

ПЕТРИШИН РОМАН

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0009-2770-6656>e-mail: romeopetryshyn@gmail.com**КУЗЬМІН МАКСИМ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0006-7693-3159>e-mail: 123kmv123@gmail.com**ПАВЛІВ АНДРІЙ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0009-2855-915X>e-mail: Andriypavliv1@gmail.com**КОЛІНКО ВЛАДИСЛАВ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0000-9930-1257>e-mail: kolinkovlad@gmail.com**ГОЛОВЧАК ВЛАДИСЛАВ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0006-2571-5258>e-mail: vladyslav.holovchak-a12322@nung.edu.ua

ІНТЕЛЕКТУАЛЬНА ІНТЕРПРЕТАЦІЯ ДІАГРАМ КАРОТАЖНИХ КРИВИХ НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ ЗАСОБІВ

Суть даної роботи полягає у розробці та використанні методу машинного навчання для генерування синтетичних каротажних діаграм свердловин на основі наявних каротажних даних. Цей метод дозволяє доповнити відсутню інформацію у каротажних діаграмах, що є критично важливим для точного моделювання та аналізу геологічних даних. Обґрунтовано, що традиційні повноз'язні нейронні мережі не ефективні для збереження просторової залежності, тому у роботі застосовано мережі з довготривалою короткочасною пам'яттю (ДКЧП), що дозволяє ефективно обробляти і запам'ятовувати інформацію з великих обсягів даних і з великою кількістю параметрів, що змінюються в часі, що робить її ідеальною для задач, де важлива послідовна інформація. Методика дозволяє створювати синтетичні каротажні діаграми, використовуючи наявні каротажні дані. Це означає, що можна моделювати каротажні дані там, де вони відсутні або неповні, що допомагає уникнути витрат на нові зйомки. Використання каскадної мережі, яка поєднує стандартну ДКЧП мережу з додатковими системами, забезпечує покращення точності результатів. Така мережа здатна краще адаптуватися і оптимізувати обробку даних залежно від контексту, що забезпечує вищу точність порівняно з однорівневими мережами. Метод було апробовано на реальних каротажних даних, що дозволило не тільки перевірити його ефективність, але і підтвердити вищу точність порівняно з іншими традиційними методами. Результати тестувань показали, що нова методика може значно покращити обробку та аналіз каротажних даних. Розроблений метод може використовуватися для реконструкції повних каротажних діаграм на основі часткових даних, що дозволяє значно збільшити обсяг і якість інформації, доступної для геологів і інженерів. Ця робота показує значний потенціал ДКЧП і каскадних нейромереж для задач синтезу та аналізу великих обсягів геологічних даних, і може стати основою для подальших досліджень та розробок у цій області.

Ключові слова: каротажні криві, метод генерації, процес буріння, машинне навчання, повноз'язна нейронна мережа; штучний інтелект, рекурентна нейронна мережа, мережа з довготривалою короткочасною пам'яттю.

PETRYSHYN ROMAN, KUZMIN MAKSYM, PAVLIV ANDRII, KOLINKO VLADYSLAV, HOLOVCHAK VLADYSLAV
Ivano-Frankivsk National Technical University of Oil and Gas

INTELLIGENT INTERPRETATION OF LOG CURVES BASED ON NEURAL NETWORK TOOLS

The essence of this work lies in the development and application of a machine learning method for generating synthetic well log diagrams based on existing logging data. This method allows for the supplementation of missing information in well logs, which is crucial for accurate modeling and analysis of geological data. It has been demonstrated that traditional fully connected neural networks are not effective in preserving spatial dependency, therefore, an LSTM network was used in this work. LSTM is capable of efficiently processing and remembering information from large data volumes and numerous time-varying parameters, making it ideal for tasks where sequential information is vital. The technique allows for the creation of synthetic well log diagrams using existing data. This means that it is possible to model well log data where it is missing or incomplete, which helps avoid the costs of new surveys. Using a cascaded network that combines a standard LSTM network with additional systems improves the accuracy of the results. Such a network can better adapt and optimize data processing depending on the context, providing higher accuracy compared to single-level networks. The method was tested on real well log data, which not only allowed for verifying its effectiveness but also confirmed its higher accuracy compared to other traditional methods. The test results showed that the new technique could significantly improve the processing and analysis of well log data. The developed method can be used for reconstructing complete well log diagrams based on partial data, significantly increasing the volume and quality of information available to geologists and engineers. This work demonstrates the significant potential of LSTM and cascaded neural networks for synthesis and analysis tasks involving large volumes of geological data, and it could form the basis for further research and development in this area.

Keywords: log curves, generation method, drilling process, machine learning, fully connected neural network; artificial intelligence, recurrent neural network, network with long-term short-term memory.

Постановка задачі

У сучасному світі обробки геофізичних даних та розвідки корисних копалин велике значення набуває використання передових технологій машинного навчання для аналізу каротажних даних. Значні обсяги даних, отримані в результаті каротажних досліджень, вимагають ефективних методів аналізу та інтерпретації, що здатні виявляти складні залежності в даних та автоматизувати процес генерації та доповнення каротажних кривих. Традиційні методи аналізу часто не в змозі адекватно обробляти просторові та часові залежності, характерні для каротажних даних, що підвищує ризик помилок та знижує точність прогнозування показників порід. Водночас, існуючі методи машинного навчання, хоч і демонструють потенціал у вирішенні подібних задач, часто залишаються недостатньо дослідженими у контексті специфіки геофізичних даних. Особливо це стосується використання глибокого навчання і, зокрема, мереж з довгою короткочасною пам'яттю, які мають великий потенціал у моделюванні довготривалих залежностей в часових рядах. Враховуючи це, важливою задачею є розробка та апробація ефективних методів на основі аналізу та інтерпретації каротажних даних, які б дозволяли автоматизувати процеси генерації та реконструкції каротажних кривих, а також генерації синтетичних каротажних діаграм. Це включає розробку нових підходів до структурування нейромереж, зокрема через впровадження каскадних систем, для підвищення точності та надійності прогнозування властивостей геологічного середовища на основі каротажних даних.

