

Довженко Тимур Павлович

кандидат технічних наук

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID:0000-0002-0352-8391

timurdov@ukr.net

МАРШРУТНА НЕПЕРЕРВНІСТЬ ОЦІНКИ АНОМАЛЬНОСТІ В ТЕЛЕКОМУНІКАЦІЙНИХ ЧАСОВИХ РЯДАХ ЗА УМОВ ПЕРЕХІДНИХ РЕЖИМІВ НА ОСНОВІ HYBRID AWRED

Анотація. У статті розглянуто задачу виявлення перехідних аномалій у часових рядах KPI (ключових показників ефективності мережі). На відміну від коротких збоїв, такий режим не завжди проявляється у вигляді різкого викиду одного показника. Ця зміна може накопичуватись поступово. При цьому змінюється форма маршруту, порушується узгодженість між RSRP (потужність прийнятого опорного сигналу), DL_BLER (частка помилкових блоків у низхідному каналі), UL_MCS (модуляційно-кодова схема у висхідному каналі) та UL_SNR (співвідношення сигнал/шум у висхідному каналі), в той час як окремі значення ще можуть залишатися близькими до допустимих меж. Ось чому реконструкційні моделі нерідко реагують на локальні піки оцінки аномальності, але не можуть утримувати її підвищеною на всій перехідній ділянці.

Для вирішення цієї задачі запропоновано маршрутно-орієнтований метод Hybrid AWRED v6. Він поєднує Transformer-реконструктор, механізм Normal-Support Anchor і маршрутну складову оцінки аномальності. Саме така побудова враховує не тільки величину локального відхилення, а й сталість реакції моделі вздовж переходу. Перевірку виконано на наборі TelecomTS для сценарію м'якої зміни режиму. Проведено порівняння в серії з п'яти незалежних прогонів з моделями DAGMM, TranAD та Anomaly Transformer.

Hybrid AWRED v6 досяг середніх значень ROC-AUC = 0.959 та PR-AUC = 0.890. Також метод показав вищі F1, Recall і маршрутну якість виявлення RDQ. Precision була децю нижчою, ніж у TranAD та Anomaly Transformer, але ця різниця пов'язана з більш широким покриттям переходу, а не з втратою здатності розділяти нормальні й аномальні вікна. Окремо зафіксовано повторюваність Continuity у п'яти прогонах — 0.378 ± 0.000 . Найдовший неперервний відрізок правильного виявлення мав однаково відносно довжину незалежно від ініціалізації.

Отримані результати показують, що Hybrid AWRED v6 формує не тільки точкову, а й маршрутно сталу оцінку аномальності при м'яких перехідних режимах у часових рядах.

Ключові слова: Hybrid AWRED v6, виявлення аномалій, телекомунікаційні часові ряди, перехідна аномалія, маршрутна неперервність, KPI, PR-AUC, RDQ.

Tymur Dovzhenko

Candidate of Technical Sciences

State University of Information and Communication Technologies, Kyiv, Ukraine

ORCID:0000-0002-0352-8391

timurdov@ukr.net

ROUTE CONTINUITY OF ANOMALY ASSESSMENT IN TELECOMMUNICATION TIME SERIES UNDER TRANSITION REGIMES BASED ON HYBRID AWRED

Abstract. The article considers the task of detecting transition anomalies in KPI time series, where KPI denotes key network performance indicators. Unlike short failures, such a regime does not always appear as a sharp outlier in a single indicator. The change may accumulate gradually. In this case, the shape of the route changes, the consistency between RSRP (reference signal received power), DL_BLER (downlink block error rate), UL_MCS (uplink modulation and coding scheme), and UL_SNR (uplink signal-to-noise ratio) is disturbed, while individual values may still remain close to acceptable limits. For this reason, reconstruction-based models often respond to local peaks of the anomaly score but cannot keep it elevated over the entire transition segment.

To address this task, a route-oriented Hybrid AWRED v6 method is proposed. It combines a Transformer reconstructor, the Normal-Support Anchor mechanism, and the route component of the anomaly score. This structure takes into account not only the magnitude of a local deviation, but also the stability of the model response along the transition. The evaluation was performed on the TelecomTS dataset for a soft regime-change scenario. The comparison was carried out in a series of five independent runs against DAGMM, TranAD, and Anomaly Transformer.

Hybrid AWRED v6 achieved mean values of ROC-AUC = 0.959 and PR-AUC = 0.890. The method also demonstrated higher F1, Recall, and route detection quality RDQ. Precision was slightly lower than that of TranAD and Anomaly Transformer, but this difference is related to broader transition coverage, rather than to a loss of ability to separate normal and anomalous windows. Full repeatability of Continuity was also recorded across five runs — 0.378 ± 0.000 . The longest continuous segment of correct detection had the same relative length regardless of model initialization.

The obtained results show that Hybrid AWRED v6 forms not only a pointwise, but also a route-stable anomaly score for soft transition regimes in time series.

Keywords: Hybrid AWRED v6, anomaly detection, telecommunication time series, transition anomaly, route continuity, KPI, PR-AUC, RDQ.

1. Вступ

Безперервне спостереження телекомунікаційних мереж спирається на часові ряди KPI: RSRP, BLER, MCS, SNR і інші показники стану каналу. Ці сигнали практично поводяться нерівно. Вони можуть залежати один від одного, змінюватись під навантаженням, реагувати на завади та режим роботи обладнання.

Різкі збої в каналі чи обладнанні виявляються простіше. Це або провал сигналу, обрив зв'язку, або інші помилки, що дають помітний відрив від норми. Інша річ, коли йдеться про поступовий перехід у нестійкий стан. Якщо окремі KPI ще можуть бути допустимими, то спільна динаміка вже буде змінена.

