

DOI <https://doi.org/10.32782/2078-0877-2026-26-1-8>

УДК 004.8

І. С. Узун, аспірант

М. В. Лобачев, канд. техн. наук, проф.

Національний університет «Одеська політехніка»

e-mail: uzun.i.s@op.edu.ua

ORCID: 0000-0001-6619-4862

ORCID: 0000-0002-4859-304X

БЮДЖЕТОВАНА ДРЕЙФ-ІНІЦІЙОВАНА МІКРОАДАПТАЦІЯ ДЛЯ ПОТОКОВОГО ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ ЗА УМОВАМИ ЗМІН РЕЛЕВАНТНОСТІ МОДАЛЬНОСТЕЙ

Анотація. У потокових інтелектуальних системах підтримки прийняття рішень прогнозування мульти-модальних часових рядів виконується каузально та за обмежених ресурсів, тому повне перенавчання після кожної зміни середовища є надмірним. Розглянуто дрейф відносної релевантності модальностей і подієво-ініційовану бюджетовану мікроадаптацію, що оновлює лише малу голову злиття $\theta = (a, b, c)$. Подію дрейфу визначають за сигналом релевантності на ковзному вікні (із згладженням і перевіркою персистентності), після чого запускається інкрементне оновлення. Показано, що в постдрейфових сегментах точність зростає до MAE = 0.66 ± 0.01 проти 0.70 ± 0.01 та RMSE = 0.84 ± 0.01 проти 0.90 ± 0.01 , а також середній час відновлення становить 157 кроків; у середньому виконуються 3 оновлення.

Ключові слова: машинне навчання, аналіз даних, інформаційні системи, системи підтримки прийняття рішень, багатоканальні дані, нестаціонарність, злиття даних, подієво оновлення параметрів, інкрементне навчання, ресурсні обмеження.

Постановка проблеми. У практичних потокових інтелектуальних системах підтримки прийняття рішень (СППР) мультимодальні часові ряди формуються гетерогенними джерелами (сенсори, інформаційні канали) і прогнозуються каузально, тобто з використанням лише доступної історії. У таких умовах нестаціонарність проявляється, зокрема, як концептуальний дрейф і призводить до деградації якості прогнозування. Окремо важливим є дрейф, за якого змінюється не стільки розподіл ознак модальностей, скільки їхня *відносна релевантність* щодо цільової змінної. Повне перенавчання моделі після кожної зміни середовища часто суперечить вимогам малої латентності та обмежених ресурсів, тому актуальною є подієва адаптація з прозорим обліком витрат.

Аналіз останніх досліджень. Проблематику адаптації до концептуального дрейфу (concept drift) у потокових постановках систематизовано в оглядових працях, де узагальнено типи дрейфу (раптовий, поступовий, повторюваний), класи стратегій адаптації та підходи до оцінювання якості у потоках [1; 2]. Як приклади практичних механізмів виявлення змін і керування масштабом історії розглядають адаптивне ковзне вікно зі статистичними гарантіями для потоків [11]. Динамічне перезважування та заміну експертів у ансамблях для дрейфових концепцій описано у [13]. Для мультимодальних моделей принциповим є коректне злиття модальностей та керування внеском каналів: огляд методів data fusion і типових викликів (несумісність масштабів, шум, пропуски) узагальнено в [3], а таксономію мультимодального машинного навчання та типові сценарії злиття модальностей подано в [4]. У прикладних системах з потоковими даними актуальними залишаються питання моніторингу якості та організації контрольних конвеєрів у режимі експлуатації: підходи до виявлення дрейфу/аномалій як частини конвеєра валідації даних для часових рядів описано в [6], а приклад адаптивного ансамблевого підходу для еволюціонуючих потоків даних із механізмами оновлення за зміни розподілів продемонстровано в [12]. Порівняння підходів до прогнозування часових рядів на великих наборах

даних узагальнюється в результатах бенчмарків: у масштабному порівнянні методів підкреслено роль ансамблевих та гібридних схем як сильного базового рівня [14]. Українські прикладні роботи ілюструють різні домени та постановки: прогнозування пікових навантажень енергосистеми [7], прогноз температури поверхні Землі [8], оцінювання моделей для фінансових часових рядів за турбулентності [9], інформаційні системи для класифікації стану дорожнього покриття з використанням методів машинного навчання [15], прогнозування валютного курсу з використанням градієнтного бустингу [16], гібридну схему прогнозування базової інфляції на основі поєднання статистичної та нейромережевої моделей [17], а також використання нейромереж у задачах підтримки прийняття рішень [18]. Окремі прикладні роботи також розглядають адаптацію процедур у потоках за дрейфу концепції в умовах ресурсних обмежень, зокрема для політик безпеки даних [10]. Разом із тим для сценарію *дрейфу релевантності модальностей* доцільним є підхід, у якому адаптація запускається подієво та обмежується малим бюджетом оновлення, що забезпечує керований компроміс «якість–вартість».

