

О. Ю. Слободяник

Національний технічний університет “Харківський політехнічний інститут”, Харків, Україна

МЕТОД ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ АВТОМАТИЗОВАНОГО АНАЛІЗУ PQ-ДАНИХ ПОКАЗНИКІВ ЯКОСТІ ЕЛЕКТРОЕНЕРГІЇ

Анотація. Актуальність. Стрімкий розвиток цифровізації енергетики та зміни характеру навантажень у сучасних енергосистемах призводить до наступних наслідків: зростання обсягів даних, збільшення кількості аномалій, поширення нелінійних навантажень та економічним збиткам. Відомі методи та підходи при аналізі за жорсткими порогоми не контролюють складні, комбіновані та динамічні аномалії PQ-даних (Power Quality data) показників якості електроенергії. Таким чином, розробка методу підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії є актуальною науковою задачею. **Предметом дослідження** в статті є математичні моделі, методи та процедури інтелектуального аналізу великих масивів даних показників якості електроенергії, спрямовані на виявлення відхилень та типових режимів. **Метою дослідження** є підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії. **Завданням дослідження** є розробка методу підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії. В ході досліджень використано **методи** машинного навчання (для класифікації PQ-подій за ознаками), методи інтелектуального аналізу (для PQ Big Data), графові методи (для відображення топології електромережі та просторових взаємозв'язків), а також методи щільності, локальної близькості та кластеризації. **Результатами дослідження** у статті є розроблений метод підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії на основі інтеграції удосконаленого методу глибинного автоенкодера з кластеризацією ознак для аналізу великих масивів даних показників якості електроенергії та розробленого методу глибокого виявлення аномалій у PQ-даних, зумовлених геофізичними факторами. **Висновки.** Запропоновано розроблений метод підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії. Представлено два взаємопов'язаних методи (автоенкодер + аномальний моніторинг), які разом підвищують ефективність автоматизованого аналізу PQ-даних показників якості електроенергії. Розроблено узагальнену структурну схему процесу автоматизованого аналізу вимірювальних PQ-даних показників якості електроенергії. Отримані **результати** можуть бути основою для розширення переліку об'єктів спостереження, підвищення стійкості до зміни конфігурацій мережі та сезонно-добової нестаціонарності, а також розвитку процедур адаптації моделей та інтеграції аналітики з подіями керування для поглиблення причинно-наслідкової інтерпретації в експлуатаційних умовах.

Ключові слова: PQ-дані; показник якості електроенергії; глибинний автоенкодер з кластеризацією ознак; глибоке виявлення аномалій; метод; математична модель; машинне навчання; інтелектуальний аналіз.

1. Вступ

1.1 Актуальність дослідження

Стрімкий розвиток цифровізації енергетики та зміни характеру навантажень у сучасних енергосистемах призводить до наступних наслідків:

- зростання обсягів даних – впровадження смарт-лічильників та систем Phasor Measurement Unit (PMU – це пристрої синхронізованих векторних вимірювань, що є основними елементами технології Wide Area Measurement Systems (WAMS) для цифрових енергосистем (Smart Grid)) генерує терабайти інформації, яку неможливо обробити вручну;

- збільшення кількості аномалій – масове підключення сонячних та вітрових електростанцій створює нестабільність частоти та напруги електроживлення;

- поширення нелінійних навантажень – побутова електроніка, LED-освітлення та зарядні станції для електромобілів спотворюють «чисту» синусоїду струму;

- економічні збитки – низька якість електроенергії призводить до перегріву трансформаторів, збоїв автоматики тощо та простою виробництва;

- недоліки відомих методів та підходів – аналіз за жорсткими порогоми пропускає складні,

комбіновані та динамічні аномалії даних показників якості електроенергії.