Аналіз останніх джерел

Процес каротажу свердловин [1–5] є важливим інструментом для опису пластів, вимірювання різних геофізичних параметрів та оцінки вуглеводневих запасів під час розвідки та буріння нафтогазових свердловин. Інтегроване використання даних декількох геофізичних каротажів у свердловині може значно зменшити неоднозначність їх геологічної інтерпретації та полегшити побудову покращених та адекватних моделей пласта для видобутку. Однак, часто буває так, що каротажна інформація відсутня або неповна з різних причин, наприклад розширення свердловини, виходу з ладу приладів або виконання неповного каротажу через економічну недоцільність. Відсутність таких каротажних даних створює серйозні проблеми для вивчення пластів, а тому поширеним рішенням, в цьому випадку, є повторний каротаж свердловини, що є не зовсім практично і призводить до додаткових затрат, особливо, коли свердловина була обсаджена. Тому реконструкція втрачених і викривлених каротажних діаграм є дуже важливою. Для економічності ефективності, простою ідеєю є безпосередня генерація синтетичних каротажних діаграм свердловин за наявними каротажними даними, для чого використовують різні підходи. Наприклад, можна синтезувати каротажні діаграми за геологічними та механічними властивостями з використанням відповідних фізичних моделей. Однак, отримана фізична модель завжди передбачає певний ступінь спрощення, припущення та суб'єктивного досвіду, що впливає на якість отриманих синтетичних каротажних кривих. Ефективною альтернативою є перевірка основних та неявних кореляцій між різними каротажними діаграмами, а відсутні каротажні діаграми доповнюються відповідно до їх взаємозв'язків із збереженими каротажними даними. Для цього можуть бути застосовані певні підходи, такі як перехресні каротажні діаграми та методи множинної регресії. Але існує надзвичайно складний взаємозв'язок між нелінійно пов'язаними вхідними та вихідними даними каротажу через неоднорідність і складні умови під землею, а тому традиційні методи не зовсім підходять для побудови таких складних взаємозв'язків, оскільки вони є лінійно-похідними.

З появою *машинного навчання* [6–7], для вирішення геологічних задач [8–10], таких як оцінка геофізичних параметрів, характеристика літології, визначення стратиграфічних меж та інших, часто використовують підходи побудовані на основі даних, а саме: методу опорних векторів [9] (*supported vector machine*), нечітких логічних моделей [11] (*fuzzy logic models*) та *штучних нейронних мереж* (ШНМ) [12–20]. В даному випадку, найчастіше використовується традиційно повнозв'язна нейронна мережа (*Fully Connected Neural Network*), яка будує відображення "точка-точка" і означає, що вихідні каротажні діаграми співвідносяться лише з певними вхідними каротажними діаграмами з тієї ж глибини. Однак, нелінійні взаємозв'язки і додаткова інформація в резервуарах не враховується, що є критичним під час геологічних досліджень. Оскільки структура повнозв'язності не здатна зберігати попередню інформацію і не може прогнозувати довгострокові ряди даних, то якість згенерованого каротажу свердловини не є повністю достовірною. Тому для вирішення цієї проблеми можна виконувати інтеграцію з іншими методами, наприклад, з вейвлет-перетворенням та сингулярним спектральним аналізом, хоча застосування цих модифікацій є досить складним та громіздким. Тому, оптимальнішим варіантом є використання рекурентної нейронної мережі (*Recurrent Neural Network*), в якій існує внутрішня циклічна структура, що дозволяє мережі запам'ятовувати попередню інформацію. Рекурентна структура дозволяє даним рухатися як вперед, так і назад всередині мережі і таким чином, вихідні дані ШНМ генеруються з серії вхідних даних з урахуванням їх внутрішніх взаємозв'язків і варіаційних тенденцій, що добре узгоджується з перспективою геологічного аналізу.

В представленому дослідженні застосовується мережа довготривалої короткочасної пам'яті (*Long Short-Term Memory*) та вдосконалена архітектура штучної нейронної мережі (ШНМ), яка є очікувано застосовною моделлю глибокого навчання для виконання генерації синтетичного каротажу свердловини. Оскільки вхідні структури будуються в нейронних клітинах, що самозациклюються, дана модель здатна зберігати довгострокову попередню інформацію для подальшого використання без будь-яких подальших модифікацій. Така перевага робить даний тип ШНМ досить поширеним в області штучного інтелекту та

глибокого навчання.

Виклад основного матеріалу

Штучна нейронна мережа (ШНМ) – це ієрархічна модель, яка здатна апроксимувати нелінійні функціональні залежності між *вхідними та вихідними змінними*. З математичної точки зору, нейронна мережа може моделювати будь-яку функцію з будь-якою заданою точністю за допомогою великої кількості базисних функцій. Повнозв'язна нейронна мережа є найпоширенішою ШНМ, яка має типову ієрархічну структуру, обчислювальними елементами мережі виступають нейрони які організовані у вигляді шарів. У такій мережі нейрони повністю з'єднані один з одним, тобто нейрони в шарі з'єднані з усіма іншими нейронами в сусідніх шарах, але між нейронами в межах одного шару зв'язків немає. Структура чотиришарової мережі представлено на рисунку і як приклад вхідний шар не враховується в загальну кількість. Вихід нейрона обчислюється нелінійною функцією від суми його входів, а нелінійна функція ще називається функцією активації, і найпоширенішими варіантами є сигмоїда, тангенс і ReLU - функція (*Rectified Linear Unit*). Сила зв'язків між різними нейронами представляється вагами, які змінюються в процесі навчання, а тому дана мережа часто використовується для вирішення реальних інженерних задач.

Повнозв'язна нейронна мережа добре працює у багатьох випадках, але вона повинна приймати вхідні дані фіксованого розміру і видавати вихідні дані також фіксованого розміру з відображенням, використовуючи певну кількість обчислювальних кроків, що суттєво обмежує її використання, особливо в задачах з обробкою послідовних даних. Тобто, повнозв'язна нейронна мережа не може використовувати свої міркування про попередні події для інформування про наступні, а *рекурентна нейронна мережа (РНМ)* має в своїй архітектурі цикл, який використовується для передачі впливу попереднього кроку на поточний крок, що дозволяє зберігати інформацію. Таким чином, рекурентна нейронна мережа здатна оперувати послідовністю векторів на входах і виходах, типовий приклад такої мережі представлено зліва на рисунку 1.

