

УДК 539.3:620.179.17:004.8

## МЕТОДИ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АКУСТИКО-ЕМІСІЙНОГО ДІАГНОСТУВАННЯ СТАДІЙ РУЙНУВАННЯ (Огляд). Ч. 2: ШТУЧНІ НЕЙРОННІ МЕРЕЖІ ТА ГЛИБОКЕ НАВЧАННЯ

О. М. СТАНКЕВИЧ, Д. П. РЕБОТ

*Національний університет "Львівська політехніка"*

На основі аналізу найновіших досліджень розглянуто можливості використання штучних нейронних мереж та методів глибокого навчання для автоматизації опрацювання сигналів акустичної емісії (АЕ), щоб ідентифікувати стадії руйнування. Порівняно точність результатів для різних підходів та виокремлено їх переваги та недоліки. Перспективним є впровадження у практику АЕ діагностування методів глибокого навчання.

**Ключові слова:** акустична емісія, штучна нейронна мережа, глибоке навчання, згортоква нейронна мережа, рекурентна нейронна мережа, ідентифікація дефектів.

Based on the analysis of the latest studies, the possibilities of using artificial neural networks and deep learning algorithms for automating the processing of acoustic emission (AE) signals to identify fracture stages are considered. The accuracy of the results for different approaches is compared and their advantages and disadvantages are highlighted. Deep learning methods have broad prospects for implementation in practice of AE diagnostics.

**Keywords:** acoustic emission, artificial neural network, deep learning, convolution neural network, recurrent neural network, identification of defects.

**Вступ.** Метод акустичної емісії (АЕ) – цінний інструмент у різних напрямках неруйнівного контролю [1–7]. Інтерес до розроблення нових технологій АЕ невідносно зростає, особливо для розв’язання задач моніторингу та діагностування стану складних об’єктів та структур. Удосконалення елементної бази, швидке збільшення обсягів діагностичної інформації та розширення можливостей її відбору разом зі стрімким прогресом у методах її інтелектуального опрацювання сприяють розвитку методу АЕ [8].

Методи штучного інтелекту, зокрема машинного навчання (МН), широко використовують для автоматизації аналізу АЕ інформації [9]. До них належать алгоритми неконтрольованого (unsupervised learning) та контрольованого навчання (supervised learning), штучні нейронні мережі (artificial neural network – ANN) та методи глибокого навчання (deep-learning methods). Алгоритми МН дають змогу удосконалити звичайні підходи та поліпшити їх продуктивність. Потенційні перспективи їх застосування в методиках АЕ діагностування зростають через можливість легко впровадити зміни та швидко адаптувати шляхом інтеграції нових даних.

Останнім часом серед алгоритмів МН стають популярними штучні нейронні мережі (ШНМ) та методи глибокого навчання.

ШНМ – це математичні моделі, побудовані за правилами організації та функціонування біологічних нейронних мереж нервової системи людини [10]. Будь-яка ШНМ містить два обов’язкових шари (вхідний, куди надходять зовнішні

сигнали, та вихідний, який відтворює реакцію нейронів на комбінації вхідних сигналів) та один або більше прихованих шарів. Залежно від зворотних зв'язків розрізняють такі моделі ШНМ: прямого (feed forward) та зворотного поширення (feedback), а також самоорганізувальні (self-organizing). Нейронна мережа без попереднього опрацювання вхідних даних формує набір діагностичних ознак за аналізом форми отриманих інформаційних сигналів. Такі мережі можна використовувати в задачах кластерного аналізу, розпізнавання образів, класифікації дефектів тощо. Один із найважливіших недоліків ШНМ – неконтрольоване збільшення кількості класів за умови значного рівня завад у сигналах, що врешті може призвести до порушень функціонування системи загалом.

На ШНМ ґрунтуються методи глибокого МН. Основна перевага алгоритмів такого типу полягає у можливості визначення оцінювальних функцій для вивчення зв'язків будь-якої складності. Тут найпоширеніші згорткові та рекурентні нейронні мережі.

Мета досліджень – аналіз та систематизація використання алгоритмів ШНМ та глибокого навчання для ідентифікування та локалізації джерел АЕ під час діагностування матеріалів і конструкцій.

**Штучні нейронні мережі в опрацювання сигналів АЕ.** Особливими перевагами ШНМ у неруйнівному контролі є їх здатність інкапсулювати великі обсяги зібраних під час діагностування даних і швидко класифікувати сигнали АЕ на їх основі. Архітектура мережі (кількість вузлів у прихованих шарах, з'єднання в мережі, призначення початкової ваги, функції активації) та тип навчання (контрольоване чи неконтрольоване) залежать від поставленого завдання. Критерієм зупинки навчання ШНМ може бути заздалегідь встановлена межа абсолютної похибки, мінімальна квадратична похибка або максимальна кількість епох навчання.

Багатотипну модель ШНМ зворотного поширення (Backpropagation Neural Network) для точного визначення місця розташування тріщини у трубі на основі вібраційних сигналів та сигналів АЕ запропоновано у праці [11]. Вона підвищує точність визначення місця дефекту порівняно з методом, що ґрунтується на однотипних даних.

