



§10.2 МЕТОД ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ АВТОМАТИЗОВАНОГО АНАЛІЗУ ВИМІРЮВАЛЬНИХ ДАНИХ ЕЛЕКТРОЕНЕРГІЇ НА ОСНОВІ ГЛИБИННОГО НАВЧАННЯ БЕЗ ВЧИТЕЛЯ (Коломійцев О.В., Національний технічний університет «Харківський політехнічний інститут», Слободяник О.Ю., Національний технічний університет «Харківський політехнічний інститут»)

Вступ. Сучасні енергетичні системи швидко трансформуються під впливом цифровізації, розвитку розподілених джерел, інтернету речей (Internet of Things, IoT) та розумних лічильників. Різноманіття компонентів, збільшення об'ємів даних (масштабуванні) та необхідність їх оперативного аналізу висувають нові вимоги до систем моніторингу якості електроенергії (power quality, PQ).

Існуючі засоби аномального аналізу покладаються на ознаки та правила, що не дозволяє вчасно виявляти складні патерни (pattern – зразок, шаблон, модель, закономірність у вирішенні певної задачі) у великих потоках вимірювальних даних. Дослідження показують, що з поширенням пристроїв IoT енергетичні системи стають більш складними, а відомі методи виявлення аномалій та відхилень перестають збільшувати об'єми роботи (масштабувати). Крім того, централізоване об'єднання даних спричинює затримки та ризики у конфіденційності.

Глибинне навчання (deep learning) відкриває можливості для автоматизованого вилучення прихованих ознак з сигналів та виявлення нетипових режимів без необхідності ретельного ручного налаштування. Однак, більшість існуючих моделей потребує наявності мічених вибірок, що проблематично у реальному моніторингу PQ.

Саме тому, актуальною є розробка та удосконалення методів глибинного навчання без вчителя (unsupervised deep learning), здатних ідентифікувати та



кластеризувати типові та аномальні режими в умовах відсутності еталонних міток. Така ідея отримує підтвердження у сучасних дослідженнях.

На приклад, у [1] запропоновано автоенкодерно-федеративний підхід для покращення виявлення аномалій у розподілених енергосистемах, що підкреслює проблеми традиційних методів у масштабуванні та конфіденційності, а також переваги глибинного представлення даних.

У [2] розглядається гібридна система для ідентифікації порушень якості електроенергії, де безперервні вейвлет-перетворення та глибокі нейронні мережі (ResNet/VGG) комбінуються з аналізом важливості ознак та SVM-класифікатором. Така система на тестових мережах IEEE 9-bus та 13-bus досягає точності 98,54 % та 97,17 % відповідно, перевершивши традиційні методи на основі перетворень Фур'є та вейвлетів.

Незважаючи на переваги, більшість представлених рішень орієнтуються на класифікацію за заздалегідь визначеними класами порушень або потребують ручного узгодження параметрів. В умовах польових вимірювань доводиться працювати з різнорідними сигналами, відсутністю однозначних міток та великою часткою пропущених або зіпсованих даних. Отже, виникає необхідність у методах, які забезпечать адаптивність, стійкість до шуму, здатність до самоорганізації та інтерпретації результатів [7, 8].

Запропонований у статті удосконалений метод оснований на глибинному навчанні без вчителя для підвищення ефективності автоматизованого аналізу вимірювальних даних електроенергії. Метод поєднує переваги глибинних моделей з вимогами галузевих стандартів (IEC 61000-4-30) [4-6] та забезпечує оперативну підтримку рішень у системах SCADA/АСУ.

У межах дослідження передбачено:

- розробку модуля попередньої обробки даних, який враховує реальні умови вимірювань (пропуски, несинхронність та різні класи PQ);



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

- удосконалення ядра методу завдяки інтеграції двох взаємопов'язаних аналітичних контурів – глибинного автоенкодера з кластеризацією ознак та механізму глибокого виявлення аномалій у спільному латентному просторі представлення PQ-даних [8, 9];

- створення механізму інтерпретації результатів та зворотного зв'язку, який забезпечить аудиторську відтворюваність та відповідність вимогам NIST щодо пояснюваного штучного інтелекту;

- реалізацію блоку підтримки рішень, який агрегує вікна в інциденти, ранжує події за критичністю та генерує рекомендації диспетчеру.

Втілення такого підходу дозволить підвищити ефективність автоматизованого аналізу вимірювальних даних електроенергії, зменшити кількість хибних спрацювань, забезпечити своєчасне виявлення суттєвих відхилень та зробити результати зрозумілими для операторів.

Таким чином, розробка методу підвищення ефективності автоматизованого аналізу вимірювальних даних електроенергії на основі глибинного навчання без вчителя є актуальною науковою задачею.

Виклад основного матеріалу. В роботі викладається єдина концепція розробки методу підвищення ефективності автоматизованого аналізу даних показників якості електроенергії. Метод інтегрує дві складові дослідження: удосконалені метод глибинного автоенкодера з кластеризацією ознак та метод глибокого виявлення аномалій у даних PQ. Обидва методи працюють у складі одного аналітичного конвеєра, що пов'язує моделювання типової «норми» з моніторингом відхилень. Така узагальнена постановка задачі пов'язана з результатами [3], де підкреслено необхідність формування стійких латентних представлень часових фрагментів PQ-сигналів та виявлення аномальних відхилень без повної розмітки даних.

