

Т. П. ДОВЖЕНКО, канд. техн. наук,  
ORCID:0000-0002-0352-8391

Державний університет інформаційно-комунікаційних технологій, Київ

## РОБАСТНЕ ВИЯВЛЕННЯ АНОМАЛІЙ У ЧАСОВИХ РЯДАХ ЗА УМОВ НАЯВНОСТІ СТРУКТУРНИХ СПОТВОРЕНЬ: ІНТЕГРАЦІЯ МЕТОДУ HYBRID AWRED V5 У КЛАСИЧНІ ТА ДВОНАПРАВЛЕНІ LSTM-МЕРЕЖІ

*Глибокі рекурентні нейронні мережі широко застосовуються для аналізу часових рядів, однак їхня ефективність істотно залежить від чистоти навчальної вибірки. Класична функція втрат на основі середньоквадратичної похибки (MSE) є чутливою до структурних спотворень у даних, оскільки аномальні вікна можуть зміщувати градієнтні оновлення та погіршувати якість сформованого прихованого подання. У статті розглянуто п'яту генерацію методології Hybrid AWRED v5 (Adaptive Weighted Reconstruction with Regularized Energy and Dynamics), у якій використано диференційовну функцію втрат із механізмом просторово-часового м'якого відсікання. Для налаштування параметрів вагової функції застосовано Байєсівську оптимізацію, що дає змогу адаптувати поріг відсікання до поточного розподілу похибок реконструкції.*

*Експериментальне оцінювання проведено для двох базових архітектур - класичної LSTM та двонаправленої BiLSTM із шаровою нормалізацією — за умов 15% структурних спотворень у навчальній вибірці. Результати показали, що при використанні стандартної MSE метрика Average Precision становить 0.534 для LSTM та 0.566 для BiLSTM, тоді як інтеграція Hybrid AWRED v5 підвищує ці значення до 0.835 та 0.922 відповідно. Для сучасної архітектури також отримано AUC-ROC на рівні 0.990. Це свідчить, що запропонований підхід краще зберігає якість ранжування аномалій за наявності структурних спотворень у навчальних даних.*

*Отримані результати дають підстави розглядати Hybrid AWRED v5 як перспективний архітектурно-незалежний інструмент робастної оптимізації для задач виявлення аномалій у часових рядах. Разом із тим переваги методу доцільно інтерпретувати насамперед через покращення метрик виявлення та ранжування, тоді як окреме кількісне оцінювання просторово-часової локалізації може бути предметом подальших досліджень.*

**Ключові слова:** виявлення аномалій, часові ряди, глибоке навчання, LSTM, BiLSTM, структурні спотворення, забруднення даних, робастна оптимізація, Hybrid AWRED v5.

### Вступ

З розвитком сенсорних мереж, кіберфізичних систем та фінансового моніторингу обсяги даних, що генеруються у вигляді неперервних часових послідовностей, постійно збільшуються [16]. Відповідно, що задача автоматизованого виявлення аномалій у часових рядах є актуальною для забезпечення надійності складних інфраструктур. Сучасним стандартом для розв'язання цієї задачі є використання глибоких рекурентних мереж, таких як LSTM, BiLSTM та їхніх модифікацій, у форматі автоенкодерів [1], [2], які проєктують нормальну поведінку системи у прихований простір ознак.

Однією з ключових проблем глибокого навчання без вчителя є припущення щодо репрезентативності та чистоти вибірки. Традиційні підходи вимагають, щоб на етапі навчання мережа отримувала виключно нормальні дані. Насправді реальні масиви даних часто містять нерозмічені системні збої, імпульсні збурення та шум [19]. Цей сценарій класифікується як забруднення даних або наявність структурних спотворень.

Для навчання автоенкодерів переважно використовується цільова функція середньоквадратичної похибки (MSE). Недоліком MSE є її квадратична чутливість до відхилень. Якщо у навчальному міні-пакеті присутнє вікно з аномалією, оптимізатор генерує значний градієнт, змушуючи матриці пам'яті рекурентної мережі адаптуватися під цей шум. Як наслідок, топологія нормального класу у прихованому просторі порушується і алгоритми класифікації, такі як метод опорних векторів для одного класу (OC-SVM) [3] або Deep SVDD [14], не здатні побудувати коректну розділяючу гіперсферу.

Існуючі методи розв'язання цієї проблеми (зокрема, відсікання за порогом 3-сигма або використання функції втрат Х'юбера [4]) мають недоліки у вигляді втрати градієнта або необхідності ручного підбору гіперпараметрів, що вже знижує їхню ефективність для складних нелінійних коливань.

У цій роботі пропонується підхід до формування робастності на рівні градієнтів - п'ята генерація методології Hybrid AWRED v5. Тут замість модифікації архітектури мережі, здійснюється вплив на динаміку навчання шляхом впровадження адаптивної логістичної ваги для кожного часового вікна.

Основні результати цієї статті:

1. Розроблено диференційовану функцію втрат Hybrid AWRED v5, яка використовує механізм м'якого відсікання для динамічної ізоляції аномальних градієнтів під час зворотного поширення похибки.

2. Застосовано методологію автономного пошуку гіперпараметрів функції (квантиля відсікання та крутизни експоненти) за допомогою Байєсівської оптимізації.

3. Проведено порівняльний структурний аналіз між класичною однонаправленою рекурентною пам'яттю (LSTM) та глибокою двонаправленою архітектурою з шаровою нормалізацією (BiLSTM + Layer Normalization). Визначено, що збільшення репрезентативної потужності архітектури самостійно не вирішує проблему деградації простору ознак.

4. Показано, що використання цільової функції Hybrid AWRED v5 за умов 15% структурних спотворень пов'язане із збереженням роздільної здатності прихованого простору та високими значеннями  $AUC-ROC = 0.990$  і  $AP = 0.922$ .