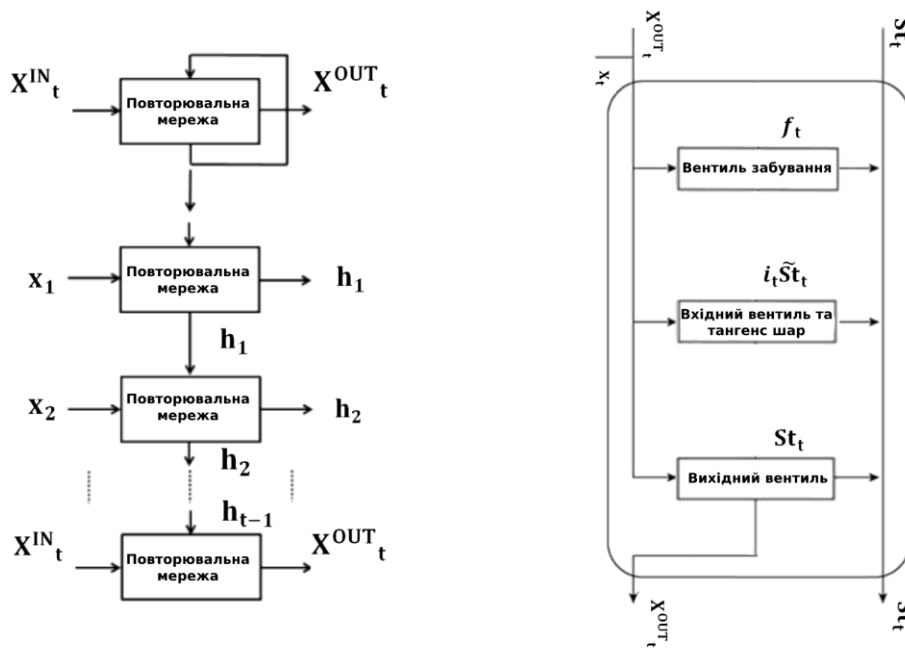


Рис. 1. Представлення стандартної рекурентної нейронної мережі та структури повторюваної мережі з довготривалою короткочасною пам'яттю (ДКЧП)

Вектори X^{IN}_t та X^{OUT}_t представляють вхід та вихід на кроці t , відповідно, а стрілки показують різні рівні обчислення матриці. В даному випадку, цикл є основною відмінністю РНМ від традиційної повнозв'язної нейронної мережі, який дозволяє передавати інформацію від одного кроку до іншого. Показана зліва ШНМ на рисунку є дещо неоднозначною, тоді як її розгорнута версія, яка представлена праворуч є більш зрозумілою, оскільки може розглядатися як декілька копій однієї цієї мережі, причому вихід попереднього кроку передається на наступний крок. Таким чином, на вихід РНМ впливають не тільки вхідні дані поточного кроку, але й вся історія вхідних даних, що подавалися в модель у минулому. Такий тип взаємозв'язку РНМ виявляє його перевагу в аналізі послідовних даних над іншими типами нейронних мереж, а тому ШНМ можна вважати природною мережевою архітектурою для використання з послідовними даними, такими як діаграми каротажних кривих.

Щодо процесу обчислення РНМ, то кожен шар обчислює наступну функцію для кожного елемента вхідної послідовності:

$$X_t^{OUT} = \tanh(\text{weight}_{X_t^{OUT}} X_t^{OUT} + [rs- > sc]_{X_t^{OUT}} + \text{weight}_{X_t^{OUT} X_{t-1}^{OUT}} X_{t-1}^{OUT} + [rs- > sc]_{X_t^{OUT} X_{t-1}^{OUT}}) \quad (1)$$

де $[rs- > sc]$ – структура асоціативного правила за умови релевантності rs та умові задоволення sc .

Як показано в рівнянні 1, прихований стан в момент часу t визначається не тільки вхідними даними в момент часу t , але й прихованим станом в момент часу $t-1$, при чому кінцевий результат в момент часу t генерується на основі прихованого стану в момент часу t . Таке використання прихованого стану підвищує виразність моделі, оскільки цей стан завжди має більше вимірів і ширший діапазон значень, ніж початкові вхідні дані, що дозволяє нейронній мережі представити більш складний розподіл за обмеженим значенням спостереження. Крім наявності циклу в своїй архітектурі РНМ має ще одну перевагу, яка полягає в тому, що такі параметри навчання як вага (weight_i , $\text{weight}_{X_t^{OUT}}$) та зсув ($[rs- > sc]$, $[rs- > sc]_{X_t^{OUT} X_{t-1}^{OUT}}$) розподіляються між різними часовими кроками, що є схожим до технології спільного використання параметрів у *згорткових нейронних мережах* (ЗНМ). Зокрема, ЗНМ ділить параметри ядра згортки між просторовими локаціями, тоді як РНМ ділить параметри між часовими кроками даних послідовності, а спільне використання параметрів робить модель менш складною і дозволяє РНМ адаптуватися до послідовностей довільної довжини, що призводить до кращої узагальнюваності.

Однією з переваг РНМ є її здатність використовувати інформацію з попередніх кроків для оцінки результату на поточному кроці, але на практиці даний тип мережі демонструє низьку продуктивність, коли розрив між відповідною інформацією на попередньому кроці та поточним кроком є досить великим. Мережа з довготривалою короткочасною пам'яттю (ДКЧП) - це особливий тип рекурентної мережі, яка призначена для вивчення довгострокових залежностей, тобто здатна до зберігання та використання інформації протягом тривалого часу.

Мережа ДКЧП має схожу архітектуру ланцюга із повторюваною мережею, як і стандартна рекурентна нейронна мережа. Але повторювана мережа в стандартній РНМ є досить простою, в той час як ДКЧП містить чотири взаємодіючих шари (три шари вентилів (gate layers) і тангенс шар (tanh layer)). Стан комірки є ключовою змінною ДКЧП, яка може проходити через мережу, несучи інформацію про попередні кроки, а вентиля використовуються для видалення або додавання інформації до стану комірки, відповідно до прихованого стану попереднього кроку та входу поточного кроку. Вхід кожної повторюваної мережі включає прихований стан та стан комірки з попереднього кроку, а також вхідну змінну поточного кроку. Стан комірки оновлюється відповідно за результатами чотирьох шарів, а оновлений стан комірки та прихований стан є виходом, який передається на наступний крок.

