

І. С. УЗУН

аспірант кафедри штучного інтелекту та аналізу даних
Інститут штучного інтелекту та робототехніки
Національного університету «Одеська політехніка»
ORCID: 0000-0001-6619-4862

М. В. ЛОБАЧЕВ

кандидат технічних наук,
професор кафедри штучного інтелекту та аналізу даних
Інститут штучного інтелекту та робототехніки
Національного університету «Одеська політехніка»
ORCID: 0000-0002-4859-304X

БЕЗПЕЧНЕ НАДІЙНІСНО-АДАПТИВНЕ ЗЛИТТЯ МОДАЛЬНОСТЕЙ ДЛЯ ПОТОКОВОГО ПРОГНОЗУВАННЯ МУЛЬТИМОДАЛЬНИХ ЧАСОВИХ РЯДІВ ЗА ТИМЧАСОВОЇ ДЕГРАДАЦІЇ ДАНИХ

Потокові системи підтримки прийняття рішень працюють каузально та за обмежень малої латентності, тому мультимодальні часові ряди мають аналізуватися онлайн. У реальних конвеєрах окремі джерела даних тимчасово деградують (пропуски, підвищений шум, масштабні зсуви), через що статичні стратегії злиття стають нестійкими: деградована модальність продовжує впливати на прогноз, а будь-яке додаткове керування ризикує погіршити якість у сегментах без деградації. У статті розглянуто метод надійнісно-адаптивного динамічного злиття модальностей для потокового прогнозування, у якому онлайн-оцінки надійності модальностей використовуються як керувальний сигнал для переважування внеску модальних предикторів зі згладжуванням, а безпечний «чистий режим» реалізовано через *clean gate*: у чистих вікнах вихід збігається з сильним базисом раннього злиття, що виключає регресію якості без деградації. Ефективність оцінено в потоковому протоколі передпослідовного оцінювання (*prequential*) на контрольованих потоках із детерміновано заданими ін'єкціями деградацій та на реальних даних *UCI Appliances Energy Prediction*. Показано, що в *clean*-режимі метод узгоджується з базисом раннього злиття ($MAE = 0,56 \pm 0,13$, $RMSE = 0,70 \pm 0,17$), у режимі чергування пропусків зменшує похибку ($MAE = 0,64 \pm 0,11$ проти $0,68 \pm 0,08$), демонструє вищу робастність при «*missing level*» = 0,9 ($MAE = 0,64$ проти 0,70) та на деградованих сегментах *UCI Appliances* досягає $MAE = 63,69 \pm 5,82$ проти $381,91 \pm 95,22$. Надійність модальності трактується як каузальна ймовірнісна оцінка її поточного недеградованого стану та використовується як керувальний інтерфейс для злиття в потоці. Отримані результати сформовано як частину цілісного онлайн-конвеєра, що задовольняє вимоги каузальності, малої латентності та обмежених обчислювальних ресурсів у потокових системах підтримки прийняття рішень. Латентність покрового інференсу залишається мікросекундною (у середньому $10,07 \mu s$), що робить підхід придатним для низьколатентних потокових конвеєрів.

Ключові слова: машинне навчання, аналіз даних, інформаційні системи, системи підтримки прийняття рішень, мультимодальні часові ряди, потокове прогнозування, деградація даних, надійність модальності, динамічне злиття, *clean gate*.

I. S. UZUN

Postgraduate Student at the Department of Artificial Intelligence
and Data Analysis
Institute of Artificial Intelligence and Robotics
of Odesa Polytechnic National University
ORCID: 0000-0001-6619-4862

M. V. LOBACHEV

Ph.D., Professor at the Department of Artificial Intelligence and Data Analysis
Institute of Artificial Intelligence and Robotics
of Odesa Polytechnic National University
ORCID: 0000-0002-4859-304X



SAFE RELIABILITY-ADAPTIVE MODALITY FUSION FOR STREAMING FORECASTING OF MULTIMODAL TIME SERIES UNDER TEMPORARY DATA DEGRADATION