Можливість застосування АЕ не лише для моніторингу пошкоджень мостів, а й для визначення навантаження на них транспортних засобів досліджували у праці [12]. Для цього запропонували вдосконалену модель ансамблевої ШНМ (Ensemble Artificial Neural Network), точність якої під час оцінювання навантажень транспортних засобів на плоскі плити зі збірною залізобетону – понад 70%.

У гірничій промисловості зі збільшенням глибини виробітку важливо попереджати раптові вибухи породи. Двокроковий алгоритм встановлення місця джерела АЕ за допомогою ШНМ зворотного поширення подано у праці [13]. Точність методу перевищила 97%.

Для автоматизації ідентифікації механізмів розтріскування цементного тіста за даними АЕ, записаними під час випробувань на стиск та чотириточковий згин, автори публікації [14] розробили покроковий підхід до аналізу даних. На першому застосовували метод агломеративної ієрархічної кластеризації; на другому – штучну нейронну мережу, а на третьому – алгоритм визначення місця розташування джерела з трасуванням променів.

Ефективний метод локалізації джерел АЕ, заснований на використанні ШНМ, подали у праці [15]. За основу брали результати моделювання хвиль Лемба в залізобетонній балці методом скінченних елементів та порівнювали їх зі сигналами АЕ з експериментальних досліджень. Встановили, що похибка запропонованого підходу 10%, тобто він точніший, ніж класичний метод визначення місця розташування джерела АЕ за часом надходження пружної хвилі.

Автори праці [16] досліджували вплив коефіцієнта армування залізобетону на його міцність на вигин. Для прогнозування ступеня його пошкодження запропонували класифікаційну модель ШНМ зворотного розповсюдження, оптимізовану алгоритмом мережі глибоких переконань (Deep Belief Network), і виявили, що середня точність прогнозування моделі становить понад 89%.

У праці [17] досліджували можливість використання різних моделей нейронних мереж для автоматизації діагностики стану ізоляційного матеріалу. Зокрема, нейронної мережі прямого поширення (FeedForward Network – FFN) з трьома прихованими шарами та 15 нейронами, мережі радіальних базисних функцій (Radial Basis Functions – RBF), вейвлетної з двома вейвлет-нейронами (Wavelet Neural Network – WNN) та методу опорних векторів (Support Vector Machine – SVM). Кожна модель виявилась високоефективною для класифікації джерел АЕ: FFN – 97,6%, RBF – 95,8%, WNN – 95,7%, SVM – 96,3%. Також встановили, що методом головних компонент можна зменшити кількість даних для навчання мережі до однієї змінної, водночас ефективність кожної мережі зменшується менш ніж на 0,5%.

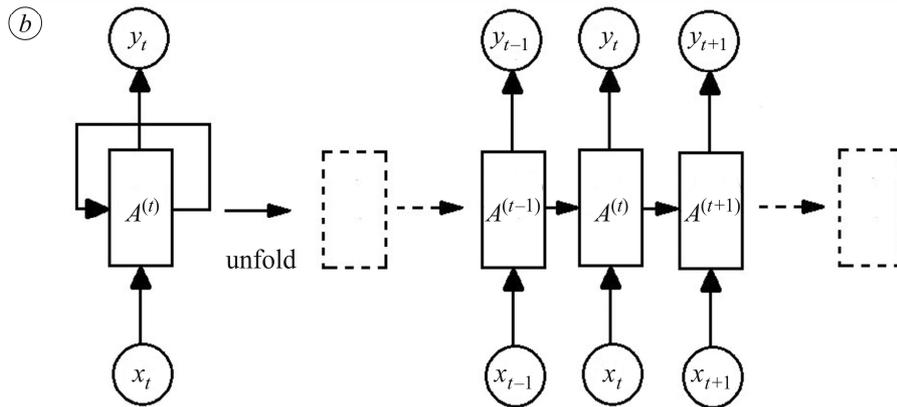
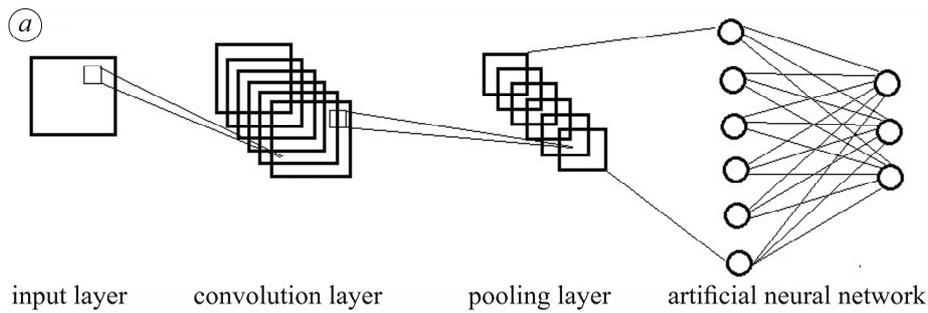
У праці [18] побудували самоорганізувальну нейронну мережу (Self-Organizing Map Neural Network), яка дає змогу ідентифікувати сигнали-попередники вибуху породи. Особливість цього методу – циклічна ітерація сегментації даних. Процес ґрунтується на принципах “екранування сигналу завад”, “вилучення ключового сигналу” та “інверсії сигналу-попередника”. Встановили, що сигнали-попередники вибуху породи складаються зі серії сигналів АЕ з великою тривалістю, високою енергією, низькими середньою та піковою частотами, які, ймовірно, пов’язані з утворенням великомасштабних тріщин розтягу перед вибухом породи.

