

УДК 539.3:620.179.17:004.8

МЕТОДИ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АКУСТИКО-ЕМІСІЙНОГО ДІАГНОСТУВАННЯ СТАДІЙ РУЙНУВАННЯ (Огляд). Ч. 1: АЛГОРИТМИ НЕКОНТРОЛЬОВАНОГО ТА КОНТРОЛЬОВАНОГО МАШИННОГО НАВЧАННЯ

О. М. СТАНКЕВИЧ, Д. П. РЕБОТ

Національний університет "Львівська політехніка"

За результатами аналізу найновіших досліджень оцінено можливості використання алгоритмів неконтрольованого та контрольованого машинного навчання для автоматичного опрацювання сигналів акустичної емісії, щоб ідентифікувати та локалізувати їх джерела. Порівняно точність результатів для різних підходів та окреслено напрямки її підвищення. Підтверджено важливість подальших досліджень для адаптації та оптимізації новітніх методик для різних матеріалів та структур.

Ключові слова: акустична емісія, машинне неконтрольоване та контрольоване навчання, ідентифікація дефектів.

Based on the analysis of the latest studies, the possibilities of using unsupervised and supervised machine learning algorithms for automating the processing of acoustic emission signals to identify and localize their sources are considered. The accuracy of the results for different approaches is compared and directions for its improvement are described. The importance of further research regarding the adaptation and optimization of the latest techniques for various materials and structures is confirmed.

Keywords: acoustic emission, machine unsupervised and supervised learning, identification of defects.

Вступ. Невід'ємним елементом технічної діагностики (ТД) виробів та елементів конструкцій є їх неруйнівний контроль (НК) як під час виготовлення, так і експлуатації. За результатами НК оцінюють дефектність об'єкта контролю і визначають його залишковий ресурс та приймають рішення про можливість подальшої безпечної експлуатації.

Тут слід виділити метод акустичної емісії (АЕ), який ґрунтується на явищі випромінювання пружних хвиль внаслідок локальної структурної перебудови матеріалу під дією механічних, фізичних, хімічних та інших чинників [1]. Він дає змогу виявляти зародження руйнування в матеріалі ще задовго до настання його критичної стадії за параметрами сигналів АЕ, які реєструють відповідними вимірювальними системами.

Найчастіше закономірності між параметрами дефектів та пружних хвиль, які генеруються під час їх підростання, встановлюють аналітико-числовим та комп'ютерним моделюванням [2]. Однак під час розв'язання рівнянь часто виникають труднощі з обчисленнями, а комп'ютерне моделювання може ускладнюватися, наприклад, через непросту геометрію об'єктів чи особливі граничні умови.

Останнім часом для опрацювання діагностичної інформації та прийняття важливих рішень дослідники застосовують методології, засновані на штучному інтелекті, зокрема машинному навчанні (МН) [3]. МН під час НК особливо важливе для розв'язання оберненої задачі, яка полягає в тому, щоб за характеристи-

ками зареєстрованого сигналу визначити параметри дефекту, його форму, місце та глибину розташування чи встановити тип руйнування в матеріалі об'єкта контролю. За алгоритмами МН вдається знайти приховані закономірності між результатами контролю, що відкриває додаткові можливості для підвищення ефективності НК та врешті-решт для точності прогнозування залишкового ресурсу об'єктів контролю.

Мета досліджень – аналіз та порівняння методик неконтрольованого та контрольованого МН для ідентифікування джерел АЕ під час діагностування матеріалів і конструкцій.

Основи акустичної емісії. Джерела АЕ збуджують різні механізми [1]. Зокрема, у гомогенних матеріалах розглядають: дислокаційні процеси пластичної деформації, фазові зміни, руйнування частинок вторинної фази, магнетні ефекти, поверхневі явища, утворення пустот та тріщин, водневе окрихчення, корозію тощо. У гетерогенних, окрім вказаних, джерелами АЕ слугують інші процеси. Наприклад, у волоконних композитах – це руйнування матриці, розшарування, витягування та розрив волокон.

Раптове утворення джерела АЕ генерує пружні хвилі, які, поширюючись у структурі матеріалу, досягають встановлених на поверхні об'єкта контролю первинних перетворювачів (ПАЕ). Вимірювальна система реєструє коливання у вигляді електричних сигналів. Розповсюджуючись від джерела до поверхні зразка, сигнали АЕ суттєво спотворюються внаслідок дисперсії швидкості звуку, трансформації типу та форми хвилі під час відбиття, зникання хвиль, шуму від джерел, які не залежать від можливого структурного дефекту. Суттєво на результати вимірювань впливають характеристики ПАЕ. Додаткові труднощі в прийнятті рішень за результатами опрацювання діагностичної інформації виникають через обмеження повторюваності експериментів. Адже навіть для одного і того ж матеріалу, тих самих розмірів зразків та ідентичних умов випроб діагностична інформація може відрізнитись для кожного екземпляра.

