

НАЦІОНАЛЬНА АКАДЕМІЯ НАУК УКРАЇНИ
ІНСТИТУТ ТЕЛЕКОМУНІКАЦІЙ І ГЛОБАЛЬНОГО ІНФОРМАЦІЙНОГО
ПРОСТОРУ

Кваліфікаційна наукова
праця на правах рукопису

НОСКОВ Олексій Вікторович

УДК 004.62

ДИСЕРТАЦІЯ

**ТЕХНОЛОГІЯ ЗБІЛЬШЕННЯ РОЗРІЗНЕНОЇ ЗДАТНОСТІ
МІГРОВАНИХ СЕЙСМІЧНИХ ДАНИХ НА ОСНОВІ ВИКОРИСТАННЯ
НЕЙРОННИХ МЕРЕЖ**

122 – Комп'ютерні науки

Галузь знань 12 – Інформаційні технології

Подається на здобуття кваліфікаційного рівня PhD candidate

Дисертація містить результати власних досліджень. Використання ідей,
результатів і текстів інших авторів мають посилання на відповідне джерело.

О.В. Носков

Науковий керівник:
Миронцов Микита Леонідович
доктор фізик-математичних наук,
старший науковий співробітник

Київ – 2025

Анотація

Носков О.В. Технологія збільшення розрізненої здатності мігрованих сейсмічних даних на основі використання нейронних мереж – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття кваліфікаційного рівня PhD candidate за спеціальністю 122 – Комп’ютерні науки. – Інститут телекомунікацій і глобального інформаційного простору Національної академії наук України, Київ, 2025. Дисертаційне дослідження присвячено вирішенню актуальної науково-технічної задачі збільшенню розрізненої здатності та збільшенню співвідношення сигнал/завада для мігрованих сейсмічних даних.

Мета роботи – збільшення розрізненої здатності мігрованих даних польової сейсмічної зйомки в 2D і 3D форматах із застосуванням згорткової нейронної мережі із оптимізованими для вирішення даної задачі параметрами, а саме – архітектурою мережі, функцією втрат і аугментованого набору вхідних синтетичних даних використаних для її навчання.

Відповідно до мети роботи було поставлено такі завдання дослідження:

- аналіз існуючих технік підвищення розрізненої здатності мігрованих сейсмічних даних з використанням нейронних мереж та визначення недоліків їх використання в геолого-геофізичних умовах Дніпровсько-Донецького басейну;
- формування масиву даних що відповідають геолого-геофізичним умовам Дніпровсько-Донецького басейну для навчання та перевірки моделі штучного інтелекту;
- підбір оптимальної архітектури нейронної мережі та підбір функцій втрат та їх комбінування для вирішення поставленої задачі;
- аугментація набору даних для ефективного тренування моделі;

- ітеративне тестування та внесення коригувань в модель нейронної мережі та вхідний масив даних для досягнення оптимальних результатів навчання моделі;
- отримання та перевірка результатів тренування моделі на практичних мігрованих кубах.

Об’єкт дослідження – процеси формування послідовностей даних для ефективного навчання моделі нейронної мережі з метою збільшення розрізненої здатності мігрованих матеріалів сейсмічної зйомки.

Предмет дослідження – інформаційна технологія обробки мігрованих сейсмічних даних для збільшення розрізненої здатності на основі використання нейронних мереж.

У першому розділі роботи описано еволюцію геофізичних досліджень, що проводились в межах головного нафтогазоносного басейну України, Дніпровсько-Донецької западини (ДДЗ), описано головні методики міграційної обробки польового сейсмічного матеріалу, що застосовуються в сучасній геології, описано розвиток машинного навчання як окремого напрямку робіт з даними, сконцентровано увагу на сучасних тенденціях алгоритмів нейронних мереж.

У зв’язку зі зростаючою тенденцією на залучення алгоритмів нейронних мереж до обробки сейсмічних даних, було приведено приклади їх успішного застосування в геологорозвідувальному процесі, зокрема в питанні поліпшення якості як попередньої обробки польових сейсмічних матеріалів, так і пост-обробки мігрованих сейсмічних 3D кубів та 2D профілів.

У другому розділі роботи описано сучасні тенденції в геологорозвідувальних роботах, у тому числі – побудову моделі родовища, що базується на сіквенс-стратиграфічному підході, що гармонійно поєднує в собі як свердловинні дані, так і матеріали сейсмозвідувальних робіт, формуючи якісний каркас для розповсюдження колекторських властивостей, а також прогнозування напрямку змін літологічного складу осадової товщі.

Проведено аналіз якості та достатності існуючих сейсмічних матеріалів для побудови моделі нейронної мережі для підкреслення ключових рис хвильового поля, що притаманні межі між окремими парасіквенсами. Дійдено висновку стосовно недостатності якості існуючих сейсмічних матеріалів і дійдено висновку стосовно необхідності створення додаткового кроку їх пост-обробки з метою збільшення розрізної здатності.

Проведено аналіз ринку існуючих програмних рішень в тому числі для покращення процесу геофізичної інтерпретації сейсмічних даних, виділено ряд програмних пакетів, а також обрано архітектуру нейронної мережі, що доцільно використовувати для вибудови програмного рішення поставленої задачі збільшення розрізної здатності мігрованих сейсмічних матеріалів.

В подальшому розділ містить опис побудови моделі штучного інтелекту для 2D набору даних – вказуються особливості компоновки самої моделі, обґрунтовується вибір активізаційної функції як окремих конволюційних блоків, так і загальну активізаційну функцію моделі. Роз'яснено вибір функції втрат як з точки зору механіки роботи для конкретної моделі штучного інтелекту, так і з точки зору кінцевого користувача – а саме спеціаліста з інтерпретації сейсмічних даних. Вказано чому найкраще з точки зору прогнозної статистики моделі рішення не є таким з точки зору подальшої роботи з даними.

Наприкінці розділу описано проблематику застосування існуючої прогнозної моделі фіксованого розміру до польових даних, попередньо чий розмір не є відомим. Описано процес трансформації даних із вхідного робочого формату *.SEG Y до робочого *.NUMPY і зворотної трансформації у вхідний формат для подальшого ведення інтерпретаційних робіт з даними покращеної якості.

У третьому розділі роботи описано задачу застосування створеної моделі для роботи з 2D даними до трьохмірних мігрованих кубів – а саме проблему відсутності часткового просторового контексту для прогнозу моделі. Обґрунтовано необхідність створення іншої моделі – на базі архітектури U-net.

Описано зміни, які були внесені як в модель, так і в тренувальний та перевірочний набори даних, а саме:

- алгоритм трансформації 2D зображень до псевдо 3D матриць, що імітують геологічні зміни в своїй структурі
- алгоритм афінних перетворень для подолання проблеми «горизонтальності» прогнозу моделі
- алгоритм блюр-зон, артефактів вхідних сейсмічних даних, що суттєво покращив якість прогнозу.

Сконцентровано увагу на розрахунки потужностей, необхідних для обрахунку збільшеного масиву даних для 3D варіанту мережі, наведено приклади підбору параметрі зерна прогнозу моделі для оптимізації розрахунків.

Наведено пояснення безальтернативності використання платних дата центрів для високонавантажених обрахунків моделі, наведено приклади якості прогнозу із використанням збільшеного зерна прогнозу і без нього. На додаток перелічено результати прогнозу моделі – куби без відновлення оригінального діапазону значень, і з його відтворенням, і наведено додаткові данні, що можна отримати за умови їх використання в процесі геологічного моделювання.

У четвертому розділі роботи описано рівні масштабування при веденні геологорозвідувальних робіт і вказано необхідність якісної прив'язки між сейсмічними і каротажними даними. Приведено найгостріші проблеми при роботі з індукційним каротажем – а саме усунення впливу показників сусідніх пластів для покращення вертикальної розрізняюваності, а також проблему визначення питомого радіального опору для коректного визначення літології та насичення пласта. Для кожної з висвітлених проблем було запропоноване рішення у вигляді простої нейронної мережі, що обробляє саме каротажні дані.

Ключові слова: модель нейронної мережі, 3D сейсмічні дослідження, 2D сейсмічні дослідження, розрізнявальна здатність, активаційна функція, функція втрат, аугментація даних, U-net архітектура, пост-обробка сейсмічних даних, прогнозування, моделювання.

Публікації здобувача

Праці, в яких опубліковано основні наукові результати дисертації

1. Karpenko O., Myrontsov M., Anpilova Y., Noskov O. Efficiency of Electric Logging in Thin-Layer Sections of Hydrocarbon Deposits (Gas Fields of the Precarpathian Depression). Zaporozhets, A. (eds) Systems, Decision and Control in Energy IV. Studies in Systems, Decision and Control, vol. 454, 2023 pp. 337-351. https://doi.org/10.1007/978-3-031-22464-5_20 ISSN 2198-4182 SCOPUS
2. Myrontsov M., Karpenko O., Dovgyi S., Anpilova Y., Noskov O. Information Technologies of Logging (Environmental Aspect). Zaporozhets, A., Popov, O. (eds) Systems, Decision and Control in Energy IV. Studies in Systems, Decision and Control, vol. 456, 2023 pp. 223-234 https://doi.org/10.1007/978-3-031-22500-0_15 ISSN 2198-4182 SCOPUS.
3. Noskov. O., Myrontsov M., Karpenko O., Dovgyi S., Anpilova Y. Implementation of Sequence-Stratigraphy Based Geological Studies in Ukraine. Zaporozhets, A., Popov, O. (eds) Systems, Decision and Control in Energy IV. Studies in Systems, Decision and Control, vol. 456, 2023 pp. 213-221. https://doi.org/10.1007/978-3-031-22500-0_14 ISSN 2198-4182. SCOPUS
4. О.В. Носков, М.Л. Миронцов. Застосування технології збільшення роздільної здатності мігрованих сейсмічних зображень для 2D сейсмічних зйомок за допомогою нейронної мережі, Екологічна безпека та природокористування. 2025 №1. DOI: <https://doi.org/10.32347/2411-4049.2025.1>
5. О.В. Носков, В.О. Охарєв. Застосування технології збільшення роздільної здатності мігрованих сейсмічних зображень для 2d- і 3D-зйомок. Міжнародний науково-технічний журнал Проблеми керування та інформатики, 2025. –49-59с. <https://doi.org/10.34229/1028-0979-2025-1-4>
6. Носков О.В. Технологія збільшення роздільної здатності мігрованих сейсмічних даних на основі використання нейронних мереж // Доповіді національної академії наук України:, 2024. – (12-17)с. <https://doi.org/10.15407/dopovidi2024.03.011>

Праці, які засвідчують апробацію матеріалів дисертації

7. Носков О.В., Миронцов М.Л. Побудова 3D моделі Комишнянського родовища: проблеми та шляхи їх вирішення. Сучасні інформаційні технології управління екологічною безпекою, природокористуванням, заходами в надзвичайних ситуаціях: виклики 2021 року // Колективна монографія за матеріалами XX Міжнародної науково-практичної конференції (Київ, 04-08 жовтня 2021 р.) / За заг. ред. С.О. Довгого. – К.: ТОВ «Видавництво «Юстон», 2021. –168-172с.
https://itgip.org/wp-content/uploads/2021/10/1_zbirka_2021.pdf
DOI: 10.35350/2021-1-1-1-223
8. Salata A., Noskov O. Geophysics and superresolution: practical issues and resolution. AI&BigData Online Day 2025.
<https://www.slideshare.net/slideshow/andrii-salata-geophysics-and-ai-superresolution-practical-issues-and-resolution-ua-d8c5/278092236>
9. O. Noskov. (2021) Concepts of modern field 3d model creation. XV International Scientific Conference “Monitoring of Geological Processes and Ecological Condition of the Environment”, Extended Abstracts, p. 1-5.
<https://doi.org/10.3997/2214-4609.20215K2018>
10. O. Noskov. (2021) 3d model of Komyshnianske field. Challenges and way forward. XV International Scientific Conference “Monitoring of Geological Processes and Ecological Condition of the Environment”, Extended Abstracts, p. 1-6.
<https://doi.org/10.3997/2214-4609.20215K2019>
11. O.V. Noskov, S.M. Levoniuk, M. L. Myrontsov. (2021) Creation of Geological 3D-model of Komyshnianske Field Based on the Sequence Stratigraphy Principles. SPE Eastern Europe Subsurface Conference DOI: <https://doi.org/10.2118/208507-MS>
ISBN: [978-1-61399-851-9](https://doi.org/10.2118/208507-MS)
12. Myrontsov, M., Krasovska I., Noskov O. Error in determining the geoelectrical parameters of reservoirs of finite thickness by the method of induction logging. 17th International Conference Monitoring of Geological Processes and Ecological

Condition of the Environment, Nov. 2022, Vol. 2023, p.1 – 5
<https://doi.org/10.3997/2214-4609.2023520049>

13. Myrontsov, M., Krasovska I., Noskov O. Dependence of accuracy of geophysical research of oil and gas wells on measurement error. 17th International Conference Monitoring of Geological Processes and Ecological Condition of the Environment, Nov. 2023, Vol. 2023, p.1 – 5. <https://doi.org/10.3997/2214-4609.2023520048>

ABSTRACT

Noskov O.V. Technology for Enhancing the Resolution of Migrated Seismic Data Using Neural Networks. – Qualification scientific work in the form of a manuscript. – Dissertation for obtaining the Ph.D. qualification level in the specialty 122 – Computer Science. – Institute of Telecommunications and Global Information Space, National Academy of Sciences of Ukraine, Kyiv, 2025.

This dissertation research addresses a pressing scientific and technical problem: improving the resolution and signal-to-noise ratio of migrated seismic data.

The aim of the study is to enhance the resolution of field seismic survey data in 2D and 3D formats using a convolutional neural network optimized specifically for this task. Optimization parameters include network architecture, loss function, and an augmented set of synthetic input data used for training the model.

In line with the research objectives, the following tasks were defined:

- Conducting an analysis of existing techniques for improving the resolution of migrated seismic data using neural networks, and identifying the limitations of their application in the geological and geophysical conditions of the Dnieper-Donets Basin.
- Compiling a dataset corresponding to the geological and geophysical conditions of the Dnieper-Donets Basin for training and validating the artificial intelligence model.
- Selecting the optimal neural network architecture, as well as identifying and combining appropriate loss functions to address the research problem.
- Augmenting the dataset to facilitate effective model training.
- Iterative testing and adjustments to the neural network model and input dataset to achieve optimal training results.
- Obtaining and validating the training outcomes of the model on practical migrated seismic volumes.

Research Object: The processes of data sequence formation for optimizing the training of a neural network model to enhance the discriminative capability of migrated seismic survey materials.

Research Subject: Information technology for processing migrated seismic data to enhance discriminative capability based on the application of neural networks.

The first chapter of the work describes the evolution of geophysical studies conducted within Ukraine's primary oil and gas basin, the Dnieper-Donets Basin (DDB). It outlines the key migration processing techniques applied to a field seismic materials in modern geology and presents the development of machine learning techniques as an independent direction for data handling and processing, focusing on contemporary trends in neural network algorithms.

Given the growing trend of using neural network algorithms for seismic data processing, examples of their successful application in geological exploration are provided. These examples highlight improvements in both the preliminary processing of field seismic data and the post-processing of migrated seismic 3D volumes and 2D profiles.

The second chapter discusses current trends in geological exploration, including reservoir modeling based on a sequence-stratigraphic approach. This approach seamlessly integrates well data and seismic survey materials, creating a robust framework for propagating reservoir properties and predicting changes in the lithological composition of sedimentary layers.

An analysis of the quality and sufficiency of existing seismic data for building an artificial intelligence model is presented. It emphasizes key features of the wavefield associated with boundaries between individual parasequences. Conclusions are drawn regarding the inadequacy of the existing seismic data resolution, underscoring the necessity for an additional post-processing step for its enhancing.

An analysis of the market for existing software solutions was conducted, including those aimed at improving the geophysical interpretation of seismic data. Several software packages were identified, and a neural network architecture was selected for building a software solution to address the task of increasing the resolution of migrated seismic materials.

Subsequently, the chapter includes a description of the artificial intelligence model constructed for 2D datasets. It outlines the specific features of the model's

composition and justifies the choice of activation functions for individual convolutional blocks as well as the overall activation function for the model. The selection of the loss function is explained, both in terms of its operational mechanics for the specific artificial intelligence model and from the perspective of the end user—namely, seismic data interpretation specialist. It highlights why the solution that is statistically optimal for model prediction may not necessarily be ideal for further data processing tasks.

The chapter concludes by describing the challenges of applying the existing fixed-size predictive model to field data, whose size is initially unknown. It details the process of data transformation from the input working format (*.SEGY) to the working *.NUMPY format and the reverse transformation back to the input format to facilitate further interpretative work with enhanced-quality data.

In the third chapter, the issue of applying the developed model for 2D data to three-dimensional migrated seismic volumes is discussed—specifically, the problem of the absence of partial spatial context for the model's predictions. The necessity of developing a new model based on the **3D U-Net** architecture is substantiated.

The modifications introduced to both the model and the training and validation datasets are described, including:

- An algorithm for transforming 2D images into pseudo-3D matrices that mimic geological variations in their structure.
- An affine transformation algorithm designed to address the problem of the model's "horizontal" prediction.
- A blur-zone algorithm for mitigating artifacts in input seismic data, which significantly improved the quality of predictions.

The focus is placed on calculating the computational power required for processing the expanded dataset for the 3D network variant. Examples are provided for selecting the grain size parameters of the model's prediction to optimize computations.

An explanation is given regarding the necessity of using paid data centers for high-load computations of the model, along with examples demonstrating the prediction quality with and without the expanded grain size parameter. Additionally,

the prediction results of the model are outlined — volumes without restoring the original range of values and with their restoration — and additional insights are provided that can be obtained when using these enhanced-quality data in the geological modeling process.

The fourth chapter of the study examines the levels of scaling involved in geological exploration and emphasizes the necessity of establishing a robust correlation between seismic and well logging data. The chapter outlines the most pressing issues associated with induction logging, particularly the mitigation of the influence of adjacent rock layers to enhance vertical resolution, as well as the challenge of determining the specific radial resistivity required for the accurate assessment of lithology and reservoir saturation. For each of these highlighted issues, a solution is proposed in the form of a simple neural network designed specifically to process logging data.:

Keywords: neuron network model, 3D seismic, 2D seismic, seismic resolution, activation function, loss function, data augmentation, U-Net architecture, post-processing of seismic data, modelling, forecasting.

ЗМІСТ

Список використаних позначень і скорочень	15
ВСТУП	16
РОЗДІЛ 1. Розвиток та сучасний стан алгоритмів обробки польових сейсмічних даних	
1.1 Розвиток та сучасні проблеми використання інформаційних технологій при обробці польових сейсмічних даних	22
1.2 Технологічний прогрес у сейсмічних дослідженнях	37
1.3 Історія розвитку машинного навчання	42
1.4 Нейронні мережі як підрозділ машинного навчання	45
РОЗДІЛ 2. Постановка задачі та загальний алгоритм її розв’язання для 2D профілів	
2.1. Побудова моделі сіквенс-стратиграфічного розчленування розрізу на прикладі Комишнянської площі	60
2.2. Якість мігрованих сейсмічних даних для побудови моделі для сіквенс-стратиграфічного розчленування	62
2.3. Аналіз існуючих програмних рішень для збільшення розрізної здатності	65
2.4. Виділення ряду програмних пакетів, які будуть використовуватись для побудови моделі штучного інтелекту	68
2.5. Аналіз ряду найбільш поширених архітектур моделей для вирішення задач збільшення розрізної здатності.	69
2.6 Відтворення архітектури моделі на базі мережі U-net для двомірного набору даних	72
2.7 Застосування моделі до реальних даних 2D профілів.	92
2.8 Перехід на 3D архітектуру U-Net	103
2.9 Висновки	105
РОЗДІЛ 3. Особливості побудови моделі на базі архітектури 3D U-net.	

3.1.	Алгоритм трансформації тренувального та валідаційного набору даних для застосування в мережі 3D U-net	108
3.2	Заходи стосовно аугментації тренувального набору даних, що внесли суттєвий вплив на якість прогнозу моделі	110
3.3	Зміни в компоновці моделі штучного інтелекту при переході з 2D до 3D U-net архітектури	115
3.4	Застосування моделі 3D U-net до реальних даних.	121
3.5	Висновки	124

РОЗДІЛ 4. Побудова мережі штучного інтелекту простої архітектури для вирішення обернених задач підвищення вертикальної розрізної здатності електричного та індукційного каротажу

4.1	Особливості застосування нейронних мереж для збільшення вертикальної розрізної здатності електричного та індукційного каротажу несфокусованими зондами	127
4.2	Опис моделі досліджуваного пласта-колектора та особливості будови моделі НМ для визначення радіального питомого опору	133

ВИСНОВКИ	139
-----------------	-----

СПИСОК ЛІТЕРАТУРИ	141
--------------------------	-----

Додаток А. Акти впроваджень	153
-----------------------------	-----

Список використаних позначень і скорочень

PSDM (Prestack Depth Migration) – глибинна міграція до сумування

RTM (Reverse Time Migration) – зворотна міграція часу

КМЗХ – методика кореляційно-методичних заломлених хвиль

ВВ – вуглеводні

ДДЗ – Дніпровсько-Донецька западина

ML – Machine Learning (машинне навчання)

НМ – нейронна мережа

ІІ – штучний інтелект

ПК – персональний комп'ютер

CNN – convolution neuron network (згорткова нейронна мережа)

ПО – питомий опір

УО – уявний опір

ВСТУП

Розвиток машинного навчання і алгоритмів глибокого навчання із залученням нейронних мереж зазнав значного зростання популярності за останні роки, що зумовлено трьома основними чинниками: ростом обчислювальних можливостей сучасної комп'ютерної техніки, появою нових алгоритмів навчання та розширенням обсягу доступних наборів даних для навчання моделей штучного інтелекту різних типів. Хоча перші два фактори легко доступні у сучасних комп'ютерах та у загальнодоступних бібліотеках машинного навчання, останній залишається викликом для багатьох областей застосування можливостей машинного навчання.

Інтерпретація даних сейсмічних досліджень є ключовим елементом у процесах циклу геологорозвідувальних робіт, а також вважається незамінним інструментом у процесі ідентифікації та деталізації нафтових і газових родовищ. Здатність точно окреслити геологічну будову вивчаємої території, а також виділити зону інтересу в межах вказаного розрізу, залишається пріоритетною для вивчення нових територій, а також ефективної експлуатації та дорозвідки відомих родовищ, однак цей процес вимагає значних людських зусиль і часу.

Техніка 2D та 3D зйомки, хоча й пропонує непрямий спосіб дослідження особливостей розрізу досліджуваної площі, однак, часто ускладнює процес вивчення площі через вади якості зібраного і обробленого польового сейсмічного матеріалу і обмежену вертикальну та інколи горизонтальну розрізнявальну здатність. Отже, розуміння особливостей розповсюдження геологічних даних на базі залучення сейсмічних досліджень залишається непростим комплексним завданням не зважаючи на технологічний прогрес як у зборі даних, так і в обробці.

Ріст проведених первинних досліджень без можливості виконання якісного поглибленого геологічного аналізу через вади якості матеріалу або брак спеціалістів для його опрацювання є поширеною проблемою багатьох галузей

науки, тому впродовж останніх років росте попит на застосування алгоритмів машинного навчання для трансформації первинно-оброблених даних як підготовчий крок для поглибленого, більш результативного, аналізу і опрацювання спеціалістами відповідних галузей.

Актуальність проблеми:

На сьогоднішній день для нафтогазової промисловості України якість сейсмічних даних є критично важливою складовою геологорозвідувального процесу. Однак є ряд фізичних обмежень, що ускладнює їх інтерпретацію та знижує точність подальших геологічних досліджень і бурових робіт. До цих обмежень слід віднести:

- наземний характер польових робіт, що в контексті Дніпровсько-Донецької западини (ДДЗ), виконуються в густо-заселеній території, активно залученій до аграрного господарства.
- здебільшого високі глибини покладів вуглеводнів, середні значення цільового інтервалу для багатьох площ центральної частини ДДЗ коливаються в межах 4,5-5,5 км.
- вузьку спектральну складову сигналу, що скеровується на приймачі під час польових робіт, зумовлену глибоким заляганням цільової частини розрізу.

Застосування машинного навчання та інших сучасних технологій для покращення якості сейсмічних даних має потенціал суттєво підвищити чіткість зображень, точність інтерпретації та кількість інтерпетуємих геологічних подій меншого порядку. Це дозволяє геологам та геофізикам створювати деталізовані проекти геологічного моделювання та сейсмічної інтерпретації, що є основою для закладання свердловин. Варто зазначити, що обробка сейсмічних даних є дорогою процедурою, а низький рівень впевненості картування горизонтів відбиття можуть призвести до значних фінансових втрат через неоптимальне розташування свердловин, які самі по собі коштують дуже дорого.

Існування публічних синтетичних наборів даних для тренування моделей машинного навчання є важливим чинником, що робить цей проект можливим. Тому, дослідження з покращення якості сейсмічних даних за допомогою

машинного навчання має значну **актуальність** та потенціал для економічно ефективного використання природних ресурсів в Україні [1].

Мета роботи – збільшення розрізної здатності мігрованих даних польової сейсмічної зйомки в 2D і 3D форматах із застосуванням згорткової нейронної мережі із оптимізованими для вирішення даної задачі параметрами, а саме – архітектурою мережі, функцією втрат і аугментованого набору вхідних синтетичних даних використаних для її навчання.

Об’єкт дослідження – процеси формування послідовностей даних для ефективного навчання моделі нейронної мережі з метою збільшення розрізної здатності мігрованих матеріалів сейсмічної зйомки.

Предмет дослідження – інформаційна технологія обробки мігрованих сейсмічних даних для збільшення розрізної здатності на основі використання нейронних мереж.

Фактичний матеріал та методи дослідження. У якості фактичного набору даних було використано загальнодоступний репозиторій з набором синтетичних 2D сейсмічних зображень у вигляді *.dat файлів згрупованих в пари – зображення високої розрізної здатності та його аналог низької якості. Готові моделі застосовувалась до реальних сейсмічних кубів і 2D профілів, що були опрацьовані різними сервісними компаніями в різні роки для АТ «Укргазвидобування» за різними алгоритмами обробки з метою тестування обмежень застосування моделі штучного інтелекту.

Достовірність та обґрунтованість. Підтверджується результатом буріння пошукових свердловин, які були закладено з участю сейсмічних матеріалів опрацьованих за допомогою моделі конволюційної нейронної мережі, представленій в роботі. Дослідження також було проведено до нових свердловин, що дали негативний результат для пояснення причин відсутності пасткових умов.

Практична значимість роботи. Розроблений алгоритм дозволяє отримати детальніше уявлення про геологічну будову в зонах збільшення перешарування та мінливості геологічного розрізу що збільшує впевненість

структурних побудов і, таким чином, покращує якість матеріалів, що подаються на закладання нових свердловин. В умовах пошукового буріння, де сейсмічні дані становлять базу геологічного прогнозу поширення колекторів та нафтогазоносності розрізу, алгоритм зберігає співвідношення амплітуд, що дозволяє використовувати спектр сейсмічних атрибутів для дослідження хвильового поля, і робить аналіз нових територій більш повноцінним.

Зв'язок роботи з науковими програмами, планами, темами. Винесена на розгляд робота аспіранта Носкова О.В. має зв'язок із наступними науковими роботами, що курувались керівником представленої роботи, Миронцовим М.Л., а саме «Моделювання електрометрії нафтогазових свердловин» (Гранти Президента України докторам наук для здійснення наукових досліджень, 2019, ДР № 0119U103192), а також «Розроблення програмно-методичного комплексу геофізичного та екологічного забезпечення інтенсифікації видобування газу із виснажених свердловин Дніпровсько-Донецької западини. Розділ 1. Моделювання електрометрії геофізичного дослідження свердловин (Науково-технічні проекти установ НАН України, 2021, ДР № 0121U108133)».

Положення, що винесені на захист

Наукова новизна:

- вперше створено 3D модель нейронної мережі для ефективної обробки реальних сейсмічних даних, що відповідають геолого-геофізичним умовам Дніпровсько-Донецького басейну на базі архітектури 3D U-net із трансформацією синтетичного набору 2D даних у псевдо 3D куби;
- вперше розроблено та реалізовано оптимізацію роботи функції втрат та метрик шляхом ітеративного підбору і аналізу впливу гіперпараметрів, що використовується для тренування конволюційної нейронної мережі з метою підвищення просторової розрізної здатності мігрованих матеріалів польової сейсмічної зйомки;
- вперше розроблено та впроваджено алгоритм аналізу методом вікна зі згладження екстремальних значень мігрованих сейсмічних даних за функцією

активації сігмоїди із подальшим відтворенням близького до первинного інтервалу при зворотній трансформації.

Особистий внесок здобувача полягає в наступному: всі результати, які становлять основний зміст дисертації були отримані автором самостійно. Ряд робіт було написано здобувачем самостійно [6, 9, 10].

У публікації [1] викладено поглиблений аналіз сейсмічних матеріалів і каротажних даних, що було використані для побудови сіквенс-стратиграфічної моделі осадконакопичення Комишнянського родовища; коротко описані проблеми моделювання і змальовано шляхи їх вирішення за рахунок пост-обробки сейсмічних даних. У роботі [2] протестовано ефективність розв'язання оберненої задачі даних електрометрії, також у роботі [3] порівняно ефективність електрометрії і інших методів каротажу, що використовуються при прив'язці даних ГДС до даних сейсміки. У публікації [4] описаний процес побудови моделі штучного інтелекту для 2D мігрованих сейсмічних даних, де висвітлюються питання достатності тренувального і перевірного наборів даних, а також підбір архітектури нейронної мережі для реальних даних, що відрізняються від синтетичних, які були використані в її навчанні. У публікації [5] представлена заключна стаття, що висвітлює питання застосування нейронної мережі для 2D і 3D мігрованих сейсмічних зйомок і описує ряд робіт, що було виконано для аугментації вхідних даних з метою збільшення продуктивності їх використання в фінальних моделях на реальних сейсмічних даних. У публікації [6] розроблено шляхи оптимізації архітектури та функції втрат моделі штучного інтелекту збудованої для збільшення розрізної здатності сейсмічних даних. У публікації [7] автором побудовано модель Комишнянського родовища; визначено інтервали де повнота сейсмічних даних недостатня для відображення геологічних процесів седиментації; описано шляхи вирішення цих проблем на базі інструментарія геологічного моделювання, що пропонується програмним пакетом Petrel від компанії Schlumberger. У роботі [8] висвітлено технічну складову виконаної роботи із акцентом на конкретних рішеннях, поставлених під час виконання роботи завдань. У публікації [9] надається огляд інструментарію

геологічного моделювання та сейсмічної інтерпретації, що використовується компанією «Укргазвидобування» в операційній роботі. У публікаціях [10, 11] надається опис підходу до побудови моделі осадконакопичення із застосуванням сіквенс-стратиграфічної методики. У публікаціях [12, 13] використано метод підвищення просторової розрізної здатності даних електрометрії.

Апробація результатів дисертаційного дослідження. Основні наукові положення та результати досліджень, викладені в дисертаційній роботі, доповідались і обговорювались на 4 науково-практичних конференціях, а саме на: XV International Scientific Conference “Monitoring of Geological Processes and Ecological Condition of the Environment”, Київ, 2021р; SPE Eastern Europe Subsurface Conference, Київ, 2021р., AI&BigData Day, 2025р.

Публікації. За темою дисертації з викладенням її основних результатів опубліковано 13 наукових праць, серед яких три – у наукових фахових виданнях України (в тому числі 1 – одноосібна), 1 – у науковому періодичних виданнях іноземних держав, що входять до Європейського союзу та входять у наукометричну базу SCOPUS, 9 – у електронному міжнародному виданні що входить у наукометричну базу SCOPUS. Із праць, що опубліковано в співавторстві в дисертаційній роботі використано виключно ті результати, які були одержані здобувачем особисто.