Перший шар називається вентилям забування (forget gate), який визначає яку інформацію необхідно забути і описується рівнянням 2 з використанням сигмоїдної функції σ . Вихідний сигнал f_t - це число від нуля до одиниці, яке буде помножене на стан комірки отриманого з виразу (5) і визначає, кількість інформації яку має бути пропущено через неї з попереднього кроку.

$$f_t = \sigma[\text{weight}_f (X_{(t-1)}^{OUT}, X_t^{IN}) + [rs- > sc]_f] \quad (2)$$

Другий рівень називається вхідним вентилям (input gate), який визначає, яка нова інформація повинна зберігатися в стані комірки і описується рівнянням 3. Вихід вирішує, які значення в третьому шарі будуть оновлені.

$$i_t = \sigma[\text{weight}_i (X_{(t-1)}^{OUT}, X_t^{IN}) + [rs- > sc]_i] \quad (3)$$

Третій шар – це тангенс шар (tanh), який створює нове кандидат-значення, яке можна додати до стану комірки і визначається рівнянням 4:

$$\tilde{St}_t = \tanh[\text{weight}_c (X_{(t-1)}^{OUT}, X_t^{IN}) + [rs- > sc]_c] \quad (4)$$

Після підготовки у вищезгаданих трьох шарах стара пам'ять, яку несе старий стан комірки $St_{(t-1)}$, об'єднується з новим кандидатом \tilde{St}_t , що описується рівнянням 5. Результат від вентиля забування f_t вирішує, що забути в $St_{(t-1)}$, а результат від вхідного вентиля вирішує, що додати в \tilde{St}_t .

$$St_t = f_t St_{(t-1)} + i_t \tilde{St}_t \quad (5)$$

Відповідно, останній шар називається вихідним, який генерує вихід ДКЧП на основі оновленого стану комірки відповідно та описується наступним виразом:

$$X_t^{OUT} = \sigma[\text{weight}_o (X_{(t-1)}^{OUT}, X_t^{IN}) + [rs- > sc]_o] \tanh St_t \quad (6)$$

ДКЧП – це різновид рекурентної мережі з чотирма взаємодіючими шарами в у своїй повторюваній мережі, що здатна не лише видобувати інформацію з послідовних вхідних даних, як стандартна нейронна мережа, але й може зберігати інформацію з попередніх часових кроків з довготривалими залежностями. ДКЧП є ідеальним інструментом для створення синтетичних каротажних діаграм свердловин, оскільки каротажні дані є послідовними, а тренд каротажних діаграм є значним. Крім того, в кривих каротажних діаграм існують довгострокові (просторові) залежності, оскільки інтервали дискретизації відносно малі, а ДКЧП має достатній обсяг довготривалої пам'яті для вирішення цих проблем.

Для тестування продуктивності ДКЧП проведемо імітаційне моделювання яке складатиметься з двох незалежних етапів з автодоповнення каротажу свердловин та з генерації синтетичного каротажу свердловин. Основними цілями моделювання є: 1) визначення здатності ДКЧП до автоматичного

доповнення кривих каротажу пропущеними ділянками на основі неповних каротажних діаграм; 2) оцінка точності роботи ДКЧП для синтезованих каротажних діаграмах на основі інформації про сусідні свердловини зі зміщенням; 3) порівняння ефективності ДКЧП з класичною повнозв'язною нейронною мережею.

Для першого етапу вважатимемо, що деякі частини каротажних діаграм відсутні. Метод ДКЧП використовується для регенерації та доповнення каротажних кривих на основі решти каротажних діаграм з тієї ж свердловини. Як приклад взято одну виділену свердловину. Для процесу моделювання використано п'ять каротажних діаграм: гамма-каротаж, індукційний опір масиву, нейтронна пористість, дельта-часовий зсув і дельта-часовий стиск.

У цьому експерименті нейтронна пористість, дельта-часовий зсув та індукційний опір масиву в заданому діапазоні глибин вилучаються для моделювання відсутніх частин каротажних кривих. Відповідно, отримуємо, що відсутні частини складають 20% від загального каротажного розрізу.

Така довжина вибірки для навчання вказує на припущення, що точки в заданих межах перед кожним елементом вибірки впливають на їх значення. Регулюючи довжину навчальної вибірки, діапазон пам'яті ДКЧП можна змінювати відповідно до потреб, а навчальні послідовності двох повних секцій журналу витягуються окремо, а потім випадковим чином змішують для побудови навчальної вибірки даних.

ДКЧП-модель, що використовується на даному етапі, містить два ДКЧП-шари і повністю з'єднаний шар, а прихований стан кожного шару ДКЧП має десятки вимірів. Для того, щоб уникнути надмірної підгонки, до ДКЧП застосовується відсікання з заданою ймовірністю.

В процесі автодоповнення каротажу свердловини спочатку вибирається невелика частина даних перед відсутнім сегментом в якості початкових даних, і за цими даними оновлюється прихований стан і стан комірки ДКЧП, а потім на основі оновлених даних послідовно обчислюються прогнозовані значення пропущених даних з каротажних кривих.

Прихований стан h_0 і стан комірки St_0 задаються для початкового сегмента, а $h_{(d-1)}$ та $St_{(d-1)}$ – це виходи сегмента відповідно, які надсилаються на перший крок у відсутньому сегменті. Припускаючи, що перша виміряна глибина відсутнього сегмента дорівнює d , то прихований стан $h_{(d-1)}$ і стан комірки $St_{(d-1)}$ можна обчислити за допомогою ДКЧП-моделі на основі даних виміряних на глибині $d-1$. Потім, на основі значень гамма-квантів і дельта-часу стиснення на вимірній глибині d , прогнозується прихований стан h_d і стан комірки s_d , а також отримуються індукційний двофутутовий опір масиву, нейтронна пористість і дельта-часовий зсув на глибині d . Відповідно до прихованого стану і стану комірки на глибині d , у поєднанні з вхідними каротажними кривими на глибині $d+1$, розраховуються прихований стан і стан комірки на глибині $d+1$, які генерують вихідні каротажні криві. У цій моделі автодоповнення каротажу свердловини кожне прогнозування ґрунтується на результатах попереднього кроку у вибірці, а пропущені значення доповнюються одне за одним.

