

<https://doi.org/10.15407/dopovidi2024.03.011>

УДК 004.4

О.В. Носков, <https://orcid.org/0000-0002-6729-0538>

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

E-mail: a33211noskov@gmail.com

Технологія збільшення роздільної здатності мігрованих сейсмічних даних на основі використання нейронних мереж

Представлено членом-кореспондентом НАН України О.М. Трофимчуком

Розроблено і програмно реалізовано математичну модель машинного навчання на базі нейронної мережі архітектури U-net для збільшення роздільної здатності та збільшення значення сигнал/завада для полів сейсмічної зйомки 2D і 3D досліджень із застосуванням синтетичного набору тренувальних даних. Описано будову моделі, наведено метрики якості тренування/валідації. 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, U-net архітектура, функція втрат.

Вступ. Україна стрімко розвиває свою нафтогазову галузь з метою здобуття енергетичної незалежності. Ключову роль в процесі пошуку та розвідки нових нафтогазових покладів становить побудова геолого-технологічної 3D моделі досліджуваної площі, яка спирається на сейсмічні дані [1]. Нажаль, в переважній кількості випадків, якість сейсмічних даних не є оптимальною для вирішення поставленої задачі [2]. Це обумовлено рядом причин:

- один зі основних нафтогазових басейнів України — Дніпровсько-Донецька западина, що розташована в щільно-заселеній частині країни;
- ведення робіт з дорозвідки родовищ має істотний вплив на якість сейсмічних даних та привносить антропогенний фактор інфраструктури будь-якого активного родовища;
- різна якість польових матеріалів та міграції сейсмічних зйомок, що зумовлює зменшення співвідношення сигнал/завада.

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

Ц и т у в а н н я: Носков О.В. Технологія збільшення роздільної здатності мігрованих сейсмічних даних на основі використання нейронних мереж. *Допов. Нац. акад. наук Укр.* 2024. № 3. С. 11—17. <https://doi.org/10.15407/dopovidi2024.03.011>

© Видавець ВД «Академперіодика» НАН України, 2024. Стаття опублікована за умовами відкритого доступу за ліцензією CC BY-NC-ND (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

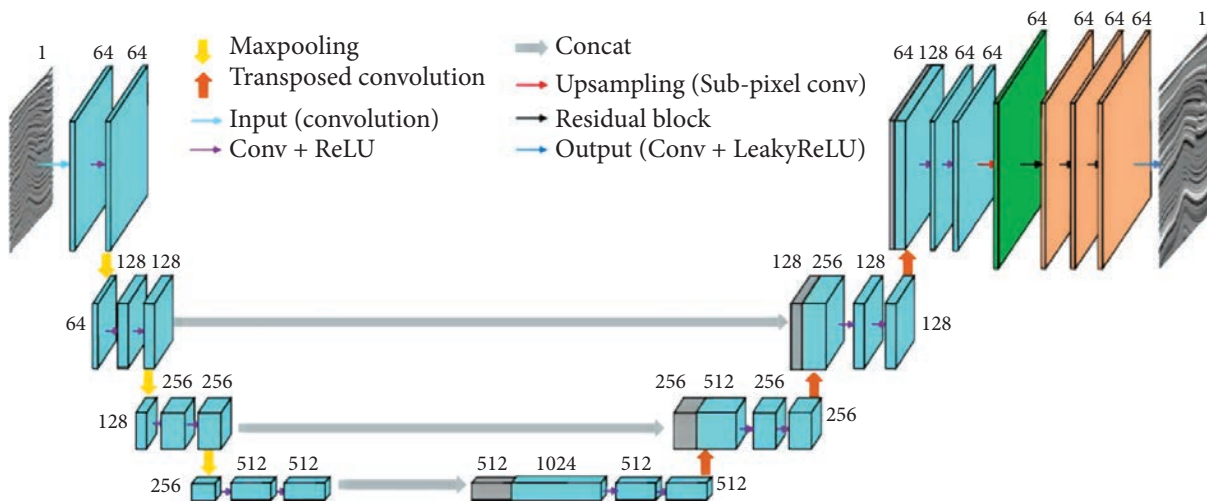


Рис. 1. Схематична будова використаної нейронної мережі

Якість геологічних структурних побудов, а також розповсюдження колекторських властивостей гірських порід — це основні задачі, які ставляться на етапі сейсмічної інтерпретації. Вирішення цих задач залежить від якості як свердловинного матеріалу, так і мігрованих сейсмічних даних.

