



DOI 10.28925/2663-4023.2025.30.964

УДК 004.85:681.5

Ніщененко Дмитро Олександрович

аспірант

викладач кафедри технологій цифрового розвитку

Державний університет інформаційно-комунікаційних технологій, Київ, Україна

ORCID: 0009-0006-1781-4109

dima.nishchenko@gmail.com

ОПТИМІЗАЦІЯ ГІБРИДНИХ МОДЕЛЕЙ НА ОСНОВІ TCN, LSTM, LIGHTGBM ДЛЯ ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ В РОЗУМНИХ БУДИНКАХ

Анотація. Точне короткострокове прогнозування навантаження є ключовим завданням для ефективного управління енергоресурсами в системах розумного будинку. Гібридні моделі, що поєднують архітектури глибокого навчання (DL) та ансамблі дерев рішень, є провідним напрямом сучасних досліджень. Аналіз останніх публікацій підтверджує, що порівняння мереж з довгою короткостроковою пам'яттю (LSTM) та темпоральних згорткових мереж (TCN) є популярною темою, а гібридизація з LightGBM та використання стратегій корекції помилок («прогнозування залишків») є доведеними практиками для підвищення точності. Однак, огляд літератури виявляє декілька невирішених частин загальної проблеми: 1) відсутність систематичного аналізу компромісу між точністю прогнозу та обчислювальною вартістю (час навчання, вимоги до ресурсів), що є критичним для імплементації на пристроях Інтернету речей (IoT); 2) недостатня дослідженість впливу інженерії ознак, зокрема їх відбору, на обчислювальну ефективність гібридних моделей; 3) тенденція до фокусування на метриках точності без надання практичних методологій вибору оптимальної моделі залежно від конкретного завдання. Ця робота спрямована на заповнення вказаних прогалів. Реалізовано багатоетапний експериментальний аналіз. Для обраних моделей тестувалися дві стратегії гібридизації: "коригування піків" та "прогнозування залишків". Розроблено методику оптимізації часу навчання шляхом відбору найважливіших ознак для моделі-коректора. Для забезпечення статистичної значущості результатів застосовувалася перехресна валідація для часових рядів. Дослідження підтвердило, що гібридні моделі значно перевершують базові, а стратегія "прогнозування залишків" є найбільш ефективною. Виявлено дві високопродуктивні спеціалізовані конфігурації. Гібрид LSTM + LightGBM продемонстрував найвищу загальну точність (MAPE 13.36%). Водночас гібрид TCN + LightGBM виявився ефективнішим у прогнозуванні критичних пікових навантажень (Peak Magnitude MAPE 16.71%) та на 21% швидшим у навчанні. Ключовим результатом є запропонована методика оптимізації моделі TCN + LightGBM шляхом відбору ознак, що дозволило прискорити навчання в 5.4 рази при збереженні високої точності прогнозування піків (Peak MAPE 16.77%). Робота заповнює ідентифіковані прогалини в літературі, надаючи не лише кількісні результати, а й практичну методологію для обґрунтованого вибору архітектури прогнозування залежно від пріоритетних завдань системи розумного будинку: максимальна загальна точність, пріоритетне управління піковими навантаженнями або збалансована продуктивність для пристроїв з обмеженими ресурсами. Запропонований оптимізований гібридний підхід є перспективним для практичного впровадження в адаптивні системи управління енергією завдяки доведеному балансу високої точності та низьких обчислювальних витрат.

Ключові слова: прогнозування навантаження; розумний будинок; гібридні моделі; глибоке навчання; TCN; LSTM; LightGBM; оптимізація.



ВСТУП

Постановка проблеми. Точне короткострокове прогнозування енергоспоживання є фундаментальним завданням для забезпечення стабільності функціонування енергосистем, оптимізації управління енергоресурсами та підтримки прийняття економічно обґрунтованих рішень у сучасних розумних будинках [6]. Традиційні підходи, що покладаються на стандартні профілі навантаження, втрачають свою ефективність в умовах сучасних електромереж. Поява нових потужних споживачів, таких як теплові насоси та електромобілі, а також інтеграція непередбачуваної відновлюваної генерації суттєво змінюють класичні патерни споживання [8]. Навіть незначна помилка у прогнозі, на рівні 1%, може призводити до значних фінансових втрат, що підкреслює економічну важливість розробки високоточних алгоритмів. Водночас прогнозування ускладнюється нелінійним, нестационарним та волатильним характером часових рядів енергоспоживання, що зазнають впливу багатьох зовнішніх факторів, зокрема погодних умов та економічної активності [2].

