

<https://doi.org/10.31891/2307-5732-2026-361-80>

УДК 004.8:622.276.6

**ПЕТРИШИН РОМАН**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0009-2770-6656>

e-mail: [romeopetryshyn@gmail.com](mailto:romeopetryshyn@gmail.com)

## ІДЕНТИФІКАЦІЯ ЛІТОЛОГІЇ ШЛЯХОМ АДАПТИВНОЇ АГРЕГАЦІЇ ОЗНАК НА ГРАФОВИХ НЕЙРОННИХ МЕРЕЖАХ

*В роботі наведено результати дослідження автоматизованої ідентифікації літології за даними каротажу шляхом використання адаптивної агрегації ознак у моделях графових нейронних мереж, що поєднують вейвлет-аналіз та графові структури для підвищення точності класифікації в умовах обмеженості мічених даних. Запропонований підхід дозволяє зменшити суб'єктивність експертної інтерпретації, скоротити обчислювальні витрати та підвищити надійність геолого-розвідувальних рішень.*

*Ключові слова:* ідентифікація літології, каротажні дані, графові нейронні мережі, адаптивна агрегація ознак, напівконтрольоване навчання, машинне навчання.

**PETRYSHYN ROMAN**

Ivano-Frankivsk National Technical University of Oil and Gas

## LITHOLOGY IDENTIFICATION BY ADAPTIVE FEATURE AGGREGATION ON GRAPH NEURAL NETWORKS

*The current complex problems in the field of geological science and hydrocarbon exploration require the introduction of innovative technologies to improve the prediction of rock lithology. In this context, automatized lithology prediction becomes extremely relevant. The scientific research represented in this article offers an integrated approach that combines modern machine learning methods with the analytical power of graph neural networks. This stack allows for the effective processing of logging data, improving the quality and accuracy of lithological classification processes traditionally performed by experts. Traditional methods of logging interpretation, which rely on the human factor, often result in significant time and resource costs. In addition, differences in the knowledge and experience of different experts can lead to inconsistencies in results. With the increasing volume and complexity of data to be interpreted, it is becoming increasingly important to use new, automated approaches. Besides, wavelet analysis combined with graph structures provides new opportunities for faster and more accurate processing of geological data.*

*The purpose of this study is to improve conventional methods of lithology identification by introducing adaptive feature aggregation into graph neural network models. The well-defined purpose of the study allows us to focus on the possibilities of introducing the latest technologies into the geological modeling process. The structure of the work is logically organized, ensuring consistency and coherence of the presentation. The author have demonstrated a thorough understanding of the subject area, which enhances the value of the obtained scientific conclusions. The article is particularly valuable in that the methods presented can significantly improve accuracy and reduce the risks associated with the exploration process, especially in conditions of limited data. This demonstrates the author's high level of expertise in the subject and his ability to adapt to current challenges in the field. The methodological part of the study is characterized by an ideal combination of theory and practice, which makes the proposed approach understandable and useful for the scientific community. A significant advantage is the development of algorithmic principles that take into account the specific needs and limitations when working with logging data. This is a significant contribution to solving the problem of computational complexity that often arises in the context of geological exploration. The scientific novelty of the research consist in the implementation of adaptive methods that open up new perspectives in the automation of learning processes based on the collection of identification signals.*

*Consequently, this scientific article is intended not only to improve the accuracy and reliability of lithological identification, but also to contribute to the improvement of existing approaches to geological research. Provided results can be effectively integrated into the practice of modern geological exploration, demonstrating broad potential for further development in this area.*

**Keywords:** lithology identification, logging data, graph neural networks, adaptive feature aggregation, semi-supervised learning, machine learning.

Стаття надійшла до редакції / Received 13.12.2025

Прийнята до друку / Accepted 11.01.2026

Опубліковано / Published 29.01.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Петришин Роман

### Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

Ідентифікація літології за даними каротажу є ключовою задачею геофізичної інтерпретації, від якої безпосередньо залежать якість побудови геологічних моделей, оцінка продуктивності пластів та економічна обґрунтованість рішень у розвідці та розробці родовищ. Традиційні підходи, що базуються на експертній інтерпретації логів, виявляються малоефективними при складній будові колекторів і великому обсязі даних. Саме вони потребують значних часових витрат, що схильні до суб'єктивності та призводять до неоднорідності результатів між різними фахівцями. Використання методів машинного та глибинного навчання частково зменшує ці обмеження, проте моделі з навчанням під наглядом критично залежать від великої кількості якісно промаркованих кернами вибірок, що у практиці буріння є дорогим і обмеженим ресурсом. Додатково складність створюють нелінійність та багатовимірність логів, дисбаланс класів літологій, а також просторові залежності вздовж стовбура свердловини, що не враховуються більшістю класичних алгоритмів. Напівконтрольовані графові методи дають змогу залучати немарковані дані, але фіксована структура графа та некоректно задана подібність між зразками призводять до накопичення помилок і деградації якості класифікації. Тому, актуальною науковою та прикладною проблемою є розроблення методів ідентифікації літології, здатних працювати в умовах дефіциту міток, можливості враховувати геологічну структуру пласта та адаптивно регулювати зв'язки між вибіркою на основі їхніх ознак і глибин.

**Аналіз досліджень та публікацій**

У роботі [1] дослідниками наведено підхід до розв'язання задачі оптимальної фільтрації для лінійних гаусових систем із різними частотами оновлення станів та вимірювань. У дослідженні авторами розглядається ситуація, коли внутрішній стан об'єкта оновлюється значно частіше, ніж надходять вимірювальні дані, причому співвідношення між цими частотами є сталим. На цій основі дослідники формують асинхронний фільтр самоналаштування, що у моменти надходження вимірювань забезпечує оцінювання стану в сенсі лінійного мінімального середньоквадратичного відхилення. Додатково враховується змінність статистичних характеристик шумів, для чого в структуру фільтра вводиться регулятор, що адаптивно коригує фільтраційні коефіцієнти. Наведені приклади застосування до навігації колісного робота та оцінювання якості повітря демонструють інженерну придатність такого підходу. Отримані результати дослідження є суттєво важливими для нашого дослідження у якості концептуальної бази побудови адаптивних алгоритмів обробки даних у складних динамічних системах.

У роботі [2] представлено підхід до підвищення ефективності буріння в складних глибоких пластах за рахунок попереднього прогнозування літології для раціонального вибору бурового інструменту. Автори модернізують класичну нейромережеву модель зворотного поширення помилки, удосконалюючи схему корекції ваг, впроваджуючи самоадаптивні механізми навчання та змінюючи функції активації, після чого реалізують окремий програмний модуль для практичного застосування. Запропонована модифікована BP-модель продемонструвала працездатність при прогнозуванні літології ще не пробурених інтервалів реального газового родовища, що підтверджує її придатність як інженерного інструменту. В межах нашого дослідження ця праця важлива тим, що демонструє цілеспрямоване удосконалення стандартних нейромережевих архітектур та їх адаптацію до специфіки геологічних даних, що дозволяє суттєво покращити якість автоматизованої інтерпретації та створює підґрунтя для подальшої інтеграції більш складних моделей у задачі ідентифікації літології.

У роботі [3] представлено підхід до підбору оптимального алгоритму машинного навчання для задачі ідентифікації літології за даними каротажу, орієнтований на використання інформації як зі стандартних вимірювань, так і з каротажу під час буріння. Автори розглядають порівняння кількох поширених класифікаторів – двох варіантів опорних векторних машин та моделі випадкового лісу – з позицій придатності до роботи в умовах реального часу. Навчальні ознаки формуються шляхом відбору найбільш інформативних каналів каротажу на основі кореляційного аналізу, а параметри моделей налаштовуються через сітковий пошук і перехресну валідацію. На цій основі здійснюється прогноз літології для реальних даних під час буріння, а вибір найкращої моделі ґрунтується на поєднанні двох критеріїв: точності класифікації та часу навчання. Показано, що метод випадкового лісу забезпечує вищу загальну якість розпізнавання та прийнятну швидкість порівняно з варіантами опорних векторних машин, що дозволяє розглядати його як практичний інструмент для оперативної геонавігації. Для нашого дослідження ця праця є важливою тим, що демонструє доцільність поєднання попереднього відбору ознак із систематичним порівнянням різних моделей, а також підкреслює необхідність урахування обчислювальних витрат при створенні алгоритмів автоматизованої ідентифікації літології.

