



ЕЛЕКТРОЕНЕРГЕТИКА, ЕЛЕКТРОТЕХНІКА ТА ЕЛЕКТРОМЕХАНІКА

DOI <https://doi.org/10.32782/2220-8674-2026-16-1-19>

УДК 004.4:004.8

О. В. Бойко, канд. техн. наук

ORCID: 0000-0001-8557-2267

А. С. Комін, аспірант

ORCID: 0000-0003-0328-3934

Сумський державний університет

e-mail: anton.komin2@gmail.com

**ОЦІНКА І ВИБІР МОДЕЛІ-ЧЕМПІОНА У ЗАДАЧАХ АДАПТАЦІЇ
МОДЕЛЕЙ ПРОГНОЗУВАННЯ РІВНЯ СПОЖИВАННЯ ЕЛЕКТРОЕНЕРГІЇ
У SMART GRID**

Анотація. У статті запропоновано модель оцінки та вибору моделі-чемпіона у задачах адаптації моделей прогнозування рівня споживання електроенергії до умов експлуатації кінцевим споживачем. Модель було перевірено у рамках прототипу інформаційної технології з використанням LSTM-моделі прогнозування. Експеримент проведено на реальних даних про погодинне споживання електроенергії домогосподарством за 8 місяців. У процесі інкрементального навчання було сформовано пул моделей-кандидатів і за допомогою запропонованої моделі на кожному із вікон оцінки було обрано модель-чемпіона з найкращою якістю прогнозів. Це дозволило провести адаптацію моделі прогнозування і покращити RSME на 35.3 % у порівнянні із початковою моделлю, що підтвердило ефективність запропонованої моделі оцінки та вибору моделі-чемпіона.

Ключові слова: периферійні обчислення, машинне навчання, розумні мікромережі, енергоефективність, прогнозування споживання електроенергії, Tensorflow Lite.

Постановка проблеми. Короткострокове прогнозування електроспоживання є важливим компонентом сучасних HEMS, адже якість таких прогнозів безпосередньо впливає на планування навантаження, керування накопиченням електроенергії, оптимізації споживання, тощо. Для забезпечення високого рівня точності прогнозів навчання моделей машинного навчання потребує наявності достатньої кількості історичних даних про рівень споживання електроенергії. Також варто зазначити, що кожна енергетична мережа є унікальною як з точки зору її компонентів, так і з точки зору її використання. Відповідно для надання точних прогнозів необхідно навчати моделі з використанням історичних даних мережі, де ця модель буде використовуватись. Нажаль не завжди можна отримати достатню кількість даних для первинного навчання моделі на етапі впровадження HEMS, а отже і її підсистема прогнозування не зможе повноцінно функціонувати, що ускладнює задачу ефективного управління енергомережою.

Варто зазначити, що у практичних середовищах моделі прогнозування не можуть залишатись статичними, адже режими використання енергомережі можуть змінюватись з часом – підключення нових споживачів, оновлення обладнання мережі, кліматичні зміни. Відповідно виникає потреба у адаптації моделей прогнозування по мірі накопичення історичних даних мережі. Зазвичай процес адаптації полягає у оптимізації вагових коефіцієнтів моделі, або її перенавчанні. З часом утворюється множина моделей, кожна з яких була навчена на різному обсязі історичних даних. Виникає проблема вибору поточної моделі для використання і якщо порівнювати моделі лише за метриками, що були отримані під час їх первинного навчання і тес-

тування, то таке порівняння буде некоректним, адже кожна модель була оцінена на власному часовому зрізі даних, і кожна наступна модель вже мала ці дані у своїй навчальній вибірці.