Аналіз останніх досліджень і публікацій. Протягом останнього десятиліття методи прогнозування енергоспоживання (STLF) еволюціонували від класичних статистичних моделей (ARIMA) до прогресивних підходів на основі машинного та глибокого навчання, що є загальною тенденцією в застосуванні інформаційних технологій в науці [1. 20]. Архітектури глибокого навчання, зокрема мережі з довгою короткостроковою пам'яттю (LSTM), довели свою високу ефективність у захопленні складних часових залежностей в даних про навантаження [5]. Паралельно, значну увагу привернули темпоральні згорткові мережі (TCN), які, завдяки своїй згортковій архітектурі, здатні моделювати довгострокові залежності з вищою обчислювальною ефективністю порівняно з рекурентними архітектурами [9, 17, 22].

Сучасним трендом є розробка гібридних моделей, що поєднують сильні сторони різних алгоритмів [7]. Огляд літератури показує, що гібридизація моделей глибокого навчання (TCN, LSTM) з ансамблями дерев рішень, такими як LightGBM, є поширеною та ефективною практикою для підвищення точності прогнозування [4, 23]. Багато досліджень підтверджують, що такі гібридні структури стабільно демонструють вищу точність у порівнянні з одиночними моделями [26]. Також популярними є стратегії корекції помилок, відомі як «прогнозування залишків» (error correction/compensation), які додатково підвищують надійність прогнозів [19]. Для підвищення якості вхідних даних широко застосовуються методи декомпозиції сигналів, такі як VMD та CEEMDAN, що дозволяють зменшити волатильність часових рядів [3. 12]. Важливо зазначити, що надійність прогнозування напряму впливає на стабільність функціонування систем розумного будинку. Ці системи, в свою чергу, покладаються на складні гетерогенні інформаційно-комунікаційні мережі, безпека та кібербезпека яких є фундаментальною вимогою для їх коректної роботи [10, 15. 16, 24, 25].

Однак, проведений аналіз виявив кілька невирішених частин загальної проблеми, яким присвячена дана стаття:

1. Незважаючи на велику кількість робіт, що порівнюють TCN та LSTM, залишається недостатньо дослідженим їхнє систематичне порівняння саме в рамках гібридних архітектур з моделями-коректорами, що не дозволяє зробити однозначний висновок про оптимальну базову архітектуру для таких систем [27].

2. У більшості робіт відсутній комплексний аналіз компромісу між точністю прогнозування та обчислювальною вартістю (час навчання, вимоги до ресурсів). Цей аспект, як зазначається в огляді літератури, є критичним для практичної імплементації

алгоритмів на енергоефективних пристроях Інтернету речей (IoT), які є основою систем розумного будинку.

3. Недостатньо досліджено вплив інженерії ознак, зокрема їх відбору, на обчислювальну ефективність гібридних моделей [14]. Існуючі роботи зосереджені на підвищенні точності, ігноруючи потенціал оптимізації швидкості навчання, що є задокументованою прогалиною в дослідженнях.

Мета статті. Метою даної роботи є проведення комплексного порівняльного аналізу гібридних моделей на основі TCN та LSTM для короткострокового прогнозування енергоспоживання, визначення найефективнішої архітектури та стратегії гібридизації, а також розробка методики оптимізації фінальної моделі для досягнення балансу між високою точністю та обчислювальною ефективністю, що є ключовим для їх практичного застосування в системах розумного будинку.

МЕТОДИКА ДОСЛІДЖЕННЯ

Для досягнення поставленої мети було розроблено та реалізовано комплексну методику експериментального дослідження, яка включала підготовку даних, багастапний порівняльний аналіз моделей та оцінку їхньої ефективності. Дослідження проводилося на відкритому наборі даних 15-хвилинних показників смарт-метрів (Рис. 1) з 130 домогосподарств Німеччини за 2019 рік [джерело даних].




