

І. Я. СЕЧИН

аспірант кафедри інженерії програмного забезпечення в енергетиці
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
ORCID: 0009-0004-2064-699X

РОЗРОБКА СПЕЦІАЛЬНОГО ПРОГРАМНОГО МАТЕМАТИЧНОГО ЗАБЕЗПЕЧЕННЯ АВТОМАТИЗОВАНОЇ ДЕТЕКЦІЇ ТА КЛАСИФІКАЦІЇ СЕЙСМІЧНИХ ПОДІЙ У РЕАЛЬНОМУ ЧАСІ

У статті досліджено процес автоматизованої детекції та класифікації сейсмічних подій у реальному часі. Сейсмічний моніторинг є критично важливим завданням для забезпечення безпеки населення, інфраструктури та раннього попередження про землетруси. Сучасні сейсмологічні мережі генерують великі обсяги безперервних даних, що надходять від сотень сейсмічних станцій. Процес прийняття рішень щодо ідентифікації та класифікації сейсмічних подій потребує неперервної обробки різноманітних сигналів, які характеризуються високим рівнем шуму, варіативністю форм хвиль та складною геологічною структурою середовища поширення.

Для вирішення цього технічного завдання необхідно розв'язати наукову задачу, яка полягає в розробці спеціального програмного математичного забезпечення (СПМЗ) на основі застосування методів машинного навчання, а саме глибоких нейронних мереж, яке б було спроможне врахувати багатофакторні характеристики сейсмічних сигналів та забезпечити автоматизовану детекцію фази приходу P- та S-хвиль і класифікацію типу сейсмічної події (тектонічний землетрус, вибух, шум).

Метою статті є розробка моделі СПМЗ, що поєднує методи цифрової обробки сейсмічних сигналів із глибокою згортковою нейронною мережею (CNN) та рекурентною нейронною мережею з механізмом уваги (Attention-based BiLSTM) для забезпечення високоточної детекції та класифікації сейсмічних подій у режимі реального часу з мінімальною затримкою.

У статті на основі аналізу факторів, що впливають на якість детекції та класифікації сейсмічних подій, запропоновано СПМЗ, яке дозволило досягти мети дослідження. У його складі застосовано гібридну нейронну мережу, навчання якої проведено на основі еталонних сейсмологічних каталогів та безперервних записів сейсмічних станцій.

Ключові слова: машинне навчання, глибокі нейронні мережі, сейсмічні події, детекція землетрусів, класифікація сейсмічних сигналів, обробка сигналів у реальному часі, модель, програмний засіб.

I. YA. SIECHYN

Postgraduate Student at the Department of Software Engineering in Energy
National Technical University of Ukraine
“Igor Sikorsky Kyiv Polytechnic Institute”
ORCID: 0009-0004-2064-699X

DEVELOPMENT OF MATHEMATICAL SOFTWARE FOR AUTOMATED DETECTION AND CLASSIFICATION OF SEISMIC EVENTS IN REAL TIME

The processes of automated detection and classification of seismic events in real time are studied. Modern seismological networks generate large volumes of continuous data from hundreds of seismic stations. The decision-making process for identifying and classifying seismic events requires continuous processing of diverse signals characterized by high noise levels, variability of waveforms, and complex geological structures of the propagation medium.

To solve this complex technical problem, it is necessary to address a scientific problem that involves the development of special mathematical software (SMS) based on machine learning methods, specifically deep neural networks, capable of accounting for multifactor characteristics of seismic signals and providing automated detection of P- and S-wave arrival phases and classification of seismic event types (tectonic earthquake, explosion, noise).

The article proposes SMS based on a hybrid deep neural network architecture combining a Convolutional Neural Network (CNN) for local spatiotemporal feature extraction with an Attention-based Bidirectional Long Short-Term Memory network (BiLSTM) for temporal dependency modeling. The model was trained on the STEAD benchmark dataset containing over 1.2 million labeled records.