### **Огляд останніх досліджень і публікацій**

*Еволюція рекурентних архітектур у задачах виявлення аномалій.* Традиційні статистичні методи аналізу часових рядів мають обмеження, особливо коли потрібно описувати багатовимірні системи. Через це глибокі нейронні мережі, здатні відтворювати нелінійні залежності, набули широкого застосування [16]. Одним із важливих кроків у цьому напрямі стала поява рекурентних автоенкодерів на базі довгої короткострокової пам'яті (LSTM-AE) [1].

Надалі увага дослідників змістилася до глибших двонаправлених архітектур (BiLSTM) та моделей із механізмом уваги, зокрема трансформерів [17]. Для зменшення нестабільності розподілу ознак між шарами також застосовують шарову нормалізацію [5]. Разом із тим за наявності структурних спотворень у навчальній вибірці здатність таких моделей до узагальнення помітно зменшується [2].

*Проблема забруднення даних та вразливість цільових функцій.* У задачах навчання без учителя зазвичай припускають, що автоенкодер навчається на даних, які відображають нормальний стан системи. У реальних умовах ця вимога часто порушується, оскільки набори даних містять нерозмічені системні збої або шумові викиди. Імовірнісні моделі оцінки щільності, зокрема DAGMM [15], також чутливі до таких спотворень і в окремих випадках формують хибні кластери для аномальних станів.

Найпоширенішим підходом до навчання автоенкодерів залишається мінімізація середньоквадратичної похибки (MSE). Вона забезпечує швидку збіжність завдяки гладкості та опуклості, але її квадратичний характер робить модель чутливою до відхилень. Якщо в часовому вікні є аномалія, виникає великий градієнт. Рекурентні мережі оновлюють параметри саме на його

основі, тому можуть частково запам'ятовувати структурні спотворення, а це знижує роздільну здатність прихованого простору.

*Існуючі методи робастної оптимізації.* Щоб зменшити вразливість MSE, запропоновано кілька підходів робастної оптимізації. Використання абсолютної похибки (MAE) приводить до сталого градієнта навіть за малих похибок, через що ускладнюється точна збіжність.

Функція втрат Х'юбера поєднує властивості MSE для малих похибок і MAE для великих [4], однак потребує ручного вибору параметра переходу. Існують і методи жорсткого відсікання, коли відкидається певний відсоток часових вікон із найбільшою похибкою. Проблема полягає в тому, що в точці відсікання втрачається диференційовність [6].

*Еволюція методології Hybrid AWRED.* Для розв'язання проблеми адаптивної робастності було сформовано концепцію Adaptive Weighted Reconstruction with Regularized Energy and Dynamics (AWRED). Попередні версії методології пройшли кілька етапів: від стабілізації простору мультимодальних фінансових транзакцій (v1) [7] до топологічного якорування в умовах кібератак (v2) [8]. Пізніше метод адаптували до аналізу забруднених візуальних даних (v3) [9], а згодом - до наскрізної класифікації в умовах дефіциту вибірки (v4) [10].

Для рекурентних мереж і часових рядів потрібен окремий підхід до стабілізації градієнтів, оскільки під час зворотного поширення похибки вони накопичуються в часі. Тому, запропоновано п'яту генерацію методу - Hybrid AWRED v5. У цій версії відмовились від класичних осцилюючих штрафів і просторової дисперсії, а натомість було використано просторово-часове нелінійне відсікання у поєднанні з Байєсівською оптимізацією.

### **Запропонована методологія Hybrid AWRED v5**

*Формулювання проблеми: вразливість цільової функції MSE*

Будемо розглядати неперервний багатовимірний часовий ряд  $X \in \mathbb{R}^{F \times N}$ , де  $F$  - кількість ознак, а  $N$  - загальна довжина послідовності. Для навчання рекурентних автоенкодерів ряд сегментується на множину часових вікон  $\{X_\tau\}_{\tau=1}^M$  фіксованої довжини  $W$ . Навчання без вчителя базується на мінімізації функції втрат (MSE) для кожного міні-паketу:

$$L_{MSE} = \frac{1}{B \cdot W} \sum_{b=1}^B \sum_{t=1}^W (x_{b,t} - \hat{x}_{b,t})^2, \quad (1)$$

де  $x_{b,t}$  - істинне значення, а  $\hat{x}_{b,t}$  - реконструйоване значення на часовому кроці  $t$  для вікна  $b$  у пакеті розміру  $B$ .

В умовах наявності структурних спотворень емпіричний розподіл похибки реконструкції набуває властивостей розподілу з «важкими хвостами». Відповідно, вектор градієнта цільової функції  $\nabla_{\theta} L_{MSE}$  зазнає впливу компонент викидів. Ці градієнти індукують збурення у матрицях вагів рекурентних вентилів, що призводить до просторової деградації.

*Механізм просторово-часового м'якого відсікання*

На відміну від попередніх ітерацій методу HYBRID AWRED (v1-v4), де адаптивна вага формувалася на основі міжкласової дисперсії та осцилюючих штрафів для просторових даних, у рекурентних мережах (v5) математичний апарат модифіковано для усунення ефекту лавиноподібного накопичення похибки у часових послідовностях. Сам механізм просторово-часового м'якого відсікання діє як адаптивний нелінійний регулятор. Метод обчислює логістичну вагу  $w_\tau \in [0,1]$  для кожного часового вікна  $\tau$  у міні-пакеті:

$$w_\tau = \frac{1}{1 + \exp(G_{max} \cdot (e_\tau - Q))}, \quad (2)$$

де:  $e_\tau$  - усереднена локальна похибка реконструкції для конкретного часового вікна  $\tau$ ,  $Q$  - динамічний поріг відсікання,  $G_{max}$  - коефіцієнт підсилення градієнта, який визначає крутизну переходу сигмоїдної функції.

