

UDC 004.4

Oleksii Noskov, postgraduate student

ORCID ID: <https://orcid.org/0000-0002-6729-0538> **e-mail:** a33211noskov@gmail.com

Mykyta Myrontsov, Doctor of Physical and Mathematical Sciences, Senior Researcher

ORCID ID: <https://orcid.org/0000-0002-2830-8803> **e-mail:** myrontsov@ukr.net

Institute of Telecommunications and Global Information Space of NASU, Kyiv, Ukraine

IMPLEMENTATION OF NEURAL NETWORK BASED 2D SEISMIC IMAGES SUPER RESOLUTION APPROACH

Abstract. *In the modern geological exploration process, involvement of seismic interpretation data has long become an everyday norm. The quality of field data and the migration procedure plays a key role in determining the geological structure of the area and the distribution of reservoirs. As an example of seismic survey materials post-processing, a mathematical model of machine learning based on a neural network based on U-net architecture was developed and programmatically implemented to increase the resolution and decrease noise value for 2D images based on a synthetic set of training data. The structure of the model was described, and an algorithm was built for preparing migrated seismic data in the standard SEG Y format for processing with the help of the model and reverse conversion into the input format.*

Keywords: *machine learning model, neuron network, seismic, 2D U-net architecture, loss function.*

О.В. Носков, М.Л. Миронцов

Інститут телекомунікацій і глобального інформаційного простору НАН України,
м. Київ, Україна

ЗАСТОСУВАННЯ ТЕХНОЛОГІЇ ЗБІЛЬШЕННЯ РОЗДІЛЬНОЇ ЗДАТНОСТІ МІГРОВаних СЕЙСМІЧНИХ ЗОБРАЖЕНЬ ДЛЯ 2Д СЕЙСМІЧНИХ ЗЙОМОК ЗА ДОПОМОГОЮ НЕЙРОННОЇ МЕРЕЖІ

Анотація. *В сучасному геологорозвідувальному процесі залучення даних сейсмічної інтерпретації давно стало повсякденною нормою. Якість польових даних та процедури міграції грає ключову роль у визначенні геологічної будови площі та розповсюдженні колекторів. У якості процесу пост-обробки матеріалів сейсмічної зйомки було розроблено і програмно реалізовано математичну модель машинного навчання на базі нейронної мережі архітектури U-net для збільшення роздільної здатності і збільшення значення сигнал/завада для 2D зображень на основі синтетичного набору тренувальних даних. Описано будову моделі, побудовано алгоритм для підготовки мігрованих сейсмічних даних у стандартному форматі SEG Y для опрацювання за допомогою моделі і зворотною конвертацією у вхідний формат.*

Ключові слова: *модель машинного навчання, нейронна мережа, сейсміка, 2D U-net архітектура, функція втрат.*

<https://doi.org/10.32347/2411-4049.2025.1.139-145>

Вступ

За останні десятиріччя із розвитком обчислювальних технологій суттєво змінився процес геологічного пошуку вуглеводнів. Ключову роль в процесі пошуку та розвідки нових нафтогазових покладів відіграє побудова геолого-технологічної 3D моделі досліджуваної площі, яка спирається на сейсмічні дані [1] і без якої зараз важко уявити процес закладання свердловин. На жаль, в переважній кількості випадків, якість сейсмічних даних не є оптимальною для вирішення поставленої задачі [2]. Для цього є низка причин:

- Один зі основних нафтогазових басейнів України, Дніпровсько-Донецька западина, розташований в щільно заселеній частині країни;
- Для ведення робіт з дорозвідки родовищ суттєвий вплив на якість сейсмічних даних чинить антропогенний фактор інфраструктури будь-якого активного родовища;
- Різні якість польових матеріалів та міграції сейсмічних зйомок, що призводить до зменшення співвідношення сигнал/завада.

Мета представленої роботи – створення і тренування нейронної мережі, для збільшення якості мігрованих сейсмічних даних, що підвищує якість і ефективність робіт з сейсмічної інтерпретації та геологічного моделювання площі досліджень.

Якість геологічних структурних побудов, а також розповсюдження колекторських властивостей гірських порід – основні задачі, які ставляться на етапі сейсмічної інтерпретації.