Покращенню інформативної частини сейсмічних даних присвячено ряд наукових праць (зокрема [3—5]), проте більшість із них сфокусовані на дослідженні геологічних умов, що сильно відрізняються від наявних в Україні за глибиною залягання. В цій роботі пропонується розв’язання таких задач за допомогою використання згорткових нейронних мереж [6] (НМ), що набули широкого розвитку за останні роки.

Як відомо, для якісного тренування нейронних мереж (НМ) потрібна значна кількість якісних зображень, позбавлених шумів, що в реальній природі досить важко отримати. Неякісне тренування НМ призводить до неякісного розв’язання поставленої задачі. У роботах [7, 8] пропонується застосування якісних сучасних матеріалів з яскраво-вираженими порушеннями в якості джерела даних для тренування та валідації моделі, проте використання подібних результатів може по-перше, бути недостатнім для тренування моделі, а по-друге, є питання стосовно якості прогнозу моделі — бо функція середньої абсолютної похибки (MSE loss function $\ell 1$), яка зазвичай використовується згортковими мережами, прагне до «згладженого» результату в зоні існування порушень, що в підсумку знижує якість фінальної сейсмічної інтерпретації.

Для вирішення першої частини задачі [9] було згенеровано 800 синтетичних сейсмічних кубів, з яких було екстраговано 3200 різних 2D зображень, які і сформували базу даних для навчання моделі.

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

Архітектура НМ. Використана мережа має три блоки кодувальника (encoder block) та відповідно три блоки декодувальника (decoder block), що поєднуються зв’язковим блоком (bridge layer), який функціонально потрібен для переносу вхідної інформації до шарів декодера (Upsampling layers) для захвату та збереження ключових паттернів навчених у попередніх шарах, забезпечуючи тим самим факт, що інформацію буде правильно відтворено

в наступних. Структурно рівень зв'язкового блоку 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 [10].

Окремо слід відмітити, що для покращення роботи моделі в якості функції активізації було використано модифіковану ReLU (*Rectified Linear Unit*), а саме leaky ReLU для усунення проблем із зникаючим градієнтом — градієнти для значень, більших за нуль 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 приводить їх до нульових значень, що зумовлює проблеми “відмираючих нейронів”. Головний недолік обох функцій — ненормалізованість. Його було покрито за рахунок нормалізації тренувального та валідаційного наборів даних із тим, що при роботі нейронної мережі з реальними даними, останні будуть також нормалізовані на початку навчання та денормалізовані при перетворенні масиву даних у робочі файли (наприклад, *.SEGY).

Результати дослідження та їх аналіз. Модель складається з трьох шарів, вона поступово збільшує кількість малюнків в ітерації в послідовності 1 — 64 — 128 — 512. Була апробована версія моделі з чотирьох шарів, а саме до 1024, але при значному збільшенні часу розрахунку моделі, а саме з 57 мс (64 GB RAM/32 GB Nvidia RTX 3060) на епоху у випадку тришарової моделі і 76 мс у випадку чотиришарової, якісні показники прогнозу моделі вказують ріст на 2 %. Тому раціонально використовувати глибшу мережу вже на фінальній стадії імплементації моделі до реальних даних, зекономивши час на ітеративну адаптацію коду з використанням тришарової моделі.

Вирішальний вплив на якість роботи згорткової нейронної мережі має тип функції втрат, обраний при компіляції моделі.

Рішення подібних задач активно досліджується [11, 12] 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 для оцінки якості навчання нейронної мережі:

- ℓ_1_loss
- ℓ_2_loss
- PSNR
- Pixel MSE

Мережа навчається 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 так:

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

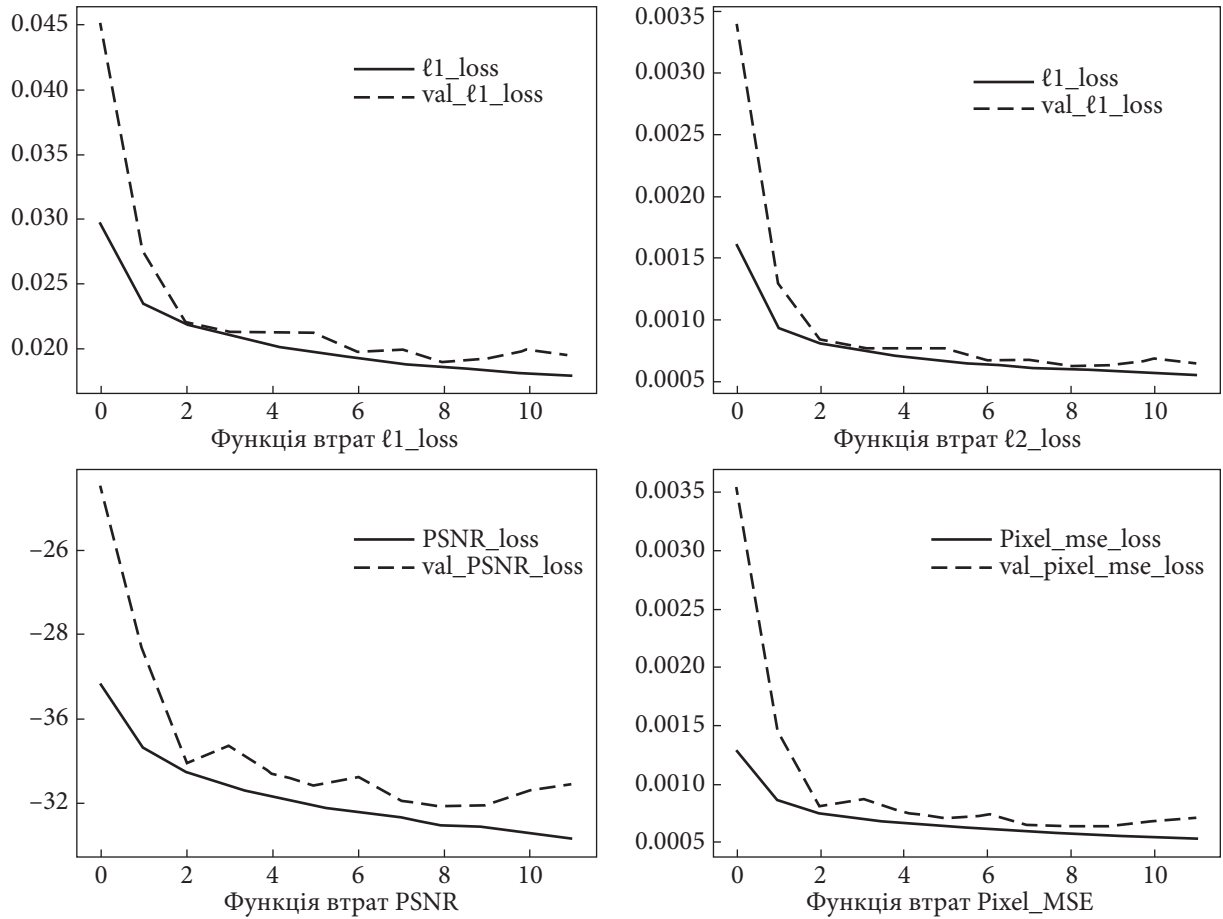


Рис. 2. Результати навчання моделі із застосуванням різних функцій втрат

де N — кількість пікселів; I_{SR} — зображення низької роздільної здатності; I_{HR} — зображення високої роздільної здатності.

Однак на практиці нейронна мережа, що навчена використовувати лише $l1_loss$, генеруватиме зображення високої роздільної здатності з гладкими текстурами, що не є прийнятними для подальшого процесу робіт з сейсмічної інтерпретації через втрату окремих геологічних подій [9], які локально розташовані в хвильовому полі. Причина полягає в тому, що $l1_loss$ мінімізує єдину піксельну відстань між результатом навчання моделі і метою та ігнорує текстурні елементи.

Вирішення другої частини завдання, а саме заміни стандартної $l1$ функції відбувалось ітеративно [10], з контролем результатів роботи моделі за використаної функції втрат. Фінальне рішення — застосування пікового співвідношення сигнал-завада (PSNR loss function), яке краще відображає кількість сигналів, що мають зашумлену природу, а відтак, має бути змінений в ході навчання моделі:

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




Рис. 3. Співвідношення спектральних показників наборів даних для трьох різних зразків з набору даних. Червоний — вхідні дані низької роздільної здатності, сині — прогноз моделі