Згідно зі стандартом [4], основними параметрами, які характеризують подію АЕ, є амплітуда, тривалість, підсумковий рахунок, швидкість рахунку, час наростання, активність, енергія сигналу. Водночас багато досліджень спрямовано для пошуку додаткових дескрипторів, які дають змогу класифікувати події АЕ, щоб ефективно ідентифікувати їх джерела [5, 6]. За результатами АЕ діагностування можна визначити місце зародження руйнування в матеріалі; місце розташування тріщини та механізми її поширення; ділянки підвищених напружень; деякі властивості матеріалу тощо [7–9].

Враховуючи певні труднощі та обмеження методу АЕ, поліпшити результати ідентифікації структурних пошкоджень можна, активно впроваджуючи методики, засновані на штучному інтелекті [10–12].

Методології МН для АЕ діагностування. МН (machine learning) – це галузь інформатики, яка ґрунтується на створенні алгоритмів для виявлення шаблонів у наборах даних і прийняття відповідних рішень. Особливість цих алгоритмів – постійне підвищення продуктивності без додаткового втручання людини. Вони дають змогу прогнозувати результати, визначати закономірності та поліпшувати вибір [13].

Вхідною інформацією для алгоритмів МН є набори числових значень інформативних параметрів подій АЕ. Залежно від типу алгоритму оптимальна кількість цих параметрів та наборів їх значень може бути різною. Побудовано (див. рисунок) схему функціонування системи з МН. Насамперед сигнали, отримані за результатами АЕ контролю, слід очистити від шуму. Для цього найчастіше використовують вейвлет-перетворення. Далі дані передають у систему виділення ознак, мета якої – зменшити їх розмірність без втрати інформації та визначити від-

повідні характеристики. Для вибору репрезентативних параметрів застосовують метод головних компонент (principal component analysis – PCA). Зменшені в об’ємі дані придатні в моделях кластеризації та автоматичної класифікації типів пошкоджень у матеріалах. Далі сформовані їх набори слугують вхідною інформацією для моделей МН. Результат роботи системи – класифікація та розпізнавання джерел АЕ, а також виявлення місця їх знаходження.

Серед загальної класифікації алгоритмів МН для опрацювання АЕ інформації виділяють такі найпоширеніші: алгоритми неконтрольованого (unsupervised learning) та контрольованого (supervised learning) навчання, штучні нейронні мережі (artificial neural network) та методи глибокого навчання (deep-learning methods). Останнім часом поєднують різні методи, що дає змогу, підвищуючи їхні переваги, підвищувати ефективність НК та оптимізувати прийняття рішень за його результатами.

Методика алгоритмів неконтрольованого навчання полягає у вивченні декількох функцій (залежностей) із набору даних. Після введення нового набору алгоритм використовує вивчені функції для розпізнавання класу даних. Такі алгоритми застосовують для кластеризації та зменшення кількості функцій. До них відносять кластеризацію *k*-середніх (*k*-means) та нечітку логіку або *C*-середніх (fuzzy *C*-means), генетичні алгоритми (genetic algorithms), ієрархічну кластеризацію (hierarchical clustering).

За алгоритмами контрольованого навчання прогнозують та класифікують результати. Їх суть ось у чому. За заданим тестовим набором даних система аналізує навчальний набір, який використовува-тимуть для ідентифікації з найбільшою можливою точністю. До таких алгоритмів належать, наприклад, регресійний аналіз (linear and logistic regression), дерево рішень (decision tree), випадковий ліс (random forest), метод опорних векторів (support vector machine), байєсівська класифікація (naive Bayes), лінійний дискримінантний аналіз (linear discriminant analysis), *k*-найближчих сусідів (*k*-nearest neighbor).

Неконтрольоване навчання, коли система вчиться розпізнавати подібності в даних, сприяє виявленню пошкоджень через кластеризацію результатів контролю, а контрольоване, за якого системи отримують вхідні та очікувані результати, можна вживати для встановлення типів пошкоджень.

Проаналізуємо використання вказаних алгоритмів МН у технології АЕ діагностування.

Алгоритми неконтрольованого навчання. Вони є основою методик кластеризації даних, які полягають у порівнянні елементів їх набору за вибраними критеріями [14]. Подібні елементи утворюють один кластер або групу, в іншому випадку – формують різні кластери. За допомогою кластеризації можна віднайти шаблони та виявити зв’язки між даними, а отже, зменшити розмір набору для навчання, вибравши репрезентативні для кожного кластера.




Схема основних етапів функціонування автоматизованої системи ідентифікування джерела АЕ.

Scheme of the main stages of the functioning of the automated system of AE source identification.