Формулювання цілей статті. Метою роботи є опис і обґрунтування подієво-ініційованої бюджетованої мікроадаптації для потокового мультимодального прогнозування у випадку стійкої зміни релевантності модальностей, а також представлення ключових чисельних результатів експериментальної перевірки.

Формулювання наукового результату. Удосконалено метод дрейф-ініційованої бюджетованої мікроадаптації мультимодальної моделі прогнозування, у якому подія дрейфу визначається як стійка зміна релевантності модальностей, а оновлення виконується лише для малої адаптивної голови у фіксованому бюджеті зразків/кроків.

Постановка та позначення. Розглядається потік спостережень $\{(\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, y_t)\}_{t \in \mathbb{N}}$, де $\mathbf{x}_t^{(m)}$ – ознаки модальності $m \in \{1, 2\}$, а y_t – цільове значення для однокрокового прогнозування. Нехай базові модальні предиктори формують прогнози $\hat{y}_t^{(1)}$ та $\hat{y}_t^{(2)}$. Мікроадаптація виконується в «голові» злиття, що має малу кількість параметрів:

$$\hat{y}_t = a\hat{y}_t^{(1)} + b\hat{y}_t^{(2)} + c, \quad (1)$$

де $\theta = (a, b, c)$ – параметри, які допускається оновлювати в онлайн-режимі.

Подієвий тригер за дрейфу релевантності модальностей. Дрейф інтерпретується як персистентна зміна відносної релевантності модальностей, тобто як стійка зміна того, яка з модальностей має більший внесок у прогнозування цілі. Діагностика дрейфу виконується через зміну оптимальної ваги злиття на ковзному вікні, а після підтвердженої події дрейфу запускається подієва мікроадаптація. Для керованості частоти запусків у процедурі використовуються бюджети (за кількістю зразків/кроків) та період «охолодження», що зменшує ризик каскадних повторних спрацювань у шумних ділянках.

Схема методу. Для подання логіки «сигнал релевантності → подія дрейфу → бюджетоване оновлення θ » наведено узагальнену схему (рис. 1).

Метрики якості. Якість прогнозування оцінюється метриками MAE та RMSE:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|, \quad \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}. \quad (2)$$

Ключовий чисельний результат. Показано, що дрейф-ініційована бюджетована мікроадаптація суттєво покращує точність у постдрейфових сегментах стосовно відсутності адаптації (MAE = 0,66 ± 0,01 проти 0,70 ± 0,01, RMSE = 0,84 ± 0,01 проти 0,90 ± 0,01) та забезпечує найшвидше середнє відновлення якості після дрейфу (157 кроків проти 242 для періодичної стратегії та 800 без адаптації) за малого бюджету оновлень.




Рис. 1. Схема подієво-ініційованої бюджетованої мікроадаптації за дрейфу релевантності модальностей

Таблиця 1

Постдрейфова похибка прогнозування (MAE, RMSE) з подієвою мікроадаптацією та без адаптації (10 сідів, $\mu \pm \sigma$)

Сценарій (постдрейфові сегменти)	MAE	RMSE
Без адаптації	$0,70 \pm 0,01$	$0,90 \pm 0,01$
Подієва бюджетована мікроадаптація	$0,66 \pm 0,01$	$0,84 \pm 0,01$

Порівняння якості прогнозування за методами. На рис. 2 наведено стовпчикову діаграму MAE ($\mu \pm \sigma$) для п'яти порівнюваних стратегій на постдрейфових сегментах.




Рис. 2. Постдрейфова якість прогнозування: MAE за методами

Компромiс «якiсть–вартiсть» за бюджетом оновлень. На рис. 3 подано дiаграму Парето «якiсть (MAE) проти вартостi (загальна кiлькiсть оновлених параметрiв)».