У роботі [4] досліджується застосування альтернативного нейромережевого підходу до розпізнавання літофацій як заміни класичної машини опорних векторів, яка страждає від повільного навчання та складного підбору параметрів. Автори використовують алгоритм одношарової мережі прямого поширення з аналітичним обчисленням ваг, що дозволяє суттєво спростити налаштування моделі й прискорити навчання без помітної втрати якості класифікації. Порівняння з традиційним SVM показує співставну точність за значно менших обчислювальних витрат. Для нашого дослідження це важливо як аргумент на користь використання легших у налаштуванні моделей у задачах класифікації літологічних об'єктів.

Дослідження [5] характеризується спробою подолати обмеження класичного лінійного дискримінантного аналізу в задачі ідентифікації літології, де вирішальну роль відіграють саме нелінійні залежності у просторі ознак. Автори використовують підхід, що спочатку відображає вихідні дані у простір вищої розмірності для «виявлення» нелінійної структури, а потім виконує зменшення розмірності з фокусом на ознаках, релевантних класифікації. Порівняння з лінійними та класичними нелінійними дискримінантними методами на реальних даних показує кращу здатність такого підходу виокремлювати літологічні класи. Для нашого дослідження це важливо як підтвердження доцільності використання методів, що явно враховують нелінійність простору ознак при побудові моделей ідентифікації літології.

У науковій праці [6] досліджується використання згорткових нейронних мереж для задачі інтерпретації літології, яка формулюється як контрольована класифікація за каротажними даними. Автори звертають увагу, що попри успіх CNN у комп'ютерному зорі, їх застосування до каротажних кривих ускладнюється відмінністю формату даних: мережі очікують багатошарове зображення, тоді як логи подані як послідовності чисел. Для подолання цієї невідповідності пропонується метод побудови «зображення» для кожної точки каротажу на основі вейвлет-розкладу, що перетворює задачу літологічної інтерпретації на задачу розпізнавання образів. Апробація на реальних свердловинах показує високу якість результатів. Цей підхід є цінним для нашого дослідження тим, що демонструє ефективність попереднього перетворення каротажних даних у формат, придатний для глибоких моделей, і відкриває можливість використання зрілих архітектур CNN у галузі автоматизованої інтерпретації літології.

Особливості аналізу [7] полягають у розробленні напівконтрольованого підходу до ідентифікації літології в умовах дефіциту прямих лабораторних даних, коли відсутні керни та буровий шлам. Автори

пропонують дерево-рішень як базову модель, акцентуючи на його інтерпретованості для оцінки ризиків, та вводять механізм генерації псевдоміток для немаркованих зразків, спираючись одночасно на близькість у просторі ознак і за глибиною. Додатково розв'язується проблема ручного задання спорідненості між зразками шляхом її автоматизованого наближення на основі кількох припущень про гладкість. У сукупності це дає стійку до неточних налаштувань класифікаційну модель із прозорою логікою прийняття рішень, що важливо для нашого дослідження як приклад поєднання напівконтрольованого навчання з вимогою пояснюваності результатів.

Дослідження, запропоноване автором [8], передбачає систематичний виклад основ теорії графів як інструменту дискретної математики з одночасним акцентом на строгих доведеннях і практичних застосуваннях. У роботі наголошується на важливості вибору послідовності тем, формулюванні ключових ідей та доборі доказів, що відображає відсутність усталеного «канонічного» підходу до введення в теорію графів. Для нашого дослідження цей внесок цінний тим, що підкреслює роль графових структур як універсального апарату моделювання й аналізу, на який доцільно спиратися при побудові графових моделей і алгоритмів у задачах обробки геологічних та каротажних даних.

Акцент дослідників [9] на проблемі розбіжності розподілу даних між різними свердловинами характеризує перехід від локальних моделей машинного навчання до більш узагальнених рішень для інтерпретації каротажу. Автори формалізують задачу калібрування геофізичних кривих і пропонують метод одностороннього вирівнювання як інструмент безнаглядної адаптації ознак між доменами, що дозволяє узгоджувати логи окремих свердловин без залучення кернових міток і без втрати фізичного змісту. Експериментальні результати на кількох свердловинах і різних задачах підтверджують, що такий підхід підвищує стійкість моделей до змін розподілу й зберігає інтерпретованість. Для нашого дослідження це важливо як орієнтир на необхідність урахування доменної адаптації при побудові графових та напівконтрольованих моделей ідентифікації літології.

Дослідження [10] нових архітектур нейронних мереж зосереджене на побудові моделей, що працюють безпосередньо з графовими даними та вміють по-різному зважувати внесок сусідніх вузлів. Автори пропонують підхід на основі механізму уваги, у якому кожен вузол «обирає», на які сусіди більше орієнтуватися при оновленні свого представлення, без дорогих спектральних обчислень і жорсткої прив'язки до зафіксованої структури графа. Показано, що такі мережі уваги на графах забезпечують кращі результати як у задачах класифікації вузлів на відомих графах, так і в індуктивних сценаріях, де тестові графи не присутні на етапі навчання. Для нашого дослідження це є ключовим теоретичним підґрунтям для використання механізмів уваги в графових моделях ідентифікації літології.

У науковому дослідженні [11] дослідники розглядають, як графові нейронні мережі можуть підвищити якість персоналізованих рекомендацій, якщо враховувати не лише структуру взаємодій «користувач–об'єкт», а й багатомодальні ознаки самих об'єктів (текст, зображення, звук). Автори показують, що просте агрегування інформації від усіх сусідів без розрізнення важливості різних модальностей призводить до накопичення шуму та нестійких представлень. Для вирішення цієї проблеми пропонується мультимодальна графова мережа з увагою, яка на кожному кроці поширення інформації окремо оцінює вагу кожної модальності для конкретного користувача, фактично «розплутуючи» його інтереси за каналами даних. Експериментальні результати на реальних наборах рекомендацій демонструють суттєве покращення точності порівняно з попередніми графовими моделями. У контексті нашого дослідження це підкріплює доцільність використання механізмів уваги в графових моделях для вибіркового врахування різних груп ознак і побудови більш інформативних представлень вузлів.

Кластеризація [12] розглядається через призму виявлення невеликої множини репрезентативних об'єктів, навколо яких формуються кластери. Автори інтегрували метод поширення спорідненості, що працює не з вихідними координатами, а з матрицею подібності між парами точок. Алгоритм організовує обмін числовими «повідомленнями» між об'єктами, у результаті чого автоматично виокремлюються зразки та відповідні їм групи без потреби складного попереднього ініціювання. Показано, що такий підхід на різних прикладних даних забезпечує меншу похибку класифікації та значно менший час обчислень порівняно з традиційними методами. Для нашого дослідження цей підхід важливий як ефективний інструмент побудови кластерів та виявлення представницьких зразків при роботі з багатовимірними каротажними даними.

Наукова праця [13] присвячена проблемі побудови векторних подань вузлів у великих графах у ситуації, коли частина вузлів з'являється вже після етапу навчання моделі. Автори пропонують індуктивний підхід, у якому замість фіксованих вбудовувань для кожного вузла навчається узагальнена функція формування подання шляхом вибіркової агрегації ознак із локального оточення. Використання вихідних атрибутів вузлів дозволяє генерувати вбудовування для раніше невідомих об'єктів і навіть для повністю нових графів. Порівняння з трансдуктивними методами на різних наборах даних показує кращу здатність такого підходу до узагальнення. У нашому дослідженні ці результати є методологічним орієнтиром для побудови графових моделей, здатних працювати з новими свердловинами та літологічними інтервалами без повного перенавчання.