Об’єм та структура роботи. Дисертаційна робота складається із вступу, чотирьох розділів, висновків, списку використаних джерел зі 105 найменувань та 1 додатку. Повний обсяг дисертації становить 155 сторінок машинописного тексту. Основний зміст викладений на 140 сторінках. Робота ілюстрована 48 рисунками та 2 таблицями. Робота супроводжується 1 додатком.

РОЗДІЛ 1. РОЗВИТОК ТА СУЧАСНИЙ СТАН АЛГОРИТМІВ ОБРОБКИ ПОЛЬОВИХ СЕЙСМІЧНИХ ДАНИХ

1.1. Розвиток та сучасні проблеми використання інформаційних технологій при обробці польових сейсмічних даних

Історія розвитку геофізичних методів пошуку корисних копалин в Україні пройшла декілька етапів, але найбільш визначним є періоди з 60-тих по 90-ті роки минулого сторіччя. В цей проміжок часу відбувся інтенсивний розвиток та широке використання різноманітних геофізичних методів для пошукових та розвідувальних робіт, особливо у сфері видобутку нафти та газу. Початковий період випадає на 1960-1980-ті роки, в цей період основні зусилля були спрямовані на ручну обробку сейсмічних даних та використання базових алгоритмів.

Численні дослідження висвітлено в роботах вітчизняних науковців [1-3]. Перші алгоритми були досить простими і використовувалися для обчислення часу приходу сейсмічних хвиль та первинного аналізу даних [1].

В період з 1986 року з розвитком комп'ютерних технологій в Україні почали використовуватися більш складні алгоритми для обробки сейсмічних даних. Це включало цифрову обробку сигналів, фільтрацію шумів та базові методи інверсії даних. На початку 90-х українські науковці розробили спеціалізовані програмні пакети для обробки польових сейсмічних даних. Це дозволило автоматизувати процеси та підвищити точність результатів. Зокрема, були розроблені алгоритми для покращення якості сейсмічних зображень, методи міграції даних та покращені методи інверсії. [2]

Починаючи з 2003 року відбулось помітне зменшення обсягів геофізичних досліджень через економічну кризу та недбале ставлення керівництва до розвитку мінерально-сировинної бази країни. Попри існуючі проблеми, в сучасні алгоритми обробки польових сейсмічних даних в Україні інтегровано новітні

технології, такі як PSDM (Prestack Depth Migration, глибинна міграція до сумування), RTM (Reverse Time Migration, Зворотна міграція часу) міграції сейсмічних даних 3D зйомок. [3]

Отже, розвиток методів обробки польових сейсмічних даних в Україні пройшов довгий шлях, включаючи впровадження як традиційних, так і сучасних підходів до аналізу та інтерпретації польових даних, таких як гравіметрія, електромагнітні техніки, а також автоматизована обробка геофізичної інформації. Один із важливих етапів розвитку обробки польових даних пов'язаний з використанням методики кореляційно-методичних заломлених хвиль (КМЗХ), а також впровадженням сучасних 2D і 3D методів сейсморозвідки, тож розглянемо кожен з цих методів [4].

Гравіметричний аналіз - це метод геофізичного дослідження, що використовує вимірювання гравітаційного поля Землі для вивчення підземних структур. Цей метод заснований на тому, що різні геологічні структури та матеріали мають різну густину, що впливає на локальне гравітаційне поле. Ця методика відносно дешевша за 3D сейсмічну зйомку, тому використовується на більш ранніх етапах геологорозвідувальних робіт для оцінки перспективності площі пошуків і первинного картування геологічних структур.

Основні парадигми гравіметричного аналізу включають:

1. Вимірювання гравітаційного поля. За допомогою спеціальних приладів, гравіметрів, проводяться точні вимірювання сили тяжіння на поверхні землі або в повітрі (гравіметрія з літальних апаратів). Ці вимірювання фіксують зміни гравітаційного поля, що можуть бути спричинені підземними структурами з різною густиною.

2. Аналіз аномалій. Результати вимірювань порівнюються з теоретичним гравітаційним полем, яке очікується для однорідної Землі. Відхилення від цього теоретичного поля, відомі як гравітаційні аномалії, вказують на наявність підземних структур або матеріалів з відмінною густиною.

3. Інтерпретація даних. Гравітаційні аномалії аналізуються для визначення розташування, форми, розмірів та густини підземних структур. Це може

включати застосування математичних моделей та інверсійних методів для більш точної інтерпретації даних.

4. Застосування в геології та геофізиці. Гравіметричний аналіз широко використовується для пошуку корисних копалин (вуглеводнів, рудної сировини), дослідження геологічних структур (визначення глибини осадових басейнів, вивчення тектонічних структур), а також у вулканології та гідрогеології.

Гравіметричний аналіз є безконтактним методом, що дозволяє досліджувати великі площі з мінімальним впливом на навколишнє середовище. Він також може використовуватися у важкодоступних або екологічно чутливих районах.

Точність методу може бути обмежена через вплив зовнішніх факторів, таких як топографія, погодні умови або людська діяльність. Крім того, інтерпретація гравітаційних аномалій може бути неоднозначною без додаткових даних з інших геофізичних методів.

Таким чином, гравіметричний аналіз є потужним інструментом для дослідження підземних структур, але його ефективність часто покращується при комбінуванні з іншими геофізичними методами.

Автоматизована обробка геофізичної інформації стала ключовим етапом в сучасних геологічних та геофізичних дослідженнях. Цей процес використовує комп'ютерні технології та алгоритми для аналізу, інтерпретації та візуалізації великих об'ємів даних, зібраних з різних джерел, таких як сейсмічні датчики, гравіметричні та магнітні вимірювання, а також віддалене зондування та буріння. Однією з головних переваг автоматизованої обробки є швидкість і ефективність обробки великих обсягів даних. Комп'ютерні алгоритми дозволяють швидко аналізувати інформацію та виділяти ключові особливості, які можуть вказувати на наявність корисних родовищ або геологічних структур.

Електромагнітні методи обробки сейсмічних даних - це важливий аспект в геофізичних дослідженнях. Вони використовуються для аналізу та інтерпретації інформації, отриманої за допомогою сейсмічних приладів. Одним з ключових методів є електромагнітна індукція, яка полягає у використанні

змінних магнітних полів для стимулювання електричних струмів у ґрунті або породах. Ці струми генерують свої власні магнітні поля, які можуть бути виміряні на поверхні або в глибині. Аналіз цих даних дозволяє отримати інформацію про властивості ґрунту або порід, такі як провідність, магнітна проникність та інші.[4]

Крім електромагнітної індукції, існують інші електромагнітні методи, такі як електромагнітна томографія, яка використовує магнітні поля для створення тривимірних зображень внутрішньої структури ґрунту або порід. Ці методи дозволяють отримати детальну інформацію про геологічні формації і шари, що знаходяться під землею. Використання електромагнітних технік для обробки сейсмічних даних є важливим інструментом для геофізичних досліджень і може мати велике значення для різних галузей, включаючи нафтогазову промисловість, геотермальну енергетику та інженерні дослідження [4].

Електромагнітні методи – це група геофізичних методів, що використовують електромагнітні поля для дослідження підземних структур. Ось короткий опис основних електромагнітних методів:

1. Метод природного електромагнітного поля (МТ). Принцип методу полягає у вимірюванні природних варіацій електричних і магнітних полів на поверхні Землі. Використовується для дослідження глибоких геологічних структур, включаючи нафтові і газові родовища, тектонічні плити та глибокі водоносні горизонти.

2. Метод контрольованих джерел електромагнітного поля (CSEM). Принцип полягає у використанні штучних джерел електромагнітного поля для створення сигналів, які проникають у підземні структури. Застосовується для пошуку і дослідження нафтових і газових родовищ, визначення електричних властивостей підземних порід.

3. Метод радіохвильового зондування (GPR). Принцип полягає у випромінюванні високочастотних радіохвиль і аналіз їх відбиття від підземних об'єктів. Застосовується для дослідження неглибоких підземних структур, таких як археологічні об'єкти, інженерні комунікації, ґрунтові шари.

4. Метод індукційної електромагнітної розвідки (ЕМ). Принцип полягає у використанні електромагнітних індукторів для створення змінного магнітного поля та вимірювання індукованих струмів у підземних структурах. Застосовується для визначення електропровідності підземних порід, пошук рудних родовищ, визначення глибин підземних вод.

Ці методи дозволяють досліджувати різноманітні підземні структури, надаючи важливу інформацію про електропровідність, діелектричні властивості та магнітні характеристики гірських порід. Вони є важливими інструментами в геофізиці, геології, гідрогеології та інших науках [5-8].

Методика кореляційно-методичний заломлених хвиль (КМЗХ) є одним з перших методів, застосованих для обробки сейсмічних даних в Україні. Ця методика базується на аналізі заломлених хвиль, які відбиваються від різних геологічних шарів під час проведення сейсмічних зйомок. Основна мета КМЗХ полягає в отриманні інформації про структуру ґрунтових розчленувань і глибину розташування корисних копалин, таких як вуглеводні. Серед переваг цього методу слід визначити доступність та економічність, оскільки використання цього підходу не потребує складного обладнання і може бути виконано за відносно низькою вартістю. Також варто зазначити, що методика є достатньо простою для виконання та інтерпретації результатів, але попри всі переваги, у цього підходу є деякі недоліки, як от обмежена точність в порівнянні з сучасними методами, а також застарілість, оскільки з розвитком нових технологій цей метод поступово втратив свою актуальність, в порівнянні з методами 2D і 3D сейсмічних зйомок.

Зоклад стосується **сучасних методів 2D та 3D сейсмічних зйомок**, вони значно перевершують традиційні методи, такі як КМЗХ, за точністю та деталізацією отриманих даних. Вони дозволяють створювати тривимірні моделі геологічних структур, що є особливо важливим для точного визначення розташування корисних копалин. 2D сейсмічні зйомки включають запис сейсмічних хвиль вздовж однієї лінії профілю, що дозволяє отримати двовимірне

зображення підземних структур. Цей метод використовується для попереднього дослідження територій і картування основних геологічних структур.

3D сейсмічні зйомки своєю чергою записують сейсмічні хвилі з різних напрямків, створюючи тривимірну модель підземних структур. Використовуються для детального дослідження територій, що дозволяє точніше визначати розташування та обсяг покладів корисних копалин.

Методика сейсморозвідки застосовується для дослідження геологічних об'єктів, виходячи з використання пружних коливань, відомих як сейсмічні хвилі. Цей метод заснований на залежності швидкості розповсюдження сейсмічних хвиль від характеристик геологічного середовища, включаючи склад гірських порід, рівень їх пористості, наявність тріщин, рівень насиченості водою та інші параметри. Слід зазначити важливість сейсморозвідки, як інструменту дослідження геологічних структур та пошуку корисних копалин [9-10].

Сейсмічні дослідження в ДДЗ спрямовані на вивчення підземних структур за допомогою сейсмічних хвиль, що відбиваються від різних геологічних шарів. Ці дані дозволяють визначити розташування нафтогазоносних пластів, оцінити їх потенціал та планувати буріння. Варто зазначити, що збір польових даних і їх міграція для родовищ Дніпровсько-Донецької западини (ДДЗ) пов'язаний з деякими проблемними, які потребують уваги та розробки спеціалізованих рішень [6]. Основні засади цієї методики полягають в:

1. Використанні сейсмічних хвиль. Сейсморозвідка базується на використанні звукових хвиль, що відбиваються від геологічних формацій. Сейсмічні джерела, такі як вибухові навантаження або сейсмічні джерела, створюють звукові хвилі, які проникають у ґрунт. Потім датчики (геофони) реєструють відбиті хвилі, які дають інформацію про геологічні структури.

2. Аналізі рефлексії та розсіяння хвиль. Головний принцип сейсморозвідки полягає у вивченні рефлексії (відбиття) та розсіяння сейсмічних хвиль. По мірі того, як ці хвилі зустрічаються з різними геологічними шарами, вони

відбиваються або розсіюються, надаючи інформацію про їх структуру та глибину.

3. Сейсмічній обробці даних. Після збору сейсмічних даних вони піддаються спеціальній обробці, що включає фільтрацію, ампліфікацію, конволюцію та інші методи аналізу. Це допомагає виокремити корисну інформацію від шумів та інших завад.

4. Інтерпретації результатів. Після обробки даних геологи проводять інтерпретацію отриманих результатів. Це включає визначення глибини, розміру та характеристик геологічних формацій, таких як поклади вуглеводнів [9].

5. Моделюванні геологічних структур. Всі сучасні методи сейсморозвідки також використовують комп'ютерне моделювання для реконструкції тривимірного образу геологічних структур [11-13].

Проходячи через геологічні шари з різними властивостями, сейсмічні хвилі відбиваються від різних об'єктів та повертаються на сейсмоприймач. Зареєстровані дані після обробки дозволяють створити дво- або трьох вимірне аналогове зображення, що базується на просторовому розміщенні а також інтенсивності відбиттів від геологічних об'єктів, відоме як сейсмічний розріз або тривимірний масив даних, який являє собою сейсмічний куб (рис. 1.1).

Куб розбивається на вертикальні зрізи вздовж осі, що відповідає положенню сейсмоприймачів (інлайни або *inlines*), або поперек (кросслайни, або *crosslines*, *xlines*) (див. рис. 1.1), а сам куб може бути виконаним в залежності від типу обробки як у часовому так і в глибинному доменах. Отже, у геофізиці сейсмічний куб є тривимірним об'ємом, що складається з обробленого масиву даних польових сейсмічних досліджень. Він формується з мережею точок вибухів (джерел сейсмічних хвиль) та приймачів (датчиків), які реєструють відбиті сигнали. Інлайни та кросслайни – це ключові елементи цієї мережі, що дозволяють створити тривимірну картину підземних структур.

Дизайн геометрії сейсмічної зйомки є важливим аспектом планування будь-якого сейсмічного дослідження, а правильне розміщення інлайнів та кросслайнів критично впливає на якість отриманих даних та точність

інтерпретації. Таким чином дизайн геометрії сейсмічної зйомки має відповідати декільком вимогам, а саме:

- Організація сейсмічних ліній уздовж падіння шарів, що дозволяє отримати більш детальну інформацію про шари порід, оскільки хвилі відбиваються під кутом, який максимально збільшує їх реєстрацію приймачами.

- Сейсмічні лінії (інлайни) мають бути розміщені поперек головних диз'юнктивних порушень в межах досліджуваної площі, що допомагає деталізувати трасування та тип таких порушень і чіткіше визначити випадіння по розрізу, оскільки хвилі, що перетинають порушення дають різні значення імпедансу на межах горизонтів відбиття, утворюючи тим самим чіткішу картину в мігрованих матеріалах зйомки. Якщо лінії сейсмічної зйомки проходять субпаралельно трасуванню порушень, то мінлива природа диз'юнктивів дає змішані дані імпедансу, що в контексті мігрованих матеріалів ускладнює інтерпретацію за рахунок «розмитості» мігрованого зображення в зоні самої незгідності залягання.

Відповідаючи цим принципам, можна створювати високоякісні сейсмічні зображення, що є основою для подальшої геологічної інтерпретації і прийняття рішень щодо видобутку корисних копалин [9-10].




Рисунок 1.1 – Приклад відображення сейсмічного куба




Рисунок 1.2 - Сейсмопрофіль (сейсмотраси з відхиленням/сейсмотраси з кольоровим кодуванням відбиттів)

Отже, інлайни та кросслайни складаються з тих же сейсмотрас (рис. 1.2), з близькими один до одного абсолютними значеннями відхилення, що характеризують поступову зміну сейсмічного розрізу уздовж конкретної секції площі сейсмічної зйомки за виключенням зон різкої зміни умов седиментації, що відображається в відповідній різкій зміні характеру сейсмічних відбиттів і служить чудовим літологічним маркером границі двох різних циклів седиментації. Відмінності можуть також виникати у місцях розломів, проте загальна схожість залишається. Отримані дані піддаються ручній обробці фахівцями-інтерпретаторами, які інтерпретують в межах площі сейсмічних досліджень окремі сейсмічні відбиття, особливості їх поширення, а також окремі врізані геологічні об'єкти такі як соляні діапіри, диз'юнктивні порушення та інші особливості геологічної структури. Працюючи з 3D кубом або 2D профілем, інтерпретатор починає з верифікації відбиттів та картування геологічних границь, що характеризують зміни у характері осадконакопичення для площі досліджень (рис. 1.3). Для кожного інтерпретованого горизонту використовується автоматична, напів-автоматична або ручна інтерпретація в залежності від контрасту відбиттів в зоні трасуємого об'єкту та витриманості геологічної події.




Рисунок 1.3 – Приклад зрізу сейсмічного куба з прив’язаними у часі свердловинами

В цьому випадку інтерпретатор в часовому домені проводить попередню роботу з побудови синтетичних сейсмограм для свердловин з існуючим комплексом ВСП (вертикальне сейсмопрофілювання) за допомогою процесу часової прив’язки свердловин (seismic to well tie), що дає змогу побудувати зв’язок між свердловинними даними в глибинному і сейсмічними – в часовому доменах, після чого проводиться ручна/напівручна або автоматична інтерпретація структуроформуючих відбивальних горизонтів і порушень, що в подальшому супроводжується деталізаційною інтерпретацією зони інтересу де є або очікується поклад вуглеводнів.

Сейсмічні методи критично-важливі для розв’язання структурних та регіональних геологічних проблем. Вони мають перевагу серед інших геофізичних методів у пошуках нафти, газу, залізної руди, вугілля та інших

корисних копалин. Складність полягає в унікальності кожного набору даних через особливості геологічних формацій у досліджуваному регіоні, відмінностей у технічних засобах та методах сейсморозвідки, а також різноманітність методів обробки та міграції польових даних відповідно обраної методики при створенні мігрованих кубів або 2D профілів [10].

Навіть зовнішні перешкоди, наприклад, інфраструктура родовищ корисних копалин, а також фізичні завади для збору якісного матеріалу – складні ландшафтні умови (ліси/яри/болота, річки), навантажені автомобільні траси, або населені пункти, збір сейсмічної інформації в зоні яких суттєво ускладнений. Останнє створює ряд проблем для компаній з розвідки/дорозвідки родовищ видобувними підприємствами Української нафтогазовидобувної галузі через високий рівень заселення пріоритетних для пошуку вуглеводнів областей Східного нафтогазового регіону – Полтавської, Харківської та Сумської.

У випадку дослідження Дніпросько-Донецької западини (ДДЗ) виникають деякі складнощі під час збору даних, які пов'язані з наступними проблемами:

1. Складний рельєф. Складний рельєф може викликати розсіювання або спотворення сейсмічних хвиль, що зменшує точність геологічних даних. Яри, ліси, пагорбові ділянки можуть ускладнити доступ до локацій для розміщення сейсмічного обладнання відповідно дизайн-проекту сейсмічної зйомки.

2. Велика кількість населених пунктів. Місцеві спільноти можуть виступати проти проведення геологічних досліджень через побоювання щодо впливу на навколишнє середовище, а також пошкодження транспортної інфраструктури. Також можуть існувати законодавчі обмеження щодо ведення досліджень і видобутку ресурсів у певних районах (заповідники, заказники), що вимагають додаткових дозволів або регуляцій.

3. Наявність інфраструктури родовищ. Необхідність інтеграції нових розвідувальних та видобувних проектів з уже існуючими нафтогазовими об'єктами може ускладнювати логістику та планування. Існуюча інфраструктура родовищ вуглеводнів може зашкодити якісному збору польових сейсмічних даних через створюємі нею шумові завади.

4. Складнощі доступу. Доступ до деяких ділянок може бути ускладнений через географічні або інфраструктурні обмеження, особливо в віддалених або малонаселених регіонах, що є досить суттєвою проблемою для Західного нафтогазового регіону.

5. Змінні погодні умови. Суворі погодні умови можуть перешкоджати роботі на місцевості, особливо під час зимових місяців або в періоди інтенсивних опадів.

6. Проблеми з міграцією даних. Сучасні сейсмічні дослідження генерують великі обсяги даних, що вимагають значних ресурсів для обробки і зберігання. Проблеми із сумісністю форматів даних між різними системами і програмами можуть ускладнювати обробку та аналіз [14].

Для ефективної роботи в таких умовах необхідно використовувати передові інформаційні технології, зокрема сейсмічні дослідження з використанням бездротових технологій, які можуть забезпечувати менший вплив на навколишнє середовище та населені пункти. Також потрібно тісно співпрацювати з місцевими спільнотами та урядовими організаціями для забезпечення дотримання відповідних екологічних норм і регуляцій.

Останні дані досліджень наразі свідчать про значний потенціал України у сфері нетрадиційних вуглеводнів, газ з ущільнених порід. Ці ресурси мають потенціал, який може суттєво доповнити запаси традиційних видів вуглеводнів у випадку відновлення контролю над окупованими територіями. І одним із перспективних районів, який варто відзначити, знаходиться у північно-західній частині Дніпровсько-Донецької западини (ДДЗ). За останні роки Україна в значній мірі наростила щорічний видобуток вуглеводнів (більше 1 млрд куб. м. газу) саме за рахунок компанії зі зйомки нових або переробки існуючих матеріалів 3D сейсміки для дорозвідки існуючого фонду родовищ та відкриття нових [11-13].

Отже, таким чином Дніпровсько-Донецька западина (ДДЗ) є головним нафтогазовим басейном України, який має вирішальне значення для нафтогазової промисловості країни. Геологічна структура розташована в

центральної та східній частинах України, простягається з північного заходу на південний схід, охоплюючи частини Київської, Чернігівської, Полтавської, Сумської, Харківської та Дніпропетровської областей. Западає є частиною великої Дніпровсько-Донецької системи рифту, яка утворилася в результаті потужних тектонічних процесів у земній корі під час палеозою [3].

Методи обробки польових сейсмічних даних є важливою складовою частиною геофізичних досліджень. Вони дозволяють отримати детальну інформацію про структуру та властивості глибинних шарів земної кори, що є важливим для розуміння характеру процесів седиментації, що відбувались в зоні робіт, а також виділенню і дослідженню зон ймовірного розповсюдження покладів вуглеводнів. Для покращення якості мігрованих даних сейсмічної зйомки слід розглянути послідовні кроки з обробки сейсмічних даних:

- вивчення історичних даних, що включає аналіз раніше здійснених сейсморозвідувальних робіт та фонду розбурених свердловин для кореляції сейсмічних даних;

- 2D сейсмічна зйомка, що дозволяє сформувати зображення розрізу через трансформацію хвильового поля, зареєстрованого під час сейсмічних спостережень. 2D міграція використовується для обробки даних, зібраних у двовимірному форматі. Цей метод підходить для початкових стадій геологорозвідувальних робіт, мета яких – попередня оцінка будови площі досліджень, а також попереднє виділення та картування розмірів пошукових об'єктів.

- 3D міграція є наступним кроком геологорозвідувальних робіт і застосовується для створення тривимірних даних, надаючи більш детальне та точне зображення підземних структур. Цей метод є надзвичайно важливим для складних геологічних умов [14].

- моделювання геологічних процесів, що полягає у використанні отриманих даних для створення комп'ютерних моделей площ досліджень, які допомагають прогнозувати розповсюдження, а також розподіл параметрів продуктивних горизонтів.

Що стосується варіантів обробки польових матеріалів, то розрізняють певну кількість алгоритмів міграції даних, які пройшли досить довгий еволюційний шлях розвитку. Починаючи з простіших розрізняють:

- **Алгоритм простої міграції (Kirchhoff migration)**, який базується на законах геометричної оптики і використовується для міграції 2D та 3D сейсмічних даних. Він розраховує різницю часу прибуття сейсмічних хвиль від джерела до реєстраторів і використовує ці дані для виправлення просторових спотворень у зображенні.

- **Міграція фазових зсувів (Phase-shift migration)** являє собою алгоритм, який використовується для обробки даних в умовах геологічної нерівномірності акустичних властивостей ґрунту. Він передбачає перетворення сейсмічних даних у частотно-хвильовий домен, з подальшим застосуванням фазових зсувів для вирахування розповсюджень хвиль і фінальним поверненням їх у просторовий домен для створення зображення поверхні. Різниця між простою міграцією Кірхгофа і міграцією фазових зсувів полягає в тому що остання краще справляється з комплексними варіаціями швидкості, тоді як перша може мати труднощі з складними геологічними структурами, якщо накладені відбиті хвилі (multiples) не враховані належним чином.

- **Радонівська міграція (Radon Transform migration)** – використовується для покращення зображення підповерхневих структур. Вона базується на радонівському перетворенні, яке дозволяє перетворити часові сигнали у простір відстаней і кутів (перетворення Радона) допомагаючи ізолювати та підсилити сигнали, які важко розпізнати через високий рівень шуму або складні геологічні умови. Алгоритм спочатку застосовує радонівське перетворення, щоб виокремити прямі та непрямі події, а потім виконує міграцію даних для створення точного зображення розрізу. Цей метод особливо важливий для дослідження приповерхневих нафтогазових родовищ [15], проте він дуже чутливий до якості вхідних даних.

- **Комплексна міграція (Depth migration)** – алгоритм, що використовується для обробки тривимірних сейсмічних даних та включає в себе різні підходи, такі як алгоритм Кірхгофа та інші методи оптимізації.

- **Depth Migration** — це загальний термін для міграції сейсмічних даних у глибинному домені, який включає різні методи, такі як RTM і PreSDM. Метод полягає у тому, що дані мігруються з часового масштабу у глибинний, використовуючи швидкісні моделі. Серед переваг варто зазначити точне зображення геологічних структур у глибинному домені. Серед недоліків слід згадати залежність від свердловинних даних. До прикладу, якщо в моделі використані лише свердловинні дані з апікальної частини складки, периклінальні частини структури можуть бути відображеними з певним рівнем похибки. Застосовується для детального аналізу підземних структур, включаючи розвідку нафти і газу, а також допомагає у плануванні та управлінні видобутком природних ресурсів [16-20].

- **RTM (Reverse Time Migration)** — це сучасна високоточна методика міграції сейсмічних даних, яка використовує повну форму хвильового рівняння для реконструкції зображень підземних структур. Принцип методу полягає у тому, що сейсмічні хвилі моделюються у зворотному напрямку від приймачів до джерела і враховується весь комплекс хвильових ефектів, включаючи дифракції та множинні відбиття. Серед переваг цього методу слід зазначити високу точність та деталізацію зображень навіть у складних геологічних умовах (наприклад, соляних штоків). А також ефективність для виявлення та аналізу глибоких і складних підземних структур. Метод можна використовувати для дослідження глибоководних басейнів та регіонів з великою складністю геологічних структур [21].

- **PreSTM (Pre-Stack Time migration)** – це методика обробки сейсмічних даних, яка покращує зображення сейсмічного розрізу до сумування даних. Методика передбачає переміщення сейсмічних подій на їх правильні часові позиції до підсумування шляхом використання міграційних алгоритмів,

оновлення швидкісної моделі на основі цих результатів міграції і проведення фінальної ітерації мігрування на основі оновленої швидкісної моделі.

- **PreSDM (Pre-stack Depth Migration)** — це метод міграції сейсмічних даних до сумування (до об'єднання окремих трас) у глибинному домені. Принцип методу полягає в тому, що процес міграції застосовується до кожної окремої сейсмічної траси до їх комбінування, а дані трансформуються у глибинний масштаб, враховуючи швидкості розповсюдження хвиль. Серед переваг методу слід зазначити високу розрізнявальну здатність, що полягає у детальному відображенні геологічних структур, а також можливість корекції швидкісної моделі в процесі міграції, що підвищує точність кінцевого зображення. Метод використовується для точного картування підземних структур, що дозволяє краще зрозуміти геологію регіону і підходить для областей з великою варіабельністю швидкостей і складними геологічними умовами [22].

Таким чином, наведені методики сейсмічної міграції забезпечують високу точність і деталізацію зображень підземних структур. Вони є критично важливими для ефективної розвідки і розробки природних ресурсів, особливо у складних геологічних умовах.

1.2. Технологічний прогрес у сейсмічних дослідженнях

Нові вимоги в нафтогазовій промисловості, що виникають у зв'язку з технологічним прогресом і підвищенням уваги до екологічних аспектів, вимагають впровадження передових рішень у сфері сейсморозвідки. Саме використання сучасних інформаційних технологій дозволило зробити певний прорив в цьому напрямку.

Наземна сейсморозвідка, яка є одним із ключових інструментів пошуку і вивчення родовищ вуглеводнів, традиційно має обмеження зумовлені поверхневими умовами – так урбанізовані місцевості, лісисті райони, заплавні зони та інші природно-охоронні території можуть ускладнювати або навіть

унеможливлувати проведення сейсморозвідки та впливати на її результативність [22].

Однією із сучасних тенденцій, спрямованих на зменшення впливу навколишнього середовища на якість сейсмічної зйомки, є перехід до бездротових систем реєстрації, відомих як сейсморозвідка мінімального впливу. Використання бездротового обладнання дозволяє значно знизити негативні ефекти поверхневих умов на якість отримання польових матеріалів під час проведення польових робіт, оскільки обладнання може бути встановлене без використання дротового з'єднання [22].

Бездротові системи сейсморозвідки відкривають нові можливості для проведення комплексних досліджень важкодоступних територій, включаючи природно-охоронні зони та інші маловивчені області. У перелічених умовах розгортання сейсмічних кабелів може бути надзвичайно складним або навіть неможливим. Використання бездротових технологій дозволяє легко вирішувати ці проблеми, забезпечуючи мінімальний вплив на природу та швидку розстановку приймачів.

Гнучкість та легкість масштабування бездротових систем реєстрації сейсмічних даних надають їм значні переваги у порівнянні з традиційними методами. Відсутність довгих дротів дозволяє легко збільшувати кількість каналів приймання та проводити високоякісну широкоазимутальну сейсморозвідку з використанням окремих сеймоприймачів на значні глибини [23].

Успішний пілотний проект, реалізований спільними зусиллями компаній ТОВ "ДТЕК Нафтогаз" і ТОВ "ДЕНІМЕКС ГЕО" на Хорошівській площі, підтверджує переваги використання бездротових рішень. Цей проект відкриває нові можливості для використання сейсморозвідки в раніше недоступних районах та реалізації проектів високоякісного знімання. Впровадження бездротових телеметричних систем у практику геологорозвідувальних робіт розширює можливості сейсморозвідки в багатьох відношеннях та сприяє

вирішенню відповідних проблем. До переваг бездротових систем по відношенню до традиційних слід віднести:

- підвищення продуктивності та мобільності у полі, оскільки можна уникнути складної процедури змотування та розмотування кабелів, що призводить до зменшення кількості персоналу у польових роботах та автотранспорту, а отже, до зниження витрат на дослідження;

- можливість проведення сейсморозвідувальних робіт у районах, де використання іншого обладнання обмежене через поверхневі умови;

- реалізація проектів з великою кількістю каналів та окремими сейсмоприймачами для застосування прямих індикаторів вуглеводнів у сейсмічному полі;

- зменшення негативного впливу геологорозвідувальних робіт на довкілля, оскільки відпадає необхідність у спеціальному автотранспорті для змотування та розмотування кабелів;

- можливість розширення набору техніко-методичних засобів під час польових досліджень, таких як нерівномірне збільшення щільності ліній приймання у разі наявності перешкод.

Загалом варто зауважити, що використання активних бездротових систем дозволяє не лише значно прискорити проведення польових досліджень, навіть під час виконання проектів з високою щільністю спостережень, а й отримувати високоякісні дані та мінімізувати пропуски, що в свою чергу знижує ризики та невизначеності геологічних моделей. Мобільність та гнучкість таких систем дозволяють легко масштабувати знімання та адаптувати їх дизайн за необхідності без втрати якості.