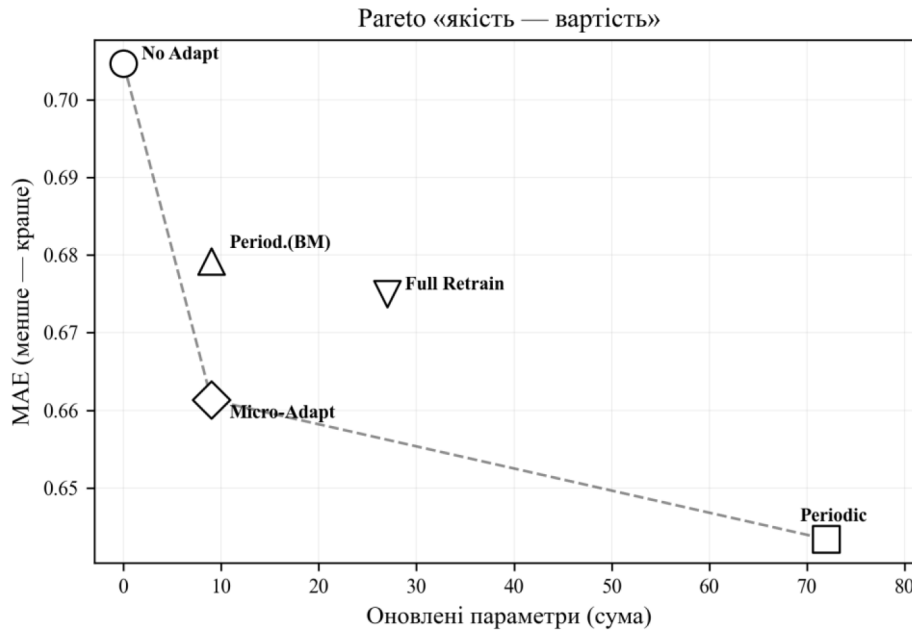


Рис. 3. Парето «якiсть–вартiсть»: MAE проти сумарної кiлькостi оновлених параметрiв

Компромiс «якiсть–вартiсть» i час вiдновлення. Оскiльки мiкроадаптацiя запускається подiєво, практична ефективнiсть визначається не лише рiвнем похибки, а й тим, наскiльки швидко система повертається до прийнятної якостi та який бюджет оновлення потрібен для цього. У проведеному експериментi оновлення виконується лише для малої голови $\theta = (a, b, c)$ (три параметри), а середнiй час вiдновлення якостi пiсля дрейфу та вартiсть оновлень наведено в табл. 2.

Таблиця 2

Компромiс «якiсть–вартiсть»: середнiй час вiдновлення пiсля дрейфу та вартiсть оновлень (10 сiдiв)

Стратегiя	Середнє вiдновлення, кроки	Сума оновлень	Оновлення (у середньому)
Без адаптацiї	800	0	0
Перiодичне оновлення	242	72	24
Подiєва бюджетована мiкроадаптацiя	157	9	3

Динамiка вiдновлення навколо подiй дрейфу. На рис. 4 наведено реальнi траєкторiї згладженої похибки з позначенням подiй дрейфу ($seed = 42$) для трьох стратегiй.

Дiагностика тригерiв. Оскiльки адаптацiя є подiєвою, важливо роздiляти три аспекти: (i) якiсть сигналу релевантностi (наскiльки стабiльно вiн вiдображає змiну внеску модальностей), (ii) якiсть правила спрацювання (персистентнiсть, «охолодження», компромiс мiж пропущеними та хибними подiями), (iii) ефект самого оновлення голови на постдрейфову похибку та швидкiсть вiдновлення. На рис. 5 наведено дiагностичний таймлайн iз сигналом релевантностi, моментами спрацювання та траєкторiєю похибки.

Абляцiйний аналiз. На рис. 6 подано результати абляцiйного аналiзу компонентiв запропонованого методу.