Streaming decision support systems operate causally and under low-latency constraints; therefore, multimodal time series must be analyzed online. In real pipelines, individual data sources temporarily degrade (missing values, elevated noise, and scale shifts), making static fusion strategies unstable: a degraded modality continues to affect the forecast, while any additional control risks harming quality in segments without degradation. This paper considers a reliability-adaptive dynamic modality-fusion method for streaming forecasting, where online modality-reliability estimates are used as a control signal for reweighting modal predictors with smoothing, and a safe “clean regime” is implemented via a clean gate: in clean windows, the output matches a strong early-fusion baseline, which excludes quality regression in degradation-free segments. Effectiveness is evaluated in the prequential streaming protocol on controlled streams with deterministic degradation injections and on real data (UCI Appliances Energy Prediction). It is shown that, in the clean regime, the method matches the early-fusion baseline ($MAE = 0.56 \pm 0.13$, $RMSE = 0.70 \pm 0.17$); under alternating missingness it reduces error ($MAE = 0.64 \pm 0.11$ versus 0.68 ± 0.08); it demonstrates higher robustness at «missing_level» = 0.9 (MAE 0.64 versus 0.70); and on degraded UCI Appliances segments it achieves $MAE = 63.69 \pm 5.82$ versus 381.91 ± 95.22 . Modality reliability is treated as a causal probabilistic estimate of being in a non-degraded state and is used as a control interface for streaming fusion. The results are positioned as part of a coherent online pipeline that satisfies causality, low latency, and bounded computational resources in streaming decision support. Per-step inference latency remains in the microsecond range (on average $10.07 \mu s$), which makes the approach applicable to low-latency streaming decision support.

Key words: machine learning, data analysis, information systems, decision support systems, multimodal time series, streaming forecasting, data degradation, modality reliability, dynamic fusion, clean gate.

Постановка проблеми

У поточних інтелектуальних системах підтримки прийняття рішень рішення мають прийматися каузально, тобто на кроці t використовуються лише дані, доступні до моменту t , а латентність є операційним обмеженням. Для мультимодальних часових рядів додатково характерні тимчасові деградації окремих модальностей (пропуски, шум, масштабні зсуви), які можуть імітувати нестационарність або маскувати її прояви. За відсутності явного сигналу якості деградація проблемної модальності призводить до зростання похибки саме в тих сегментах, де потрібна робастність. Водночас будь-яке «агресивне» керування злиттям може спричинити регресію якості в чистих ділянках, де керування не потрібне. Отже, потрібен метод потокового злиття, який одночасно задовольняє дві вимоги: (i) не погіршує якість у режимі без деградацій порівняно зі сильним базисом раннього злиття та (ii) зменшує похибку в сегментах деградації, зберігаючи низьку латентність.

Аналіз останніх досліджень і публікацій

Мультимодальне машинне навчання та методи злиття даних описані в оглядових працях, які формують базис для постановки задачі робастного злиття в умовах неоднакової якості джерел і неповноти спостережень [1, 2, 7, 9–11]. Зокрема, запропоновано таксономію мультимодального ML із виокремленням задач представлення, узгодження та злиття модальностей [1], систематизовано підходи до data fusion та обговорено виклики різномірності, невизначеності й конфліктності сенсорних даних [2], а також узагальнено архітектури deep multimodal learning і тренди їх застосування [7]. У мультисенсорному/мультимедіа контексті підкреслено практичну важливість неповноти спостережень, конфліктності даних і варіативної надійності модальностей [9–11]. Еволюцію технологій підтримки прийняття рішень і перехід до інтеграції зі сховищами даних, багатовимірною аналітикою та інтелектуальним аналізом даних систематизовано [14]. Для потокових даних ключовою є коректна (каузальна) логіка оцінювання; prequential-підхід формалізує послідовність «спочатку прогноз – потім спостереження» і тим самим узгоджується з потоковою постановкою [3]. Нестационарність потоків у прикладних задачах часто пов'язують із concept drift; узагальнено адаптаційні стратегії та протоколи оцінювання, а також деталізовано типи дрейфу й способи його кількісної характеристизації [15, 16]. Проблеми пропусків і механізми missingness класично розглядають у статистиці неповних даних, зокрема через припущення MCAR/MAR/MNAR та їх наслідки для оцінювання [18]. Для багатовимірних часових рядів показано, що маски пропусків і часові інтервали можуть інтегруватися в рекурентні моделі, покращуючи прогнозування за неповноти даних [17]. Для оцінювання точності прогнозування у часових рядах стандартними метриками є MAE та RMSE; проаналізовано їхні властивості та застереження щодо інтерпретації при порівнянні методів [4]. У прикладних постановках потокового прогнозування важливо спиратися на відтворювані реальні дані; описано Appliances Energy Prediction та наведено стандартизований доступ до наборів даних через репозиторій UCI [5, 6].