Пілотний проект на Хорошівській площі, успішно реалізований ТОВ «ДТЕК Нафтогаз» та ТОВ «ДЕНІМЕКС ГЕО», підтверджує переваги застосування бездротових систем та відкриває нові можливості для проведення сейсморозвідки в раніше недоступних районах. Реалізація проектів 2D і 3D високощільної сейсморозвідки в Україні сприятиме глибокому вивченню

нафтогазоперспективних об'єктів, надійній оцінці їхнього ресурсного потенціалу та зниженню ризиків, пов'язаних із пошуково-розвідувальним бурінням.

За останні роки в світовій практиці ведення геологорозвідувальних робіт відбувся значний прогрес у сфері обробки сейсмічних даних у кількох напрямках. Дослідження та застосування нових методик підсумування та міграції даних значно спростили геологічний аналіз та інтерпретаційні дослідження в межах площі робіт. Процес деконволюції став складнішим, включаючи використання статистичних, модельних і детермінованих підходів [24].

Застосування багатоканальної фільтрації та аналізу в областях перетворення призвело до розробки ефективних методів зниження рівня шумів і поліпшення якості сигналу. У статичному аналізі використання сейсмічної поверхні як вертикального обмежувача інтервальної швидкості залишається стандартною практикою, а застосування аналізу заломлення стає дедалі популярнішим засобом попередньої обробки даних з метою оцінки залишкової статистики. Просування в методології підсумовування в основному пов'язані з усуненням трьох факторів: спотворення променя через проходження скрізь зони з різними середніми значеннями поперечної швидкості, складності геологічної структури досліджуваного розрізу та зміни азимуту джерела та приймача.

В останні роки багато методів обробки мігрованих даних були спрямовані на поліпшення оцінки властивостей геологічного розрізу. Взаємодія між суміжними дисциплінами стала більш інтенсивною, що сприяє підвищенню ефективності кожної окремої дисципліни, оскільки вони розвиваються у тіснішій взаємодії. Нижче наведені приклади сучасних напрямків розвитку в обробці сейсмічних даних:

1. Машинне навчання та нейронні мережі. Інтеграція машинного навчання в аналіз сейсмічних даних може значно підвищити точність і швидкість обробки даних. Алгоритми машинного навчання можуть допомогти в автоматизації ідентифікації геологічних особливостей та відокремлення шумів.

2. Високопродуктивні обчислення (HPC). Зростаюча потреба в обробці великих обсягів сейсмічних даних вимагає більш потужних обчислювальних

систем. Високопродуктивні обчислення дозволяють швидше аналізувати великі об'єми даних і проводити більш складні симуляції.

3. Інтегровані геонаукові платформи. Розробка інтегрованих платформ, що поєднують сейсмічні дані з іншими геологічними та геофізичними даними, дозволяє отримати більш повне уявлення про підземні структури. Це сприяє кращому розумінню геологічних процесів та поліпшенню якості прийняття рішень у нафтогазовій індустрії.

Найбільш популярними платформами є:

- Paradigm GeoDepth - програмний комплекс розроблений компанією Paradigm і призначений для обробки та інтерпретації сейсмічних даних. Він має інструменти для міграції даних, а також для побудови сейсмічних кубів та їх інтерпретації.

- Landmark ProMAX - програма має модулі для міграції даних та побудови сейсмічних кубів. Вона також має ряд інструментів для візуалізації та аналізу результатів.

- Schlumberger Omega - це інтегрована програма для обробки сейсмічних даних від компанії Schlumberger. Вона має функціональність для міграції даних та побудови сейсмічних кубів, а також для їх аналізу та інтерпретації.

- ION GX Technology - розроблений компанією ION, також надає інструменти для обробки та аналізу сейсмічних даних, включаючи функціональність для міграції даних та побудови сейсмічних кубів.

- SubsurfaceAI – комплексне програмне забезпечення, що в більшій мірі використовує треновані моделі штучного інтелекту (ШІ) для вирішення задач геологічної та геофізичної направленості.

1. Поліпшення методів візуалізації. Розвиток технологій візуалізації дозволяє більш детально і інтуїтивно представляти сейсмічні дані, що сприяє кращому розумінню і аналізу [25].

2. Інверсійні методи. Удосконалення інверсійних методів обробки сейсмічних даних, які дозволяють більш точно реконструювати підземні

структури на основі залучення сейсмічних і бурових даних, є одним з напрямків, які активно розвиваються.

3. Автоматизація процесів. Розвиток автоматичних систем для обробки сейсмічних даних зменшує людський фактор та збільшує ефективність досліджень.

Окрім того відзначається значне підвищення стійкості сейсмічних досліджень з врахуванням екологічних аспектів, що також є важливою частиною сучасних досліджень. Це все не тільки сприяє підвищенню точності та ефективності обробки сейсмічних даних, але й відкриває нові можливості для досліджень [26-27].

Додатково стрімко розвивається активний пошук джерел відновлюваної енергії з використанням новітніх рішень геоінформаційних систем з використанням математичних та математико-картографічних методів, які були висвітлені в роботах Зацерквоного В. І. [28].

1.3. Історія розвитку машинного навчання

Машинне навчання або Machine Learning (ML), бере свій початок з галузей математичної логіки, статистики та штучного інтелекту, що сягають початку 20-го століття і перші ідеї щодо створення машин, які могли б навчатися, виникли на основі штучного інтелекту. Варто зазначити, що розрізняють декілька видів машинного навчання [29]:

- класичне машинне навчання;
- глибоке машинне навчання;
- навчання з вчителем/без вчителя (supervised/unsupervised machine learning)

Класичне машинне навчання базується на алгоритмах, які обробляють дані для навчання моделей. Основні етапи розвитку припадають на 50-ті роки, коли Алан Тьюринг запропонував тест Тьюринга як спосіб оцінки інтелекту машини, а згодом у 1957 році була розроблена перша нейронна мережа Френком

Розенблаттом — перцептрон. У 60-ті роки почалась розробка алгоритмів кластеризації та регресії.

Навчання з вчителем (Supervised Learning) – метод, який включає навчання моделей на маркованих даних, де кожен вхідний приклад має відповідну мітку. Основні етапи розвитку цього методу припадають на 70-90-ті роки минулого сторіччя, так, наприклад, у 70-ті роки почався розвиток алгоритмів найближчих сусідів (k-nearest neighbors), у 80-ті – винайшли алгоритм зворотного поширення помилки для тренування нейронних мереж, а у 90-ті почалось зростання популярності алгоритмів підтримки векторних машин (SVM).

Навчання без вчителя (Unsupervised Learning) базується на навчанні даних без міток, зосереджуючись на виявленні структури або закономірностей у даних. Основні етапи розвитку випадають на 70-80-ті роки минулого сторіччя і початок 2000х, так у 70-ті були розроблені методи кластеризації, такі як алгоритм k-середніх (k-means), у 80-ті роки почався розвиток методів головних компонент (PCA) для зниження розмірності, а у 2000-ті спостерігався прогрес в області генеративних моделей, таких як алгоритми навчання змішаних моделей.

Оскільки машинне навчання стало однією з найпопулярніших і найважливіших галузей комп'ютерних наук, то з розвитком цієї галузі з'явилася велика кількість програмних бібліотек, що допомагають спростувати процес розробки і впровадження моделей машинного навчання. Ці бібліотеки забезпечують розробників зручними інструментами для реалізації різноманітних алгоритмів, обробки даних, візуалізації результатів і оптимізації моделей [29].

Деякі з найвідоміших бібліотек для машинного навчання включають TensorFlow, PyTorch, Keras, XGBoost та інші. Кожна з них має свої унікальні особливості та сфери застосування, але всі вони спрямовані на полегшення процесу створення ефективних і надійних моделей машинного навчання. Однією з найвідоміших і найпоширеніших бібліотек для машинного навчання є Scikit-learn.

Scikit-learn надає широкий спектр алгоритмів для задач класифікації, регресії, кластеризації, зниження розмірності та вибору моделей. Це включає алгоритми, перелічені раніше в групах класичного машинного навчання, а також навчання з вчителем і без – лінійна регресія, логістична регресія, підтримка векторних машин (SVM), дерева рішень, випадкові ліси, k-середні та багато інших. Бібліотека містить інструменти для нормалізації, стандартизації, генерації відсутніх значень, обробки категорійних змінних та інших задач перед-обробки даних.

Зокрема Scikit-learn надає засоби для розбиття даних на тренувальні та тестові набори, проведення крос-валідації, обчислення метрик якості моделей, таких як точність, F-міра, площа під кривою ROC та інші. Бібліотека дозволяє створювати комплексні рішення, що включають послідовність етапів перед-обробки та навчання моделі. Це полегшує автоматизацію процесу створення моделей.

Таким чином, Scikit-learn є одним із найважливіших інструментів для машинного навчання в екосистемі Python, забезпечуючи розробників потужними та зручними інструментами для створення ефективних моделей і аналізу даних. Варто також звернути увагу на можливості Scikit-learn, які можна використовувати у обробці масивів даних, що характерні для сейсморозвідки [29].

У бібліотеці Scikit-learn існує багато інструментів для роботи з даними, що створюють якісну базу для побудови спеціалізованих моделей машинного навчання для вирішення проблем сейсмічної інтерпретації.

1. Обробка та перед-обробка даних. Scikit-learn надає широкий спектр інструментів для перед-обробки даних, що є важливим кроком у побудові моделі ІІІ для роботи з сейсмічними даними. Дані сейсмічних досліджень часто бувають об'ємними, містять шум і пропущені значення і Scikit-learn дозволяє привести нормалізувати дані і заповнити пропущені значення, а також провести фільтрацію та обробку даних для видалення небажаних сигналів.

2. Класифікація. Обробка даних сейсмозвідки включає ідентифікацію різних типів сейсмічних сигналів та характеристик порід, використовуючи такі алгоритми, як дерева рішень для класифікації типів порід на основі характеру поведінки сейсмотрас в інтервалі досліджень, а також виявлення аномальних сейсмічних подій, що можуть вказувати на наявність корисних копалин або структурних аномалій.

3. Регресія. Регресійні моделі в Scikit-learn можуть використовуватися для передбачення різних параметрів, наприклад, прогнозування глибини шарів порід на основі сейсмічних даних або оцінка властивостей порід.

4. Зниження розмірності. Сейсмічні дані часто мають високу розмірність, що ускладнює їх аналіз, але Scikit-learn надає методи, такі як аналіз головних компонент (PCA) та t-SNE, для зниження розмірності даних і виявлення основних закономірностей.

5. Оцінка моделей та крос-валідація. Scikit-learn дозволяє оцінювати якість моделей штучного інтелекту за допомогою різних метрик та методів крос-валідації, виконуючи перевірку моделей на різних підмножинах даних для оцінки їхньої надійності та запобігання перенавчанню. Для оцінки використовуються такі метрики, як точність, середньоквадратична помилка (MSE) [12] для оцінки моделей.

Загалом, Scikit-learn є потужним інструментом для аналізу сейсмічних даних, забезпечуючи різноманітні алгоритми та методи, які допомагають дослідникам і інженерам отримувати корисну інформацію з великих обсягів даних [29].

1.4. Нейронні мережі як підрозділ машинного навчання

Штучна нейронна мережа — це математична модель, яка черпає натхнення з біологічних нейронних мереж. Вона в певній мірі створена за аналогією з мережею нервових клітин живих організмів. По суті, штучна нейронна мережа являє собою групу штучних нейронів, що взаємодіють між собою. Основні

принципи функціонування нейронних мереж були викладені ще в 1943 році Уорреном Мак-Каллоком та Уолтером Пітсом. Варто зазначити, що штучні нейронні мережі складаються з декількох шарів:

1. Вхідний шар, який приймає початкові дані.
2. Приховані шари – мають один або більше шарів, що виконують обробку даних. Кількість шарів і нейронів у кожному шарі визначає складність моделі.
3. Вихідний шар, який видає кінцевий результат моделі.

У 1957 році нейрофізіолог Френк Розенблатт розробив першу нейронну мережу, а у 2010 році великі обсяги даних для навчання дозволили використовувати нейронні мережі для машинного навчання. Зараз нейронні мережі застосовуються в багатьох сферах машинного навчання та вирішують завдання різної складності.

На рисунку 1.4 представлено перцептрон — найпростіша нейронна мережа, запропонована нейрофізіологом Френком Розенблаттом. В її основі лежить математична модель сприйняття інформації мозком, яка складається з сенсорів, асоціативних і реагуючих елементів.




Рисунок 1.4 – Перцептрон

Ця нейронна мережа складається з одного шару, в якому знаходиться єдиний нейрон. Розглянемо її структуру більш детально на наступному рисунку (рис. 1.5).




Рисунок 1.5 – Структура перцептрону

Згідно структурі, є деякий вектор X , який складається з l компонент. Важливість кожної компоненти визначається вагою ω_i . Цей коефіцієнт керує «силою» синаптичного зв'язку. Функція f називається функцією активації, в якості аргументу вона приймає лінійну комбінацію компонент вектора X . Таким чином, математично один нейрон можна уявити як:

$$a(X, \omega) = f(\omega^T X) = f\left(\sum_{j=1}^d \omega_j^{(1)} x_j + \omega_0^{(1)}\right)$$

Якщо активаційну функцію прибрати, то ми отримаємо такий вираз:

$$a(X, \omega) = \omega^T X$$

з іншого боку, якщо в якості функції активації $\text{sign}(x)$, то рівняння, що описує нейронну мережу прийме вигляд:

$$a(X, \omega) = \text{sign}(\omega^T X)$$

Обидва ці вирази використовуються для вирішення задачі лінійної регресії та бінарної класифікації. Таким чином, одношаровий перцептрон може бути використаний як регресор або лінійний класифікатор як показано на рисунку 1.6.




Рисунок 1.6 – Варіанти використання перцептрона

Розглянемо приклад. Нехай дано наступний набір даних (рис. 1.7 – 1.10):

$$x_1 = [0, 0]^T, y_1 = 0$$

$$x_2 = [0, 1]^T, y_2 = 1$$

$$x_3 = [1, 0]^T, y_3 = 0$$

$$x_4 = [1, 1]^T, y_4 = 1$$

Рисунок 1.7 – Набір даних

Такі дані дуже просто класифікуються. Справді, достатньо намалювати лінію подібну до тієї, що зображена на рисунку 8 (кола зображують нулі, а ромби - одиниці). Для визначення оптимальних параметрів поділяючої прямої можна скористатися методом градієнтного спуску або будь-яким іншим алгоритмом оптимізації.




Рисунок 1.8 – Класифікація даних

Нейронна мережа, що складається з єдиного нейрона описує саме таку лінію. Однак такий класифікатор дуже сильно обмежений. Розглянемо наступний приклад [37]:

$$x_1 = [0, 0]^T, y_1 = 0$$

$$x_2 = [0, 1]^T, y_2 = 1$$

$$x_3 = [1, 0]^T, y_3 = 1$$

$$x_4 = [1, 1]^T, y_4 = 0$$

Рисунок 1.9 – Новий набір даних

Зобразимо отримані дані на площині. Як і попередньому прикладі кола зображують нулі, а ромби - одиниці. Очевидно, що в даному випадку не існує такої прямої, яка була б здатна розділити площину на дві частини так, щоб об'єкти одного класу знаходилися в одній напівплощині.




Рисунок 1.10 – Класифікація нових даних

Для розв'язання такого завдання лінійного класифікатора вже буде недостатньо. У цьому випадку нейронну мережу необхідно ускладнити за рахунок додавання додаткових шарів та/або нейронів. Таким чином ми поступово приходимо до поняття **багат шарового перцептрон**у. Розвиток багат шарових перцептронів (MLP) та винахід алгоритму зворотного поширення помилки припадає на 80-ті роки минулого сторіччя. Від одношарового він відрізняється лише тим, що в ньому є більше шарів і нейронів. За рахунок такого ускладнення нейронної мережі у неї з'являється здатність "відловлювати" більш

складні, нелінійні залежності між атрибутами. Схематичне зображення багатошарової нейронної мережі показано на рисунку 1.11.




Рисунок 1.11 - Багатошаровий перцептрон

Нейронна мережа вважається універсальною моделлю, оскільки вона здатна апроксимувати будь-які поверхні. І хоча на початок 2000х популярність нейронних мереж зменшилась через обмеження обчислювальних ресурсів і складність навчання, у 2010-ті роки спостерігалось відродження інтересу до нейронних мереж завдяки успіхам у глибокому навчанні (deep learning).

Відродження інтересу до нейронних мереж відбулося завдяки доступності великих обсягів даних, збільшення обчислювальної потужності та розробки більш ефективних алгоритмів навчання. Успіхи глибокого навчання у різних сферах, наприклад, у розпізнанні зображень, продемонстрували виняткові здібності нейронних мереж у вирішенні складних завдань. Еволюція нейронних мереж характеризується збільшенням глибини та складності моделей. Від простих перцептронів з одним шаром нейронів до глибоких нейронних мереж із сотнями шарів зростання масштабів і складності цих мереж вражає. Цей прогрес дозволив нейронним мережам досягти і навіть перевершити рівень людської продуктивності у таких завданнях, як розпізнавання зображень та мовлення [30-32].

Розвиток нейронних мереж ще далекий від завершення, дослідники продовжують вивчати нові архітектури, методи навчання та застосування. Ця область розвивається стрімко і вже робить революцію у різних галузях, суттєво впливаючи на повсякденне життя, а взаємозв'язок між нейронними мережами та глибоким навчанням є важливою частиною досягнень у галузі штучного інтелекту. Глибоке навчання, як різновид машинного навчання, відноситься до нейронних мереж з кількома шарами, відомим як глибокі нейронні мережі. Ці мережі можуть вивчати ієрархічні уявлення даних, що важливо задля розуміння складних закономірностей і зв'язків. Суттєвий внесок в розвиток сучасного бачення застосування нейронних мереж був зроблений вітчизняними вченими, зокрема Недашківською Н.І. [33], а також Ходневичем Я. В. [34].

Розвиток нейронних мереж, а також машинного навчання базується на новітніх математичних алгоритмах, які як закладено в основу сучасних існуючих програмних бібліотек, так і існуючих у вигляді окремих математичних моделей, зокрема розроблених Терентьєвим О. М. [35], а також Калюхом Ю.І. [36].

Глибоке навчання знаходиться на старті розвитку у галузі штучного інтелекту завдяки своїй здатності обробляти та навчатися на великих обсягах даних. Глибина цих мереж дозволяє їм уловлювати тонкі нюанси та абстрактні особливості, які можуть бути втрачені більш простими моделями. Це спричинило прориви в таких областях, як комп'ютерний зір, обробка природної мови та автономні системи. У міру того, як глибоке навчання продовжує розвиватися, воно розширює межі можливостей нейронних мереж. Дослідники вивчають нові архітектури та методи навчання, щоб підвищити продуктивність та ефективність моделей, відкриваючи шлях до ще більш вражаючих програм штучного інтелекту в майбутньому [37-40].

Майбутнє нейронних мереж виглядає перспективним, і поточні дослідження спрямовані на вирішення цих проблем та розширення їх можливостей. В даний час робляться зусилля щодо поліпшення інтерпретованості, зменшення залежності від великих наборів даних та розробки більш ефективних методів навчання. Крім того, дослідження нових архітектур,

таких як імпульсні нейронні мережі, що імітують взаємодію біологічних нейронів, відкриває потенціал для створення більш енергоефективних та біологічно правдоподібних моделей.

Однією з найпомітніших сучасних тенденцій у розвитку алгоритмів нейронних мереж є використання архітектури **U-net**. Ця архітектура стала дуже популярною в задачах сегментації зображень, таких як медична діагностика, обробка супутникових знімків та інші області, де важливо точно визначати межі об'єктів на зображеннях. Ця архітектура була вперше запропонована в 2015 році і з тих пір здобула велику популярність завдяки своїм високим результатам. Її переваги полягають у високій точності сегментації завдяки своїй здатності захоплювати як глобальні, так і локальні контексти зображення, а також ефективності використання обчислювальних ресурсів, що дозволяє її застосовувати навіть на обмежених апаратних ресурсах для окремих випадків. Завдяки симетричній структурі і наявності зворотних зв'язків, U-Net може навчатися навіть на невеликих наборах даних [41-44].

Також варто зазначити, що U-Net може бути адаптована для різних задач, включаючи медичну сегментацію, аналіз супутникових зображень, обробку відео та головне – роботу з сейсмічними даними. Проте слід відмітити, що попри всі переваги цієї архітектури, у U-Net є деякі недоліки, наприклад – архітектура може потребувати значну кількість пам'яті при обробці високоякісних зображень або трьохмірних масивів даних. Також варто звернути увагу на складність налаштувань, яка проявляється в тому, що налаштування гіперпараметрів U-Net вимагає значних експериментів.

Також спостерігаються деякі проблеми з дрібними об'єктами, попри те що U-Net добре справляється з сегментацією великих об'єктів, вона може мати проблеми з дрібними об'єктами або деталями через можливість втрати інформації при збільшенні кількості шарів. На сьогодні U-Net продовжує розвиватися і вдосконалюватися, стаючи основою для багатьох нових методів і досліджень, в тому числі в сфері обробки сейсмічних даних [45-48].

Використання нейронних мереж для покращення обробки сейсмічних даних є одним із напрямів розвитку сучасних технологій у галузі геофізики. Цей підхід дозволяє підвищити точність та швидкість обробки даних, що важливо для більш ефективного пошуку нафти та газу, а також для моніторингу тектонічних процесів.

Варто зазначити, що перші спроби використання нейронних мереж у сейсмічних дослідженнях датуються близько 1990-х років. Одним з ранніх прикладів був застосунок нейронних мереж для визначення геологічної структури з використанням сейсмічних даних. Відтоді використання нейронних мереж у сейсмічних дослідженнях розширилося і включає такі напрямки:

1. Автоматичне визначення меж геологічних структур на сейсмічних знімках.
2. Покращення розрізної здатності сейсмічних знімків, що дозволяє отримати більш детальну інформацію про геологічну структуру під землею.
3. Фільтрація шумів у сейсмічних даних, що дозволяє покращити якість обробки та інтерпретації даних
4. Інтерпретація сейсмічних даних і визначення параметрів геологічних структур.

Ці напрямки використання нейронних мереж у дослідженнях сейсмічних даних демонструють потенціал цих методів в контексті покращення якості та ефективності обробки польових даних та їх інтерпретації [49-59].

Згодом нейронні мережі швидко виявили свій потенціал у покращенні обробки сейсмічних даних. Вони дозволяють виявляти складні залежності між різними параметрами сейсмічних сигналів і автоматизувати процес обробки. Варто зазначити, що Україна також зробила свій внесок у внесла свій внесок у розвиток цієї галузі, наприклад, створено алгоритм і програму Concmap – Density для об'єднання отриманих даних в результаті роботи програми Density, яка дозволяє визначити значення параметру густини на певній глибині залягання між двома поверхнями (в горизонті), представленими як значенням, так і картою

(академік НАН України В.І. Старостенко, О.В. Легостаєва, О.С. Савченко, І.Б.Макаренко).

Завдяки успішному застосуванню та розвитку технологій глибокого навчання в галузі сегментації зображень, спостерігається значний прогрес в інтерпретації сейсмічних фацій з використанням згорткових нейронних мереж. Ці розумні та автоматизовані методи суттєво знижують потребу в ручній роботі, особливо у трудомісткому процесі ручного маркування сейсмічних фацій. Тим не менш, висока потреба в навчальних даних обмежує їх ширше застосування [59,60].

Сейсмічні фації – частини розрізу з окремими характеристиками в полях сейсмічних даних (амплітуда, текстура, безперервність, характер контакту). Інтерпретація сейсмічних фацій відіграє ключову роль у розумінні та відокремленні генетично пов'язаних процесів осадконапичення та розподілу літофацій, а також в прогнозуванні розподілу покладів нафти та газу. Ручний аналіз сейсмічних фацій вимагає великих зусиль інтерпретаторів, що займає багато часу і схильне до суб'єктивних факторів, тому тривають спроби розробити швидкі та ефективні схеми їх автоматичного відокремлення та інтерпретації [61,62].

Нелінійна природа геофізичних проблем добре підходить для використання технологій глибокого навчання, які можуть виявляти високорозмірні нелінійні взаємозв'язки даних. Завдяки цій особливості методи глибокого навчання знайшли широке застосування в різних дисциплінах [63-66]. Особливо добре зарекомендували себе згорткові нейронні мережі (CNN) у розпізнаванні образів, виявленні об'єктів та обробці зображень.

Завдяки схожості між інтерпретацією сейсмічних даних та обробкою зображень, CNN починають залучатись до роботи з сейсмічними даними. Поєднання методів глибокого навчання з інтерпретацією сейсмічних даних показує більш високу стабільність та здатність до узагальнення, що призвело до широкого застосування цих методів західними компаніями впродовж останніх років, включаючи виявлення розломів, ідентифікацію соляних куполів,

відстеження горизонтів, виділення перших вступів і класифікацію сейсмічних фацій [67-69].

Методи аналізу сейсмічних фацій можна розділити на дві основні категорії: методи аналізу на основі сейсмічних атрибутів та методи класифікації на основі кластеризації хвильових форм. Введення різних сейсмічних атрибутів у моделі глибоких нейронних мереж значно підвищило ефективність класифікації сейсмічних фацій. Проте через велику кількість атрибутів інтерпретація стає складним завданням, а складні взаємозв'язки між різними атрибутами та цільовими геологічними завданнями ускладнюють вибір відповідних атрибутів та оцінку результатів класифікації.

Хоча глибоке навчання дещо полегшує це завдання, основна проблема залишається вибір правильних характеристик, в цьому випадку методи кластеризації хвильових форм пропонують альтернативу обмежень аналізу сейсмічних атрибутів та відкривають нові можливості для класифікації сейсмічних фацій. Серед алгоритмів кластеризації хвильових форм, що найчастіше використовуються, — кластеризація К-середніх, метод головних компонент (PCA) і карта, що самоорганізується (SOM). Ці методи належать до навчання без вчителя, не вимагають маркованих даних, але часто дають меншу точність класифікації та складніше оптимізуються.

Глибокі згорткові нейронні мережі (DCNN) широко використовуються для сегментації зображень [70]. Їхні особливості, такі як спільне використання ваг та локальні з'єднання, роблять мережу компактною та легкою для навчання. Повністю-згорткова мережа (FCNN) замінює повнозв'язні шари в класичній структурі CNN на згорткові, що дозволяє обробляти входи будь-якого розміру та досягати піксельного рівня сегментації зображень. Хоча FCNN забезпечує сегментацію у форматі end-to-end, деталізація сегментації потребує поліпшення.

Щоб вирішити цю проблему використовувався пакет U-Net для кодування та декодування даних. В процесі обробки використовувалась інформація різних рівнів, що покращувало розрізнявальну здатність зображення. На відміну від FCN, який об'єднує пікселі шляхом додавання, U-Net використовує

конкатенацію, що зберігає більше інформації про положення та вимірювання. Ця архітектура знайшла успішне застосування в геофізиці для морської зйомки, успішно виконуючи виявлення розломів та класифікацію сейсмічних фацій.

Для поєднання переваг моделі U-Net для навчання на невеликих вибірках з можливостями контрольованого навчання, пропонується покращена глибока нейронна мережа з модулями просторової пірамідальної вибірки (DCSPP) для класифікації сейсмічних фацій. Включення просторової пірамідальної вибірки (SPPM) покращує здатність моделі отримувати глобальну інформацію, а застосування шарів розширеної згортки в процесі обробки збільшує поле, що сприймається. Таке поєднання модулів із архітектурою U-Net підвищує точність класифікації і експерименти на польових даних демонструють, що запропонована структура досягає високої точності класифікації і має практичність та узагальнюючу здатність.

Але через відсутність універсального алгоритму для покращення сейсмічних даних виникають складнощі під час самого процесу обробки даних із залученням різних фізичних, геологічних та геофізичних знань. Нейронні мережі можуть надати значний внесок у покращення якості інтерпретації сейсмічних даних і часткову автоматизацію процесу завдяки таким можливостям:

1. Узагальнення послідовностей. Нейронні мережі можуть виявляти складні залежності та послідовності у великих обсягах сейсмічних даних, що допомагає у виявленні корисних сигналів та прихованих структур.

2. Автоматичне вилучення ознак. Нейромережі можуть самостійно вибирати найбільш інформативні ознаки для аналізу, що допомагає відсікати шуми та непотрібну інформацію.

3. Моделювання складних змінних структур. Нейронні мережі можуть бути ефективними у моделюванні нестационарності в сейсмічних даних, таких як змінна швидкість поширення хвиль.

4. Автоматизація обробки даних. Завдяки навчанню на великому обсязі даних, нейронні мережі можуть автоматично обробляти та аналізувати сейсмічні дані, що зменшує необхідність в ручному втручанні.

5. Адаптивність. Вони можуть навчатися на нових даних та адаптуватися до змін у сейсмічній активності, покращуючи з часом якість інтерпретації.

Перелічені можливості нейронних мереж роблять їх потужним інструментом для покращення якості обробки сейсмічних даних та зменшення залежності від людського фактору у цьому процесі [71-76].

Інформація даних сейсмічних досліджень на суші та в морі часто містить завади, включаючи документовані позиції джерел та приймачів. Один із перших етапів обробки даних – перевірка їх на наявність таких помилок. Глибокі нейронні мережі можуть використовуватися для контролю якості отриманих даних та ідентифікації променів та приймачів з помилками позиціонування. Після виправлення дані проходять через послідовність обробки, щоб бути перетвореними на зображення, що інтерпретується після видалення ефектів збору даних і поширення хвиль. Метою цих кроків обробки є виділення подій, пов'язаних з ключовими фізичними факторами, що належать до геології/структури отриманих даних [77-80].

Інтерполяція та екстраполяція даних є одними з найпопулярніших застосувань глибоких нейронних мереж для попередньої обробки сейсмічних зображень. При сейсмічних дослідженнях неминуче відсутні деякі траси в сітці збору даних через фізичні перешкоди, економічні обмеження або несправні прилади. Ці пропущені дані можуть виникати як нерегулярно, так і регулярно за просторовими координатами, і впливати на подальшу обробку, таку як усунення множинних поверхневих відображень (SRME), аналіз зміни амплітуди при зсуві (AVO), аналіз швидкості та перетворення/інверсія попереднього стека. Техніки інтерполяції сейсмічних трас широко використовують для вирішення цієї проблеми шляхом відновлення відсутніх трас [81].

Можливості глибоких згорткових нейронних мереж автоматично отримувати характеристики високого рівня для точної характеристики

сейсмічних даних і вивчення складних нелінійних функцій відображення роблять їх чудовими інструментами для інтерполяції сейсмічних даних. Ці методи інтерполяції, засновані на глибокому навчанні, ефективні як для регулярних, так і для нерегулярних випадків пропущених трас і пропонують переваги високої продуктивності та високої гнучкості, атрибутів, які також надають традиційні методи, засновані на хвильовому рівнянні та обробці сигналу, але без великих обчислювальних витрат.

Глибоке навчання також є ефективним інструментом екстраполяції сейсмічних даних. Синтез нових даних на основі існуючих є одним з місць, де глибокі нейронні мережі були залучені до виробничого процесу обробки польових сейсмічних даних. Надання інформації низьких частот є важливим фактором успішного виконання повного хвильового інвертування (FWI), оскільки це допомагає пом'якшити проблему пропусків циклів, щоб отримати більш надійне зображення підземних структур. Однак збір та попередня обробка польових даних з високоякісною енергією низьких частот становлять певні труднощі. Тому [82-83] використовували глибоку 2D-згорткову нейронну мережу для екстраполяції відсутніх компонентів низьких частот для всієї групи сейсмічних слідів (упорядкованої колекції сейсмічних трас) на основі компонентів більш високих частот сейсмічного поля.