Сигмоїдальна вагова функція  $w_\tau$  гарантує Ліпшицеву неперервність цільової функції у точці відсікання. Якщо похибка вікна знаходиться у межах норми ( $e_\tau \ll Q$ ), вага  $w_\tau \rightarrow 1$ . У випадку аномального викиду ( $e_\tau \gg Q$ ), вага  $w_\tau \rightarrow 0$ , тим самим обмежуючи поширення аномального градієнта. Модифікована цільова функція набуває вигляду:

$$L_{AWRED-v5} = \frac{\sum_{\tau=1}^B w_{\tau} \cdot e_{\tau}}{\max(1, \sum_{\tau=1}^B w_{\tau})} + \lambda \|\theta\|_2^2 \quad (3)$$

Тут використання  $L_2$ -регуляризації ( $\|\theta\|_2^2$ ) замість регуляризації дисперсії ваг забезпечує стабільність рекурентних вентилів.

#### *Динамічна локалізація та Байєсівська оптимізація гіперпараметрів*

Інтеграція Байєсівського виводу [11], [18] для визначення порогу  $Q$  дозволяє системі адаптуватися до нестационарної дисперсії похибки. Поріг  $Q$  обчислюється на кожній ітерації як квантиль розподілу похибки:

$$Q = \text{Quantile}(\{e_1, e_2, \dots, e_B\}, q_{\text{tail}}), \quad (4)$$

де  $q_{\text{tail}} \in [0,1]$  - цільовий параметр квантиля.

Для знаходження оптимуму параметрів  $q_{\text{tail}}$  та  $G_{\text{max}}$  застосовується метод Байєсівської оптимізації з використанням гауссівських процесів та критерію очікуваного покращення (Expected Improvement).

### **Експериментальна база**

#### *Моделювання динамічної системи та структурних спотворень*

Для експериментальної перевірки запропонованої цільової функції було згенеровано багатовимірний нелінійний часовий ряд, який складається з двох взаємопов'язаних ознак, що генеруються за гармонічним законом із накладенням гауссівського білого шуму:  $X(t) = f(\sin(t), \cos(t)) + \mathcal{N}(0,0.1)$ . Навчальна вибірка становить  $N_{\text{train}} = 3000$  точок, а тестова -  $N_{\text{test}} = 1500$  точок. Часовий ряд сегментується методом ковзного вікна з довжиною  $W = 20$ .

Для відтворення умов наявності структурних спотворень у навчальну вибірку було введено штучні аномалії. Рівень забруднення встановлено на 15% (prevalence = 0.15). Тестова вибірка містить 10% істинних аномалій, які використовуються виключно для оцінювання ефективності та розрахунку фінальних метрик.

#### *Базові архітектури*

У дослідженні порівнюються дві рекурентні архітектури різної складності, що дозволяє ізолювати вплив архітектури від впливу функції втрат:

1. Класичний LSTM-AE: автоенкодер на базі однонаправленої рекурентної пам'яті (LSTM) з розмірністю прихованого простору 32 та шаром проріджування.
2. Сучасна модель BiLSTM-AE: двонаправлена архітектура. Для стабілізації розподілу активацій після кожного рекурентного шару застосовано механізм шарової нормалізації.

Обидві архітектури навчалися протягом 70 епох з використанням оптимізатора Adam та механізму ранньої зупинки. Для фінальної класифікації використовувався алгоритм OC-SVM з радіальною базисною функцією. З метою формування контрольної бази для порівняння, алгоритму OC-SVM було надано апріорну інформацію: його параметр очікуваної частки викидів ( $\nu$ ) був жорстко заданий на рівні істинного забруднення вибірки (15%). Натомість запропонована цільова функція Hybrid AWRED v5 функціонувала автономно, не використовуючи апріорних даних про рівень структурних спотворень, і визначала квантиль відсікання виключно через контур Байєсівської оптимізації.

#### *Оцінювання ефективності*

Для об'єктивного порівняння якості виявлення та ранжування аномалій застосовувалися такі метрики: площа під ROC-кривою (AUC-ROC), середня точність (Average Precision, AP), точність (Precision), повнота (Recall), F1-score та коефіцієнт кореляції Метьюза (MCC).

### **Аналіз результатів**

#### *Кількісна оцінка ефективності*

Для оцінювання запропонованої методології виконано порівняння класичної архітектури LSTM і сучасної BiLSTM за двох варіантів цільової функції: стандартної MSE та запропонованої Hybrid AWRED v5. У табл. 1 подано усереднені результати п'яти незалежних прогонів за наявності 15% структурних спотворень у навчальній вибірці.

Таблиця 1

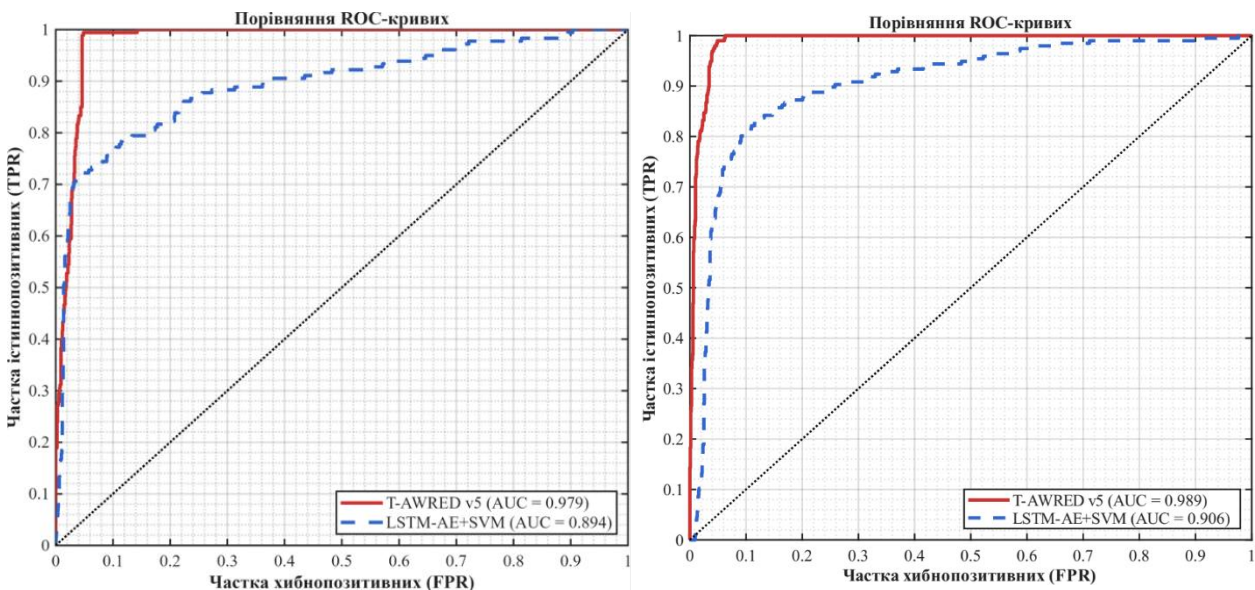
**Усереднені показники ефективності виявлення аномалій  
(порівняльний аналіз архітектур)**