Мета передових методів для аналізу сигналів АЕ – полегшити ідентифікацію механізмів руйнування в матеріалах різного типу та вчасно попереджати аварійні ситуації. Насамперед важливо сформувати комплексну основу відбору та порівняння характеристичних параметрів сигналу АЕ як індикаторів запобігання розвитку найнебезпечнішого дефекту – тріщини. Недоліком відомих методів постопрацювання сигналів є вибір параметрів вручну, що призводить до накладання їх числових діапазонів та ускладнення ідентифікування. Для вирішення цієї проблеми використовують алгоритми МН.

Серед інших першим найактивніше почали запроваджувати для автоматизації аналізу АЕ інформації метод кластеризації k -середніх. Наприклад, простий, але ефективний неітераційний алгоритм кластеризації адаптивних послідовних k -середніх для виявлення пластичної деформації, зародження тріщини та корозійного розтріскування запропонували автори праці [15]. Його особливістю є те, що кількість кластерів вказувати не потрібно, бо вони автоматично формуються з вхідних даних. Водночас за властивостями фонового шуму алгоритм контролює виникнення нових кластерів. Підхід виявився ефективним для групування сигналів АЕ, які генерують різні джерела. Точність ідентифікування становила 91...93%. Методом АЕ досліджували руйнування литої сталі G20Mn5QT під час розриву та розтягу [16]. Для вибору характеристичних параметрів АЕ та визначення типів її пошкодження використали метод головних компонент та k -середніх. За результатами кластеризації встановили, що за часом наростання/амплітудою (RA), кількістю подій/тривалістю (AF) та енергією (E) можна ефективно диференціювати різні типи сигналів та прогнозувати критичну стадію руйнування. Запропоновано [17] нову методику онлайн-моніторингу розвитку тріщин у маловуглецевій сталі Q325, яка поєднує методи мультифрактальної розмірності та кластеризації k -середніх. Досліджували зразки без зварних з'єднань та з ними. Методом мультифрактальної розмірності сигналу АЕ вдалось позбутися залежності традиційного частотно-часового аналізу від налаштування порога дискримінації сигналу АЕ. Побудовано мультифрактальний спектр сигналів АЕ від тріщини на різних стадіях її розвитку. Новий спосіб мультифрактальної просторової кластеризації зашумлених компонент на основі густини (Multifractal Density-based Spatial Clustering of Application with Noise – MF-DBSCAN) поєднує мультифрактальну характеристику з розпізнаванням образів, а також дає змогу оптимізувати основні параметри в режимі реального часу за допомогою алгоритму Парето.

У багатьох публікаціях поєднано метод АЕ та кластеризацію k -середніх для вивчення руйнування композитних матеріалів [18–25]. Наприклад, результати дослідження впливу циклу заморожування/розморожування на класифікацію механізмів руйнування бетону на основі аналізу параметрів АЕ подано у праці [18]. Розвиток деформацій на бетонній поверхні, зародження та поширення внутрішніх тріщин контролювали в режимі реального часу методом АЕ та цифровою кореляцією зображень. За параметрами АЕ, густиною ядра (b -value) та кластеризацією k -середніх класифікували типи макроскопічних тріщин у бетонних зразках під час різного циклу заморожування/розморожування.

У праці [19] вивчали сигнали АЕ в армованому сталевим фібром бетоном внаслідок його руйнування за розтягу. Для виділення характеристик форми сигналу реалізували пакетне вейвлет-перетворення. Методом кластеризації k -середніх ідентифікували сигнали від розтріскування цементної матриці та витягування сталевих волокон. Також встановили, що зі зменшенням об'ємної частки волокна спадає кількість АЕ подій, які відповідають його витягуванню. Автори статті [20] зв'язок між поширенням тріщини та характеристиками сигналу АЕ досліджували під час чотириточкового згину залізобетонної балки, зміцненої листами армованого базальтом полімеру. Для кластеризації сигналів методом k -середніх

вибрали час наростання, середньоквадратичне відхилення сигналу та абсолютну енергію. Механізми пошкодження балок оцінювали за результатами комплексного аналізу зародження та поширення пошкоджень, а також типами руйнування. Виявили, що листи армованого базальтом полімеру значно підвищили тримку здатність балок.