Оскільки застосовність потокового методу визначається не лише точністю, а і часовими характеристиками, важливо дотримуватися дисципліни експериментального дизайну та коректних вимірювань продуктивності; відповідні практичні принципи систематизовано в класичній монографії з аналізу продуктивності комп'ютерних систем [8].

Формулювання мети дослідження

Метою є представлення та узагальнення методу надійнісно-адаптивного динамічного злиття для потокового прогнозування мультимодальних часових рядів за тимчасової деградації модальностей із виконанням вимоги «не нашкодь» у чистому режимі, а також відтворення ключових числових результатів його експериментальної перевірки у потоковому prequential-протоколі.

Викладення основного матеріалу дослідження

Надійність модальності як керувальний інтерфейс. У розглянутій постановці надійність модальності трактується як каузальна шкала $r_i^{(m)} \in [0,1]$, що інтерпретується як ймовірність перебування джерела в недеградованому режимі та виступає керувальним сигналом для злиття в потоці. Далі ці оцінки використовуються для переважування внеску модальних предикторів без порушення каузальності.

Безпечне надійнісно-адаптивне злиття з clean gate. Ключовий дизайн методу полягає у поєднанні двох вимог: у режимі без деградацій метод не повинен програвати сильному базису раннього злиття, тоді як у деградованих сегментах ваги мають зміщуватися в бік більш надійної модальності. Це реалізується через (i) правило безпеки «чистого режиму» (clean gate), (ii) перетворення $r_i^{(m)}$ у ваги злиття та (iii) експоненційне згладжування керування для стабільності. Переважування можна інтерпретувати як кероване комбінування предикторів: у mixture-of-experts використовується механізм «gating» для вибору/зважування експертів [12], тоді як у комбінуванні класифікаторів формалізовано правила агрегації рішень та їх зв'язок із апостеріорними ймовірностями [13]; у цій роботі ваги керуються оцінками надійності та обмежуються правилом безпеки у чистих вікнах.

Наукова новизна. Запропоновано безпечне керування злиттям у потоковому режимі на основі онлайн-оцінок надійності модальностей: у чистих вікнах прогноз примусово збігається з базисом раннього злиття, а за деградації ваги автоматично зміщуються на користь надійнішої модальності.

Експериментальна перевірка та результати. Експериментальна перевірка виконана в потоковому протоколі передпослідовного оцінювання (prequential) на контрольованих потоках із детерміновано заданими ін'єкціями деградацій та на реальних даних UCI Appliances Energy Prediction. Результати подані за метриками MAE/RMSE і включають оцінювання якості у clean-режимі, у стрес-режимах чергування деградацій та в деградованих сегментах реальних даних; окремо наведено мікровимірювання латентності покровоного інференсу.

У clean-режимі запропонований метод узгоджується з сильним базисом раннього злиття ($MAE = 0,56 \pm 0,13$, $RMSE = 0,70 \pm 0,17$), а у режимах чергування деградацій зменшує похибку (наприклад, для чергування пропусків $MAE = 0,64 \pm 0,11$ проти $0,68 \pm 0,08$ для раннього злиття) та демонструє вищу робастність при «missing_level» = 0,9 ($MAE = 0,64$ проти $0,70$). На реальних даних UCI Appliances у деградованих сегментах запропонований метод досягає $MAE = 63,69 \pm 5,82$ проти $381,91 \pm 95,22$ для раннього злиття за збереження конкурентної якості на чистих сегментах. Латентність зростає відносно найпростішого злиття, але залишається мікросекундною (у середньому $10,07 \mu s$).

Таблиця 1

Бенчмарк: clean-режим і деградації

Умова	Метрика	Раннє злиття	Надійнісно-адаптивне злиття
Clean-режим (без деградацій)	MAE	$0,56 \pm 0,13$	$0,56 \pm 0,13$
Clean-режим (без деградацій)	RMSE	$0,70 \pm 0,17$	$0,70 \pm 0,17$
Чергування пропусків	MAE	$0,68 \pm 0,08$	$0,64 \pm 0,11$
«missing_level» = 0,9 (робастність)	MAE	0,70	0,64

Обмеження та межі застосовності. Межі застосовності зумовлені тим, що: сигнали деградації є проксі-ознаками і не гарантують однаково якісного розділення «надійна/ненадійна» для всіх доменів (зокрема для деградацій типу систематичного зсуву); компоненти, що використовують похибку, припускають доступність фактичного y_t у потоці з допустимою затримкою, а у сценаріях із відкладеною розміткою потребують використання затриманих або альтернативних проксі-сигналів; зовнішня валідність обмежена набором реальних даних, а абсолютні значення метрик і латентності залежать від середовища виконання, тому їх слід інтерпретувати як орієнтир щодо порядків величин і відносних відмінностей.