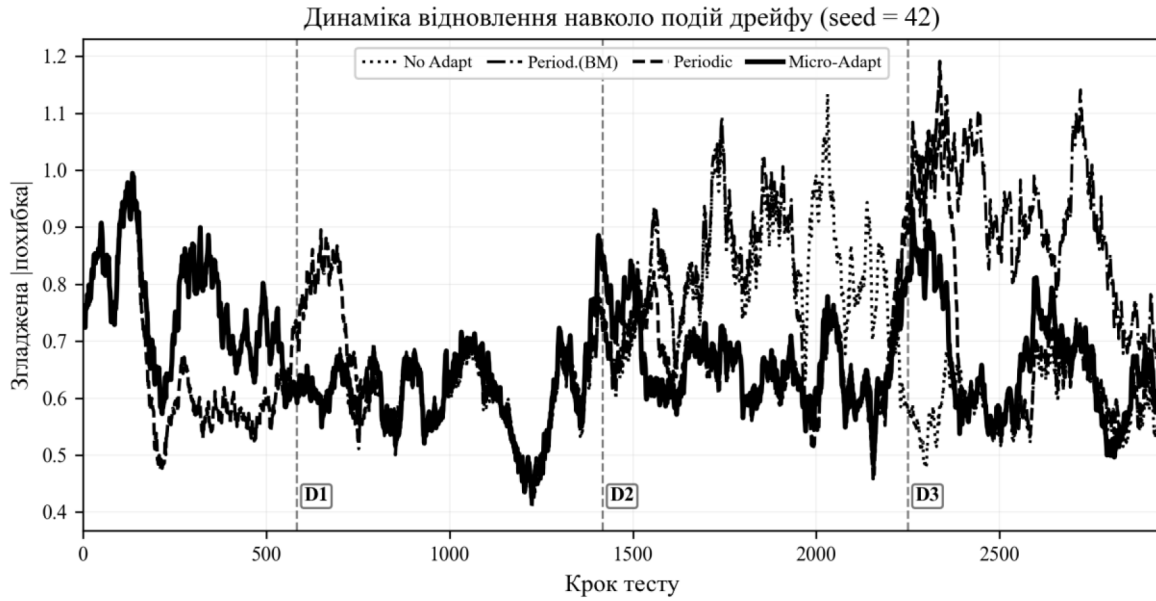


Рис. 4. Динаміка відновлення навколо подій дрейфу (seed = 42)

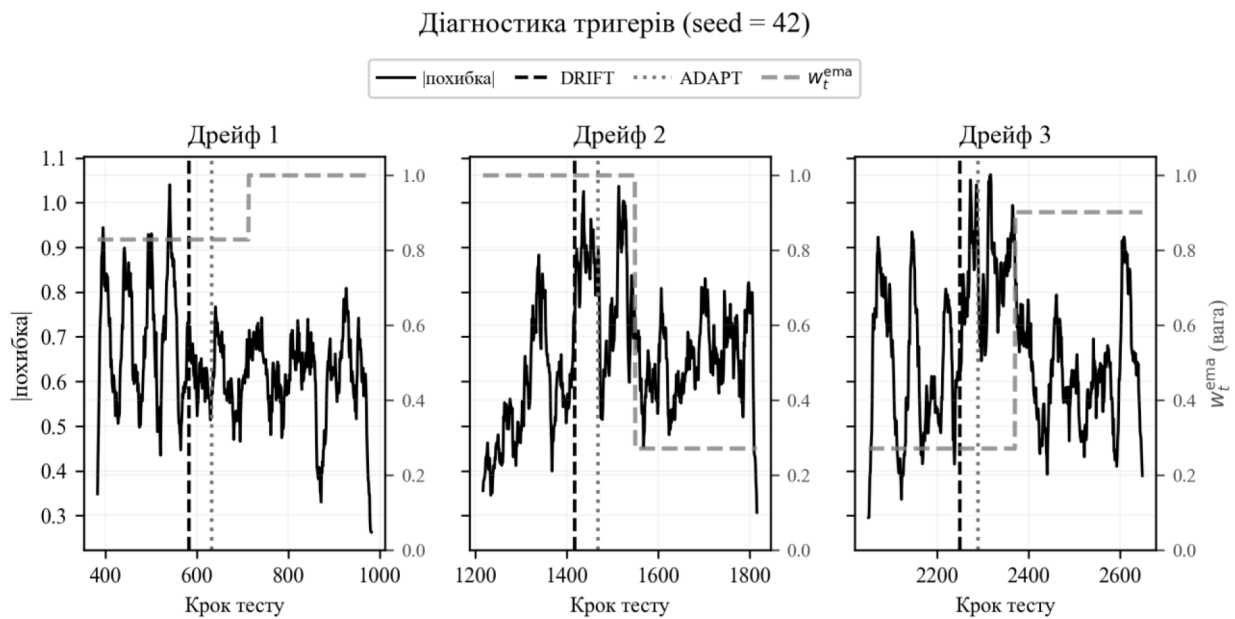


Рис. 5. Діагностика тригерів: сигнал релевантності, події дрейфу/спрацювання та динаміка відновлення якості (seed = 42)