Аналіз останніх досліджень. Враховуючи динамічну і мінливу природу Smart Grid використання статичних моделей прогнозування не є ефективним. Хоча сучасні моделі машинного навчання, наприклад LSTM [1], здатні надавати досить точні короткострокові прогнози, з часом практично неможливо уникнути дрейфу даних та концепту моделі [2], що призводить до деградації їх точності [3]. Для Smart Grid і енергомереж в цілому таким дрейфом може бути зміна шаблонів споживання і його рівнів. Яскравим прикладом впливу цих факторів є вплив пандемії COVID-19, що не тільки показав вразливість моделей прогнозування [4], але і стимулював дослідження у сфері адаптації моделей прогнозування до актуальних умов їх використання [5], [6]. В рамках процесу адаптації виникає задача вибору оптимальної моделі для використання. У результаті аналізу актуальних публікацій було помічено, що більшість з них сфокусовані на виборі оптимальної моделі прогнозування на етапі первинного навчання, а подальший процес оновлення часто залишається поза рамками досліджень. Для вирішення даної проблеми пропонуються підходи, такі як застосування підкріпленого навчання у процесі вибору [7], або підхід конкурентного вибору моделі-чемпіона [8], що особливо актуально у випадках, коли донавчання поточної моделі ускладнене або неможливе. Прикладом таких моделей можуть бути моделі прогнозування LSTM на мобільних пристроях [9]. Проаналізовані публікації мають прогалину у даній темі досліджень і не пропонують універсальних підходів щодо оцінки моделей машинного навчання у задачах прогнозування рівня споживання електроенергії.

Формулювання цілей статті (постановка завдання). Метою цієї статті є розробка моделі оцінки та вибору моделі-чемпіона у задачах адаптації моделей прогнозування рівня споживання електроенергії до умов експлуатації кінцевим споживачем.

Основна частина. Нехай часовий ряд погодинного споживання електроенергії задається як:

$$Y = \{y_t\}_{t=1}^T, \quad y_t \in \mathbb{R}_{\geq 0} \#, \quad (1)$$

де y_t є фактичним значенням електроспоживання в момент часу t , а крок дискретизації становить одну годину.

У момент прийняття рішення τ доступна множина моделей-кандидатів

$$\mathcal{M}_\tau = \{M_1, M_2, \dots, M_{K_\tau}\}, \quad (2)$$

де K_τ це загальна кількість навчених моделей, що доступні на момент прийняття рішення. Кожна модель M_k була навчена на історичних даних, доступних до моменту початку її навчання.

$$T_k^{\text{train}}. \quad (3)$$

Оскільки значення T_k^{train} відрізняються між навченими моделями, первинні зафіксовані метрики оцінки не можуть бути використані як основа для прямого порівняння.

Нехай останній доступний індекс спостереження в поточний момент дорівнює T , а довжина зовнішнього вікна оцінювання становить H часових кроків. Тоді вікно оцінки визначається як

$$W(T, H) = \{t \mid T - H + 1 \leq t \leq T\}. \quad (4)$$

Важливо зазначити, що дане вікно використовується виключно для зовнішньої оцінки та порівняння моделей і ніколи не входить у вибірку даних для навчання.

У рамках даної моделі розглядається прогноз з горизонтом прогнозування в один часовий крок із фіксованою довжиною історії L . Для кожного допустимого моменту часу формується вхідний вектор

$$x_t = [y_{t-L}, y_{t-L+1}, \dots, y_{t-1}]^T, \quad (5)$$

а прогноз моделі M_k визначається як



$$\hat{y}_t = f_{M_k}(\mathbf{x}_t). \quad (6)$$

Для відносної оцінки ефективності навчених моделей прогнозування введемо наївну базову модель:

$$\hat{y}_t^{(b)} = y_{t-1}. \quad (7)$$

Для моделі-кандидата M_k похибка прогнозу в момент часу $t \in W$ визначається як

$$e_t^{(k)} = y_t - \hat{y}_t^{(k)}. \quad (8)$$

Якість прогнозів моделей оцінюється за чотирма метриками.