Але відома статистика має низку недоліків:

- прокляття розмірності – PQ-дані (Power Quality data) містять десятки взаємопов'язаних параметрів (статистичні матриці коваріації стають занадто громіздкими та втрачають точність);

- припущення про нормальність – статистика часто вимагає, щоб дані мали нормальний (Гаусовий) розподіл (реальні спотворення напруги мають складні та мультимодальні розподіли);

- жорсткі статичні пороги – класичний аналіз фіксує лише вихід за межі (він пропускає приховані аномалії, які знаходяться у межах норми);

- чутливість до часових зсувів – статистичні методи не якісно вловлюють складні динамічні зміни форми сигналу у часі.

На даний час відома статистика опирається на фіксовані математичні моделі, а використання елементів штучного інтелекту (ШІ), зокрема глибинного навчання без вчителя, дозволяє адаптуватися до реального стану енергосистеми.

Сучасна статистика не обмежується лише фіксованими моделями. Вона активно використовує динамічні, адаптивні та непараметричні методи, баєсівський підхід, а також алгоритми машинного навчання, які самостійно оновлюються й змінюються під час обробки нових даних у реальному часі.

До основних сучасних підходів можливо віднести наступні:

- Баєсівська статистика – яка постійно оновлює ймовірності при появі нових фактів;
- машинне навчання – створює моделі, які навчаються на даних без жорстких попередніх формул;
- непараметричні методи – не вимагають заздалегідь заданих законів розподілу для даних;
- адаптивні системи – змінюють свої параметри автоматично зі зміною умов.

До математичних переваг ІІІ (автоенкодерів) можливо віднести наступні:

- нелінійне стиснення – автоенкодери використовують нелінійні функції активації, що дозволяє знаходити складні залежності між гармоніками, які ігнорує класичний метод головних компонент (РСА);
- автоматичний пошук ознак – ІІІ самостійно виділяє основні паттерни з сирого сигналу (відома статистика вимагає від інженера вручну задавати математичні критерії);
- динамічний простір станів – кластеризація у латентному (стиснутому) просторі автоенкодера групує режими роботи не за абсолютними значеннями, а за внутрішньою структурою сигналу;
- оцінка за помилкою реконструкції – ІІІ навчається відновлювати нормальний сигнал (за умови, якщо на вхід подається аномалія, помилка реконструкції (Mean Squared Error, MSE) різко зростає, що математично сигналізує про дефект без налаштування порогів.

Таким чином, розробка методу підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії є актуальною науковою задачею.

1.2 Аналіз літературних джерел і визначення проблеми

У [1] для покращення виявлення аномалій у розподілених енергосистемах запропоновано автоенкодерно-федеративний підхід. Акцентовано увагу на проблематику відомих методів у масштабуванні та конфіденційності. Розкрито основні переваги глибинного представлення даних.

У [2] розкрито особливості гібридної системи, яка застосовується для ідентифікації порушень якості електроенергії. При цьому, безперервні вейвлет-перетворення та глибокі нейронні мережі ResNet/VGG (Residual Network, ResNet, залишкова мережа та Visual Geometry Group VGG, група візуальної геометрії) комбінуються з аналізом важливості ознак та SVM-класифікатором (Support Vector Machine, метод опорних векторів).

У [3] підкреслено необхідність у формуванні стійких латентних представлень часових фрагментів PQ-даних (сигналів) та виявлення аномальних відхилень без повної розмітки даних.

У [4] наведено вимоги галузевих стандартів (IEC 61000-4-30), у тому числі [5].

Однак, запропоновані рішення 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.

Тому, виникає необхідність у розробці методів, які спроможні забезпечити адаптивність та стійкість до шуму, а також здатність до самоорганізації та інтерпретації результатів [6–8].

При цьому, можливо використовувати інтеграцію двох взаємопов'язаних аналітичних контурів – глибинного автоенкодера з кластеризацією ознак та механізму глибокого виявлення аномалій у спільному латентному просторі представлення PQ-даних [9, 10].

1.3 Мета і завдання дослідження

Метою дослідження є підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії.

Для досягнення мети було поставлено наступне завдання: розробка методу підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії.