Більшість методів здебільшого спираються на реконструкційну помилку, енергетичну функцію або відхилення ознак від нормального режиму. Але для перехідної аномалії цього часто замало. Модель реагує на окремі фрагменти і не завжди утримує підвищену оцінку аномальності на всій ділянці.

Тому ROC-AUC, PR-AUC і F1 не повністю описують таку задачу. Такий результат може виглядати прийнятним, в той час як покрито лише найвиразніші частини переходу. У цій роботі перехідна аномалія розглядається як часовий маршрут зміни стану мережі.

2. Постановка проблеми

В телекомунікаційних часових рядах перехідні аномалії відрізняються від коротких ізольованих збоїв. Для різкого викиду достатньо зафіксувати факт відхилення. Але для переходу цього замало. Аномальний стан може розтягуватись в часі, охоплювати послідовність вікон і часто проявляється через спільну динаміку кількох KPI.

Проблема ще й в тому, що метод може мати прийнятні стандартні метрики, але реагувати лише на ту частину переходу, де переважно існують найвиразніші піки. Формально аномалія буде виявлена. Але для моніторингу це слабке місце, бо система може показати повернення до норми, хоча перехідний процес ще триває.

Отже, оцінювати потрібно не тільки розділення нормальних і аномальних вікон. Тут важливо знати, чи тримається підвищена оцінка аномальності в межах маршруту і чи не виникають зайві фрагментовані спрацьовування на нормальних ділянках. Для цього стандартні метрики доповнено маршрутно-орієнтованою характеристикою.

3. Аналіз останніх досліджень і публікацій

Дослідження з виявлення аномалій у часових рядах розвиваються у кількох напрямках. Значна частина робіт зосереджена на глибоких моделях для багатовимірних послідовностей. Інші роботи стосуються протоколів оцінювання та відкритих еталонних наборів. Для цієї роботи важливими є всі три напрями, оскільки HYBRID AWRED порівнюється з трансформерними, реконструкційними та енергетично-густинними методами.

В роботі [1] Anomaly Transformer розглядає аномалії через розбіжність асоціацій у механізмі уваги. Робота [2] присвячена тому, як TranAD використовує трансформерну реконструкцію з урахуванням попередньої помилки. Ці підходи є сильними базовими моделями для порівняння. Однак у задачі перехідної аномалії важлива не тільки сила локального відхилення, а й сталість реакції вздовж ділянки зміни режиму.

До групи робіт з оцінювання методів виявлення аномалій у часових рядах належать праці [3], [4]. В них показано, що результат залежить від типу даних, протоколу оцінювання та способу обробки аномальних інтервалів. Підходи які представлені в [5], [6] також звертають увагу на форму, тривалість і положення аномалії в часовій послідовності. Для цієї статті це важливо, бо перехідна аномалія не є одиничним викидом.

В роботах [7], [8] наголошується на тому, що вибір метрики має відповідати природі задачі. Для незбалансованих сценаріїв PR-AUC часто інформативніша за одну лише ROC-AUC. Але вона не показує, наскільки неперервною є реакція моделі в межах аномального інтервалу. AutoTSAD [9] розвиває інший напрям – автоматизований добір і ансамблювання алгоритмів. HYBRID AWRED v6 має іншу логіку: він формує спеціалізовану маршрутно-орієнтовану оцінку аномальності.

Прикладний контекст роботи задає набір TelecomTS [10], у якому телекомунікаційні KPI розглядаються як складні, шумні й нестабільні часові ряди. Це дає змогу перевіряти метод не на абстрактному сигналі, а на сценарії, близькому до задач моніторингу мережі. Для цієї статті особливо важливим є випадок м'якого переходу між режимами, де зміна стану проявляється не як один різкий пік, а як протяжна ділянка поступової деградації.

Отже, наявні роботи добре охоплюють трансформерні, реконструкційні, енергетичні та еталонні порівняльні дослідження до виявлення аномалій у часових рядах. Водночас недостатньо розкритою залишається задача маршрутно неперервності виявлення перехідних аномалій. Більшість методів оцінює факт або силу відхилення, але не завжди показує, чи зберігається підвищена оцінка аномальності вздовж усієї перехідної ділянки. Саме ця невирішена частина проблеми визначає спрямованість даної статті.

4. Мета і задачі дослідження

Об'єктом дослідження є процес автоматичного виявлення перехідних аномальних режимів у багатовимірних телекомунікаційних часових рядах KPI.

Метою дослідження є визначення можливості архітектури HYBRID AWRED забезпечувати маршрутну неперервність оцінки аномальності в телекомунікаційних часових рядах за умов м'яких перехідних режимів.

Для досягнення мети було поставлено й вирішено такі задачі:

1. Сформувані експериментальний сценарій м'якої перехідної аномалії в багатовимірних телекомунікаційних часових рядах на основі KPI RSRP, DL_BLER, UL_MCS та UL_SNR.

2. Реалізувати маршрутно-орієнтовану схему HYBRID AWRED, що поєднує Transformer-реконструктор, механізм Normal-Support Anchor та оцінку сталості аномального маршруту.
3. Порівняти якість виявлення перехідної аномалії з методами DAGMM, TranAD та Anomaly Transformer за стандартними метриками ROC-AUC, PR-AUC, F1 і Recall.
4. Оцінити маршрутну неперервність оцінки аномальності за допомогою RDQ та показника неперервності виявлення, а також перевірити відтворюваність результатів у серії з п'яти незалежних прогонів.