Середня абсолютна помилка (MAE), що розраховується як:

$$MAE^{(k)}(W) = \frac{1}{|W|} \sum_{t \in W} |e_t^{(k)}|. \quad (9)$$

Метрика MAE характеризує загальну стабільність прогнозу і менш чутлива до значних одиничних відхилень точності прогнозу.

Корінь із середньоквадратичної помилки (RMSE):

$$RMSE^{(k)}(W) = \sqrt{\frac{1}{|W|} \sum_{t \in W} (e_t^{(k)})^2}. \quad (10)$$

RMSE у порівнянні з MAE чутлива до значних одиничних відхилень у точності прогнозу. Значні промахи у прогнозах у задачах управління енергомережами можуть призводити до некоректного вибору режиму їх роботи.

Зважена абсолютна відсоткова похибка (WAPE) надає відносну оцінку похибки у відсотках, але при цьому у порівнянні із середньою абсолютною відсотковою похибкою (MAPE) може бути розрахована для показників, які можуть містити нульові значення або наближатися до них, що є типовим для часових рядів рівня споживання електроенергії. WAPE можна розрахувати як

$$WAPE^{(k)}(W) = \frac{\sum_{t \in W} |e_t^{(k)}|}{\sum_{t \in W} |y_t|} \cdot 100\%. \quad (11)$$

Четвертою метрикою для порівняння задаємо коефіцієнт покращення відносно базової моделі (Skill), що можна розрахувати як

$$Skill_{RMSE}^{(k)}(W) = 1 - \frac{RMSE^{(k)}(W)}{RMSE^{(b)}(W)}. \quad (12)$$

Обраний набір критеріїв дозволяє провести оцінку моделі-кандидата. MAE та RMSE характеризують абсолютну точність прогнозу, WAPE надає відносну інтерпретацію точності прогнозу відносно фактичних показників на вікні оцінки $W(T, H)$, а Skill дозволяє оцінити чи дійсно натренована модель машинного навчання надає кращій прогноз, ніж базова модель прогнозування.

Оскільки обрані критерії оцінки мають різний масштаб та напрямок оптимізації перед їх агрегацією необхідно застосувати нормалізацію. Для метрик, що мінімізуються застосуємо

$$\tilde{m}^{(k)} = \frac{m^{(k)} - m_{\min}}{m_{\max} - m_{\min} + \varepsilon}, \quad (13)$$

де $\varepsilon > 0$ є малою константою, яка запобігає діленню на нуль.

Для метрики Skill, яку необхідно максимізувати нормалізований показник розрахуємо як

$$\tilde{S}_{raw}^{(k)} = \frac{Skill_{RMSE}^{(k)} - Skill_{min}}{Skill_{max} - Skill_{min} + \varepsilon}, \quad (14)$$

та виконаємо його інверсію

$$\tilde{S}^{(k)} = 1 - \tilde{S}_{raw}^{(k)}. \quad (15)$$

В результаті всі нормалізовані показники мають єдиний напрямок оптимізації – менше значення відповідає моделі з найкращою якістю прогнозів.

На основі зазначених критеріїв оцінки можемо сформулювати інтегральний критерій вибору моделі-чемпіона. Нехай для моделі M_k маємо вектор критеріїв

$$\mathbf{g}^{(k)} = (RMSE^{(k)}, MAE^{(k)}, WAPE^{(k)}, Skill_{RMSE}^{(k)}). \quad (16)$$

Тоді інтегральний критерій можна задати як

$$S^{(k)} = \alpha_{RMSE} \widehat{RMSE}^{(k)} + \alpha_{MAE} \widehat{MAE}^{(k)} + \alpha_{WAPE} \widehat{WAPE}^{(k)} + \alpha_{Skill} \tilde{S}^{(k)}, \quad (17)$$

де ваги задовольняють умову

$$\alpha_{RMSE} + \alpha_{MAE} + \alpha_{WAPE} + \alpha_{Skill} = 1, \quad \alpha_i \geq 0. \quad (18)$$

На основі інтегрального критерію вибору моделі-чемпіона сформуємо правило для вибору відповідної моделі серед моделей-кандидатів

$$M^*(T) = \arg \min_{M_k \in \mathcal{M}_t} S^{(k)}. \quad (19)$$

Відповідно до правила 19 моделлю-чемпіоном вважається модель із мінімальним значенням інтегрованого критерію на спільному зовнішньому вікні оцінювання.