Метод оснований на тому, що вихідні дані – це великі масиви багатоканальних часових рядів показників якості електроенергії (напруга,



струм, гармоніки, індекси пульсацій тощо) з відповідними часовими мітками та метаданими (стан пристроїв, умови роботи та оцінка якості прийому). Дані, після попередньої обробки утворюють набір часових вікон спостереження. При цьому, спочатку формуються компактні латентні представлення для типових режимів роботи системи за допомогою автоенкодера, а потім – у тому ж просторі, здійснюється детектування аномалій, які не відповідають нормальному режиму.

На рис. 1 наведено структурну схему, яка показує логічні блоки методу.

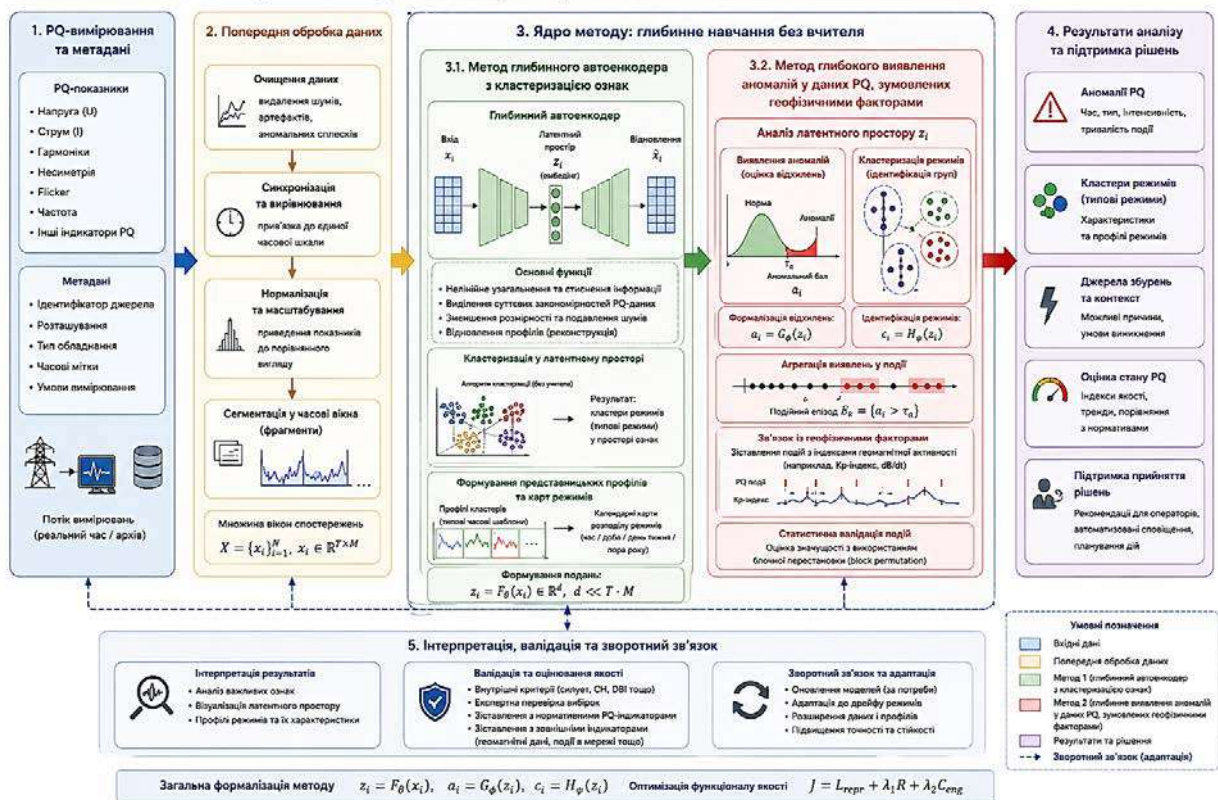


Рис. 1 Узагальнена структура методу підвищення ефективності аналізу даних показників якості електроенергії – від попередньої обробки даних до виділення типових режимів та подієвого детектування аномалій

Зроблено наступне припущення. Нехай X – матриця вхідних даних, яка записана у вигляді множини N часових вікон (фрагментів) довжини T



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

(кількість відліків вікна) та з M каналами (різні показники) наступним чином:

$$X = \{x_i\}_{i=1}^N, x_i \in R^{T \times M}, \quad (1)$$

де x_i – вектор-матриця вимірювань i -го вікна, який містить значення усіх M показників у T моментах часу.

Наприклад, за кроком 10 хв протягом доби матриця x_i може мати розмірність $T = 144$ та $M = 5$ каналів (5 показників якості). Набір X формується після виділення «спокійних» інтервалів (без техногенних аномалій та підвищеної геомагнітної активності) у вихідних PQ-даних.

Для коректного навчання автоенкодера важливо вирівняти амплітуди сигналів, щоб модель аналізувала форми, а не абсолютні рівні. Тому, кожен канал даних стандартизується за фіксованим часом доби наступним чином:

$$x \sim_i(t) = \frac{x_i(t) - \mu_t}{\sigma_t}, \quad (2)$$

де μ_t та σ_t – середнє та стандартне відхилення усіх $x_j(t)$ у фіксований момент доби t за усіма вікнами i .

Такий підхід знижує вплив дисбалансу та дрейфу потужностей на результат та забезпечує узгодженість масштабів під час кластеризації.

Вихідні дані мають фрагментації (добові цикли, зміни навантаження тощо). Набір добових фрагментів можливо представити наступним чином:

$$\{x_i\}_{i=1}^N, x_i = [x_i(1), x_i(2), \dots, x_i(T)], \quad (3)$$

де $x_i(t)$ – значення показника у часовий відлік t (при множинних каналах – відповідний вектор).