5. Результати дослідження

5.1. Структура маршрутної оцінки аномальності HYBRID AWRED

Поточна робота продовжує методологічну лінію HYBRID AWRED, сформовану в попередніх дослідженнях автора [11]–[14]. У версії HYBRID AWRED v6 ця ідея перенесена на задачу перехідних аномалій у телекомунікаційних часових рядах. Аномалія тут розглядається не лише як велика похибка реконструкції, а як порушення стійкого маршруту нормального режиму. Тому модель має не просто зафіксувати локальний пік оцінки аномальності, а сформуванати протяжний відгук на ділянці зміни режиму.

На вхід моделі подається багатовимірне часове вікно KPI $X_t \in R^{F \times L}$, де F — кількість фізичних показників, а L — довжина вікна. У проведеному експерименті використовувалися чотири KPI: RSRP, DL_BLER, UL_MCS та UL_SNR, тобто $F = 4$, а довжина вікна становила $L = 128$. Базова частина HYBRID AWRED v6 виконує реконструкцію цього вікна за допомогою Transformer-реконструктора: $\hat{X}_t = f_\theta(X_t)$. Додатково використовується Normal-Support Anchor, який порівнює поточний стан із опорною областю нормального режиму [1], [2], [15].

Узагальнена базова оцінка аномальності складається з кількох каналів:

$$S_t = \sqrt{(\gamma_E E_t)^2 + (\gamma_G G_t)^2 + (\gamma_H H_t)^2 + (\gamma_\Phi \Phi_t)^2} + \lambda_{mix} (\gamma_E E_t + \gamma_G G_t + \gamma_H H_t + \gamma_\Phi \Phi_t). \quad (1)$$

Тут E_t — реконструкційне відхилення, G_t — відхилення від області нормального режиму, H_t — топологічне відхилення, Φ_t — неузгодженість координати Normal-Support Anchor, а $\gamma_E, \gamma_G, \gamma_H, \gamma_\Phi$ — вагові коефіцієнти відповідних каналів. У проведених експериментах використовувалося фіксоване значення $\lambda_{mix} = 0.15$.

Оцінка S_t добре фіксує локальні відхилення, однак для перехідної аномалії важлива також сталість реакції в часі. Тому спочатку береться невід’ємна частина $S_t^+ = \max(0, S_t)$, після чого ця послідовність згладжується на сусідніх часових вікнах за допомогою симетричного трикутного ядра. У проведеному експерименті використовувалося вікно згладжування $w = 7$.

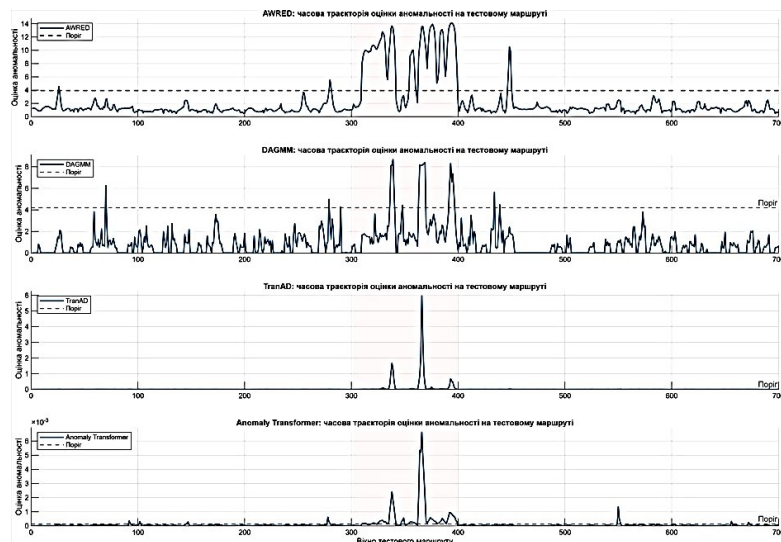


Рис. 1. Часова траєкторія оцінки аномальності HYBRID AWRED на тестовому маршруті

Фінальна маршрутна оцінка аномальності визначається як геометричне поєднання незгладженої оцінки та її згладженої форми:

$$R_t = \sqrt{S_t^+ \cdot \tilde{S}_t}. \quad (2)$$

Саме R_t використовується як фінальна оцінка аномальності HYBRID AWRED v6 у сценарії перехідного режиму. Така форма послаблює короткі ізольовані піки, якщо вони не підтримуються сусідніми вікнами, але

зберігає підвищене значення на протяжних ділянках зміни режиму. Для інтерпретації ізольованих спрацьовувань додатково використовувався індекс піковості $I_t = \max(0, S_t^+ - R_t)$.

На рис. 1 показано часову траєкторію HYBRID AWRED v6 для репрезентативного прогону Run_02. На ньому подано базову оцінку S_t , маршрутну оцінку R_t , пікову складову I_t динаміку Normal-Support Anchor.

5.2. Дані, протокол і метрики оцінювання

Експериментальна перевірка виконувалася на даних TelecomTS [10]. Для цієї роботи використано сценарій TelecomTS_Twitch_static_transition_soft, який моделює м'який перехід телекомунікаційної системи від нормального режиму до аномального і назад до нормального стану. Такий сценарій не зводиться до короткого викиду, оскільки перехідна ділянка має власну тривалість, форму й послідовне розміщення в тестовому маршруті.

У дослідженні використовувалися чотири KPI: RSRP, DL_BLER, UL_MCS та UL_SNR. Вони описують різні сторони стану телекомунікаційного каналу: рівень прийнятого сигналу, помилки передавання, характеристики модуляційно-кодової схеми та співвідношення сигнал/шум. Окремо кожен показник може не давати повної картини, але разом вони формують багатовимірний маршрут стану мережі [17], [19].