Для зменшення частоти нестійких перемикань між моделями, що мають практично еквівалентний показник інтегрованого критерію оцінки доцільно використати поріг гістерезису. Нехай $S^{(c)}$ є значенням інтегрованого критерію оцінки поточної моделі-чемпіона, а $S^{(n)}$ є значенням інтегрованого критерію оцінки моделі-кандидата. Тоді відносне покращення моделі дорівнює

$$\Delta = \frac{S^{(c)} - S^{(n)}}{S^{(c)} + \varepsilon}. \quad (20)$$

Якщо

$$\Delta < \delta, \quad (21)$$

де δ це мінімальний поріг покращення інтегрального критерію оцінки моделі, то чинна модель-чемпіон зберігається.

Практична перевірка моделі. Для перевірки ефективності розробленої моделі було проведено прототипування інформаційної технології (ІТ) для оцінки і вибору моделі-чемпіона у задачах адаптації моделей прогнозування рівня споживання електроенергії до умов експлуатації кінцевим споживачем. Практичний сценарій моделює середовище, у якому дані про рівень споживання електроенергії накопичуються поступово і навчання моделі прогнозування виконується з використанням інкрементального підходу, тобто по мірі надходження нових даних. На кожному кроці спостереження часовий ряд подовжується до нового моменту T . Останні H значень часового ряду формують поточне вікно чемпіона, а вся попередня історія спостережень використовується у якості даних для навчання нової моделі. Період перенавчання задається окремим параметром R . Якщо перенавчання виконується кожні R днів, то часовий зсув становить

$$\Delta T = 24R. \quad (22)$$



В практичному експерименті перевірки прототипу ІТ значення R становить 7 днів. Важливо зазначити, що довжина вікна оцінювання H та періодичність перенавчання моделі R є незалежними параметрами і можуть бути змінені відповідно до потреб користувача ІТ.

У якості вхідних даних для перевірки прототипу було використано набір даних щогодинного споживання електроенергії домогосподарства за 8 місяців. Набір даних було попередньо очищено від аномалій та пропусків даних, обрано проміжок даних, що містить 5760 значень, або 240 повних діб. Дані для навчання і оцінки були нормалізовані за допомогою MinMaxScaler (0, 1) пакету NumPy. Горизонт вхідних даних для виконання прогнозу на один часовий крок вперед – 24 години. Період перенавчання R було задано як 7 діб, відповідно крок перенавчання становить ΔT 168 годин. Спільне вікно оцінювання $W(T, H)$ в експерименті було задано як 720 годин (30 діб). Значення гістерезису δ задано як 0.01. При розподілі вагових коефіцієнтів метрик оцінки більшого пріоритету надано α_{RMSE} , адже саме ця метрика найбільш чутлива до масштабу промахів прогнозів моделі. Загальна кількість вікон оцінки моделей на основі вищевказаних даних становить 31. Значення ключових параметрів моделі оцінки наведено в таблиці 1.

Таблиця 1

Ключові параметри моделі оцінки і вибору моделі-чемпіона

Параметр	R (год.)	ΔT (год.)	$W(T, H)$	δ	α_{RMSE}	α_{MAE}	α_{WAPE}	α_{Skill}
Значення	7	168	720	0.01	0.4	0.2	0.2	0.2

В якості експериментальної моделі прогнозування було обрано модель на базі LSTM. Архітектура шарів моделі вказана у таблиці 2. Для навчання та перевірки моделі прогнозування використовувалися фреймворки TensorFlow Keras, та NumPy. В якості функції втрат при навчанні було використано середньоквадратичну помилку MSE, оптимізатор Adam. Для навчання кожної моделі було задано розмір вибірки 64, та 10 епох навчання.