Дослідження міждоменої ідентифікації літології [14] зосереджене на ситуації, коли модель потрібно перенести з однієї свердловини на іншу, для якої відсутні або майже відсутні мітки. Автори підкреслюють дві ключові проблеми: відмінність розподілів каротажних даних між свердловинами та високу вартість отримання нових літологічних міток. Для їх подолання запропоновано поєднання активного навчання та адаптації домену, де, з однієї сторони, цілеспрямовано відсортовуються найбільш «інформативні» зразки для ручного

маркування, а з іншої – отримані мітки використовуються для переважування вихідних даних і зменшення доменної розбіжності. Як результат стверджується, що такий підхід дозволяє утримувати якість класифікації за мінімальною кількістю нових міток, що є показовим для нашого дослідження в частині побудови моделей, стійких до змін умов між різними свердловинами.

Наукове дослідження [15] зосереджене на застосуванні контрольованих методів машинного навчання для класифікації літологій за багатомірними каротажними даними морських свердловин. Автори формують узагальнену схему групування літологій у кілька категорій і будують різні «шаблони» наборів даних, щоб перевірити стійкість моделей у геологічно відмінних умовах. Порівнюються кілька алгоритмів – багатошаровий перцептрон, дерево рішень, випадковий ліс та машина опорних векторів – із розподілом вибірки на навчання, валідацію та тест. Для нашого дослідження ці висновки важливі як підтвердження ефективності класичних ансамблевих та нейромережових методів при роботі з різнорідними каротажними наборами й необхідності адаптації вибору моделі до конкретних даних і сценарію застосування.

#### Формулювання цілей статті

Метою роботи є: дослідження та розроблення напівконтрольованої графової моделі ідентифікації літологій на основі адаптивної агрегації ознак каротажу, побудова геологічно осмисленої графової структури даних із використанням подібності за глибиною та ознаками й алгоритму поширення спорідненості, застосування та порівняння архітектур GraphSAGE і графових мереж уваги для формування вбудовуваних вузлів та динамічного налаштування ваг ребер, оцінка точності, стійкості до дисбалансу класів і дефіциту міток за допомогою узгоджених метрик класифікації, а також обґрунтування доцільності використання запропонованого підходу як основи для автоматизованої, більш точної та оперативної інтерпретації літологій свердловин.

#### Виклад основного матеріалу

Метою інтерпретації каротажу є отримання геологічної інформації, такої як літологія, вміст сланців, проникність тощо. Традиційна робота з інтерпретації, як правило, виконується експертами, тому складна геологічна структура нетрадиційних колекторів може спричинити великі, але непотрібні витрати часу. Крім того, різні знання про колектори, результати інтерпретації каротажу свердловин, які аналізують різні експерти, можуть бути неспівпадливими. Зі збільшенням кількості та складності даних каротажу висуваються більш високі вимоги до якості їх інтерпретації, виявляються недоліки традиційних методів. Таким чином, звертаються до вивчення більш розумних і швидших методів інтерпретації каротажу.

У процесі розвідки та розробки нафти розподіл літологій, отриманий зі свердловин, є важливим показником для характеристики пласта. Після попередньої обробки геофізичних каротажів за допомогою деяких методів фільтрації каротажі можна використовувати для отримання геологічної інформації (наприклад, літології, пористості) уздовж траєкторії буріння [1]. Таку процедуру часто називають інтерпретацією каротажу та ідентифікацією літології, яка є одним із найважливіших засобів дослідження нафтових пластів. До цього часу було зроблено багато спроб застосувати інструменти машинного навчання (ML) для вирішення завдань ідентифікації літології, які могли б створити модель інтерпретації автоматично на основі даних, а не трудомістку ручну інтерпретацію [2,3]. Було багато робіт з ідентифікації літології, які застосовують підходи ML, такі як ANN, SVM, ELM та інші [4,5]. Крім того, існує також багато досліджень із використанням глибокого навчання (DL) для ідентифікації літології, особливо методів на основі загорткової нейронної мережі (CNN) [6].

Згідно з порівняльними експериментами, випадковий ліс підтверджено найкращим класифікатором для ідентифікації літології під час буріння, який демонструє більш швидке навчання та вищу точність. ELM є добрим класифікатором для прогнозування літології даних каротажу свердловин. Лінійний дискримінантний аналіз (LDA) можна використовувати лише для виділення лінійних характеристик, але він не підходить для нелінійних даних каротажу свердловин. Для ідентифікації літології застосовують ядерний дискримінантний аналіз Фішера, який може класифікувати дані нелінійного каротажу свердловин [9]. Запропоновано також метод машинного навчання для калібрування невідповідності розподілу між свердловинами, тим самим покращуючи ефективність ідентифікації літофацій [10].

Методи, згадані вище, можна класифікувати як парадигми навчання під наглядом, які потребують масивних мічених даних під час навчання, у той час як кількість навчальних даних сильно залежить від продуктивності моделі. Однак на продуктивність підходу, заснованого на навчанні, впливає якість набору даних. Наприклад, випадок дефіцитних міток (тобто через високу вартість аналізу кернів) і дисбаланс класу (тобто неоднорідність розподілу порід), що є однією з головних проблем для наборів даних каротажу. В останні роки було запропоновано деякі напівкеровані методи навчання для цього випадку ідентифікації літології, і їхня ефективність була певною мірою доведена [7]. Зокрема, нестача літологічних міток і дисбаланс класів серйозно впливають на ефективність навчання під наглядом. Навпаки, напівконтрольоване навчання може покращити ефективність ідентифікації літології шляхом введення попередньої інформації з журналів замість кернів. Граф є корисним інструментом для покращення ефективності ідентифікації, особливо у випадку дефіцитних літологічних міток, шляхом використання попередньої інформації між зразками (наприклад, подібності ознак і глибин).

Граф – це структура, що становить набір об'єктів, у якому деякі пари об'єктів певним чином «пов'язані». Об'єкти відповідають математичним абстракціям, які називаються вузлами, а кожна з пов'язаних пар вузлів називається ребром [8]. Граф записується так:

$$G = (V, E),$$

де  $V$  – вузол, що представляє об'єкт дослідження,  $E$  – ребро, що представляє конкретні відносини між об'єктами. Графи поділяються на орієнтовані та неорієнтовані. Кількість ребер, що з'єднують вузол у графі, називається степенем вузла. Кількість спрямованих ребер, що починаються з вузла, називається степенем назовні вузла, а кількість спрямованих ребер, що закінчуються у вузлі, називається степенем всередину вузла. Степінь вузла є сумою вхідних і зовнішніх степенів. У деяких випадках кожен вузол має вектор ознак, і вектори ознак усіх вузлів складають матрицю ознак графа. Отже, граф також можна розділити на структуру графа та матрицю ознак. У звичайних каротажах для ідентифікації літології, якщо глибина відбору проб, інтервал між двома точками даних становить 0,125 м, береться як вузол, між вузлами не буде жодного чіткого зв'язку. Тому надзвичайно важливо встановити структуру графа, придатну для ідентифікації літології. Метод побудови графа в основному базується на наступних двох моментах: 1) структура графа повинна базуватися на загальній седиментації пласта і повинна мати певне геологічне значення; 2) вузли з однаковою літологією повинні мати з'єднання.