Модель	AUC	AP	Recall	Precision	F1	MCC
Класична LSTM-AE+OC-SVM	0.862±0.024	0.534±0.042	0.574±0.041	0.745±0.037	0.648±0.037	0.610±0.042
Класична LSTM+Hybrid AWRED v5	0.979±0.004	0.835±0.033	0.617±0.035	0.800±0.040	0.696±0.034	0.665±0.039
Сучасна BiLSTM-AE+OC-SVM	0.886±0.030	0.566±0.033	0.572±0.055	0.697±0.034	0.628±0.043	0.585±0.048
Сучасна BiLSTM+Hybrid AWRED v5	0.990±0.009	0.922±0.067	0.741±0.120	0.900±0.092	0.812±0.109	0.794±0.121

З наведених результатів видно, що використання MSE супроводжується погіршенням якості простору ознак незалежно від репрезентативної потужності архітектури. Перехід від класичної LSTM до двонаправленої BiLSTM дав лише помірне покращення AP - з 0.534 до 0.566. Натомість інтеграція цільової функції Hybrid AWRED v5, яка виконує роль адаптивного регулятора градієнтів, була пов'язана з істотнішим покращенням інтегральних показників: для класичної мережі AP зросла до 0.835, а для сучасної - до 0.922 при AUC = 0.990.

*Аналіз просторово-часової динаміки*

Порівняння ROC-кривих для обох архітектур (рис. 1) показує, що моделі з функцією Hybrid AWRED v5 забезпечують вищі значення AUC-ROC, ніж відповідні базові конфігурації на основі MSE. Для класичної LSTM значення AUC зростає з 0.862 до 0.979, а для BiLSTM - з 0.886 до 0.990. Це відповідає числовим результатам, наведеним у табл. 1, і вказує на краще розрізнення нормальних та аномальних станів за умов структурного забруднення навчальних даних.



**Рис. 1. Порівняння ROC-кривих для задач виявлення аномалій: а) класична архітектура LSTM-AE; б) сучасна архітектура BiLSTM-AE**

Графіки показують покращення інтегральної якості розрізнення нормальних та аномальних станів при використанні цільової функції Hybrid AWRED v5 порівняно з відповідними базовими моделями (MSE + OC-SVM). Динаміка оцінки аномальності в часі (рис. 2) показує,

що при використанні MSE обидві базові архітектури формують більшу кількість хибних спрацьовувань і менш стабільний профіль похибки реконструкції на тестовій вибірці. Для моделей із Hybrid AWRED v5 сигнали аномальності виглядають більш контрастними в моменти появи структурно викривлених вікон. Це дає підстави припустити, що механізм м'якого відсікання зменшує вплив аномальних градієнтів на процес навчання. Проте такі висновки представлені передусім на візуальному аналізі часових кривих і мають інтерпретаційний характер.