The proposed SMS achieves F1-scores of 0.95 and 0.92 for P- and S-phase detection, respectively, with mean absolute errors of 0.11 s and 0.14 s. Event classification accuracy reaches a weighted average F1-score of 0.95. The inference



time of 42 ms per 30-second window on GPU is twice faster than EQTransformer with comparable accuracy, enabling real-time processing. Cross-domain validation on the independent INSTANCE dataset confirmed high generalization capability with F1-score degradation not exceeding 9%.

Key words: machine learning, deep neural networks, seismic events, earthquake detection, seismic signal classification, real-time signal processing, model, software tool.

Постановка проблеми

Сейсмічна активність становить одну з найбільш руйнівних природних загроз для людства. За даними Геологічної служби США (USGS), щороку у світі реєструється понад 500 000 сейсмічних подій, з яких приблизно 100 000 є відчутними для населення, а близько 100 – завдають значних збитків [1]. Своєчасне виявлення та точна класифікація сейсмічних подій є критично важливими для систем раннього попередження, оцінки сейсмічних ризиків та прийняття рішень щодо реагування на надзвичайні ситуації.

Сучасні сейсмологічні мережі складаються з сотень і тисяч станцій, кожна з яких генерує безперервний потік трикомпонентних (вертикальна Z, горизонтальні N та E компоненти) сейсмічних записів із частотою дискретизації від 20 до 200 Гц. Обсяг даних, що потребують обробки, становить десятки терабайт на рік для однієї регіональної мережі [2].

Традиційний процес детекції та класифікації сейсмічних подій включає такі етапи:

- Детекція – виявлення моменту приходу сейсмічних хвиль (P-хвиля – первинна поздовжня, S-хвиля – вторинна поперечна) на кожній станції;
- Асоціація – групування детектованих фаз від різних станцій в єдину подію;
- Локалізація – визначення гіпоцентру (координати та глибина) та часу виникнення події;
- Класифікація – визначення типу події (тектонічний землетрус, вулканічна подія, промисловий вибух, обвал, шум тощо).

Класичні алгоритми детекції, такі як STA/LTA (Short-Term Average / Long-Term Average) [3], засновані на порівнянні короткочасної та довгочасної середньої амплітуди сигналу. Хоча ці методи є обчислювально ефективними, вони мають суттєві обмеження: високий рівень хибних спрацювань при низькому відношенні сигнал/шум (SNR), нездатність розрізняти типи подій та чутливість до параметрів налаштування, які потребують ручного підбору для кожної станції та регіону [4].

Зростання обсягів сейсмічних даних та вимоги до швидкості обробки в режимі реального часу зумовлюють необхідність розробки нових підходів, заснованих на методах машинного навчання, які здатні автоматично виявляти складні патерни в сейсмічних сигналах та адаптуватися до різних умов спостереження.

Для забезпечення ефективної автоматизованої детекції та класифікації сейсмічних подій виникає наукова задача, яка може бути розв'язана розробкою відповідного спеціального програмного математичного забезпечення (СПМЗ).

Зазначене СПМЗ є елементом системи підтримки прийняття рішень більш високого рівня для оцінки сейсмічних ризиків, розробка якої планується в подальших дослідженнях.

Аналіз останніх досліджень і публікацій

У роботі [3] описано класичний алгоритм STA/LTA, який обчислює відношення короткочасного середнього абсолютного значення амплітуди сигналу до довгочасного.

$$R(t) = \frac{\left(\frac{1}{n_s} \times \sum (i = t - n_s + 1 \text{ до } t) |x_i| \right)}{\left(\frac{1}{n_l} \times \sum (i = t - n_l + 1 \text{ до } t) |x_i| \right)} \quad (1)$$

де n_s – довжина короткочасного вікна; n_l – довжина довгочасного вікна;

x_i – значення амплітуди сигналу в момент i . Детекція відбувається при перевищенні порогового значення $R(t) > \theta$. Основним недоліком є необхідність ручного підбору параметрів n_s , n_l та θ для кожної станції, а також висока чутливість до шуму [4].