Для провідних вітових компаній, нейронні мережі проникли майже у всі сектори сейсморозвідки і перевершили багато класичних підходів до автоматизації збору сейсмічних даних, попередньої обробки даних (наприклад, інтерполяції/екстраполяції, шумоподавлення, вибору першого приходу, вибору швидкості, сейсмічної міграції), обробки даних (наприклад структурним інтерпретаціям та моделюванню даних). І одним з інноваційних підходів до обробки даних є метод на основі згорткових нейронних мереж (CNN), який використовується для одночасного підвищення розрізної здатності сейсмічних зображень і зменшення шуму. Цей метод продемонстрував високу ефективність як на штучних, так і на фактичних сейсмічних даних і цей підхід значно

покращує детальні структурні та стратиграфічні особливості, такі як тонкі шари та дрібномасштабні розломи, у вхідних сейсмічних зображеннях [48, 49].

Саме імплементації подібного підходу, але з урахуванням особливостей вітчизняного розрізу, умов осадконакопичення та вимог нафтогазовидобувних компаній і буде присвячена дана робота.

РОЗДІЛ 2. ПОСТАНОВКА ЗАДАЧІ ТА ЗАГАЛЬНИЙ АЛГОРИТМ ЇЇ РОЗВ'ЯЗАННЯ ДЛЯ 2D ПРОФІЛІВ

2.1 Побудова моделі сіквенс-стратиграфічного розчленування розрізу на прикладі Комишнянської площі

Оригінальною метою, що була поставлена перед написанням роботи була побудова моделі штучного інтелекту, яка б підкреслювала риси хвильового поля мігрованих кубів сейсмічної зйомки, що відповідають межах сіквенс-стратиграфічних підрозділів.

Сіквенс стратиграфія – це методика геологічного дослідження, яка дозволяє аналізувати осадові послідовності з метою вивчення їхньої геологічної історії, зміни рівня моря, а також прогнозування розташування порід-колекторів вуглеводнів. Одним з ключових аспектів методики є інтеграція різних джерел даних, зокрема сейсмічних профілів і свердловинних даних, для отримання максимальної інформації про структуру та розвиток осадових басейнів.

Сіквенс-стратиграфія базується на ідентифікації осадових послідовностей, які обмежені стратиграфічними межами (unconformities), що виникають через зміни рівня моря або тектонічні процеси. Ці послідовності включають в себе окремі цикли осадконакопичення, які поділяються на системні тракти (system tracts). Кожний системний тракт характеризується специфічними умовами осадконакопичення, що залежать від співвідношення швидкості седиментації, тектонічного підняття або опускання та зміни рівня моря. Існує певна стадійність робіт при виділенні сіквенсів і парасіквенсів для кожної площі – а саме побудова геологічних профілів (рис 2.1), що базуються на бурових даних і інтеграції сейсмічних даних 2D чи 3D польових зйомок з метою точного простеження монохронних подій (рис. 2.2). Суттєвою проблемою для цього процесу є розрізнявальна здатність сейсмічних матеріалів, що становить десятки метрів і свердловинних, що може розрізняти за каротажними проشارками потужністю в десятки сантиметрів. Простеження синхронних подій в контрольованому

свердловинами просторі повинно супроводжуватись їх екстраполяцією за допомогою сейсмічних даних і тут дуже важливими є два фактори – співвідношення сигнал/завада в зоні інтересу в межах сейсмічної зйомки, а також розрізнявальна здатність сейсмічних матеріалів, що може «замилювати» картину, спотворюючи тим самим аналіз геологічних подій.




Рисунок 2.1. Побудова сейсмо-геологічного профіля в ході створення сіквенс-стратиграфічної моделі.

Цей тип геологічних досліджень в Україні, нажаль, мало застосовується, тому має великі перспективи для дорозвідки родовищ та скерування зусиль пошукової геології. Зважаючи на відносну простоту Комишнянського родовища та відносно високий рівень якості вхідних матеріалів, подібний аналіз був успішно проведений автором і представлений на численних конференціях, у тому числі міжнародній конференції SPE в 2021р [84].




Рисунок 2.2. Сейсмічна інтерпретація в ході створення сіквенс-стратиграфічної моделі.

2.2. Якість мігрованих сейсмічних даних для побудови моделі для сіквенс-стратиграфічного розчленування

Не зважаючи на успіх геологічних досліджень для конкретної Комишнянської площі [85], для поточної роботи було проведено аналіз можливості побудови моделі штучного інтелекту для ряду площ, що має в операційній діяльності АТ «Укргазвидобування» і результати показали обмежену можливість їх використання. Для цього є ряд причин, які були частково поійменовані в попередньому розділі роботи:

- Один зі основних нафтогазових басейнів України, ДДЗ, розташований в щільно-заселеній частині країни, що створює перешкоди як в контексті фізичного існування поверхневих завод для проведення польових геофізичних

робіт – лінії електропередачі, населені пункти, дороги, території обмежені для проведення робіт, тощо;

- Для ведення робіт з дорозвідки родовищ суттєвий вплив на якість сейсмічних даних привносить антропогенний фактор інфраструктури будь-якого активного родовища. Зважаючи на тривалу історію пошуків вуглеводнів в межах ДДЗ, існує сталий фонд родовищ, які потребують уточнення своєї будови з метою дорозвідки або оновлення моделі родовища на базі сучасних сейсмічних досліджень, і саме тут на заваді може стати вже існуюча інфраструктура родовища, яка створює завади для збору якісного сейсмічного польового матеріалу;

- Різна якість польових матеріалів та міграції сейсмічних зйомок що призводить до зменшення співвідношення сигнал/завада. Мова йде про сукупну обробку матеріалів різних років зйомки для спільної переобробки і формування об'єднаних мігрованих кубів як правило для досліджень периклінальних частин родовищ. Співставлення матеріалів різних польових зйомок, зібраних за різними дизайн-проектами, призводить до отримання фінальних мігрованих кубів зі зменшеним співвідношенням сигнал/завада в окремих інтервалах розрізу.

- Концентрація пошукових робіт на площах, що знаходяться в центральній частині ДДЗ і мають приштоковий характер. Наявність великої кількості соляних штоків складає суттєву проблему для міграції і отримання якісних сейсмічних матеріалів через велику кількість дифракційних хвиль від козирка соляного штока, а також при підсумовуванні трас уздовж круто-падаючих крил структури, що була утворена штоком.

Таким чином, для проведення якісного сіквенс-стратиграфічного аналізу із залученням куба, опрацьованого моделлю ІІІ, що підкреслювала б характерні риси хвильового поля, потрібно провести суттєву попередню роботу, що була б скерована на покращення якості вхідних сейсмічних даних. Ба більше, в роботах [86-88] вже виділено ряд корисних методик скерованих на покращення якості каротажних даних, що змальовують динаміку процесу осадконакопичення, їм потрібна сейсміка відповідної якості.

Вирішенню задачі покращення інформативної частини сейсмічних даних світовими вченими присвячено ряд наукових праць, зокрема [92-93], проте більшість із них сфокусовані на дослідженні геологічних умов, що сильно відрізняються від наявних в ДДЗ за глибиною залягання.

Тому у якості проміжного висновка можна підсумувати: існує значний фонд площ сейсмічної зйомки, більша частина яких була відстріляна в 2000-2014 роках, чия якість дозволяє виконати обмежений спектр геологічних досліджень. Переобробка польових матеріалів, особливо з використанням нових технологій збору матеріалу, можлива для обмеженого фонду структур. Зважаючи на техногенну катастрофу, спричинену агресією Росії, є фондовий ряд структур, переобробка матеріалів польових сейсмічних досліджень на даний час фізично неможлива.

Як вирішення подібної проблеми пропонується побудова нейронної мережі (НМ) яка б збільшувала розрізнявальну здатність і, відповідно, співвідношення значення сигнал-завада.

Слід одразу визначитись які вимоги і обмеження будуть застосовані до НМ, що буде конструюватись:

- Мережа мусить однаково якісно працювати як з 2D, так і з 3D мігрованими сейсмічними матеріалами, що означає створення двох варіантів мережі для відповідних типів сейсмічних досліджень.

- Мережа має зменшувати рівень шуму не спотворюючи контрастні рефлектори за рахунок великого рівня згладжування, бо має на меті надати якісніші вхідні матеріали для повного комплексу робіт з сейсмічної інтерпретації, враховуючи сіквенс-стратиграфічний аналіз, а не виключно конструювання структурного каркасу статичної геологічної моделі родовища.

- З огляду на певну конкретну трансформацію даних, яку робитиме НМ, вона не пропонується для роботи як з первинними етапами циклу міграційних трансформацій польових матеріалів (brutto stack, fasttrack і т.д.), так і з матеріалами, які зазнали забагато ітерацій згладження і сумування (PSTM зі збільшеною кількістю ітерацій згладження сигналу процедурами MPFI

інтерполяції, TRIM, та жорстким м'ютом дальніх кутів). Тобто оптимальні матеріали для обробки прогнозною моделлю – мігровані сейсмічні матеріали з помірною кількістю зашумлених ділянок/інтервалів.

- Мережа не виконує прогнозно-надійні інтерполяції в зонах відсутності сигналу (населені пункти).

2.3 Аналіз існуючих програмних рішень для збільшення розрізної здатності

З метою оцінки існуючого вибору програмних продуктів, що вирішують проблеми циклу геологорозвідувальних робіт, було проведено аналіз ринку найпоширеніших продуктів, зацентрувавши увагу саме на програмах, що концентруються на проблематиці геолого-геофізичного дослідження розрізу, процесі 3D моделювання і мають в своїй структурі рішення, що базуються на штучному інтелекті.

В результаті аналізу було оцінено можливості і особливості роботи таких програмних комплексів як: Schlumberger Petrel, SubsurfaceAI, Geoplat AI, Stone Ridge technology, Softserve, dGB Earth Sciences. Більша частина із них є складними екосистемами які покривають повністю або майже повністю весь цикл геолого-геофізичного моделювання – від аналізу каротажів, кореляції свердловин та інтерпретації сейсмічних даних до статичного моделювання і просторового розповсюдження окремих фацій базуючись на моделях III із закритою логікою.

Серед програмних продуктів, що викликали значний інтерес через часткове співпадіння задач, що стосуються покращення інтерпретуємості матеріалів сейсмічних зйомок, хотілось би окремо виділити компанію **GridPoint Dynamics** із їх програмним продуктом GeoplatAI. Він позиціонується як продукт пост-обробки для збільшення інтерпретуємості сейсмічних даних та побудови кубів ймовірності диз'юнктивних порушень. За допомогою моделі штучного

інтелекту, що є їх комерційною таємницею, досягається покращена простежуваність рефlectorів, що супроводжується незначною зміною трасування горизонтів відбиття. Тобто програма скерована на побудову стабільнішого структурного каркасу і не підтримує збереження атрибутивної картини за рахунок зміни як трасування так і частотної компоненти сейсмічних даних, що певною мірою розходиться з метою цієї роботи.

Під час аналізу супутніх матеріалів, була знайдена суттєва кількість репозиторіїв зі зразками коду, що можуть бути використані як точка відліку для побудови власного програмного рішення, проте було відмічено дві особливості – роботи західних вчених здебільшого скеровані на пізніші кроки інтерпретаційного процесу – трасування горизонтів відбиття, виділення порушень, сегментація сейсмічних зображень для виділення характерних рис, тощо. Кондиціювання сейсміки не було знайдено через те що у всіх випадках вхідний матеріал – сейсмічні дані морської зйомки, що по своїй природі містять набагато менше зон зашумленого сигналу ніж наземні, тож цей крок традиційно віддається на опрацювання центрам обробки польових даних.

В дослідженнях [89] зі збільшення розрізної здатності мігрованих сейсмічних даних було обговорення можливих стратегій поведінки стосовно підбору даних для навчання і перевірки моделі ШІ. Якщо підсумувати їх – можна дійти наступного висновку: для набору якісних даних моделі ШІ є принципово дві стратегії:

- 1) Обирається максимально-якісний набір сейсмічних даних з мінімальним вмістом шумів і з характерними рисами геологічної будови, подібними до тих, до яких в подальшому планується залучати треновану модель ШІ. До цих даних штучно додаються шумові завади, тобто їх якість погіршується і таким чином використовується в парі з «чистими» даними для тренування моделі
- 2) Створюється штучний синтетичний набір даних, копію яких так само штучно погіршується для додання до тренувального процесу моделі.

Для даної роботи було використано дещо інший підхід: в роботі [89] було викладено посилання на GitHub профіль автора зі збереженим архівом, що

містить 3200 2D зображень, екстрагованих з 800 синтетичних 3D кубів. Матеріали було розбито на 2 категорії – оригінальні синтетичні зображення та їх копії з доданим гаусовим шумом та погіршеною якістю самого зображення при збереженні. Маючи ці набори 2D зображень з’являється можливість побудувати модель, що виконуватиме роботу з відновлення якості зображення та видалення гаусового шуму, що і є метою даної роботи.

Слід відмітити важливий момент – всі зразки коду і набори даних для тренування і валідації нейронних мереж які є в загальному доступі – налаштовані на 2D формат даних. Це зумовлено тим фактом що тренувальний набір даних для 3D формату даних займав би великий дисковий простір, і ще він має комерційну цінність, тому у вільному доступі їх знайти не вдалось можливим. Тому стадійність робіт видається наступною – будується якісне рішення для 2D формату даних, а після цього воно транслюється для 3D. Забігаючи наперед, слід відмітити, що на відміну від існуючих зразків коду з різними функціями апроксимації, в рамках цієї роботи було прийняте рішення стосовно побудови окремої мережі для 3D формату даних, про що буде розказано в 3 розділі.

Під час консультацій зі спеціалістами з розробки додатків із залученням штучного інтелекту з Української компанії SoftServe, дане питання було покомуніковане і дійдено висновку що комерційним підходом є виділення проблематики, що вимагає покращення для кожного конкретного замовника і побудова тренувального набору під конкретний ряд проблем. Саме тому ідеальним варіантом для побудови моделі під умови, що зустрічаються в вітчизняній геологічній розвідці було б створення власного набору даних, що б ураховував як особливості геологічної будови площ досліджень, так і проблематики, з якою стикаються центри обробки польових даних, проте ця задача занадто масштабна для окремого дослідника і потребує значних коштів і консолідації зусиль групи геофізиків та геологів. З огляду на стрімкий розвиток центрів 3D моделювання всіма основними гравцями ринку геологорозвідувальних робіт України («Укргазвидобування», ДТЕК,

«Укрнафта»), попередні напрацювання з моделювання на базі сейсмічних даних можуть стати підґрунтям для подібних досліджень в майбутньому.

2.4. Виділення ряду програмних пакетів, які будуть використовуватись для побудови моделі штучного інтелекту

За час збору матеріалів автором було пройдено курс з мови програмування Python, знання якого і полягли в основу представленої роботи. Ця мова була обрана через те, що Python є однією з найпоширеніших мов програмування для побудови моделей штучного інтелекту завдяки своїй простоті, читабельності та потужній екосистемі бібліотек. Простий синтаксис мови дозволяє користувачам швидко розробляти та тестувати алгоритми, не витрачаючи багато часу на складне кодування.

Однією з основних переваг Python є велика кількість бібліотек, таких як **TensorFlow**, **PyTorch**, **Keras**, **NumPy**, **Pandas** та **Scikit-learn**, які значно полегшують розробку, тренування та розгортання моделей ШІ. Ці бібліотеки надають готові модулі для машинного навчання, глибокого навчання, обробки великих даних та візуалізації, що дозволяє зосередитись на налаштуванні гіперпараметрів моделі, а не на низькорівневих деталях.

Крім того, Python підтримує інтеграцію з іншими мовами, такими як C++ та Java, що дозволяє створювати гібридні рішення, коли необхідно досягти більшої продуктивності. Розвинені можливості багатозадачності та підтримка паралельного обчислення сприяють побудові більш оптимізованих та ефективних моделей. Python також добре підходить для аналізу даних та обробки природної мови, що дозволяє працювати з широким спектром задач, від комп'ютерного зору до розпізнавання тексту та голосу.

У якості середовища розробки на різних етапах роботи було використано різні програмні рішення – наприклад **PyCharm**, **Jupyter Notebook**, проте більша частина процесу побудови моделі ШІ відбувалась за допомогою **Google Colab**. Остання пропонує простий, але потужний інтерфейс, зручну інтеграцію з **Google**

drive, а також свою головну перевагу – сумісний доступ до робочих файлів, що дозволяє активно вести проект за умови віддаленого знаходження учасників розробницького проекту. Нажаль, він має також і недоліки – неможливість використовувати візуалізаційні бібліотеки, які активно залучались до роботи на початкових етапах роботи – **holoviews**, **seaborn**.

З огляду на складність і багатогранність бібліотек, що використовуються для машинного навчання, між **PyTorch** та **Keras** вибір був зроблений на користь останнього здебільшого з тієї причини, що більшість репозиторіїв ШІ що покривають ті чи інші аспекти геологорозвідувальних робіт, використовують саме **Keras** у якості свого двигуна.

З огляду на те, що для обчислення моделі потрібні значні потужності ПК, ключовим моментом є активізація обчислювальних можливостей відеокарти. Для розрахунків робочої моделі була використана відеокарта 32 GB Nvidia RTX 3060, для якої було інстальовано CUDA та CUDnn як програмно-апаратну архітектуру паралельних обчислень, що дозволяє суттєво збільшити обчислювальну продуктивність саме продуктів корпорації Nvidia.

2.5. Аналіз ряду найбільш поширених архітектур моделей для вирішення задач збільшення розрізної здатності.

За час аналізу існуючої літератури та репозиторіїв коду на **GitHub** було проаналізовано ряд архітектур конволюційних нейронних мереж, які можна використати для вирішення задачі збільшення розрізної здатності сейсмічних даних. Сама ця задача по своїй природі дуже подібна до задачі збільшення розрізної здатності 2D малюнка (рис. 2.3).

Під час збільшення розрізної здатності важливою властивістю для обраної нейронної мережі буде не тільки відтворювати характерні риси зображення, але і зберігати пропорції і ключові елементи в похідному стані.



Рисунок 2.3. Зразок роботи алгоритму xPixel для збільшення розрізненої здатності зображення.

Таким чином, серед існуючих варіантів реалізації архітектури, вибір коливався між найпопулярнішими, а відповідно – тими, що мають гарно описану документацію та широкий функціонал – xPixel та U-net.

Архітектура нейронної мережі xPixel є новітнім підходом до обробки зображень, яка використовує глибокі нейронні мережі для високоточного розпізнавання та класифікації зображень. Ця архітектура забезпечує високу точність та швидкість обробки, що робить її ідеальною для застосувань, що потребують високої обчислювальної продуктивності, таких як комп'ютерний зір для роботи з відео, розпізнавання обличчя та інші. xPixel відрізняється від архітектури U-net, яка є популярною для вирішення завдання сегментації зображень, особливо в медичній візуалізації. U-net має складну структуру з двома частинами: енкودером, який зменшує розмір вхідного зображення, і декодером, який відновлює його до початкового розміру з високою розрізняювальною здатністю. xPixel, з іншого боку, зосереджується на точній класифікації зображень, використовуючи більш просту структуру, яка забезпечує високу продуктивність та швидкість обробки.

Мережа xPixel базується на унікальній архітектурі, яка, як відмічалось раніше, забезпечує високу продуктивність в задачах класифікації зображень. Вона використовує багатошарові перцептрони та згорткові нейронні мережі (CNN) для обробки великих обсягів вхідних даних з високою точністю. Мережа xPixel складається з кількох шарів, які обробляють зображення поетапно, виділяючи важливі особливості та зменшуючи шум. Ключова особливість xPixel полягає в використанні спеціалізованих блоків, таких як ResNet-блоки, що дозволяють мережі бути глибокою, зберігаючи при цьому ефективність обчислень. Завдяки цьому, xPixel може виконувати точну класифікацію навіть на великих наборах даних з низьким рівнем помилок. Архітектура xPixel включає також адаптивні механізми навчання, які дозволяють мережі швидко пристосовуватися до нових типів даних, підвищуючи свою ефективність з кожною новою ітерацією (рис. 2.4).




Рисунок 2.4. Схема роботи архітектури xPixel

Мережа з архітектурою xPixel показує свої переваги над U-net у ситуаціях, де критична швидкість обробки та класифікація зображень. Це може бути корисно в реальному часі, наприклад, для автоматизованих систем відеоспостереження, де кожна мілісекунда має значення. У задачах, що вимагають обробки великої кількості зображень за короткий час, xPixel демонструє вищу продуктивність завдяки своїй оптимізованій структурі.

U-net, в свою чергу, відмінно підходить для задач сегментації зображень, де важливо визначити точні контури та структури об'єктів в зображенні. U-net також має перевагу в задачах, що вимагають збереження просторової інформації, оскільки її архітектура дозволяє зберігати деталі високої розрізненості протягом обробки. Завдяки цьому, U-net часто використовується в задачах, де потрібно зберігати геометричні пропорції та деталі. Крім того, U-net часто використовують для задач, де вхідні дані мають високу розрізнявальну здатність, але обмежений розмір наборів даних. Це означає, що вона може добре працювати з відносно невеликими наборами навчальних даних, що може бути корисним в умовах, де доступ до великих обсягів даних обмежений.

Таким чином, U-net перевершує xPixel у задачах сегментації, збереження просторової інформації та роботи з невеликими наборами даних.

Вибір саме архітектури U-net для даного проекту визначили два фактори:

- U-net можна налаштувати таким чином щоб змінювати дані в цільових зонах, при чому не вносити зміни в зони чіткого сигналу, де вони не потрібні;
- Існує як двохмірний варіант архітектури, так і трьохмірний, 3D U-net, що стане критично-важливим фактором для переходу в роботі з 2D сейсмічних даних до мігрованих кубів 3D;
- Суттєвим недоліком U-net є його вибагливість до системних ресурсів під час розрахунків, проте під час навчання та збору матеріалів для проведення роботи було знайдено ряд засобів як апаратного так і програмного походження для вирішення даного питання. Ця тема буде детальніше розкрита в описі структури 3D U-net.

2.6. Відтворення архітектури моделі на базі мережі U-net для двомірного набору даних.

Як було сказано в розділі 2.3 даної роботи, початковий вхідний набір даних для тренування майбутньої моделі III складався з парного набору 2D зображень великої та низької розрізненої здатності і налічував 3200 зображень у форматі *.dat. Тож початковим завданням було побудувати модель на базі архітектури U-net, яка б мала високі показники рівня впевненості прогнозу для синтетичного набору даних, а вже потім додавати модулі адаптації її до реальних геологічних даних. Відправною точкою буде трьохшарова модель, схематичну будову котрої зображено на рис. 2.5.




Рисунок 2.5. Схематична будова нейронної мережі на базі архітектури U-net.

Використана мережа в своїй будові має 3 блоки кодувальника (encoder block) та відповідно 3 блоки декодувальника (decoder block), які поєднуються зв'язковим блоком (bridge layer), який функціонально потрібний для переносу вхідної інформації до шарів декодера (Upsampling layers) для захвату та збереження ключових паттернів навчених в попередніх шарах, забезпечуючи тим самим факт що інформація буде правильно відтворено в послідовних. Структурно рівень зв'язкового блоку складається з параметрів, які можна навчити і які дозволяють моделі адаптувати та точно налаштовувати своє внутрішнє представлення на основі характеристик даних. Він діє як важлива ланка, підвищуючи здатність моделі вивчати ієрархічні та складні функції [94].

З огляду на те, що мета моделі, а саме – фільтрація шумів і збільшення розрізної здатності – досить низькорангові задачі, тобто модель не має на меті запам'ятовування та відтворення складних багатозв'язкових паттернів даних, на кшталт комплексних візуальних об'єктів як тварини, автомобілі, тощо для кластеризації зображень; додавання більшої кількості шарів не є необхідним, бо це призводить до перенавантаження моделі без якісних змін в результуючому прогнозі.

Як зображено на принциповій схемі (рис 2.5) моделі, мета блоку кодувальника полягає в зменшенні піксельного розміру вхідного розміру малюнка, що обробляється під час конкретної епохи тренування моделі в послідовності 1 – 64 – 128 – 512, для чого використовується доступний в бібліотеці Keras клас MaxPooling2D layer.

Функціонал MaxPooling2D полягає в поділі вхідного простору на невеликі регіони, що не мають перекриття, після чого обирається максимальне значення з кожного регіону. У випадку кількох каналів (для зображень це стандартно 3 – RGB кодування), підбір максимального значення відбувається для кожного каналу індивідуально. Для сейсмічних даних, де існує тільки одна площина даних, операція виконується одноразово. Всі значення поза межами обраного значення відкидаються тим самим зменшуючи розмірність результуючого зображення відповідно до обраного розміру регіону роботи функції MaxPool (рис. 2.6). Максимальне об'єднання зменшує просторові розміри зображення, що підлягає трансформації, роблячи наступні шари більш ефективними, і збільшуючи рівень абстракції, відсікаючи другорядні значення, оскільки саме максимальне значення – найбільш представницьке в оцінюваному регіоні.

$$f \max x = \max\{x_i\}_i^N = 1 \quad (2.1)$$

Операція корисна для виявлення наявності певних послідовностей, наприклад, кутів, різких змін поведінки даних, і допомагає зменшити вплив невеликих спотворень у вхідному зображенні. З огляду на певну втрату

інформації через відкидання частини значень, в налаштуваннях функції було використано менший крок.




Рисунок 2.6. Схема роботи функції MaxPool.

Додатково під час підбору параметрів моделі III було апробовано варіант з AvgPool, який відрізняється тим, що в кожному регіоні відбувається відбір не максимального, а усередненого значення. Модель, що має в будові кодувальника AvgPool значно гірше справлялась з виділенням змін в даних (зони порушень, амплітудні коливання), тому була відкинута.

Вищепойменована функція MaxPooling2D виконувалась до конволюційного блоку, який є основним компонентом згорткової конволюційної нейронної мережі (CNN) і використовується для обробки двовірних даних, будь то зображення чи 2D сейсмічний розріз. Його основне завдання – виділення ознак вхідного зображення за допомогою фільтрів або ядер.

Коли зображення подається на вхід 2D конволюційного шару, кожен фільтр виділяє конкретні особливості (текстури, краї, порушення). Результати цих операцій створюють активаційні карти, які передаються далі в мережу для подальшої обробки. Основна ідея його застосування разом з MaxPooling2D – зменшити розмір зображення, зберігаючи важливі ознаки для ефективного навчання моделі.

Наостанок слід описати два важливі елементи блоку кодувальника (рис. 2.7) – а саме опцію нормалізації вхідних даних BatchNormalization та активаційну функцію ‘LeakyReLU’.

```

1  kernel_size = (7,3)
2
3  def conv_block(input, num_filters):
4      x = Conv2D(num_filters,
5                kernel_size=kernel_size,
6                padding="same")(input)
7      x = BatchNormalization()(x)
8      x = Activation("LeakyReLU")(x)
9      return x
10
11 #Encoder block: Conv block followed by maxpooling
12 def encoder_block(input, num_filters):
13     x = conv_block(input, num_filters)
14     p = MaxPool2D((2, 2))(x)
15     return x, p

```

Рисунок 2.7. Принципова компановка блоку кодувальника моделі ШІ.

Ідеальні мігровані сейсмічні дані мають бути приведені до нульової фази (zero phase), тобто їх вейвлет мусить бути симетричним відносно нульової відмітки [95]. Деконволюція під час обробки польових даних сейсмічних досліджень може перетворювати дані зі стану змішаної фази до нульової фази, проте ця процедура не завжди успішна і в мігрованих сейсмічних даних інколи залишається певний зсув в позитивний або негативний бік. Таку поведінку сейсмічних даних було відтворено в синтетичному наборі даних для тренування моделі ШІ, і саме тому попередньо до навчання моделі, починаючи з самого верхнього згорткового шару дані підверглись нормалізації.

Що стосується активізаційної функції, ReLU (Rectified Linear Unit) є однією з найпопулярніших функцій активації, що використовується у нейронних мережах. Вона дозволяє моделі ефективно навчатися, завдяки своїй простоті та ефективності. Формально, ReLU визначається як:

$$f(x) = \max(0, x) \quad (2.2)$$

Це означає, що всі негативні значення обнуляються, а всі позитивні залишаються незмінними за рахунок наявної точки перегину функції в 0. Основні переваги ReLU включають:

- Простоту обчислення: функція ReLU дуже проста і швидка в обчисленні, що дозволяє ефективно використовувати обчислювальні ресурси.
- Покращене навчання: ReLU допомагає вирішити проблему зникнення градієнтів, оскільки градієнт є константним для всіх позитивних значень.
- Сприяння рідкісному кодуванню: обнуляючи негативні значення, ReLU створює "рідке" (sparse) кодування, що може покращити ефективність і точність моделі.

Однак, ReLU має і певні недоліки, такі як "мертві нейрони", коли значні частини нейронів можуть просто перестати активуватися (видаючи нульовий вихід), що може вплинути на ефективність моделі. Головна відмінність Leaky ReLU від похідної функції – вона не зберігає інформацію про негативні значення, нівелюючи тим самим проблему «відмираючих нейронів».

Варто зазначити, Leaky ReLU — це варіація ReLU, що намагається вирішити проблему "мертвих нейронів" шляхом введення невеликого нахилу для негативних значень. Формально, Leaky ReLU визначається як:

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha_{x,x}, & x \leq 0 \end{cases}, \text{ де} \quad (2.3)$$

$\alpha_{x,x}$ є невеликою константою (наприклад, 0.01).

Основні переваги Leaky ReLU включають:

- Уникнення мертвих нейронів: завдяки введенню нахилу для негативних значень, Leaky ReLU запобігає повному обнулінню негативних виходів, зберігаючи активність нейронів.
- Краща градієнтна пропагація: навіть для негативних значень, Leaky ReLU забезпечує ненульовий градієнт, що покращує пропагацію градієнтів та загальну ефективність навчання моделі.

Головний недолік обох функцій, а саме – ненормалізованість було покрито за рахунок нормалізації тренувального та валідаційного наборів даних (BatchNormalization) із тим, що при роботі нейронної мережі з реальними даними, останні будуть також нормалізовані на початку навчання та денормалізовані при перетворенні масиву даних в робочі файли (наприклад, *.SEGY).

Принциповою складовою НМ є активаційна функція, яка вирішує питання активізації тих чи інших нейронів. В індивідуальному випадку вага нейрона в прямій нейронній мережі розраховується за формулою

$$Y = \sum_{i=1}^n (X_i * w_i) + b, \text{ де} \quad (2.4)$$

X_i – вхідні властивості, w_i – ваги, а b – це зміщення (біас) нейрона.

В такому випадку, функція активації f , застосовується до кожного нейрона і виконується активізація тих чи інших нейронів.

$$Output = f(Y)$$

На рисунку 2.8 у вигляді діаграми зображено роботу активаційної функції




Рисунок 2.8. Схематичне зображення роботи активаційної функції.

Таким чином, функції активізації є одномірними і нелінійними, оскільки нейронна мережа з лінійною функцією активізації еквівалентна моделі лінійної

регресії. Саме завдяки своїй нелінійності функції активізації можуть захоплювати для НМ складні семантичні структури і досягати високої продуктивності.

З огляду на характер і структуру сейсмічних даних, в якості активаційної функції було випробувано два її варіанти – **сигмоїд** та **тангенс**.