Даний крок виконується перед автоенкодером та забезпечує порівнянність форм. Модель навчається на одноманітних послідовностях (наприклад, кожне x_i – це добове коливання гармоніки напруги).

У загальному вигляді до основних аналітичних блоків методу можливо віднести наступні.

1. Блок PQ-вимірювань (показників) та метаданих.
2. Блок попередньої обробки даних.
3. Блок глибинного навчання без вчителя (ядро методу).
4. Блок результатів аналізу та підтримки рішень.
5. Блок інтерпретації, валідації та зворотного зв'язку.

Блок PQ-вимірювань (показників) та метаданих, який є одним із основних елементів запропонованої архітектури інтелектуального аналізу даних якості електричної енергії. Даний блок забезпечує формування інформаційного простору для подальшої обробки, кластеризації та виявлення аномальних режимів функціонування електроенергетичної системи на основі методів глибокого навчання без вчителя. Множину вхідних даних можна представити у наступному вигляді:

$$X = \{x_1, x_2, \dots, x_N\},$$

де N – кількість вимірних часових фрагментів або записів PQ-моніторингу, а кожен елемент x_i описує поточний стан системи електропостачання у певний момент часу.

Кожний вектор спостереження формується наступним чином:

$$x_i = [U_i, I_i, f_i, THD_{U_i}, THD_{I_i}, P_i, Q_i, S_i, \cos \varphi_i, \Delta U_i, K_{nsym_i}],$$

де U_i – діюче значення напруги; I_i – діюче значення струму; f_i – частота мережі; THD_{U_i} – коефіцієнт гармонічних спотворень напруги; THD_{I_i} –



коефіцієнт гармонічних спотворень струму; P_i – активна потужність; Q_i – реактивна потужність; S_i – повна потужність; $\cos[\varphi_i]$ – коефіцієнт потужності; ΔU_i – відхилення напруги від номінального значення; K_{nsym} – коефіцієнт несиметрії фаз.

Формування такого набору параметрів обумовлено необхідністю комплексного опису як стаціонарних, так і перехідних режимів електроенергетичної системи. На відміну від відомих методів, де аналіз окремих RQ-показників здійснюється ізольовано, у методі використовується багатовимірний опис стану мережі, що дозволяє враховувати приховані кореляційні залежності між параметрами.

Для забезпечення коректної роботи моделей глибокого навчання виконується попередня нормалізація даних наступним чином:

$$x_{ij}^{norm} = \frac{x_{ij} - \mu_j}{\sigma_j},$$

де x_{ij} – значення j -го параметра для i -го вимірювання; μ_j – середнє значення j -го параметра; σ_j – середньоквадратичне відхилення j -го параметра.

Нормалізація дозволяє привести параметри з різними фізичними розмірностями до єдиного масштабу та підвищити стійкість процесу навчання нейромережевої моделі. Окрім безпосередньо RQ-показників, блок містить метадані, які характеризують контекст виникнення вимірних подій.

Метадані можливо представити у наступному вигляді:

$$M_i = [t_i, L_i, ID_i, T_i, C_i],$$

де t_i – часовий штамп вимірювання; L_i – місце встановлення вимірювального пристрою; ID_i – ідентифікатор вузла або сенсора; T_i – тип



події або режиму; C_i – службові характеристики або додаткові параметри конфігурації.

Використання метаданих є важливим для подальшої інтерпретації результатів кластеризації та аналізу аномалій. Наприклад, однакові відхилення напруги можуть мати різну природу, залежно від часу доби, типу навантаження або географічного розташування вузла мережі.

Таким чином, метадані формують додатковий семантичний рівень опису стану енергосистеми. Сукупність PQ-вимірювань та метаданих утворює розширений інформаційний простір наступним чином:

$$Z_i = \{x_i, M_i\},$$

який подається на блок глибокого ненаглядного навчання для побудови латентного представлення даних. У процесі навчання нейромережа автоматично виділяє приховані закономірності, характерні для нормальних та аномальних режимів функціонування електроенергетичної системи.

Запропонований підхід дозволяє підвищити інформативність аналізу PQ-даних, зменшити вплив шумових компонент та забезпечити адаптивне виявлення нових типів аномалій без необхідності попереднього ручного маркування даних.

Даний підхід важливий для сучасних Smart Grid-систем, у яких об'єм телеметричної інформації постійно зростає, а характер режимів роботи мережі є динамічним та слабо формалізованим [14, 15].

Блок попередньої обробки даних у структурі методу, наведено на рис. 1, виконує роль шлюзу між сирими PQ-вимірюваннями та ядром глибокого навчання без вчителя. Його завдання полягає у відокремленні технічних артефактів вимірювання від фізично змістовних відхилень, синхронізації багатоканальних рядів, вирівнюванні масштабів, формуванні часових вікон та приєднанні контекстних метаданих.



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

Даний підхід є основним, оскільки сучасні безнаглядні моделі аномалій для багатовимірних часових рядів навчаються на «нормальних» спостереженнях та чутливі до забруднення навчального набору, тоді як нормативні документи для RQ-моніторингу вимагають порівнюваних та відтворюваних процедур вимірювання й інтерпретації результатів.

У повній логіці методу блок попередньої обробки розташований між блоком «RQ-вимірювання та метадані» та двома аналітичними гілками ядра методу: глибинним автоенкодером із кластеризацією ознак та модулем глибокого виявлення аномалій.