**Методи глибокого машинного навчання для розпізнавання дефектів.** Серед них найчастіше використовують згорткові (Convolution Neural Network – CNN) та рекурентні (Recurrent Neural Network – RNN) нейронні мережі, водночас відомі дослідження, де застосовують інші моделі або інтегрують різні підходи.

Стандартна згорткова нейронна мережа складається з таких рівнів: вхідний, згортка, об’єднання та повністю зв’язані шари (див. рисунок, схема *a*). Уже на рівні згортки вибирають функції з вхідного набору даних шляхом згортання даних з меншими за розміром ядрами, щоб створити карту активації. Отже, згорткова нейронна мережа може легко вказати на локальні шаблони в наборі даних, на відміну від традиційної ШНМ, яка вивчає глобальні шаблони.

Ще одним класом ШНМ для розпізнавання шаблонів у послідовних даних є рекурентна нейронна мережа, яка містить кілька нейронних мереж прямого зв’язку, які передають інформацію на наступний вузол (прихований стан) (див. рисунок, схема *b*). Іншими словами, результатом поточного вузла є узгодження попередніх знань (прихованого стану) з власним досвідом, який потім передається наступному вузлу. Отже, рекурентна нейронна мережа використовує попередній вихід для визначення наступного.

Новий метод для моніторингу в режимі реального часу якості поверхні під час її оброблення лазерним ударом на основі АЕ та згорткової нейронної мережі подано у праці [19]. Досліджували алюмінієвий сплав 7075. Вхідними даними для нейронної мережі слугували кепстри дискретного пакетного вейвлет-перетворення сигналів АЕ. Застосовували згорткову нейронну мережу з подвійним функціоналом (Dual-Feature Fusion Convolutional Neural Network – DFCNN). Досягли середньої точності 99,2% визначення твердості поверхні за різного часу оброблення лазером та 99,67% – поверхневих напружень за різної енергії лазера. Експериментальні результати засвідчили, що ознаки АЕ, засновані на аналізі кепстра, ефективніші, ніж традиційні методи виділення ознак.



Типова архітектура штучних нейронних мереж глибокого навчання:  
*a* – згорткової; *b* – рекурентної.

Typical architecture of artificial neural networks of deep learning:  
*a* – convolution; *b* – recurrent.

У праці [20] в онлайн-системі моніторингу газових турбін методом АЕ використовували згорткову нейронну мережу. Випробовували невелику турбину, робочі стани якої можна безпечно модифікувати, щоб відтворювати як нормальний, так і несправний. Сигнал АЕ опрацьовували у два етапи: виділяли обвідну часового ряду, усереднюючи час, вибраний для поліпшення основних функцій та усунення нерелевантного шуму; генерували частотно-часові характеристики на основі неперервного вейвлет-перетворення. Виділені характеристики застосували для навчання глибокої згорткової нейронної мережі, щоб класифікувати стан турбіни. Побудована модель з високою точністю класифікувала два нормальні та два несправні стани роботи за різних швидкостей турбіни.

Метод ідентифікації стану наплавлення під час нанесення лазером з допомогою згорткової нейронної мережі описано у праці [21]. Моніторячи сигнал АЕ, можна визначити параметри процесу, наприклад, потужність лазера, швидкість сканування та швидкість подачі порошку, а також виявити тріщини. Вектори ознак сигналу АЕ створювали на основі його двох основних характеристик – максимальної амплітуди та енергії, щоб виділити шаблони сигналів високої (для відстеження зміни параметрів лазерного наплавлення) та низької енергії (для виявлення утворення типових тріщин у шарі наплавлення). Застосовуючи нейронну мережу до високоенергетичних сигналів АЕ, вдалось визначити, чи тріщина утворилась у результаті адитивного лазерного наплавлення, а вживаючи її до низькоенергетичних – ідентифікувати поточний стан оболонки. Згідно з вектором ознак, отриманим з цих даних, поточний стан процесу розпізнається як нор-

мальне якісне покриття або з відхиленням певного технологічного параметра та можливими тріщинами в шарі облицювання.

Акцентуючи увагу на важливості раннього виявлення пошкоджень та їх локалізації на обладнанні атомних електростанцій, автори праці [22] пропонують новий метод автоматизації цих процесів на основі глибокого навчання з використанням методу АЕ. Спочатку до зареєстрованих сигналів АЕ застосовують неперервне вейвлет-перетворення та отримують зображення в частотно-часовій області, які згорткові нейронні мережі використовують як вхідні дані. Навчені мережі допомогли оцінити координати розташування пошкоджень. Для підтвердження ефективності нового методу випробували бетонну панель та куб зі штучно створеними дефектами.