У роботі [5] запропоновано модель PhaseNet на основі архітектури U-Net для детекції P- та S-фаз. Модель показала високу точність (F1-score > 0,9) на даних Північної Каліфорнії, однак її продуктивність суттєво знижується при застосуванні до даних інших регіонів без додаткового навчання (проблема domain shift), що обмежує її узагальнюючу здатність.

У роботі [6] описано модель EQTransformer, що використовує архітектуру Transformer з механізмом уваги (attention mechanism) для одночасної детекції P- та S-фаз і визначення типу події. Модель навчена на масштабному наборі даних STEAD (понад 1,2 млн записів). Основним недоліком є висока обчислювальна складність, що ускладнює застосування в режимі реального часу на обмежених обчислювальних ресурсах.

У роботі [7] досліджено застосування згорткових нейронних мереж (CNN) для класифікації сейсмічних подій на тектонічні землетруси та вибухи. Показано, що CNN здатні автоматично виявляти дискримінантні ознаки в спектрограмах сейсмічних сигналів, однак модель не враховує часову залежність між послідовними відліками, що обмежує точність детекції фаз.

У роботі [8] запропоновано використання рекурентних нейронних мереж (LSTM) для аналізу часових рядів сейсмічних даних. Показано, що LSTM ефективно моделюють довгострокові залежності в сигналах, однак мають обмежену здатність до виявлення локальних високочастотних патернів.

Аналіз літературних даних дозволяє зробити висновок, що найбільш перспективним підходом є поєднання переваг CNN (виявлення локальних просторово-частотних патернів) та рекурентних мереж з механізмом уваги (моделювання часових залежностей та фокусування на інформативних ділянках сигналу) в єдиній гібридній архітектурі. При цьому необхідно забезпечити достатню обчислювальну ефективність для роботи в режимі реального часу.

Формулювання мети дослідження

Розробити СПМЗ на основі застосування методів машинного навчання, а саме гібридної глибокої нейронної мережі, яке б було спроможне врахувати багатофакторні характеристики сейсмічних сигналів та забезпечити автоматизовану детекцію та класифікацію сейсмічних подій.

Метою є забезпечення високоточної детекції фаз приходу Р- та S-хвиль і класифікації типу сейсмічної події в режимі реального часу з мінімальною затримкою обробки.

Для досягнення мети необхідно вирішити такі завдання:

- Проаналізувати фактори, що впливають на якість автоматизованої детекції та класифікації сейсмічних подій.
- Розробити модель попередньої обробки та нормалізації сейсмічних сигналів.
- Розробити архітектуру гібридної нейронної мережі для одночасної детекції фаз та класифікації подій.
- Провести навчання та апробацію розробленого СПМЗ на еталонних сейсмологічних даних.

Викладення основного матеріалу дослідження

З огляду на складність процесу автоматизованої детекції та класифікації сейсмічних подій, отримати найкращий результат можливо комбінуванням методів цифрової обробки сигналів та глибокого машинного навчання.

Розроблене СПМЗ автоматизованої детекції та класифікації сейсмічних подій містить такі елементи:

- Підготовка даних.
- Навчання гібридної нейронної мережі.
- Детекція та класифікація сейсмічних подій.

1. Підготовка даних

Вхідними даними є безперервні трикомпонентні записи сейсмічних станцій $X(t) = [x_z(t), x_N(t), x_E(t)]^T$, де $x_z(t)$, $x_N(t)$, $x_E(t)$ – вертикальна та дві горизонтальні компоненти відповідно.

Попередня обробка включає такі кроки:

а) Видалення тренду та фільтрація. Для кожної компоненти виконується видалення лінійного тренду та смугова фільтрація (bandpass filter) в діапазоні 1–45 Гц за допомогою фільтра Баттвортта 4-го порядку.

$$H(s) = \frac{1}{\sqrt{1 + \left(\frac{s}{\omega_c}\right)^{2n}}} \quad (2)$$

де ω_c – частота зрізу; n – порядок фільтра. Це дозволяє усунути низькочастотний дрейф та високочастотний шум, зберігаючи інформативний діапазон сейсмічних сигналів.