Таблиця 2

Структура експериментальної моделі прогнозування

Шар	Параметри
InputLayer	(24, 1)
LSTM	200, activation='relu'
Dense	100, activation='relu'
Dropout	0.1
Dense	1

Вихідний код прототипу ІТ, що включає імплементацію моделі оцінки і вибору моделі-чемпіона, розрахунку критеріїв моделі, підготовку даних для навчання моделей прогнозування, навчання моделей прогнозування, тестування навчених моделей було розроблено з використанням мови програмування Python.

В результаті тестування прототипу було проведено тренування 31 моделей-кандидатів (по 1 моделі прогнозування на кожне вікно оцінки). Експеримент показав, що якість моделі покращується у процесі адаптації, але динаміка покращення не є монотонною. На початкових вікнах оцінки спостерігається швидке зниження похибки, ближче до середини експерименту є період деградації якості прогнозів і наприкінці експерименту процес знову переходить до стабілізації та покращення, що узгоджується з логікою перенавчання моделі на дедалі більшій виборці історичних даних. За показником RMSE модель-чемпіон на вікні 1 мала значення RMSE 0,304186, а в процесі адаптації цей показник вдалось знизити до 0,196611, що є на 35.3 % краще. Динаміку зміни RMSE у процесі адаптації моделей можна побачити на рис 1.

Динаміка зміни інтегрального критерію оцінки моделі-чемпіона демонструє, що на вікні 1 критерій має найгірше значення, адже на старті є лише один кандидат і модель навчається на дуже обмеженому наборі даних. На вікнах 2, 4, 5 і 12 значення критерію наближається до нуля, тобто поточні чемпіони мали виражену перевагу серед моделей-кандидатів. На кроках 7–16 значення критерію мало велику кількість локально високих значень, що означало високу конкуренцію між моделями-кандидатами, а вибір моделі-чемпіона не був очевидним, що призводило до частішої зміни обраного чемпіона. На фінальних вікнах експерименту конкуренція моделей знову зменшується і перемикання моделі-чемпіона не відбувалось між вікнами 22 та 30 і фінальна модель-чемпіон мала відносно невелику перевагу. Візуалізацію динаміки значень