Обмеження. Інтерпретація результатів має враховувати такі обмеження. По-перше, подієва мікроадаптація обґрунтована насамперед для дрейфів, що змінюють *відносну релевантність* модальностей; для інших типів дрейфу можуть знадобитися важчі стратегії. По-друге, на практиці доступність фактичного y_t у потоці та затримка його надходження впливають на можливість оперативного оновлення. По-третє, на рівні детектора можливі компроміси між чутливістю та стабільністю: надто «агресивні» правила можуть збільшувати кількість хибних спрацювань, тоді як надто консервативні – збільшувати затримку реакції. У статті ці аспекти розглядаються як керовані через бюджети та діагностичні журнали подій.

Висновки. Розглянуто сценарій дрейфу релевантності модальностей у потоковому мульти-модальному прогнозуванні та подієво-ініційовану бюджетовану мікроадаптацію, що оновлює




Рис. 6. Абляційний аналіз компонентів мікроадаптації (MAE, 10 сідів)

лише малу голову злиття з трьома параметрами. Наведено формулювання наукового результату та ключовий чисельний результат експериментальної перевірки, який демонструє покращення постдрейфової якості та швидке відновлення за помірної вартості оновлень. Перспективою подальших досліджень є розширення емпіричної валідації на інші прикладні домени та уточнення діагностики тригерів у довготривалих потоках.

Список використаних джерел

1. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A Survey on Concept Drift Adaptation. *ACM Computing Surveys*. 2014. Vol. 46(4). Article 44. DOI: <https://doi.org/10.1145/2523813>
2. Lu J., Liu A., Dong F., Gu F., Gama J., Zhang G. Learning under concept drift: a review. *IEEE Transactions on Knowledge and Data Engineering*. 2019. Vol. 31(12). P. 2346–2363. DOI: <https://doi.org/10.1109/TKDE.2018.2876857>
3. Lahat D., Adali T., Jutten C. Multimodal Data Fusion: An Overview of Methods, Challenges, and Prospects. *Proceedings of the IEEE*. 2015. Vol. 103(9). P. 1449–1477. DOI: <https://doi.org/10.1109/JPROC.2015.2460697>
4. Baltrušaitis T., Ahuja C., Morency L.-P. Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2019. Vol. 41(2). P. 423–443. DOI: <https://doi.org/10.1109/TPAMI.2018.2798607>
5. Hyndman R. J., Khandakar Y. Automatic Time Series Forecasting: The *forecast* Package for R. *Journal of Statistical Software*. 2008. Vol. 27(3). DOI: <https://doi.org/10.18637/jss.v027.i03>. URL: <https://www.jstatsoft.org/article/view/v027i03>
6. Boyko N., Kovalchuk R. Data Update Algorithms in the Machine Learning System. *Computer Systems and Information Technologies*. 2023. No. 1. P. 6–13. DOI: <https://doi.org/10.31891/csit-2023-1-1>
7. Kholiavka Y., Parfenenko Y. Forecasting Peak Load on the Power Grid. *Computer Systems and Information Technologies*. 2023. No. 3. P. 12–22. DOI: <https://doi.org/10.31891/csit-2023-3-2>
8. Hovorushchenko T., Alekseiko V., Shvaiko V., Ilchyshyna J., Kuzmin A. Information System for Earth's Surface Temperature Forecasting Using Machine Learning Technologies. *Computer Systems and Information Technologies*. 2024. No. 4. P. 51–58. DOI: <https://doi.org/10.31891/csit-2024-4-7>