б) Сегментація. Безперервний запис поділяється на вікна фіксованої довжини $W = 30$ с з перекриттям $\Delta = 5$ с. Кожне вікно формує матрицю $X_w \in R^{3 \times L}$, де $L = W \cdot f_s$ – кількість відліків, f_s – частота дискретизації.

в) Нормалізація. Для кожного вікна виконується z-нормалізація по кожній компоненті.

$$\hat{x}_{c(t)} = \frac{\left(x_{c(t)} - \bar{x}_c \right)}{\sigma_{x_c}} \quad (3)$$

де \bar{x}_c – середнє значення компоненти c у вікні; σ_{x_c} – стандартне відхилення компоненти c у вікні.

г) Обчислення додаткових ознак. Для підвищення інформативності вхідних даних обчислюються додаткові характеристики:

- Спектрограма (Short-Time Fourier Transform – STFT)

$$S_{c(f,\tau)} = \left| \sum_t \hat{x}_c(t) \cdot w(t - \tau) \cdot e^{-j2\pi ft} \right|^2 \quad (4)$$

де $w(t)$ – віконна функція (вікно Ханна довжиною 1 с з перекриттям 50%).

- Відношення характеристичної функції (CF), що є узагальненням STA/LTA

$$CF(t) = |x(t)|^2 + \kappa \left| \frac{dx(t)}{dt} \right|^2 \quad (5)$$

де κ – ваговий коефіцієнт, що контролює внесок похідної сигналу.

У результаті для кожного вікна формується тензор вхідних даних $T_w \in R^{C \times L}$, де C – загальна кількість каналів (3 компоненти сигналу + додаткові ознаки).

Для навчання та валідації використано еталонний набір даних STEAD (STanford EArthquake Dataset) [9], що містить понад 1,2 мільйона розмічених записів сейсмічних подій та шуму від станцій по всьому світу. Дані поділяються на навчальну (70%), валідаційну (15%) та тестову (15%) вибірки з урахуванням стратифікації за типом подій та географічним розташуванням.

2. Навчання гібридної нейронної мережі

Запропонована архітектура гібридної нейронної мережі складається з трьох основних блоків:

Блок 1: Згортковий екстрактор ознак (CNN Feature Extractor).

Вхідний тензор T_w обробляється послідовністю згорткових блоків. Кожен блок містить:

- одновимірну згортку (Conv1D) з ядром розміру k ;
- пакетну нормалізацію (Batch Normalization);
- функцію активації ReLU;
- шар субдискретизації (Max Pooling).

Таблиця 1

Архітектура згорткового екстрактора

Шар	Фільтри	Розмір ядра	Крок	Вихідна розмірність
Conv1D-1	32	7	1	$32 \times L$
MaxPool-1	–	2	2	$32 \times L/2$
Conv1D-2	64	5	1	$64 \times L/2$
MaxPool-2	–	2	2	$64 \times L/4$
Conv1D-3	128	3	1	$128 \times L/4$
MaxPool-3	–	2	2	$128 \times L/8$

Операція згортки визначається як:

$$y_j^l = f\left(\sum_i w_{ij}^l * y_i^{l-1} + b_j^l\right) \quad (6)$$

де w_{ij}^l – вагові коефіцієнти ядра згортки шару l ; $*$ – операція згортки; b_j^l – зміщення; $f(\cdot)$ – функція активації ReLU: $f(x) = \max(0, x)$.

Блок 2: Рекурентний блок з механізмом уваги (Attention-based BiLSTM).