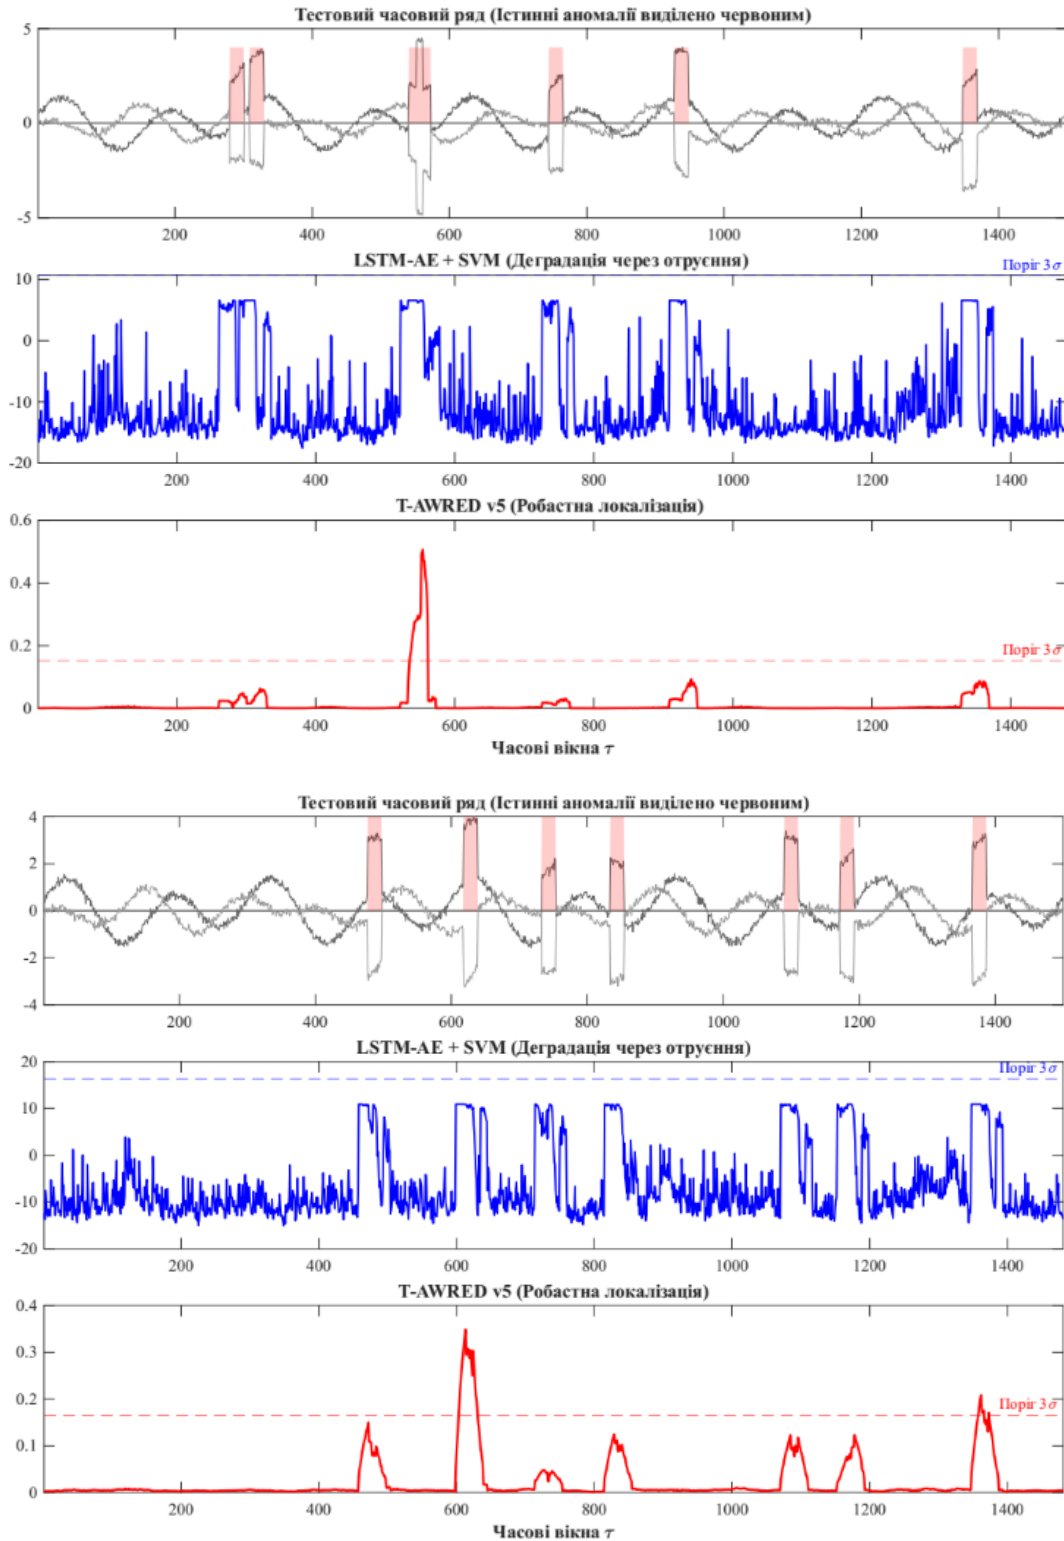


Рис. 2. Динаміка оцінки аномальності на тестовому часовому ряді: а) класична архітектура LSTM-AE; б) сучасна архітектура BiLSTM-AE

Показано, що при використанні Hybrid AWRED v5 сигнали аномальності є більш контрастними в моменти появи структурно спотворених вікон, тоді як базові моделі демонструють вищий рівень хибних спрацьовувань.

Отже, результати цього підрозділу узгоджуються з числовими метриками та підтримують припущення, що інтеграція Hybrid AWRED v5 може бути корисною для стабілізації навчання за наявності структурних спотворень. Водночас переваги просторово-часової локалізації на цьому етапі доцільно розглядати як такі, що потребують подальшої кількісної перевірки.

### 5.3. Дослідження еволюції вагової функції та сепарації простору рішень

Динаміка адаптивних ваг у процесі оптимізації (рис. 3) показує, що механізм просторово-часового м'якого відсікання формує стійке розділення між нормальними та структурно спотвореними вікнами без переходу до жорсткого бінарного відсікання. Така поведінка узгоджується з математичною моделлю, де сигмоїдальна вагова функція забезпечує Ліпшицеву неперервність у зоні порога та зберігає диференційовність цільової функції. Саме завдяки цьому перехід між нормальними та аномальними вікнами відбувається плавно, без різких розривів градієнта.

У наведених експериментах після фази нарощування штрафу математичне очікування ваг для імпульсних збурень знижується приблизно до 0.41, тоді як для нормальних станів стабілізується поблизу 0.56. Це можна інтерпретувати як ознаку того, що аномальні сегменти отримують менший внесок у градієнтні оновлення, тоді як нормальні зразки зберігають домінуючу роль у формуванні параметрів моделі. У такому випадку механізм Ліпшицевої неперервності виконує не лише формальну роль забезпечення гладкості, а й підтримує стабільність оптимізаційної траєкторії під час навчання.