Вихідні дані були подані у вигляді послідовностей віконних фрагментів. Загальна кількість нормальних вікон становила 3007, вікон з завадою – 94, перехідних вікон – 98. Після поділу було сформовано 2116 вікон для навчання, 289 нормальних валідаційних вікон, 602 нормальних тестових вікна і 98 перехідних тестових вікон. Загальна довжина тестового маршруту становила 700 вікон. Його структура мала вигляд: нормальна ділянка до переходу → перехідна ділянка → нормальна ділянка після переходу, тобто нормальні й аномальні вікна не змішувалися випадково.

Поріг виявлення визначався за нормальною валідаційною частиною даних. Тестова перехідна ділянка для його налаштування не використовувалася. Це важливо для відтворюваності експерименту, оскільки поріг не підбирався після перегляду тестових аномалій.

Для оцінювання використовувалися дві групи показників. Перша група охоплювала стандартні метрики бінарної класифікації: ROC-AUC, PR-AUC, Precision, Recall і F1. Вони розраховувалися за загальноприйнятими формулами та використовувалися для порівняння HYBRID AWRED v6 із базовими методами. У таблицях основного тексту подано ROC-AUC, PR-AUC, F1 та Recall. Precision розглядається окремо, оскільки для цієї задачі він має інтерпретуватися разом із покриттям перехідної ділянки.

Друга група містила маршрутно-орієнтовані характеристики. Для кожного тестового вікна модель формувала оцінку аномальності a_t . Для HYBRID AWRED v6 такою оцінкою була маршрутна складова R_t , а для порівнюваних методів — їхні власні оцінки аномальності. Бінарне рішення приймалося за правилом: $\hat{y}_t = 1$, якщо $a_t \geq \theta$, і $\hat{y}_t = 0$, якщо $a_t < \theta$, де θ — поріг виявлення.

Для оцінювання маршрутної поведінки використано RDQ — маршрутну якість виявлення [8], [16], [20]. Нехай T — множина вікон перехідної ділянки, а N — множина нормальних вікон тестового маршруту. У розрахунку RDQ враховувалися покриття переходу $Coverage = TP_T / |T|$, маршрутна точність $Proute = TP_T / (TP_T + FP_N)$, маршрутна F1-міра, неперервність виявлення $Continuity (C_{route})$ як частка найдовшого неперервного відрізка правильних спрацьовувань у T , частка хибних спрацьовувань $FAR = FP_N / |N|$ і штраф фрагментованості $P_{frag} = 1 / (1 + \ln(1 + N_{seg}))$.

Підсумкова маршрутна якість виявлення визначалася як

$$RDQ = F1_{route} \cdot \sqrt{C_{route}} \cdot (0,1 - FAR) \cdot P_{frag} \quad (3)$$

На відміну від стандартних метрик, RDQ не може бути високою лише через один сильний пік усередині аномальної ділянки. Для високого значення потрібні одночасно покриття переходу, неперервність реакції, невелика кількість хибних спрацьовувань і мала фрагментованість цих спрацьовувань

5.3. Оцінювання за стандартними метриками

Порівняння HYBRID AWRED v6 виконувалося з трьома базовими методами: DAGMM, TranAD та Anomaly Transformer [1], [2], [18]. Усі методи оцінювалися на однаковому тестовому маршруті та за однаковим протоколом. Основний візуальний приклад подано для Run_02, оскільки його ROC-AUC для HYBRID AWRED становив 0.955, що близько до середнього значення по серії з п'яти прогонів — 0.959.

ROC- та PR-криві для Run_02 наведено на рис. 2. Вони показують, що HYBRID AWRED v6 краще відокремлює нормальні й перехідні вікна порівняно з базовими методами. Для цієї задачі особливо важливою є PR-крива, оскільки перехідна ділянка займає меншу частину тестового маршруту.

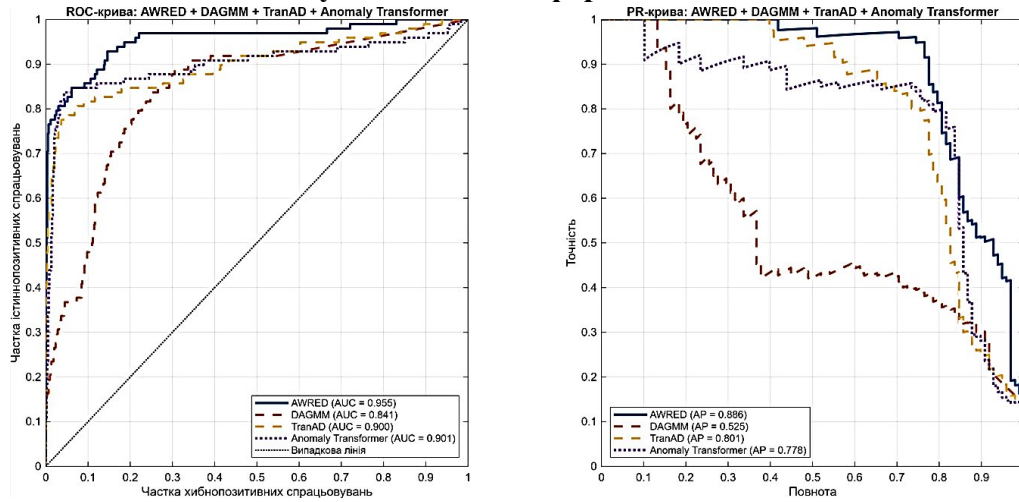


Рис. 2. ROC- та PR-криві для HYBRID AWRED і конкурентних моделей

Узагальнені результати за серією з п’яти незалежних прогонів наведено в табл. 1.