Поєднуючи метод k -середніх кластеризації подій АЕ на основі максимальної частоти й амплітуди та цифрової кореляції зображень, автори праці [21] ідентифікували механізми руйнування композитних ламінатів. АЕ та інфрачервоне теплове зображення використали для вивчення механізмів руйнування склоепоксидних композитів з бульбашками та дефектами розшарування у публікації [22]. Методами k -середніх та головних компонент визначили характерний частотний діапазон для кожного виду пошкодження композиту. Запропонували [23] двоетапну кластеризацію для ідентифікування розвитку пошкодження в сендвічі-композиті зі скловолоконного полімеру та бальзи. Встановили, що амплітуда, максимальна частота та тривалість сигналу АЕ є індикаторами для виявлення зародження та розвитку пошкоджень і забезпечують ефективне застосування методу k -середніх для ідентифікування механізмів руйнування такого композиту. Виокремили міжфазне розшарування та мікротріщини в бальзовому ядрі; розшарування на межі між композитною оболонкою та серцевиною з бальзи; у композитній оболонці – розтріскування матриці, розшарування на межі волокно–матриця, розшарування та розрив волокон. Також запропонували кореляції між цими механізмами пошкодження та характеристиками обраних трьох параметрів АЕ. Нові методології застосування методу АЕ для характеристики пошкоджень в армованому вуглецевим волокном композиті описано в праці [24]. Для вибору репрезентативних ознак АЕ використали оцінки Лапласа та дисперсію даних. Виявили, що найефективніші для опису типів пошкоджень кумулятивна амплітуда, частота рахунку ($C-F_{req}$), частота повторення певного типу сигналу ($R-F_{req}$) та ентропія його форми. Розроблено комплексну характеристику типів пошкоджень на кожному етапі навантаження та остаточного руйнування. У праці [25] досліджували зародження, поширення та кінцеве руйнування армованого карбованим волокном полімеру під дією комбінованого навантаження. Зважену пікову частоту та амплітуду сигналів АЕ використали для кластеризації k -середніх та ідентифікації типів пошкодження за різних комбінованих умов навантаження. Результати ідентифікації підтверджено методом цифрової кореляції зображень. Поведінку під час згину та механізми пошкодження багатошарових полімерних композитів, армованих скловолокном, з різними наночастинками вивчали у праці [26]. Для кількісного визначення механізмів пошкодження застосували пакетне вейвлет-перетворення та швидке перетворення Фур'є. За вейвлет-перетворенням сигналів АЕ встановили, що розтріскування матриці – домінуючий механізм руйнування у всіх типах полімерів. Групували дані методами ієрархічної кластеризації та k -середніх, виявили вищу точність першого з них. Розвиток пошкоджень у зразках армованого скловолокном поліефірного композиту за допомогою різних підходів МН оцінено у праці [27]. Для прогнозування пошкоджень і вибору ключових характеристик АЕ вибрали методи XGboost, LightGBM і CatBoost, а за алгоритмом k -середніх класифікували тип пошкодження. Точність цих підходів підтверджує надійність МН для прогнозування втомної довговічності композиційних матеріалів за допомогою АЕ.

Сигнали АЕ аналізували також за алгоритмами нечіткої логіки (fuzzy C-means). Зокрема, в праці [28] досліджували стандартні ламіновані композити під час розтягу. Для розпізнавання механізмів їх пошкодження за дескриптор сигналів АЕ вибрали їх вейвлет-перетворення та методику нечітких C -середніх. Із точністю 85...89% виявили три типи пошкодження: розтріскування матриці, відшарування

волокна від матриці та його розрив. Підтверджували результати методом скінченних елементів (МСЕ) та порівнюючи зображення сканівного електронного мікроскопа. За такою ж методикою [29] визначали діапазони частот різних механізмів руйнування ламінованого карбонепоксидного композиту: розтріскування матриці (100...250 kHz), розрив волокна (420...500 kHz), його висмикування (250...320 kHz) і відшарування від матриці (320...380 kHz), а також розшарування ламінату (380...420 kHz). Кореляцію між механізмами руйнування та повзучістю у вологому окиснювальному середовищі композиту 2D-C/SiC на основі розпізнавання структур сигналів АЕ досліджували у праці [30]. За результатами факторного аналізу та кластеризації методом нечітких *C*-середніх ідентифікували: розтріскування матриці, пошкодження поверхні, розрив волокна та пучка волокон. За цими ж методиками встановили [31] характеристики сигналів АЕ механічних пошкоджень літій-іонних акумуляторів. У праці [32] подано результати ідентифікування механізмів руйнування у скловолоконному композиті залежно від способу переплетення волокон. Для цього скористались вейвлет-перетворенням і кластеризацією нечітких *C*-середніх. Ефективність такої ідентифікації перевірили МСЕ. Механізм внутрішньої втоми та розвиток пошкодження неперервних сталобетонних композитних балок досліджували у публікації [33]. Кластеризували сигнали АЕ за алгоритмом нечітких *C*-середніх. Запропонували новий метод визначення місця втомного пошкодження бетонної конструкції. Встановили залежності між характеристиками поширення втомної тріщини і законом зміни швидкості хвилі АЕ в бетоні. Довговічність балки прогнозували за кумулятивною моделлю пошкодження від втоми на основі енергії АЕ. У праці [34] за допомогою різних методів кластеризації оцінювали швидкість витоку клапана в трубопроводі природного газу. Щоб зменшити кількість надлишкової інформації та вибрати оптимальні характеристики кластеризації, застосували факторний аналіз. Порівнювали продуктивність трьох методів: нечітких *C*-середніх, *k*-середніх та *k*-медоїдів (*k-medoids*). Останній, на відміну від інших, розбиває набір даних на заздалегідь відому кількість кластерів. Модель, заснована на факторному аналізі та кластеризації *k*-медоїдів, виявилась надзвичайно ефективною для розв'язання задач такого типу. Її точність становить 95,8...96,3%. Розвиток пошкодження та механізмів руйнування корозійних бетонних балок, зміцнених вуглепластиком, досліджували у статті [35]. Використовуючи модель суміші Гауса для кластеризації сигналів АЕ, автори зауважили, що пошкодження бетонної матриці супроводжували високочастотні та низькоенергетичні сигнали АЕ; під час відшарування волокна від матриці виявили проміжні значення для всіх параметрів сигналів; розрив волокна супроводжували сигнали більшої тривалості, низької частоти та високої енергії. Водночас на кумулятивну енергію АЕ суттєво впливала корозія. За незначної сигнали АЕ володіли вищою кумулятивною енергією під час пошкодження бетонної матриці та відшарування волокна.