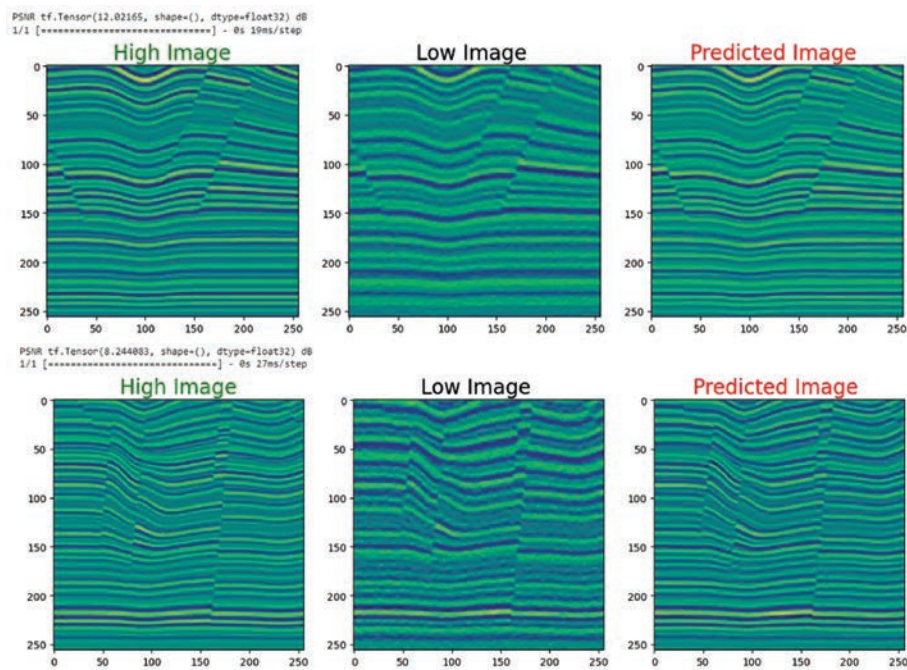


Рис. 4. Результат роботи моделі машинного навчання. Зліва — очікуваний результат, в центрі — вхідні дані для роботи моделі, справа — результат прогнозу. Значення PSNR вказують на відносний рівень впевненості прогнозу

Метрики роботи моделі з вказаною функцією втрат зображено на рис. 2.

Порівняння графіків співвідношення амплітуда/частота для даних з низькою просторовою роздільною здатністю і прогнозних даних, а також значення функції втрат PSNR вказує на високий рівень відтворення вхідних сейсмічних знімків високої роздільної здатності, що і було метою моделі III (рис. 3, 4).

Презентована робота виконується в Україні вперше, в світовій практиці подібні дослідження були виконані і представлені [5] в рамках конференції AAPG, 2020 р.

Наступний крок розвитку проекту полягатиме в трансформації сейсмічного набору даних у робочому форматі *.SEGҮ в матрицю тензорів, поділ її на направлених зрізів, які називаються інлайнами і крослайнами на розмірність 2D зображень, використаних при побудові моделі і зворотна трансформація зміненої матриці в похідний формат даних.

Висновки. На базі публічних синтетичних даних побудовано нейронну мережу, а також підібрано оптимальні налаштування її блокової будови і функції втрат, що ефективно збільшує співвідношення сигнал/завада для мігрованих сейсмічних даних і таким чином збільшує можливості для сейсмічної інтерпретації площі досліджень.

ЦИТОВАНА ЛІТЕРАТУРА

1. Nabhan M. Hauzan et al. Analysis of Geological Structure based on 3D Virtual Outcrop Model and Physical Properties of Rocks in Wringinanom District, Gresik Regency, IOP Conf. Series Earth and Environmental Science. 2024. **1307**, № 1. <https://doi.org/10.1088/1755-1315/1307/1/012024>
2. Nascimento A. et al. Well-velocity variogram sensibility analysis when building geologically constrained velocity models for onshore seismic data, Conf.: 18th Int. Congress of the Brazilian Geophysical Society, 2023.
3. Zhang Y.-G., Wang Y., Yin J.-J. Single point high density seismic data processing analysis and initial evaluation. Shiyou Diqiu Wuli Kantan (Oil Geophys. Prospecting). 2010. **45**, № 2. P. 201—207.
4. Xiao F. et al. High-density 3D point receiver seismic acquisition and processing—a case study from the Sichuan Basin, China. *Firs t Break*. 2014. **32**, № 1. <https://doi.org/10.3997/1365-2397.32.1.72598>
5. Rebert T., Sablon R., Vidal N., Charrier P., Soubaras R. Improving pre-salt imaging with variable-depth streamer data. Proc. SEG Tech. Program Expanded Abstr., Sep. 2012. P. 1—5.
6. Yang J., Zhang Y., Yu Y. Nested U-Net Architecture Based Image Segmentation for 3D Neuron Reconstruction. *J. Medical Imaging and Health Informatics*. 2021. <https://doi.org/10.1166/jmih.2021.3379>
7. Lu P., Morris M., Brazell S., Comiskey C., Xiao Y. Using generative adversarial networks to improve deep-learning fault interpretation networks. *Lead. Edge*. 2018. **37**, № 8. P. 578—583. <https://doi.org/10.1190/tle37080578.1>
8. Lim B., Son S., Kim H., Nah S., Lee K.M. Enhanced deep residual networks for single image super-resolution. Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW). Jul. 2017. P. 136—144.
9. Wu X., Liang L., Shi Y., Fomel S. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*. 2019. **84**, № 3. P. IM35—IM45. <https://doi.org/10.1190/geo2018-0646.1>
10. Wu X., Geng Z., Shi Y., Pham N., Fomel S., Caumon G. Building realistic structure models to train convolutional neural net-works for seismic structural interpretation. *Geophysics*. 2020. **85**, № 4. P. WA27—WA39. <https://doi.org/10.1190/geo2018-0646.1>
11. Недзельський О.Ю., Лашевська Н. О. Реставрація зображень методом Super resolution з використанням згорткових нейронних мереж. *Вісник НТУУ “КПІ”. Радіотехніка, радіоапаратобудування*. 2023. **91**. P. 79—86. <https://doi.org/10.20535/RADAP.2023.91.79-86>
12. Garcia-Garcia A., Orts-Escolano S., Oprea S., Villena-Martinez V., Garcia-Rodriguez J. A review on deep learning techniques applied to semantic segmentation. 2017, arXiv:1704.06857. <https://doi.org/10.48550/arxiv.org/abs/1704.06857>