9. Pastukh O., Petrov Y. Efficiency Analysis of Financial Time Series Forecasting Models under Market Turbulence Conditions. *Computer Systems and Information Technologies*. 2025. No. 3. P. 128–134. DOI: <https://doi.org/10.31891/csit-2025-3-13>
10. Vizhevskiy P., Savenko O. Evolutionary Adaptation of DLP Policies under Concept Drift in Streaming Data. *Збірник наукових праць*. 2025. Issue 12(43), Part II. P. 9–19. DOI: [https://doi.org/10.32515/2664-262X.2025.12\(43\).2.9-19](https://doi.org/10.32515/2664-262X.2025.12(43).2.9-19)
11. Bifet A., Gavaldà R. Learning from Time-Changing Data with Adaptive Windowing. *Proceedings of the 2007 SIAM International Conference on Data Mining*. 2007. P. 443–448. DOI: <https://doi.org/10.1137/1.9781611972771.42>
12. Gomes H. M., Bifet A., Read J., Barddal J.P., Enembreck F., Pfahringer B., Holmes G., Abdesslem T. Adaptive Random Forests for Evolving Data Stream Classification. *Machine Learning*. 2017. Vol. 106. P. 1469–1495. DOI: <https://doi.org/10.1007/s10994-017-5642-8>
13. Kolter J. Z., Maloof M. A. Dynamic Weighted Majority: An Ensemble Method for Drifting Concepts. *Journal of Machine Learning Research*. 2007. Vol. 8. P. 2755–2790. URL: <https://jmlr.org/papers/v8/kolter07a.html>
14. Makridakis S., Spiliotis E., Assimakopoulos V. The M4 Competition: Results, Findings, Conclusion and Way Forward. *International Journal of Forecasting*. 2018. Vol. 34(4). P. 802–808. DOI: <https://doi.org/10.1016/j.ijforecast.2018.06.001>
15. Mochurad L., Ilkiv A., Kravchenko O. A New Information System for Road Surface Condition Classification Using Machine Learning Methods and Parallel Calculation. *Computer Systems and Information Technologies*. 2023. No. 1. P. 53–61. DOI: <https://doi.org/10.31891/csit-2023-1-7>
16. Pryimak V., Bartkiv B., Holubnyk O. Forecasting the Exchange Rate of the Ukrainian Hryvnia Using Machine Learning Methods. *Computer Systems and Information Technologies*. 2023. No. 1. P. 75–83. DOI: <https://doi.org/10.31891/csit-2023-1-10>
17. Krukovets D. Exploring an LSTM–SARIMA Routine for Core Inflation Forecasting. *Technology Audit and Production Reserves*. 2024. Vol. 2. No. 2(76). P. 6–12. DOI: <https://doi.org/10.15587/2706-5448.2024.301209>
18. Savchuk O. V., Ladanyuk A. P. Research of Possibilities of Using Neural Networks in the Decision Support System. *Eastern-European Journal of Enterprise Technologies*. 2015. Vol. 4. No. 4(76). P. 15–19. DOI: <https://doi.org/10.15587/1729-4061.2015.47692>

Дата першого надходження статті до видання: 23.01.2026

Дата прийняття статті до друку після рецензування: 14.02.2026

Дата публікації (оприлюднення) статті: 28.04.2026

Стаття поширюється на умовах ліцензії відкритого доступу (CC BY 4.0)



I. Uzun, M. Lobachev

National University Odesa Polytechnic

BUDGETED DRIFT-INITIATED MICRO-ADAPTATION FOR STREAMING TIME-SERIES FORECASTING UNDER MODALITY-RELEVANCE CHANGES

Summary

Streaming multimodal time-series forecasting for decision support must operate causally under tight latency and update budgets, while the relative usefulness of modalities can change over time. This work considers modality-relevance drift as a persistent change in which modality contributes more to the target, and applies an event-triggered budgeted micro-adaptation mechanism that updates only a small fusion head $\theta = (a, b, c)$. A relevance signal is estimated on a sliding window and smoothed to suppress noise; a drift event is confirmed via a persistence rule and a cooldown period to avoid cascaded triggers. When a drift event is confirmed, a short online update is executed using a fixed step/sample budget, and the system logs adaptation events and costs (number of updates and updated parameters) to make the quality–cost trade-off auditable. The approach is evaluated in a controlled streaming setup with two modalities and repeated runs (10 seeds). In post-drift segments, micro-adaptation improves accuracy to



MAE = 0.66 ± 0.01 versus 0.70 ± 0.01 without adaptation, and RMSE = 0.84 ± 0.01 versus 0.90 ± 0.01 . The mean recovery time after drift is 157 steps, compared with 242 for periodic updating and 800 without adaptation. The update budget remains small: on average 3 micro-updates are executed, corresponding to 9 updated parameters in total, whereas periodic updating requires 24 updates (72 parameters). Diagnostic timelines and a Pareto view of MAE versus total updated parameters summarize the trigger behavior and the controllable trade-off between accuracy and update cost. An ablation study quantifies the contribution of the trigger components and budgeted updating to MAE across methods, supporting robust tuning decisions. Overall, event-triggered micro-adaptation provides a resource-efficient way to maintain streaming forecasting quality under modality-relevance changes.

Keywords: machine learning, data analysis, information systems, decision support systems, multimodal time series, concept drift, modality relevance, event-triggered adaptation, budgeted updating, online forecasting.