

ІНТЕГРАЦІЯ НЕЧІТКОЇ ЛОГІКИ В ГЕНЕРАТИВНО-ЗМАГАЛЬНУ МЕРЕЖУ TIMEGAN ДЛЯ ПРОГНОЗУВАННЯ ФІНАНСОВИХ ЧАСОВИХ РЯДІВ

Перцев Ю.О.¹ [ORCID], Коротка Л.І.² [ORCID]

¹УДУНТ ННІ УДХТУ, аспірант, Україна

²УДУНТ ННІ УДХТУ, к.т.н., доцент, Україна

Анотація. Розглянуто проблему фіксованої довжини вікна спостереження у генеративно-змагальній мережі TimeGAN та запропоновано метод її вирішення через інтеграцію нечіткого регулятора параметра k . На відміну від детермінованого підбору гіперпараметрів, нечіткий модуль $\Phi: S \rightarrow K = \{10, \dots, 60\}$ динамічно адаптує k залежно від поточного ринкового режиму, що характеризується вектором з чотирьох індикаторів: риночної волатильності, нормованого нахилу лінійної регресії, нормованого обсягу торгів відносно ковзного середнього та волатильності сентименту новин.

Описано архітектурні зміни у функції вбудовування TimeGAN, необхідні для інтеграції змінного вікна, та підтверджено ефективність підходу на двох активах (S&P 500, AAPL) за 2019–2025 р. MAE знизився на 16,4% для S&P 500 та на 12,9% для AAPL порівняно з базовим TimeGAN при фіксованому k .

Ключові слова: TimeGAN, нечітка логіка, система Мамдані, адаптивне вікно, генеративно-змагальні мережі, прогнозування часових рядів.

Прогнозування нестаціонарних фінансових часових рядів є актуальною задачею обчислювального інтелекту: динаміка цін акцій визначається поєднанням нелінійних залежностей, структурних режимних зсувів та подієво-орієнтованих стрибків, що унеможливорює ефективне застосування класичних статистичних моделей (ARIMA) та авторегресійних нейронних мереж (LSTM) у довгостроковому горизонті [1].

Генеративно-змагальна мережа TimeGAN [2] є найбільш перспективною генеративною моделлю для даної задачі: на відміну від LSTM, що прогнозує лише умовне математичне сподівання $E[y_{t+1}|y_1, \dots, y_t]$, TimeGAN моделює повний умовний розподіл майбутніх траєкторій $p(y_{[t+1:t+h]}|y_1, \dots, y_t)$, що дозволяє природно будувати довірчі інтервали та здійснювати сценарний аналіз.

Незважаючи на переваги, базовий TimeGAN має структурне обмеження: довжина вікна спостереження k визначається одноразово у процесі перебору гіперпараметрів та залишається фіксованою впродовж всього навчання й інференсу. Між тим декомпозиція очікуваної квадратичної похибки:

$$E[(y_{t+1} - \hat{y}_{t+1})^2] = \text{Bias}^2(k, s_t) + \text{Var}(k, s_t) + \varepsilon^2, \quad (1)$$

показує, що оптимальний k є функцією поточного стану ринку s_t : при підвищеній волатильності ($\sigma_t > 0,02$) складова Bias^2 стрімко зростає для великих k – оскільки нестационарний ринковий режим змінюється швидше, ніж встигає накопичитися репрезентативна вибірка довжиною k , і модель усереднює спостереження з різних режимів – оптимум $k \approx 20-30$, а у стабільних трендових фазах ($\sigma_t < 0,008$, $|\tau_t| > 0,5$) оптимум зміщується до $k \approx 50-60$. Фіксоване k неминуче призводить до субоптимальних прогнозів при зміні ринкового режиму.