Вирішення цих задач напряму залежить від якості як свердловинного матеріалу, так і мігрованих сейсмічних даних. Вирішенню задачі покращення інформативної частини сейсмічних даних світовими вченими присвячено низку наукових праць (зокрема [3-5]), проте більшість із них сфокусовані на дослідженні геологічних умов, що сильно відрізняються від наявних в Україні за глибиною залягання і характером зйомки. У вирішенні подібних задач прийнято обирати з двох варіантів – або обирати максимально «чистий» набір сейсмічних даних, з мінімальним вмістом зашумлених зон, або створювати синтетичний набір даних і штучно вносити в нього шумові завади. З точки зору адаптивності до різних умов осадконакопичення – як в латеральному, так і вертикальному сенсі, перший варіант видається менш адаптивним, бо він описує одні конкретні умови седиментації, у той час як синтетичний набір може вмщати будь-які варіації геологічних умов. Саме тому дана робота спирається на останній варіант вхідних даних для вирішення цих задач за допомогою використання згорткових нейронних мереж [6] (НМ), що набули широкого розвитку за останні роки.

Для вирішення першої частини задачі [7] було згенеровано 800 синтетичних сейсмічних кубів, з яких було екстраговано 3200 різних 2D зображень, які і сформували базу даних для навчання моделі.

Архітектура нейронної мережі. Із проаналізованих на етапі відбору архітектур нейронних мереж для роботи із зображеннями, що зарекомендували себе впродовж останніх років, можна виділити U-net та XPixel [8]. Проте їх порівняльний аналіз вказує на неможливість використання для поточних цілей мережі на базі XPixel.

Для побудови моделі нейронної мережі було використано варіант архітектури U-net, який схематично зображено на рис. 1. Варіант саме U-net

було обрано через те, що він не змінює геометрію об'єктів в межах малюнку, а тому сейсмічні зображення, треновані даною мережею, матимуть ту саму ступінь достовірності, як і похідні сейсмічні дані, включаючи їх вертикальні і латеральні обмеження з точки зору роздільної здатності.

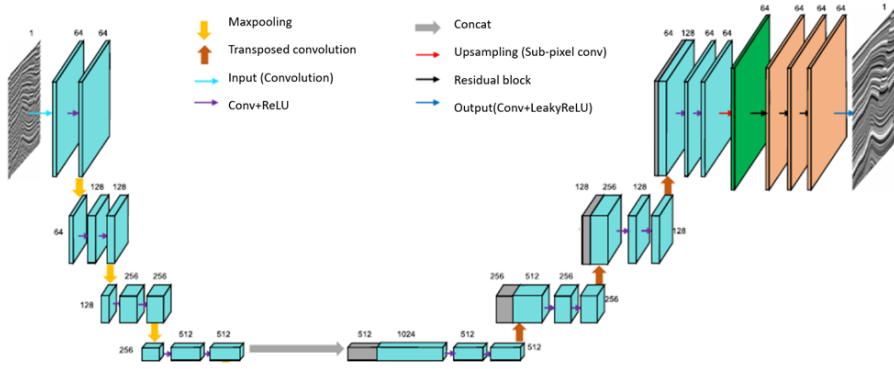


Рис. 1. Схематична будова використаної нейронної мережі

Використана мережа в своїй будові має 3 блоки кодувальника та 3 блоки декодувальника, які поєднуються зв'язковим блоком, що 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 відтворена в послідуючих. Структурно рівень зв'язковий блок складається з параметрів, які можна навчити і які дозволяють моделі адаптувати та точно налаштувати своє внутрішнє представлення на основі характеристик даних. Він діє як важлива ланка, підвищуючи здатність моделі вивчати ієрархічні та складні функції [9]. З огляду на те, що мета моделі – фільтрація шумів і збільшення роздільної здатності – досить низькорангові, тобто модель не має на меті запам'ятовування та відтворення складних багатозв'язкових паттернів даних, додавання більшої кількості шарів не є необхідним, бо це призводить до перенавантаження моделі, без якісних змін в результуючому прогнозі.

Для покращення роботи моделі у якості функції активізації було використано модифіковану ReLU (Rectified Linear Unit), а саме leaky ReLU для усунення проблем із зникаючим градієнтом – градієнти для значень більше нуля мають залишатися ненульовими, що забезпечуватиме ефективне поширення градієнтів та оновлення ваги в процесі тренування. Leaky ReLU, як і її похідна функція, активує лише окремі нейрони, залишаючи інші неактивними. Завдяки цьому нейронна мережа може навчатися на більш розріджених уявленнях даних – і знижується ризик перенавчання, що підтверджується отриманою похибкою під час перевірки на нових, небачених мережею даних. Головна відмінність Leaky ReLU від похідної функції – вона не зберігає інформацію про негативні значення, у той час як ReLU їх приводить до нульових значень, що призводить до проблеми «відмираючих нейронів».

Головний недолік обох функцій, а саме – ненормалізованість, було покрито за рахунок нормалізації тренувального та валідаційного наборів.

