості виглядає точнішим.

Середня абсолютна помилка (MAE) для пористості є досить низькою (0.006), що є цілком прийнятним результатом. Водночас, для проникності середня абсолютна помилка становить вже 18.84 мД, а показник середньої абсолютної відсоткової помилки (MAPE) для проникності становить 11.47%, що є більш суттєвим значенням. Тест на відповідність розподілу Андерсона-Дарлінга був обраний для перевірки відповідності залишків нормальному




Рисунок 2 – Статистичний аналіз для прогнозованих значень коефіцієнта пористості




Рисунок 3 – Статистичний аналіз для прогнозованих значень коефіцієнта проникності

закону розподілу, оскільки саме нормальний розподіл помилок є однією з базових передумов адекватності регресійних моделей, зокрема нейромережових. Отримані значення дозволяють стверджувати, що залишки статистично відповідають нормальному розподілу.

Обмеження моделі

Прогнозування проникності ускладнюється її високою чутливістю до мікротріщин, дрібномасштабної неоднорідності, структурних змін, а також підвищеною шумністю лабораторних вимірювань. Отриманий результат ($R^2 = 0.871$) є прийнятним для геологічної практики, однак значення $MAPE = 11.47\%$ свідчить про нестабільність у структурно ускладнених інтервалах. Додатково, варіації між літотипами (текстури, поровий простір, режими фільтрації) обмежують узагальнюваність моделі між різними геологічними середовищами; ці чинники слід враховувати під час інтерпретації результатів і планування подальшого вдосконалення.

Висновки

Результати досліджень свідчать про перспективність нейромережевого підходу для прогнозування фільтраційно-ємнісних параметрів гірських порід. Попри наявні недоліки, загальна якість моделі є обнадійливою і може розглядатися, як успішна спроба впровадження інноваційних технологій у ГДС. Для подальшого покращення точності прогнозування планується збільшувати обсяг тренувальних даних, проводити додаткові лабораторні дослідження, адаптувати моделі до особливостей конкретних родовищ і експериментувати з різними архітектурами нейронних мереж. Це дозволить суттєво розширити потенціал практичного застосування такого підходу у галузі.

Подяки

Відсутні.

Конфлікт інтересів

Відсутній.

Список використаних джерел

1. Schon J. H. Physical properties of rocks: A Workbook. Handbook of petroleum exploration and production. Elsevier, Vol. 8. 2011. 494 p. URL: <http://ndl.ethernet.edu.et/bitstream/123456789/419/1/97.pdf>
2. Bernabe Y., Mok U., Evans B. A note on oscillation flow method for measuring rock permeability. *International Journal of Rock Mechanics & Mining Sciences*. 2006. № 43. P. 311–316. DOI: [10.1016/j.ijrmms.2005.04.013](https://doi.org/10.1016/j.ijrmms.2005.04.013).
3. Tiab D., Donaldson E. Petrophysic: Theory and practice of measuring reservoir rock and fluid transport properties. 2nd edition. Gulf Professional Publishing. 2011. 950 p. URL: <https://www.geokniga.org/books/40073>
4. Вижва С. А., Безродна І. М., Козіонова О. О. Аналіз фільтраційно-ємнісних властивостей карбонатних порід карбону Руденківсько-Пролетарського регіону за результатами петрофізичних досліджень. *Геоінформатика*. 2012. № 1. С. 17–25. URL: <http://jnas.nbu.gov.ua/article/UJRN-0000039914> (дата звернення: 25.11.2025).
5. Вижва С. А., Михайлов В. А., Онищук Д. І. та ін. Петрофізичні параметри нетрадиційних порід-колекторів Південного нафтогазового регіону. *Геоінформатика*. 2013. № 3. С. 17–25. URL: <http://jnas.nbu.gov.ua/article/UJRN-0000025433> (дата звернення: 25.11.2025).
6. Ahmadi M. A., Chen Z. Comparison of machine learning methods for estimating permeability and porosity of oil reservoirs via petrophysical logs. *Petroleum*. 2019. № 5. P. 271–284. URL: <https://www.scribd.com/document/419961181/Comparison-of-Machine-Learning-Methods-for-Estimating-Permeabilityand-Porosity-of-Oil-Reservoirs-via-Petro-physical-Logs> (дата звернення: 25.11.2025).
7. Heidari A. A., Faris H., Aljarah I., etc. An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Comput.* 2019. № 23. P. 7941–7958. DOI: [10.1007/s00500-018-3424-2](https://doi.org/10.1007/s00500-018-3424-2).
8. Saputro O. D., Maulana Z. L., Latief F. D. E. Porosity log prediction using artificial neural network. *J. Phys. Conf. Ser.* 2016. № 739. P. 012092. DOI: [10.1088/1742-6596/739/1/012092](https://doi.org/10.1088/1742-6596/739/1/012092)
9. Abdel Azim R., Aljehani A. Neural Network Model for Permeability Prediction from Reservoir Well Logs. *Processes*. 2022. № 10. 2587. DOI: [10.3390/pr10122587](https://doi.org/10.3390/pr10122587).