Для усунення виявленого обмеження запропоновано інтегрувати у TimeGAN нечіткий регулятор параметра k – відображення $\Phi: S \rightarrow K = \{10, \dots, 60\}$, що реалізується системою нечіткого виведення Мамдані [3]. Вхідний вектор стану ринку:

$$s_t = (\sigma_t, \tau_t, v_t, \xi_t)^T \in S \subseteq R^4, \quad (2)$$

де σ_t – реалізована волатильність (стандартне відхилення логарифмічних прибутковостей за $w = 20$ днів); $\tau_t \in [-1, 1]$ – нормований нахил лінійної регресії (одночасно кодує напрямок та силу тренду); v_t – нормований обсяг торгів відносно ковзного середнього; $\xi_t \in [0, 1]$ – волатильність настрою (стандартне відхилення тональних оцінок новин за 10 торгових днів, що є раннім індикатором режимного переходу).

Система Мамдані містить 18 правил IF-THEN: 9 базових правил охоплюють усі комбінації рівнів $\sigma_t \times \tau_t$ (по 3 рівні: низький / середній / високий), інші 6 додаткових враховують взаємодію аномального v_t з рівнями σ_t (2 стани $v_t \times 3$ стани σ_t), останні 3 правила описують поведінку при нестабільному ξ_t незалежно від тренду. Функції належності – сигмоїдні класу C^∞ з параметрами $\gamma_\sigma = 600$, $\gamma_\tau = 15$, $\gamma_v = 8$, $\gamma_\xi = 11$. Дефазифікація виконується методом центра ваги (COG). Для відображення Φ доведено: обмеженість $k^*(s_t) \in [10, 60]$, неперервність $k^*(s_t) \in C^0(S)$ та монотонність ($\sigma_t \uparrow \Rightarrow k^* \downarrow$, $|\tau_t| \uparrow \Rightarrow k^* \uparrow$).

Ключовим архітектурним питанням було як інтегрувати змінний k_t у TimeGAN, де функція вбудовування $e: R^k \rightarrow H$ очікує вхід фіксованої розмірності. Рішення було знайдено за допомогою проєкційного шару:

$$x_t^{proj} = W_p \cdot pad(x_t^{k_t}, k_{max}) + b_p, W_p \in R^{d_p \times (k_{max} \cdot n)}, b_p \in R^{d_p}, \quad (3)$$

де $pad(x_t^{k_t}, k_{max})$ доповнює вектор довжини k_t нулями зліва до стандартної довжини $k_{max} = 60$, W_p ($d_p = 64$) навчається разом з усіма компонентами TimeGAN та схильний зменшувати вагу нульових позицій паддингу. Модифікований вхідний вектор $e(x_t^{proj}) \in H$ зберігає розмірність $d_h = 24$, і жоден із п'яти GRU-компонентів TimeGAN (e, r, S, G_s, D_s) не вимагає структурних змін – інтеграція реалізується виключно на рівні вхідного шару. У даній роботі моделюється одновимірний ціновий ряд ($n = 1$), тому $W_p \in R^{64 \times 60}$.

Доведено, що для будь-якого $k_t \in K$ розмірність вхідного вектора $x_t^{proj} \in R^{d_p} = R^{64}$ є фіксованою константою, що не залежить від k_t . Отже, властивості генератора G_s (диференційованість при обмежених вагах W_p) та збіжність GAN-навчання зберігаються.

Навчання модифікованого TimeGAN (TimeGAN-F) відбувається у трьох фазах. Фаза 1 (одноразово): калібрування нечіткого регулятора Φ на навчальній вибірці – визначення порогових значень c_0, c_1, c_2 для функцій належності через квантілі Q_{25}, Q_{50}, Q_{75} розподілів $\sigma_t, \tau_t, \nu_t, \xi_t$. Фаза 2: попереднє навчання автокодувальника (e, r) через мінімізацію $L_{reconstruction}$ при фіксованих G_s, D_s . Фаза 3: спільне навчання всіх компонентів через функцію втрат, ідентичну базовому TimeGAN:

$$L_{TimeGAN-F} = L_{reconstruction} + \lambda_2 L_{supervised} + \lambda_3 L_{unsupervised}, \quad (4)$$

де $\lambda_2 = \lambda_3 = 10$ успадковуються від конфігурації Yoon et al. (2019) [4]. Принципова відмінність від базового TimeGAN – перерахунок $k_t = \Phi(s_t)$ на кожному пакеті (batch-level adaptive window): для кожного зразка у пакеті нечіткий регулятор обчислює індивідуальний k_t перед формуванням x_t^{proj} . Обчислювальна вартість виклику Φ становить $O(18)$ операцій ($\sim 0,08$ мс), що складає менше 0,3% від часу одного навчального кроку GRU-компонентів.