На основі цих двох пунктів процес побудови графа складається з двох етапів: спочатку вузли сортуються на основі послідовності глибини, а пари суміжних вузлів глибини з'єднуються ребрами. Завдяки безперервному процесу осаконакопичення кожен вузол на певній глибині має літологічну подібність із просторовими сусідніми вузлами. Таким чином, не тільки побудований граф відображає вертикальний просторовий розподіл фактичної товщі, але також будуть з'єднані вузли з однаковою літологічною міткою на суміжних глибинах. Вузли групуються з несуміжною глибиною за допомогою алгоритму поширення спорідненості (AP), щоб обчислити евклідову відстань між вузлами в кожній групі на основі нормалізованих кривих каротажу. Для цього вибирають відповідний квантиль, визначаючи співвідношення між вузлами відповідно до евклідової відстані від малого до великого. Процес утворює зв'язок між цими вузлами зі схожими характеристиками кривої каротажу, але не суміжними по глибині, тоді як ці з'єднані вузли можуть мати однакові літологічні мітки.

Графова нейронна мережа (GNN) – це потужна нейронна мережа для напівконтрольованого навчання, яка має переваги традиційного графового методу напівконтрольованого навчання та нейронної мережі. Крім того, GNN не лише використовує інформацію, що міститься на графі, для покращення ефективності класифікації у випадку дефіцитних міток, але також може витягувати нелінійні функції, як традиційні нейронні мережі. Для подальшого вдосконалення можливостей вилучення ознак використовуються згорткові мережі графів (GCN) шляхом використання оператора згортки на графах. Вибір згорткових архітектур мотивований локалізованими апроксимаціями першого порядку згорток спектральних графів. Таким чином, ця модель може вивчати представлення прихованих шарів, які кодуєть структуру локального графа та особливості вузла. Розглядаючи негативні наслідки графа, що містить помилки, які зазвичай існують у моделі графа, пропонують мережу звернення уваги на граф (GAT), яка дозволяє динамічно вивчати вагу ребер за допомогою замаскованих шарів само уважності [11]. Отже, немає необхідності маніпулювати матрицею та проектувати структуру графа заздалегідь. Розширенням GAT є мережа уваги мультимодального графа, заснована на графі мультимодальної взаємодії, яка може фіксувати більш складні шаблони взаємодії, приховані в поведінці користувача, і надавати більш точні рекомендації [12].

Розглянемо використання методу графовой нейронної мережі (GNN) під назвою GraphSAGE для навчання моделі ідентифікації літології. Процес навчання ідентифікації літології виглядає наступним чином: після введення створеного графа в модель перший шар графовой нейронної мережі GraphSAGE використовується для побудови матриці вбудовування  $H_1$ , яка об'єднує як початковий вектор ознак вузлів, який є добре стандартизованим каротажем, так і інформацію про локальну структуру графа, яка їх оточує. Потім матриця вбудовування  $H_1$  активується функцією  $F$  і використовується як вхідні дані наступного рівня GraphSAGE для другого об'єднання інформації для отримання матриці вбудовування  $H_2$ . У процесі оновлення представлення вузлів після  $n$  разів кінцевий результат класифікації отримується шляхом розрахунку матриці вбудовування  $H_n$  з шаром Softmax.

Поширення спорідненості (AP) – це метод кластеризації, заснований на концепції «передачі повідомлень» між точками даних [13]. Основна концепція цього методу полягає в тому, щоб розглядати всі зразки як вузли в мережі, а потім обчислювати центр кластеризації кожного зразка через передачу повідомлень кожного краю в мережі. І AP, і  $k$ -середні класифікують групи за визначенням відстаней. Однак, оскільки AP використовував ідею передачі повідомлень, він міг отримати кращу загальну квадратичну помилку, ніж  $k$ -середні, і здатність кластеризації також значно покращилася, особливо підходить для кластеризації багатовимірних і багатотипних даних. У процесі кластеризації AP існує два типи передачі повідомлень між вузлами: відповідальність і доступність. За допомогою кількох ітерацій відповідальність і доступність вузлів постійно оновлюються, доки не буде створено кілька зразків, а решта вузлів буде призначено відповідним групам.

AP має такі переваги: 1. Немає необхідності вказувати кількість кластерів, що робить попередній досвід непотрібною умовою та розширює сферу застосування; 2. Нечутливий до початкового значення і не потребує вибору випадкового початкового значення; 3. Має малу загальну квадратичну похибку. Суть ідентифікації літології полягає в класифікації вузлів на графі. GraphSAGE – це алгоритм пакетного навчання для згортання графів [14]. Він вибирає сусідні вузли кожного кореневого вузла, розширює суміжні вузли кореневих вузлів на  $k$  кроків і оновлює представлення кореневих вузлів шляхом агрегування представлень прихованих вузлів

ієрархічно від сусідніх вузлів до кореневих вузлів. Цей процес називається вбудовуванням вузла. Основна ідея вбудовування вузлів полягає у вилученні багатовимірної інформації сусідів кореневих вузлів у щільні векторні вбудовування за допомогою методу зменшення розмірності. Потім ці вбудовані вузли надсилаються до системи машинного навчання, що йде далі, і допомагають виконувати завдання класифікації вузлів, кластеризації та прогнозування зв'язків. Конкретний процес вбудовування можна виразити такими формулами:

$$\begin{aligned} h_{N(v)}^k &= \phi_k(h_u^{k-1}), \forall u \in N(v), \\ h_v^k &= \sigma(W^k \varphi(h_u^{k-1}, h_{N(v)}^k)). \end{aligned} \quad (1)$$

Перша формула представляє агрегацію інформації сусідніх вузлів. Друга формула представляє подання оновлення інформації кореневих вузлів.  $h_{N(v)}^k$  – агреговані вектори,  $h_u^{k-1}$  – сусідній вузол кореневого вузла,  $N(v)$  – сусідні вузли кореневих вузлів,  $h_v^{k-1}$  – поточне представлення кореневого вузла,  $W^k$  – вагова матриця  $k$ -го шару,  $\sigma$  – функція активації,  $\varphi(\cdot)$  – функція конкатенації,  $\phi(\cdot)$  – агрегуюча функція. Функція агрегування включає поелементне середнє, довготривалу короткочасну пам'ять (LSTM) і об'єднання.

Наведені вище формули містять концепцію передачі повідомлень, розділену на агрегацію та оновлення векторів ознак вузлів. Візьмемо літологічну ідентифікацію як приклад, щоб пояснити ці два процеси. Агрегація векторів ознак полягає в тому, що кожен вузол збирає інші вектори ознак від своїх сусідів за допомогою еквіваріантної функції перестановки [14]. Припустимо, що вузол «0» є кореневим вузлом, вузли «1» і «2» є сусідами з одним переходом вузла «0». Процес підготовки першого рівня розділений на два етапи. Перший крок полягає в тому, що вектори ознак  $x_1, x_2$ , відповідні вузлам «1» і «2», агрегуються за допомогою функції агрегування поелементного середнього для отримання вектора повідомлення. Другим кроком є функція оновлення, де кореневий вузол «0» об'єднує вектор повідомлення зі своїм власним вектором ознак для створення нового вектора  $h_0^1$ . Вкладення, отримані після оновлення ознак усіх вузлів, об'єднуються в матрицю вкладення  $H_1$ . Після активації функцією активації вбудована матриця виводиться на другий рівень. Процес навчання схожий на перший шар. Вбудовування  $h_1, h_2$ , що відповідають сусіднім вузлам із двома переходами «1» та «2», агрегуються для отримання вектора повідомлення, який поєднується з  $h_0^1$  для оновлення представлення вузла «0». Оскільки  $h_1^1, h_2^1$  містять інформацію вузлів «5», «6» і «3», «4» відповідно,  $h_0^2$  містить інформацію не тільки про сусідів з одним проміжком «1», «2», а й про сусідів з двома проміжками «5», «6», «3», «4». Встановлення  $n$  рівнів еквівалентно агрегації інформації сусідніх вузлів  $n$ -стрибками. Оскільки GraphSAGE належить до напівконтрольованого навчання, він працює за наступних двох умов: усі дані (марковані та немарковані) відбираються з одного граничного розподілу, а дві ближчі вибірки, швидше за все, потрапляють до одного класу. Остання умова добре відома як припущення гладкості (або різноманітності) [15].