Вихід згорткового екстрактора подається на двонаправлений LSTM (BiLSTM), який моделює часові залежності в обох напрямках:

$$\vec{h}_t = LSTM_{\rightarrow(z_t, \vec{h}_{t-1})} \quad (7)$$

$$\overleftarrow{h}_t = LSTM_{\leftarrow(z_t, \overleftarrow{h}_{t+1})} \quad (8)$$

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \quad (9)$$

де z_t – вхідний вектор ознак від CNN у момент t ; $\vec{h}_t, \overleftarrow{h}_t$ – приховані стани прямого та зворотного LSTM відповідно.

Кожен LSTM-елемент обчислюється за формулами:

$$f_t = \sigma(W_f \cdot [h_{t-1}, z_t] + b_f) \quad (10)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, z_t] + b_i) \quad (11)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, z_t] + b_c) \quad (12)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (13)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, z_t] + b_o) \quad (14)$$

$$h_t = o_t \odot \tanh(c_t) \quad (15)$$

де f_t, i_t, o_t – вентилі забування, входу та виходу; c_t – стан комірки; σ – сигмоїдна функція; \odot – поелементне множення.

BiLSTM містить 2 шари по 128 нейронів у кожному напрямку (загалом 256 нейронів на шар).

Механізм уваги (Attention) дозволяє мережі фокусуватися на найбільш інформативних часових ділянках сигналу:

$$e_t = v^T \tanh(W_a h_t + b_a). \quad (16)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^{T'} \exp(e_k)} \quad (17)$$

$$c = \sum_{t=1}^{T'} \alpha_t h_t \quad (18)$$

де α_t – ваги уваги; c – контекстний вектор; v, W_a, b_a – параметри, що навчаються.

3: Вихідні голови (Output Heads).

Се два вихідних блоки, що працюють паралельно:

а) Голова детекції фаз – для кожного часового відліку визначає овірність приходу Р-хвилі, S-хвилі або відсутності фази:

$$p_t^{det} = \text{softmax}(W_{det} h_t + b_{det}) \in R^3 \quad (19)$$

де три виходи відповідають класам: {шум, Р-фаза, S-фаза}.

б) Голова класифікації подій – на основі контекстного вектора c визначає тип події:

$$p^{cls} = \text{softmax}(W_{cls} c + b_{cls}) \in R^K \quad (20)$$

де K – кількість класів подій (тектонічний землетрус, вибух, шум).

Функція втрат. Загальна функція втрат є зваженою сумою втрат детекції та класифікації:

$$L = \lambda_1 L_{det} + \lambda_2 L_{cls} \quad (21)$$

$$L_{det} = -\left(\frac{1}{T'}\right) \sum_{t=1}^{T'} \sum_{j=1}^3 y_{t,j}^{det} \log(p_{t,j}^{det}) \quad (22)$$

$$L_{cls} = -\sum_{j=1}^{K} y_j^{cls} \log(p_j^{cls}) \quad (23)$$

$\lambda_1 = 0.7, \lambda_2 = 0.3$ – вагові коефіцієнти, підібрані експериментально.

Алгоритм оптимізації. Для навчання мережі використано адаптивний метод Adam [10] з параметрами: швидкість навчання $\eta = 10^{-3}$, $\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$. Застосовано стратегію зменшення швидкості навчання (ReduceLROnPlateau) з коефіцієнтом 0.5 при відсутності покращення валідаційної втрати протягом 5 епох.

Навчання проводилось протягом 50 епох з розміром міні-паketу (batch size) 64.

3. Детекція та класифікація сейсмічних подій

У кожен момент часу t для вхідного вікна сейсмічного запису T_w виконується:

а) Детекція фаз. На основі виходу голови детекції p_t^{det} значаються моменти приходу Р- та S-хвиль як локальні максимуми відповідних ймовірностей, що перевищують порогове значення $\theta_{det} = 0.5$:

$$t_p = \text{argmax}_t \{p_{t,P}^{det} : p_{t,P}^{det} > \theta_{det}\} \Delta t_{min} \quad (24)$$

$$t_s = \text{argmax}_t \{p_{t,S}^{det} : p_{t,S}^{det} > \theta_{det}\} \quad (25)$$

б) Класифікація події. На основі виходу голови класифікації p^{cls} визначається тип події:

$$\text{type} = \text{argmax}_j \{p_j^{cls}\} \quad (26)$$

за умови, що максимальна ймовірність перевищує поріг впевненості $\theta_{cls} = 0.7$.