Функція активізації сигмоїд (також називається логістичною функцією) приймає будь-яке дійсне значення на вході і видає значення в діапазоні (0,1). Вона обчислюється наступним чином:

$$s(x) = \frac{1}{1+e^{-x}} \quad (2.5)$$

Тут x є вихідним значенням нейрона. Більше того, ми можемо побачити графік функції сигмоїд, коли вхідне значення знаходиться в діапазоні -10, 10 (рис 2.9, а). Як і очікувалося, сигмоїдна функція є нелінійною і обмежує значення нейрона в малому діапазоні (0, 1). Коли вихідне значення наближається до 1, нейрон активний і забезпечує потік інформації, тоді як значення, близьке до 0, відповідає неактивному нейрону.

Також важливою характеристикою сигмоїдної функції є те, що вона прагне штовхати вхідні значення до одного з кінців кривої (0 або 1) через свою S-подібну форму. В області, близькій до нуля, якщо ми злегка змінимо вхідне значення, відповідні зміни у виході будуть дуже великими і навпаки. Для вхідних значень менше -5 вихід функції майже нульовий, тоді як для вхідних значень більше 5 вихід майже один.

Важливо нагадати, що бажана поведінка моделі – а саме збільшення співвідношення сигнал-завада сейсмічних даних, частково як раз і полягає в створенні градієнта в даних, які через особливості геологічного розрізу площі, процесу обробки або вад вхідних даних мають близькі до нуля значення і ускладнюють процес сейсмічної інтерпретації.

Нажаль, вказана активаційна функція має і свої вади:

- У випадку дуже великих або дуже малих значень x , похідна функції сигмоїд стає дуже маленькою, що призводить до проблеми зникнення градієнта.

Це ускладнює навчання глибоких нейронних мереж, оскільки градієнти майже не передаються назад через шари мережі.

- Вихідні значення функції варіюються від 0 до 1, що означає, що виходи не центровані навколо нуля. Додатковий крок із денормалізації моделі для приведення її до початкової структури даних ускладнює кодування і потребує ресурсів ПК для додаткових обрахунків та збереження тимчасових прорахованих об'єктів.


Ще однією функцією активації, яка є поширеною в глибокому навчанні, є гіперболічна тангенс функція, або просто функція $\tanh$. Вона обчислюється наступним чином:

$$s \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} = \frac{2 - (1 + e^{-2x})}{1 + e^{-2x}} = \frac{2}{1 + e^{-2x}} - 1(x) = \frac{1}{1 + e^{-x}} \quad (2.6)$$


Функція $\tanh$ є зсунутою та розтягнутою версією сигмоїдної функції. Нижче ми можемо побачити її графік, коли вхід знаходиться в діапазоні -10, 10 (рис. 2.9, б). Вихідний діапазон функції $\tanh$ становить (-1, 1) і демонструє схожу поведінку з сигмоїдною функцією. Отже, головна відмінність полягає в тому, що функція $\tanh$ штовхає вхідні значення до 1 і -1 замість 1 і 0. Серед переваг даної функції слід зазначити:

- Завдяки центрованості навколо нуля, градієнти, обчислені на основі $\tanh$, можуть бути більш стабільними та рівномірними. Це допомагає уникати проблеми зміщення активаційних значень, що може пришвидшити процес навчання моделі.

- В області, близькій до нуля, функція $\tanh$ є дуже чутливою до змін вхідних даних. Це означає, що невеликі зміни на вході призводять до значних змін на виході, що корисно для розрізнення невеликих відмінностей у вхідних даних.



а) сигмоїд



б) тангенс

Рисунок 2.9. Графіки активаційних функцій.

Таким чином, використання останньої функції не тільки пришвидшує роботу НМ, а й відкидає необхідність проводити денормалізацію опрацьованих даних, зміщуючи діапазон значень в негативну площину. В фінальному варіанті моделі для активації нейронів окремого слою була використана функція Leaky ReLU, що запускає розрахунок вихідних значень нейрону, а от функція $\tanh$ була використана для активації останнього шару, тобто виходу моделі.

Ключовим інструментом керування та налагодження ваг НМ є функція втрат що коригує поведінку моделі, а також функції для вимірювання параметрів навчання моделі. Визначним моментом є – простеження відповідності прогнозованого сейсмічного розміру до тренувального зображення з одного боку, і збереження структурних особливостей (характер примикання відбивальних горизонтів, простеження порушень) з іншого. Рішення подібних задач активно досліджується [89, 94] і вже опубліковано порівняльні результати робіт із застосуванням найбільш актуальних функцій втрат – Mean Squared Error (MSE), VGG Loss, PSNR, MSSE.

В межах представленої роботи було використано наступні зразки функції втрат, використані для оцінки якості навчання нейронної мережі:

- ℓ_1_loss
- ℓ_2_loss
- PSNR

- Pixel MSE
- SSIM
- MS-SSIM

Функція втрат ℓ_1 (або ℓ_1_loss , середнє абсолютне відхилення) визначається як сума абсолютних різниць між передбачуваними значеннями та фактичними значеннями. Математично це виражається наступним чином:

$$\mathcal{L}^{\ell_1} = \frac{1}{N} \sum_{i,j} |I_{SR}(i,j) - I_{HR}(i,j)| \quad , \text{ де } \quad (2.7)$$

N – кількість пікселів, I_{SR} – зображення низької розрізної здатності, I_{HR} – зображення високої розрізної здатності.

Функція ℓ_1_loss вимірює величину помилки без урахування її напрямку (позитивного чи негативного), що робить цю функцію корисною у задачах, де важливо враховувати лише відхилення від істинного значення незалежно від їхнього знаку. Її застосовують для вирішення:

- регресійних задач з викидами, бо ℓ_1_loss добре працює в ситуаціях, коли дані містять викиди, оскільки ця функція менше реагує на великі помилки порівняно з ℓ_2_loss (сума квадратів помилок). Це робить модель більш стійкою до викидів.

- розріджених моделей у завданнях, де бажано, щоб багато параметрів моделі були нульовими, використання ℓ_1_loss разом з ℓ_1 регуляризацією (Lasso) допомагає створювати розріджені моделі. Це корисно для високорозмірних даних.

- задач обробки зображень для деяких випадків, де при обробці зображень, (задач збільшення співвідношення сигнал/шум або стискання), використання ℓ_1_loss може бути більш доречним для збереження деталей та структури зображень.

- контролю якості, ℓ_1_loss може використовуватися у випадках, де важливо враховувати лише абсолютні відхилення від стандартів без урахування напрямку помилки.

І хоча завдяки перевагам у покращенні продуктивності та конвергенції над середньоквадратичною помилкою (MSE) або ℓ_2_loss [8], ℓ_1_loss широко використовується для збільшення розрізної здатності зображень, для вирішення поточної задачі, де зміни здебільшого коливаються в діапазонах, близьких до нуля, вона може використовуватись лише на початкових ітераціях з метою оцінки будови моделі і визначенням напрямку подальших коригувань для досягнення бажаного результату. Виявилось, що на практиці нейронна мережа, навчена використовувати лише ℓ_1_loss , генеруватиме зображення високої розрізної здатності з гладкими текстурами, що не є прийнятними для подальшого процесу робіт з сейсмічної інтерпретації через втрату окремих геологічних подій, що локально розташовані в хвильовому полі. Причина полягає в тому, що ℓ_1_loss мінімізує єдину піксельну відстань між результатом навчання моделі і метою, та ігнорує текстурні елементи.

Функція втрат ℓ_2 (або ℓ_2_loss , середньоквадратична похибка, mean squared error, MSE), визначається як сума квадратів різниць між передбачуваними значеннями та фактичними значеннями. Математично це виражається наступним чином:

$$\mathcal{L}_{l_2} = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \text{ де} \quad (2.8)$$

y_i — це фактичне значення, а $\hat{y}_i$ — передбачуване значення.

Як і ℓ_1_loss , ℓ_2_loss надає більшу вагу великим помилкам, оскільки вони підносяться до квадрату, що робить цю функцію корисною у ситуаціях, де важливо мінімізувати великі відхилення. Напрямки її застосування подібні до функції ℓ_1_loss :

- регресійні задачі без викидів, бо ℓ_2_loss добре працює у задачах регресії, де дані не містять значних викидів, оскільки великі відхилення сильно впливають на функцію втрат. Це допомагає моделі краще навчатися на даних без екстремальних значень.
- гладкі моделі, через те що ℓ_2_loss сприяє створенню гладких моделей, де малі зміни у вхідних даних призводять до невеликих змін у вихідних

даних. Це корисно для задач, де важливо уникати раптових стрибків у передбаченнях.

- оптимізація: ℓ_2 loss часто використовується у багатьох алгоритмах оптимізації, таких як градієнтний спуск, оскільки її похідна легко обчислюється і вона має гарні властивості для швидкої та стабільної збіжності.
- контроль якості у виробничих процесах, де важливо мінімізувати великі відхилення від стандартів, ℓ_2 loss використовується для точного контролю якості та виявлення значних помилок.

Вирішення другої частини завдання, а саме заміни стандартної ℓ_1 функції відбувалось ітеративно, з контролем результатів роботи моделі за використаної функції втрат. Суттєвим приріст якості прогнозу моделі був при застосуванні пікового співвідношення сигнал-завада (PSNR loss function), яке краще відображає кількість сингалу, який має зашумлену природу, а відтак – має бути змінений в ході навчання моделі.

Функція втрат PSNR loss (або пікове відношення сигнал/завада, Peak Signal-to-Noise Ratio) це міра якості реконструкції або обробки зображень, звукових сигналів та інших типів даних. PSNR визначає, наскільки реконструйоване (або оброблене) зображення відрізняється від оригінального зображення, вимірюючи рівень шуму, що був доданий під час обробки.

PSNR розраховується на основі середньоквадратичної помилки (ℓ_2 loss, MSE) між оригінальним та реконструйованим зображеннями і математично може бути зображена наступним чином:

$$PSNR = 10\log_{10} \left(\frac{MAX_I^2}{MSE} \right) = 20\log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right), \text{ де} \quad (2.9)$$

MAX_I - максимальне можливе значення пікселів зображення (наприклад, 255 для 8-бітного зображення), а MSE — середньоквадратична помилка між оригінальним і реконструйованим зображеннями.

PSNR дуже часто застосовується для вирішення різноманітних задач:

- PSNR широко використовується для оцінки якості стиснення зображень та відео. Ця функція втрат дозволяє порівнювати різні алгоритми стиснення (наприклад, JPEG, PNG) і оцінювати їх вплив на якість відновлених даних.
- обробка зображень: PSNR використовується для оцінки якості різних методів обробки зображень, таких як фільтрація, збільшення співвідношення сигнал/завада та збільшення розрізної здатності. Чим вище значення PSNR, тим краща якість відновленого зображення.
- при кодуванні відео PSNR допомагає оцінити ступінь втрати якості при використанні різних методів кодування, таких як H.264, HEVC та інші. Це важливо для збереження якості відео при зменшенні його розміру.
- PSNR застосовується для оцінки якості методів зниження шуму у медичних зображеннях, таких як МРТ або КТ. Це допомагає забезпечити високу якість діагностичних зображень.
- PSNR використовується для оцінки якості зображень та відео, що передаються через мережі з обмеженою пропускну здатністю. Це допомагає мінімізувати втрати якості під час передачі даних.

Хоча PSNR є популярним показником якості зображень, він має свої обмеження. Наприклад, він не завжди корелює з візуальним сприйняттям якості людиною. У деяких випадках зображення з високим PSNR можуть виглядати гірше для людського ока, ніж зображення з нижчим PSNR, через втрату просторових співвідношень об'єктів композиції, тому для більш точного оцінювання якості можуть використовуватися додаткові метрики, такі як структурна подібність (SSIM).

Похідною функцією від ℓ_2_loss є Pixel MSE або середньоквадратична помилка пікселів. Вона визначається як середнє значення квадратів різниць між відповідними пікселями двох зображень: оригінального та реконструйованого (або обробленого) зображення.

Математично це виражається наступним чином:


$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i,j) - K(i,j)]^2, \text{ де} \quad (2.10)$$

$I(i,j)$ — інтенсивність пікселя в оригінальному зображенні.


$K(i, j)$ — інтенсивність пікселя в реконструйованому (або обробленому) зображенні.

m і n — кількість рядків та стовпців у зображенні відповідно.


Так само, як і PSNR, дана функція застосовується для задач оцінки якості стиснення або обробки зображень, кодування відео, тощо. Різниця між цими двома функціями полягає в наступному: Pixel MSE виражається як абсолютна числова величина, тоді як PSNR використовується логарифмічна шкала, що робить її більш інтуїтивно зрозумілою для інтерпретації. Також PSNR краще показує різницю у якості між зображеннями з високою якістю, оскільки логарифмічна шкала дозволяє краще розрізняти малі відхилення. Щодо сфери застосування – Pixel MSE краще підходить для задач, де важлива точна кількісна оцінка помилки, тоді як PSNR більше використовується у задачах оцінки суб'єктивної якості зображень. Результати тренування моделі із використанням різних функцій втрат зображено на рисунку 2.10.



Функція втрат ℓ_1_loss



Функція втрат ℓ_2_loss



Функція втрат PSNR

Функція втрат **Pixel_MSE**

Рисунок 2.10. Результати навчання моделі із застосуванням різних функцій втрат.

Застосовуючи вищепойменовані функції втрат до відтворення зображень з тестового набору даних, було отримано досить високі значення для прогнозних зображень по PSNR, що відповідало поставленій задачі (рис. 2.10), проте при застосуванні до реальних сейсмічних даних, цей результат було признано неоптимальним через часткову втрату просторових залежностей елементів сейсмопрофілів. Тобто при фактичному збільшенні співвідношення сигнал/завада були фактично змінені трасування контрастних рефlectorів, що

було неприйнятною поведінкою моделі в рамках встановлених обмежень на очкувань до роботи НМ (рис. 2.11).




Рисунок 2.11 Результат роботи моделі ШІ на синтетичних даних. Зліва – очікуваний результат, в центрі – вхідні дані для роботи моделі, справа – результат прогнозу. Значення PSNR вказують відносний рівень впевненості прогнозу.

Для покращення роботи моделі потрібно було ввести певний баланс між збільшенням співвідношення сигнал/завада і збереженням просторового співвідношення об'єктів в межах сейсмопрофілів. Для цього було прийнято рішення стосовно використання таких функцій втрат як SSIM та MS-SSIM.

Структурна подібність (Structural Similarity Index, SSIM) — це метрика для оцінки якості зображень, яка враховує зміни у структурі об'єктів, освітленні та контрасті між оригінальним і відновленим (обробленим) зображенням. На відміну від традиційних показників, таких як MSE та PSNR, SSIM краще корелює

з людським сприйняттям якості зображень. Ідея SSIM полягає в тому, що близько-розташовані пікселі мають сильний взаємозв'язок. Ця залежність несе важливу інформацію про структуру об'єктів та загальну компоновку.

Математично SSIM виражається наступним чином:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \text{ де} \quad (2.11)$$

x і y – оригінальне та відновлене зображення відповідно;

μ_x і μ_y – середні значення інтенсивностей пікселів у вікні зображень x та y ;

σ_x^2 і σ_y^2 – дисперсії інтенсивностей пікселів у вікні зображень x та y ;

σ_{xy}^2 – коваріація між інтенсивностями пікселів у вікні зображень x та y ;

C_1 і C_2 – малі стабілізаційні константи, щоб уникнути дільника нуля.

SSIM часто використовується для оцінки якості різних методів обробки зображень, таких як фільтрація, збільшення співвідношення сигнал/завада та стискання. Ця метрика враховує локальні зміни в структурі, освітленні та контрасті зображень, що робить її більш релевантною для людського сприйняття. SSIM використовується для оцінки якості відеокодеків, таких як H.264 або HEVC, де важливо зберегти візуальну якість відео при його стисканні. Щодо відтворення композиції зображення, SSIM часто використовується в медичних зображеннях, таких як МРТ або КТ, де SSIM допомагає оцінити якість методів зниження шуму та покращення зображень, щоб забезпечити високу точність діагностики. Ще один із важливих напрямків застосування цієї метрики – в системах розпізнавання обличчя SSIM може бути використаний для оцінки якості зображень обличчя, що важливо для розуміння якості відтворення композиційної цілісності рисунка.

MS-SSIM (multi-scale structural similarity index metric) – Розширена метрика SSIM, яка здійснює оцінку подібності одночасно в кількох різних масштабах зображення [94]. Механізм роботи полягає в розбитті зображення на кілька масштабів, де для кожного масштабу розраховується SSIM індекс. Остаточний MS-SSIM індекс розраховується як середнє значення SSIM індексів на різних масштабах.

Таким чином, SSIM використовується у багатьох загальних задачах оцінки якості зображень для відносно невеликих зображень, у той час як MS-SSIM: використовується у задачах, де важливо враховувати як дрібні, так і великі деталі, таких як медичні зображення, високоякісне стиснення зображень і відео

Додатково хотілось би нагадати, що постійні згадки інших царин застосування тих чи інших функцій втрат, метрик якості або ж навіть архітектур НМ в першу чергу пов'язані з тим, що бурхливий розвиток нейронних мереж в супутніх дисциплінах дав старт багатьом існуючим прикладам застосування, статтям та відкритим репозиторіям коду на GitHub, які підштовхнули дане дослідження і в багатьох аспектах скерували його напрямом.

Первинно PSNR, MS-SSIM та SSIM є додатними зростаючими метриками, але для цілей навчання нейронної мережі було створено функції втрат на їх основі.

Як було вказано вище, бажана поведінка моделі – це певний баланс між збільшенням співвідношення сигнал/завада і збереженням структурної композиції, яка була в похідному сейсмічному матеріалі, тому в результаті ітеративного випробування різних метрик ід час тренування моделі для покращення прогнозової якості моделі було скомбіновано **l1_loss** та MS-SSIM функції втрат. В математичному вигляді фінальну функцію втрат можна представити наступним чином:

$$\mathcal{L}^{mix} = \alpha * \mathcal{L}^{ms-ssim} (1 - \alpha) * \mathcal{L}^{\ell_1}, \text{ де}$$

$$\mathcal{L}^{ms-ssim} = 1 - \text{MS-SSIM}(l_{sr}, l_{hr}) \quad (2.12)$$

α – вага функції втрат,

l_{sr} – зображення низької розрізненості

l_{hr} – зображення високої розрізненості

Результат тренування з використанням оптимізованої функції втрат зображено на рисунку 2.12.





Рисунок 2.12. Співставлення **Pixel_MSE** та комбінованої функцій втрат впродовж процесу тренування моделі.

Досить показовим є також порівняння значень різних метрик застосованих до прогнозованого зображення на реальних даних, що продемонстровано на рисунку 2.13.



```

Low to Hi (SSIM): -0.552664577960968
Low to predict (SSIM): -0.6900178790092468
Predict to Hi (SSIM): -0.728191614151001
=====
Low to Hi (MS-SSIM): -0.7778390645980835
Low to predict (MS-SSIM): -0.6900178790092468
Predict to Hi (MS-SSIM): -0.9152898788452148
=====
Low to Hi (PSNR): -37.935272216796875
Low to predict (PSNR): -43.37538146972656
Predict to Hi (PSNR): -43.31098937988281
=====
Low to Hi (MSE): 0.05073368176817894
Low to predict (MSE): 0.027120081707835197
Predict to Hi (MSE): 0.02732187695801258
=====
Low to Hi (mixed): 0.15359003841876984
Low to predict (mixed): 0.11970748752355576
Predict to Hi (mixed): 0.061754826456308365

```

Рисунок 2.13. Порівняння метрик моделі ШІ на реальних даних

2.7. Застосування моделі до реальних даних 2D профілів.

Один із головних критеріїв працездатності моделі – якість результатів її застосування до реальних даних, які досить часто так чи інакше відрізняються від синтетичного набору, що був використаний при побудові НМ. Слід нагадати, що найбільш поширений похідний і давно стандартизований формат зберігання сейсмічних даних, до якого будувалась НМ – *.SEG Y (Society of Exploration Geophysicists Y, де "Y" означає формат). Але цей формат спроектовано для зберігання та демонстрації даних, а для числових маніпуляцій його слід конвертувати в датафрейм, з яким можливі обчислювальні операції. З огляду на те, що наразі в Україні відсутній чіткий стандарт зберігання і маркування даних (це стосується як полярності даних, так і маркованих байтних діапазонів для зберігання інформації стосовно координат чи заголовків інлайнів та кросслайнів), було апробовано кілька бібліотек, які пропонують автоматичне, або напів-автоматичне зчитування заголовків для розпізнавання координатних та номінаційних даних.

Найпростішим варіантом виявилось застосування бібліотеки *segysak*, як спрощеного варіанту бібліотеки *segvio* із її вбудованими функціями трансформації даних та читання заголовків (рис. 2.14) і подальшим ручним вводом аргументів функції зчитування, що поставляється в бібліотеці.

В результаті трансформації отримується файл з розширенням *.nc, який авторами бібліотеки іменується як xArray – по суті це датафрейм із заголовками, які були копійовані з похідного SEG Y файлу. На додаток, *.nc формат має прямі функції конвертації в *.пру для проведення прямих розрахунків.

Зворотна процедура конвертації обробленого *.nc файлу теж можлива за допомогою цієї ж бібліотеки, і тут є цікавий нюанс – під час конвертації в *.пру втрачається інформація стосовно просторових даних матеріалів сейсмічної зйомки. Найпростіший і найоптимальніший шлях відновлення вказаних координат – це зробити копію даних з інформацією про вузлові точки з вхідного файлу, напряму привласнивши їх до обробленого моделлю набору даних.

► Dimensions:	(iline: 778, xline: 586, depth: 3501)		
▼ Coordinates:			
iline	(iline)	uint16	18 19 20 21 22 ... 792 793 794 795
xline	(xline)	uint16	7 8 9 10 11 ... 588 589 590 591 592
depth	(depth)	float64	0.0 2.0 4.0 ... 6.998e+03 7e+03
cdp_x	(iline, xline)	float32	...
cdp_y	(iline, xline)	float32	...
▼ Data variables:			
data	(iline, xline, depth)	float32	...
► Indexes: (3)			
▼ Attributes:			
sample_rate :	2.0		
text :	C01 CLIENT: C02 SURVEY: UKRAINE. C03 TYPE OF DATA: FINAL PSDM FULL ANGLE STACK TO TIME, DOMAIN: TIME C04 DATA FORMAT: SEG-D, DATE ACQUISITION: 2017, COORDINATE SYSTEM: WGS84 UTM 36N C05 SOURCE TYPE: VIBROSEIS/DYNAMITE, SAMPLE RATE: 2MS, SWEEP FREQUENCY: 8-96 Hz C06 RECORD LENGTH: 7 SEC, SOURCE INTERVAL: 50 M, RECEIVER INTERVAL: 50 M C07 SRC LINE INTERVAL: 350 M, REC LINE INTERVAL: 350 M, CHANNELS: 4732 TRACES C08 BIN SIZE: 25.0 M X 25.0 M C09 PROCESSING BY: PROCESSING DATE: FEBRUARY 2020 C10 GRID CORNER 4 IL 800 C11 GRID CORNER 3 IL 800 C12 GRID CORNER 2 IL 1 C13 GRID CORNER 1 IL 1 C14 DATUM PLANE: 150 M, REPL VELOCITY: 1750 M/S, FIRST SAMPLE: 0 MS C15 PROCESSING SEQUENCE C16 INPUT SEG-D, REFORMAT, GEOMETRY MERGE, TRACE EDIT, DESPIKE, MINIMUM PHASING, C17 REFRACTION TOMO STATICS, T2 GAIN, XSPREAD-3DAAA, NUCNS, SURVEY MATCH, INV Q, C18 SCAC/ DECON, ZERO PHASING, NMO VELOCITY ANALYSIS AND C19 RESIDUAL STATICS (3 PASSES), TAU-P DEMULTIPLE, 5DMPFI, PSDM TOMOGRAPHY C20 (2 ISOTROPIC AND 2 ANISOTROPIC ITERATIONS), ANISO VTI KPSDM, DEPTH TO TIME. C21 TRIM STATICS, C22 0-45 DEG MUTE, C23 STACK, BW EXT, TVF, MPNA, C24 OUTPUT SEG-Y (IBM FLOAT 32-BIT).		

Рисунок 2.14. Заголовок *.SEG-Y файлу для завантаження в проект

Як було обговорено в розділі 2.3, використаний для навчання НМ набір даних складався з 3200 пар зображень у форматі *.dat з фіксованим розміром 256x256 для малюнків високої розрізної здатності та 128x128 для тих, що мають низьку. Реальні сейсмічні мігровані дані значно більші за розмірами, до того ж їх розмір визначається дизайн-проектом для кожного конкретного поля зйомки. В загально-доступному наборі синтетичних тренувальних даних їх

розмірність зумовлена саме обмеженнями швидкості обробки і вимогами до потужностей обчислювальної техніки (в поточній реалізації на обчислення приймається 7,707,457 нейронів), в той час як реальні дані в рази більші (256x256 для синтетичного набору даних проти 778x3501 з реальних даних в наведеному прикладі).

Таким чином, для обробки матеріалів сейсмічної зйомки, потрібно провести певну підготовку даних.

Трансформований формат у вигляді датафрейму містить вимірювані показники положення в просторі даних. Для 3D кубів це – глибина (або час), інлайни та кросслайни, а для навігації в 2D профілях було використано `cdp` та глибину (час). `Cdp`, або `common depth point` було використано для навігації уздовж профіля, а стовпчик «`depth`» – у вертикальній осі. Слід відмітити що під час формування датафрейму для спрощення робочого процесу завжди використовувалась назва «`depth`», навіть для часових кубів. Зрозуміло, що вертикальний крок у двох різних реалізацій одного і того ж сейсмічного матеріалу в залежності від домену буде різним, але це питання було покрито за рахунок ведення змінної кроку глибини (рис. 2.15, змінна «`depth_inc`») який для часового домену для Українських даних зазвичай дорівнює 2мс, а для глибинного – 5м. Далі виконується послідовний поділ 2D профіля на слайси розмірністю заданою моделлю III з урахуванням невеликої зони оконтурювання для зменшення крайових ефектів. Для кожного такого утвореного зображення створюється контейнер, застосовується тренувана модель і виконується функція агрегації оброблених контейнерів в єдиний датафрейм. Зміна кількості вимірів (строчки 45, 47) була зумовлена тим, що під час тренування моделі зображення подавались порційно (`batches`), і хоча технічно можна одразу пустити модель обробляти кілька зображень, сама постановки задачі потребує послідовного виконання перетворень. Таким чином, команда `container.reshape((1, 256, 256, 1))` означає форматувати простір наступним чином:

```

1 def process_volume(seggy, overlapping=0.5, agg_function=average_custom, extremes_cut_sigmas=None, grid_thickness=6):
2     if extremes_cut_sigmas:
3         seggy.data.values[seggy.data.values > extremes_cut_sigmas] = extremes_cut_sigmas
4         seggy.data.values[seggy.data.values < -extremes_cut_sigmas] = -extremes_cut_sigmas
5
6     idx = dict(seggy.indexes)#Normal folw - use seggy.indexes
7
8     cdp_range = len(idx['cdp'])
9     cdp_start = int(idx['cdp'].min())
10    depth_range = len(idx['depth'])
11    depth_start = int(idx['depth'].min())
12    depth_inc = int(np.ceil((idx['depth'].max()-idx['depth'].min())/depth_range))
13    step = 256 - grid_thickness
14    over_abs = int(step * overlapping)
15    shift_size = step - over_abs
16
17    step_cdp = int(np.ceil(cdp_range/shift_size))
18    step_depth = int(np.ceil(depth_range/shift_size))
19    processed_array = seggy.data.to_numpy()
20    processed_array = processed_array.reshape(1, *processed_array.shape)
21
22    border = int(grid_thickness/2)
23
24    for cdp in range(step_cdp):
25        #divided iterations per required step
26        for depth in range(step_depth):
27            # get original values
28            image_p = seggy.data.sel(
29                cdp = slice((cdp*(shift_size - border)), cdp*(shift_size - border) + step - 1 + grid_thickness),
30                depth = slice((depth*(shift_size - border)*depth_inc, depth*(shift_size - border)*depth_inc + step*depth_inc - 1 + grid_thickness*depth_inc)
31            )
32            prep_image = image_p.to_numpy()
33
34            # get the shape of current frame
35            x_orig, y_orig = prep_image.shape
36
37            # get previously computed values for overlapping (iline remains the same for 2D)
38            prep_image_prev = processed_array[((cdp)*shift_size) : ((cdp)*shift_size + step),
39                ((depth)*shift_size) : ((depth)*shift_size + step)]
40
41
42            # put image to container
43            container = np.zeros((1, 256, 256))
44            container[:, :x_orig, :y_orig] = prep_image
45
46            predict_image = container.reshape((1, 256, 256, 1))
47            predict_image = model.predict(predict_image)
48            predict_image = predict_image.reshape((1, 256, 256))
49
50            # apply aggregation
51            if overlapping > 10 :
52                weights_1 = (frame_ker(l=256, sig=1.)).reshape(1, 256, 256)
53                weights_2 = (1 - frame_ker(l=256, sig=1.)).reshape(1, 256, 256)
54                prep_image_agg = agg_function(np.array([predict_image[:, :x_orig, :y_orig] * weights_1[:, :x_orig, :y_orig],
55                    prep_image_prev * weights_2[:, :x_orig, :y_orig]]), axis=0)
56            else:
57                prep_image_agg = predict_image[:, :x_orig, :y_orig]
58                processed_array[:,
59                    (cdp)*(shift_size-border):(cdp)*(shift_size-border) + x_orig),
60                    (depth)*(shift_size-border):(depth)*(shift_size-border) + y_orig] = prep_image_agg
61
62    return processed_array

```

```

1 processed_array_orig_W_0_overlap = process_volume(seggy=processing_seggy, overlapping=0, agg_function=average_custom, extremes_cut_sigmas=None, grid_thickness=8)

```

Рисунок 2.15. Блок коду обробки 2D профілів за допомогою моделі ШІ

1 – кількість файлів поданих на обробку (batch);

256 – «довжина» зображення що обробляється;

256 – «висота» зображення що обробляється;

1 – кількість каналів кольору. Для зображень їх стандартно три (RGB), але так як об'єкт роботи – сейсмічні дані, що мають одну розмірність, канал тут теж один.

Під час застосування моделі III є дві базові стратегії поведінки – не вказувати розмір вікна для зчитування, що «розтягне» вікно прогнозу моделі на все вікно обробки даних і, відповідно, розбити вікно аналізу на блоки за розміром моделі. Під час тестування перший варіант дав доволі поганий результат через різницю масштабів моделі III і реальних даних, тобто один розріз (до прикладу один інлайн) сейсмічного куба містить набагато більше інформації ніж в невеликий зразок синтетичних даних і таким чином рівень узагальнення по результатах тренування надвисокий. Таким чином залишається другий варіант – поділення вікна аналізу на блоки за розміром моделі. Подібний поділ дозволяє дотримуватись співвідношення реальних/синтетичних даних 1:1, що виключає проблему узагальнення, але натомість викликає проблему крайових зон двох сусідніх зон прогнозу і їх коректного поєднання, що може бути вирішено двома шляхами – з перекриттям (overlap) і без нього. Саме існування цих крайових зон зумовлене тим що робота моделі проводиться саме в межах виділеного вікна без контексту оточуючих даних. Якщо дані не мають вертикальної зональності – співвідношення двох примикаючих вікон буде гладким, якщо ж зональність присутня – буде помітна зона стикування двох вікон прогнозу.

1) Варіант з перекриттям має суттєвий теоретичний плюс – наявність контексту на кожний фрагмент, що збільшує достовірну вірогідність прогнозу моделі. Проте на практиці виникає проблема згладжування та 2-3 кратного аналізу частини набору даних. Подібний варіант прийнятий стандартним рішенням для графічних зображень, але для безперервних даних зустрічається проблема спотворення первинного сейсмічного матеріалу, тож такий варіант було відкинуто в процесі тестування.