Тому, його вихід має бути придатним одночасно для реконструктивного навчання, кластерного аналізу та подієвого детектування. Це означає, що на виході формується не лише тензор очищених вікон, а й маска валідності, оцінка якості вікна, вирівняні метадані та компактний набір похідних ознак для допоміжного аналізу:

$$\mathcal{D}_{\text{prep}} = \{(\mathbf{X}_i, \boldsymbol{\mu}_i, \mathbf{V}_i, q_i, \boldsymbol{\phi}_i)\}_{i=1}^N,$$

де $X_i \in \mathbb{R}^{T_w \times c}$ – очищене вікно довжини T_w для C каналів; μ_i – вирівняний вектор метаданих; $V_i \in \{0, 1\}^{T_w \times c}$ – маска валідності; $q_i \in [0, 1]$ – інтегральна оцінка якості вікна; ϕ_i – набір похідних ознак; N – кількість сформованих вікон.

Якість вікна визначається як частка валідних відліків наступним чином:

$$q_i = \frac{1}{T_w \cdot C} \sum_{t=1}^{T_w} \sum_{m=1}^C V_i(t, m).$$

Така форма подання узгоджується з переходом від потоку сирих вимірювань до множини вікон спостережень у блоці 2 (рис. 1). Однак, додатково робить конвеєр відтворюваним та придатним до аудиту.



Послідовність операцій у блоці попередньої обробки організовується наступним чином. Спочатку виконується контроль цілісності даних: перевіряються монотонність часових міток, дублікати, відповідність одиниць вимірювання та конфігурації каналів. Далі, проводиться синхронізація та вирівнювання каналів відносно єдиної часової шкали.

За умови, якщо джерела працюють у потоковому режимі, синхронізацію доцільно орієнтувати на event-time, а не лише на processing-time, оскільки для необмежених та неупорядкованих потоків істотними є саме порядок подій та виконання за власним часом даних.

Після часового вирівнювання – виконується очищення від технічних викидів та імпульсних артефактів. Тому, використовується робастний локальний критерій на основі медіани та MAD:

$$r_m(t) = \frac{|y_m(t) - \text{med}_{\tau \in N_t} y_m(\tau)|}{1.4826 \cdot \text{MAD}_{\tau \in N_t}(y_m(\tau)) + \varepsilon},$$

де $y_m(t)$ – значення m-го каналу в момент часу t ; $N_t = \{\tau : |\tau - t| \leq L_h\}$ – локальне вікно; med – медіана; MAD – median absolute deviation; ε – мале число для забезпечення числової стійкості.

За умови, якщо виконується умова наступна умова:

$$r_m(t) > \kappa_h,$$

то відлік позначається як технічний викид, але замінюється лише тоді, коли сплеск не підтверджується суміжними каналами або фізикою режиму.

На етапі обробки пропусків короткі розриви доцільно заповнювати інтерполяцією, а довгі – переносити в маску валідності. Для короткого пропуску використовується



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

$$\tilde{y}_m(t) = y_m(t_\ell) + \frac{t - t_\ell}{t_r - t_\ell} (y_m(t_r) - y_m(t_\ell)), \quad g \leq g_{\max},$$

де t_l та t_r – сусідні валідні точки; g – довжина пропуску; g_{\max} – максимально допустима довжина інтерпольованого фрагмента.

За умови, якщо частка невалідних відліків у вікні перевищує встановлений поріг, таке вікно не використовується для навчального набору, що дозволяє зменшити ризик внесення штучних патернів у латентний простір моделі. Після цього, виконуються ресемплінг, детрендинг та робастне масштабування.

Для приведення параметрів до єдиного масштабу використовується IQR-нормалізація наступним чином:

$$x_m^{prep}(t) = (\tilde{y}_m(t) - b_m(t)) / (IQR_m + \varepsilon),$$

де $b_m(t)$ – локальна основна лінія сигналу, яка визначається рекурсивно:

$$b_m(t) = \alpha \tilde{y}_m(t) + (1 - \alpha) b_m(t - 1),$$

де $\alpha \in [0.05; 0.2]$ – коефіцієнт згладжування.

Для каналів із важкохвостим розподілом, зокрема THD або енергій гармонічних груп [13], до масштабування доцільно застосовувати логарифмічне перетворення наступним чином:

$$x_m^{log}(t) = \log(1 + x_m(t)).$$



Після нормалізації формуються похідні ознаки, які використовуються для допоміжного аналізу та інтерпретації результатів. Узагальнений вектор таких ознак можна записати як:

$$\varphi_i = [\max_t |\Delta x_m(t)|, \text{RMS}(x_m), \rho_{1,m}, E_m^{\text{Hf}}]_{m=1}^c,$$

де $\rho_{1,m}$ – лагова автокореляція першого порядку; E_m^{Hf} – енергія високочастотної складової або гармонічної підгрупи.

Завершальними операціями є сегментація у часові вікна, аугментація та вирівнювання метаданих. Для контекстних моделей доцільно використовувати вікна довжини $T^w = 36 \dots 144$ відліків із кроком ковзання $s = 1 \dots 6$, що забезпечує компроміс між оперативністю, стійкістю та чутливістю до добових патернів навантаження.

Першим аналітичним блоком ядра методу є глибинний автоенкодер з кластеризацією ознак. Автоенкодер складається з енкодера F_θ та декодера D_η , що послідовно зменшують розмірність входу до компактного латентного вектора, а потім – відновлюють сигнал. Процес навчання формалізується наступним чином:

$$z_i = F_\theta(x_{\sim i}), z_i \in R^d, d \ll T \cdot M, \quad (4)$$

де $x_{\sim i}$ – нормалізоване вхідне вікно; z_i – його латентний код розмірності d ; θ – параметри енкодера.