2. Матеріали і методи дослідження

Розроблений метод підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії оснований на інтеграції [11]:

- удосконаленого методу глибинного автоенкодера з кластеризацією ознак для аналізу великих масивів даних показників якості електроенергії [12, 13];

- розробленого методу глибокого виявлення аномалій у PQ-даних, зумовлених геофізичними факторами [14, 15].

При цьому, обидва методи працюють у складі одного аналітичного конвеєра, який пов'язує моделювання типової «норми» з моніторингом відхилень [16]. При аналізі даних показників якості електроенергії в умовах цифровізації енергосистем використано методи аналізу. При розробці методу підвищення ефективності автоматизованого аналізу вимірювальних даних електроенергії, удосконаленні методу глибинного автоенкодера з кластеризацією ознак та розробці методу глибокого виявлення аномалій у PQ-даних використано методи машинного навчання (для класифікації PQ-подій за ознаками), методи інтелектуального аналізу (для PQ Big Data), графові методи (для відображення топології електромережі та просторових взаємозв'язків), а також методи щільності, локальної близькості та кластеризації.

3. Результати розробки і дослідження розробленого методу підвищення ефективності автоматизованого аналізу PQ-даних показників якості електроенергії

Сутність розробленого методу підвищення ефективності автоматизованого аналізу PQ-даних

показників якості електроенергії полягає у 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 узагальнену структурну схему розробленого методу від попередньої обробки даних до виділення типових режимів та подієвого детектування аномалій.




Рис. 1. Узагальнена структурна схема розробленого методу

За рис. 1 зроблено припущення. Отже, X – матриця вхідних даних, яка подана у вигляді множини N часових вікон (фрагментів) довжини T (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, яка містить значення усіх M показників у T моментах часу.

Тоді, 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.

Відповідно, 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:

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

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

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

Вихідні дані часто мають фрагментації (добові цикли, зміни навантаження тощо). Тоді, набір добових фрагментів можливо записати таким 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).

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

Сутність основних аналітичних блоків методу підвищення ефективності аналізу даних показників якості електроенергії полягає у наступному (рис. 1).

Першим аналітичним блоком розробленого методу є удосконалений метод глибокого автоенкодера з кластеризацією ознак (рис. 1, блок 3.1). 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:

$$z_i = F_\theta(\tilde{x}_i), z_i \in R^d, d \ll T \cdot M, \quad (4)$$

де $\tilde{x}_i$ – нормалізоване вхідне вікно; z_i – його латентний код розмірності d ; θ – параметри енкодера.

Декодер відновлює сигнал наступним чином:

$$\hat{x}_i = D_\eta(z_i), \quad (5)$$

де η – параметри декодера.

Під час навчання зменшується середньоквадратична помилка реконструкції:

$$L_{rec}(\theta, \eta) = \frac{1}{N} \sum_{i=1}^N \|\tilde{x}_i - \hat{x}_i\|_F^2. \quad (6)$$

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 здійснюється його декодування:

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

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).

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

Другий аналітичний контур – розроблений метод глибокого виявлення аномалій у PQ-даних, який призначений для моніторингу відхилень від типового режиму (рис. 1, блок 3.2). Він використовує 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 неймережі) лише на нормальних даних (таймові проміжки без буревіїв та техногенних перебоїв). Після цього, для кожного вікна x_i обчислюється аномальний скор s_i , наприклад як відстань MSE між x_i та його реконструкцією $\hat{x}_i$ (або приріст помилки рекурсії):

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

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, розроблений метод глибокого виявлення аномалій у PQ-даних, зумовлених геофізичними факторами, вирішує задачу виявлення де тимчасові PQ-серії виходять за межі нормального контексту. Він формує безперервний показник

аномальності та агрегацію спрацювань у події з атрибутами (піковий скор, тривалість та зв'язок із GIC). Визначення порога завдяки ROC/PR-аналізу із заданим рівнем хибних спрацювань та зведення метрик Precision/Recall/F1 для оцінки якості детектування дають чисельні критерії.