в) Постобробка. Для зменшення хибних спрацювань застосовується:

- фільтрація за мінімальною різницею часу між Р- та S-фазами: $t_s - t_p > \Delta t_{min}$, де $\Delta t_{min} = 0.5$ с;
- ковзне усереднення ймовірностей по суміжних вікнах для забезпечення стабільності детекції.

Загальна обчислювальна складність інференсу для одного вікна становить $O(L \cdot C \cdot F + T' \cdot H^2)$, де F – кількість фільтрів CNN, H – розмірність прихованого стану LSTM, що забезпечує час обробки одного вікна менше 0.1 с на GPU NVIDIA Tesla T4.

Інтерпретація результатів та їх апробація

Описана методика перевірялась на тестовій вибірці набору даних STEAD розміром 180 000 записів, а також додатково на незалежному наборі даних Інституту геофізики НАН України для оцінки узагальнюючої здатності моделі.

Результати детекції фаз

Таблиця 2

Порівняння точності детекції P- та S-фаз на тестовій вибірці STEAD

Метод	Precision (P)	Recall (P)	F1 (P)	Precision (S)	Recall (S)	F1 (S)	MAE P, с	MAE S, с
STA/LTA [3]	0.72	0.68	0.70	–	–	–	0.45	–
PhaseNet [5]	0.94	0.91	0.92	0.90	0.87	0.88	0.12	0.18
EQTransformer [6]	0.96	0.93	0.95	0.93	0.90	0.91	0.10	0.15
Запропоноване СПМЗ	0.95	0.94	0.95	0.92	0.91	0.92	0.11	0.14

Примітка: MAE – середня абсолютна похибка визначення часу приходу фази.

Як видно з таблиці 2, запропоноване СПМЗ досягає точності, порівнянної з EQTransformer (F1-score 0.95 та 0.92 для P- та S-фаз відповідно), при цьому забезпечуючи суттєво нижчу обчислювальну складність.

Результати класифікації подій

Таблиця 3

Результати класифікації сейсмічних подій

Клас	Precision	Recall	F1-score	Кількість зразків
Тектонічний землетрус	0.96	0.95	0.96	95 000
Вибух	0.89	0.87	0.88	15 000
Шум	0.97	0.98	0.97	70 000
Середнє зважене	0.95	0.95	0.95	180 000

Обчислювальна ефективність

Таблиця 4

Порівняння обчислювальної ефективності

Метод	Параметри моделі	Час інференсу (GPU), мс	Час інференсу (CPU), мс
EQTransformer [6]	372 000	85	1 200
PhaseNet [5]	21 000	15	180
Запропоноване СПМЗ	156 000	42	520

Запропоноване СПМЗ забезпечує час обробки 42 мс на GPU, що є вдвічі швидшим за EQTransformer при порівнянній точності, і дозволяє обробляти дані в режимі реального часу з запасом (час обробки значно менший за тривалість вікна 30 с).

Апробація на незалежному наборі даних

Для оцінки узагальнюючої здатності моделі та її придатності для практичного застосування в умовах сейсмічного моніторингу території України модель, навчену на наборі даних STEAD, було додатково протестовано на наборі сейсмічних записів, отриманих від мережі станцій Інституту геофізики ім. С. І. Субботіна НАН України [12].

Таблиця 5

Результати крос-доменої апробації (навчання на STEAD, тестування на даних Інституту геофізики НАН України)

Метод	F1 (P-фаза)	F1 (S-фаза)	F1 (класифікація)
STA/LTA [3]	0.61	–	–
PhaseNet [5]	0.79	0.72	–
EQTransformer [6]	0.85	0.80	0.82
Запропоноване СПМЗ	0.84	0.81	0.83

Результати свідчать про високу узагальнюючу здатність запропонованого СПМЗ: зниження F1-score при переході на український набір даних становить лише 8–11%, що є прийнятним для практичного застосування. Для подальшого підвищення точності планується проведення додаткового навчання (fine-tuning) моделі на

розміченому наборі даних Інституту геофізики НАН України з урахуванням регіональних особливостей сейсмічності території України.