2) Варіант без перекриття має теоретичний мінус в якості відсутності контексту для крайових областей обробленого поля. В нашому випадку це не має великого значення позаяк об'єкт роботи – мігровані сейсмічні дані які зазвичай мають крайовий ефект міграції що під час процесу сейсмічної інтерпретації не враховується в побудовах. Позитивний момент відсутності перекриття полягає в тому що кожен блок даних обробляється один раз і таким чином отримується одна реалізація, що виключає будь-яку варіативність прогнозу.

В обох випадках модель створює артефакти по краях зони прогнозу у вигляді «сітки» шириною в 1 піксель (див. рис. 2.16, А), яка виникає на границях обчислювальних вікон моделі ШІ.




Рисунок 2.16. Моделювання процесу формування сітки (а) і код вирішення цієї проблеми (б).

Під час спроб вирішити проблему крайових зон було ітеративно виконано ряд реалізацій з різними параметрами, а саме:

- було випробувано варіант з 50% перекриттям вікон аналізу, що повинно було гарантувати безперервний прохід вікна аналізу по сейсмічних даних. Нажаль, на практиці це призвело до того що прогноз уздовж вікон аналізу

нашаровувався проходячи по вже прогнозованих даних, що призводило до нереалістичного поділу сингалу.

- було мінімізовано перекриття до 15%, але натомість було використано функцію узагальнення даних. Серед доступних варіантів були осереднююча (avg), мінімальних/максимальних значень в зонах стику, та гаусова (gauss). Нажаль, такий підхід генерував невеликі артефактні зони по краях вікон прогнозу, що було видно неозброєним оком і, таким чином, якість прогнозу в зонах стику була неприйнятною.

У якості фінального рішення цієї проблеми було застосовано наступний ряд заходів: саму ситуацію формування «похибок» було в спрощеному вигляді змодельовано в окремому excel файлі щоб наочно побачити процес їх формування. На рисунку 2.16, А схематично зображено процес формування артефактів по краях зони прогнозу. Трьома кольорами позначено 3 зони прогнозу і жирним кольором позначено зони накладання даних одні на інші. Праві дві таблиці – це моделювання вибірки з куба оригінальних даних (синя) і моделювання запису результату прогнозу моделі (зелена). На рисунку 2.16, Б викладено код вирішення даної проблеми. Розроблене рішення полягає в тому, що після передбачення для кожного окремого фрагменту відсікається задана ширина граничних пікселів і підбираються цільові фрагменти таким чином, щоб вхідні фрагменти накладались саме на ширину границі, що буде відрізана, а результат прогнозу після відсікання границі був би продовженням попереднього передбачення з відсіканням. Таким чином отримується результуючий прогнозний куб з найбільш релевантних даних. Складність роботи з сіткою і формулою для неї полягає в тому, що у формулі треба врахувати крайні фрагменти, в яких границі необхідно залишити і не відрізати, але вся їх конфігурація має бути описана формулами, що розраховують координати початкових і кінцевих пікселів для кожного із вимірів (змінна «border» в коді на рисунку 2.16, Б).

Наступним питанням, що потребувало уваги можна вважати використані підходи до нормалізації даних. Як відомо [95], сейсмічні дані мають нормальний

розподіл амплітуд – тобто максимальна кількість даних знаходиться ближче до нульових значень, а той час як суттєво менша – належить до екстремальних (рис. 2.17).




Рисунок 2.17 Амплітудна складова куба сейсмічних даних

Під час побудови моделі III було проведено нормалізацію синтетичних даних для коректної роботи функції втрат, таким чином, постає питання стандартизації сейсмічних даних так як стандартизація дозволяє зробити припущення про нормальний розподіл даних який буде пропрацьований тренуваною на нормалізованих даних моделлю.

Статистичними методами обчислювання, спираючись на правило трьох сигм можна обмежити граничні значення амплітуд мігрованих сейсмічних даних, замінивши їх граничними показниками значення σ . До прикладу $\sigma = 0,7$ замінює екстремальні значення на $0,7 \sigma$, відсікаючи таким чином екстремальні значення у плаваючому вікні. Дана методика дозволяє концентруватись не на абсолютних значеннях даних у вікні аналізу, а на шаблонах їх поведінки, що і є метою застосування моделі III.

Тестування алгоритму із застосуванням даної методики відбувалось ітеративно, тому на початкових стадіях роботи, до введення елементів аугментації в навчальний набір даних, застосування досить великого значення $\sigma=1,5$, що призводило до агресивного «зрізання» моделлю екстремальних значень, видавалось виправданою ідеєю. Натомість, з еволюцією розуміння важелів, що впливають на прогноз – процесів аугментації тренувального набору, детальніше про які буде розказано в наступній главі, призвела до того, що модель забезпечує якісний прогноз з надзвичайно низьким градієнтом значень по відношенню до вихідних матеріалів. Таким чином, було протестовано два варіанти моделі – з $\sigma=3$ для зрізання крайових значень, що вносить відносно невеликий рівень нормалізації та з $\sigma=None$, де дані мають оригінальні ліміти значень, а аномальні зони розгладжуються за рахунок налаштувань вхідних зображень під час тренування моделі.

Суттєвим кроком перед збереженням конвертованого зображення обратно в *.SEG Y формат слід вважати процедуру денормалізації зображення, що намагається відтворювати оригінальні ліміти значень. За рахунок нормалізації та зрізання під час навчання моделі відтворити оригінальні дані не можливо, проте відбувається централізація даних навколо 0 та розширення спектру значень від

оригінального прогнозу. Код функцій нормалізації та денормалізації зображено на рис. 2.18.

```
[ ] 1 def normalize_SEGY(segy):
2     normalized_segy = segy.copy()
3     mean_val = np.mean(normalized_segy.data.values)
4     std_dev_val = np.std(normalized_segy.data.values)
5     normalized_segy['data'] = (normalized_segy.data-mean_val*1)/std_dev_val
6     return normalized_segy, mean_val, std_dev_val
7
8 def denormalize_SEGY(normalized_segy, mean_val, std_dev_val):
9     denormalized_segy = normalized_segy.copy()
10    denormalized_segy = denormalized_segy*std_dev_val+mean_val*1
11    return denormalized_segy
12
13 normalized_segy, mean_val, std_dev_val = normalize_SEGY(processing_segy)
14 normalized_segy.std
```

```
[ ] 1 gc.collect()
```

```
[ ] 1 scaler = np.max(np.abs(normalized_segy.data).values)
2     scaler
3     scaled_segy = normalized_segy.copy()
4     scaled_segy['data'] = scaled_segy.data / (scaler/3)
5     # del normalized_segy
6     gc.collect()
```

Рисунок 2.18. Блок нормалізації/денормалізації для прогнозної матриці значень.

Робочий діапазон значень моделі обумовлений її активаційною функцією - гіперболічним тангенсом. Особливістю цієї функції те, що вона повертає значення симетричні відносно 0. Стандартизація (нормалізація на середньоквадратичне відхилення) вхідних даних дає 99,7% значень у діапазоні від -3 до 3 і решту екстремальних значень понад 10 середньоквадратичних відхилень (сігм). Якщо подати такі данні на вхід моделі, то модель відсіче вихідні дані по діапазону від -1 до 1 і втратить інформацію щодо амплітуди поза цим діапазоном. Проте, якщо нормалізувати дані за допомогою модифікованого алгоритму мін-макс нормалізації (зі збереженням знаку сигналу), то та самі 9.7%

або $-3 +3$ сігми даних будуть стиснуті до менш ніж 10% робочого діапазону моделі і таке стиснення призведе до втрати точності прогнозу.

За результатами ітераційного тестування було прийнято рішення здійснити наступну нормалізацію із збереженням повноцінної денормалізації результатів прогнозу:

1. Стандартизація (нормалізація на середньоквадратичне відхилення із центрування по середньому значенню)

2. Розрахунок максимального абсолютного значення отриманих результатів і нормалізація отриманих даних на $1/3$ від цього максимального значення, що дає можливість спроектувати діапазон $+3$ сігма (99.7% значень) на робочий діапазон моделі $+1$.

Денормалізація відбувається у зворотному порядку. Вищеописана нормалізація дає можливість максимально ефективно використовувати робочий діапазон активаційної функції гіперболічного тангенсу, проте втрачає екстремальні значення амплітуд сигналів поза діапазоном $+3$ сігма. Для відновлення цих екстремальних значень, а також для зниження завищених значень результатів прогнозування, що утворилися через алгоритми вирівнювання інтенсивності сигналу було застосовно масштабування сигналу на основі первинних даних, а саме – розраховано матрицю інтенсивності сигналу як співвідношення актуального значення до значення при 3σ середньоквадратичних відхиленнях, а саме 99,7 персентиль. Після множення цієї матриці на отримані результати, ділянки, що мали низьку силу сигналу у вхідному кубі отримали послаблення, а ділянки з екстремально-сильними значеннями амплітуди - посилення сигналу. Отриманий результат зберігає топографію інтенсивності сигналу, надаючи при цьому вищу розрізняльну здатність.

Додатковою перевагою такого методу є те, що останній крок необхідний для кінцевого використання інтерпретатором, а проміжний результат розрахунку моделі, той що з екстремальними значеннями, може бути використаний напямую для покращеного трасування диз'юнктивних порушень.

2.8. Перехід на 3D U-net архітектуру мережі.

В сучасному світі геологорозвідувальних робіт стандартом даних для постановки пошукового буріння є 3D сейсмічні дані, ситуацій коли даних 2D зйомки достатньо для винесення позитивного рішення стосовно закладання свердловини існує вкрай мало через високий рівень геологічних ризиків, тому реальна цінність моделі що збільшує розрізнявальну здатність і зменшує кількість шумів проявляється здебільшого на мігрованих сейсмічних кубах.

Проблема прогнозу існуючої 2D моделі змальовано на рисунку 2.19.




Рисунок 2.19. Розповсюдження вікон прогнозу моделі в 3D просторі.

Як було сказано раніше, що кожне вікно прогнозу моделі диктується розміром загальнодоступного набору тренувальних і валідаційних 2D даних. Проблема їх послідовного безшовного складання уздовж двомірного профілю було ефективно вирішено, і це не було великою проблемою через послідовний характер даних (рис 2.19, А). Проте головна відмінність 3D куба від 2D профілів полягає в тому, що вони складаються з великої кількості таких послідовних ліній, названих інлайнами та кросслайнами і ці лінії мають генетичний зв'язок даних між ними (рис 2.19, Б). І якщо вікна прогнозу моделі можуть зробити покращений конкретний інлайн чи кросслайн, то їх поєднання разом (рис 2.19, В) вже аж ніяк не буде безшовним через зміни, які модель вносить в ті зони що потребують коригування. На рисунку 2.20 зображено подібну різницю: верхній ряд демонструє зліва направо інлайн, що складений із вікон прогнозу моделі, кросслайн з вікон прогнозу моделі та різницю між сусідніми вікнами. Ідеально щоб вона була якомога близькою до нуля. Нижній ряд демонструє подібну ситуацію на прикладі іншого тестового сейсмічного куба.




Рисунок 2.20. Вікна прогнозу моделі по одному з напрямків сейсмічного куба.

Таким чином, на цій стадії виникає два можливих сценарія розвитку подій:

- Розробити рішення для якісної апроксимації даних, щоб різниця між сусідніми інлайнами була мінімальною або геологічно-обоснованою
- Залишити двомірний варіант мережі для 2D профілів, а для мігрованих сейсмічних кубів розробити подібну модель використовуючи 3D архітектуру U-net

Зваживши всі позитивні і негативні сторони обох варіантів, було прийняте рішення щодо створення ще одної моделі, що принципово працюватиме з 3D даними.

3.1 Висновки

В другому розділі було сформульовано проблематику, яку потрібно вирішити за допомогою моделі ІІІ і в скороченому вигляді описано комплекс проблем, що призвів до самої постановки задачі. Також було проаналізовано продукти головних гравців ринку послуг програмного забезпечення для вирішення різних задач комплексу геологорозвідувальних робіт.

Додатково було проведено аналіз існуючих репозиторіїв коду для вирішення проблем сегментації, а також покращення розрізної здатності сейсмічних матеріалів. Ключовою особливістю проаналізованих репозиторіїв була концентрація робіт західних вчених на суто морській сейсмічній зйомці, що за характером сигналу і проблем, що потребують вирішення суттєво відрізняється від умов ДДЗ. Таким чином, серед наукових робіт, що концентрувались на дослідженні наземної сейсмічної зйомки, як точка відліку та база для формування набору даних для тренування і валідації моделі, були обрані роботи С. Ву [89].

Було проаналізовано найбільш поширені архітектури мереж ІІІ, а саме xPixel та U-net, відповідно до якого було винесено висновок щодо доцільності використання саме моделі U-net через її більшу відповідність поставленій задачі, а також існуванню її різновиду для 3D даних.

Важливим кроком було налаштування гіперпараметрів мережі для підвищення якості роботи саме з сейсмічними даними, бо оригінальний об'єкт для взаємодії з U-net – графічне зображення. Головними чинниками, що впливали на якість прогнозу моделі були активізаційна функція та функція втрат.

Під час тестування активізаційної функції було виконано перехід від сігмоїдної функції, що вважається стандартом для архітектури U-net, до тангенс, яке спростило процес кодування за рахунок відкидання додаткової операції нормалізації-денормалізації даних через той факт, що сама структура тангенс функції більш подібна до структури сейсмічних даних за інтервалом розповсюдження їх даних. Слід відмітити, що процес нормалізації призводить до зрізання екстремальних значень, що автоматично означає втрату корисної інформації. Таким чином, відмова від цього кроку дозволяє в кінцевому етапі зекономити ресурси ПК за рахунок відмови від додаткових операцій з даними і отримати покращений прогноз із застосуванням повного спектру даних.

Тестування функції втрат мало свої складнощі, пов'язані більше з процесом подальшої інтерпретації опрацьованих сейсмічних матеріалів. Проблема полягає в тому що цей процес полягає отриманні витриманих поверхонь рефlectorів без геологічно-пояснюваної різкої зміни значень, проте із збереженням характерних рис розрізу – таких як диз'юнктивні порушення. Використання окремо **l1_loss** було недоцільно саме через «зернистість» результату прогнозу, що погіршувало його інтерпретуємість, а **MS-SSIM** натомість давав сильно «згладжений» результат, що не підкреслював, а навпаки «замилював» критично важливі в геологічній розвідці ознаки невеликих за зоною випадіння диз'юнктивних порушень, понижуючи тим самим достовірність прогнозу. Рішення полягало у створенні об'єднаної функції, що в відсотковому відношенні об'єднує як піксельне співпадіння, яке важливе в зонах контрастних рефlectorів, так і дотримання загальної компоновки зображення у різних масштабах, що більш актуальне в зонах зашумленого сигналу, або просто інтенсивного перешарування, що не може бути в повній мірі відображене через обмеження розрізної здатності сейсмічного матеріалу.

В другому розділі було створено робочий процес застосування моделі ІІІ до реальних 2D профілів, що за замовченням мають більший розмір ніж вікно прогнозу моделі: було обрано програмний пакет для трансформації матеріалів мігрованих сейсмічних 2D зйомок в робочий формат *.nupru, і зворотної трансформації в файли *.SEGҀ після опрацювання за допомогою моделі. Було вирішено проблему співставлення двох сусідніх вікон прогнозу із гарантуванням безшовного переходу градієнту даних від одного вікна до іншого. Також було сформовано алгоритм відновлення спектру даних із оригінального мігрованого набору, що для 2D профілів не має великого значення, проте критично важливий для мігрованих кубів 3D.

Було проведено аналіз можливого застосування 2D варіанта компоновки моделі до 3D даних із розробкою алгоритму осереднення значень між окремими інлайнами. Подібне використання було спостережено в окремих досліджених зразках комерційного програмного забезпечення, на кшталт GeoplatAI. Такий підхід гарантує побудову надійного структурного каркасу для подальшого геологічного моделювання. Нажаль, такий перебіг подій не задовольняє вимоги, які було висунуто до моделі ІІІ бо було б сильно обмежене поле можливого застосування моделі в контексті виявлення і картування аномалій хвильового поля, зняття сейсмічних атрибутів, проведення спектральних декомпозицій, а також картування сейсмічних фацій, що в певних ситуаціях становить критичну роль для опису можливої пастки вуглеводнів в зоні дослідження.

РОЗДІЛ 3. ОСОБЛИВОСТІ ПОБУДОВИ МОДЕЛІ НА БАЗІ АРХІТЕКТУРИ 3D U-NET.

3.1 Алгоритм трансформації тренувального та валідаційного набору даних для застосування в мережі 3D U-net

У зв'язку із безальтернативністю джерела даних для тренування та валідації моделі, було прийняте рішення стосовно напрацювання алгоритму трансформації існуючих 2D даних у псевдо 3D куби, що приймаються трьохмірною архітектурою 3D U-net у якості тренувальних даних. Сам алгоритм виглядає наступним чином:

- Вручну переглянуто список з 3200 зображень і відібрано список з 800 об'єктів;
- Обрано зразок зі списку маркованих зображень і до нього застосовано функцію нормалізації через те що оригінальні дані походили з різних синтетичних моделей, що мали різні діапазони позитивних і негативних значень і так само як для 2D мережі потребували нормалізації;
- Створено порожню матрицю розміром 128X128x128 пікселів і задано розрядність даних в 16 біт. Форматування під розрядність в 16 біт дозволяє збільшити вертикальну вісь за рахунок зменшення споживання пам'яті;
- 3D об'єм містить набагато більше інформації ніж 2D зображення, а значить для обробки пакету зображень і синтетичних псевдо 3D кубів останні треба фізично зменшити у розмірі для того щоб об'єму відеокарти ПК вистачило для обробки збільшеного обсягу даних. У зв'язку з різницею розмірів зображення похідного 2D файлу і цільового 3D об'єму, обирається центральна частина обраного 2D зображення для обрізки за заданим розміром (128x128), тобто 64 пікселя по контуру відкидається з кожного зображення, що трансформується (рис. 3.1);

- В створену матрицю імпортуються дані з 2D зображення із заданням динамічних змін для імітації розвитку геологічних відбиттів в реальних наборах 3D даних;

- Імітація виконується за допомогою біноміального закону розподілу випадкової величини, генеруються події в напрямку інлайну з обов'язковим обмеженням дистанції зміни або зсуву події не більше 1 пікселя. На практиці виявилось що зміни більші за 1 піксель генерують події, подібні до диз'юнктивних порушень, що погіршує якість прогнозу моделі;

- Для рівномірного навчання моделі за інлайн та крослайн напрямками, виконується довільне обертання напрямку генерації подій в 3D об'ємах;




Рисунок 3.1. Схематичне зображення формування псевдо 3D об'єму з двомірних зображень.

У випадку тренування 2D мережі ШІ є пряма можливість застосувати весь набір вхідних даних, тобто по 3200 2D зображень сейсмічних даних високої і низької розрізної здатностей, що відповідало критеріям достатності кількості даних для тренування моделі. Для 3D мережі постає необхідність трансформації цих 2D даних у псевдо 3D, що суттєво збільшує кількість розрахункових даних, навантаження на відеокарту, а відтак – для стабільної роботи програмного забезпечення необхідно і провести трансформацію даних, і відібрати з існуючого набору даних найбільш представницькі зразки. У якості критерія відбору було обрано геологічну різноманітність – наявність антикліналей, синкліналей, грабенів, тощо; додатковий критерій відбору – наявність порушень різної

геометрії. Концентрація на різноманітності геологічних обставин зробить модель різноманітнішою, а відтак – вона може бути застосована до більшої кількості родовищ, що мають відмінності в геологічній будові.

Кількісно було обрано 500 зображень з 3200 вхідних файлів із наступних міркувань достатності: 1 куб через свою трьохмірну природу містить в 32 рази більше інформації ніж зображення, тому нейронна мережа потребує менше вхідних кубів ніж зображень, що є однією із переваг 3D варіанту. Один псевдо 3D об'єм – це 128 згенерованих зображень, що з точки зору розмірності були обрізані двічі по кожній осі по відношенню до початкових 2D зображень, і зібраних в єдиний об'єм.

Таким чином, для побудови двох варіантів моделі НМ збережено два набори даних – оригінальні 2D зображення, та згенеровані на їх основі псевдо 3D об'єми.

3.2 Заходи стосовно аугментації тренувального набору даних, що внесли суттєвий вплив на якість прогнозу моделі

На додаток до заходів стосовно відбору найбільш представницьких зображень, було проведено ще ряд заходів аугментаційного характеру, які позитивно вплинули на якість прогнозу моделі.

Виконана робота носила ітераційний характер, суттєву частину якого займав аналіз результатів роботи моделі, пошук відповідей на питання виникнення тієї чи іншої похибки, а також аналіз варіантів її вирішення. Серед проблем, які мають найбільший вплив на роботу моделі (після оптимізації функції втрат та архітектури моделі) можна зосередитись на двох рисах хвильового поля.

Першою слід вважати наявність артефактів, що утворюються при мігруванні польових сейсмічних даних, навіть з відносно продвинутим алгоритмом міграції, у вказаному прикладі (рис. 3.2) – це PostSTM міграція.




Рисунок 3.2. Приклад роботи моделі ІІІ (зліва) та вхідних сейсмічних матеріалів (справа) з артефактами обробки польових даних.

На рисунку зони недосконалої обробки відмічені овальними позначками. Дані аномалії мають комбінований характер походження – здебільшого це зони більш тонкого перешарування відкладів, які через обмеження, що вносяться розрізняювальною здатністю вхідних матеріалів не можуть бути повністю відображеними. Певний шаблон перешарування утім зберігається, і в залежності від типу обробки він може бути більш, або менш вираженим. Нажаль, на ранніх етапах роботи дані аномалії не мали відображення в наборах навчальних та перевірочних даних, тому модель напряду їх переносила в результат своєї роботи без доопрацювання.

Вирішення цієї проблеми полягало у внесенні в тренувальний набір даних низької якості зон із розмиттям (рис. 3.3):




Рисунок 3.3. Код та графічне втілення зон розмиття.

Алгоритмічно задача (рис. 3.3, А) полягала в використанні вбудованої в бібліотеку *open cv* функції *GaussianBlur*, що застосовує гауссове розмиття в зоні виклику і формування маски, яка складається з пустого масиву і круга що дорівнює радіусу функції гаусового розмиття, що заповнена одиницями. За допомогою стандартної функції *np.where* виконується комбінування оригінального та розмитого зображень (рис. 3.3, Б). У якості контрагента в процес тренування моделі завантажується чисте зображення високої розрізненості без нанесеного розмиття і далі відбувається навчання, результат якого зображено на останньому фрагменті рисунка 3.3, Г.

Іншою суттєвою проблемою був той факт, що абсолютна більшість зображень, які містяться у вхідному наборі даних, має субгоризонтальне нашарування. Так, це – найпоширеніший варіант залягання гірських порід, але це також означає той факт, що модель матиме тренд до «горизонтального» нашарування і там де це не відповідатиме актуальній геологічній картині, прогноз буде погіршувати якість даних, роблячи картину менш витриманою і логічною саме з геологічної точки зору. На рисунку 3.4 зображено саме такий

приклад – оригінальні сейсмічні дані (рис. 3.4, А) виглядають набагато логічнішими ніж прогноз моделі (рис. 3.4, Б)




Рисунок 3.4. Поведінка ранніх ітерацій моделі в умовах похилого налягання гірських порід.

З огляду на обмежений розмір зображення і матриці прогнозу моделі, що базуватиметься на ньому, ввести повний проворот зображення не є рішенням поставленої задачі. Було прийнято рішення стосовно додаткової зміни вхідних зображень шляхом додавання маски, в межах якої буде відбуватись частковий проворот зображення. Реалізація функції застосовуватиметься до пари пов'язаних зображень – низької і високої розрізної здатностей. Функція зображена на рис.3.5, А. В її реалізації також використовується пакет *open cv*, а саме його вбудована функція *warpAffine*, що застосовує афінні перетравлення в нашому випадку до матриці повертання з кутом 30 градусів. окремо слід зазначити що цифра в 30 градусів – це певний компроміс, який в даному випадку було прийнято суто з міркувань отримання користі від моделі. В ДДЗ, в межах кубів, що опрацьовувались автором, існувала певна кількість ситуацій, де кут нахилу гірських порід суттєво перевищував 30 градусів, всі ці випадки були пов'язані з галокінезом. Автор свідомо відмовився від можливості покриття подібних геологічних обставин базуючись на тому що алгоритми міграції далеко

не завжди якісно сумують сигнал уздовж рефлектора, що різко змінює свій кут падіння, а тому навряд чи продукуватимуть якісні тренди, які модель ШІ може підхопити і покращити. На додаток до того, з наближенням до ніжки соляного штока зростає кількість відбитих хвиль від козирка, що суттєво спотворює хвильову картину. Таким чином, свідомо обмежуючи кут можливого нахилу гірських порід в прогнозі моделі, робиться крок в напрямку структурного фактору, не пов'язаного з галокінезом. Рисунок 3.5 Б – Г зображує послідовні етапи накладання маски провороту зображення, де Б – вхідне зображення низької якості, В – маска провороту, Г – вхідне зображення низької якості, в яке у вікні було додано маску провороту.




Рисунок 3.5. Код функції та послідовні етапи накладання елемента провороту зображення.

На рисунку 3.6 зображено ту саму ділянку сейсмічного куба, що і на малюнку 3.5, проте вже із застосуванням покращеного алгоритму аугментації вхідних зображень, що були використані під час тренування моделі.




Рисунок 3.6. Різниця прогнозу моделі з використанням кутової маски.

Таким чином, застосування елементів наближення тренувального набору даних до реальних геологічних обставин суттєво покращило прогнозні здатності моделі.

3.3 Зміни в компоновці моделі штучного інтелекту при переході з 2D до 3D U-net архітектури

Під час побудови моделі із 3D архітектурою було додано досить велику кількість змін як в саму модель, так і у функції втрат. Суттєва частина введених змін була покликана необхідністю економії обчислювальних ресурсів ПК для збереження самої можливості провести обчислення.

Одним із доданих елементів на цьому етапі – був клас дата генератора (рис 3.7)

```

1 class DataGenerator(tf.keras.utils.Sequence):
2     'Generates data for keras'
3     def __init__(self, dpath, fpath, data_IDs, batch_size=1,
4                 dim=(SIZE_I, SIZE_X, SIZE_D),
5                 n_channels=1, shuffle=True, fraction=1.00):
6         'Initialization'
7         self.dim = dim
8         self.dpath = dpath
9         self.fpath = fpath
10        self.batch_size = batch_size
11        self.data_IDs = data_IDs
12        self.n_channels = n_channels
13        self.shuffle = shuffle
14        self.fraction = fraction
15        self.on_epoch_end()
16
17
18    def __len__(self):
19        'Denotes the number of batches per epoch'
20        return int(np.floor((len(self.data_IDs) * self.fraction)/self.batch_size))
21
22    def __getitem__(self, index):
23        'Generates one batch of data'
24        # Generate indexes of the batch
25        bsize = self.batch_size
26        indexes = self.indexes[index*bsize:(index+1)*bsize]
27
28        # Find list of IDs
29        data_IDs_temp = [f"{self.data_IDs[k]:04d}" for k in indexes]
30
31        # Generate data
32        X, Y = self.__data_generation(data_IDs_temp)
33
34        return X, Y
35
36
37    def goTrain(model):
38        # input image dimensions
39        params = {'batch_size':1,
40                'dim':(SIZE_I, SIZE_X, SIZE_D),
41                'n_channels':1,
42                'shuffle': True}
43
44        Low_path_train = basic_path+ 'Low_Res\\'
45        High_path_train = basic_path+ 'High_Res\\'
46
47        Low_path_val = basic_path+ 'Low_Res_val\\'
48        High_path_val = basic_path+ 'High_Res_val\\'
49        train_ID = ID_list_train
50        valid_ID = ID_list_val
51
52        train_generator = DataGenerator(dpath=Low_path_train,fpath=High_path_train,
53                                     data_IDs=train_ID,**params)
54        valid_generator = DataGenerator(dpath=Low_path_val,fpath=High_path_val,
55                                     data_IDs=valid_ID,**params)
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71

```

Рисунок 3.7 Опис класу дата генератора та його застосування.

Цей доданий механізм на ходу формує псевдо 3D куби і надсилає їх в процес тренування моделі. Маючи в своїй будові обмежувач у вигляді змінної `batch_size`, можна адаптувати кількість наданих до тренування кубів в залежності від обчислювальних можливостей ПК, на якому виконуються обрахунки.

Іншим елементом, що було використано в побудові моделі – застосування технології (політики) `mixed precision` (рис. 3.8). Політика `mixed precision` є потужним підходом, який широко застосовується в середовищі Python, зокрема у високопродуктивних обчисленнях, машинному навчанні та глибокому навчанні. Ця техніка дозволяє оптимізувати обчислення, комбінуючи використання чисел з одинарною точністю (32 біта) та з половинною точністю (16 біт), що сприяє підвищенню ефективності та зменшенню витрат ресурсів.

Основна ідея `mixed precision` полягає в тому, щоб виконувати менш критичні обчислення, які не суттєво впливають на кінцевий результат, з половинною точністю (`float16`). У той же час критично важливі операції, які вимагають високої точності, виконуються з одинарною точністю (`float32`). Такий підхід забезпечує баланс між швидкістю обчислень і точністю результатів. Застосування `mixed precision` має значні переваги. По-перше, це дозволяє економити пам'ять на графічних процесорах (GPU), оскільки числа з половинною точністю займають удвічі менше місця, ніж числа з одинарною точністю. По-друге, це прискорює обчислення, оскільки багато сучасних GPU мають апаратну підтримку `float16`, що дозволяє виконувати операції швидше. Зрештою, це дає змогу використовувати більші моделі або обробляти більші набори даних за допомогою потужностей того самого обладнання.

```

1 policy = mixed_precision.Policy('mixed_float16')
2 mixed_precision.set_global_policy(policy)

1 optimizer = tf.keras.optimizers.Adam(learning_rate = 0.0001)
2 optimizer = mixed_precision.LossScaleOptimizer(optimizer)

[ ] 1 model.compile(optimizer = mixed_precision.LossScaleOptimizer(tf.keras.optimizers.Adam(learning_rate = 0.0001)),
    2         loss = mixed_loss, #tf_ms_ssim_loss, #tf_ssim_loss, #PSNR_loss_v3, #
    3         metrics = [tf_ssim, pixel_mse_loss, PSNR_loss_v3, tf_ms_ssim_loss, mixed_loss])

```

Рисунок 3.8. Декларація та застосування `mixed precision`

В даному випадку `mixed precision` реалізується через бібліотеку TensorFlow. Вона надає інструменти автоматичного налаштування обчислень для роботи з `mixed precision`.

У випадку створеної моделі критично важливим є збереження градієнту функції втрат при обрахунках моделі, а от беручи до уваги виконані заходи з нормалізації вхідних даних і зрізання екстремальних значень спектру, 16 біт формату вистачає для отримання якісних активаційних карт на кожному слої моделі.

Під час побудови моделі, емпірично було підібрано розмір куба, який є аналогом вікна прогнозу оригінального набору даних в 2D варіанті мережі. Якщо там вікно прогнозу становило 256x256 пікселів, що давало досить непогану прогнозу площу, що покривала суттєву площу розрізу, то із залученням більшої кількості даних в 3D варіанті, максимальний об'єм, що міг бути обрахований із залученням усіх вищепойменованих заходів з економії обрахункових можливостей – 64x64x64. Слід відмітити, що через те, що всі розрахунки ведуться на потужностях GPU, які для робочої машини автора становлять 32ГБ, ряд змін довелось вводити як в функцію втрат, так і в структуру моделі.

Та частина функції втрат, що відповідає за збереження просторових компонентів зображення, SSIM, була змінена в кількості масштабних рівнів і, відповідно, їх вагових складових (рис. 3.9). Кількість масштабних рівнів, в свою чергу, напрямку залежить від розміру ядра або вікна прогнозу, до якого вони будуть застосовуватись.