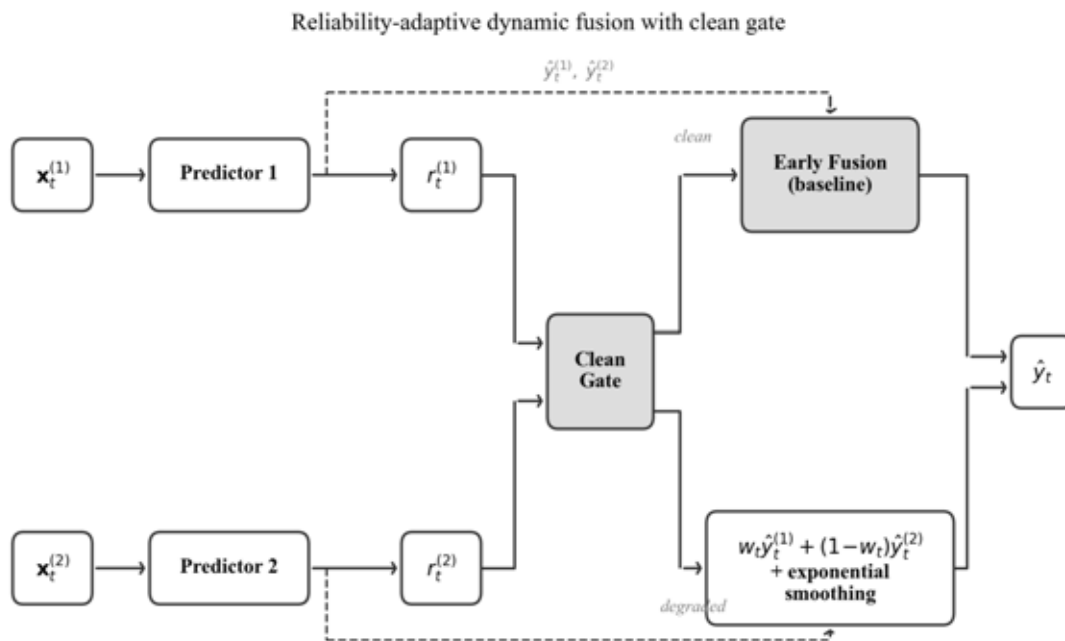


Рис. 1. Схема безпечного надійнісно-адаптивного злиття з clean gate у потоковому прогнозуванні

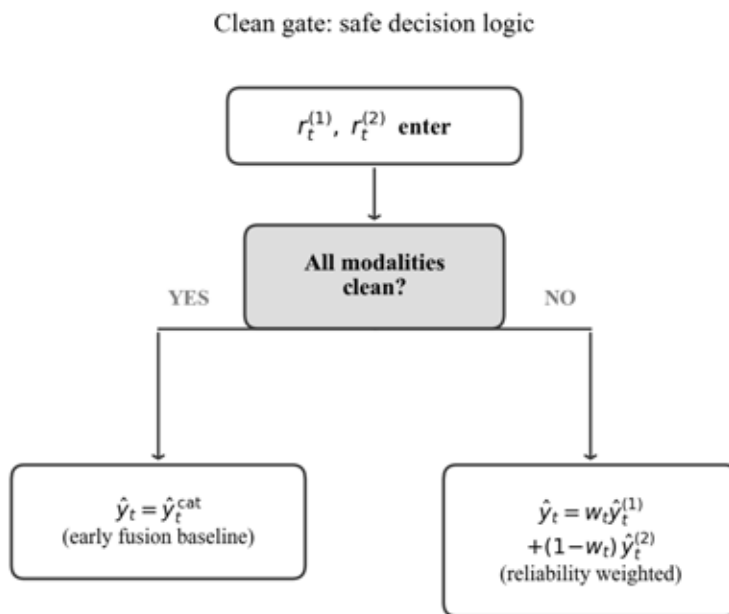


Рис. 2. Логіка безпечного перемикання clean gate: у чистому режимі вихід збігається з сильним базисом раннього злиття