Таблиця 1

Порівняння методів за стандартними метриками

Метод	ROC-AUC	PR-AUC	F1	Recall
HYBRID AWRED	0.959 ± 0.008	0.890 ± 0.008	0.823 ± 0.024	0.794 ± 0.017
TranAD	0.901 ± 0.003	0.807 ± 0.005	0.762 ± 0.019	0.682 ± 0.043
Anomaly Transformer	0.890 ± 0.019	0.785 ± 0.040	0.751 ± 0.041	0.661 ± 0.059
DAGMM	0.813 ± 0.033	0.464 ± 0.106	0.283 ± 0.126	0.190 ± 0.091

З табл. 1 видно, що HYBRID AWRED v6 має найвищі середні значення за всіма поданими стандартними метриками. Найбільша перевага спостерігається за PR-AUC і Recall. Це важливо саме для перехідної аномалії, оскільки високий Recall означає краще покриття аномальної ділянки, а не лише реагування на окремі локальні піки.

Порівняно з TranAD, HYBRID AWRED v6 підвищує PR-AUC з 0.807 до 0.890, а F1 — з 0.762 до 0.823. Anomaly Transformer також поступається HYBRID AWRED v6 за всіма основними метриками. DAGMM у цьому сценарії має найнижчі результати, що свідчить про слабку придатність енергетично-густинної оцінки для м’якого перехідного режиму.

Окремо слід зазначити Precision. У середньому HYBRID AWRED v6 мав Precision = 0.856 ± 0.053, тоді як Anomaly Transformer — 0.873 ± 0.044, а TranAD — 0.868 ± 0.036. Різниця невелика і пояснюється ширшим покриттям перехідної ділянки. Для цієї задачі це можна розглядати як компроміс між точністю окремого спрацювання і здатністю не втратити аномальний маршрут.

Стандартні метрики підтверджують перевагу HYBRID AWRED v6, але не повністю пояснюють її характер. Для цього далі аналізуються часові траєкторії оцінки аномальності.

5.4. Часова та маршрутна якість виявлення

Для перехідної аномалії важливо не лише числове розділення нормальних і аномальних вікон, а й форма оцінки аномальності в часі. На рис. 3 наведено часові траєкторії для чотирьох методів: HYBRID AWRED v6, DAGMM, TranAD та Anomaly Transformer. Усі методи аналізували один і той самий тестовий маршрут, у якому перехідна ділянка розташована між нормальними фрагментами.

З рис. 3 видно, що HYBRID AWRED v6 формує не окремий короткий пік, а протяжну реакцію в межах перехідної ділянки. Оцінка аномальності зростає на ділянці зміни режиму й утримується підвищеною протягом значної частини цього інтервалу. TranAD та Anomaly Transformer також реагують на перехідний режим, але їхній відгук частіше має вигляд локальних піків. DAGMM демонструє найменш стійку поведінку, що узгоджується з його нижчими значеннями PR-AUC та Recall.

Для кількісної оцінки такої поведінки використано RDQ — маршрутну якість виявлення. На відміну від стандартних метрик, цей показник враховує покриття перехідної ділянки, неперервність правильного виявлення та фрагментованість хибних реакцій на нормальних частинах маршруту. Середні значення RDQ та неперервності виявлення за серією з п’яти незалежних прогонів наведено в табл. 2




Рис. 3. Часові траєкторії оцінки аномальності для HYBRID AWRED, DAGMM, TranAD та Anomaly Transformer

Таблиця 2

Маршрутна якість виявлення перехідної аномалії

Метод	RDQ	Неперервність виявлення
HYBRID AWRED	0.186 ± 0.028	0.378 ± 0.000
TranAD	0.125 ± 0.027	0.231 ± 0.082
Anomaly Transformer	0.118 ± 0.034	0.173 ± 0.046
DAGMM	0.023 ± 0.021	0.055 ± 0.028

З табл. 2 видно, що HYBRID AWRED v6 має найвище середнє значення RDQ — 0.186 ± 0.028 . Для TranAD цей показник становить 0.125 ± 0.027 , для Anomaly Transformer — 0.118 ± 0.034 , а для DAGMM — 0.023 ± 0.021 . Такий розподіл узгоджується з часовими траєкторіями на рис. 3: методи з більш фрагментованою реакцією отримують нижче значення маршрутної якості.

Окремо важливим є показник неперервності виявлення. Для HYBRID AWRED v6 він становить 0.378 ± 0.000 . Нульове СКВ означає, що в усіх п'яти прогонах найдовший неперервний відрізок правильного виявлення всередині перехідної ділянки мав однакову відносну довжину. Це підтверджує, що маршрутна реакція моделі не була випадковим наслідком окремої ініціалізації.

Поріг HYBRID AWRED v6 визначався за валідаційною частиною даних, що містила лише нормальні вікна і не налаштовувався за тестовою перехідною ділянкою. У п'яти прогонах його значення змінювалися приблизно від 2.95 до 3.93, а середнє значення становило близько 3.41. Така варіативність не призвела до втрати переваги HYBRID AWRED v6 за стандартними або маршрутними метриками, що додатково підтверджує відтворюваність процедури оцінювання [8], [16], [20].

6. Висновки та перспективи подальших досліджень

У роботі сформовано сценарій м'якої перехідної аномалії в багатовимірних телекомунікаційних часових рядах на основі показників RSRP, DL_BLER, UL_MCS та UL_SNR. Тестовий маршрут мав послідовну структуру нормальна ділянка до переходу → перехідна ділянка → нормальна ділянка після переходу і складався із 700 вікон, серед яких 98 належали до перехідної ділянки. Така побудова дала змогу оцінювати не тільки розділення нормальних і аномальних вікон, а й поведінку оцінки аномальності вздовж усього маршруту.