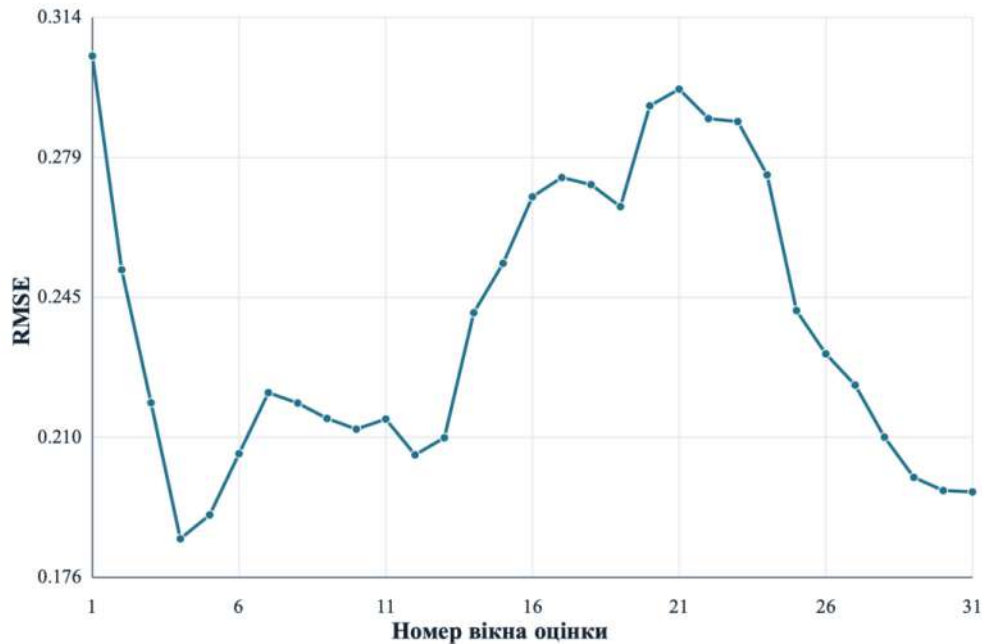


Рис. 1. Зміна критерію RMSE моделі-чемпіона у процесі адаптації

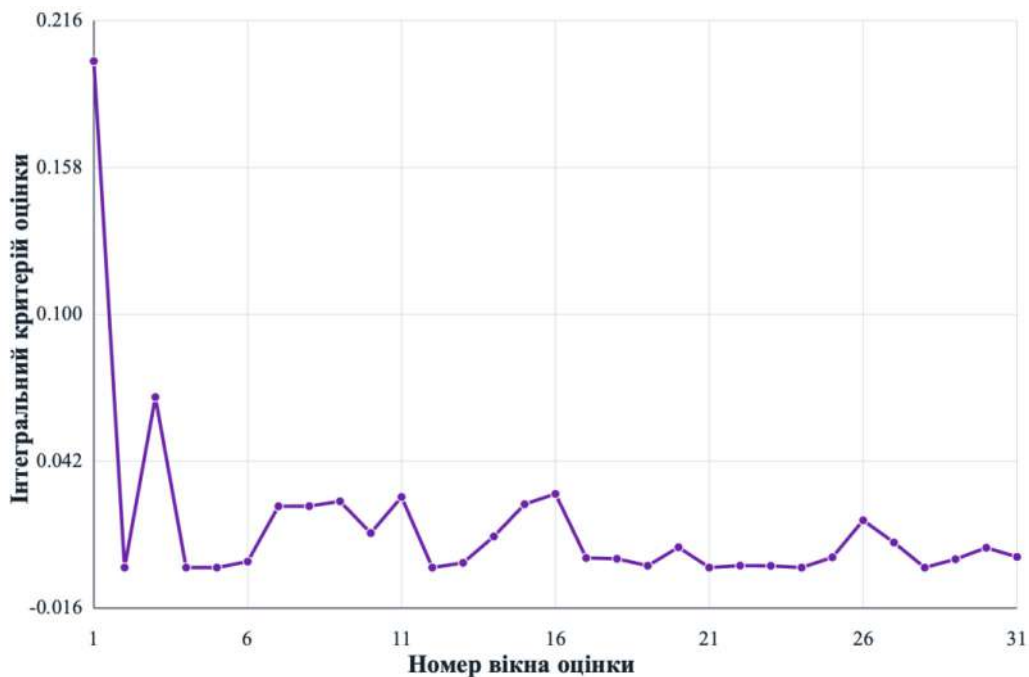


Рис. 2. Зміна значення інтегрального критерію оцінки моделі-чемпіона у процесі адаптації