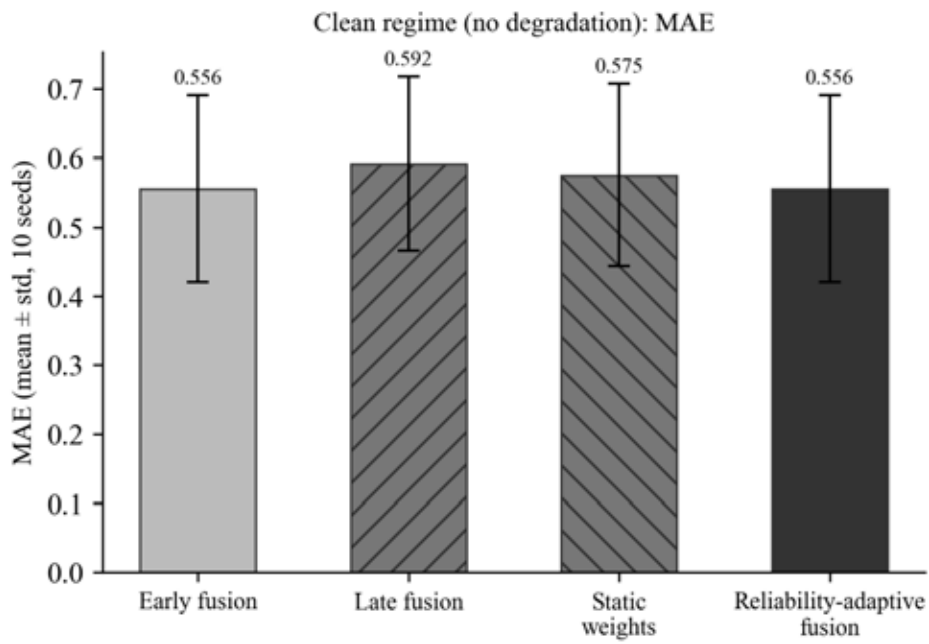


Рис. 3. Контрольований бенчмарк: MAE у clean-режимі (узгодженість із базисом раннього злиття).

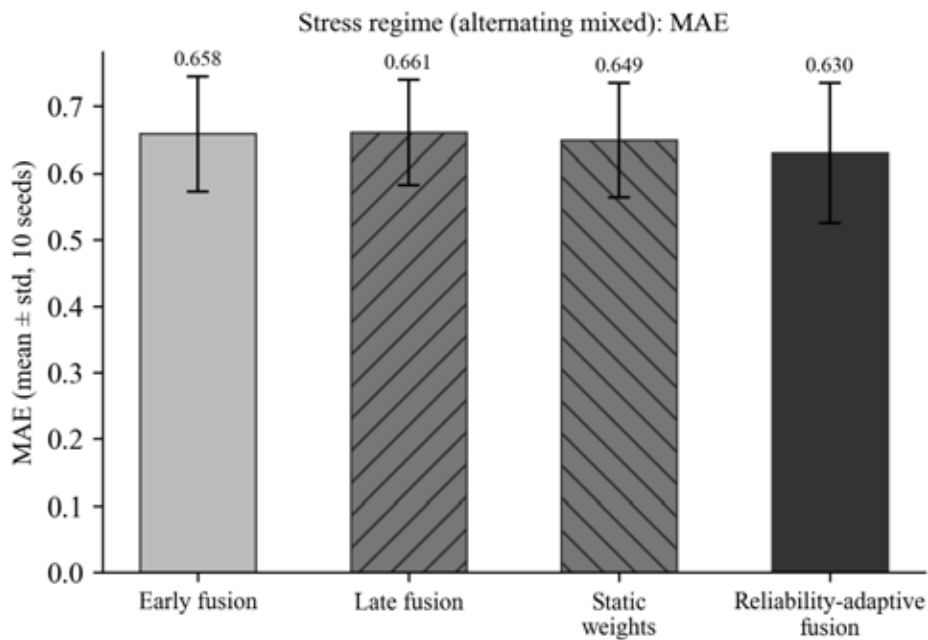


Рис. 4. Стрес-бенчмарк: MAE у режимі чергування деградацій (зменшення похибки)