10. Matinkia M., Hashami R., Mehrad M., etc. Prediction of permeability from well logs using a new hybrid machine learning algorithm. *Petroleum*. 2023. № 9. P. 108–123. DOI: 10.1016/j.petlm.2022.03.003.
11. Антонюк В. В. Прогнозування фільтраційно-ємнісних властивостей та класифікація порід-колекторів за комплексом каротажних та петрофізичних даних (на прикладі відкладів верхнього та середнього карбону приосової зони Дніпровсько-Донецької западини): дис. на здобуття наук. ст. доктора філософії: 103 «Науки про Землю». Київ: Київський національний університет імені Тараса Шевченка. 2023. URL: https://scc.knu.ua/upload/iblock/037/5sz8xiks1jqeyupptx7ftprxybqf62x/Dis_Antoniuk_V.pdf (дата звернення: 25.11.2025).
12. Дмитрієва І. С., Дмитренко А. М. Методи штучного інтелекту для прогнозування покладів вуглеводнів з тривимірних сейсмічних зображень. *Системні технології*. 2025. № 4(159). С. 158–165. DOI: [10.34185/1562-9945-4-159-2025-16](https://doi.org/10.34185/1562-9945-4-159-2025-16).

References

1. Schon, J. H. (2011). Physical properties of rocks: A Workbook. (Vol. 8). Elsevier. <http://ndl.ethernet.edu.et/bitstream/123456789/419/1/97.pdf>
2. Bernabe, Y., Mok, U., & Evans, B. (2006). A note on oscillation flow method for measuring rock permeability. *International Journal of Rock Mechanics & Mining Sciences*, 43(2), 311–316. <https://doi.org/10.1016/j.ijrmms.2005.04.013>
3. Tiab, D., & Donaldson, E. (2011). Petrophysic: Theory and practice of measuring reservoir rock and fluid transport properties (2nd ed.). Gulf Professional Publishing. <https://www.geokniga.org/books/40073>
4. Vyzhva, S. A., Bezrodna, I. M., & Kozionova, O. O. (2012). Analiz filtratsiino-iemnisnykh vlastyvostei karbonatnykh porid karbonu Rudenkivsko-Proletarskoho rehionu za rezultatamy petrofizychnykh doslidzhen [Analysis of filtration-volumetric properties of Carboniferous carbonate rocks of the Rudenkivsko-Proletarskyi region based on petrophysical research results]. *Heoinformatyka*, (1), 17–25. <http://jnas.nbuv.gov.ua/article/UJRN-0000039914> [in Ukrainian].
5. Vyzhva, S. A., Mykhailov, V. A., Onyshchuk, D. I., & etc. (2013). Petrofizychni parametry netradytsiinykh porid-kolektoriv Pivdennoho naftohazovoho rehionu [Petrophysical parameters of unconventional reservoir rocks of the Southern oil and gas region]. *Heoinformatyka*, (3), 17–25. <http://jnas.nbuv.gov.ua/article/UJRN-0000025433> [in Ukrainian].
6. Ahmadi, M. A., & Chen, Z. (2019). Comparison of machine learning methods for estimating permeability and porosity of oil reservoirs via petrophysical logs. *Petroleum*, 5(3), 271–284. <https://www.scribd.com/document/419961181/Comparison-of-Machine-Learning-Methods-for-Estimating-Permeabilityand-Porosity-of-Oil-Reservoirs-via-Petro-physical-Logs>
7. Heidari, A. A., Faris, H., Aljarah, I., & etc. (2019). An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*, 23(17), 7941–7958. <https://doi.org/10.1007/s00500-018-3424-2>
8. Saputro, O. D., Maulana, Z. L., & Latief, F. D. E. (2016). Porosity log prediction using artificial neural network. *Journal of Physics: Conference Series*, 739(1), 012092. <https://doi.org/10.1088/1742-6596/739/1/012092>
9. Abdel Azim, R., & Aljehani, A. (2022). Neural Network Model for Permeability Prediction from Reservoir Well Logs. *Processes*, 10(12), 2587. <https://doi.org/10.3390/pr10122587>
10. Matinkia, M., Hashami, R., Mehrad, M., & etc. (2023). Prediction of permeability from well logs using a new hybrid machine learning algorithm. *Petroleum*, 9(1), 108–123. <https://doi.org/10.1016/j.petlm.2022.03.003>
11. Antoniuk, V. V. (2023). Prohnozuvannia filtratsiino-iemnisnykh vlastyvostei ta klasyfikatsiia porid-kolektoriv za kompleksom karotazhnykh ta petrofizychnykh danykh... [Prediction of filtration and storage properties and classification of reservoir rocks...] (Doctoral dissertation). Taras Shevchenko National University of Kyiv. https://scc.knu.ua/upload/iblock/037/5sz8xiks1jqeyupptx7ftprxybqf62x/Dis_Antoniuk_V.pdf [in Ukrainian].
12. Dmytriieva, I. S., & Dmytrenko, A. M. (2025). Metody shtuchnoho intelektu dlia prohnozuvannia pokladiv vuhlevodniv z tryvymirnykh seishmichnykh zobrazhen [Artificial intelligence methods for predicting hydrocarbon deposits from three-dimensional seismic images]. *Systemni tekhnologii*, (4(159)), 158–165. <https://doi.org/10.34185/1562-9945-4-159-2025-16> [in Ukrainian].