Реалізовано маршрутно-орієнтовану схему HYBRID AWRED v6, яка поєднує реконструктор на основі трансформера, еталон нормального режиму і маршрутну складову оцінки аномальності. На відміну від звичайної реконструкційної моделі, цей підхід орієнтований не лише на локальне відхилення, а й на сталість реакції в межах перехідної ділянки.

Порівняння з DAGMM, TranAD та Anomaly Transformer показало перевагу HYBRID AWRED v6 за основними стандартними метриками. У серії з п'яти незалежних прогонів метод досяг ROC-AUC = 0.959 ± 0.008 , PR-AUC = 0.890 ± 0.008 , F1 = 0.823 ± 0.024 та Recall = 0.794 ± 0.017 . Найпомітнішою була перевага за PR-AUC і

Recall, що важливо для незбалансованого маршруту, де перехідна ділянка займає меншу частину тестової послідовності.

Маршрутна якість виявлення також була найвищою для HYBRID AWRED v6. Значення RDQ становило 0.186 ± 0.028 , а неперервність виявлення — 0.378 ± 0.000 . Нульове СКВ для неперервності означає, що в усіх п'яти прогонах найдовший неперервний відрізок правильного виявлення мав однакову відносну довжину. Це підтверджує відтворюваність маршрутної реакції моделі.

HYBRID AWRED v6 мав дещо нижчу Precision, ніж TranAD та Anomaly Transformer, однак це пов'язано з ширшим покриттям перехідної ділянки. Для задачі м'якої перехідної аномалії такий результат є прийнятним компромісом між точністю окремого спрацьовування і здатністю не втрачати аномальний маршрут.

Подальші дослідження доцільно спрямувати на перевірку HYBRID AWRED v6 на ширшому наборі телекомунікаційних сценаріїв, зокрема з різною тривалістю переходів і різними типами деградації. Окремого уточнення потребують маршрутні метрики RDQ і неперервність виявлення, а також процедура порогової калібровки для практичного використання методу в системах моніторингу.

Декларація про штучний інтелект

Автор не використовував штучний інтелект при створенні матеріалів статті.

Конфлікт інтересів

Автор заявляє про відсутність конфлікту інтересів.

Список використаних літератури

1 Xu, J.; Wu, H.; Wang, J.; Long, M. Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy. ICLR, 2022. URL: https://openreview.net/forum?id=LzQQ89U1qm_. DOI: <https://doi.org/10.48550/arXiv.2110.02642>.

2 Tuli, S.; Casale, G.; Jennings, N. R. TranAD: Deep Transformer Networks for Anomaly Detection in Multivariate Time Series Data. Proceedings of the VLDB Endowment, 2022, 15(6), 1201–1214. URL: <https://vldb.org/pvldb/vol15/p1201-tuli.pdf>. DOI: <https://doi.org/10.14778/3514061.3514067>.

3 Schmidl, S.; Wenig, P.; Papenbrock, T. Anomaly Detection in Time Series: A Comprehensive Evaluation. Proceedings of the VLDB Endowment, 2022, 15(9), 1779–1797. URL: <https://www.vldb.org/pvldb/vol15/p1779-wenig.pdf>. DOI: <https://doi.org/10.14778/3538598.3538602>.

4 Kim, S.; Choi, K.; Choi, H.-S.; Lee, B.; Yoon, S. Towards a Rigorous Evaluation of Time-Series Anomaly Detection. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(7), 7194–7201. URL: <https://ojs.aaai.org/index.php/AAAI/article/view/20680>. DOI: <https://doi.org/10.1609/aaai.v36i7.20680>.

5 Paparrizos, J.; Kang, Y.; Boniol, P.; Tsay, R. S.; Palpanas, T.; Franklin, M. J. TSB-UAD: An End-to-End Benchmark Suite for Univariate Time-Series Anomaly Detection. Proceedings of the VLDB Endowment, 2022, 15(8), 1697–1711. URL: <https://www.vldb.org/pvldb/vol15/p1697-paparrizos.pdf>. DOI: <https://doi.org/10.14778/3529337.3529354>.

6 Paparrizos, J.; Boniol, P.; Palpanas, T.; Tsay, R. S.; Elmore, A. J.; Franklin, M. J. Volume Under the Surface: A New Accuracy Evaluation Measure for Time-Series Anomaly Detection. Proceedings of the VLDB Endowment, 2022, 15(11), 2774–2787. URL: <https://www.vldb.org/pvldb/vol15/p2774-paparrizos.pdf>. DOI: <https://doi.org/10.14778/3551793.3551830>.

7 Darban, Z. Z.; Webb, G. I.; Pan, S.; Aggarwal, C. C.; Salehi, M. Deep Learning for Time Series Anomaly Detection: A Survey. ACM Computing Surveys, 2024, 57(1), Article 15. URL: <https://dl.acm.org/doi/10.1145/3691338>. DOI: <https://doi.org/10.1145/3691338>.

8 Sørnbø, S.; Ruocco, M. Navigating the Metric Maze: A Taxonomy of Evaluation Metrics for Anomaly Detection in Time Series. Data Mining and Knowledge Discovery, 2024, 38, 1027–1068. URL: <https://link.springer.com/article/10.1007/s10618-023-00988-8>. DOI: <https://doi.org/10.1007/s10618-023-00988-8>.

9 Schmidl, S.; Naumann, F.; Papenbrock, T. AutoTSAD: Unsupervised Holistic Anomaly Detection for Time Series Data. Proceedings of the VLDB Endowment, 2024, 17(11), 2987–3002. URL: <https://www.vldb.org/pvldb/vol17/p2987-schmidl.pdf>. DOI: <https://doi.org/10.14778/3681954.3681978>.