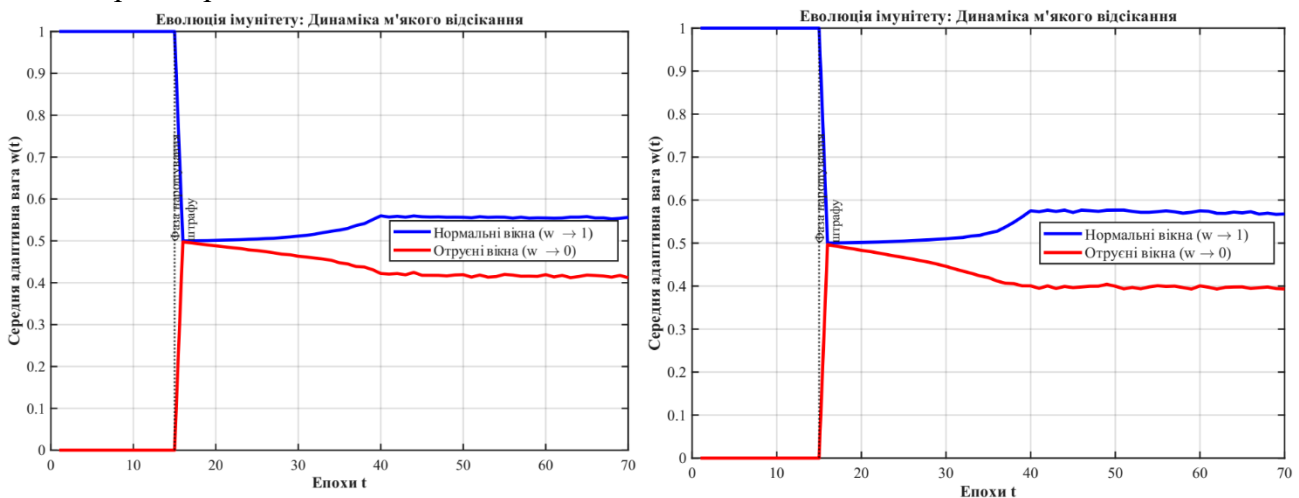
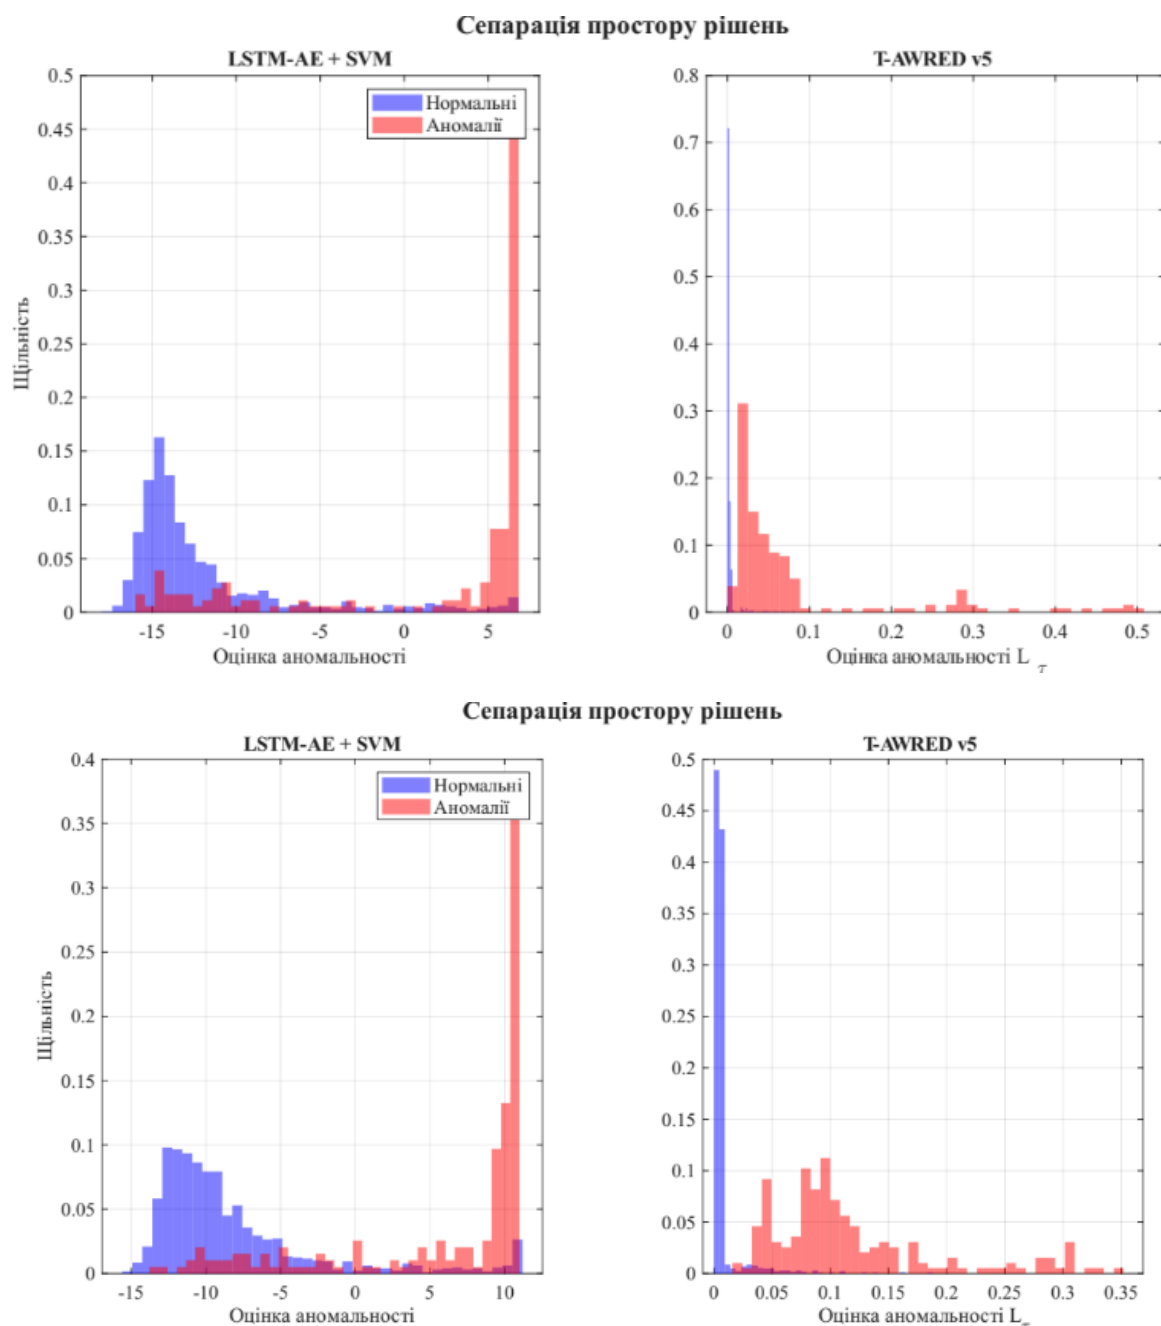