Алгоритми контрольованого навчання. Їх використовували у різноманітних прикладних задачах для автоматизації аналізу сигналів АЕ. Зокрема, автоматизовану систему виявлення дефектів клапана поршневого компресора методом опорних векторів (support vector machine – SVM) за параметрами АЕ описано у праці [36]. Виявили, що точність прогнозування запропонованої моделі становить 99,4%. Для моніторингу аномалій оброблення та прогнозування шорсткості поверхні під час одноточкового алмазного точіння побудували [37] модель, що використовує метод регресії опорних векторів (support vector regression – SVR). Середньоквадратична похибка прогнозування шорсткості поверхні становить 1,76 nm, а середня частота похибок ідентифікування дефектів процесу – 14,8%. Автори публікації [38] розробили підхід для ідентифікації та локалізації витоку в трубопроводах за параметрами сигналів АЕ (швидкістю рахунку, кумулятивною

енергією та потужністю сигналу) та двома алгоритмами МН: методом опорних векторів і розпізнаванням шаблонів (relevance vector machine – RVM). На точність та ефективність виявлення витоків впливає вибір функції ядра. У праці [39] запропонували концепцію системи виявлення тріщин у виробках, виготовлених лазерним сплавленням порошку, за сигналами АЕ та різними алгоритмами контрольованого навчання (логістичною регресією, класифікатором опорних векторів з лінійними та квадратичними експонентними ядрами, класифікаторами випадкового лісу та гауссівських процесів). Встановили, що у просторі хвильових відображень сигналів класифікатор гауссівських процесів має найвищу точність ідентифікування серед усіх моделей ($99\pm 1\%$), досягаючи найкращої продуктивності для 13 ознак, а в спектрі головних компонент найточніший алгоритм логістичної регресії ($99\pm 1\%$) – для 18 ознак. МН та метод АЕ виявились ефективними і для розроблення онлайн-системи моніторингу зношування коліс шліфувальної машини [40]. Вивчали також вплив на характеристики сигналів АЕ довжини вікон аналізу сигналів, типів ПАЕ та смуги їх пропускання. Вибрані з часової, частотної та частотно-часової областей характеристики сигналів АЕ уточнили, щоб зменшити надмірність ознак за алгоритмом послідовного плаваючого прямого вибору (sequential floating forward selection – SFFS). Підготовлені дані слугували вхідними параметрами методу опорних векторів для класифікації шаблонів сигналів АЕ. Такий підхід забезпечив стовідсоткову точність класифікації.

Відомі також застосування для аналізу сигналів АЕ логістичної регресії [41], лінійного дискримінантного аналізу [42] та k -найближчих сусідів [43].

Порівняння методів МН для аналізу сигналів АЕ. Важливе завдання ТД та НК матеріалів та конструкцій – виявити дефект, встановити його тип та локалізувати місце знаходження. Безумовно, точність отриманих за допомогою алгоритмів МН результатів залежить, насамперед, від якості вхідних даних, на що суттєво впливають умови експерименту, зокрема зовнішні та внутрішні завади (шуми), налаштування вимірювальної системи (порог дискримінації сигналу), вибір типу ПАЕ та місця його розташування до гіпотетичного дефекту, структурні особливості конструкційного матеріалу, геометрія об'єкта контролю тощо [44]. Ці чинники суттєво впливають на базові параметри сигналів АЕ – амплітуду, час наростання сигналу, енергію тощо, а відтак, і на прийняття релевантних рішень за результатами ТД. Водночас високу точність ідентифікування джерел АЕ забезпечують методики, які серед інших використовують часово-частотні характеристики сигналу АЕ за його вейвлет-перетворенням (див. таблицю). Застосовуючи МН для опрацювання великих обсягів даних, можна поглибити пошук кореляції між механізмами пошкодження конструкційних матеріалів та параметрами АЕ, а отже, підвищити точність результатів діагностування відповідальних об'єктів та виробів.