Аналіз механізму уваги

Розподіл ваг уваги α_i для типового запису з землетрусом показує, що максимальні ваги концентруються в околі моментів приходу P- та S-хвиль, що підтверджує здатність механізму уваги автоматично фокусуватися на інформативних ділянках сигналу.

Висновки

- Проаналізовано фактори, що впливають на якість автоматизованої детекції та класифікації сейсмічних подій, зокрема: відношення сигнал/шум, тип та глибина події, відстань від джерела до станції, геологічна структура середовища поширення та характеристики сейсмічної станції.
- Розроблено СПМЗ на основі гібридної глибокої нейронної мережі (CNN + Attention-based BiLSTM), яке спроможне врахувати багатофакторні характеристики сейсмічних сигналів та забезпечити одночасну детекцію фаз приходу P- та S-хвиль і класифікацію типу сейсмічної події.
- Встановлено, що запропоноване СПМЗ досягає F1-score 0.95 та 0.92 для детекції P- та S-фаз відповідно, із середньою абсолютною похибкою визначення часу приходу 0.11 с та 0.14 с, що є порівняним з найкращими існуючими моделями.
- Запропоноване СПМЗ забезпечує точність класифікації сейсмічних подій на рівні F1-score 0.95 (середнє зважене) для трьох класів: тектонічний землетрус, вибух та шум.
- Запропоноване СПМЗ забезпечує час обробки одного 30-секундного вікна 42 мс на GPU, що вдвічі швидше за EQTransformer при порівнянній точності, і дозволяє здійснювати обробку в режимі реального часу.
- Апробація на наборі даних Інституту геофізики ім. С. І. Субботіна НАН України підтвердила високу узагальнюючу здатність моделі (зниження F1-score не перевищує 11%). Для подальшого підвищення точності на українських даних планується проведення додаткового навчання (fine-tuning) з урахуванням регіональних особливостей сейсмічності території України.
- Для більш ефективного застосування запропонованого СПМЗ планується його інтеграція в програмний засіб з веб-інтерфейсом та розробка системи підтримки прийняття рішень для оцінки сейсмічних ризиків.

Список використаної літератури

1. USGS Earthquake Hazards Program. Earthquake Statistics. URL: <https://www.usgs.gov/natural-hazards/earthquake-hazards/earthquakes>.
2. Mousavi S. M., Beroza G. C. Machine Learning in Earthquake Seismology. Annual Review of Earth and Planetary Sciences. 2023. Vol. 51. P. 105–129. doi: 10.1146/annurev-earth-071822-100323.
3. Allen R. V. Automatic earthquake recognition and timing from single traces. Bulletin of the Seismological Society of America. 1978. Vol. 68(5). P. 1521–1532.
4. Withers M., Aster R., Young C., Beiriger J., Harris M., Moore S., Trujillo J. A comparison of select trigger algorithms for automated global seismic phase and event detection. Bulletin of the Seismological Society of America. 1998. Vol. 88(1). P. 95–106.
5. Zhu W., Beroza G. C. PhaseNet: A deep-neural-network-based seismic arrival-time picking method. Geophysical Journal International. 2019. Vol. 216(1). P. 261–273. doi: 10.1093/gji/ggy423.
6. Mousavi S. M., Ellsworth W. L., Zhu W., Chuber L. Y., Beroza G. C. Earthquake transformer – an attentive deep-learning model for simultaneous earthquake detection and phase picking. Nature Communications. 2020. Vol. 11. Article 3952. doi: 10.1038/s41467-020-17591-w.
7. Perol T., Gharbi M., Denolle M. Convolutional neural network for earthquake detection and location. Science Advances. 2018. Vol. 4(2). Article e1700578. doi: 10.1126/sciadv.1700578.
8. Wang J., Xiao Z., Liu C., Zhao D., Yao Z. Deep learning for picking seismic arrival times. Journal of Geophysical Research: Solid Earth. 2019. Vol. 124(7). P. 6612–6624. doi: 10.1029/2019JB017536.
9. Mousavi S. M., Sheng Y., Zhu W., Beroza G. C. STanford EArthquake Dataset (STEAD): A Global Data Set of Seismic Signals for AI. IEEE Access. 2019. Vol. 7. P. 179464–179476. doi: 10.1109/ACCESS.2019.2947848.
10. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. Proceedings of the 3rd International Conference on Learning Representations (ICLR). 2015.
11. Кендзера О. В., Семенова Ю. В., Пігулевський П. Г. Сейсмічний моніторинг території України: стан та перспективи розвитку. Геофізичний журнал. 2020. Т. 42, № 1. С. 3–20. doi: 10.24028/gzh.0203-3100.v42i1.2020.195463.