10 Feng, A.; Varvarigos, A.; Panitsas, I.; Fernandez, D.; Wei, J.; Guo, Y.; Chen, J.; Maatouk, A.; Tassiulas, L.; Ying, R. TelecomTS: A Multi-Modal Observability Dataset for Time Series and Language Analysis. arXiv, 2025. URL: <https://arxiv.org/abs/2510.06063>; dataset URL: <https://huggingface.co/datasets/AliMaatouk/TelecomTS>. DOI: <https://doi.org/10.48550/arXiv.2510.06063>.

11 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>

12 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>

13 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>

14 Довженко, Т. П. Робастне виявлення аномалій у часових рядах за умов наявності структурних спотворень: інтеграція методу Hybrid AWRED v5 у класичні та двонаправлені LSTM-мережі.

15 Wu, H.; Hu, T.; Liu, Y.; Zhou, H.; Wang, J.; Long, M. TimesNet: Temporal 2D-Variation Modeling for General Time Series Analysis. *ICLR*, 2023. DOI: <https://doi.org/10.48550/arXiv.2210.02186>. URL: <https://arxiv.org/abs/2210.02186>.

16 Liu, Q.; Paparrizos, J. The Elephant in the Room: Towards A Reliable Time-Series Anomaly Detection Benchmark. *Advances in Neural Information Processing Systems 37 (NeurIPS 2024), Datasets and Benchmarks Track*, 2024. DOI: <https://doi.org/10.52202/079017-3437>. URL: https://proceedings.neurips.cc/paper_files/paper/2024/hash/c3f3c690b7a99fba16d0efd35cb83b2c-Abstract-Datasets_and_Benchmarks_Track.html.

17 Bordeau-Aubert, K.; Whatley, J.; Nadeau, S.; Glatard, T.; Jaumard, B. Classification of Anomalies in Telecommunication Network KPI Time Series. *arXiv*, 2023. DOI: <https://doi.org/10.48550/arXiv.2308.16279>. URL: <https://arxiv.org/abs/2308.16279>.

18 Wang, F.; Jiang, Y.; Zhang, R.; Wei, A.; Pang, X.; Xie, J. A Survey of Deep Anomaly Detection in Multivariate Time Series: Taxonomy, Applications, and Directions. *Sensors*, 2025, 25(1), 190. DOI: <https://doi.org/10.3390/s25010190>. URL: <https://www.mdpi.com/1424-8220/25/1/190>.

19 Liu, J.; Gu, W.; Chen, Z.; Li, Y.; Su, Y.; Lyu, M. R. MTAD: Tools and Benchmarks for Multivariate Time Series Anomaly Detection. *arXiv*, 2024. DOI: <https://doi.org/10.48550/arXiv.2401.06175>. URL: <https://arxiv.org/abs/2401.06175>.

20 Correia, L.; Goos, J.-C.; Klein, P.; Bäck, T.; Kononova, A. V. Online Model-Based Anomaly Detection in Multivariate Time Series: Taxonomy, Survey, Research Challenges and Future Directions. *Engineering Applications of Artificial Intelligence*, 2024, 138, 109323. DOI: <https://doi.org/10.1016/j.engappai.2024.109323>. URL: <https://www.sciencedirect.com/science/article/pii/S0952197624014817>

References

1 Xu, J.; Wu, H.; Wang, J.; Long, M. Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy. *ICLR*, 2022. URL: https://openreview.net/forum?id=LzQQ89U1qm_. DOI: <https://doi.org/10.48550/arXiv.2110.02642>.

2 Tuli, S.; Casale, G.; Jennings, N. R. TranAD: Deep Transformer Networks for Anomaly Detection in Multivariate Time Series Data. *Proceedings of the VLDB Endowment*, 2022, 15(6), 1201–1214. URL: <https://vldb.org/pvldb/vol15/p1201-tuli.pdf>. DOI: <https://doi.org/10.14778/3514061.3514067>.

3 Schmidl, S.; Wenig, P.; Papenbrock, T. Anomaly Detection in Time Series: A Comprehensive Evaluation. *Proceedings of the VLDB Endowment*, 2022, 15(9), 1779–1797. URL: <https://www.vldb.org/pvldb/vol15/p1779-wenig.pdf>. DOI: <https://doi.org/10.14778/3538598.3538602>.

4 Kim, S.; Choi, K.; Choi, H.-S.; Lee, B.; Yoon, S. Towards a Rigorous Evaluation of Time-Series Anomaly Detection. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(7), 7194–7201. URL: <https://ojs.aaai.org/index.php/AAAI/article/view/20680>. DOI: <https://doi.org/10.1609/aaai.v36i7.20680>.

5 Paparrizos, J.; Kang, Y.; Boniol, P.; Tsay, R. S.; Palpanas, T.; Franklin, M. J. TSB-UAD: An End-to-End Benchmark Suite for Univariate Time-Series Anomaly Detection. *Proceedings of the VLDB Endowment*, 2022, 15(8), 1697–1711. URL: <https://www.vldb.org/pvldb/vol15/p1697-paparrizos.pdf>. DOI: <https://doi.org/10.14778/3529337.3529354>.

6 Paparrizos, J.; Boniol, P.; Palpanas, T.; Tsay, R. S.; Elmore, A. J.; Franklin, M. J. Volume Under the Surface: A New Accuracy Evaluation Measure for Time-Series Anomaly Detection. *Proceedings of the VLDB Endowment*, 2022, 15(11), 2774–2787. URL: <https://www.vldb.org/pvldb/vol15/p2774-paparrizos.pdf>. DOI: <https://doi.org/10.14778/3551793.3551830>.