Верифікацію проведено на двох активах американського фондового ринку (S&P 500, AAPL) за 2019-2025 рр. методологією ковзного вікна ($T_{train} = 500, T_{val} = 60, T_{slide} = 20$ днів; 11 незалежних тестових перевірок).

Таблиця 1 наводить порівняльні метрики для горизонту прогнозування $h = 5$ днів для обох активів.

Таблиця 1

Порівняння метрик якості прогнозування

Модель	Актив	MAE	RMSE	MAPE, %	R ²
ARIMA	S&P500	42,1	58,7	3,42	0,721
LSTM	S&P500	28,6	39,4	2,31	0,847
TimeGAN (базовий)	S&P500	21,3	29,8	1,73	0,903
TimeGAN-F (нечітке k)	S&P500	17,8	25,1	1,44	0,931
ARIMA	AAPL	8,45	9,7	3,04	0,33
LSTM	AAPL	6,34	7,28	2,28	0,51
TimeGAN (базовий)	AAPL	2,71	3,57	1,38	0,95
TimeGAN-F (нечітке k)	AAPL	2,36	3,29	1,09	0,98

TimeGAN з нечітким регулятором k (TimeGAN-F) перевершує базовий TimeGAN за всіма метриками на обох активах. Для S&P 500: MAE знизився на 16,4% (з 21,3 до 17,8), RMSE – на 15,8% (з 29,8 до 25,1), R² зріс з 0,903 до 0,931. Для AAPL: MAE знизився на 12,9% (з 2,71 до 2,36), RMSE – на 7,8% (з 3,57 до 3,29), R² зріс з 0,95 до 0,98. Порівняно з ARIMA покращення MAE становить 57,7% для S&P 500 та 72,1% для AAPL.

Поведінка нечіткого регулятора підтверджена окремо: на даних S&P 500 та AAPL за 2019-2025 рр. (14 ринкових режимів) MAE між k_t , обчисленим нечітким регулятором Φ , та оптимальним k_t^* , визначеним ретроспективним перебором на валідаційній вибірці, становить 1,08 кроки, коефіцієнт рангової кореляції Спірмена $\rho_s(k_t, \sigma_t) = -0,84$ та $\rho_s(k_t, |\tau_t|) = +0,76$ ($p < 0,001$). При COVID-кризі 2020 р. регулятор знизив k_t з 50-55 до 15-22 впродовж 8-10 торгових днів; аналогічну реакцію відтворено при тарифному шоці квітня 2025 р. k_t знизився до 12-19.

Ключова властивість інтеграції – плавність адаптації. Пороговий підхід до вибору k при осциляції σ_t навколо порогу генерує стрибки $\Delta k = 10-15$ кроків між сусідніми торговими сесіями (RMSE від «ідеальної» траєкторії: 7,2), тоді як нечіткий регулятор забезпечує $\Delta k \leq 2$ кроки (RMSE = 0,8) – перевага у 9 разів. Ця властивість безпосередньо впливає на якість прогнозів: стрибкоподібна зміна k дестабілізує GAN-навчання на відміну від плавної адаптації.

Таким чином, було запропоновано метод інтеграції нечіткого регулятора параметра k у генеративно-змагальну мережу TimeGAN. При цьому отримані наступні результати:

– розроблено нечіткий регулятор $\Phi: S \rightarrow K = \{10, \dots, 60\}$ на основі системи Мамдані з 18 правилами IF-THEN та 4 вхідними змінними $(\sigma_t, \tau_t, \nu_t, \xi_t)$ з формально доведеними властивостями обмеженості, неперервності та монотонності;

– запропоновано архітектурне рішення для інтеграції змінного k_t у TimeGAN через проєкційний шар $W_p \in R^{64 \times 60}$ з операцією нульового паддингу; доведено коректність – фіксована розмірність входу e зберігається при будь-якому $k_t \in K$;

– верифіковано на 2 активах (S&P 500, AAPL), 2019–2025 р.: MAE знизився на 16,4% (S&P 500) та 12,9% (AAPL) порівняно з базовим TimeGAN, на 57,7% та 72,1% відповідно порівняно з ARIMA;

– підтверджено, що плавна адаптація k_t ($\Delta k \leq 2$ між сесіями) є необхідною умовою стабільного GAN-навчання на відміну від стрибкоподібного порогового підходу (Δk до 15).