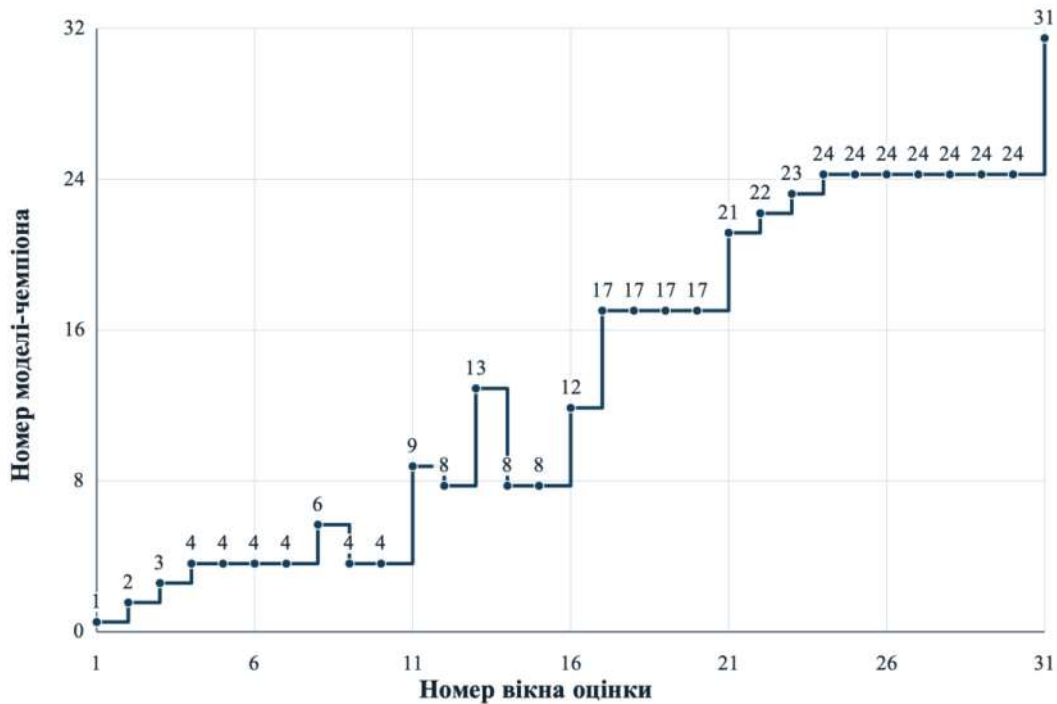


Рис. 3. Значення номера обраної моделі-чемпіона у процесі адаптації

інтегрального критерію оцінки зображено на рис. 2. Динаміку перемикаць моделей чемпіонів зображено на рис. 3. Цікавим спостереженням є те, що на певних вікнах оцінки моделлю-чемпіоном обиралась модель із попередніх вікон, що була натренована на меншому об'ємі історичних даних, але показувала кращі показники точності прогнозів на актуальному вікні оцінки.

Висновки. Запропоновану модель оцінки та вибору моделі-чемпіона у задачах адаптації моделей прогнозування рівня споживання електроенергії до умов експлуатації кінцевим споживачем було реалізовано у рамках прототипу інформаційної технології та перевірено на реальних даних про рівень споживання електроенергії домогосподарством. Експеримент підтвердив, що модель дає змогу ефективно оцінювати інкрементально навчені моделі-кандидати та обирати модель-чемпіон із найкращими значеннями критеріїв на актуальному вікні оцінки. На основі отриманих даних експерименту можна побачити, що моделі навчені на більшій кількості історичних даних не завжди забезпечували найкращу якість прогнозів і запропонована модель оцінки та вибору дозволила попередити регрес у якості прогнозів прототипом інформаційної системи. У комбінації з інкрементальним навчанням моделей запропонована модель оцінки дозволила адаптувати модель прогнозування і покращити її RMSE на 35.3 % – з 0.304186 до 0.196611. Отриманий результат підтверджує практичну доцільність використання запропонованої моделі при запуску підсистеми прогнозування HEMS для споживачів із малою кількістю історичних даних із подальшою адаптацією до умов експлуатації їх мережі. Перспективою подальших досліджень є розширення моделі шляхом додавання нових критеріїв оцінки та вагових коефіцієнтів для врахування важливості точності прогнозів у часових точках найближчих до поточного моменту.