ДКЧП успішно визначає закономірності в послідовних даних, прогнозує відсутні сегменти і доповнює каротажні криві на основі цих закономірностей. Щодо дельта-часового зсуву та нейтронної пористості, синтетичні криві на основі ДКЧП та реальні виміряні каротажні криві не тільки демонструють подібні тенденції, але й мають схожі значення, що свідчить про те, що мережа ДКЧП здатна регенерувати відсутні частини кривих каротажних діаграм. Що стосується показника індукційного двофутутового каротажу, де абсолютне значення автоматично заповненої кривої відрізняється від фактичної кривої каротажу, то існує певна схожість у тенденції, яку можна використовувати як орієнтир відсутнього сегмента. Але, видно, що автоматично заповнена крива індукційного двофутутового опору масиву і реальна каротажна крива сильно відрізняються на межі пластів, що може бути пов'язано з тим, що на даний показник впливають показники вмісту нафти і мінералізації, які не повністю враховуються у вхідних каротажних діаграмах свердловин. Також є можливим, той факт, що вигляд індукційного двофутутового опору масиву на межі пластів відрізняється від вигляду у верхньому і нижньому пластах. Мережі ДКЧП складно навчати виявляти закономірності в точках межі пласта, оскільки вони не включена в навчальну вибірку, а тому у випадку відсутності частини кривих каротажу, ДКЧП можна навчити ідентифікувати закономірності в послідовних даних каротажу на основі повної частини в тій самій свердловині. При цьому відсутній сегмент може бути регенований відповідно до цих шаблонів, вивчених ДКЧП, що означатиме, що весь процес автоматичного завершення не залежить від інших свердловин. Однак продуктивність може бути значно покращена, якщо доступні повні каротажні діаграми в зміщених свердловинах на тому ж родовищі, які можна використовувати для навчання мережі. На другому етапі імітаційного моделювання відбуватиметься генерація синтетичних каротажних діаграм свердловин з використанням ДКЧП, каскадної ДКЧП і традиційної повнозв'язної нейронної мережі (ПЗНМ) відповідно, а також порівнюється точність цих методів. Дані цього експерименту отримані з шести вертикальних свердловин досліджуваного нафтового родовища. Оскільки вертикальні свердловини проходять через більшу кількість пластів, ніж горизонтальні свердловини, то зв'язок між вхідними та вихідними каротажними діаграмами є більш складним, і цей етап є більш складним, ніж попередній з автоматичним заповненням каротажних діаграм. З точки зору навчальних вибірок даних, то кожна вертикальна свердловина містить сім каротажних діаграм, які представляють собою різницю амплітуд мікропотенціалу та мікроградієнта, каротаж, спонтанний потенціал, гамма-каротаж, акустичний каротаж з високою роздільною здатністю, свердловинний компенсований звуковий каротаж та густина.

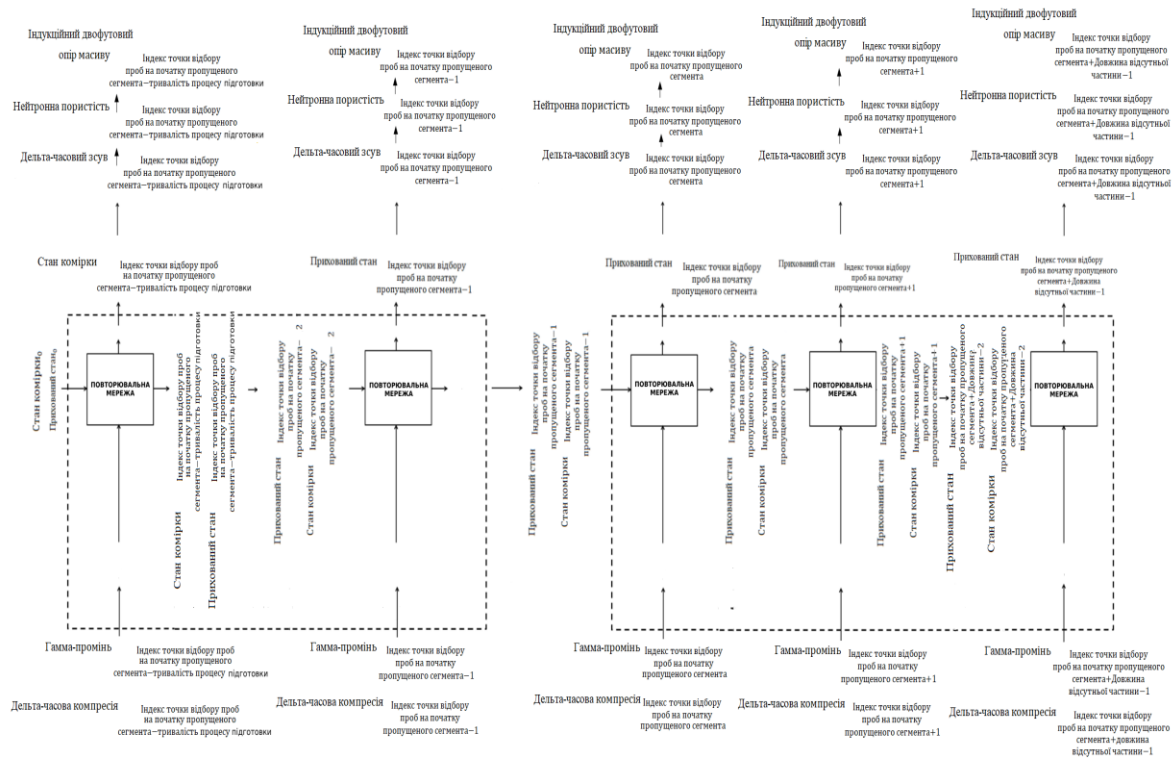


Рис. 2. Схема процесу підготовки мережі

Криві каротажу використовуються як вхідні дані, а останні три криві – як вихідні, а каротажні ділянки поділено на частини, залежно від глибини. В процесі побудови навчальної вибірки для навчання, дані кожної свердловини витягуються незалежно, а потім випадковим чином перемішуються, при заданому інтервалі дискретизації каротажної кривої та встановленій довжині навчальної вибірки. Таким чином, коли для генерації навчальних даних використовуються виділені свердловини, кількість послідовностей становить очікувані значення відповідно.