Декодер відновлює сигнал наступним чином:

$$x_i = D_\eta(z_i), \quad (5)$$

де η – параметри декодера.



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

Під час навчання мінімізується середньоквадратична помилка реконструкції:

$$L_{rec}(\theta, \eta) = \frac{1}{N} \sum_{i=1}^N \|x_{\sim i} - x_i\|_F^2. \quad (6)$$

Одночасно з навчанням автоенкодера задається кількість кластерів K . Після отримання латентних кодів $\{z_i\}$ виконується кластеризація (наприклад, методом k -середніх) у латентному просторі. Кожному з K кластерів відповідає типова група вікон. Для кожного кластера обчислюється центр m_k у просторі z та декодується:

$$x_{repr,k} = D_{\eta}(m_k), \quad (7)$$

що дає репрезентативний профіль $x_{repr,k}$ – типовий добовий сигнал для даного режиму.

Таке реконструювання профілів та побудова календарних карт режимів (з тривалістю та частотою появи кластерів у часі) забезпечують інтерпретацію результатів (типових шаблонів роботи).

Отже, удосконалений метод глибинного автоенкодера з кластеризацією ознак для аналізу великих масивів даних показників якості електроенергії вирішує задачу виділення типових режимів: формує компактні ознаки, групує їх у кластери та відновлює репрезентативні шаблони.

Другий аналітичний контур призначений для моніторингу відхилень від типового режиму. Тут використовується той же простір латентних ознак z_i , але для виявлення часових вікон, що не узгоджуються з «нормою».

Спочатку задається навчання моделі (наприклад, того самого автоенкодера або прогностичної нейромережі) лише на нормальних даних



(таймові проміжки без буревіїв та техногенних перебоїв). Після цього, для кожного вікна x_i обчислюється оцінка аномальності (аномальний скор) s_i , наприклад як відстань MSE між x_i та його реконструкцією \hat{x}_i (або приріст помилки рекурсії). Отже, це задається як:

$$s_i = \|x_i - \hat{x}_i\|_F^2. \quad (8)$$

Далі, обирається поріг τ детектування аномалій, щоб контролювати рівень помилкових спрацювань. Наприклад, поріг може бути визначений як квантиль α розподілу скорів на тренувальній вибірці (невеликий α дає малу частку хибних спрацювань):

$$\tau = Q_\alpha(\{s_j\}_{j \in \text{train}}). \quad (9)$$

Вікно i позначається аномальним, якщо $s_i > \tau$. Окремі ізольовані спрацювання групуються у події за часовим критерієм (наприклад, суміжні або близькі за часом вікна з $s > \tau$ об'єднуються в один інцидент з піковим скором s_{\max} та тривалістю).

Таким чином, метод глибокого виявлення аномалій у даних PQ, зумовлених геофізичними факторами, вирішує задачу виявлення де тимчасові серії PQ виходять за межі нормального контексту. Він формує безперервний показник аномальності та агрегацію спрацювань у події з атрибутами (аномальний скор, тривалість, зв'язок із GIC).

Визначення порога за ROC/PR-аналізом із заданим рівнем хибних спрацювань та зведення метрик Precision/Recall/F1 для оцінки якості детектування дають відповідні чисельні критерії.



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

Для кількісної оцінки ефективності обох блоків запропоновано використовувати узгоджені метрики, зокрема:

- для блоку кластеризації – середній силует (silhouette) [10] та стійкість кластерів при різних ініціалізаціях/підвибірках;
- для блоку детектування – метрики якості детекції подій (Precision, Recall, F1) на рівні епізодів, частка False Alarm Rate (FAR), а також медіанна затримка (lead time) виявлення;
- значущість зв'язку подій з геомагнітними індексами оцінюється за *r-value* блочних перестановок.

У логіці удосконаленого методу (рис. 1), блок результатів аналізу та підтримки рішень завершує перетворення латентних представлень, кластерних міток та скорів аномальності на операторські сутності – події, попередження, KPI, звіти та рекомендації.

Далі, блок інтерпретації, валідації та зворотного зв'язку – перевіряє достовірність даних результатів, надає пояснення, збирає операторські підтвердження та повертає сигнали для корекції порогів, правил агрегації та циклу супроводу моделей. Така замкнена архітектура відповідає загальній ідеї статті: «типові режими → аномалії → інтерпретація → рішення → контроль якості та адаптація».

Призначення блоку результатів аналізу та підтримки рішень полягає у тому, щоб перетворити вихід ядра глибинного аналізу без учителя на форму, придатну для оперативного використання в цифровізованому контурі моніторингу PQ.

На його вхід надходять: ідентифікатор та часові межі вікна, вузол або фідер, клас вимірювання, рівень агрегації, ознаки валідності, кластер типового режиму, відстань до репрезентативного профілю, аномальний скор, оцінка невизначеності та посилання на первинний фрагмент або хвильову форму.



На виході формуються три групи артефактів: подієві повідомлення тривоги, аналітичні зведення для диспетчера та періодичні KPI-знімки (KPI snapshots – знімки основних показників ефективності) для звітності й контролю експлуатації. Даний підхід продовжує зв'язок «типові режими → подієве детектування», де передбачено агрегацію віконних спрацювань у події, оцінювання їх інтенсивності та практичні рекомендації щодо цифрового впровадження.