Список використаних джерел

1. Comparison of short-term forecasting methods of electricity consumption in microgrids / Y. V. Parfenenko та ін. *Radio electronics, computer science, control*. 2023. № 1. С. 14. DOI: <https://doi.org/10.15588/1607-3274-2023-1-2>
2. Bayram F., Ahmed B. S., Kassler A. From concept drift to model degradation: an overview on performance-aware drift detectors. *Knowledge-Based systems*. 2022. Т. 245. С. 108632. DOI: <https://doi.org/10.1016/j.knosys.2022.108632>



3. Deterioration of electrical load forecasting models in a smart grid environment / A. Azeem та ін. *Sensors*. 2022. Т. 22, № 12. С. 4363. DOI: <https://doi.org/10.3390/s22124363>
4. Abulibdeh A., Zaidan E., Jabbar R. The impact of COVID-19 pandemic on electricity consumption and electricity demand forecasting accuracy: Empirical evidence from the state of Qatar. *Energy strategy reviews*. 2022. С. 100980. DOI: <https://doi.org/10.1016/j.esr.2022.100980>
5. Power system load forecasting using mobility optimization and multi-task learning in COVID-19 / J. Liu та ін. *Applied energy*. 2022. Т. 310. С. 118303. DOI: <https://doi.org/10.1016/j.apenergy.2021.118303>
6. Obst D., de Vilmarest J., Goude Y. Adaptive methods for short-term electricity load forecasting during COVID-19 lockdown in france. *IEEE transactions on power systems*. 2021. Т. 36, № 5. С. 4754–4763. DOI: <https://doi.org/10.1109/tpwrs.2021.3067551> (дата звернення: 26.03.2026).
7. Wee C. K., Nayak R. Adaptive load forecasting using reinforcement learning with database technology. *Journal of information and telecommunication*. 2019. Т. 3, № 3. С. 381–399. DOI: <https://doi.org/10.1080/24751839.2019.1596470>
8. AI governance in the system development life cycle / S. Laato та ін. *CAIN '22: 1st conference on AI engineering–software engineering for AI*, м. Pittsburgh Pennsylvania. New York, NY, USA, 2022. DOI: <https://doi.org/10.1145/3522664.3528598>
9. Комін А. С., Бойко О. В. Прогнозування енергоспоживання у мікромережах: оцінка конвертованих моделей. *Вісник Херсонського національного технічного університету*. 2025. Т. 2, № 1(92). С. 84–92. DOI: <https://doi.org/10.35546/kntu2078-4481.2025.1.2.12>

Дата першого надходження статті до видання: 11.02.2026

Дата прийняття статті до друку після рецензування: 19.03.2026

Дата публікації (оприлюднення) статті: 18.05.2026

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



О. Boiko, A. Komin
Sumy State University

EVALUATION AND CHAMPION MODEL SELECTION IN THE ADAPTATION OF ELECTRICITY CONSUMPTION FORECASTING MODELS FOR SMART GRIDS

Summary

The article proposes a model for the evaluation and selection of a champion model in the tasks of adapting electricity consumption forecasting models to the operating conditions of the end consumer. The model applies a multicriteria approach to model evaluation using the RMSE, MAE, WAPE, and Skill metrics. It includes their normalization and combination into a single integral evaluation criterion. Together with the use of a common external evaluation window, this allows forecasting models trained in different time periods to be effectively compared. To reduce the frequency of probable champion model switching, a hysteresis rule was added to the evaluation and selection model. The proposed model was validated in scope of the information technology prototype using an LSTM forecasting model based on the TensorFlow Keras library. The experiment was conducted on real data on the household's hourly electricity consumption over 8 months. Based on these data, 31 time intervals with a 7-day step were formed, corresponding to a scenario of weekly updates of the forecasting model during its operation. As a result of the incremental training on the specified data intervals, a pool of candidate models was formed, and with the help of the proposed model, a champion model with the best forecasting quality was selected at each of the external evaluation windows. This made it possible to adapt the forecasting model used in the prototype of the information technology and improve its RMSE by 35.3 % compared with the initial version, which confirmed the effectiveness of the proposed model. The obtained results confirm the practical value of the model when deploying HEMS forecasting subsystems for consumers with a small amount of historical data, followed by adaptation to the operating conditions of their network.

Keywords: edge computing, machine learning, microgrids, energy consumption forecasting, TensorFlow Lite.