Рис. 1. Приклад тижневого профілю агрегованого енергоспоживання

Підготовка та попередня обробка даних. Первинний набір даних було підготовлено для подальшого моделювання. Було створено цільову змінну P_{agg} шляхом агрегації (сумування) показників споживання всіх 130 домогосподарств. Для покращення якості прогнозів було проведено інженерію ознак: створено часові ознаки (година доби, день року, ознака вихідного дня) та застосовано їх синусоїдальне перетворення для збереження циклічності. Усі дані, включаючи показники окремих домогосподарств та створені ознаки, було масштабовано до діапазону $[0, 1]$ за допомогою методу Min-Max нормалізації.



Дослідження було структуровано як багатоетапний порівняльний аналіз для послідовного відбору та тестування найбільш ефективних архітектур.

Етап 1 кваліфікаційний аналіз. Проведено тестування трьох базових архітектур глибокого навчання (1D-CNN, LSTM, TCN) для визначення 1-2 моделей з найкращим балансом точності та швидкодії та підтвердження результатів попередніх досліджень.

Етап 2 аналіз стратегій гібридизації. Для найкращої базової моделі (TCN) було протестовано дві стратегії гібридизації: «коригування піків» та «прогнозування залишків». В ролі моделей-коректорів використовувались LightGBM та XGBoost, для яких було створено окремий набір денних статистичних ознак (середнє, максимум, мінімум тощо) на основі показників 20 домогосподарств з найбільшим споживанням.

Етап 3 фінальний аналіз та оптимізація. Найефективніша гібридна стратегія («прогнозування залишків» з LightGBM) була застосована до двох найкращих базових моделей (TCN та LSTM) для фінального порівняння. Додатково було розроблено та протестовано методику оптимізації часу навчання шляхом відбору найважливіших ознак для моделі-коректора.

Для забезпечення статистичної значущості та надійності результатів застосовувалася 5-блокова перехресна валідація для часових рядів за принципом «ковзного вікна». Ефективність моделей оцінювалася за комплексом метрик:

- Середня абсолютна відсоткова помилка (MAPE): для оцінки загальної точності прогнозу.
- Середньоквадратична помилка (RMSE): для оцінки величини помилок.
- Peak Magnitude MAPE: спеціалізована метрика для оцінки точності прогнозування саме пікових навантажень.
- Час навчання: для оцінки обчислювальної ефективності моделей.

У ході дослідження було реалізовано та протестовано кілька архітектур глибокого навчання, що виступили як базові моделі для подальшої гібридизації.

Для моделі TCN (Темпоральна згорткова мережа) було використано архітектуру, що складається з одного блоку TCN з 64 фільтрами, розміром ядра 3 та факторами розширення (dilations) (1, 2, 4, 8), що дозволяє ефективно захоплювати залежності на різних часових масштабах. Після TCN-шару слідували два повнозв'язних шари (Dense) для формування фінального прогнозу.

В моделі LSTM (Мережа з довгою короткостроковою пам'яттю) було відтворено архітектуру, запропоновану в [21]. Вона складається з двох двонаправлених (Bidirectional) LSTM-шарів по 200 нейронів у кожному, між якими розташовані повнозв'язні шари. Для запобігання перенаванчання використовувався шар Dropout з коефіцієнтом 0.2.

Для підвищення точності базових моделей було реалізовано гібридний підхід, що поєднує модель глибокого навчання з моделлю-коректором на основі градієнтного бустингу LightGBM. Було протестовано дві стратегії гібридизації.

У стратегії «Коригування піків» (Peak Correction) використовувались дві окремі моделі LightGBM: класифікатор для прогнозування часового кроку добового піку (t_{pmax}) та регресор для прогнозування його величини (P_{max}). Отримані прогнози використовувались для точкової корекції прогнозу базової моделі.

Стратегія «Прогнозування залишків» (Residual Fitting) передбачала навчання моделі-коректора LightGBM на залишках (помилках) базової моделі. Фінальний прогноз формувався як сума прогнозу базової моделі та прогнозу залишків, що дозволяло коригувати всі систематичні помилки. Для підвищення ефективності та уникнення

проблем з оперативною пам'яттю було навчено 96 окремих «спеціалізованих» моделей LightGBM — по одній для кожного 15-хвилинного кроку прогнозу.

Загальна архітектура найбільш ефективного гібридного підходу представлена на Рис. 2.