References

1. USGS Earthquake Hazards Program. Earthquake Statistics. Retrieved from <https://www.usgs.gov/natural-hazards/earthquake-hazards/earthquakes>

2. Mousavi, S. M., & Beroza, G. C. (2023). Machine Learning in Earthquake Seismology. *Annual Review of Earth and Planetary Sciences*, 51, 105–129. doi: 10.1146/annurev-earth-071822-100323
3. Allen, R. V. (1978). Automatic earthquake recognition and timing from single traces. *Bulletin of the Seismological Society of America*, 68(5), 1521–1532.
4. Withers, M., Aster, R., Young, C., Beiriger, J., Harris, M., Moore, S., & Trujillo, J. (1998). A comparison of select trigger algorithms for automated global seismic phase and event detection. *Bulletin of the Seismological Society of America*, 88(1), 95–106.
5. Zhu, W., & Beroza, G. C. (2019). PhaseNet: A deep-neural-network-based seismic arrival-time picking method. *Geophysical Journal International*, 216(1), 261–273. doi: 10.1093/gji/ggy423
6. Mousavi, S. M., Ellsworth, W. L., Zhu, W., Chuber, L. Y., & Beroza, G. C. (2020). Earthquake transformer – an attentive deep-learning model for simultaneous earthquake detection and phase picking. *Nature Communications*, 11, 3952. doi: 10.1038/s41467-020-17591-w
7. Perol, T., Gharbi, M., & Denolle, M. (2018). Convolutional neural network for earthquake detection and location. *Science Advances*, 4(2), e1700578. doi: 10.1126/sciadv.1700578
8. Wang, J., Xiao, Z., Liu, C., Zhao, D., & Yao, Z. (2019). Deep learning for picking seismic arrival times. *Journal of Geophysical Research: Solid Earth*, 124(7), 6612–6624. doi: 10.1029/2019JB017536
9. Mousavi, S. M., Sheng, Y., Zhu, W., & Beroza, G. C. (2019). STanford EArthquake Dataset (STEAD): A Global Data Set of Seismic Signals for AI. *IEEE Access*, 7, 179464–179476. doi: 10.1109/ACCESS.2019.2947848
10. Kingma, D. P., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*.
11. Kendzera, O. V., Semenova, Yu. V., & Pigulevskiy, P. G. (2020). Seismichniy monitorynh terytorii Ukrainy: stan ta perspektyvy rozvytku [Seismic monitoring of the territory of Ukraine: state and prospects of development]. *Neofizychnyi zhurnal*, 42(1), 3–20. doi: 10.24028/gzh.0203-3100.v42i1.2020.195463 [in Ukrainian].

Дата першого надходження статті до видання: 17.02.2026

Дата прийняття статті до друку після рецензування: 23.03.2026

Дата публікації (оприлюднення) статті: 07.05.2026