Важливою проблемою атомної енергетики є зберігання відпрацьованого радіоактивного палива. Щоб запобігти його витоку через пошкоджені контейнери, необхідний їх тривалий моніторинг методом АЕ та забезпечення своєчасного обслуговування. Водночас необхідно встановити мінімальну кількість первинних перетворювачів АЕ (ПАЕ) на об'єкті контролю. Автори праці [23] розробили автоматизований метод локалізації пошкоджень для оцінювання їх координат з допомогою одного ПАЕ. У набір даних інтегрували параметри хвильових відображень сигналів та спектрів швидкого перетворення Фур'є, зображення сигналів АЕ на основі короткочасового перетворення Фур'є і неперервного вейвлет-перетворення, ентропії спектра. Для аналізу зображень і обчислення координат пошкодження запропонували згорткову нейронну мережу на основі зваженої ансамблевої регресії. Використовували зразок зі сталеві пластины, який імітує каністру, і виконали триразову перехресну перевірку, щоб забезпечити ефективну оцінку. Результати засвідчили високу продуктивність запропонованого методу для локалізації дефектів.

Просту, але надійну модель згорткової нейронної мережі для попередньої фільтрації сигналів АЕ від тріщин у бетоні і новий метод її навчання для підвищення точності продано у праці [24]. Спочатку зібрали різні шумові сигнали та сигнали АЕ від розтріскування бетонних зразків для навчання нейронної мережі. Точність навченої моделі оцінили за набором експериментальних даних. Для кількісного визначення пошкодження бетону, що відповідає різним стадіям навантаження, запропонували скалярну змінну пошкодження на основі вейвлет-ентропії [25]. Вхідними даними розробленої згорткової нейронної мережі слугували 6000 зображень скалограм часу та частоти. Автоматизована модель добре розрізняє фази пошкодженого матеріалу з високою точністю навчання та тестування.

Можливість точного розділення припрацювання та стабільного стану зношування в промислових елементах та одночасно умов навантаження на основі сигналів АЕ за допомогою згорткової нейронної мережі з двома мітками досліджували у публікації [26]. У випробуваннях використали сталеву кульку, яка ковзає по сталевих пластинах у сухих умовах. За кривими тертя триботест розділили на два типи: припрацювання та стабільний. За допомогою згорткової нейронної мережі з двома мітками аналізували сигнали АЕ. Запропонований метод МН точно класифікує стадії зношування, а також умови навантаження з точністю 99%.

Методику прогнозування стадії зношування фрезерувального інструменту за допомогою згорткової нейронної мережі запропонували у праці [27]. Набір даних для мережі створювали, вимірюючи знос та реєструючи сигнали АЕ. Для класифікації хвильових відображень сигналів використали глибоку згорткову нейронну мережу. Оскільки набір даних був незбалансованим, для поліпшення продуктивності моделі застосували підхід ваги класів. Досягнута точність моделі понад 90% свідчить про її ефективність у прогнозуванні стану зносу інструменту.

Методику розпізнавання дефектних станів, спричинених водневими пошкодженнями, за допомогою нейронної мережі глибокого навчання подано у праці [28]. Характерні параметри, включаючи кількість рахунку та тривалість сигналів АЕ, заздалегідь опрацьовували та ідентифікували поточні стани пошкодження – поширення дислокацій та появу тріщин. Для виділення вектора ознак різних типів пошкоджень за сигналами АЕ використали швидке перетворення Фур'є. За допомогою згорткової нейронної мережі створили модель розпізнавання водневих дефектів, точність класифікації якої становить 98,37%.

Метод локалізації джерел АЕ в композитних панелях на основі просторово-часових графових згорткових мереж (Spatial-Temporal Graph Convolutional Networks – STGCN) розробили у публікації [29]. Дані, згенеровані мережею перетворювачів АЕ, подавали у вигляді графа, де часові параметри, отримані зі сигналів АЕ за допомогою одновимірних згорткових нейронних мереж (1D-CNN), і просторова інформація перетворювачів є характеристиками вершин. Для відображення зв'язності графа розробили адаптивний метод обчислення матриці суміжності за відстанню до місця розташування ПАЕ. Метод експериментально підтверджено на панелі з армованого скловолокном пластику та оцінено його ефективність багаторазово перехресною перевіркою. Виявили, що запропонований метод точніше локалізує пошкодження порівняно з іншими.

У праці [30] подано результати розпізнавання сигналів зсуву та розтягу на основі параметрів АЕ та хвильових відображень за допомогою різних методів МН. Для класифікації сигналів АЕ використали дві моделі МН – дерево рішень та три типові згорткові нейронні мережі (InceptionV3, ResNet50 і VGG19). У першій моделі за основу класифікації вибрали такі параметри сигналів АЕ, як час наростання, кількість рахунку, амплітуда, максимальна частота та абсолютна енергія. Вхідними даними нейронних мереж були хвильові відображення та спектрограми пакетного вейвлет-перетворенням. Згорткові мережі продемонстрували точність розпізнавання типів дефектів до 88%, що перевищує точність моделі дерева рішень. Рекомендовано для підвищення ефективності виявлення сигналів АЕ, які супроводжують розтяг та зсув, використовувати мережу VGG19 і їх хвильове відображення.

Для ідентифікації джерел АЕ під час діагностики конструкцій у праці [31] порівнювали моделі ШНМ, одно- та двовимірної згорткових нейронних мереж у поєднанні з глибоким трансферним навчанням (Deep Transfer Learning). Для навчання ШНМ та одновимірної згорткової мережі використовували сигнали АЕ у часовій області, для навчання двовимірної – будували їх RGB-зображення. За результатами класифікації оцінювали похибки кожної моделі МН. Глибоке трансферне навчання двовимірної згорткової мережі успішно можна застосовувати на невеликих наборах АЕ даних.