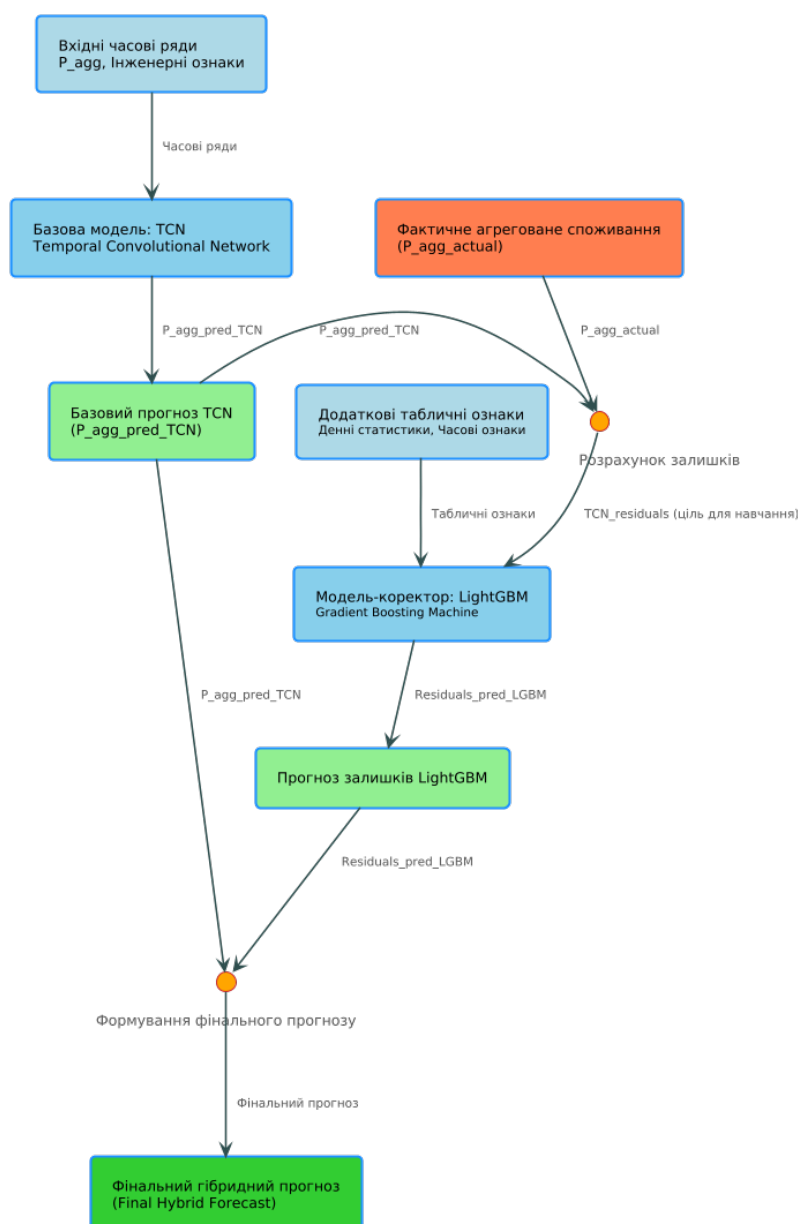


Рис. 2. Архітектура гібридної моделі на основі TCN та LightGBM зі стратегією «прогнозування залишків»

Усі нейронні мережі навчалися з використанням оптимізатора Adam зі швидкістю навчання 0.001 та функцією втрат 'mean_squared_error'. Для запобігання перенавчанню застосовувався механізм ранньої зупинки (EarlyStopping) з відстеженням помилки на валідаційному наборі (patience=5). Вхідна послідовність для всіх моделей складала 96 часових кроків (24 години), а горизонт прогнозування — 96 кроків.



РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

У даному розділі представлено аналіз та обґрунтування наукових результатів, отриманих у ході багатоетапного експериментального дослідження. Усі кількісні показники ефективності моделей зведено у Таблиці 1.