Згідно з концепцією проходження повідомлень і припущеннями, згаданими вище, результати навчання двох вузлів, з'єднаних у графі, впливають один на одного і, як правило, поділяються на ту саму літологію. Дані журналу, які необхідно передбачити, також повинні бути залучені до побудови графа. Для того, щоб оцінити валідність моделі, необхідно встановити уніфікований індекс оцінки, щоб оцінити здатність моделі ідентифікувати літологію. Для багатокласифікаційної задачі ідентифікації літології матриця похибок використовується для оцінки результатів ідентифікації моделі, включаючи TP (істинний позитивний), FP (хибний позитивний), FN (хибний негативний) і TN (істинний негативний), які відповідно представляють кількість правильно ідентифікованих позитивних зразків, кількість негативних зразків, неправильно визначених як позитивні зразки, кількість позитивних зразків, неправильно визначених як негативні зразки, і кількість правильно ідентифікованих негативних зразків [16].

Точність (Ac) визначається як відношення кількості правильно класифікованих зразків до загальної кількості зразків:

$$Ac = \frac{TP+TN}{TP+TN+FP+FN}. \quad (2)$$

Для моделі ідентифікації літології точність може представляти лише загальну здатність класифікатора для всіх зразків, але не може відображати здатність класифікатора для кожної літології. Точність (Pr) визначає відношення кількості правильно ідентифікованих позитивних зразків у класі зразків до загальної кількості правильно ідентифікованих позитивних зразків і негативних зразків, неправильно визначених як позитивні:

$$Pr = \frac{TP}{TP+FP}. \quad (3)$$

Чим вища точність, тим менше зразків іншої літології помилково ідентифікуються. Відкликання (Re) визначає відношення кількості правильно ідентифікованих позитивних зразків у класі зразків до загальної кількості правильно ідентифікованих позитивних зразків і позитивних зразків, неправильно визначених як негативні:

$$Re = \frac{TP}{TP+FN}. \quad (4)$$

Чим вище відкликання, тим менше зразків помилково ідентифікують як інші літології. Відповідно до процесу побудови графової структури та принципу GraphSAGE, робочий процес ідентифікації літології за допомогою GraphSAGE узагальнено (рис. 1).

Перш за все, звичайні каротажі свердловин, позначені наявними кернами, після стандартизації розподіляються на дані навчання та тестування випадковим чином у певному співвідношенні. По-друге, на основі послідовності глибин і методу кластеризації AP будується структура графа, а стандартизована крива каротажу використовується як матриця ознак. Нарешті, GraphSAGE використовується для навчання

побудованого графа. Після визначеної кількості ітерацій навчена модель ідентифікації літології застосовується до даних тестування та сліпої свердловини, щоб перевірити надійність моделі.

Незважаючи на те, що ці напівконтрольовані методи на основі графів певною мірою покращують продуктивність, у них є головна проблема, тобто сили з'єднання (краї) серед зразків фіксуються перед навчанням. Очевидно, що неминуче існують деякі невідповідні налаштування подібності, наприклад у разі використання подібності глибини до зразків прикордонного шару та деякі зразки належать до іншої літології, але мають схожість ознак. У цьому випадку ці фактори спонукають розглянути можливість динамічного коригування цих сильних сторін подібності за допомогою графової мережі уваги (GAT).

Розглянемо напівконтрольований метод, заснований на графовій мережі уваги GAT (Graph Attention Network) для ідентифікації літології за допомогою даних каротажу [11]. Цей метод може вивчати вагові коефіцієнти ребер і уникнути перешкод через помилку початкових вагових коефіцієнтів ребер. Схожість характеристик і глибини використовується в GAT для встановлення зв'язків між даними журналу та перетворення їх у дані структури графів.

Кількість мічених даних каротажу свердловин (LD) для ідентифікації літології обмежена через високу вартість отримання керн, тоді як існує маса немаркованих даних каротажу (UD), які містять цінну інформацію для побудови моделі ідентифікації літології.

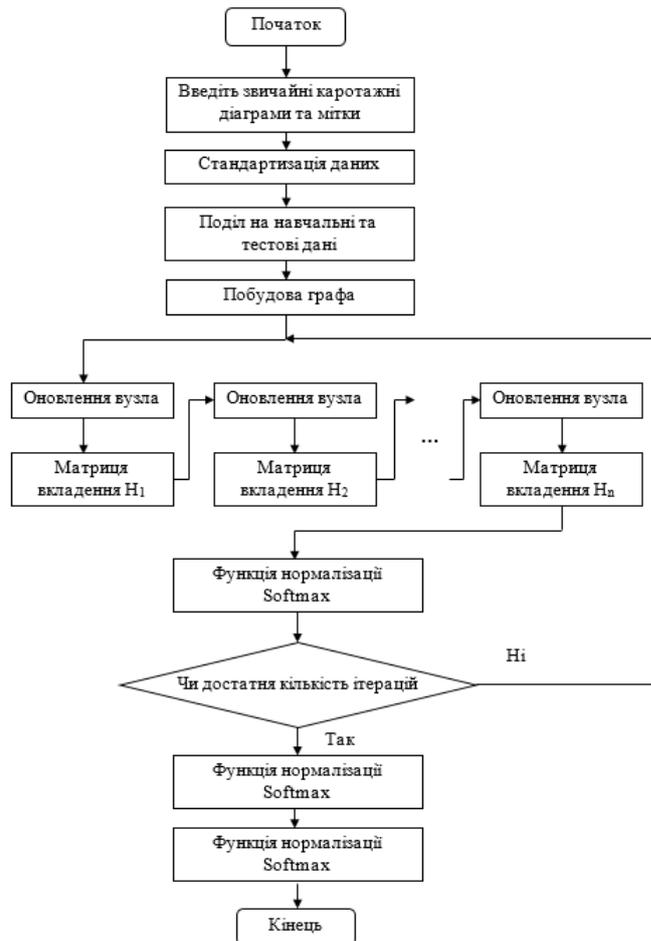


Рис. 1. Блок-схема ідентифікації літології на основі алгоритму GraphSAGE

Загальна основа для напівконтрольованого навчання показана на рис. 2. На відміну від навчання та тестування лише під наглядом на LD, алгоритм напівконтрольованого навчання може використовувати UD і менше LD для створення моделі, яка забезпечує кращу продуктивність порівняно з використанням лише LD. Дані каротажу можна представити у вигляді

$$D_l = \{(x_i, y_i), i = 1, \dots, l\}, D_u = \{x_i, i = l + 1, \dots, N\}, \quad (5)$$

де  $D_l$  і  $D_u$  відповідно представляють LD і UD,  $x_i \in R^{1 \times d}$  зазвичай вважається вектор, утворений кривою каротажу,  $y_i \in \{1, \dots, c\}$  представляє відповідну літологічну мітку ( $c$  вид літології), об'єднання даних може бути визначено  $D = \{D_l, D_u\}$ . Отримання міток  $D_u$  передбачає реалізацію кроків. Спочатку попередньо оброблені дані журналу перетворюються на структуровані на графіку дані за допомогою подібності ознак і глибини між зразками. Згодом структуровані на графіку дані відображаються лінійним шаром. Процеси наступних кроків описують, що крайові коефіцієнти відображених графоструктурованих даних оновлюються за допомогою механізму уваги, таким чином агрегуючи інформацію про підключених сусідів (включаючи мічені та не мічені) до вузлів та оновлення самих вузлів. На останньому кроці класифікація вузла виконується

на оновленому графіку, а параметри оптимізовано відповідно до класифікаційних втрат. Нарешті, кроки повторюються, доки втрати не стануть меншими за порогове значення, отримуючи таким чином остаточну модель.