Як видно з таблиці, точність різних алгоритмів МН для ідентифікування та локалізації дефектів порівняльна, тому неможливо, опираючись на відомі результати, дати рекомендації про переваги того чи іншого алгоритму у конкретному випадку. Усе залежить від даних, якими оперує автоматизована система, та швидкості адаптації до них.

Як свідчить аналіз літературних джерел, алгоритми неконтрольованого навчання, зокрема кластеризації, переважно використовують для ідентифікування джерел АЕ у матеріалах зі складною структурою (різні композити, зварні з'єднання). Недоліком цих методів є відносно висока похибка та упереджені результати, хоча їх досить легко реалізувати з мінімальними обчислювальними затратами, що пояснює їх широке впровадження. Алгоритми контрольованого навчання застосовують для виявлення дефектів у різних об'єктах контролю під час складних виробничих процесів та експлуатації. Точність отриманих результатів подекуди досягала максимально можливого значення.

Точність алгоритмів МН (за результатами публікацій)

Метод МН	Джерело	Точність, %	
		min	max
Алгоритми неконтрольованого навчання			
<i>k</i> -середніх (<i>k</i> -means)	[15]	91	93
<i>C</i> -середніх (<i>C</i> -means)	[28]	85	89
<i>k</i> -медоїди (<i>k</i> -medoids)	[34]	95,8	96,3
Алгоритми контрольованого навчання			
Метод опорних векторів (Support Vector Machine)	[36, 40]	99,4	100
Регресія опорних векторів (Support Vector Regression)	[37]	–	85,2
Класифікатор гауссівських процесів (Gaussian Process Classifier)	[39]	98	100
Логістична регресія (Logistic Regression)	[39]	98	100
Лінійного дискримінантного аналізу (Linear Discriminant Analysis)	[42]	–	85
<i>k</i> -найближчих сусідів (<i>k</i> -nearest neighbor)	[43]	–	97

ВИСНОВКИ

Надійна ідентифікація та локалізація дефектів у структурі конструкційних матеріалів спрямовані на реалізацію безпечного та стійкого використання відповідальних інженерних систем. Найкращі результати отримані інтегруванням передових методів НК, зокрема методу АЕ та сучасних алгоритмів, для вдосконалення постопрацювання сигналів. Аналіз найновіших літературних джерел свідчить, що досягти поставленої мети можна, впроваджуючи в автоматизовані системи опрацювання сигналів АЕ моделі неконтрольованого та контрольованого МН, які довели свою незаперечну ефективність для виявлення дефектів та їх класифікації. Водночас для забезпечення високої точності результатів важлива якість вхідних даних, особливо через зростання їх обсягів. Для цього потрібна ретельна підготовка до експериментальних досліджень із урахуванням як умов їх виконання, так і апаратних засобів. У другій частині огляду проаналізуємо найновіші дослідження методик використання штучних нейронних мереж та алгоритмів глибокого навчання для розв'язання різноманітних задач АЕ діагностування.

1. Skalskyi V., Nazarchuk Z., and Stankevych O. Macrofracture of structural materials and methods of determining its type // Acoustic Emission. Fracture Detection in Structural Materials. – Cham: Springer, 2022. – P. 1–50.
2. Skalskyi V., Nazarchuk Z., and Stankevych O. Mathematical models for displacement fields caused by the crack in an elastic half-space // Acoustic Emission. Fracture Detection in Structural Materials. – Cham: Springer, 2022. – P. 51–86.
3. Taheri H., Bocanegra M. G., and Taheri M. Artificial Intelligence, Machine Learning and Smart Technologies for Nondestructive Evaluation // Sensors. – 2022. – 22, № 11. – Article number 4055. <https://doi.org/10.3390/s22114055>
4. ДСТУ 9118:2021. Технічна діагностика. Діагностування технічного стану матеріалів конструкцій. Загальні вимоги. – Чинний від 2022–07–01.
5. Skalsky V. R., Stankevych O. M., and Kuz I. S. Application of wavelet transform for the analysis of acoustic-emission signals accompanying fracture processes in materials (A survey) // Materials Science. – 2018. – 54, № 2. – P. 139–153. <https://doi.org/10.1007/s11003-018-0168-1>
6. 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 // Strength Mater. – 2015. – 47, № 4. – P. 566–572.