Основна операція блоку – не окрема класифікація кожного вікна, а агрегування суміжних або близьких у часі аномальних вікон у завершений інцидент із часовими межами, тривалістю, піковою інтенсивністю та контекстом вузла.

Для PQ-застосувань це має виконуватися з урахуванням нормативної логіки IEC 61000-4-30 – класів Class A/Class S, стандартних інтервалів агрегації 150/180 циклів, 10 хв і 2 год, а також концепції позначених даних (flagged data), коли дані з певних інтервалів можуть бути марковані та в окремих сценаріях виключатися з подальшої інтерпретації.

Відповідно, подія у системі підтримки прийняття рішень повинна нести не лише аномальний скор або мітку аномалії, а й метадані (metadata fields) на кшталт aggregation_level (рівень агрегації), qc_flag (прапорець контролю якості), flag_reason (причина маркування), measurement_class (клас вимірювання), node_id (ідентифікатор вузла), phase (фаза) та waveform_ref (посилання на хвильову форму). Це робить результати відтворюваними, аудитованими та сумісними з регламентами PQ-моніторингу.

Ранжування аномалій доцільно будувати як багатокритеріальний пріоритет, у якому поєднуються сила події, її тривалість, критичність об'єкта, регуляторна значущість та невизначеність моделі. Саме невизначеність є принциповою – високий аномальний скор за низької довіри моделі не



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

повинен автоматично ескалюватися так само, як високий скор із підтвердженням кількома каналами, стабільним контекстом і відхиленням від типового режиму.

Пояснення для оператора формуються завдяки порівнянню інциденту з найближчим «нормальним» шаблоном, виділення каналів, що найбільше відхилилися, посилання на репрезентативний профіль кластера та, за наявності, на хвильову форму або її часово-частотний образ.

Така інтерпретація узгоджується як з обраним підходом до фізичної інтерпретації кластерів та пояснення спрацювань завдяки внеску ознак, так і з сучасними публікаціями про XAI (explainable artificial intelligence [11, 12] – пояснюваний штучний інтелект) для PQ та загальними вимогами NIST до explainable/interpretable AI (пояснюваного/інтерпретованого штучного інтелекту).

Результатом роботи блоку є не лише сигнал тривоги, а й рекомендація для дії. У спрощеному операторському варіанті вона має відповідати на чотири питання: що сталося, де це сталося, наскільки це критично та що необхідно перевірити першочергово. Для інцидентів, подібних до раніше виявлених шаблонів, рекомендація може бути напівавтоматичною. Для нових або низькодостовірних подій – маршрутизованою на режим контролю людиною (human-in-the-loop).

Досвід виробничих PQ-платформ підтверджує доцільність саме такого подання: браузерні інформаційні панелі (dashboards), кольорові індикатори, попередження (alerts), звіти за інцидентами, сигнатури хвильових форм (waveform signatures), оцінка тяжкості подій та деталізація до конкретного місця або типу порушення (drill-down).

Блок інтерпретації, валідації та зворотного зв'язку виконує дві взаємопов'язані функції. Перша – змістова інтерпретація результатів, тобто



перевірка того, чи узгоджується виявлена аномалія з типовим режимом вузла, календарним контекстом, міжканальною фізикою процесу, відомими зовнішніми чинниками або нормативними межами.

Друга – контроль достовірності, який включає оцінювання якості моделі на часово відокремлених вибірках, відстеження помилок першого і другого роду, дрейфу даних (data drift), дрейфу скорів (score drift) та дрейфу самих пояснень (explanation drift). Тому, є необхідність в узгодженому протоколі валідації, використанні подієвих метрик (event-level metrics) для детектування, PR-орієнтованої оцінки в умовах дисбалансу, контролю частоти хибних спрацювань (False Alarm Rate, FAR) та затримки виявлення, а також окремого моніторингу дрейфу якості даних, вихідних скорів та Top-K ознак.

Для блоку інтерпретації, валідації та зворотного зв'язку доцільно використовувати три рівні перевірки. На рівні моделі – event-level Precision, Recall, F1, PR-криві (precision-recall curves), частоту хибних спрацювань, медіанну затримку виявлення та стабільність кластеризації.

На рівні фізичного змісту – узгодженість пояснення з каналами, що реально змінилися, відсутність суперечностей між пов'язаними показниками та зіставлення з незалежними індикаторами. Для спеціального геофізичного сценарію, що запропоновано, – зіставлення подій із геомагнітними драйверами та статистичну перевірку через блочні перестановки (block permutations).

На рівні експлуатації – журнали рішень, повторюваність пояснень, частка операторських підтверджень, швидкість закриття інцидентів та частота повторного відкриття кейсів.

Така багаторівнева валідація добре узгоджується як із RQ-літературою, так і з сучасними оглядами часових аномалій, де наголошується на



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

необхідності не лише модельних, а й data-centric (орієнтованих на дані) та deployment-centric (орієнтованих на експлуатацію) метрик.

Контур зворотного зв'язку має бути формалізованим. Оператор або інженер-експерт повинен мати змогу підтвердити подію, позначити її як хибне спрацювання (false positive), уточнити клас порушення, додати причину, зафіксувати вплив на обладнання, а також ініціювати перегляд порогів чи запуск контрольованого перенавчання.