В експерименті використовується метод пропущених свердловин, тобто всього виконується шість груп експериментів. Одна з шести свердловин використовується для побудови тестового набору даних у кожній групі експериментів, а інші п'ять об'єднуються в навчальний набір даних. Також дані з свердловини, яка використовується як тестовий набір даних дані не враховуються. Замість цього, чотири вхідні каротажні криві вводяться в ДКЧП як чотири повні послідовності для прогнозування інших трьох вихідних каротажних кривих. З точки зору архітектури нейронної мережі, мережа ДКЧП використовує два шари ДКЧП з прихованим станом вимірів і два повністю з'єднаних шари. Три ПЗНМ мають таку саму кількість ваг, як і мережа ДКЧП.

На основі стандартної ДКЧП також виконується спроба прийняти мережу ДКЧП з каскадною системою, в якій один з невідомих каротажів спочатку оцінюється за відомими каротажними даними, а потім отримана синтетична діаграма поєднується з відомими каротажними даними як нові вхідні дані, що використовуються для оцінки іншого каротажної діаграми з решти невідомих каротажних даних. Потім, всі невідомі каротажні діаграми оцінюються шляхом повторення вищезгаданих кроків. На прикладі набору даних на цьому етапі, крива акустичного каротажу високої роздільної здатності спочатку оцінюється за чотирма відомими каротажними діаграмами свердловин, а потім додається до вхідних даних і використовується для прогнозування свердловинного компенсованого каротажу з іншими чотирма відомими каротажними діаграмами свердловин.

На останньому кроці, новий вхідний каротаж будується на основі акустичного каротажу з високою роздільною здатністю, каротажу з компенсацією свердловини та чотирьох відомих каротажів свердловин для оцінки останнього невідомого каротажу (густини). Використання каскадної мережі ДКЧП має дві переваги. По-перше, оскільки одночасно прогнозується лише одна крива каротажу, то зменшується взаємна інтерференція між вихідними каротажними діаграмами, що підвищує точність моделі. По-друге, завдяки застосуванню ідеї каскаду, то модель має більшу сумісність з вхідними даними. Наприклад, для свердловини з більш відомими каротажними даними модель можна запустити безпосередньо з середнього кроку каскадної ДКЧП без перенавчання самої моделі, що є корисним для реальних інженерних задач. Але каскадна ДКЧП також має і недолік який пов'язаний із його мережевою складністю, яка є вищою, ніж у стандартної мережі ДКЧП. Однак, оскільки розмірність вхідних даних у задачах генерації синтетичного каротажу свердловин переважно не перевищує десятків одиниць виміру, навіть якщо каскадна ДКЧП є

складнішою, то кількість параметрів мережі не перевищуватиме десятків тисяч, що є набагато менше, ніж при застосуванні глибоких нейронних мереж з великою кількістю вагових коефіцієнтів. Складність каскадної мережі ДКЧП є прийнятною з огляду на наявні на сьогоднішній день обчислювальні потужності. Для того, щоб оцінити продуктивність каскадної ДКЧП, стандартної ДКЧП, 4-, 8- та 12-шарових мереж ПЗНМ, використаємо їх до задачі генерації синтетичних каротажних діаграм шести свердловин на досліджуваному нафтовому родовищі. Результати представляються як середнє значення та стандартне відхилення середньоквадратичної похибки оцінок значень різних методів. Зокрема, чим менша середньоквадратична похибка, тим точнішою є модель. Результати прогнозування за допомогою ДКЧП є більш точними, будь якої конфігурації ПЗНМ мережі. Всі моделі дають хороші оцінки на виділених свердловинах, що може бути наслідком того, що вона має відмінні від інших свердловин приховані закономірності, які не зазначені в навчальній вибірці даних. Однак, каскадна ДКЧП і стандартна ДКЧП все ще мають прийнятну точність, що демонструє їхню стійкість до визначення невідомих закономірностей. Крім того, порівняно зі стандартною ДКЧП, каскадна ДКЧП не тільки досягає вищої точності прогнозування, але й має значно менше середньоквадратичне відхилення прогнозу втрати. Для того, щоб проаналізувати продуктивність каскадної ДКЧП, на рисунках побудовано синтетичні каротажні криві які є найкращим та найгіршим прогнозами каскадної ДКЧП, відповідно, та порівняння з ПЗНМ. Ліворуч від глибинної лінійки наведено чотири відомі каротажні діаграми - різниця амплітуд мікропотенціалу та мікроградієнта, каротаж, спонтанний потенціал та гамма-каротаж. Криві каротажу з правого боку лінійки глибин відповідають акустичному каротажу з високою роздільною здатністю, свердловинному компенсованому каротажу та каротажу густини, згенерованому каскадною ДКЧП та 8-шаровим ПЗНМ, відповідно. Червоні криві представляють результати, отримані за допомогою каскадної ДКЧП, сині криві - результати, отримані за допомогою ПЗНМ, а чорні – представляють реальні каротажні діаграми як еталон. Зеленою пунктирною рамкою показано, що значення акустичного каротажу високої роздільної здатності і свердловинного компенсованого каротажу мають ступінчасте збільшення в цьому інтервалі. Однак, на чотирьох кривих вхідного каротажу в цьому інтервалі немає очевидних змін, тому ПЗНМ не змогла згенерувати цю ступінчасту зміну у своїх синтетичних каротажних кривих. Щодо каскадної ДКЧП, то оскільки вона навчається на основі даних послідовності зі зміщених свердловин, то вона може визначати акустичний каротаж високої роздільної здатності та свердловинний компенсований акустичний каротаж за трендом вхідних кривих у заданому діапазоні глибин.