Моніторинг стану конструкцій методом АЕ забезпечує передчасне виявлення небезпечних дефектів типу тріщин. Один із підходів до класифікації тріщин за двома параметрами (відношення часу наростання сигналу до максимальної амплітуди (RA) та відношення кількості подій АЕ до тривалості генерування (AF)) розроблено у праці [32]. Однак однозначно визначити лінію поділу для класифікації різних типів тріщин (розтягу та зсуву) у цьому методі досить важко. Автори публікації [33], досліджуючи кілька алгоритмів МН до кластеризації сигналів АЕ з відомими типами тріщин, спростили вирішення цієї проблеми. Найбільший вплив на класифікацію тріщин параметрів RA та AF підтвердили за допомогою аналізу головних компонент на наборі сигналів АЕ. Далі використали алгоритми МН – кластеризацію  $k$ -середніх ( $k$ -means), модель суміші Гауса (Gaussian Mixture Model), конкуруючі нейронні мережі (Competing Neural Networks) та самооргані-

зувальну нейронну мережу (Self-Organizing Feature Map). Найкращим виявився алгоритм моделі суміші Гауса.

Інший підхід до вирішення вказаної проблеми подано у праці [34]. Автори використали неконтрольовану модель встановлення типу тріщини у цементних матеріалах на основі ансамблевої кластеризації з методом опорних векторів і контрольовану модель зі застосуванням графових нейронних мереж (Graph Neural Networks – GNN), перевіривши їх на загальнодоступному наборі даних АЕ моніторингу цементних матеріалів. Спочатку за хвильовими відображеннями сигналів АЕ розраховували параметри RA та AF, проаналізували частотно-часову область та виділили ознаки вихідних даних. Методи групової кластеризації та опорних векторів можуть автоматично розрізняти різні типи тріщин (розтягу, зсуву, змішаного типу I та II) і створювати кількісно визначені граничні лінії. Контрольована модель графової нейронної мережі точно розрізняє типи тріщин, досягаючи середньої точності до 97,5% на тестовому наборі даних. Запропонований метод визначення частотно-часової області АЕ надає нові аналітичні інструменти для розуміння розвитку пошкоджень у цементних матеріалах, застосовуючи МН для розпізнавання шаблонів сигналів АЕ.

У праці [35] подано методику застосування необробленого сигналу АЕ для точного оцінювання залишкового терміну експлуатації машин. Модель прогнозування базується на гібридному підході, який використовує рівні довгої короткочасної пам'яті (Long Short-Term Memory – LSTM) і рекурентну нейронну мережу. Для підвищення ефективності навчання вживають техніку відсіву та зникання швидкості навчання. Комплексне експериментальне дослідження на основі широкого набору прогностичних даних довело ефективність такого підходу.

Новий спосіб прогнозування залишкового ресурсу бетонних конструкцій за необробленим сигналом АЕ описано у праці [36]. Розвиток пошкоджуваності відтворює індикатор роботоздатності, який формується автоматично з необроблених даних АЕ за допомогою глибокої нейронної мережі (Deep Neural Network – DNN). Щоб побудувати точні лінії індикаторів, запропонували відбирати для подальшого аналізу лише ті події АЕ, які найбільше відрізняються від інших. Побудований рядок індикатора роботоздатності стає вхідними даними для нейронної мережі довгострокової короткочасної пам'яті (Long Short-Term Memory Recurrent Neural Network – LSTM-RNN) і використовується для навчання та перевірки прогнозування залишкового терміну експлуатації. Такий підхід виявився значно ефективнішим, ніж інші рекурентні нейронні мережі. Аналогічний тип нейронної мережі застосували для моніторингу зношування підшипників ковзання за даними АЕ [37]. На першому етапі досліджень встановили, що методом АЕ можна розрізняти стадії змішаного тертя та гідродинамічного режиму. Далі за експериментальними результатами (за сталої швидкості з різним типом змащування, різних навантажень та часу роботи) формували вхідні параметри для нейронної мережі. Прогнозували зношування рекурентною нейронною мережею, яка може передбачити деградацію в часі.

Упродовж багатьох років досліджень АЕ розробили чимало методів для локалізації дефектів. Важливим інформаційним параметром для цього є час надходження сигналу на ПАЕ, точність визначення якого впливає на точність виявлення місця розташування дефекту. У праці [38] запропонували дві методики для його визначення. Перша базується на інформаційному критерії Akaike, а друга – на рекурентній згортковій нейронній мережі. Встановили, що найважливішими параметрами для високої точності локалізації джерела АЕ є середня абсолютна (MAE) і середня квадратична (RMSE) похибки між прогнозованим і справжнім моментом часу надходження сигналу. Ідея полягала у тому, щоб вибрати модель,

яка забезпечить найнижчі значення цих параметрів. Точність класифікації навчальної моделі на тестовому наборі сигналів дорівнює 98%.