7. Дослідження впливу поверхневої обробки та гартування сталі 60C2A 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. 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.
9. 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.
10. Surucu O., Gadsden S. A., and Yawney J. Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances // Expert. Syst. Appl. – 2023. – **221**. – Article number 119738. <https://doi.org/10.1016/j.eswa.2023.119738>
11. Ciaburro G. and Iannace G. Machine-learning-based methods for acoustic emission testing: a review // Appl. Sci. – 2022. – **12**. – Article number 10476.
12. State-of-the-art review on the acoustic emission source localization techniques / F. Hassan, A. K. B. Mahmood, N. Yahya, A. Saboor, M. Z. Abbas, Z. Khan, and M. Rimsan // IEEE Access. – 2021. – **9**. – P. 101246–101266.
13. Isonkobong C. Machine learning: review // Semicond. Sci. Inform. Dev. – 2020. – **2**, № 2. – P. 5–14.
14. A short review on different clustering techniques and their applications / A. Ghosal, A. Nandy, A. K. Das, S. Goswami, and M. Panday // Emerging Technology in Modelling and Graphics. – Springer: 2020. – P. 69–83.
15. Pomponi E. and Vinogradov A. A real-time approach to acoustic emission clustering // Mech. Syst. Signal Process. – 2013. – **40**. – P. 791–804.
16. Tracing fracture damage evolution and identifying damage patterns in cast steel using advanced acoustic emission analysis / X. Wang, J. Xu, Q. Yue, and X. Liu // Eng. Fract. Mech. – 2023. – **293**. – Article number 109680. <https://doi.org/10.1016/j.engfracmech.2023.109680>
17. Acoustic emission technology-based multifractal and unsupervised clustering on crack damage monitoring for low-carbon steel / J. Huang, Z. Zhang, B. Zheng, R. Qin, G. Wen, W. Cheng, and X. Chen // Measurement. – 2023. – **217**. – Article number 113042. <https://doi.org/10.1016/j.measurement.2023.113042>
18. Investigation the effect of freeze–thaw cycle on fracture mode classification in concrete based on acoustic emission parameter analysis / S. Lian, K. Zheng, Y. Zhao, J. Bi, C. Wang, and Y. Huang // Constr. Build. Mater. – 2023. – **362**. – Article number 129789. <https://doi.org/10.1016/j.conbuildmat.2022.129789>
19. Saha I. and Sagar R. V. Classification of the acoustic emissions generated during the tensile fracture process in steel fibre reinforced concrete using a waveform-based clustering method // Constr. Build. Mater. – 2021. – **294**. – Article number 123541.
20. Assessment of damage evolution of concrete beams strengthened with BFRP sheets with acoustic emission and unsupervised machine learning / K. Liu, T. Wulan, Y. Yao, M. Biam, and Y. Bao // Eng. Struct. – 2024. – **300**. – Article number 117228.
21. Andraju L. B. and Raju G. Damage characterization of CFRP laminates using acoustic emission and digital image correlation: Clustering, damage identification and classification // Eng. Fract. Mech. – 2023. – **277**. – Article number 108993.
22. Cluster analysis of acoustic emission signals and infrared thermography for defect evolution analysis of glass/epoxy composites / Ya. Zhang, B. Zhou, F. Yu, and Ch. Chen // Infrared Phys. Technol. – 2021. – **112**. – Article number 103581.
23. Characterization of damage mechanisms of GFRP-balsa sandwich under 4-point bending based on two-step clustering process in acoustic emission analysis / Y. Wu, M.-L. Pastor, M. Perrin, P. Casari, and X. Gong // Compos. Part B: Eng. – 2023. – **260**. – Article number 110774. <https://doi.org/10.1016/j.compositesb.2023.110774>
24. Laplacian score and K-means data clustering for damage characterization of adhesively bonded CFRP composites by means of acoustic emission technique / C. Barile, C. Casalova, G. Pappalettera, and V. P. Kannan // Appl. Acoust. – 2022. – **185**. – Article number 108425. <https://doi.org/10.1016/j.apacoust.2021.108425>
25. Experimental investigation on open-hole CFRP laminate under combined loading using acoustic emission and digital image correlation / P. Mahesh, V. Chinthapenta, G. Raju, and M. Ramji // Theor. Appl. Fract. Mech. – 2024. – **130**. – Article number 104300.