Проведений експеримент показує, що каскадна ДКЧП може всебічно аналізувати вплив даних перед точкою прогнозування і вхідних даних у точці прогнозування, що дозволяє каскадній ДКЧП точно прогнозувати тенденції послідовності даних, таких як синтетичні каротажні діаграми свердловин. Обидві синтетичні каротажні діаграми, згенеровані каскадною ДКЧП і ПЗНМ, мають велике відхилення від реальних вимірних каротажних діаграм. Тим не менше, каскадна ДКЧП має кращу передбачуваність для загального тренду цільових каротажних діаграм, що показано пунктирною зеленою рамкою. Також визначено, що ПЗНМ є більш нестабільною мережею в порівнянні з каскадною ДКЧП, оскільки остання є надійнішою при роботі з даними в яких не виявлені та невідомі закономірності.

Каскадний шар

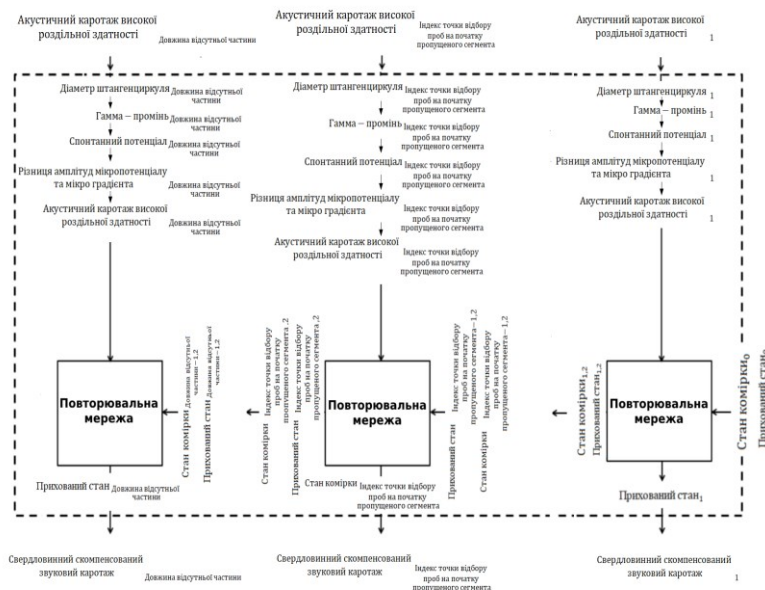


Рис. 3. Архітектура каскадної ДКЧП




Рис. 4. Синтетичні каротажні діаграми свердловини згенеровані каскадною ДКЧП та ПЗМ мережами (найкращий результат оцінки)

Висока точність і стабільність каскадної ДКЧП досягається завдяки тому, що кожен етап процесу прогнозування використовує результати як нові вхідні дані для наступного етапу і ця стратегія не тільки допомагає ефективніше виокремлювати закономірності в процесі навчання, але й ефективніше використовувати вхідну інформацію в процесі прогнозування.

При застосуванні каскадної ДКЧП порядок прогнозування невідомих каротажів є важливим, оскільки результат прогнозування кожного етапу стає вхідною інформацією для наступного, а помилка прогнозування також певною мірою переноситься на наступний етап, що призводить до проблеми їх накопичення. Відповідно, для уникнення цих проблем рекомендується прогнозувати прості каротажні криві на неглибоких етапах, а складніші криві прогнозувати поступово в міру поглиблення етапу. Крім того, інформація, що міститься в результатах на початкових етапах, буде використана на більш глибоких етапах, щоб компенсувати вплив накопичення помилок. Цей метод дозволяє досягти кращих результатів навіть у кривих каротажу на глибоких стадіях, що підтверджується даними на діаграмах.

У каскадній ДКЧП спочатку прогнозується акустичний каротаж високої роздільної здатності на першій стадії, потім генерується свердловинний каротаж з компенсацією, а на другій стадії генерується акустичний каротаж високої роздільної здатності як один з вхідних каротажів, і, в кінцевому результаті генерується каротаж густини. Хоча в синтетичному каротажі густини існують кумулятивні похибки, але точність каскадної ДКЧП є вищою, ніж у стандартної ДКЧП, оскільки вхідні дані каскадної ДКЧП містять два додаткових каротажі і містять більше інформації, ніж стандартний ДКЧП.

Отже, на першому етапі імітаційного моделювання з автоматичного доповнення каротажу свердловини було використано мережу ДКЧП для автоматичного доповнення відсутніх кривих каротажу горизонтальної свердловини. В даному випадку вважалось, що 20% даних на кривих каротажу втрачено, а відсутній сегмент знаходиться на стику двох пластів, через які проходить горизонтальна свердловина. Оскільки криві каротажу зазвичай мають різні приховані закономірності в різних пластах, розташування відсутнього сегмента збільшує складність цієї проблеми. Однак ДКЧП досягає не поганих результатів, при чому навчальні дані не включають каротажні діаграми інших зміщених свердловин, а це означає, що процес автозавершення покладається лише на каротажні криві самої неповної горизонтальної свердловини.

На другому етапі для генерації синтетичних каротажних діаграм проаналізовано шість вертикальних свердловин на основі даних ПАТ *Украфто*, а стандартну ДКЧП порівняно з трьома ПЗМ ПЗМ-мережами різної глибини. Каскадна ДКЧП також розроблена шляхом поєднання каскадної системи зі стандартною ДКЧП для розв'язання задач з декількома пов'язаними серіями даних (каротажних діаграм). У каскадній ДКЧП відносно проста каротажна крива реконструюється на неглибокому етапі, а результат використовується як частина вхідних даних для наступного етапу. Прогнози глибоких етапів базуються не тільки на вхідних каротажних кривих у навчальних даних, але й на синтетичних каротажних кривих, згенерованих на попередніх етапах, що дозволяє ефективніше витягувати інформацію, яка міститься у вхідних даних, що підвищує точність прогнозування. Такий тип каскадної мережі ДКЧП особливо підходить для вирішення проблеми генерації каротажу декількох свердловин, оскільки результати вказують на те, що каскадна ДКЧП має явну перевагу у створенні синтетичних каротажних діаграм, а результати прогнозування

мають не тільки меншу MSE, але й меншу невизначеність. Представлений етап базується на вертикальних свердловинах, однак очікується, що каскадна ДКЧП буде коректно працювати і для випадку горизонтальних свердловин, оскільки кількість пластів, які перетинає горизонтальна свердловина, є меншою, ніж для вертикальних, що призводить до простіших прихованих закономірностей у каротажі.