**Інші методи МН.** Відомі також результати адаптації до аналізу АЕ інформації інших методів МН. Зокрема, для розуміння фізичних процесів, які відбуваються в глибині матеріалу під час адитивного виробництва, та оцінювання якості виробів, у праці [39] запропонували поєднати метод АЕ та МН з підкріпленням. Досягнута точність класифікації 74...82% підтвердила ефективність такого підходу.

Для моніторингу корозійного розтріскування сталевго дроту в арматурі бетонних мостів автори праці [40] розробили методику аналізу сигналів АЕ за допомогою напівконтрольованого навчання ШНМ. Хоча точність результатів була дещо нижчою проти керованого навчання, запропонований метод забезпечив ефективний дизайн мережі ПАЕ для АЕ моніторингу.

**Порівняння методів МН для аналізу АЕ-інформації.** Метод АЕ та ШНМ використовували здебільшого для локалізації місць руйнування. Для автоматизації аналізу даних АЕ розробили новітні алгоритми на основі розпізнавання образів за допомогою ШНМ. Високу точність отриманих результатів забезпечують методики, які використовують характеристики сигналу з часової або частотної областей, зокрема за його вейвлет-перетворення (неперервного, дискретного, пакетного). Перевагою ШНМ є те, що для оцінювання інтенсивності джерела та його локалізації не потрібно знати швидкість хвилі чи структурну геометрію матеріалу. Підвищити ефективність мережі можна шляхом адаптації її структури до типу вхідних даних. Недоліком ШНМ є складність навчання та необхідність значної кількості обчислень.

На сьогодні дослідники для розв'язування задач АЕ діагностування частіше залучають алгоритми глибокого навчання – згорткові та рекурентні нейронні мережі. Порівняно з іншими методами глибоке навчання не вимагає попереднього опрацювання вхідних даних (вилучення функцій) та застосовується до даних безпосередньо з ПАЕ, автоматично вивчаючи їх та вибираючи типові характеристики. Згорткові нейронні мережі успішно використовували не лише для ідентифікації та локалізації дефектів, але й для моніторингу якості технологічних процесів. Залишковий ресурс елементів конструкцій переважно прогнозували за допомогою рекурентних нейронних мереж з додатковою пам'яттю, що дає змогу зберігати та використовувати дані з попередніх кроків для прийняття рішення на поточному кроці.

Останнім часом активно розробляють підходи, де поєднують різні типи алгоритмів, що дає змогу підвищувати ефективність неруйнівного контролю та оптимізувати прийняття рішень за його результатами. У таблиці порівняно точність різних алгоритмів МН з розглянутих публікацій.

Як бачимо, точність різних алгоритмів МН для ідентифікації та локалізації джерел АЕ є достатньо висока та перевищує точність традиційних методів [9]. Водночас дещо кращі показники можна отримати, використовуючи для аналізу сигналів АЕ методи глибокого навчання. Збільшення обчислювальних витрат на їх реалізацію компенсують високоточні результати.

Оскільки точність аналізу сигналів АЕ за допомогою алгоритмів штучного інтелекту безпосередньо залежить від якості вхідних даних, то важливо враховувати особливості діагностування, насамперед, прагнути зменшити вплив різного роду завад, раціонально вибирати тип ПАЕ та налаштування виміральної системи.

Нейронні мережі для автоматизації опрацювання великих обсягів інформації підвищують продуктивність та точність АЕ діагностування відповідальних конструкцій та виробів.

### Точність ідентифікування джерел АЕ (за даними публікацій)

№ за/п	Метод МН	Джерело	Точність, %	
			min	max
<b>Штучні нейронні мережі</b>				
1	Штучна	[12, 13, 15, 16, 17]	70	97,6
2	Мережа радіальних базисних функцій	[17]	–	95,8
3	Вейвлетна	[17]	–	95,7
<b>Методи глибокого навчання</b>				
4	Згорткова нейронна мережа	[26, 27, 28, 30]	88	99
5	Згорткова нейронна мережа з подвійним функціоналом	[19]	99,2	99,67
6	Графова нейронна мережа	[34]	–	97,5
7	Рекурентна згорткова нейронна мережа	[38]	–	98

### ВИСНОВКИ

Виконано огляд найновіших досліджень використання методу АЕ та алгоритмів штучних нейронних мереж і глибокого навчання для ідентифікації та локалізації дефектів у матеріалах, прогнозування залишкового ресурсу елементів конструкцій. Використовуючи методи глибокого навчання для автоматизованого аналізу сигналів АЕ, можна підвищити точність результатів розв'язання задач АЕ діагностування. Водночас технології поєднання методу АЕ та штучного інтелекту для моніторингу та діагностики стану відповідальних об'єктів та виробів потребують подальшого розвитку та адаптації до різних матеріалів та структур.