Рис. 3. Еволюція адаптивної вагової функції протягом процесу оптимізації: а) класична архітектура LSTM-AE; б) сучасна архітектура BiLSTM-AE

Показано, що механізм м'якого відсікання формує стійку сепарацію математичних очікувань ваг для нормальних і структурно спотворених вікон, зберігаючи гладкість та диференційовність цільової функції.

Аналіз простору рішень (рис. 4) також вказує, що використання Hybrid AWRED v5 пов'язане з кращим розділенням нормальних та аномальних станів порівняно з базовою оптимізацією на основі MSE. У візуалізаціях базові моделі демонструють більш виражене перекриття розподілів, тоді як для запропонованого підходу спостерігається чіткіша сепарація. Це узгоджується з вищими значеннями AUC-ROC та AP, отриманими для обох архітектур у табл. 1. Разом із тим ці висновки слід трактувати як підтвердження кращої роздільної здатності простору ознак.



**Рис. 4.** Гістограми щільності та сепарації простору рішень: а) класична архітектура LSTM-AE; б) сучасна архітектура BiLSTM-AE

Візуалізація показує більш чітке розділення нормальних та аномальних станів при застосуванні Hybrid AWRED v5 порівняно з базовою оптимізацією на основі MSE.

Загалом результати цього підрозділу свідчать, що Hybrid AWRED v5 здатний зменшувати чутливість рекурентних автоенкодерів до структурного забруднення навчальної вибірки. Це насамперед помітно за покращенням інтегральних метрик виявлення та більш стабільною поведінкою вагової функції під час оптимізації. У подальшому доцільно перевірити цей ефект на інших типах часових рядів, а також окремо оцінити якість локалізації аномальних сегментів.

#### *Висновки та напрямки подальших досліджень*

У цій роботі досліджено вразливість глибоких рекурентних автоенкодерів до структурних спотворень у навчальній вибірці. Отримані результати показали, що використання класичної цільової функції середньоквадратичної похибки (MSE) пов'язане з погіршенням якості сформованого простору ознак як у базових LSTM, так і в архітектурах із механізмами шарової нор-

малізації (BiLSTM + Layer Normalization). За умов 15% забруднення даних це супроводжується зниженням метрики Average Precision до 0.534–0.566.

Для зменшення цього ефекту було досліджено застосування п'ятої генерації методології адаптивного зважування - Hybrid AWRED v5. Використання механізму просторово-часового м'якого відсікання разом з автономною Байєсівською оптимізацією дало змогу сформувати диференційовний регулятор градієнтного потоку, який не потребує апріорної інформації про істинний рівень аномалій у навчальній вибірці. У проведених експериментах це супроводжувалося покращенням інтегральних метрик виявлення: для сучасної архітектури значення AUC-ROC досягло 0.990, а Average Precision - 0.922, що перевищує показники відповідних базових моделей.

Запропонований метод є архітектурно-незалежним інструментом робастної оптимізації. У подальших дослідженнях планується застосування методології на задачі авторегресійного багатокрокового прогнозування (екстраполяції) динаміки часових рядів. Також перспективним напрямком є інтеграція розробленої цільової функції з архітектурами на базі експоненціальної вентиляльної пам'яті (xLSTM) [12] та моделями простору станів (State Space Models, Mamba) [13].

### Декларація про штучний інтелект

Автор не використовував штучний інтелект при створенні матеріалів статті.

### Конфлікт інтересів

Автор заявляє про відсутність конфлікту інтересів та підтверджує, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доброчесності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

### Список використаної літератури

1. P. Malhotra, L. Vig, G. Shroff, and P. Agarwal, "Long Short Term Memory Networks for Anomaly Detection in Time Series," in *Proceedings of the 23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)*, 2015, pp. 89-94. URL: <https://www.esann.org/sites/default/files/proceedings/legacy/es2015-56.pdf>
2. R. Chalapathy, A. K. Menon, and S. Chawla, "Robust, Deep and Inductive Anomaly Detection," *arXiv preprint arXiv:1704.06743*, 2017. DOI: 10.48550/arXiv.1704.06743. URL: <https://arxiv.org/abs/1704.06743>
3. B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, "Estimating the Support of a High-Dimensional Distribution," *Neural Computation*, vol. 13, no. 7, pp. 1443-1471, 2001. DOI: 10.1162/089976601750264965. URL: <https://doi.org/10.1162/089976601750264965>
4. J. T. Barron, "A General and Adaptive Robust Loss Function," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 4331-4339. DOI: 10.1109/CVPR.2019.00446. URL: <https://arxiv.org/abs/1701.03077>
5. J. L. Ba, J. R. Kiros, and G. E. Hinton, "Layer Normalization," *arXiv preprint arXiv:1607.06450*, 2016. DOI: 10.48550/arXiv.1607.06450. URL: <https://arxiv.org/abs/1607.06450>
6. Y. Shen and S. Sanghavi, "Learning with Bad Training Data via Iterative Trimmed Loss Minimization," in *International Conference on Machine Learning (ICML)*, 2019, pp. 5739-5748. URL: <https://proceedings.mlr.press/v97/shen19e.html>
7. Т. П. Довженко, "Hybrid AWRED: Синергія адаптивної реконструкції та топологічної кластеризації для виявлення аномалій у мультимодальних даних," - *Зв'язок*. - 2026. - № 1 - с. 80 – 88. DOI:10.31673/2412-9070.2026.017405. URL: <https://con.duikt.edu.ua/index.php/communication/article/view/2965/2848>