Надійшло до редакції 10.03.2024

REFERENCES

1. Nabhan, M. Hauzan. (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, No. 1. <https://doi.org/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 Int. Congress of the Brazilian Geophysical Society.

3. Zhang, Y.-G., Wang, Y. & Yin, J.-J. (2010). Single point high density seismic data processing analysis and initial evaluation. *Shiyou Diqiu Wuli Kantan (Oil Geophys. Prospecting)*, 45, No. 2, pp. 201-207.
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, No. 1. <https://doi.org/10.3997/1365-2397.32.1.72598>
5. Rebert, T., Sablon, R., Vidal, N., Charrier, P. & Soubaras, R. (2012). Improving pre-salt imaging with variable-depth streamer data. *Proc. SEG Tech. Program Expanded Abstr., Sep.*, pp. 1-5.
6. Yang, J., Zhang, Y., Yu, Y. (2021). Nested U-Net Architecture Based Image Segmentation for 3D Neuron Reconstruction. *J. Medical Imaging and Health Informatics*. <https://doi.org/10.1166/jmihi.2021.3379>
7. Lu, P., Morris, M., Brazell, S., Comiskey, C. & Xiao, Y. (2018). Using generative adversarial networks to improve deep-learning fault interpretation networks. *Lead. Edge*, 37, No. 8, pp. 578-583. <https://doi.org/10.1190/tle37080578.1>
8. Lim, B., Son, S., Kim, H., Nah, S. & Lee, K. M. (2017). Enhanced deep residual networks for single image super-resolution. *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, pp. 136-144.
9. Wu, X., Liang, L., Shi, Y. & Fomel, S. (2019). FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84, No. 3, pp. IM35—IM45. <https://doi.org/10.1190/geo2018-0646.1>
10. Wu, X., Geng, Z., Shi, Y., Pham, N., Fomel, S. & Caumon, G. (2020). Building realistic structure models to train convolutional neural networks for seismic structural interpretation. *Geophysics*, 85, No. 4, pp. WA27-WA39. <https://doi.org/10.1190/geo2018-0646.1>
11. Nedzelskyi, O. Y. & Lashchevska, N. O. (2023) Super-Resolution Image Restoration Using Convolutional Neural Network. *Visnyk NTUU KPI Seriiia — Radiotekhnika Radioaparotobuduvannia*, 91, pp. 79-86 (in Ukrainian). <https://doi.org/10.20535/RADAP.2023.91.79-86>
12. Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V. & Garcia-Rodriguez, J. (2017). A review on deep learning techniques applied to semantic segmentation. *arXiv:1704.06857*. <https://doi.org/10.48550/arxiv.org/abs/1704.06857>

Received 10.03.2024

O.V. Noskov, <https://orcid.org/0000-0002-6729-0538>

Institute of Telecommunications and Global Information Space of the NAS of Ukraine, Kyiv, Ukraine

E-mail: a33211noskov@gmail.com

NEURAL NETWORK-BASED SEISMIC RESOLUTION ENHANCEMENT TECHNOLOGY

The paper contains description of a U-net architecture-based machine learning model created for seismic resolution enhancement and noise reduction. The presentation includes a brief explanation of the choice of publicly available synthetic data for training and verification purposes. Apart from architecture blocks description, the author describes variations of the loss functions used as metrics to verify the model's performance.

Keywords: *machine learning model, neural network, U-net architecture, loss function.*