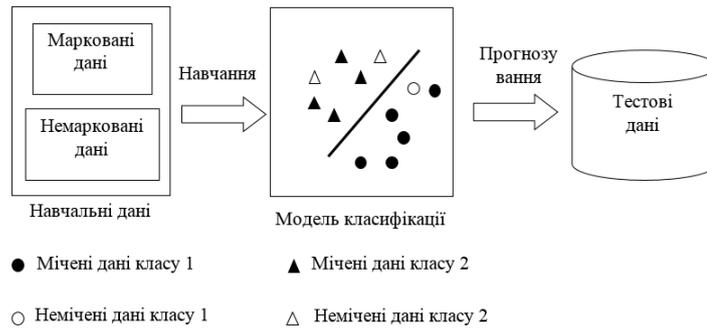


Рис. 2. Схема напівконтрольованого навчання

Напівконтрольоване навчання в основному використовує додаткову інформацію на додаток до даних міток для підвищення точності класифікації, і необхідна додаткова інформація зазвичай пов'язана з прийнятою стратегією. Додаткова інформація для напівконтрольованої класифікації витягується через асоціацію між зразками, яка розглядається з наступних двох точок зору.

Перша точка зору – це розгляд на рівні функції. Зразки зі схожими характеристиками зазвичай належать до одного класу, тому є природною ідеєю побудувати асоціації для зразків із подібними ознаками. Коли два зразки достатньо схожі, призначається зв'язок між ними. Однак під час встановлення порогу схожості виникають деякі проблеми. Наприклад, широко поширені зразки аргіліту можуть дуже відрізнятися від інших, тоді як галькові пісковики з відносно меншою кількістю зразків тісно розподілені в просторі ознак. Коли встановлено відносно високе порогове значення, доступна інформація про зразки галькового пісковика буде більшою, ніж про зразки аргіліту, і результати класифікації можуть бути упередженими. Якщо використовується низький поріг, це може призвести до того, що зразки галькового пісковика мають занадто багато зв'язків з іншими класами, що призведе до зниження точності класифікації. Для вирішення цієї проблеми метод вибирає  $K$  зразків, які найбільше схожі на кожен зразок для побудови зв'язків. Водночас використовується матриця суміжності для представлення зв'язку між двома зразками:

$$A_{ij} = \begin{cases} 1, & x_j \in N_{f,K}(x_i), \\ 0, & \text{в іншому випадку,} \end{cases} \quad (6)$$

де  $N_{f,K}(x_i)$  є набором  $K$  найближчих зразків  $x_j$  у просторі ознак за мірою евклідової відстані, яку можна визначити як  $\|x_i - x_j\|_2$ ;  $x_i$  розглядається як вектор, утворений кривою каротажу.

Друга точка зору – з глибинного рівня. Розподіл літології не є повністю розсіяним і переплетеним, тобто розподіл є безперервним, тому однакові зразки літології об'єднуються в сегменти вздовж напрямку глибини. Іншими словами, якщо два зразки з однієї свердловини знаходяться досить близько, то вони, ймовірно, мають однакову літологію, тому метод створює зв'язки для сусідніх зразків. З іншого боку, два зразки досить близькі, щоб мати приблизно однакове осадове середовище, і перебування в подібному осадовому середовищі також є ознакою зв'язку. Таким чином, є інший спосіб побудови зв'язків:

$$A_{ij} = \begin{cases} 1, & x_j \in N_{d,K}(x_i), \\ 0, & \text{в іншому випадку,} \end{cases} \quad (7)$$

де  $N_{d,K}(x_i)$  є набором  $K$  найближчих зразків  $x_j$  за мірою глибини.

Як показано на рис. 2.5, якщо зразки розглядати як вузли, а з'єднання між зразками – як краї, дані каротажу свердловини можуть бути перетворені в дані, структуровані на графіку. Використовується метод матриці суміжності для представлення даних, структурованих у графі, тобто дані та їх матриця суміжності використовуються для представлення структури графа.

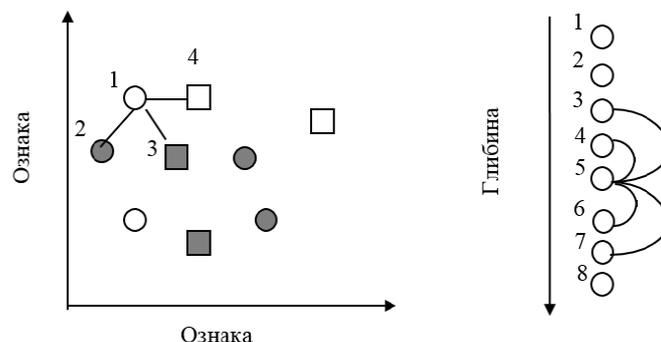


Рис. 3. Схожість ознак  $N_{f,3}(x_1) = \{x_2, x_3, x_4\}$  (зліва), глибинна подібність  $N_{d,4}(x_5) = \{x_3, x_4, x_6, x_7\}$  (справа)

GAT – це напівконтрольована нейронна мережа, заснована на графі, і її ефективність була продемонстрована у відповідній базі даних графів. Після перетворення даних журналу в дані, структуровані на графах, використовується GAT для вирішення такої проблеми напівконтрольованої класифікації даних каротажу. Рівень уваги графа GAT розділений на дві частини: увага краю та агрегація сусідніх вузлів. У попередньо створених зразках з'єднань розглядаються лише двійкові з'єднання, а не сила з'єднання. Наприклад, при використанні простору функцій для побудови з'єднань, зразки з більшою кількістю подібних функцій повинні мати вищу міцність з'єднань. При використанні подібності глибини для побудови зв'язків два сусідніх зразки за глибиною можуть мати різні мітки на межах розподілу літології. Міцність зв'язку відповідає вазі даних у структурі графа. Якщо вагові коефіцієнти встановлені для країв під час побудови графа, буде важко відокремити два зразки з високозваженим краєм, навіть якщо вони належать до різних літологій. Щоб вирішити цю проблему, мережа уваги на графі використовує увагу до країв для динамічного коригування вагових коефіцієнтів. Графічно структуровані дані для вхідного рівня – це набір вузлів ознак, які визначаються як:

$$h = \{h_1, \dots, h_{l+u}\}, h_i \in R^{1 \times d}, \tag{8}$$

де  $l + u$  – номер вузла і  $d$  – розмірність вхідних даних.  $h' = \{h'_1, \dots, h'_{l+u}\}, h'_i \in R^{1 \times d'}$  і  $d'$  – вихід вхідного шару та його розмір відповідно. Щоб отримати подільні зразки, перетворюємо вхідні функції у функції вищого рівня, які потребують принаймні одного лінійного перетворення, яке можна вивчати. Обчислюється вага між поточним вузлом і його сусідами та механізм уваги:  $a: R^{d'} \times R^{d'}$  визначає коефіцієнти уваги:

$$e_{ij} = a[W h_i^T \| W h_j^T], \tag{9}$$

де  $T$  представляє транспозицію,  $\|$  – це операція конкатенації,  $W \in R^{d' \times d}$  є матрицею перетворення,  $e_{ij}$  вказує на міцність з'єднання вузлів  $j$  та  $i$ . Зразок зазвичай пов'язує з  $K$  сусідами. Кожну вагу  $e_{ij}$  сусіда обчислюємо за наведеною вище формулою і щоб коефіцієнти уваги легко порівнювати між різними вузлами, нормалізуємо їх:

$$\alpha_{ij} = \frac{e^{f(e_{ij})}}{\sum_{k \in N(x_i)} e^{f(e_{ik})}}, f(x) = \begin{cases} x, & x > 0, \\ px, & \text{віншомувипадку,} \end{cases} \tag{10}$$

де  $N(x_i)$  є набором сусідів  $x_i$ ,  $f(\cdot)$  є функцією активації,  $p$  – гіперпараметр, який зазвичай встановлюється 0,01,  $\alpha_{ij}$  – коефіцієнти уваги краю, які представляють важливість вузла  $j$  у процесі класифікації відносно інших сусідніх вузлів вузла  $i$ .