8. Т. П. Довженко, О. В. Зінченко, "Стабільність моделей глибокого виявлення вторгнень в умовах масованих кібератак: стрес-тестування та архітектурні особливості Hybrid AWRED," - Телекомунікаційні та інформаційні технології.- 2026.- № 1 – с. 199 – 207. DOI: 10.31673/2412-4338.2026.019019. URL: <https://tit.duikt.edu.ua/index.php/telecommunication/article/view/2711/2558>
9. Т. П. Довженко, "Топологічне якорування та адаптивні штрафи: архітектура Hybrid AWRED для розпізнавання дефектів у забруднених візуальних даних," - Зв'язок. - 2026.- № 2 - с. 62 – 71. DOI: 10.31673/2412-9070.2026.027603. URL: <https://con.duikt.edu.ua/index.php/communication/article/view/2988/2866>
10. Т. П. Довженко, К. П. Сторчак, "Розробка наскрізної архітектури Hybrid AWRED для виявлення візуальних аномалій за дефіциту навчальних даних", *Technology audit and production reserves*, - 2026.-№ с.
11. J. Snoek, H. Larochelle, and R. P. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms," *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 25, 2012. URL: <https://proceedings.neurips.cc/paper/2012/hash/05311655a15b75fab86956663e1819cd-Abstract.html>
12. M. Beck et al., "xLSTM: Extended Long Short-Term Memory," *arXiv preprint arXiv:2405.04517*, 2024. DOI: 10.48550/arXiv.2405.04517. URL: <https://arxiv.org/abs/2405.04517>
13. A. Gu and T. Dao, "Mamba: Linear-Time Sequence Modeling with Selective State Spaces," *arXiv preprint arXiv:2312.00752*, 2023. DOI: 10.48550/arXiv.2312.00752. URL: <https://arxiv.org/abs/2312.00752>
14. L. Ruff et al., "Deep One-Class Classification," in *International Conference on Machine Learning (ICML)*, 2018, pp. 4390-4399. URL: <https://proceedings.mlr.press/v80/ruff18a.html>
15. B. Zong et al., "Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection," in *International Conference on Learning Representations (ICLR)*, 2018. URL: <https://openreview.net/forum?id=BJJLHbb0->
16. A. Blázquez-García, A. Conde, U. Mori, and J. A. Lozano, "A Review on Outlier/Anomaly Detection in Time Series Data," *ACM Computing Surveys*, vol. 54, no. 3, pp. 1-33, 2021. DOI: 10.1145/3444690. URL: <https://doi.org/10.1145/3444690>
17. A. Vaswani et al., "Attention Is All You Need," in *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 30, 2017. URL: <https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>
18. B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. de Freitas, "Taking the Human Out of the Loop: A Review of Bayesian Optimization," *Proceedings of the IEEE*, vol. 104, no. 1, pp. 148-175, 2016. DOI: 10.1109/JPROC.2015.2494218. URL: <https://doi.org/10.1109/JPROC.2015.2494218>
19. Q. Wen et al., "Time Series Data Augmentation for Deep Learning: A Survey," *Proceedings of the 30th International Joint Conference on Artificial Intelligence (IJCAI)*, 2021, pp. 4653-4660. DOI: 10.24963/ijcai.2021/631. URL: <https://doi.org/10.24963/ijcai.2021/631>

T. Dovzhenko

### **ROBUST TIME-SERIES ANOMALY DETECTION UNDER STRUCTURAL DISTORTIONS: INTEGRATING HYBRID AWRED V5 INTO CLASSICAL AND BIDIRECTIONAL LSTM NETWORKS**

*Deep recurrent neural networks are widely used for time-series anomaly detection, but their performance strongly depends on the purity of the training data. The classical Mean Squared Error (MSE) loss is sensitive to structural distortions because anomalous windows can bias gradient updates and degrade the quality of the learned latent representation. This paper considers the fifth generation of the Hybrid AWRED v5 methodology (Adaptive Weighted Reconstruction with Regularized Energy and Dynamics), which introduces a differentiable loss function with a spatio-temporal soft-thresholding mechanism. Bayesian optimization is used to tune the weighting function parameters, allowing the clipping threshold to adapt to the current distribution of reconstruction errors.*

*The experimental study compares two baseline architectures, a classical LSTM and a bidirectional BiLSTM with layer normalization, under a 15% structural contamination rate in the training sample. With the standard MSE loss, the Average Precision metric reaches 0.534 for the classical LSTM and 0.566 for the bidirectional architecture. After integrating Hybrid AWRED v5, these values increase to 0.835 and 0.922, respectively. For the modern architecture, the proposed objective function also achieves an AUC-ROC of 0.990. These results indicate that the method preserves anomaly ranking quality more effectively under contaminated training conditions.*

*Overall, Hybrid AWRED v5 can be viewed as a promising architecture-agnostic tool for robust optimization in time-series anomaly detection. At the same time, its advantages are most directly supported by detection and ranking metrics, while a separate quantitative evaluation of spatio-temporal localization remains a direction for further work.*

**Keywords:** anomaly detection, time series, deep learning, LSTM, BiLSTM, structural distortions, data contamination, robust optimization, Hybrid AWRED v5.

---

Надійшла до редакції: 10.04.2026

Прийнята до друку: 29.05.2026

Опубліковано: 29.06.2026

© 2026 Т. П. Довженко.

Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0/>