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 ШІ.

Тестування алгоритму із застосуванням даної методики вказує на зростання роздільної здатності та покращення якості прогнозного сейсмічного матеріалу із застосуванням із досить високим граничним значенням $\sigma = 1,5$ через те, що екстремальні значення амплітуди в хвильовому полі відповідають породам обмеженого розповсюдження по розрізу – вапнякам, ангідридам, солям, які мають досить локальне розповсюдження в межах сейсмічної зйомки.

Огляд використаних функцій втрат. При побудові мережі ШІ у якості функції втрат були розглянуті наступні варіації розповсюджених рішень для роботи з зображеннями: PSNR, MSE, ssim, ms-ssim.

PSNR (peak signal-noise response) – пікове співвідношення сигнал/завада означає співвідношення між максимумом значення сигналу (в нашому випадку – нормованого) і потужністю шуму, що його спотворює. Мережа може навчатися за допомогою PSNR функції втрати, яка поєднує втрати ℓ_1 і втрати MS-SSIM. Завдяки перевагам у покращенні продуктивності та конвергенції над середньоквадратичною помилкою (MSE) або ℓ_2_loss [8], ℓ_1_loss широко використовується для збільшення роздільної здатності зображень. Математично втрата ℓ_1 визначається як:

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

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

Нейронна мережа, що була навчена використовувати виключно ℓ_1_loss , генеруватиме зображення високої роздільної здатності зі згладженими текстурами, що не є прийнятними для подальшого процесу робіт із сейсмічної інтерпретації через втрату виразності сейсмічного відгуку [7], 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. Математично PSNR відображається наступним чином:

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) = 20 \log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right).$$

Ssim (Structural Similarity Index metric) – Індекс структурової подібності є одним із методів вимірювання подібності між двома зображеннями. Дана функція – метод повного співставлення, де контроль якості проводиться на основі вхідного зображення і напряму залежить від його якості. Особливістю метода є урахування не тільки положення пікселів, а і структурної зміни інформації. Ідея полягає в тому, що близько розташовані пікселі мають сильний взаємозв'язок. Ця залежність несе важливу інформацію про структуру

об'єктів та загальну компоновку. SSIM метрика розрахована на різні розміри вікна. Різниця між двома вікнами x та y , що мають однаковий розмір $N \times N$:

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

Ms-ssim (multi-scale structural similarity index metric) – розширена метрика Ssim, яка здійснює оцінку подібності одночасно в кількох різних масштабах зображення [10]. 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.

Первинно PSNR, Ms-ssim та Ssim є додатними зростаючими метриками, але для цілей навчання нейронної мережі було створено функції втрат на основі цих метрик, перевівши їх у площину від'ємних значень.

Для покращення прогнозної якості моделі було скомбіновано ℓ_1 loss та Ms-ssim функції втрат. В математичному вигляді фінальну функцію втрат можна представити як:

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

де

$$\mathcal{L}^{ms-ssim} = 1 - MS - SSIM(lsr, lhr),$$

α – вага функції втрат.

Трансформація сейсмічних даних та застосування моделі. Одним із головних обмежень даного проєкту є застосування попередньо сформованого набору даних для навчання моделі з фіксованими розмірами. Дані з публічного репозиторія [7] були сформовані у вигляді 2Д зображень розмірністю 256x256 пікселів.

Реальні 2Д сейсмічні зображення за замовчуванням не мають якогось попередньо визначеного фіксованого розміру, тому частиною роботи була адаптація вхідних сейсмічних даних до розміру тренованої моделі III.

Під час застосування моделі III є дві базові стратегії поведінки – не вказувати розмір вікна для зчитування, що розтягне модель на все вікно обробки даних, і, відповідно, розбити вікно 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 сейсмічного куба містить набагато більше інформації, ніж невеликий зразок синтетичних даних, і тому рівень узагальнення за результатами тренування надвисокий, що не є вирішенням поставленої задачі. Таким чином, залишається другий варіант – подрібнення 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 блоків і їх коректного поєднання (рис. 2).




Рис. 2. Фрагмент 2Д профіля з ефектом крайових зон після застосування моделі ШІ

Було заміряно товщину вказаних крайових зон – вона становить по 3 пікселі з кожного боку. Найпростішим варіантом її позбавлення є видалення по 3 пікселі з кожного краю вікна прогнозу моделі з екстраполяцією нових крайових значень на товщину видаленого простору. Незначні артефакти такого підходу залишаються, але на достовірність сейсмічних побудов із застосуванням результату прогнозу ШІ вони вже не впливають.