Блок інтерпретації, валідації та зворотного зв'язку здійснює наступне: перевіряє достовірність PQ-даних результатів, надає пояснення, збирає операторські підтвердження та повертає сигнали для корекції порогів, правил агрегації та циклу супроводження моделей. Така замкнена архітектура відповідає загальній ідеї статті: «типові режими → аномалії → інтерпретація → рішення → контроль якості та адаптація». Блок результатів аналізу та підтримки рішень призначений для перетворення виходу ядра глибинного аналізу без вчителя на форму, яка придатна для оперативного використання в цифровізованому контурі моніторингу PQ-даних. Блок виконує не окрему класифікацію кожного вікна, а агрегування суміжних (близьких у часі) аномальних вікон у завершений інцидент із часовими межами, тривалістю, піковою інтенсивністю та контекстом вузла.

Контур зворотного зв'язку є формалізованим. Отже, оператор (інженер-експерт) підтверджує подію, позначає її як хибне спрацювання (false positive), уточнює клас порушення, додає причину, фіксує вплив на обладнання, а також ініціює огляд порогів або запуск контрольованого перенавчання.

За NIST AI RMF (Artificial Intelligence Risk Management Framework – системи керування ризиками ШІ) – 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.

За рис. 1 такий сигнал зворотного зв'язку надходить не тільки на блок результатів аналізу та підтримки рішень, а й назад до ядра аналізу та правил попередньої обробки (блоки 3.1 та 3.2, рис. 1), якщо виявлено систематичні артефакти або зміну режимів функціонування електроенергетичної системи.

У табл. 1 представлено приклад порівняння вихідних артефактів та повідомлень зворотного зв'язку для узагальненої структурної схеми розробленого методу.

Таблиця 1 – Приклад порівняння вихідних артефактів та повідомлень зворотного зв'язку

Сутність	Тип / формат	Частота	Призначення
Подієве повідомлення 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 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
KPI-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

Закінчення табл. 1

Сутність	Тип / формат	Частота	Призначення
Періодичний RQ-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
Повід. false positive	feedback message (повідомлення зворотного зв'язку)	Подієво	Поповнення контрольованої вибірки, перегляд класу події, корекція шаблонів
Переналаштування	config-change / threshold-review (перегляд конфігурації та порогів)	За KPI-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

4. Обговорення результатів дослідження удосконаленого методу та розробленої моделі планування маршруту БПЛА

Таким чином, для кількісної оцінки ефективності обох блоків запропоновано використовувати узгоджені метрики, зокрема: для блоку кластеризації – середній силует (silhouette) та стійкість кластерів при різних ініціалізаціях/підвибірках; для блоку детектування – метрики якості детекції подій на рівні епізодів, частка False Alarm Rate (FAR), а також медіанна затримка (lead time) виявлення; значущість зв'язку подій з геомагнітними індексами – оцінюється за p-value блочними перестановками.

5. Висновки

Таким чином, розроблено метод підвищення ефективності автоматизованого аналізу RQ-даних показників якості електроенергії на основі інтеграції удосконаленого методу глибинного автоенкодера з кластеризацією ознак для аналізу великих масивів даних показників якості електроенергії та розробленого методу глибокого виявлення аномалій у RQ-даних, зумовлених геофізичними факторами.

Представлено два взаємопов'язаних методи (автоенкодер + аномальний моніторинг), які разом підвищують ефективність автоматизованого аналізу даних показників якості електроенергії.

Розроблено узагальнену структурну схему процесу автоматизованого аналізу вимірювальних даних електроенергії, яка поєднує:

- автоматичне нелінійне узагальнення даних у компактний простір та кластеризацію режимів;

- безперервну оцінку аномальності з керованим налаштуванням порогів;
- агрегування спрацювань у події з інженерно змістовними характеристиками;
- статистично обґрунтовану верифікацію виявлених подій за геомагнітними індикаторами.

Отриманий науковий результат може бути основою для розширення переліку об'єктів спостереження, підвищення стійкості до зміни конфігурацій мережі та сезонно-добової нестационарності, а також розвитку процедур адаптації моделей та інтеграції аналітики з подіями керування для поглиблення причинно-наслідкової інтерпретації в експлуатаційних умовах.