7 Darban, Z. Z.; Webb, G. I.; Pan, S.; Aggarwal, C. C.; Salehi, M. Deep Learning for Time Series Anomaly Detection: A Survey. *ACM Computing Surveys*, 2024, 57(1), Article 15. URL: <https://dl.acm.org/doi/10.1145/3691338>. <https://doi.org/10.1145/3691338>.

8 Sørbo, S.; Ruocco, M. Navigating the Metric Maze: A Taxonomy of Evaluation Metrics for Anomaly Detection in Time Series. *Data Mining and Knowledge Discovery*, 2024, 38, 1027–1068. URL: <https://link.springer.com/article/10.1007/s10618-023-00988-8>. DOI: <https://doi.org/10.1007/s10618-023-00988-8>

9 Schmidl, S.; Naumann, F.; Papenbrock, T. AutoTSAD: Unsupervised Holistic Anomaly Detection for Time Series Data. *Proceedings of the VLDB Endowment*, 2024, 17(11), 2987–3002. URL: <https://www.vldb.org/pvldb/vol17/p2987-schmidl.pdf>. DOI: <https://doi.org/10.14778/3681954.3681978>.

10 Feng, A.; Varvarigos, A.; Panitsas, I.; Fernandez, D.; Wei, J.; Guo, Y.; Chen, J.; Maatouk, A.; Tassiulas, L.; Ying, R. TelecomTS: A Multi-Modal Observability Dataset for Time Series and Language Analysis. *arXiv*, 2025. URL: <https://arxiv.org/abs/2510.06063>; dataset URL: <https://huggingface.co/datasets/AliMaatouk/TelecomTS>. DOI: <https://doi.org/10.48550/arXiv.2510.06063>.

11. T. P. Dovzhenko, “Hybrid AWRED: Synergy of Adaptive Reconstruction and Topological Clustering for Anomaly Detection in Multimodal Data,” *Communication*, 2026, no. 1, pp. 80–88. DOI: 10.31673/2412-9070.2026.017405. URL: <https://con.duikt.edu.ua/index.php/communication/article/view/2965/2848>
12. T. P. Dovzhenko and O. V. Zinchenko, “Stability of Deep Intrusion Detection Models under Massive Cyberattacks: Stress Testing and Architectural Features of Hybrid AWRED,” *Telecommunication and Information Technologies*, 2026, no. 1, pp. 199–207. DOI: 10.31673/2412-4338.2026.019019. URL: <https://tit.duikt.edu.ua/index.php/telecommunication/article/view/2711/2558>
13. T. P. Dovzhenko, “Topological Anchoring and Adaptive Penalties: Hybrid AWRED Architecture for Defect Recognition in Corrupted Visual Data,” *Communication*, 2026, no. 2, pp. 62–71. DOI: 10.31673/2412-9070.2026.027603. URL: <https://con.duikt.edu.ua/index.php/communication/article/view/2988/2866>
14. T. P. Dovzhenko, “Robust Anomaly Detection in Time Series under Structural Distortions: Integration of the Hybrid AWRED v5 Method into Classical and Bidirectional LSTM Networks.”
15. Wu, H.; Hu, T.; Liu, Y.; Zhou, H.; Wang, J.; Long, M. TimesNet: Temporal 2D-Variation Modeling for General Time Series Analysis. *ICLR*, 2023. DOI: <https://doi.org/10.48550/arXiv.2210.02186>. URL: <https://arxiv.org/abs/2210.02186>.
16. Liu, Q.; Paparrizos, J. The Elephant in the Room: Towards A Reliable Time-Series Anomaly Detection Benchmark. *Advances in Neural Information Processing Systems 37 (NeurIPS 2024), Datasets and Benchmarks Track*, 2024. DOI: <https://doi.org/10.52202/079017-3437>. URL: https://proceedings.neurips.cc/paper_files/paper/2024/hash/c3f3c690b7a99fba16d0efd35cb83b2c-Abstract-Datasets_and_Benchmarks_Track.html.
17. Bordeau-Aubert, K.; Whatley, J.; Nadeau, S.; Glatard, T.; Jaumard, B. Classification of Anomalies in Telecommunication Network KPI Time Series. *arXiv*, 2023. DOI: <https://doi.org/10.48550/arXiv.2308.16279>. URL: <https://arxiv.org/abs/2308.16279>.
18. Wang, F.; Jiang, Y.; Zhang, R.; Wei, A.; Pang, X.; Xie, J. A Survey of Deep Anomaly Detection in Multivariate Time Series: Taxonomy, Applications, and Directions. *Sensors*, 2025, 25(1), 190. DOI: <https://doi.org/10.3390/s25010190>. URL: <https://www.mdpi.com/1424-8220/25/1/190>.
19. Liu, J.; Gu, W.; Chen, Z.; Li, Y.; Su, Y.; Lyu, M. R. MTAD: Tools and Benchmarks for Multivariate Time Series Anomaly Detection. *arXiv*, 2024. DOI: <https://doi.org/10.48550/arXiv.2401.06175>. URL: <https://arxiv.org/abs/2401.06175>.
20. Correia, L.; Goos, J.-C.; Klein, P.; Bäck, T.; Kononova, A. V. Online Model-Based Anomaly Detection in Multivariate Time Series: Taxonomy, Survey, Research Challenges and Future Directions. *Engineering Applications of Artificial Intelligence*, 2024, 138, 109323. DOI: <https://doi.org/10.1016/j.engappai.2024.109323>. URL: <https://www.sciencedirect.com/science/article/pii/S0952197624014817>

Надійшла до редакції: 28.02.26

Прийнята до друку: 12.06.26

Опубліковано: 30.06.26