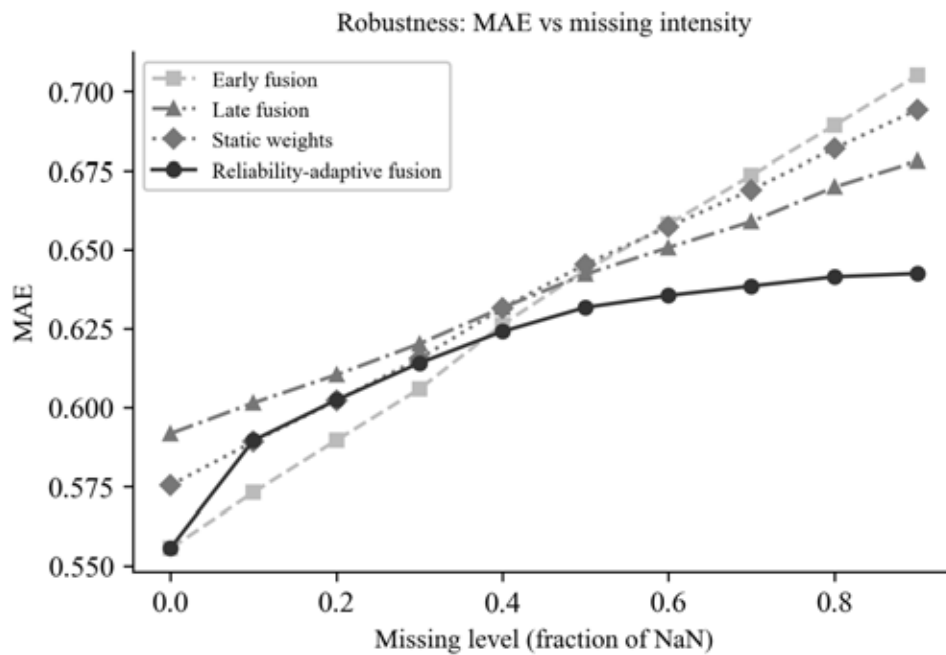


Рис. 5. Робастність при зростанні рівня деградації: MAE для різних значень «missing_level»

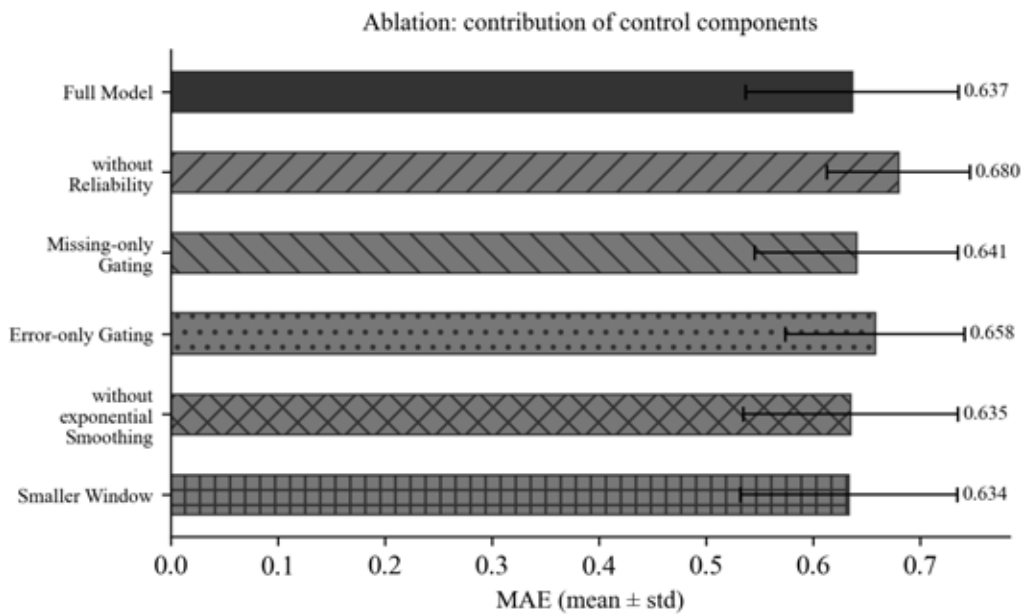


Рис. 6. Абляційне дослідження компонентів методу: вплив clean gate та експоненційного згладжування

ILLUSTRATIVE: reliability signals and fusion weight dynamics




Рис. 7. Динаміка ваг злиття та сигналів надійності у часі: перерозподіл впливу модальностей




Рис. 8. Реальні дані UCI Appliances: стабілізація похибки в деградованих сегментах без порушення безпеки у чистому режимі