Таблиця 1

Зведені результати тестування моделей за ключовими метриками

Модель	MAPE, %	RMSE	Peak MAPE, %	Час навчання, сек
1D-CNN (Базова)	14.34 ± 1.65	2.0265 ± 0.3940	23.30 ± 6.07	14.30 ± 2.56
LSTM (Базова)	14.72 ± 2.23	2.0135 ± 0.3995	22.96 ± 5.89	68.32 ± 26.68
TCN (Базова)	15.07 ± 1.53	2.1202 ± 0.3480	22.83 ± 5.66	25.22 ± 7.86
TCN-LGBM (Кор. Піків)	13.43 ± 1.67	1.7871 ± 0.2148	21.75 ± 5.75	134.09 ± 100.80
TCN-XGBoost (Кор. піків)	14.68 ± 1.71	1.8941 ± 0.3432	22.34 ± 5.98	138.83 ± 86.09
TCN-LGBM (Прогн. залишків)	13.43 ± 0.97	1.7121 ± 0.1327	16.71 ± 2.49	305.72 ± 15.94
LSTM-LGBM (Прогн. залишків)	13.36 ± 0.88	1.6852 ± 0.1556	17.33 ± 2.39	370.73 ± 27.70
TCN-LGBM (Оптимізована)	13.82 ± 0.91	1.7504 ± 0.1421	16.77 ± 3.12	56.47 ± 6.71

На першому етапі дослідження було проведено порівняльний аналіз трьох базових архітектур глибокого навчання: 1D-CNN, LSTM та TCN. Метою було визначення найбільш продуктивних моделей для подальшої гібридизації.

Результати, представлені у Таблиці 1, показали, що модель TCN продемонструвала найкращий баланс між точністю та обчислювальною ефективністю, показавши найнижчу середню абсолютну відсоткову помилку (MAPE 14.61%) при помірному часі навчання (26.13 сек). Модель LSTM показала дещо кращий результат за метрикою RMSE (2.0249), однак її час навчання був у 2.5 рази більшим, ніж у TCN. Архітектура 1D-CNN, хоч і виявилася найшвидшою (13.59 сек), суттєво поступалася іншим моделям за всіма метриками точності. На основі цих даних для подальшого аналізу були обрані моделі TCN та LSTM як найбільш перспективні.

На другому етапі було протестовано дві стратегії гібридизації («коригування піків» та «прогнозування залишків») на основі найкращої базової моделі TCN.

Аналіз показав, що обидві стратегії дозволили покращити точність у порівнянні з базовою моделлю. Однак, стратегія «прогнозування залишків» виявилася значно ефективнішою. Модель TCN-LGBM (Прогн. залишків) показала кардинальне покращення точності прогнозування піків, знизивши показник Peak Magnitude MAPE з 22.40% у базової моделі до 16.71%. Це значно краще за результат найкращої моделі з «коригуванням піків» (TCN-LGBM (Кор. піків)), яка досягла показника 20.89%. Таким чином, стратегія «прогнозування залишків» з використанням LightGBM як моделі-коректора була визнана найбільш ефективною.

На фінальному етапі найефективніша гібридна стратегія була застосована до обох моделей-фіналістів, TCN та LSTM, що дозволило виявити дві високопродуктивні спеціалізовані конфігурації.



Гібрид LSTM-LGBM (Прогн. залишків) продемонстрував найвищу загальну точність, досягнувши найкращих показників за метриками MAPE (13.36%) та RMSE (1.6852).

Гібрид TCN-LGBM (Прогн. залишків) виявився лідером у прогнозуванні критичних пікових навантажень (Peak Magnitude MAPE 16.71% проти 17.33% у LSTM-гібрида), а також був на 21% швидшим у навчанні.

Перевага гібридних моделей у прогнозуванні піків наочно продемонстрована на Рис. 3, де видно суттєве зниження помилки для гібридних архітектур порівняно з базовими.




Рис. 3. Порівняння ефективності ключових моделей за метрикою Peak Magnitude MAPE

Візуальний аналіз прогнозів на день з високим піковим навантаженням (Рис. 4) підтверджує, що гібридні моделі значно точніше відтворюють реальну криву споживання в екстремальних умовах.




Рис. 4. Порівняння прогнозів гібридних моделей на день з високим піком



Ключовим результатом дослідження стала апробація методики оптимізації моделі-лідера за точністю піків. Шляхом відбору 100 найважливіших ознак для моделі-коректора було створено конфігурацію TCN-LGBM (Оптимізована). Це дозволило скоротити середній час навчання в 5.4 рази (з 305.72 до 56.47 секунд) при практично незмінній точності прогнозування піків (16.77% проти 16.71%). Даний компроміс між точністю та обчислювальною ефективністю наочно ілюструє Рис. 5, де оптимізована модель займає вигідну позицію, поєднуючи високу точність з низькими обчислювальними витратами.