Конфлікт інтересів

Автор декларує, що не має конфлікту інтересів стосовно даного дослідження, в тому числі фінансового, особистісного характеру, авторства чи іншого характеру, що міг би вплинути на дослідження та його результати, представлені в даній статті.

Фінансування

Дослідження проводилося без фінансової підтримки.

Доступність даних

Рукопис не має пов'язаних даних.

Використання засобів штучного інтелекту

Автор підтверджує, що не використовував технології штучного інтелекту при створенні представленої роботи.

СПИСОК ЛІТЕРАТУРИ

- Kea, K., Han, Y., and Kim, T-K (2023), "Enhancing anomaly detection in distributed power systems using autoencoder-based federated learning", *PLoS ONE*, vol. 18(8), doi: <https://doi.org/10.1371/journal.pone.0290337>
- Peruman, P.M., and Ayyar, K. (2025), "Power quality disturbance identification using hybrid deep learning in renewable energy systems", *Scientific Reports*, vol. 15, 44592, doi: <https://doi.org/10.1038/s41598-025-28291-0>
- Коломійцев, О.В., & Слободяник О.Ю. (2026), "Аналіз даних показників якості електроенергії в умовах цифровізації енергосистем", *ГРААЛЬ НАУКИ*, № 68. С. 1046-1062, doi: <https://doi.org/10.36074/grail-of-science>
- (2015), *IEC 61000-4-30:2015. Electromagnetic compatibility (EMC), Testing and measurement techniques – Power quality measurement methods*, IEC, 2015, available at: <https://webstore.iec.ch/en/publication/21844>

5. (2022), *EN 50160:2022. Voltage characteristics of electricity supplied by public electricity networks*, Brussels, CENELEC, 2022 Dugan R. C., McGranaghan M. F., Santoso S., Beaty H. W. *Electrical Power Systems Quality*. 3rd ed. New York: McGraw-Hill, 2012, available at: <https://standards.iteh.ai/catalog/standards>
6. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014), “A Survey on Concept Drift Adaptation”, *ACM Computing Surveys*, vol. 46, no. 4, art. 44, doi: <https://doi.org/10.1145/2523813>
7. Pimentel, M. A. F., Clifton, D. A., Clifton, L., and Tarassenko, L. (2014), “A review of novelty detection”, *Signal Processing*, vol. 99, pp. 215–249, doi: <https://doi.org/10.1016/j.sigpro.2013.12.026>
8. Jain, A. K. (2010), “Data clustering: 50 years beyond K-means”, *Pattern Recognition Letters*, vol. 31, no. 8, pp. 651–666, doi: <https://doi.org/10.1016/j.patrec.2010.08.023>
9. Machlev, R., Heistrene, L., Perl, M., Levy, K. Y., Belikov, J., Mannor, S., and Levron, Y. (2022), “Explainable Artificial Intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities”, *Energy and AI*, vol. 9, art. 100169, doi: <https://doi.org/10.1016/j.egyai.2022.100169>
10. Ribeiro, M. T., Singh, S., and Guestrin, C. (2016), “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*, pp. 1135–1144, doi: <https://doi.org/10.1145/2939672.2939778>
11. Коломійцев, О.В., & Слободяник, О.Ю. (2026), “Метод підвищення ефективності автоматизованого аналізу вимірювальних даних електроенергії на основі глибинного навчання без вчителя”, *Moderní aspekty vědy: LXIX. Díl mezinárodní kolektivní monografie* str. 672, doi: <https://doi.org/10.52058/69-2026>
12. Коломійцев, О.В., & Слободяник, О.Ю. (2026), “Удосконалений метод глибинного навчання для автоматизованого виявлення типових шаблонів у PQ-даних показників якості електроенергії”, *ГРААЛЬ НАУКИ*, № 69, С. 1163–11816 doi: <https://doi.org/10.36074/grail-of-science>
13. Коломійцев, О.В., & Слободяник, О.Ю. (2026), “Метод глибокого виявлення аномалій у вимірювальних PQ-даних (показників якості електроенергії), зумовлених геофізичними факторами”, *ГРААЛЬ НАУКИ*, № 70, С. 831–850, doi: <https://doi.org/10.36074/grail-of-science.31.05.2026>
14. Mahela, O.P., and Shaik, A.G. (2015), “A critical review of detection and classification of power quality events”, *Renewable and Sustainable Energy Reviews*, vol. 41, pp. 549–556, doi: <https://doi.org/10.1016/j.rser.2014.08.070>
15. Fedorchenko, V., Yeroshenko, O., Shmatko, O., Kolomiitsev, O., and Omarov, M. (2024), “Password Hashing Methods and Algorithms on the .NET Platform”, *Advanced Information Systems*, vol. 8, no. 4, pp. 82–92, doi: <https://doi.org/10.20998/2522-9052.2024.4.11>
16. 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*, vol. 13(1), pp. 42–61, doi: <https://doi.org/10.1504/IJCC.2024.136284>