1. *Nazarchuk Z. T., Skal's'kyi V. R., and Stankevych O. M.* A Method for the identification of the types of macrofracture of structural materials by the parameters of the wavelet transform of acoustic-emission signals // *Materials Science*. – 2014. – **49**, № 6. – P. 841–848.
2. *Strength evaluation of stomatologic polymers by wavelet transform of acoustic emission signals / V. R. Skal's'kii, V. F. Makeev, O. M. Stankevich, O. S. Kyrmanov, S. I. Vynnyts'ka, and V. K. Opanasovich // Streng. Mater.* – 2015. – **47**, № 4. – P. 566–572.
3. *Skalsky V. R., Stankevych O. M., and Kuz I. S.* Application of wavelet transforms for the analysis of acoustic-emission signals accompanying fracture processes in materials (A survey) // *Materials Science*. – 2018. – **54**, № 2. – P. 139–153.
4. *Skalskyi V., Stankevych O., and Dubytskyi O.* Estimation of effect of hydrogen on the parameters of magnetoacoustic emission signals // *J. Magn. Magn. Mater.* – 2018. – **454**. – P. 375–385.
5. *Estimation of characteristics of nanocrystalline layer using the surface acoustic waves / V. R. Skalskyi, O. M. Mokryi, O. I. Zvirko, V. I. Kyryliv, I. M. Romanyshyn, and O. V. Maksymiv // Materials Science*. – 2023. – **59**, № 2. – P. 180–185.
6. *Скальський В. Р., Станкевич О. М.* Акустико-емісійний критерій оптимізування кількості фібри в бетонній матриці // *Фіз.-хім. механіка матеріалів*. – 2023. – **59**, № 6. – С. 56–63.
7. *Дослідження впливу поверхневої обробки та гартування сталі 60С2А на її об'ємну пошкодженість методами акустичного контролю / В. Р. Скальський, І. М. Дмитрах, Є. П. Почапський, О. М. Мокрий, А. М. Сиротюк, Б. П. Клим, Ю. І. Канюк, І. М. Романишин, П. П. Великий, П. М. Долішній // Фіз.-хім. механіка матеріалів*. – 2024. – **60**, № 1. – С. 18–25.

8. *Damage mechanism identification in composites via machine learning and acoustic emission* / C. Muir, B. Swaminathan, A. S. Almansour, K. Sevens, C. Smith, M. Presby, J. D. Kiser, T. M. Pollock, and S. Daly // *npj Computational Materials*. – 2021. – **7**. – Article number 95. <https://doi.org/10.1038/s41524-021-00565-x>
9. *Станкевич О. М., Ребот Д. П. Методи штучного інтелекту для акустико-емісійного діагностування стадій руйнування (Огляд). Ч. 1. Алгоритми неконтрольованого та контрольованого навчання* // *Фіз.-хім. механіка матеріалів*. – 2024. – **60**, № 3. – С. 5–14.
10. *Руденко О. Г., Бодяньський Є. В. Штучні нейронні мережі*. – Харків: ТОВ “Компанія СМІТ”, 2006. – 404 с.
11. *Multi-mode fusion BP neural network model with vibration and acoustic emission signals for process pipeline crack location* / L. Zhou, P. Wang, C. Zhang, X. Qu, C. Gao, and Y. Xie // *Ocean Eng.* – 2022. – **264**. – Article number 112384.
12. *Determination of vehicle loads on bridges by acoustic emission and an improved ensemble artificial neural network* / L. KC, A. Ross, L. Ai, A. Henderson, E. Elbatanouny, M. Bayat, and P. Ziehl // *Const. Buil. Mater.* – 2023. – **364**. – Article number 129844.
13. *Kolář P. and Petružálek M. A two-step algorithm for acoustic emission event discrimination based on recurrent neural networks* // *Comput. Geosci.* – 2022. – **163**. – Article number 105119.
14. *Analyzing acoustic emission data to identify cracking modes in cement paste using an artificial neural network* / V. Soltangharaei, R. Anay, L. Assi, M. Bayat, J. R. Rose, and P. Ziehl // *Const. Build. Mater.* – 2021. – **267**. – Article number 121047.
15. *Acoustic emission source location using Lamb wave propagation simulation and artificial neural network for I-shaped steel girder* / L. Cheng, H. Xin, R. M. Groves, and M. Veljkovic // *Const. Build. Mater.* – 2021. – **273**. – Article number 121706.
16. *Revealing the failure mechanism of high strength seawater coral aggregate reinforced concrete slabs based on acoustic emission technology: Parameter analysis and DBN-BPNN classification* / D. Shi, X. Chen, P. Chen, K. Shang, and T. Ji // *Eng. Struct.* – 2024. – **303**. – Article number 117439.
17. *Dobrzycki A., Mikulski S., and Opydo W. Using ANN and SVM for the detection of acoustic emission signals accompanying epoxy resin electrical treeing* // *Appl. Sci.* – 2019. – **9**. – Article number 1523.
18. *Experimental investigation on acoustic emission precursor of rockburst based on unsupervised machine learning method* / J. Sun, D. Liu, P. He, L. Guo, B. Cao, L. Zhang, and Z. Li // *Rock Mech. Bulletin*. – 2024. – **3**, № 2. – Article number 100099.
19. *Acoustic emission for surface quality monitoring in laser shock peening via dual-feature fusion convolution neural network* / R. Qin, Z. Zhang, J. Huang, Z. Du, X. Xiang, G. Wen, and W. He // *Opt. Laser Technol.* – 2023. – **164**. – Article number 109505.
20. *Gas turbine failure classification using acoustic emissions with wavelet analysis and deep learning* / M. S. Nashed, J. Renno, M. S. Mohamed, and R. L. Rauben // *Expert Sys. Appl.* – 2023. – **232**. – Article number 120684.
21. *Laser cladding state recognition and crack defect diagnosis by acoustic emission signal and neural network* / K. Li, T. Li, M. Ma, D. Wang, W. Deng, and H. Lu // *Opt. Laser Technol.* – 2021. – **142**. – Article number 107161.
22. *Damage localization using acoustic emission sensors via convolutional neural network and continuous wavelet transform* / V. Vy, Y. Lee, J. Bak, S. Park, and H. Yoon // *Mech. Syst. Sig. Proc.* – 2023. – **204**. – Article number 110831.
23. *Ai L., Bayat M., and Ziehl P. Localizing damage on stainless steel structures using acoustic emission signals and weighted ensemble regression-based convolutional neural network* // *Measurement*. – 2023. – **211**. – Article number 112659.
24. *Auto-detection of acoustic emission signals from cracking of concrete structures using convolutional neural networks: Upscaling from specimen* / G. Han, Y-M. Kim, H. Kim, T-M. Oh, K-I. Song, A. Kim, Y. Kim, Y. Cho, and T-H. Kwon // *Expert Syst. Appl.* – 2021. – **186**. – Article number 115863.
25. *Smal D. K. and Ray S. Wavelet entropy-based damage characterization and material phase differentiation in concrete using acoustic emissions* // *Eng. Fail. Anal.* – 2024. – **160**. – Article number 108144.