Висновки

На базі публічних синтетичних даних побудовано нейронну мережу, а також підбрано оптимальні налаштування її блокової будови і функції втрат, що ефективно збільшує співвідношення сигнал/завада для мігрованих 2Д сейсмічних даних. Розроблено алгоритм розбиття 2Д зображень на блокові зони за розміром вікна аналізу моделі ШІ і послідувочої генерації єдиного датафрейму з оброблених моделлю вхідних даних початкового розміру та геометрії. Застосування моделі ШІ до мігрованих даних збільшує можливості з сейсмічної інтерпретації площ досліджень, а також пришвидшує роботу інтерпретаторів за рахунок активнішого застосування інструментів автоматичного/напівавтоматичного трасування горизонтів відбиття.

REFERENCES

1. M. Hauzan Nabhan (2024). Analysis of Geological Structure based on 3D Virtual Outcrop Model and Physical Properties of Rocks in Wringinanom District, Gresik Regency. *IOP Conference Series Earth and Environmental Science*, 1307(1):01, 2024. DOI: 10.1088/1755-1315/1307/1/012024
2. Nascimento, A. et al. (2023). Well-velocity variogram sensibility analysis when building geologically constrained velocity models for onshore seismic data. *Conference: 18th International Congress of the Brazilian Geophysical Society*, 2023. https://www.researchgate.net/publication/374582482_Well-velocity_variogram_sensibility_analysis_when_building_geologically_constrained_velocity_models_for_onshore_seismic_data#full-text
3. Zhang, Y.-G., Wang, Y., and Yin, J.-J. (2010). Single point high density seismic data processing analysis and initial evaluation. *Shiyou Diqu Wuli Kantan (Oil Geophys. Prospecting)*, 45 (2), 201–207. https://www.researchgate.net/publication/289786249_Single_point_high_density_seismic_data_processing_analysis_and_initial_evaluation
4. Xiao, F. et al. (2014). High-density 3D point receiver seismic acquisition and processing – a case study from the Sichuan Basin, China. *First Break*, 32 (1), 2014. DOI: <https://doi.org/10.3997/1365-2397.32.1.72598>

5. Rebert, T., Sablon, R., Vidal, N., Charrier, P., and Soubaras, R. (2012). Improving pre-salt imaging with variable-depth streamer data. In *Proc. SEG Tech. Program Expanded Abstr.*, Sep. 2012, (pp. 1–5). <https://doi.org/10.1190/segam2012-1067.1>
6. Yang, J., Zhang, Y., Yu, Y. (2021). Nested U-Net Architecture Based Image Segmentation for 3D Neuron Reconstruction. *Journal of Medical Imaging and Health Informatics*, 2021. DOI: <https://doi.org/10.1166/jmihi.2021.3379>
7. Wu, X., Liang, L., Shi, Y., and Fomel, S. (2019). FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84 (3), IM35–IM45, 2019. DOI: <https://doi.org/10.1190/geo2018-0646.1>
8. Chao Dong, Chen Change Loy, Kaiming He, Xiaoou Tang (2016). Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (Volume: 38, Issue: 2, 01 February 2016). <https://doi.org/10.48550/arXiv.1501.00092>
9. Wu, X., Geng, Z., Shi, Y., Pham, N., Fomel, S., and Caumon, G. (2020). Building realistic structure models to train convolutional neural net-works for seismic structural interpretation. *Geophysics*, 85(4), WA27–WA39, Jul. 2020. DOI: 10.1190/geo2019-0375.1
10. Wang, Z., Simoncelli, E.P., Bowik, A. (2003). “Multi-scale structural similarity for image quality assessment. *The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers*, 2003. DOI: 10.1109/ACSSC.2003.1292216

The article was received 12.12.2024 and was accepted after revision 03.03.2025

Стаття надійшла до редакції 12.12.2024 і прийнята до друку після рецензування 03.03.2025

Носков Олексій Вікторович

аспірант Інституту телекомунікацій і глобального інформаційного простору НАНУ
Адреса робоча: 03186, Україна, м. Київ, Чоколівський бульвар, 13
ORCID ID: <https://orcid.org/0000-0002-6729-0538> e-mail: a3321noskov@gmail.com

Миронцов Микита Леонідович

доктор фізико-математичних наук, старший науковий співробітник, провідний науковий співробітник Інституту телекомунікацій і глобального інформаційного простору НАН України
Адреса робоча: 03186, Україна, м. Київ, Чоколівський бульвар, 13
ORCID ID: <https://orcid.org/0000-0002-2830-8803> e-mail: myrontsov@ukr.net