З погляду NIST AI RMF (Artificial Intelligence Risk Management Framework – системи керування ризиками штучного інтелекту), це відповідає вимогам щодо ролей і відповідальностей у конфігураціях взаємодії людини та ШІ (human-AI configurations), документування рівня людського нагляду, безперервного моніторингу, журналювання подій та процедур корекції (remediation), якщо система виходить за межі допустимого ризику.

У контексті (рис. 1) такий сигнал зворотного зв'язку має надходити не тільки до блоку результатів аналізу та підтримки рішень, а й назад до ядра аналізу та правил попередньої обробки, якщо виявлено систематичні артефакти або зміну режимів функціонування електроенергетичної системи.

Порівняння вихідних артефактів і повідомлень зворотного зв'язку представлено у табл. 1.

Таблиця 1

Порівняння вихідних артефактів і повідомлень зворотного зв'язку

Сутність	Тип / формат	Частота	Призначення
Подієве повідомлення про аномалію	JSON (формат обміну даними) / подія OPC UA (Open Platform Communications Unified Architecture) / повідомлення IEC 61850	Подієво	Оперативне оповіщення SCADA/АСУ про інцидент із severity (рівнем критичності), часовими межами, qc_flag (прапорцем контролю якості), measurement_class (класом вимірювання) та посиланням на waveform (хвильову

MODERNÍ ASPEKTY VĚDY
Svazek LXIX mezinárodní kolektivní monografie



Сутність	Тип / формат	Частота	Призначення (форму)
Черга ранжованих інцидентів	REST/API (програмний інтерфейс) / список інформаційної панелі (dashboard list)	Квазі-реальний час	Пріоритезація роботи оператора за критичністю об'єкта, інтенсивністю події та довірою моделі
КРІ-знімок моніторингу	Віджет інформаційної панелі (dashboard widget), витяг CSV (comma-separated values) / Parquet	Годинно / добово	Контроль частоти спрацювань, FAR (частоти хибних спрацювань), затримки виявлення, дрейфу даних і скорів
Періодичний PQ-звіт	PDF / вебзвіт (Web report) / експорт CSV	Добово / тижнево / місячно	Аналітика інцидентів, тяжкість sags/swells/transients (провалів/перенапруг/перехідних процесів), location/impact (місця виникнення та впливу), звітність і аудит
Пакет кейсу для експерта	Архів запису, waveform (хвильова форма), metadata (метадані), explanation payload (пакет пояснення)	За запитом	Поглиблена верифікація, розбір причин, навчання персоналу, ескалація
Підтвердження оператора	ack/close/comment message (повідомлення підтвердження/ закриття/коментаря)	Подієво	Фіксація результату human review (експертної перевірки людиною) та завершення життєвого циклу інциденту
Повідомлення false positive / relabel	feedback message (повідомлення зворотного зв'язку)	Подієво	Поповнення контрольованої вибірки, перегляд класу події, корекція шаблонів
Trigger на переналаштування	config-change / threshold-review (перегляд конфігурації та порогів)	За КРІ-тригером	Перегляд порогів, правил агрегації, ваг пріоритету
Trigger на перенавчання	retrain request / MLOps job (запит на перенавчання / задача керування життєвим циклом ML-моделі)	Епізодично	Реакція на drift (дрейф даних), зміну режимів, накопичення підтверджених нових кейсів

Отже, у табл. 1 наведено рекомендоване узагальнення вихідних сутностей двох блоків, яке спирається на логіку статті й дисертації, вимоги ІЕС/NIST та практики промислових PQ/SCADA-рішень.



MODERNÍ ASPEKTY VĚDY

Svazek LXIX mezinárodní kolektivní monografie

Висновки. Таким чином, розроблено метод підвищення ефективності автоматизованого аналізу вимірювальних даних електроенергії на основі глибинного навчання без вчителя. На відміну від відомих методів, які орієнтовані на класифікацію окремих порушень якості електроенергії, запропонований метод розглядає PQ-дані як багатовимірні часові ряди, що потребують попередньої обробки, формування латентних представлень, виділення типових режимів та подальшого подієвого виявлення аномалій.

Показано, що ядро методу доцільно будувати як поєднання двох взаємопов'язаних аналітичних контурів: глибинного автоенкодера з кластеризацією ознак та механізму глибокого виявлення аномальних відхилень у спільному латентному просторі. Така структура дозволяє не лише зменшити розмірність вхідних даних і виявити типові режими функціонування електроенергетичної системи, а й формувати оцінку аномальності для часових вікон, що не відповідають нормальному режиму.

Обґрунтовано значення блоку попередньої обробки даних, який забезпечує очищення, синхронізацію, контроль валідності, масштабування та сегментацію вимірювальних даних. Це підвищує стійкість подальшого аналізу до шумів, пропусків, технічних артефактів та неоднорідності джерел вимірювання.

Запропоновано логіку перетворення результатів глибинного аналізу у події, попередження, КРІ-знімки, звіти та рекомендації для диспетчерського персоналу. Особливо підкреслено роль інтерпретації, валідації та зворотного зв'язку, що забезпечує контроль достовірності результатів, зменшення кількості хибних спрацювань і адаптацію методу до зміни режимів роботи електроенергетичної системи.

Таким чином, запропонований підхід створює основу для побудови інтелектуального аналітичного конвеєра PQ-моніторингу, який поєднує



автоматизоване виявлення типових і аномальних режимів, експлуатаційну інтерпретованість результатів та підтримку прийняття рішень у цифровізованих енергетичних системах.

Список використаних джерел:

1. Chen X., Wang Y., Liu X. та ін. Enhancing anomaly detection in distributed power systems using autoencoder-based federated learning // *PLOS ONE* – 2023. – Vol. 18, no. 9. – e0289204. – Режим доступу: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10437833/>.