USING NEURAL NETWORKS TO ASSESS POROSITY AND PERMEABILITY OF MOUNTAIN ROCKS

Yurchyshyn O. V.

Engineer

The Oilfield Services of JSC Ukrnafta

Pivnichnyi boulevard, 2, Ivano-Frankivsk, 76019, Ukraine

<https://orcid.org/0009-0005-0733-7612>

e-mail: oleh.yurchyshyn@ukrnafta.com

Rozlovska S. Ye.*

Candidate of geological sciences, associate professor

Ivano-Frankivsk National Technical University of Oil and Gas

Karpatska Str., 15, Ivano-Frankivsk, 76019, Ukraine

<https://orcid.org/0000-0002-9259-6774>

e-mail: svitlana.rozlovska@nung.edu.ua

Abstract. The advent of artificial intelligence (AI) and its application in various industries has made it possible to automate and optimise many processes, including those in geophysics. Using AI in geophysical well surveys could transform the way data is collected, processed and interpreted. AI is expected to become a key tool in the oil and gas industry, advancing data modelling and analysis and offering significant benefits in terms of accuracy and efficiency. This paper presents an approach to estimating the porosity and permeability of rocks based on geophysical survey results, using a neural network as the primary tool. Porosity and permeability are key characteristics of reservoir formations and important parameters for design calculations and the development of productive horizons in oil and gas fields. The main difficulty in determining these parameters is that they are dependent on many other factors. Emerging information technologies offer opportunities to identify complex relationships between diverse geological and geophysical parameters. An artificial neural network model has been developed to predict the porosity and permeability coefficients of rocks, based on an in-depth analysis of geophysical data. This approach enables hidden relationships between parameters to be identified that would go unnoticed when applying traditional analytical methods. The study achieved high accuracy in predicting porosity and permeability values, as confirmed by their alignment with the results of laboratory experiments. This demonstrates the effectiveness of using machine learning to automate the analysis of geophysical data, and the proposed approach has significant advantages in terms of speed and accuracy of analysis. This is especially important in situations where laboratory research is impossible or limited. The use of neural networks contributes to a deeper understanding of the impact of various factors on rock porosity and permeability, which is important for decision-making in the process of reservoir development. The novelty of this work is the creation of an integrated approach that combines classical geophysical methods with innovative machine learning algorithms. This combination provides fast and efficient determination of rock porosity and permeability, opening up new opportunities for optimising the processes of field exploration and development.

Keywords: porosity; rock permeability; geophysical research; artificial intelligence; machine learning; neural network; data analysis; research interpretation.