Іншим питанням, що підбирався ітеративно – був розмір кернелу (зерна) прогнозу. Розмір `kernel` був підібраний таким чином, щоб дозволити нейронній мережі з одного боку охоплювати більші патерни нашарування, з іншого боку вмістити модель у наявний обсяг пам'яті. Беручи до уваги вертикальність більшості патернів, `kernel` має збільшену глибину і урізану горизонтальну

розмірність. Під час ітеративного підбору ядра було випробувано ряд варіантів, частину з яких зображено на рисунку 3.10.




Рисунок 3.9. Порівняння змін в функції втрат SSIM для 2D і 3D варіантів мережі




Рисунок 3.10 Графіки об'єднаної функції втрат та статистика параметрів тренування моделей з різним kernel.

В результаті ітеративного підбору гіперпараметрів моделі вдалось отримати оптимальне рішення для потужностей домашнього ПК. Результати підбору зерна прогнозу представлено у таблиці 3.1.

Таблиця 3.1. Результати тренування моделей з різни розміром зерна прогнозу.

Ядро прогнозу	Loss	Pixel MSE	PSNR	MS_SSIM
9x9x3 основа 32	0,0377	0,0192	-46,5597	-0,95
Кількість тренуємих параметрів 52 512 769				
3x3x9 основа 34	0,0401	0,0199	-46,2830	-0,9465
Кількість тренуємих параметрів 19 761 481				
7x7x3 основа 32	0,0346	0,0178	-47,2665	-0,9542
Кількість тренуємих параметрів 31 767 553				
8x8x3 основа 32	0,0363	0,0185	-46,9464	-0,9518
Кількість тренуємих параметрів 41 491 873				
6x6x3 основа 32	0,0414	0,0207	-45,9199	-0,9447
Кількість тренуємих параметрів 23 339 809				

Нажаль, не зважаючи на високі показники статистики якості прогнозу моделі, з точки зору кінцевого користувача, тобто інтерпретатора сейсмічних даних, результат не виглядав як суттєве покращення – бо шум зменшувався в зонах, де його кількість і так не була критично великою, натомість в протяжних зашумлених зонах результат прогнозу моделі не радикально відрізнявся від похідного сейсмічного матеріалу. На рисунку 3.11 зображено порівняння оригінальних сейсмічних даних (А) і прогнозних (Б), де червоною зоною виділено зашумлену ділянку, що потребує покращення.




Рисунок 3.11. Порівняння оригінальних (А) і прогнозних даних (Б)

Аналіз ситуації, що склалася, привів до розуміння що для покращення роботи моделі не існує іншого підходу як збільшити вікно прогнозу, збільшивши розмір псевдо 3D кубів з 64x64x64 до 128x128x128. Тренування такої моделі 3D U-net вимагає покращених розрахункових потужностей і більш сучасних графічних процесорів з більшим обсягом пам'яті графічного процесора (VRAM) і власне розрахунковою потужністю (TFlops), що перевищує можливості домашнього ПК. Як вирішення цієї проблеми, для навчання моделі були використані орендовані віртуальні машини на **vast.ai**, що відповідають цим вимогам.

3.4. Застосування моделі 3D U-net до реальних даних.

Застосування моделі з більшим вікном прогнозу, достатнім для захоплення геологічного контексту поза зоною зашумлення хоча і має показники навчання

моделі тотожні до попередніх варіантів реалізації, проте суттєво покращує якість опрацьованих сейсмічних матеріалів з точки зору їх доданої вартості до процесу сейсмічної інтерпретації, на чому варто окремо зацентувати увагу.

Як було описано в другому розділі, діапазон значень прогнозу моделі залежить від загальної активаційної функції (в даному випадку це тангенс) і становить від -1 до +1. Таким чином, в результаті прогнозу моделі отримується 3D матриця даних, яка містять максимальний контраст (рис. 3.12, 2) і дуже відрізняється від похідних даних (рис. 3.12, 1).




Рисунок 3.12 Виводи діапазонів значень розрахованих матриць для різних стадій нормалізаційно-денормалізаційного процесу.

Сама ця матриця, безумовно, теж може бути конвертована в *.SEGY формат бути використана в процесі інтерпретації. Відсутність контрасту, з одного боку, запобігає її використанню в виділенні тих чи інших сейсмічних атрибутів, пов'язаних з частотою або амплітудою, проте вона вкрай чутлива до просторових атрибутів – таких як кути нахилу порід, а також групи атрибутів, скеровані на виділення порушень (edge detection, variance, chaos, etc), що робить

її також ціним вхідним матеріалом для побудови моделі площі осадконакопичення.

Іншим аспектом, на який слід звернути увагу – діапазон значень вхідної матриці (рис. 3.12, 1), тобто поданого на обчислення оригінального мігрованого куба. Амплітудні значення не чітко центровані навколо 0, що, після процесу нормалізації, починає відрізняти оригінальний і опрацьований куби (рис. 3.12, 3). Маючи зміщений діапазон значень, аномалії, що були оригінально прокартовані в межах похідного матеріалу, хоча і матимуть подібну геометрію за виключенням зон непевненого трасування, проте матимуть різницю діапазонів значень, що для досліджень на кшталт спектральної декомпозиції матиме вкрай високе значення, аж до необхідності переобрахунку частот, що підлягають виділенню.

Таким чином, застосовуючи модель до оригінальних мігрованих даних, можна отримати ряд похідних матеріалів зі збільшеною розрізнявальною здатністю і інтпретаційною вартістю (рис. 3.13).




Рисунок 3.13 Розріз сейсмічного куба до і після опрацювання моделлю III і відтворення діапазону значень.

3.5 Висновки

В третьому розділі було сконцентровано увагу на заходах, що були необхідні для переносу мережі штучного інтелекту на архітектуру 3D U-net. При цьому значна кількість зусиль була сконцентрована навколо питання оптимізації роботи моделі та можливих заходів зі збереження максимально-можливого вікна прогнозу. Для цього були залучені як апаратно-прописані заходи (політика змішаної точності), так і зміни в компоновку самої моделі та функції втрат.

Класична архітектура U-net використовується для покращення якості зображень, що очікує виділення складних геометричних форм. У випадку розробленої моделі експериментально доведено, що 4 шар не дає росту якості прогнозу, натомість використовує ресурси GPU. Для 2D конволюційна згортка йде за розмірами 256-128-64-32 пікселів, а для 3D U-net згортка починається зі 128-64-32 і таким чином, через зменшений розмір вікна прогнозу моделі 4 шар було відкинуто. На додаток до того, саме завдання зменшення шумів не передполагає виділення складних геометричних форм, тому додатковий шар моделі, прийнятий у стандарті архітектури тут зайвий.

При використанні моделі збільшення розрізної здатності найбільшою перешкодою є апаратні обмеження, що змушують зменшити зерно прогнозу і сам розмір вікна прогнозу. Проблема полягає в тому, що якщо зашумлена зона похідного сейсмічного матеріалу більша за вікно прогнозу моделі, то модель фізично не має якісних даних, які вона може розповсюдити (див. рис. 3.11), таким чином, єдиний доступний варіант розрахувати модель, що має практичну цінність через збільшене вікно прогнозу – використати потужні можливості обчислювальних центрів.

З огляду на необхідність залучати послуги дата-центру для проведення обчислень, оновлення ваг моделі також вимагає або залучення подібного центру, або спеціалізованих кластерів обчислювання, що існують в

«Укргазвидобуванні», проте мають свій лімітований час доступу через зайнятість поточними розрахунковими процесами. Застосування вже тренованої моделі до будь-якого мігрованого сейсмічного матеріалу, з іншого боку, хоча і є ресурсоємкою задачею, але в цьому випадку навантаження падає більше на жорсткий диск і операційну пам'ять, що робить пошук ПК для цієї задачі значно легшою задачею.

Використання моделі штучного інтелекту успішно вирішує питання збільшення роздільної здатності і збільшення співвідношення сигнал/завада для значної кількості родовищ ДДЗ. Проте варто приймати запропоновану модель як базовий варіант – тобто за певну точку відліку на шляху покращення мігрованих сейсмічних даних. Справа полягає в тому, що синтетичний набір вхідних даних для тренування моделі хоча і має велику кількість змодельованих геологічних обставин, проте не може підходити під абсолютно усі можливі випадки геологічних обставин. Для цього пропонується використання технології донавчання, яка базується на наступному підході:

- 1) мігрований сейсмічний куб обробляється за допомогою базової моделі;
- 2) результат обробки передається в геологічний департамент для ознайомлення, картування основних структурних поверхонь, проведення тематичних досліджень;
- 3) за результатами звіту з геологічного департаменту виділяються зони, що потребують доопрацювання. Подібна ситуація можлива для ділянок хвильового поля, що не були представлені в наборі тренувальних даних для моделі;
- 4) створюються синтетичні пари зображень, що містять умови, описані в звіті геологічного департаменту і модель дотреновується на нових даних;
- 5) результат переобробки передається в геологічний департамент для закінчення тематичних досліджень;

Серед різноманіття сейсмічного матеріалу, автору досліджень було надано можливість використовувати для перевірки якості моделі лише окремі 2D

профілі і сейсмічні куби, які оброблялись ним в ході виконання службових обов'язків і територіально вони належали до ДДЗ. З огляду на різноманіття геолого-геофізичних умов, використання моделі для Чорноморського або Прикарпатського нафтогазоносних регіонів потребує ревізії і оновлення тренувального набору даних, навіть в контексті створення базової моделі.

РОЗДІЛ 4. ПОБУДОВА МЕРЕЖІ ШТУЧНОГО ІНТЕЛЕКТУ ПРОСТОЇ АРХІТЕКТУРИ ДЛЯ ВИРІШЕННЯ ОБЕРНЕНИХ ЗАДАЧ ПІДВИЩЕННЯ ВЕРТИКАЛЬНОЇ РОЗРІЗНЕНОЇ ЗДАТНОСТІ ЕЛЕКТРИЧНОГО ТА ІНДУКЦІЙНОГО КАРОТАЖУ.

4.1 Особливості застосування нейронних мереж для збільшення вертикальної розрізненої здатності електричного та індукційного каротажу нефокусованими зондами


Важливою складовою процесу побудови моделі осадконакопичення площі досліджень є побудова петрофізичної моделі, виділення літотипів, а також простеження динаміки змін швидкості осадконакопичення, яку зазвичай простежують або за допомогою гамма-каротажу або за допомогою електричного та індукційного типів каротажних досліджень.

Існує багато типів класифікацій обставин осадконакопичення, що поділяються спираючись на форму вищепойменованих кривих і досить детально приведено вертикальну і латеральну послідовність їх чередування в залежності від положення лінії узбережжя, що детально досліджується під час побудови сіквенс-стратиграфічної моделі родовища.

Для Комишнянської площі після знаходження меж парасіквенсів в каротажних даних і їх латерального трасування за допомогою сейсмічних даних, постало питання більш детальних досліджень в зоні інтересу, а саме – виділеної в зоні сейсмічного покриття ділянки активної зміни умов осадконакопичення в інтервалі продуктивного горизонту В-17, що пов'язані зі змінами напрямку седиментації і можуть розглядатись як додаткові пошукові об'єкти (рис. 4.1)

Нажаль, при деталізованих пошукових роботах частою є проблема накладання відбиттів від суміжних пластів, що спотворюють розріз. На додаток питання досягнення максимально можливої вертикальної розрізненої здатності каротажних даних напряду впливає на можливість розв'язання нестійкої

оберненої задачі для електричного та індукційного типів каротажів, що у випадку використання несфокусованих зондів вимагає додаткової математичної



обробки прийнятого матеріалу.

Рисунок 4.1 Виділення зони зміни седиментації за сейсмічними атрибутами.

Для вирішення подібних задач, автор надавав допомогу щодо збору і підготуванні наборів даних для навчань моделей ШІ, які були розроблені керівником поточної роботи, доктором фіз.-мат наук Миронцовим М.Л [96].

Розв’язання більшості математичних обернених задач стикається з проблемою стійкості. Обернені задачі електрометрії не є виключенням [97]. Роздивимось задачу встановлення електричного питомого опору (ПО) пласта скінченної товщини, який є частиною розрізу, розкритого вертикальною свердловиною. На рис. 4.2 наведено порівняння заданого ПО та виміряного, притаманні умовам Дніпровсько-Донецької западини [98].

Зрозуміло, що на вимір ПО, так званого уявного ПО (УО) $\tilde{\rho}(z)$ в окремо взятій точці з координатою z (глибина по вісі свердловини в циліндричній системі координат) будуть впливати значення ПО в деякому оточенні точки виміру співставному з довжиною зонда. Миронцовим М.Л. було створено підхід, який нівелює вплив сусідніх пластів на визначення геоелектричних параметрів досліджуваного за допомогою використання нейронних мереж НМ простої архітектури.




Рисунок 4.2 А -Зонд ІК1.25, Б - Зонд А2.0М0.5N. Шифр кривих: 1 – заданий ПО, 2 – виміряний УО, 3 – відновлений ПО.

Для задачі низькочастотного індукційного каротажу (ІК) електрична питома провідність (ПП) σ та уявна ПП (УП) $\tilde{\sigma}$ (обернені до ПО та УО величини) зв'язані рівнянням:

$$\tilde{\sigma}(z) = \int g(z - z')\sigma(z')dz', \text{ де} \quad (4.1)$$

де g так званий геометричний фактор зонда [99]. Задача розв'язання такого рівняння Фредгольма першого роду згорткового типу є все одно некоректно поставленою за Адамаром і, відповідно, нестійкою [97]. Цільові значення ПП визначаються через виміряні значення УП, які в свою чергу залежать від значень ПП на певному інтервалі, що визначається видом функції g . Отже на визначення величини ПП в певній точці впливають значення виміру в оточуючих. Це явище і називають «Shoulder effect».

Задача електричного каротажу (ЕК) є взагалі нелінійною і не має інтегрального опису типу наведеного рівняння, але Shoulder effect в ній також присутній.

Приведення способу знаходження стійкого розв'язання задачі встановлення ПО за даними виміру УО для ІК та ЕК.

В обох випадках метою пошуку є значення саме ПО (оскільки ПО і ПП пов'язані як

$$\sigma [{}^m C_m / m] = 1000 / \rho [1000 / O_m \cdot m]. \quad (4.2)$$

Для обох задач необхідно вирішити задачу знаходження ρ_i в кожній точці z_i деякого інтервалу якщо нам відомі :

$$\tilde{\rho}_{z_i}(\rho_{z_{i-m}}, \dots, \rho_{z_i}, \dots, \rho_{z_{i+m}}), \text{де} \quad (4.3)$$

індекси координати – номери впорядкованої множини точок виміру, бо вимір вздовж свердловини не є неперервним і виконується з дискретним кроком Δz . Тобто ми використовуємо апроксимаційну модель, де ПО є кусково-неперервною функцією вздовж свердловини і в межах кожного інтервалу товщиною Δz значення ПО не змінюються.

Фактично вищенаведена формула означає, що пряма задача є пошуком відображення значень ПО в одне значення УО. Проте необхідно встановити інше відображення (обернене):

$$\tilde{\rho}_{z_{i-m}}, \dots, \tilde{\rho}_{z_i}, \dots, \tilde{\rho}_{z_{i+m}} \rightarrow \rho_{z_i}. \quad (4.4)$$

Використано такий вид в'язку для навчання НМ із зворотним розповсюдженням помилки [100]. За відомими значеннями УО на деякому інтервалі $(2m + 1) \cdot \Delta z$ нам необхідно визначити ПО в його центрі.

Для кожного окремого прикладу моделюються криві УО для інтервалу свердловинного розрізу, який складається із послідовності пластів ПО яких задаємо як постійну в межах кожного пласта, але випадкову (random) величину

для кожного з них. Якщо ПО сусідніх пластів визначених таким чином співпадають, то ми фактично маємо один пласт постійного ПО але в два рази більшої товщини. Тобто заданому інтервалу відомого розподілу ПО чи ПП ми співставляємо одне точкове значення виміру зондом (УО чи УП), в точці, що відповідає так званій «точці запису».

Отже величина ПО кожного з пластів обраного інтервалу буде змінюватись випадковим чином для кожного прикладу навчання НМ в межах діапазону значень ПО для родовища в якому проводиться геофізичне дослідження свердловин (рис. 4, 2 крива 1 – «заданий ПО»).

В якості функції активації всіх нейронів НМ буде використана сигмоїд. Вибір сигмоїди зумовлений необхідністю неперервної диференційованості функції активації для використання методу зворотного розповсюдження похибки. Відповідно враховуючі обмежений інтервал можливих значень сигмоїди перед процесом навчання необхідно провести процедуру нормалізації вхідних даних (значення УО) та денормалізації для вихідних (значення ПО).

Для вирішення поставленої задачі було обрано наступні параметри НМ: двошарова, функція активації – сигмоїд, крок навчання 0.5, кількість епох обмежена параметром **patience**, який контролює коливання зміни функції втрат і при досягненні значення меншого за **learning rate**, силоміць прериває тренування. Кількість прикладів навчання складала 100000 (і для задач ІК і для задач ЕК).

Згідно стандартів перевірки якості результатів навчання НМ використовується перевірочний (валідаційний) набір даних, які не були присутні в навчальній вибірці даних і таким чином виконується порівняння прогнозу моделі і очікуваного результату.

Розглянемо приклад вирішення подібної задачі для ІК. Відповідно до значення довжини інтервалу (12.1 м) на якому обраховувались дані для прикладів навчання НМ та величини кроку запису (0.1 м) кількість вхідних даних НМ дорівнює 121, кількість нейронів у першому прихованому шарі 20, кількість нейронів у другому прихованому шарі (відповідає кількості вихідних сигналів) –

1. Тобто внутрішні зв'язки пов'язують: шар вхідних даних і перший прихований шар та перший і другий приховані шари. Значення на виході другого прихованого шару є значенням вихідного сигналу НМ.

На рис. 4,2 А наведені результати для зонда ІІ.25, де цифра означає відстань між генераторною та приймальною котушками і таким чином вона визначає вертикальну розрізняльну здатність методу.

Виявилось, що для товщини пластів 1 метр (менше довжини зонда) ПО за запропонованим способом встановлюється майже ідеально з точки зору загально прийнятих вимог ГДС (визначення границь кожного пласта, визначення значення його ПО з похибкою не більше 10%).

Для прикладу з ЕК (крок запису 0.05 м) довжина інтервалу на якому обраховувались дані для прикладів навчання НМ дорівнювала 10.05 м. Отже кількість вхідних сигналів дорівнює 201. Було обрано кількість нейронів першого прихованого шару 30, другого 1.

На рис. рис. 4,2 Б наведено результати для нашарування пластів товщиною 2,5 м для відомого зонда А2М0.5N (перша цифра – відстань між струмовим електродом і першим вимірювальним, друга цифра – відстань між вимірювальним електродами), який входить в комплекс стандартної електрометрії свердловин, що використовують в Україні [97].

Для товщини пластів 2.5 м. границі кожного з них визначаються точно проте визначати ПО не виявилось можливим навіть якісно.

Таким чином встановлюючи вертикальний профіль ПО для кожного зонда багатозондового комплексу ми можемо встановлювати і його радіальний розподіл з точністю, що відповідає точності запропонованого способу.

Оскільки використання НМ є по суті методом апроксимації, то маючи дуже різноманітний базис навчання за допомогою random було створено надійний спосіб апроксимації. Оскільки в базисі у нас не було прикладів розв'язання прямої задачі нестійких розв'язків, то і такий розв'язок вже оберненої задачі виявився стійким.

Більша точність встановлення вертикального профілю для задач ІК ніж для задач ЕК є наслідком більш точного якісного співпадіння кривих виміру з кривими ПО, який підлягав відновленню, проте досягнута точність встановлення ПО пластів співставних з двома довжинами зондів є більш ніж високою.

4.2 Опис моделі досліджуваного пласта-колектора та особливості будови моделі НМ для визначення радіального питомого опору.

В якості моделі досліджуваного пласта-колектора прийнято розглядати так звану п'ятишарову модель [101, 102], яка зображена на рис.4.3, А. Це аксиальносиметрична модель в якій шари по віддаленню від вісі симетрії (вісі свердловини) розташовуються наступним чином: перший шар - сама свердловина; другий шар - глиняна корка; третій шар – промита зона буровим розчином (промита зона); четвертий шар – перехідна зона; пятий шар – зона неушкоджена проникненням фільтрата бурового розчину (власне пласт). Але в більшості реальних умов, в тому числі притаманних Дніпровсько-Донецькій западині [98], розглядають тришарову модель (рис. 4.3, Б). В ній зона проникнення бурового розчину та перехідна зона об'єднані в одну, а глиняною кіркою нехтують для методів ЕК та ІК.





Рисунок 4.3 П'ятишарова (А) і тришарова (Б) моделі пласта-колектора

Діаметр свердловини і питомий опір (ПО) бурового розчину вважаються відомими величинами, що не звужує можливостей методу застосування моделі ІІІ, якщо в якості зондуючої системи буде використовуватись комплекс який має більше лінійно незалежних вимірів ніж кількість встановлюваних параметрів моделі.


Отже у випадку вертикальних свердловин необхідно вирішити задачу визначення розподілу ПО вздовж пласта обмеженої товщини, що для тришарової моделі означає встановлення параметрів $(\rho_B, \rho_Z, D/d)$. Але для пластів скінченної товщини присутній значний ефект впливу на вимір значень ПО сусідніх із досліджуваним пластом (рис. 4.4). Це значно ускладнює першу задачу. Тобто у випадку нашарування пластів обмеженої товщини співставної або меншої ніж зонди комплексу, до розв'язання надходить двовимірна задача. Для її спрощення використовують наступний підхід: одну двовимірну задачу розділяють на дві одновимірні – вздовж свердловини і вздовж кожного пласта. Перша задача має на меті максимально нівелювати вплив сусідніх пластів на вимір у досліджуваному таким чином щоби виміри навпроти нього можна було вважати такими ніби пласт має нескінченну товщину. По аналогії з методом розділення змінних при розв'язанні задач диференційних рівнянь у часткових похідних такий метод називають факторизацією.

Отже спочатку для кожного з досліджуваних пластів мінімілізується вплив shoulder effect, а потім для кожного пласта визначається його радіальні геоелектричні параметри в припущенні, що він має нескінченну потужність і сусідні пласти не впливають вже на вимір УО навпроти нього. Для розв'язання цієї задачі можна ефективно використовувати: для ІК як метод регуляризації так і використовувати НМЗРП, для задач ЕК – використовувати НМЗРП.



Зонд IL1.25

А



Зонд EL A2.0M0.5N

Б

Рисунок 4.4. Вимір значень ПО для різних зондів. Умовні позначення: 1 – оригінальний ПО, 2 – виміряний УО, 3 – прогнозований ПО

Приклади використання НМЗРП наведено на рис. 4.4 для відомої апаратури ЕК (зонд А2.0М0.5М) та ІК (зонд ІЛ1.25) [105]. Таке використання дозволяє встановити вертикальну розрізняльну здатність розв’язання задачі в цілому. При цьому за використання НМЗРП для задач ЕК і ІК використовувались мережі простої архітектури з двома прихованими шарами [103].

Отже коли задача встановлення ПО вздовж вісі свердловини вважається вирішеною (для кожного зонда багатозондового комплексу) необхідно встановити радіальні параметри кожного пласта. Для цього буде використано НМЗРП.

Спочатку необхідно підготувати масив прикладів для навчання моделі. Кожен приклад буде співставленням вхідних даних (що ми подаємо у НМ) і вихідних даних (що ми очікуємо отримати як результат розв’язання).

Такий масив буде складатись із двох частин. Перша (більша) – навчальна, яка буде використовуватись саме для навчання; друга (менша) – валідаційна, яка буде використовуватись для верифікації НМ. Для побудови такого масиву для

всього можливого діапазону значень параметрів $\rho_B, \rho_Z, D/d$ будемо таблицю (табл. 4.1) в якій кожна стрічка буде відповідати кожному прикладу з масиву навчання (ρ_i – УО кожного зонду багатозондового комплексу). Для побудови таблиці багатократно вирішувалась пряма задача за допомогою точного методу математичного моделювання [104].

Таблиця 4.1. Структура тренувального набору для побудови НМ.

ρ_Z	ρ_B	D/d	ρ_1	ρ_2	ρ_3	ρ_4	.
...	...	.	...	...	...	...	.
6,6 0693	0,2 884	6	4,0 0596	6,2 271	3,5 3237	0,6 4761	.
6,6 0693	0,2 884	8	4,0 5827	6,6 9085	4,7 7815	1,1 7128	.
6,6 0693	0,2 884	1 0	4,0 8602	6,9 7078	5,8 816	2,0 544	.
6,6 0693	0,3 02	0	0,4 37	0,2 9079	0,2 9403	0,2 9847	.
6,6 0693	0,3 02	2	3,3 8531	3,2 2457	0,7 469	0,3 0178	.
6,6 0693	0,3 02	4	3,8 6985	5,2 7074	2,0 6295	0,3 8048	.
6,6 0693	0,3 02	6	4,0 0626	6,2 2999	3,5 4321	0,6 6139	.
6,6 0693	0,3 02	8	4,0 5842	6,6 9248	4,7 8623	1,1 8481	.
6,6 0693	0,3 02	1 0	4,0 861	6,9 7163	5,8 8697	2,0 6681	.
6,6 0693	0,3 1623	0	0,4 4902	0,3 0473	0,3 0805	0,3 1261	.
6,6 0693	0,3 1623	2	3,3 8742	3,2 3547	0,7 6263	0,3 1591	.
...	...	.	...	...	...	...	.

Всього було обраховано 375000 прикладів для діапазонів зміну опорів ρ_B, ρ_Z від 10^{-2} до 10^3 і дискретних значень геометричного параметру: $D/d = 0, 2, 4, 6, 8$ або 10 . В якості НМ ми була використана двошарова. На її вхід подаються УО зондів і відповідно кількість входів НМ дорівнює кількості зондів комплексу. Перший прихований шар складається з N_1 нейронів, другий шар складається з N_2

нейронів, яка дорівнює кількості виходів НМ. Для розглянутого прикладу моделі спочатку було покладено $N_2 = 3$ (відповідно до кількості встановлюваних параметрів). Кількість епох K – підбирається в залежності від необхідної точності розв’язання (залежить від величини похибки навчання ε). Коефіцієнт навчання дорівнює 0.5, функція активації – сигмоїда.

Для початку було покладено фіксоване значення $K = 2 \cdot 10^6$. На рис. 4.5 показана залежність похибки навчання від кількості епох.




Рисунок 4.5. Залежність похибки від кількості епох тренування.

Як ми бачимо в цьому випадку залежність немонотонно спадаюча (як повинно бути при збіжності методу) і має мінімум. НМ мережа була перевірена як для такої кількості епох так і для інших – у всіх випадках розв’язок значно відрізнявся від очікуваного. Більш на те: не було встановлено навіть якісного зв’язку між вхідними даними і вихідними, який повинен бути, як наслідок фізичної залежності між геоелектричними даними моделі і результатами виміру УО для неї.

Подібна перевірка була виконана для різної архітектури НМ: для різної кількості нейронів у прихованих шарах, для різної кількості епох та навіть для тришарової НМ з різними параметрами. У всіх випадках було отримано негативний результат розв’язання. Це можливо тому, що очікувані вихідні дані

якісно відрізняються фізично (табл. 4.1): перші два є значеннями ПО, третій – безрозмірна величина.

В ході навчання, тестування НМ та аналізу отриманих результатів було підтверджено висновок, що ефективність використання НМ залежить значною мірою від створення масиву прикладів для її навчання [104]. Хоча архітектура і параметри також відіграють значну роль, але як було зазначено збільшення кількості прихованих шарів нейронів не призвели до суттєвої зміни результату.

Тоді було використано інший підхід. Ми будемо окремо розв’язувати дві задачі: перша – визначення ρ_B, ρ_Z , друга – визначення D/d . Для першої НМ $N_2 = 1$, для другої $N_2 = 2$.

Максимальна похибка спостерігалась тільки для самих малих значень тільки параметра ρ_Z (біля 50%), і параметра ρ_B (не більше 20%). Для інших порядків величин вона не перевищує 12-15%.

ВИСНОВКИ.

Проведено аналіз поточного стану процесу геологорозвідувальних робіт, зацентовано увагу на введенні нових підходів до геологічного моделювання, а саме сіквенс-стратиграфічному підході і безальтернативності залучення даних сейсмічних досліджень для побудови сучасних моделей родовищ або площ дослідження. Досліджено сучасний стан фонду матеріалів сейсмічних досліджень для родовищ АТ «Укргазвидобування» для центральної частини ДДЗ, дійдено висновку стосовно необхідності збільшення розрізної здатності і збільшення співвідношення сигнал/завада для побудови якісних геологічних моделей, а також в подальшому – часткової автоматизації процесу сейсмічної інтерпретації.

Вперше створено 3D модель нейронної мережі для ефективної обробки реальних сейсмічних даних, що відповідають геолого-геофізичним умовам Дніпровсько-Донецького басейну на базі архітектури 3D U-net із трансформацією синтетичного набору 2D даних у псевдо 3D куби, що розкриває широкий спектр можливостей щодо проведення переінтерпретаційних та дорозвідувальних робіт із використанням сейсмічних мігрованих матеріалів минулих років, а також розширює спектр можливостей щодо побудови додаткових моделей штучного інтелекту для вирішення конкретних інтерпретаційних завдань – пошуку диз'юнктивних порушень, виділень поверхонь розмивів, тощо.

Вперше розроблено та реалізовано оптимізацію роботи функції втрат та метрик шляхом ітеративного підбору і аналізу впливу гіперпараметрів, що використовується для тренування конволюційної нейронної мережі з метою підвищення просторової розрізної здатності мігрованих матеріалів польової сейсмічної зйомки. Дана функція втрат повинна була поєднувати в собі збереження просторової компоновки об'єктів хвильового поля зі збільшенням розрізної здатності – тобто зміною зашумленого або нечіткого сигналу в окремих його зонах. Вирішення даної задачі стало можливим за рахунок

використання комбінованої функції втрат із динамічним підбором співвідношення входних функцій в залежності від якості входних сейсмічних матеріалів.

Вперше розроблено та впроваджено алгоритм аналізу методом вікна зі згладження екстремальних значень мігрованих сейсмічних даних за функцією активації сігмоїди із подальшим відтворенням близького до первинного інтервалу при зворотній трансформації. Подібний підхід дозволяє не тільки зберегти ширину спектру амплітудних значень входного сейсмічного матеріалу, але і дозволяє отримувати кілька варіантів результату прогнозу моделі штучного інтелекту:

- Власне сам результат прогнозу, без відтворення спектру оригінального сейсмічного матеріалу, що може бути використаний для пошуку ди'юнктивних порушень, характерних поверхням максимального затоплення анбо ерозії, рис хвильового поля. Також цей куб може бути використаний в парі із входним, необробленим моделлю ШІ сейсмічним кубом як додатковий об'єм (co-volume) для аналізу структурних змін, що були привнесені моделлю.
- Результат прогнозу із відтворенням спектру оригінального сейсмічного матеріалу. Він має не тільки похідну інформацію зі збільшеною розрізнявальною здатністю, але і частотні/амплітудні аномалії, що знаходяться в них самих просторових координатах, що і в похідному сейсмічному матеріалі. Із точним центруванням 0 значень, такий мігрований пост-оброблений сейсмічний матеріал дає можливість досліджувати атрибутивну складову процесу сейсмічної інтерпретації – тобто виділення аномалій за допомогою атрибутів когерентності, миттєвої частоти, RMS амплітуд, спектральних декомпозицій, тощо.