ЛІТЕРАТУРА

1. Перцев Ю. О., Коротка Л. І. (2025) Порівняльний аналіз традиційних статистичних методів та нейромережевої моделі LSTM. Системні технології. 2025. №1(156). С. 65-77. <https://doi.org/10.34185/1562-9945-1-156-2025-08>
2. Перцев Ю. О., & Коротка Л. І. (2025). Порівняльний аналіз генеративно-змагальних мереж для прогнозування часових рядів фондового ринку. Вісник Кременчуцького національного університету імені Михайла Остроградського. – Кременчук: КрНУ, 2025. – Випуск 4(153), 220-231. <https://doi.org/10.32782/1995-0519.2025.4.26>
3. Mamdani E. H., Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller // International Journal of Man-Machine Studies. – 1975. – Vol. 7 (1). – P. 1–13.
4. Yoon J., Jarrett D., van der Schaar M. Time-series generative adversarial networks // Advances in Neural Information Processing Systems. – 2019. – Vol. 32. – P. 5508–5518.
5. Goodfellow I. et al. Generative adversarial nets // Advances in Neural Information Processing Systems. – 2014. – Vol. 27. – P. 2672–2680.

INTEGRATION OF FUZZY LOGIC INTO THE TimeGAN GENERATIVE ADVERSARIAL NETWORK FOR FINANCIAL TIME SERIES FORECASTING

Y. Pertsev, L. Korotka

Abstract. *The problem of a fixed observation window length in the TimeGAN generative adversarial network is examined, and a method for resolving it through the integration of a fuzzy controller for parameter k is proposed. Unlike deterministic hyperparameter tuning, the fuzzy module $\Phi: S \rightarrow K = \{10, \dots, 60\}$ dynamically adapts k according to the current market regime, characterized by a vector of four indicators: market volatility, the normalized slope of a linear regression, the normalized trading volume relative to the moving average, and news sentiment volatility. The architectural modifications to the TimeGAN embedding function required for variable window integration are described, and the effectiveness of the approach is confirmed on two assets (S&P 500, AAPL) over the period 2019–2025: MAE decreased by 16,4% for S&P 500 and by 12,9% for AAPL compared to the baseline TimeGAN with fixed k .*

Keywords: *TimeGAN, fuzzy logic, Mamdani system, adaptive window, generative adversarial networks, time series forecasting.*

REFERENCE

1. Pertsev Y. O., Korotka L. I. Comparative analysis of traditional statistical methods and the LSTM neural network model. System technologies. 2025. №1(156). P. 65-77. <https://doi.org/10.34185/1562-9945-1-156-2025-08>
2. Pertsev Y. O., & Korotka L. I. (2025). Porivnialnyi analiz heneratyvno-zmahalnykh merezh dlia prohnozuvannia chasovykh riadiv fondovoho rynku. Visnyk Kremenchutskoho natsionalnoho universytetu imeni Mykhaila Ostrohradskoho. – Kremenchuk: KrNU, 2025. – Vypusk 4(153), 220-231. <https://doi.org/10.32782/1995-0519.2025.4.26>
3. Mamdani E. H., Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller // International Journal of Man-Machine Studies. – 1975. – Vol. 7 (1). – P. 1–13.
4. Yoon J., Jarrett D., van der Schaar M. Time-series generative adversarial networks // Advances in Neural Information Processing Systems. – 2019. – Vol. 32. – P. 5508–5518.
5. Goodfellow I. et al. Generative adversarial nets // Advances in Neural Information Processing Systems. – 2014. – Vol. 27. – P. 2672–2680.