2. Ashokkumar S., Lakshmanan D., Senthilkumar B. та ін. Power quality disturbance identification using hybrid deep learning in renewable energy systems // *Scientific Reports*. – 2025. – Vol. 15, article 20259. – С. 1–14. – Режим доступу: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12738625/>.

3. Слободянюк О. Аналіз даних показників якості електроенергії в умовах цифровізації енергосистем // *Grail of Science*. – 2026. – № 68. – Режим доступу: <https://doi.org/10.36074/grail-of-science.15.05.2026>.

4. IEC 61000-4-30:2015. Electromagnetic compatibility (EMC) – Part 4-30: Testing and measurement techniques – Power quality measurement methods. Geneva : IEC, 2015.

5. IEEE Std 1159-2019. IEEE Recommended Practice for Monitoring Electric Power Quality. New York : IEEE, 2019.

6. Dugan R. C., McGranaghan M. F., Santoso S., Beaty H. W. Electrical Power Systems Quality. 3rd ed. New York : McGraw-Hill, 2012.

7. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A Survey on Concept Drift Adaptation. *ACM Computing Surveys*. 2014. – Vol. 46, No. 4. – Art. 44.



MODERNÍ ASPEKTY VĚDY
Svazek LXIX mezinárodní kolektivní monografie

8. Pimentel M. A. F., Clifton D. A., Clifton L., Tarassenko L. A review of novelty detection. *Signal Processing*. 2014. – Vol. 99. – P. 215–249.

9. Jain A. K. Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*. 2010. – Vol. 31, No. 8. – P. 651–666.

10. Rousseeuw P.J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*. 1987. – Vol. 20. – P. 53–65.

11. Machlev R., Heistrene L., Perl M., Levy K. Y., Belikov J., Mannor S., Levron Y. Explainable Artificial Intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities. *Energy and AI*. 2022. – Vol. 9. – Art. 100169.

12. Ribeiro M. T., Singh S., Guestrin C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. – P. 1135–1144.

13. IEC 61000-4-7:2002+AMD1:2008 CSV. Electromagnetic compatibility (EMC) – Part 4-7: Testing and measurement techniques – General guide on harmonics and interharmonics measurements. Geneva : IEC, 2008.

14. EN 50160:2022. Voltage characteristics of electricity supplied by public electricity networks. Brussels : CENELEC, 2022.

15. Mahela O.P., Shaik A.G. A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*. 2015. – Vol. 41. – P. 549–556.

16. Kolomiitsev O.V., Slobodanyk O.Y. An improved deep autoencoder method with feature clustering for analyzing large datasets of power quality metrics. XVI міжнародна науково-технічна конференція. *Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління*.



29-30 квітня 2026 року. – Баку – Харків – Жиліна: НТУ «ХП», 2026. – Т. 2. – С. 176. doi: <https://doi.org/10.32620/ICT.26.t2>.

17. Коломійцев О.В., Слободяник О.Ю., Комаров В.О., Катунін А.М., Рикун В.Г., Кібальник В.М., Слободенюк Ю.В., Василець Д.О., Сапон В.І., Камишинський О.М., Хабоша С.М., Кувшинова О.С. Аналіз даних показників якості електроенергії в умовах цифровізації енергосистем. *ГРААЛЬ НАУКИ: міжнар. наук. журнал.* – Вінниця: ГО «Європейська наукова платформа»; НУ «Інститут науково-технічної інтеграції та співпраці», 2026. – No 68. – С. 1046-1062. DOI 10.36074/grail-of-science.15.05.2026.

18. Коломійцев О.В., Слободяник О.Ю. Удосконалений метод глибинного автоенкодера з кластеризацією ознак. XIII Міжнародна науково-технічна конференція. Інформатика, управління та штучний інтелект (ІУШІ-2026). 13–15 травня 2026 року. – Х.: НТУ «ХП», 2026. – С. 57.

19. O.V. Kolomiitsev, O.Y. Slobodianyuk. A deep learning method for automated detection of typical patterns in PQ data. XXXIV Міжнародна науково-практична конференція. *Інформаційні технології: наука, техніка, технологія, освіта, здоров'я. MicroCAD-2026.* 14 травня 2026 року. – Х.: НТУ «ХП», 2026. – С. 1761.

20. Shmatko O., Kolomiitsev O., Reкова N., Kuchuk N., Matvieiev O. (2023), "Designing and Evaluating DL-Model for Vulnerability Detection in Smart Contracts", *Advanced Information Systems*, Vol. 7, No. 4, P. 41–51. DOI: <https://doi.org/10.20998/2522-9052.2023.4.05>

21. Fedorchenko V., Yeroshenko O., Shmatko O., Kolomiitsev O., Omarov M. (2024), "Password Hashing Methods and Algorithms on the .NET Platform", *Advanced Information Systems*, Vol. 8, No. 4, P. 82–92. DOI: <https://doi.org/10.20998/2522-9052.2024.4.11>.



MODERNÍ ASPEKTY VĚDY
Svazek LXIX mezinárodní kolektivní monografie

22. Kozina, O. A., Panchenko, V. I., Kolomiitsev, O. V., Usik, V. V., Stratiienko, N. K., Safoshkina, L. V., & Kucherenko, Y. F. (2024). Data consistency protocol for multicloud systems. *International Journal of Cloud Computing*, 13(1), 42-61. <https://doi.org/10.1504/IJCC.2024.136284>.