СПИСОК ЛІТЕРАТУРИ

1. Чебан В., Лящук Д. Історія розвитку геофізичних методів розвідки корисних копалин у західному регіоні України: *праці Наукового товариства ім. Шевченка*. Львів, 2007. 213 с.
2. Вакарчук Г.І. Основні питання стратиграфії та індексації продуктивних горизонтів нижнього карбону Дніпровсько-Донецької западини. Київ, 1998. 139 с.
3. Вакарчук Г. І. Перерви та незгоди в розрізі палеозою Дніпровсько-Донецької западини : *Геологічний журнал*.1991. № 1. С. 119-129.
4. Вакарчук Г. І. Результати сорокарічної діяльності "Чернігівнафтогазегеології" та подальші напрямки геологорозвідувальних робіт на нафту і газ у північно-західній частині Дніпровсько-Донецької западини : навч. посіб. Київ : УкрДГРІ, 2000. 157 с.
5. Вдовенко М. В. Про нижню межу візейського ярусу в Дніпровсько-Донецькій западині за даними вивчення форамініфер : *Геологічний журнал*. 2005. № 3. С. 70-73.
6. Вдовенко М. В. Про положення нижньої межі візейського ярусу карбону в Донецькому басейні : *Геологічний журнал*. 2005. № 1. С. 75-81.
7. Лось. Д.Д. Перспективи нафтогазоносності глибоких горизонтів Дніпровсько-Донецькій западини : навч. посіб. Київ : НТУ «Дніпровська політехніка», 2001. 37 с.
8. Вакарчук С. Г. Геологія, літологія та фації карбонатних відкладів візейського ярусу центральної частини Дніпро-Донецької западини у зв'язку з нафтогазоносністю. Чернігів, 2003. 163 с.
9. B. Mattos, R. S. Ferreira, R. M. D. G. Silva, M. Riva, and E. V. Brazil. Assessing texture descriptors for seismic image retrieval, Brazil, Oct 30, 2017. URL: <http://sibgrapi.sid.inpe.br/col/sid.inpe.br/sibgrapi/2017>
10. D. A. Herron, First steps in seismic interpretation. Society of Exploration Geophysicists, USA, Oct 10, 2011. URL: <https://doi.org/10.1190/1.9781560802938>

11. Вакарчук С. Г. Будова та перспективи нафтогазоносності органогенних споруд нижнього карбону Дніпровсько-Донецької западини : навч. посіб. Київ, 2003. 22 с.
12. Вдовенко М. В. Форамініферові зони нижнього карбону Дон-Дніпровського регіону / М. В. Вдовенко : *Геологічний журнал*. 2009. № 4. С. 75-86.
13. Вдовенко М. В. Про положення нижньої межі візейського ярусу карбону в Донецькому басейні : *Геологічний журнал*. 2005. № 1. С. 75-81.
14. Z. Chen, Y. Liu, H. Sun, Physics-informed learning of governing equations from scarce data, *Nature Communications*, China, May 12, 2021. URL: <https://doi.org/10.1016/j.ymssp.2023.110165>
15. Generalized Radon transforms and slant stacks. *Geophysical journal international*, Volume 66, Oct 2, 1981. URL: <https://doi.org/10.1111/j.1365-246X.1981.tb05966.x>
16. M. Rasht-Behesht, C. Huber, K. Shukla, G. E. Karniadakis, Physics-informed neural networks (pinns) for wave propagation and full waveform inversions, *Journal of Geophysical Research: Solid Earth*, Jun 5, 2022. URL: <https://doi.org/10.1190/1.9781560802938>
17. E. Shelhamer, J. Long, and T. Darrell. Fully Convolutional Networks for Semantic Segmentation, USA, Mar 8, 2015. URL: <https://arxiv.org/abs/1411.4038>
18. Dean T., O'Connell K., Quigley J. A review of nodal land seismic acquisition systems. Preview. USA, Mar 21, 2013. URL: <https://doi.org/10.1071/pvv2013n164p34>
19. Kendall R. Cableless Seismic Acquisition. Recorder. USA, Sep 11, 2015. URL: <https://doi.org/10.3997/2214-4609-pdb.159.d02>
20. J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. You only look once: Unified, real-time object detection, in CVPR, June, 2016. URL: https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Redmon_You_Only_Look_CVPR_2016_paper.pdf

21. Dean T., Tulett J., Barnwell R. Nodal land seismic acquisition: the next generation. Firstbreak. June 17, 2018. URL: <https://doi.org/10.3997/1365-2397.n0061>
22. S.Al-naqbi et all. How broadband, High dense, Full Azimuth and Source Point Reciever Acquisition Improves seismic Interpretation in Onshore Abu Dhabi, 2018. URL: <https://doi.org/10.2118/192948-MS>
23. Wang, Y.; Zhang, G.; Li, H.; Yang, W.; Wang, W. The high-resolution seismic deconvolution method based on joint sparserepresentation using logging–seismic data. Geophys. Prospect. Chine, June 4, 2022. URL: <https://www.x-mol.net/paper/article/1534187568789762048>
24. Berkhout, A. Least-squares inverse filtering and wavelet deconvolution. Geophysics, Dec, 1977. URL: <https://doi.org/10.1190/1.1440798>
25. Technological Advances in Seismic Data Processing and Imaging. USA, June 8, 2015.
URL: https://mdpires.com/bookfiles/book/8481/Technological_Advances_in_Seismic_Data_Processing_and_Imaging.pdf?v=1715159091
26. S. Cai, Z. Wang, S. Wang, P. Perdikaris, G. E. Karniadakis. Physics-informed neural networks for heat transfer problems, Journal of Heat Transfer Sep 6, 2021. URL: <https://textbook.edu.goit.global/python/data-science-remaster/v1/uk/docs/module-08/main/>
27. H.Ugochi, Dike, Y. Zhou, Unsupervised learning based on Artificial neural network: Review, IEEE international conference on Cyborg and Bionic systems, Chine, Oct 1, 2018. URL: <https://www.semanticscholar.org/paper/Unsupervised-Learning-Based-On-Artificial-Neural-A-Dike-Zhou/a0dd32cc9d53d43dd068e40239f0aec4b2ee7344>
28. V. Semeniaka¹, O. Bondarenko¹, V. Zatserkovnyi¹ and O. Ilchenko¹: Application of Geoinformation Technologies in Alternative Energy. International Conference of Young Professionals «GeoTerrace-2024» DOI: <http://dx.doi.org/10.3997/2214-4609.2024510055>
29. Nilimesh Halder. Mastering Machine Learning with Scikit-learn: A Beginner's Guide. USA, Jule 20, 2023. URL:

<https://medium.com/@HalderNilimesh/the-complete-beginners-guide-to-machine-learning-with-scikit-learn-c3613b6ed2a6>

30. Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., and Asari, V. K. Recurrentresidual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation. May 28, 2018. URL:

<https://doi.org/10.48550/arXiv.1802.06955>

31. V. Badrinarayanan, A. Kendall, and R. Cipolla. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, Nov, 2015. URL: [DOI: 10.1109/TPAMI.2016.2644615](https://doi.org/10.1109/TPAMI.2016.2644615)

32. Isola, P.; Zhu, J.Y.; Zhou, T.; Efros, A.A. Image-to-image translation with conditional adversarial networks. In Proceedings of theIEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21–26 July, 2017.

URL: <https://doi.org/10.1109/CVPR.2017.632>

33. N. Nedashkovskaya, D. Androsov: Generative time series model based on encoder-decoder architecture. System research and information technologies DOI:

<https://doi.org/10.20535/SRIT.2308-8893.2022.1.08>

34. Я. Ходневич, Д. Стефанишин: Do we need a more sophisticated multilayer artificial neural network to compute roughness coefficient? Екологічна безпека та природокористування, том 48, 2023, с. 170-182 DOI:

<https://doi.org/10.32347/2411-4049.2023.4>

35. Олександр Миколайович Терентьев, Тетяна Іванівна Просьянкіна-Жарова, Валерій Миколайович Дякон: Розроблення математичних моделей для підтримки прийняття рішень щодо функціонування критичної інфраструктури в галузі енергопостачання. *Інформаційно-керуючі системи*, том 6, 2023, с. 44-49

DOI: <https://doi.org/10.15587/2706-5448.2023.293205>

36. I. Kaliukh, O. Trofymchuk, O. Lebid: Peculiarities of Applying the Finite-Difference Method for Solving Nonlinear Problems of the Dynamics of Distributed Systems in a Flow. *Cybernetics and systems analysis*, vol.59, 2023, p. 120-133 DOI:

[10.1007/S10559-023-00548-4](https://doi.org/10.1007/S10559-023-00548-4)

37. M. Raissi, Deep hidden physics models: Deep learning of nonlinear partial differential equations, The Journal of Machine Learning Research, USA, 2018. URL: <https://www.jmlr.org/papers/volume19/18-046/18-046.pdf>
38. F. Sun, Y. Liu, H. Sun, Physics-informed spline learning for nonlinear dynamics discovery, Chine, May 17, 2021. URL: <https://doi.org/10.48550/arXiv.2105.02368>
39. Le Cun, Y., Bengio, Y., and Hinton, G. Deep learning. Nature, Nov 15, 2015. URL: <http://dx.doi.org/10.1038/nature14539>
40. Застосування штучних нейронних мереж для обробки інформації в технічних системах моніторингу навколишнього середовища : навч. посіб. / за ред. Б.В. Перелигін, Т.Б. Ткач. Київ, 2014. с. 218.
41. Comparative Performance Analysis Of Deep Learning-Based Image Steganography Using U-Net, V-Net, And U-Net Encoders. March, 2024. URL: [DOI:10.53555/jaz.v45i3.4390](https://doi.org/10.53555/jaz.v45i3.4390)
42. Kim, J. K. Lee, and K. M. Lee. Accurate image super-resolution using very deep convolutional networks, in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun, 2016. URL: <https://doi.org/10.48550/arXiv.1511.04587>
43. Muradov, R. S., and A. G. Shahtakhtinskiy. Application of artificial neural networks as a tool for properties prediction using seismic data: 9th Congress of the Balkan Geophysical Society. Sep 5, 2016. URL: <https://doi.org/10.18502/keg.v1i1.526>
44. X. Wu, Z. Geng, Y. Shi, N. Pham, S. Fomel, and G. Caumon. Building realistic structure models to train convolutional neural net-works for seismic structural interpretation. Geophysics, USA, Jul, 2020. URL: <https://doi.org/10.1190/geo2019-0375.1>
45. Mohamed, I. A., A. Othman, and M. Fathy. A new approach to improve reservoir modeling via machine learning: The Leading Edge, 39, 2021. URL: [doi: 10.1190/tle39030170.1](https://doi.org/10.1190/tle39030170.1).

46. Liu, W., Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi. A survey of deep neural network architectures and their applications: Neurocomputing, 2019. URL: [doi: 10.1016/j.neucom.2016.12.038](https://doi.org/10.1016/j.neucom.2016.12.038)
47. S. Chopra and V. Alexeev. Applications of texture attribute analysis to 3d seismic data, The Leading Edge, 2006. URL: https://chopraseismic.com/wp-content/uploads/2015/09/TEX_sep05-texture-attribute-analysis.pdf
48. P. Lu, M. Morris, S. Brazell, C. Comiskey, and Y. Xiao. Using generative adversarial networks to improve deep-learning fault interpretation networks, Lead. Edge, Chine, Aug. 2018. URL: <https://doi.org/10.1190/tle37080578.1>
49. X. Wu, L. Liang, Y. Shi, and S. Fomel. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation, Geophysics, Chine, 2019. URL: <https://doi.org/10.1190/geo2018-0646.1>
50. Lowney, B., I. Lokmer, G. S. O'Brien, and C. Bean. Direct diffraction separation by deep learning on pre-migrated seismic data: EAGE Annual Conference & Exhibition Online, Extended Abstracts, 2019. URL: [doi: 10.3997/2214-4609.202010719](https://doi.org/10.3997/2214-4609.202010719)
51. Keynejad, S., M. L. Sbar, and R. A. Johnson. Creating probabilistic 3D models of lithofluid facies using machine-learning algorithms: Interpretation, 2020. URL: [doi:10.1190/INT-2019-0249.1](https://doi.org/10.1190/INT-2019-0249.1)
52. Obstacle segmentation based on the wave equation and deep learning. Journal of Computational Physics, 2008. URL: <https://doi.org/10.1016/j.jcp.2020.109458>
53. Seismic facies analysis using machine learning. Geophysics, Hateley, J.C., Roberts, J., Mylonakis, K., and Yang, X. 2019. URL: <https://doi.org/10.1190/geo2018-0646.1>
54. Automated fault detection without seismic processing. The Leading Edge. Perol, T., Gharbi, M., and Denolle, May, 2017. URL: <http://dx.doi.org/10.1190/tle36030208.1>

55. Wang, E., and J. Nealon. Applying machine learning to 3D seismic image denoising and enhancement: Interpretation, 2019. URL: <https://doi.org/10.1190/INT-2018-0224.1>

56. Wang, B., N. Zhang, W. Lu, and J. Wang. Deep-learning-based seismic data interpolation: A preliminary result: Geophysics, Chine, 2019. URL: <https://doi.org/10.1190/geo2017-0495.1>

57. Gao, Y.; Zhang, J.; Li, H.; Li, G. Incorporating Structural Constraint Into the Machine Learning High-Resolution Seismic Reconstruction. IEEE Trans. Geosci. Remote. Sens. Chine, 2022. URL: <https://doi.org/10.1109/TGRS.2022.3157064>

58. Mukhopadhyay, P., and S. Mallick. Bayesian deep learning for seismic facies classification and its uncertainty estimation: 89th Annual International Meeting, SEG, Expanded Abstracts, 2019. URL: [doi:10.1190/segam2019-3216870.1](https://doi.org/10.1190/segam2019-3216870.1)

59. Liu, Z., Y. Chen, and G. Schuster. Deep convolutional neural network and sparse least-squares migration: Geophysics, Chine, 2020. URL: [doi:10.1190/geo2019-0412.1](https://doi.org/10.1190/geo2019-0412.1)

60. S. Ren, K. He, R. Girshick, and J. Sun. Faster R-CNN: Towards Real Time Object Detection with Region Proposal Networks, in Advances in NIPS 28 Curran Associates, Inc., Chine, 2015. URL: <https://doi.org/10.48550/arXiv.1506.01497>

61. D. Chevitarese, D. Szwarcman, R. M. D. Silva, and E. V. Brazil. Seismic facies segmentation using deep learning, in AAPG ACE, May 27, 2018. URL: <https://doi.org/10.1190/1.9781560802938>

62. D. Chevitarese, D. Szwarcman, R. M. D. Silva, and E. V. Brazil, Transfer learning applied to seismic images classification, in AAPG ACE, May 17 2018. URL: <https://doi.org/10.1190/1.9781560802938>

63. O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in International Conference on Medical image computing and computer-assisted intervention, Springer, Oct 27, 2015. URL: <https://journalofcloudcomputing.springeropen.com/articles/10.1186/s13677-022-00378-3>

64. SeisDeNet: an intelligent seismic data Denoising network for the internet of things, USA, May 15, 2015 URL:

<https://journalofcloudcomputing.springeropen.com/articles/10.1186/s13677-022-00378-3>

65. Padma K. R., Don K. R. Artificial Neural Network Applications in Analysis of Forensic Science. Cyber Security and Digital Forensics, USA, 2022. URL: [DOI: 10.1002/9781119795667.ch3](https://doi.org/10.1002/9781119795667.ch3)

66. Pooling in convolutional neural networks for medical image analysis: a survey and an empirical study. Rajendran Nirthika, Siyamalan Manivannan, Amirthalingam Ramanan, Ruixuan Wang, 2018. URL:

<https://link.springer.com/article/10.1007/s00521-022-06953-8>

67. X. Liu, X. Chen, J. Li, X. Zhou, and Y. Chen. Facies identification based on multikernel relevance vector machine, IEEE Trans. Geosci.Remote Sens China, Oct. 2020. URL: <http://dx.doi.org/10.1109/TGRS.2020.2981687>

68. Liu, Z., J. Cao, Y. Lu, S. Chen, and J. Liu. A seismic facies classification method based on the convolutional neural network and the probabilistic framework for seismic attributes and spatial classification: Interpretation, Chine, 2018. URL: [doi:10.1190/INT-2018-0238.1](https://doi.org/10.1190/INT-2018-0238.1)

69. J. Long, E. Shelhamer, and T. Darrell. Fully convolutional networks for semantic segmentation, in Proceedings of the IEEE conference on computer vision and pattern recognition, USA, Oct 15, 2015. URL:

<https://ieeexplore.ieee.org/document/7298965>

70. Phase net: A deep-neural-network-based seismic arrivaltime picking method. Geophysical Journal International, Sang, Y., Sun, J., Gao, D., and Wu, H., Chine, 2021. URL: [DOI: 10.1093/gji/ggy423](https://doi.org/10.1093/gji/ggy423)

71. C. Rao, P. Ren, Y. Liu, H. Sun. Discovering nonlinear pdes from scarce data with physics-encoded learning, Chine, Jan 28, 2022. URL:

<https://doi.org/10.48550/arXiv.2201.12354>

72. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. Deep learning, Cambridge, Sep, 2016. URL:

[http://alvarestech.com/temp/deep/Deep%20Learning%20by%20Ian%20Goodfellow,%20Yoshua%20Bengio,%20Aaron%20Courville%20\(z-lib.org\).pdf](http://alvarestech.com/temp/deep/Deep%20Learning%20by%20Ian%20Goodfellow,%20Yoshua%20Bengio,%20Aaron%20Courville%20(z-lib.org).pdf)

73. P. Lu, M. Morris, S. Brazell, C. Comiskey, and Y. Xiao. Using generative adversarial networks to improve deep-learning fault interpretation networks, Lead. Edge, Aug. 2018. URL: <http://dx.doi.org/10.1190/tle37080578.1>

74. Mlella, M., M. Ma, R. Zhang, and M. Mokhtari. Machine learning for geophysical characterization of brittleness: Tuscaloosa Marine Shale case study: Interpretation, 2020. URL: [doi:10.1190/INT-2019-0194.1](https://doi.org/10.1190/INT-2019-0194.1)

75. Zhang, J.; Li, J.; Chen, X.; Li, Y.; Huang, G.; Chen, Y. Robust deep learning seismic inversion with a priori initial model constraint. Geophys, China, 2021. URL: <http://dx.doi.org/10.1093/gji/ggab074>

76. Wang, B., N. Zhang, W. Lu, J. Geng, and X. Huang. Intelligent missingshots' reconstruction using the spatial reciprocity of green's function based on deeplearning: IEEE Transactions on Geoscience and Remote Sensing, China, 2019. URL: <http://dx.doi.org/10.1109/TGRS.2019.2947085>

77. Teopir F. Li, H. Zhou, Z. Wang, and X. Wu. ADDCNN: An attention-based deep dilated convolutional neural network for seismic facies analysis with interpretable spatial–spectral maps, IEEE Trans. Geosci. Remote Sens, China, 2021. URL: https://cig.ustc.edu.cn/_upload/tpl/05/cd/1485/template1485/papers/li2020addcnn.pdf

78. Song, C.; Lu, W.; Wang, Y.; Jin, S.; Tang, J.; Chen, L. Reservoir Prediction Based on Closed-Loop CNN and Virtual Well-Logging Labels. IEEE Trans. Geosci. Remote. Sens, China, 2022. URL: <http://dx.doi.org/10.1109/TGRS.2022.3205301>

79. Fang, Z., H. Fang, and L. Demanet. Deep generator priors for bayesian seismic inversion: Advances in Geophysics, China, 2020. URL: <http://dx.doi.org/10.1016/bs.agph.2020.07.002>

80. T. Rebert, R. Sablon, N. Vidal, P. Charrier, and R. Soubaras. Improving pre-salt imaging with variable-depth streamer data, in Proc. SEG Tech. Program Expanded Abstr., Sep. 2012. URL: DOI: [10.1190/segam2012-1067.1](https://doi.org/10.1190/segam2012-1067.1)

81. Y.-G. Zhang, Y. Wang, and J.-J. Yin. Single point high density seismic data processing analysis and initial evaluation, *Shiyou Diqu Wuli Kantan* (Oil Geophys. Prospecting), 2010. URL: <https://doi.org/10.15407/dopovidi2024.03.011>
82. X. Wu, L. Liang, Y. Shi, and S. Fomel. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation, *Geophysics, Chine*, 2019. URL: <http://dx.doi.org/10.1190/geo2018-0646.1>
83. Sun, H., and L. Demanet. Extrapolated full-waveform inversion with deep learn-ing: *Geophysics*, 2020. URL: <http://dx.doi.org/10.1190/geo2019-0195.1>
84. O. Noskov, S. Levoniuk, M. L. Myrontsov. (2021) Creation of Geological 3D-model of Komyschnianske Field Based on the Sequence Stratigraphy Principles. SPE Eastern Europe Subsurface Conference DOI: <https://doi.org/10.2118/208507-MS>
85. O. Noskov, M. Myrontsov, O. Karpenko, S. Dovgyi, Y. Anpilova Implementation of Sequence-Stratigraphy Based Geological Studies in Ukraine. Zaporozhets, A., Popov, O. (eds) *Systems, Decision and Control in Energy IV*. Studies in Systems, Decision and Control, vol. 456, 2023 pp. 213-221. https://doi.org/10.1007/978-3-031-22500-0_14
86. Myrontsov M.L. Multi-Probe Hardware for Electrometry of Oil and Gas Wells. *Science and Innovation*. 2018. V. 14, no. 2. P. 51-56. <http://doi.org/10.15407/scine14.03.051>
87. Myrontsov M.L. Application of neuron networks in solving unstable inverse problems of electrometry of oil and gas wells. *Донов. Нау. акад. наук Укр.* 2024
88. Myrontsov, M., Dovgyi, S., Trofymchuk, O., Lebid, O., & Okhariev, V. (2022). Development and Testing of Tools for Modeling R&D Works in Geophysical Instrument-Making for Oil and Gas Well Electrometry. *Science and Innovation*. 2022. V. 18, no. 3. P. 28–36. <https://doi.org/10.15407/scine18.03.028>
89. X.Wu, H. Zhanxuan. Deep learning for simultaneous seismic image super-resolution and denoising, Feb. 2021. URL: [Doi:10.1109/TGRS.2021.3057857](https://doi.org/10.1109/TGRS.2021.3057857)

90. A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, and J. Garcia-Rodriguez. A review on deep learning techniques applied to semantic segmentation, 2017. URL: <https://arxiv.org/abs/1704.06857>
91. Noise attenuation of seismic data via deep multiscale fusion network. Wireless Communications and Mobile Computing, Zhang X., Zhang M. and Tian X., 2021. URL: <http://dx.doi.org/10.1155/2021/6612346>
92. Wang, Y.; Qiu, Q.; Lan, Z.; Chen, K.; Zhou, J.; Gao, P.; Zhang, W. Identifying microseismic events using a dual-channel CNN with wavelet packets decomposition coefficients. Comput. Geosci, Chine, 2022. URL: <https://doi.org/10.1016/j.cageo.2022.105164>
93. Johnson, S. W., Chambers, D. J., Boltz, M. S. and Koper, K. D. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity. Geophys, 2020. URL: [doi:10.1093/gji/ggaa449](https://doi.org/10.1093/gji/ggaa449)
94. Недзельський О. Ю., Лашевська, Н. О. Відновлення зображень з суперроздільною здатністю за допомогою згорткових нейронних мереж. *Вісник НТУУ КПІ*. 2018. № 3. С. 17-19.
95. Rob Simm, Mike Backon. Seismic amplitude. An interpreter's handbook, USA, June, 2014. URL: <https://doi.org/10.1017/CBO9780511984501>
96. M. Myrontsov, O. Noskov, V. Sokolov. Method for determining areas of stable solutions of inverse problems of mathematical physics by the example of well electrometry. Information Technology and Mathematical Modeling for Environmental Safety 2021. pp. 115-126 <http://ceur-ws.org/Vol-3021/>
<https://elibrary.kubg.edu.ua/id/eprint/39482>
97. Миронцов М.Л. *Електрометрія нафтогазових свердловин*. Київ, 2019. 217 с.
98. Єгурнова М.Г., Зайковський М.Я., Загоротько Я.М., Цьоха О.Г., Кнішман О.Ш., Муляр П.М., Дем'яненко І.І. *Нафтогазоперспективні об'єкти України. Нафтогазоносність та особливості літогеофізичної будови відкладів нижнього карбону і девону Дніпровсько-Донецької западини*. Київ, 2005. 196 с.

99. Anderson B.I. *Modeling and inversion methods for the interpretation of resistivity logging tool response*. Delft, 2001, P. 377.
100. Rumelhart, D.E., Hinton, G.E., Williams, R.J. (1986). Learning Internal Representations by Error Propagation. *Parallel Distributed Processing*. V.1, P. 318–362.
101. Миронцов М.Л. *Електрометрія нафтогазових свердловин*. Київ, 2019. 217 с.
102. Миронцов Н.Л. *Численное моделирование электрометрии скважин*. Київ, 2012. 224 с.
103. Myrontsov M.L. Application of neuron networks in solving unstable inverse problems of electrometry of oil and gas wells. *Донов. Нац. акад. наук Укр.* 2024
104. Myrontsov, M., Dovgyi, S., Trofymchuk, O., Lebid, O., & Okhariev, V. (2022). Development and Testing of Tools for Modeling R&D Works in Geophysical Instrument-Making for Oil and Gas Well Electrometry. *Science and Innovation*. 2022. V. 18, no. 3. P. 28–36. <https://doi.org/10.15407/scine18.03.028>
105. Myrontsov M.L. Multi-Probe Hardware for Electrometry of Oil and Gas Wells. *Science and Innovation*. 2018. V. 14, no. 2. P. 51-56. <http://doi.org/10.15407/scine14.03.051>

Додаток А. Акти впровадженнь

ТОВ «ПРИДНІПРОВСЬКА ГІРНИЧО-ХІМІЧНА КОРПОРАЦІЯ»

52209, м. Жовті Води, вул. М. Грушевського, 78, Дніпропетровська обл., Україна
тел.: +38068 492-90-58, e-mail: pghk2012@ukr.net



АКТ

впровадження результатів дисертаційного дослідження Носкова Олексія Вікторовича

Наукові висновки, запропоновані в рамках поданих матеріалів дисертаційного дослідження старшого наукового співробітника відділу проектування геологорозвідувальних робіт, групи геологічного моделювання та обґрунтування буріння пошукових і розвідувальних свердловин Носкова О.В. на тему "Збільшення розрізної здатності мігрованих сейсмічних даних на основі використання нейронних мереж".

- полягають в розробці архітектури моделей штучного інтелекту в двох реалізаціях – для 2Д і 3Д мігрованих сейсмічних даних. Представлені моделі навчаються за допомогою аугментованих наборів тренувальних та валідаційних даних, збільшують співвідношення сигнал/завада в мігрованих матеріалах сейсмічної зйомки і пропонуються як додатковий крок пост-обробки даних з метою збільшення якості інтерпретаційних робіт скерованих на закладання пошукових та розвідувальних свердловин для об'єктів компанії.
- запропоновані автором моделі можуть застосовуватись до матеріалів фінальних кроків міграції як в часовому, так і в глибинному доменах. Представлена робота виконана у вигляді пов'язаних *.ipynb записників, що використовують в якості мови програмування python, приймають на вході *.SEGY файли і вивантажують результати моделювання в тому ж форматі і з тими ж метаданими, що спрощує процес завантаження опрацьованих кубів в стандартне для компанії програмне середовище для подальшого геологічного моделювання.
- якість роботи моделі пропорційна якості матеріалів, що надаються для обробки, і зважаючи на вказані автором обмеження, можуть бути використані для більшої частини родовищ компанії.
- в ході обробки за допомогою моделі підкреслюються існуючі патерни поведінки хвильових даних без додавання неіснуючих в оригінальних мігрованих матеріалах польової зйомки трендів, що робить прогноз за обробленими кубами актуальним для геологорозвідувального процесу. На прикладі представлених матеріалів порівняння спектрів прогнозних та реальних даних вказано на суттєве збільшення сигналу в інтервалі частот 30-140 Гц, що і було метою роботи моделі.

Результати дисертаційного дослідження можуть бути використані для вдосконалення процесів геологорозвідувальних робіт, скерованих на обґрунтування та закладання пошукових і розвідувальних свердловин на нафту та газ.

Генеральний директор

ТОВ «Придніпровська гірничо-хімічна корпорація»



О.В. Гребенюк



**Акціонерне товариство
«Укргазвидобування»**

04053, Київ-53, вул. Кудрявська, 26/28
Тел.: +380 (44) 272-31-15. Факс: +380 (44) 461-29-94
ЄДРПОУ 30019775
office@ugv.com.ua
www.ugv.com.ua



**Joint stock company
«UkrGasvydobuvannya»**

26/28 Kudriavska St., Kyiv, Ukraine, 04053
Tel.: +380 (44) 272-31-15. Fax: +380 (44) 461-29-94
OHSAS 18001:2010 ISO 9001:2015 ISO 14001:2015
office@ugv.com.ua
www.ugv.com.ua

АКТ

впровадження результатів дисертаційного дослідження

Носкова Олексія Вікторовича

Практичні результати, запропоновані в рамках поданих матеріалів дисертаційного дослідження старшого наукового співробітника відділу проектування геологорозвідувальних робіт, групи геологічного моделювання та обґрунтування буріння пошукових і розвідувальних свердловин УкрНДІгазу, Носкова О.В. на тему "Збільшення розрізної здатності мігрованих сейсмічних даних на основі використання нейронних мереж".

- полягають в розробці архітектури моделей штучного інтелекту в двох реалізаціях – для 2D і 3D мігрованих сейсмічних даних. Представлені моделі навчаються за допомогою аугментованих наборів тренувальних та валідаційних даних, збільшують співвідношення сигнал/завада для мігрованих матеріалів сейсмічної зйомки і пропонуються як можливий альтернативний крок пост-обробки даних з метою збільшення деталізації інтерпретаційних результатів скерованих на закладання пошукових та розвідувальних свердловин для деяких об'єктів компанії.

- запропоновані автором моделі можуть застосовуватись до матеріалів фінальних кроків міграції як в часовому, так і в глибинному доменах. Представлена робота виконана у вигляді пов'язаних *.ipynb записників, що використовують в якості мови програмування python, приймають на вході *.SEGY файли і вивантажують результати моделювання в тому ж форматі і з тими ж метаданими, що спрощує процес завантаження опрацьованих кубів в

стандартне для компанії програмне середовище для подальшого циклу робіт з сейсмічної інтерпретації та геологічного моделювання.

- якість роботи моделі пропорційна якості матеріалів, що надаються для обробки, і зважаючи на вказані автором обмеження, можуть бути використані для серії родовищ компанії.

- в ході обробки за допомогою моделі підкреслюються існуючі патерни поведінки хвильових даних без додавання неіснуючих в оригінальних мігрованих матеріалах польової зйомки трендів, що робить прогноз за обробленими кубами актуальним для геологорозвідувального процесу. На прикладі представлених матеріалів порівняння спектрів прогнозних та реальних даних вказано розширення спектру в інтервалі частот 30-140 Гц, що і було метою роботи моделі.

Результати дисертаційного дослідження можуть бути використані для вдосконалення процесів геологорозвідувальних робіт, скерованих на обґрунтування та закладання пошукових та розвідувальних свердловин на нафту та газ як базова модель. Із точки зору різноманітності геологічних умов осадконакопичення і різних графів обробки польового сейсмічного матеріалу для кожного окремого родовища може бути застосований процес донавчання моделі для підкреслення особливостей хвильового поля, притаманних конкретним геолого-геофізичним умовам.

**Директор з геологорозвідки
та розробки родовищ**



Максим ВІТИК

Підпис

П.І.Б.

«22» квітня 2025 р.