Received (Надійшла) 07.06.2026

Accepted for publication (Прийнята до друку) 26.08.2026

Publication date (Дата публікації) 25.09.2026

ВІДОМОСТІ ПРО АВТОРІВ / ABOUT THE AUTHORS

Слободяник Олег Юрійович – аспірант кафедри комп’ютерної інженерії та програмування, Національний технічний університет «Харківський політехнічний інститут», Харків, Україна;

Oleg Slobodanyk – Postgraduate student, Department of Computer Engineering and Programming, National Technical University, “Kharkiv Polytechnic Institute”, Kharkiv, Ukraine;

e-mail: Oleh.Slobodanyk@cs.khpi.edu.ua; ORCID Author ID: <https://orcid.org/0009-0003-2886-7116>.

A method for improving the efficiency of automated analysis of pq data on electric power quality indicators

Oleg Slobodanyk

Abstract. Background. The rapid development of digitalization in the energy sector and changes in the nature of loads in modern power systems lead to the following consequences: an increase in data volumes, a rise in the number of anomalies, the proliferation of nonlinear loads, and economic losses. Existing methods and approaches based on hard thresholds fail to detect complex, combined, and dynamic anomalies in PQ data (power quality indicators). Thus, developing a method to improve the efficiency of automated analysis of PQ data is a pressing scientific challenge. The subject of this study is mathematical models, methods, and procedures for the intelligent analysis of large datasets of power quality indicators, aimed at identifying deviations and typical operating modes. The purpose of this study is to improve the efficiency of automated analysis of PQ data on power quality indicators. The objective of this study is to develop a method for improving the efficiency of automated analysis of PQ data on power quality indicators. The research utilized machine learning methods (for classifying PQ events based on characteristics), intelligent analysis methods (for PQ Big Data), graph-based methods (for representing the topology of the power grid and spatial relationships), as well as density, local proximity, and clustering methods. The results of the research presented in this article include a method for improving the efficiency of automated analysis of PQ data on power quality indicators, based on the integration of an improved deep autoencoder method with feature clustering for the analysis of large datasets of power quality indicators, and a newly developed method for deep anomaly detection in PQ data caused by geophysical factors. **Conclusions.** A method for improving the efficiency of automated analysis of PQ data on power quality indicators is proposed. Two interrelated methods (autoencoder + anomaly monitoring) are presented, which together improve the efficiency of automated analysis of PQ data on power quality indicators. A generalized block diagram of the process of automated analysis of measured PQ data on power quality indicators has been developed. The results obtained can serve as a basis for expanding the list of monitored objects, improving resilience to changes in network configurations and seasonal and diurnal variability, as well as for developing procedures for model adaptation and integrating analytics with control events to deepen the cause-and-effect interpretation under operational conditions.

Keywords: PQ data; power quality index; deep autoencoder with feature clustering; deep anomaly detection; method; mathematical model; machine learning; intelligent analysis.