26. *When AE (Acoustic Emission) meets AI (Artificial Intelligence) for wear states detection* / P. Deshpande, V. Pandiyan, R. Crockett, and K. Wasmer // Conf. SCHALL 21, Germany, January 2021. – 8 p.
27. *Tool condition monitoring for milling process using convolutional neural networks* / S. Ferrisi, G. Zangara, D. R. Izquierdo, D. Lofaro, R. Guido, D. Conforti, and G. Ambrogio // *Procedia Comput. Sci.* – 2024. – **232**. – P. 1607–16116.
28. *Hydrogen defect acoustic emission recognition by deep learning neural network* / F. Qui, Z. Shen, Y. Bai, G. Shan, D. Qu, and W. Chen // *Int. J. Hydrogen Energy.* – 2024. – **45**. – P. 878–893.
29. *Zhao Z. and Chen N-Z. Spatial-temporal graph convolutional networks (STGCN) based method for localizing acoustic emission sources in composite panels* // *Comp. Struct.* – 2023. – **323**. – Article number 117496.
30. *Recognition of shear and tension signals based on acoustic emission parameters and waveform using machine learning methods* / F. Ren, C. Zhu, Z. Yuan, M. Karakus, S. Tang, and M. He // *Int. J. Rock Mech. Min. Sci.* – 2023. – **171**. – Article number 105578.
31. *Identification of acoustic emission sources for structural health monitoring applications based on convolutional neural networks and deep transfer learning* / D. F. Hesser, S. Mostafavi, G. K. Kocur, and B. Markert // *Neurocomputing.* – 2021. – **453**. – P. 1–12.
32. *Ohno K. and Ohtsu M. Crack classification in concrete based on acoustic emission* // *Constr. Build. Mater.* – 2010. – **24**. – P. 2339–2346.
33. *Ju S., Li D., and Jn J. Machine-learning-based methods for crack classification using acoustic emission technique* // *Mech. Syst. Sig. Process.* – 2022. – **178**. – Article number 109253.
34. *Wang X., Yue Q., and Liu X. Crack pattern identification in cementitious materials based on acoustic emission and machine learning* // *J. Build. Eng.* – 2024. – **87**. – Article number 109124.
35. *Data-driven prognosis method using hybrid deep recurrent neural network* / M. Xia, X. Zheng, M. Imran, and M. Shoaib // *Appl. Soft Comp.* – 2020. – **93**. – Article number 106351.
36. *Nguyen T.-K., Ahmad Z., and Kim J.-M. A scheme with acoustic emission hit removal for the remaining useful life prediction of concrete structures* // *Sensors.* – 2021. – **21**. – Article number 7761.
37. *Data-driven wear monitoring for sliding bearings using acoustic emission signals and long short-term memory neural networks* / F. König, J. Marheineke, G. Jacobs, C. Sous, M. J. Zuo, and Z. Tian // *Wear.* – 2021. – **476**. – Article number 203616.
- Acoustic emission and artificial intelligence procedure for crack source localization* / J. Melchiorre, A. M. Bertetto, M. M. Rosso, and G. C. Marano // *Sensors.* – 2023. – **23**. – Article number 693. – <https://doi.org/10.3390/s23020693>
39. *In situ quality monitoring in AM using acoustic emission: a reinforcement learning approach* / K. Wasmer, T. Le-Quang, B. Meylan, and S. A. Shevchik // *J. Mater. Eng. Perform.* – 2019. – **28**, № 2. – P. 666–672.
40. *Semi-supervised learning for acoustic vision monitoring of tendons in pre-stressed concrete bridges* / A. Lange, M. Käding, R. Xu, S. Marx, and J. Östermann // *Proc. of the 14<sup>th</sup> Int. Workshop on Structural Health Monitoring, 2023.* – DOI: 10/12783/shm2023/36855

Одержано 25.03.2024