Після того, як з'єднання створено, ключем до завдання стає те, як використовувати додаткову інформацію, згенеровану з'єднанням. У режимі агрегації сусідніх вузлів GAT вихідна характеристика кожного вузла є зваженою сумою характеристик сусіднього вузла:

$$h_j^T = \sigma(\sum_{i \in N(x_i)} \alpha_{ij} W h_i^T), \tag{11}$$

де  $\sigma(\cdot)$  є нелінійною функцією активації.

Кожен вузол ділиться своїми характеристиками зі своїми сусідами. Натомість, функції позначених вузлів спільні з численними непозначеними вузлами. Після поширення значна кількість непозначених вузлів міститиме інформацію про ознаки позначених зразків. Оскільки початкова вага є випадковою, погана початкова вага може негативно вплинути на кінцеві результати класифікації. Щоб стабілізувати процес навчання злиття функцій, використовують мультиувагу. Це може зменшити вплив непередбачених ситуацій і створити більш надійні моделі. Таким чином, модифікований варіант:

$$h_j^T = \parallel_{q=1}^Q \sigma(\sum_{i \in N(x_i)} \alpha_{ij}^q W^q h_i^T), \tag{12}$$

де  $\parallel$  – це операція конкатенації,  $\alpha_{ij}^q$  – коефіцієнти уваги (ваги) вузла  $i$  до сусіда  $j$  обчислено  $q$  механізмом уваги.  $W^q$  є відповідною лінійною матрицею перетворення в  $q$  механізм уваги.  $h_j^T \in R^{Q \times d'}$  є виходом вхідного шару і  $Q$  є кількість перетворень матриці  $W$ .

Окрім конкатенації, отримуємо середнє значення виходів вхідного рівня при  $Q$  механізмі уваги:

$$h_j^T = \sigma\left(\frac{1}{Q} \sum_{q=1}^Q \sum_{i \in N(x_i)} \alpha_{ij}^q W^q h_i^T\right). \tag{13}$$

Завдання ідентифікації літології на основі даних каротажу перетворюється на завдання класифікації вузлів на основі графоструктурованих даних. Визначимо класифікатор як  $f(D, A)$ , де  $A$  є суміжною матрицею графоструктурованих даних. Класифікатор можна записати так:

$$\begin{aligned} h^T &= GATConv1(D, A) = \left\{ \parallel_{q=1}^Q \sigma(\sum_{i \in N(x_i)} \alpha_{ij}^q W^q x_j^T) \right\}_{i=1}^N, \\ h^T &= GATConv2(\phi(h), A) = \left\{ \sigma\left(\frac{1}{Q} \sum_{q=1}^Q \sum_{i \in N(x_i)} \alpha_{ij}^q W^q x_j^T\right) \right\}_{i=1}^N \end{aligned} \tag{14}$$

де  $\phi(h)$  є функція активації,  $GATConv1(D, A)$ ,  $GATConv2$  є рівнями уваги графа GAT,  $h$  є виходом  $GATConv1(D, A)$  з даними каротажу свердловин і  $A$  як входи,  $h'$  є виходом  $GATConv2$  з  $\phi(h)$  і  $A$  як входи.

Застосовуємо втрату перехресної ентропії до всіх мічених зразків. Щоб уникнути проблеми з налаштуванням, оптимізуємо модель шляхом мінімізації емпіричного ризику позначених вузлів і елемента регуляризації. Стратегія оптимізації:

$$\begin{aligned} \Psi(Z, y) &= \frac{1}{l} \sum_{i=1}^l \sum_{p=1}^c \mathbb{E}_{(p=y_i)} \ln Z_i, \\ f &= \operatorname{argmin} \Psi(f(D, A), y) + \lambda \|W\|_2, \end{aligned} \tag{15}$$

де  $\mathbb{E}$  – характеристична функція,  $Z_i$  – вихід, що відповідає  $i$  зразку.

У ідентифікації літології явище дисбалансу класів дуже поширене. Точність, як відкликання, зважене кількістю зразків, часто призводить до того, що результати великої кількості класів покривають результати невеликої кількості класів. Таким чином, усереднення результатів для кожного класу може дати кращу оцінку всім класам.

Таким чином, описана технологія напівконтрольованого навчання ідентифікації літології. Зокрема, подібність ознак і глибин вводиться для побудови даних графа, які розширюють подібність ознак і глибин до з'єднання вузлів. Згодом мережа звернення уваги на граф (GAT) використовується для агрегування інформації про підключених сусідів, а межі між вузлами можна адаптивно оновлювати за допомогою механізму уваги. В такий спосіб досягається краща продуктивність, порівняно з традиційними напівконтрольованими методами, такими як алгоритми поширення міток (LP) і опорні векторні машини Лапласа (LapSVM). Слід зауважити, що продуктивність моделі певною мірою залежить від з'єднання, встановленого відповідно до попередньої інформації, і якщо позначені дані занадто малі, механізм уваги цього методу може бути не достатньо ефективним.

### Висновки з даного дослідження

#### і перспективи подальших розвідок у даному напрямі

У реалізованому дослідженні запропоновано підхід до ідентифікації літології, що поєднує графові нейронні мережі з адаптивною агрегацією ознак каротажу. Побудовано геологічно осмислену графову структуру, у якій вузли відповідають точкам каротажу, а ребра формуються як за подібністю ознак, так і за глибинною близькістю. Це дозволило явним чином урахувати як вертикальну безперервність розрізу, так і багатовимірну подібність між інтервалами, що традиційно слабо відображається в класичних методах машинного навчання. Використання архітектур GraphSAGE і GAT дало змогу реалізувати напівконтрольовану схему навчання, у якій невелика кількість мічених ядерних зразків доповнюється інформацією з великого масиву немаркованих каротажних даних. Адаптивне налаштування ваг ребер за допомогою механізму уваги забезпечило більш гнучке відображення зв'язків між вибірками, що зменшує вплив помилок попереднього налаштування подібності та покращує стійкість моделі до дисбалансу класів. Запропонована методика дозволяє підвищити точність класифікації літологічних типів у порівнянні з традиційними напівконтрольованими підходами, зберігаючи при цьому прийнятні обчислювальні витрати та придатність до практичного впровадження в процесі геолого-розвідувальних робіт.

Перспективи подальших досліджень пов'язані, по-перше, з розширенням набору ознак за рахунок інтеграції сейсмічних атрибутів, петрофізичних вимірювань та даних геомеханічного моделювання в єдину графову структуру. Другий аспект характеризується доцільністю дослідження трансферного та міждоменого навчання для перенесення навчених моделей між різними родовищами та стратиграфічними комплексами. І ще один важливий напрям – розробка більш розвинених механізмів пояснюваності результатів GNN, що дозволить геологам інтерпретувати вплив окремих ознак і зв'язків на кінцеве рішення моделі. Окрему увагу варто приділити оптимізації архітектур під роботу в режимі наближеного реального часу та дослідженню стійкості моделей до шумів, пропусків у даних і невизначеностей, притаманних польовим вимірюванням. Сукупність цих напрямів здатна забезпечити подальше підвищення точності, надійності та практичної цінності автоматизованої ідентифікації літології на основі графових нейронних мереж.