Запропонований, в даному дослідженні, метод автозаповнення та генерації каротажу свердловин на основі ДКЧП допомагає знизити витрати на видобуток нафти і газу, за рахунок кращого вивчення пласта з використанням каротажу свердловин. Однак, поточна вартість каротажу свердловин є високою, особливо для горизонтальних свердловин, для яких вартість приблизно в 10 разів вища, ніж для вертикальних свердловин, а тому використання мережі ДКЧП може певною мірою вирішити цю проблему. Для навчання мережі ДКЧП можна використовувати наявні каротажні діаграми сусідніх свердловин, а для нової пробуреної горизонтальної або вертикальної свердловини, повний набір каротажних діаграм може бути автоматично згенерований на основі декількох доступних каротажних діаграм і мережі ДКЧП. Низька вартість генерації синтетичних каротажних діаграм на основі ДКЧП дозволяє її застосування у великих масштабах, що сприяє оцінці та аналізу на рівні блоків і басейнів. Крім того, цей метод генерації синтетичних каротажних діаграм на основі ДКЧП також можна застосовувати для прогнозування каротажу під час буріння, при цьому криві каротажу реального часу які генеруються на основі даних, зібраних під час буріння, можна використовувати як довідкову інформацію для коригування процесу буріння та розробки нових стратегій освоєння свердловини. Також для блоків, для яких відсутні каротажні діаграми, можна використовувати існуючі моделі, побудовані для інших блоків на основі методів навчання з перенесенням.

Висновки

В представленому дослідженні використовується мережа з довгою короткочасною пам'яттю, яка під час процесів машинного навчання використовується для автоматичного доповнення каротажних кривих та генерації синтетичних каротажних діаграм. Мережа може ефективно виокремлювати патерни, які мають довготривалі просторові залежності, а також оцінювати та реконструювати каротажні криві на їх основі. Крім того, в роботі розроблено каскадну нейромережу, поєднанням каскадної системи зі стандартною мережею яка показує хороші оцінки прогнозування для задач з декількома серіями кривих каротажу.

Як особливий різновид рекурентних мереж, даний тип більше підходить для генерування синтетичних каротажних діаграм, ніж стандартні штучні нейронні мережі, оскільки її можна навчати на основі даних невеликої кількості свердловин, і вона здатна ефективно витягувати інформацію з невеликого навчального набору даних. Така мережа є точним і економічно ефективним способом автоматичного завершення каротажу та генерації синтетичних кривих, що надає краще розуміння геологічної будови пластів та дозволяє покращити розробку стратегій буріння та освоєння свердловин, що призводить до зниження витрат та підвищення видобутку нафти і газу.

Література

1. Vikhot Y., Bubniak I., Kril S., Fourman V. COMPUTER TECHNOLOGIES FOR THE GEOLOGICAL REINTERPRETATION OF WELL LOGGING DATA. VISNYK OF LVIV UNIVERSITY. Series Geology. 2023. Is. 37. P. 98-109.
2. Shavranskyi M.V., Kuchmistenko O.V., Shavranskyi V.M. Methods of forecasting and operational detection of oil and gas-water occurrences during well drilling. Quality control methods and devices. 2021. № 2. P. 14-21.
3. Karpenko O. M., Onyshchuk O. M. Identification and analysis of periodic components in the curves of geophysical well research methods. Scientific Bulletin of the Ivano-Frankivsk National Technical University of Oil and Gas. 2009. № 1. P. 68-72.
4. Yuan, B., & Yang, Q. (2019). Digitization of Well-Logging Parameter Graphs Based on Gridlines-Elimination Approach. *J. Softw.*, 14(12), 573-578.
5. Liu, H. (2017). Principles and applications of well logging (pp. 237-269). Berlin, Heidelberg: Springer Berlin Heidelberg.
6. Sabah, M., Talebkeikhah, M., Wood, D. A., Khosravianian, R., Anemangely, M., & Younesi, A. (2019). A machine learning approach to predict drilling rate using petrophysical and mud logging data. *Earth Science Informatics*, 12, 319-339
7. Zhong, R., Johnson Jr, R. L., & Chen, Z. (2020). Using machine learning methods to identify coal pay zones from drilling and logging-while-drilling (LWD) data. *Spe Journal*, 25(03), 1241-1258.
8. Jang, H., & Topal, E. (2013). Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network. *Tunnelling and Underground Space Technology*, 38, 161-169.
9. Cheng, W. C., Bai, X. D., Sheil, B. B., Li, G., & Wang, F. (2020). Identifying characteristics of pipejacking parameters to assess geological conditions using optimisation algorithm-based support vector machines. *Tunnelling and Underground Space Technology*, 106, 103592.
10. Ivanyukovich, G. A., Malafeyev, O. A., Zaitseva, I. V., Kovshov, A. M., Zakharov, V. V., & Zakharova, N. I. (2020, April). To the evaluation of the parameters of the regression equation between the radiometric and geological testing. In *Journal of Physics: Conference Series* (Vol. 1515, No. 3, p. 032079). IOP Publishing.

11. Gowida, A., Elkatatny, S., Abdulraheem, A., & Shehri, D. A. (2020, January). Synthetic well-log generation: New approach to predict formation bulk density while drilling using neural networks and fuzzy logic. In International Petroleum Technology Conference (p. D022S147R002). IPTC.
12. Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
13. Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
14. [14]. Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." 2017 international conference on engineering and technology (ICET). Ieee, 2017.
15. Zhang, Z., & Zhang, Z. (2018). Artificial neural network. Multivariate time series analysis in climate and environmental research, 1-35.
16. Beale, M. H., Hagan, M. T., & Demuth, H. B. (2010). *Neural network toolbox. User's Guide*, MathWorks, 2, 77-81.
17. Gurney, K. (2018). *An introduction to neural networks*. CRC press.
18. Shanmuganathan, S. (2016). *Artificial neural network modelling: An introduction* (pp. 1-14). Springer International Publishing.
19. Maind, S. B., & Wankar, P. (2014). Research paper on basic of artificial neural network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2(1), 96-100.
20. O'shea, K., & Nash, R. (2015). *An introduction to convolutional neural networks*. arXiv preprint arXiv:1511.08458.