Висновки

Розглянуто метод безпечного надійнісно-адаптивного динамічного злиття для потокового прогнозування мультимодальних часових рядів за тимчасової деградації модальностей, у якому clean gate реалізує вимогу «не нашкодь» у сегментах без деградації, а надійність модальності використовується як керувальний сигнал для перезважування внеску модальних предикторів зі згладжуванням. Показано узгодженість із сильним базисом раннього злиття у clean-режимі (MAE = 0,56 ± 0,13, RMSE = 0,70 ± 0,17), зменшення похибки у режимах чергування деградацій, а також суттєвий виграв у деградованих сегментах реальних даних UCI Appliances (MAE = 63,69 ± 5,82 проти 381,91 ± 95,22). Латентність покрокового інференсу залишається мікросекундною, що підтверджує придатність підходу для низьколатентних потокових конвеєрів.

Список використаної літератури

1. 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: 10.1109/TPAMI.2018.2798607.
2. 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: 10.1109/JPROC.2015.2460697.
3. Dawid A. P. Present position and potential developments: Some personal views: Statistical theory: the prequential approach // *Journal of the Royal Statistical Society. Series A (General)*. 1984. Vol. 147(2). P. 278–292. DOI: 10.2307/2981683.
4. Hyndman R. J., Koehler A. B. Another look at measures of forecast accuracy // *International Journal of Forecasting*. 2006. Vol. 22(4). P. 679–688. DOI: 10.1016/j.ijforecast.2006.03.001.
5. Candanedo L. M., Feldheim V., Deramaix D. Data driven prediction models of energy use of appliances in a low-energy house // *Energy and Buildings*. 2017. Vol. 140. P. 81–97. DOI: 10.1016/j.enbuild.2017.01.083.
6. UCI Machine Learning Repository. Appliances Energy Prediction. 2017. URL: <https://archive.ics.uci.edu/dataset/374/appliances+energy+prediction>.
7. Ramachandram D., Taylor G. W. Deep Multimodal Learning: A Survey on Recent Advances and Trends // *IEEE Signal Processing Magazine*. 2017. Vol. 34(6). P. 96–108. DOI: 10.1109/MSP.2017.2738401.
8. Jain R. *The Art of Computer Systems Performance Analysis: Techniques for Experimental Design, Measurement, Simulation, and Modeling*. Wiley-Interscience, 1991. URL: <https://www.cse.wustl.edu/~jain/books/perfbook.htm>.
9. Khaleghi B., Khamis A., Karray F. O., Razavi S. N. Multisensor data fusion: A review of the state-of-the-art // *Information Fusion*. 2013. Vol. 14(1). P. 28–44. DOI: 10.1016/j.inffus.2011.08.001.
10. Hall D. L., Llinas J. An introduction to multisensor data fusion // *Proceedings of the IEEE*. 1997. Vol. 85(1). P. 6–23. DOI: 10.1109/5.554205.
11. Atrey P. K., Hossain M. A., El Saddik A., Kankanhalli M. S. Multimodal fusion for multimedia analysis: a survey // *Multimedia Systems*. 2010. Vol. 16(6). P. 345–379. DOI: 10.1007/s00530-010-0182-0.
12. Jacobs R. A., Jordan M. I., Nowlan S. J., Hinton G. E. Adaptive mixtures of local experts // *Neural Computation*. 1991. Vol. 3(1). P. 79–87. DOI: 10.1162/neco.1991.3.1.79.
13. Kittler J., Hatef M., Duin R. P. W., Matas J. On combining classifiers // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1998. Vol. 20(3). P. 226–239. DOI: 10.1109/34.667881.
14. Shim J. P., Warkentin M., Courtney J. F., Power D. J., Sharda R., Carlsson C. Past, present, and future of decision support technology // *Decision Support Systems*. 2002. Vol. 33(2). P. 111–126. DOI: 10.1016/S0167-9236(01)00139-7.
15. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A survey on concept drift adaptation // *ACM Computing Surveys*. 2014. Vol. 46(4). P. 1–37. DOI: 10.1145/2523813.
16. Webb G. I., Hyde R., Cao H., Nguyen H.-L., Petitjean F. Characterizing concept drift // *Data Mining and Knowledge Discovery*. 2016. Vol. 30(4). P. 964–994. DOI: 10.1007/s10618-015-0448-4.
17. Che Z., Purushotham S., Cho K., Sontag D., Liu Y. Recurrent neural networks for multivariate time series with missing values // *Scientific Reports*. 2018. Vol. 8. Article 6085. DOI: 10.1038/s41598-018-24271-9.
18. Little R. J. A., Rubin D. B. *Statistical Analysis with Missing Data*. 2nd ed. Wiley, 2002. DOI: 10.1002/9781119013563.