### Література

1. Lv W., Kang Y., Zhao Y. Self-tuning asynchronous filter for linear Gaussian system and applications. *IEEE/CAA J. Autom. Sin.*, 5 (6) (2018), pp. DOI:1054-1061. 10.1109/JAS.2018.7511183
2. Wang K., Zhang L. Predicting formation lithology from log data by using a neural network. *Petroleum Science*, 5 (3), 2008, pp. 242-246 DOI:10.1007/s12182-008-0038-9
3. Sun J., Li Q., Chen M., Ren L., Huang G., Li C., Zhang Z. Optimization of models for a rapid identification of lithology while drilling-A win-win strategy based on machine learning. *Journal of Petroleum Science and Engineering*, V.176, 2019, pp. 321-341. DOI:341 10.1016/j.petrol.2019.01.006
4. Tian Y.J., Pan H.X., Liu X.C., Cheng G.J. Lithofacies recognition based on extreme learning machine. *Applied Mechanics and Materials*, Vol. 241-244, Trans Tech Publ (2013), pp.1762-1767. DOI: 10.4028/www.scientific.net/AMM.241-244.1762
5. Dong S., Wang Z., Zeng L. Lithology identification using kernel Fisher discriminant analysis with well logs. *Journal of Petroleum Science and Engineering*, Volume 143, 2016, pp. 95-102. DOI: <https://doi.org/10.1016/j.petrol.2016.02.017>
6. Zhu L., Li H., Yang Z., Li C., Ao Y., et al. Intelligent logging lithological interpretation with convolution neural networks. *Petrophysics*, 59 (06) (2018), pp. 799-810. DOI: 10.30632/PJV59N6-2018a5
7. Li Z., Kang Y., Lv W., Zheng W.X., Wang X.-M. Interpretable semisupervised classification method under multiple smoothness assumptions with application to lithology identification. *IEEE Geosci. Remote Sens. Lett.*, 18 (3) (2021), pp. 386-390. DOI: <https://doi.org/10.1109/LGRS.2020.2978053>
8. D.B. West. Introduction to Graph Theory. Prentice hall, Upper Saddle River (2001). P. 588

9. Zhang W., Wang J., Li K., Liu H., Kang Y., Wu Y., Lv W. Unilateral alignment: An interpretable machine learning method for geophysical logs calibration. *Artif. Intell. Geosci.*, 2 (2021), pp. 192-201 DOI: <https://doi.org/10.1016/j.aiig.2022.02.006>
10. Veličković P., Cucurull G., Casanova A., Romero A., Lio P., Bengio Y. Graph attention networks. *International Conference on Learning Representations (ICLR)* (2017), pp. 1-12 DOI: <https://doi.org/10.48550/arXiv.1710.10903>
11. Tao Z., Wei Y., Wang X., He X., Huang X., Chua T.-S. Mgat: Multimodal graph attention network for recommendation. *Inf. Process. Manage.*, 57 (5) (2020), Article 102277 DOI: <https://doi.org/10.1016/j.ipm.2020.102277>
12. B.J. Frey, D. Dueck. Clustering by passing messages between data points. *Science*, 972 (315) (2007), pp. 972-976 DOI: <https://doi.org/10.1126/science.1136800>
13. W.L. Hamilton, R. Ying, J. Leskovec. Inductive Representation Learning on Large Graphs. (2017), pp. 1024-1034 DOI: <https://doi.org/10.48550/arXiv.1706.02216>
14. J. Chang, Y. Kang, Z.R. Li, W.X. Zheng, W.J. Lv, D.Y. Feng. Cross-domain lithology identification using active learning and source reweighting. *Geosci. Rem. Sens. Lett. IEEE* (2020), PP(99):1-5 DOI: <https://doi.org/10.1109/LGRS.2020.3041960>
15. T.S. Bressan, M.K. de Souza, T.J. Girelli, F.C. Junior. Evaluation of machine learning methods for lithology classification using geophysical data. *Computers & Geosciences*, 139 (2020), Article 104475 DOI: <https://doi.org/10.1016/j.cageo.2020.104475>

### References

1. Lv W., Kang Y., Zhao Y. Self-tuning asynchronous filter for linear Gaussian system and applications. *IEEE/CAA J. Autom. Sin.*, 5 (6) (2018), pp. DOI:1054-1061. 10.1109/JAS.2018.7511183
2. Wang K., Zhang L. Predicting formation lithology from log data by using a neural network. *Petroleum Science*, 5 (3), 2008, pp. 242-246 DOI:10.1007/s12182-008-0038-9
3. Sun J., Li Q., Chen M., Ren L., Huang G., Li C., Zhang Z. Optimization of models for a rapid identification of lithology while drilling-A win-win strategy based on machine learning. *Journal of Petroleum Science and Engineering.*, V.176, 2019, pp. 321-341. DOI:10.1016/j.petrol.2019.01.006
4. Tian Y.J., Pan H.X., Liu X.C., Cheng G.J. Lithofacies recognition based on extreme learning machine. *Applied Mechanics and Materials*, Vol. 241-244, Trans Tech Publ (2013), pp. 1762-1767. DOI: 10.4028/www.scientific.net/AMM.241-244.1762
5. Dong S., Wang Z., Zeng L. Lithology identification using kernel Fisher discriminant analysis with well logs. *Journal of Petroleum Science and Engineering*, Volume 143, 2016, pp. 95-102. DOI: <https://doi.org/10.1016/j.petrol.2016.02.017>
6. Zhu L., Li H., Yang Z., Li C., Ao Y., et al. Intelligent logging lithological interpretation with convolution neural networks. *Petrophysics*, 59 (06) (2018), pp. 799-810. DOI: 10.30632/PJV59N6-2018a5
7. Li Z., Kang Y., Lv W., Zheng W.X., Wang X.-M. Interpretable semisupervised classification method under multiple smoothness assumptions with application to lithology identification. *IEEE Geosci. Remote Sens. Lett.*, 18 (3) (2021), pp. 386-390. DOI: <https://doi.org/10.1109/LGRS.2020.2978053>
8. D.B. West. Introduction to Graph Theory. Prentice hall, Upper Saddle River (2001). P. 588
9. Zhang W., Wang J., Li K., Liu H., Kang Y., Wu Y., Lv W. Unilateral alignment: An interpretable machine learning method for geophysical logs calibration. *Artif. Intell. Geosci.*, 2 (2021), pp. 192-201 DOI: <https://doi.org/10.1016/j.aiig.2022.02.006>
10. Veličković P., Cucurull G., Casanova A., Romero A., Lio P., Bengio Y. Graph attention networks. *International Conference on Learning Representations (ICLR)* (2017), pp. 1-12 DOI: <https://doi.org/10.48550/arXiv.1710.10903>
11. Tao Z., Wei Y., Wang X., He X., Huang X., Chua T.-S. Mgat: Multimodal graph attention network for recommendation. *Inf. Process. Manage.*, 57 (5) (2020), Article 102277 DOI: <https://doi.org/10.1016/j.ipm.2020.102277>
12. B.J. Frey, D. Dueck. Clustering by passing messages between data points. *Science*, 972 (315) (2007), pp. 972-976 DOI: <https://doi.org/10.1126/science.1136800>
13. W.L. Hamilton, R. Ying, J. Leskovec. Inductive Representation Learning on Large Graphs. (2017), pp. 1024-1034 DOI: <https://doi.org/10.48550/arXiv.1706.02216>
14. J. Chang, Y. Kang, Z.R. Li, W.X. Zheng, W.J. Lv, D.Y. Feng. Cross-domain lithology identification using active learning and source reweighting. *Geosci. Rem. Sens. Lett. IEEE* (2020), PP(99):1-5 DOI: <https://doi.org/10.1109/LGRS.2020.3041960>
15. T.S. Bressan, M.K. de Souza, T.J. Girelli, F.C. Junior. Evaluation of machine learning methods for lithology classification using geophysical data. *Computers & Geosciences*, 139 (2020), Article 104475 DOI: <https://doi.org/10.1016/j.cageo.2020.104475>