26. *Investigating the flexural behavior of nanomodified multi-delaminated composites using acoustic emission technique* / S. Alimirzaei, R. Barbaz-Isfahani, A. Khodaei, M. A. Najafabadi, and M. Sadighi // *Ultrasonics*. – 2024. – **138**. – Article number 107249.
27. *Gholizadeh S., Leman Z., and Baharudin B. T. H. T. State-of-the-art ensemble learning and unsupervised learning in fatigue crack recognition of glass fiber reinforced polyester composite (GFRP) using acoustic emission* // *Ultrasonics*. – 2023. – **132**. – Article number 106998. <https://doi.org/10.1016/j.ultras.2023.106998>
28. *Correlation of acoustic emission with finite element predicted damages in open-hole tensile laminated composites* / R. Mohammadi, M. A. Najafabadi, M. Saeedifar, J. Yousefi, and G. Minak // *Compos. Part B: Eng.* – 2016. – **108**. – P. 427–435.
29. *Clustering effect on damage mechanisms in open-hole laminated carbon/epoxy composite under constant tensile loading rate, using acoustic emission* / H. Sayar, M. Azadi, A. Ghasemi-Ghalebahman, and S. M. Jafari // *Compos. Struct.* – 2018. – **204**. – P. 1–11.
30. *Correlation between failure mechanism and rupture lifetime of 2D-C/SiC under stress oxidation condition based on acoustic emission pattern recognition* / P. Lyu, L. Yao, X. Ma, G. An, G. Bai, A. T. Aufousti, and X. Tong // *J. Eur. Ceram. Soc.* – 2020. – **40**, № 15. – P. 5094–5102. <https://doi.org/10.1016/j.jeurceramsoc.2020.06.070>
31. *Acoustic emission analysis of 18,650 lithium-ion battery under bending based on factor analysis and the fuzzy clustering method* / C. Tang, Z. Yuan, G. Liu, S. Jiang, and W. Hao // *Eng. Fail. Anal.* – 2020. – **117**. – Article number 104800.
32. *Acoustic emission study of effect of fiber weaving on properties of fiber-resin composite materials* / Y. Mi, C. Zhu, X. Li, and D. Wu // *Compos. Struct.* – 2020. – **237**. – Article number 111906. <https://doi.org/10.1016/j.compstruct.2020.111906>
33. *Experimental study on fatigue damage of continuous steel-concrete composite beam by acoustic emission* / L. Yan, B. Han, J. Zhang, W. Li, H. Xie, C. Gao, L. Chen, J. Yu, Z. Song, and B. Zuo // *Structures*. – 2023. – **57**. – Article number 105185.
34. *Natural gas pipeline valve leakage rate estimation via factor and cluster analysis of acoustic emissions* / S.-B. Zhu, Z.-L. Li, S.-M. Zhang, L.-L. Liang, and H.-F. Zhang // *Measurement*. – 2018. – **125**. – P. 48–55.
35. *Damage pattern recognition for corroded beams strengthened by CFRP anchorage system based on acoustic emission techniques* / T. Pan, Y. Zheng, Y. Zhou, W. Luo, X. Xu, C. Hou, and Y. Zhou // *Constr. Build. Mater.* – 2023. – **406**. – Article number 133474.
36. *Automated valve fault detection based on acoustic emission parameters and support vector machine* / S. M. Ali, K. H. Hui, L. M. Hee, and M. S. Leon // *Alex. Eng. J.* – 2018. – **57**. – P. 491–498.
37. *Typical signal anomaly monitoring and support vector regression-based surface roughness prediction with acoustic emission signals in single-point diamond turning* / K.-E. Tang, C.-Y. Weng, Y.-C. Cheng, and C.-W. Liu // *J. Manuf. Proc.* – 2024. – **112**. – P. 126–135.
38. *Banjara N. K., Sasmal S., and Voggu S. Machine learning supported acoustic emission technique for leakage detection in pipelines* // *Int. J. Press. Vessel. Pip.* – 2020. – **188**. – Article number 104243. <https://doi.org/10.1016/j.ijpvp.2020.104243>
39. *An in situ crack detection approach in additive manufacturing based on acoustic emission and machine learning* / D. Y. Kononenko, V. Nikonova, M. Seleznev, J. van Brink, and D. Chernyavsky // *Addit. Manuf. Lett.* – 2023. – **5**. – Article number 100130.
40. *Shen C.-H. Acoustic emission based grinding wheel wear monitoring: Signal processing and feature extraction* // *Appl. Acoust.* – 2022. – **196**. – Article number 108863.
41. *Cutting tool operational reliability prediction based on acoustic emission and logistic regression model* / H. Li, Y. Wang, P. Zhao, X. Zahng, and P. Zhou // *J. Intell. Manuf.* – 2015. – **26**. – P. 923–931.
42. *An acoustic emission based approach for damage pattern recognition in composite using linear discriminant analysis* / R. Liu, S. Qiao, C. Li, L. Ma, W. Zhou, and Q. Li // *Compos. Adv. Mater.* – 2024. – **33**. – P. 1–17.
43. *Li R., He D., and Bechhoefer E. Investigation on fault detection for split torque gearbox using acoustic emission and vibration signals* // *Annual Conf. of the PHM Soc.* – 2009. – P. 1–11.
44. *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 Comput. Mater.* – 2021. – **7** (95). <https://doi.org/10.1038/s41524-021-00565-x>

Одержано 25.03.2024