References

1. Baltrušaitis, T., Ahuja, C., & Morency, L.-P. (2019). Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2), 423–443. <https://doi.org/10.1109/TPAMI.2018.2798607>
2. Lahat, D., Adali, T., & Jutten, C. (2015). Multimodal data fusion: An overview of methods, challenges, and prospects. *Proceedings of the IEEE*, 103(9), 1449–1477. <https://doi.org/10.1109/JPROC.2015.2460697>
3. Dawid, A. P. (1984). Present position and potential developments: Some personal views: Statistical theory: The prequential approach. *Journal of the Royal Statistical Society. Series A (General)*, 147(2), 278–292. <https://doi.org/10.2307/2981683>
4. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
5. Candanedo, L. M., Feldheim, V., & Deramaix, D. (2017). Data driven prediction models of energy use of appliances in a low-energy house. *Energy and Buildings*, 140, 81–97. <https://doi.org/10.1016/j.enbuild.2017.01.083>
6. UCI Machine Learning Repository. (2017). Appliances Energy Prediction. Retrieved from <https://archive.ics.uci.edu/dataset/374/appliances+energy+prediction>
7. Ramachandram, D., & Taylor, G. W. (2017). Deep multimodal learning: A survey on recent advances and trends. *IEEE Signal Processing Magazine*, 34(6), 96–108. <https://doi.org/10.1109/MSP.2017.2738401>
8. Jain, R. (1991). *The Art of Computer Systems Performance Analysis: Techniques for Experimental Design, Measurement, Simulation, and Modeling*. Wiley-Interscience. Retrieved from <https://www.cse.wustl.edu/~jain/books/perfbook.htm>

9. Khaleghi, B., Khamis, A., Karray, F. O., & Razavi, S. N. (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(1), 28–44. <https://doi.org/10.1016/j.inffus.2011.08.001>
10. Hall, D. L., & Llinas, J. (1997). An introduction to multisensor data fusion. *Proceedings of the IEEE*, 85(1), 6–23. <https://doi.org/10.1109/5.554205>
11. Atrey, P. K., Hossain, M. A., El Saddik, A., & Kankanhalli, M. S. (2010). Multimodal fusion for multimedia analysis: A survey. *Multimedia Systems*, 16(6), 345–379. <https://doi.org/10.1007/s00530-010-0182-0>
12. Jacobs, R. A., Jordan, M. I., Nowlan, S. J., & Hinton, G. E. (1991). Adaptive mixtures of local experts. *Neural Computation*, 3(1), 79–87. <https://doi.org/10.1162/neco.1991.3.1.79>
13. Kittler, J., Hatef, M., Duin, R. P. W., & Matas, J. (1998). On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3), 226–239. <https://doi.org/10.1109/34.667881>
14. Shim, J. P., Warkentin, M., Courtney, J. F., Power, D. J., Sharda, R., & Carlsson, C. (2002). Past, present, and future of decision support technology. *Decision Support Systems*, 33(2), 111–126. [https://doi.org/10.1016/S0167-9236\(01\)00139-7](https://doi.org/10.1016/S0167-9236(01)00139-7)
15. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4), 1–37. <https://doi.org/10.1145/2523813>
16. Webb, G. I., Hyde, R., Cao, H., Nguyen, H.-L., & Petitjean, F. (2016). Characterizing concept drift. *Data Mining and Knowledge Discovery*, 30(4), 964–994. <https://doi.org/10.1007/s10618-015-0448-4>
17. Che, Z., Purushotham, S., Cho, K., Sontag, D., & Liu, Y. (2018). Recurrent neural networks for multivariate time series with missing values. *Scientific Reports*, 8, 6085. <https://doi.org/10.1038/s41598-018-24271-9>
18. Little, R. J. A., & Rubin, D. B. (2002). *Statistical analysis with missing data* (2nd ed.). Wiley. <https://doi.org/10.1002/9781119013563>

Дата першого надходження статті до видання: 17.02.2026

Дата прийняття статті до друку після рецензування: 26.03.2026

Дата публікації (оприлюднення) статті: 07.05.2026