Рис. 5. Компроміс між точністю прогнозування піків та часом навчання

Аналіз важливості ознак для моделі-коректора, представлений на Рис. 6, показав, що найбільший вплив на корекцію помилок мають статистичні показники споживання за попередній день (lag_1), зокрема максимальні та мінімальні значення як для агрегованого навантаження, так і для окремих «сигнальних» домогосподарств. Це підтверджує логічність та інтерпретованість гібридного підходу.




Рис. 6. Важливість 20 ключових ознак для моделі-коректора



ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У ході даного дослідження було проведено комплексний порівняльний аналіз гібридних моделей глибокого навчання для короткострокового прогнозування енергоспоживання в системах розумного будинку. На основі отриманих результатів було зроблено наступні висновки.

Експериментально підтверджено, що гібридні моделі, які поєднують архітектури глибокого навчання (TCN, LSTM) та моделі-коректори на основі градієнтного бустингу (LightGBM), демонструють значно вищу точність прогнозування порівняно з базовими моделями. Найбільш ефективною стратегією гібридизації виявилось «прогнозування залишків», яка дозволила суттєво покращити точність прогнозування критичних пікових навантажень.

Гібридна модель LSTM + LightGBM показала найвищу загальну точність (MAPE 13.36%, RMSE 1.6852) і є найкращим вибором для завдань, що вимагають мінімізації загальної помилки прогнозу.

Гібридна модель TCN + LightGBM виявилася лідером у прогнозуванні пікових навантажень (Peak Magnitude MAPE 16.71%) при менших на 21% витратах часу на навчання, що робить її пріоритетною для систем управління піковим попитом.

Розроблено методику оптимізації гібридної моделі шляхом відбору найважливіших ознак для моделі-коректора. Це дозволило створити збалансовану конфігурацію TCN + LightGBM (Optimized), яка навчається в 5.4 рази швидше за найточнішу модель, практично не втрачаючи в точності прогнозування піків (16.77% проти 16.71%).

Таким чином, дослідження надає практичну методологію для обґрунтованого вибору та конфігурації моделі прогнозування залежно від специфічних вимог системи розумного будинку.

Отримані результати та проведений аналіз літератури дозволяють визначити наступні перспективні напрямки для подальшої роботи:

– Враховуючи, що одним із виявлених прогалин є недостатня дослідженість моделей у режимі реального часу, перспективним напрямом є розробка механізмів інкрементального навчання для розроблених гібридних моделей, що дозволить їм швидко адаптуватися до змін у поведінці споживачів без повного перенавчання [18].

– Виявлена в огляді літератури проблема відсутності стандартизованих протоколів оцінки відкриває можливість для створення комплексного набору даних та методології тестування, що дозволить проводити більш об'єктивне порівняння різних архітектур прогнозування в майбутньому.

– Дослідження впливу різних наборів ознак (метеорологічні, економічні, соціальні) на точність та швидкість навчання оптимізованої моделі дозволить створити більш легкі та ефективні конфігурації для пристроїв з ультранизьким енергоспоживанням [11. 13].

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Abramov, V., Astafieva, M., Boiko, M., Bodnenko, D., Bushma, A., Vember, V., Hlushak, O., Zhylytsov, O., Ilich, L., Kobets, N., Kovaliuk, T., Kuchakovska, H., Lytvyn, O., Lytvyn, P., Mashkina, I., Morze, N., Nosenko, T., Proshkin, V., Radchenko, S., & Yaskevych, V. (2021). Theoretical and practical aspects of the use of mathematical methods and information technology in education and science. <https://doi.org/10.28925/9720213284km>
2. Bouzid, M., Amayri, M., & Bouguila, N. (2023). Addressing load forecasting challenges in industrial environments using time series deep models. Proceedings of the 1st International Conference on AI-Powered IoT for Sustainable Development. <https://doi.org/10.1145/3638209.3638218>



3. Chen, G., Ma, X., & Lin, W. (2024). Multifeature-based variational mode decomposition-temporal convolutional network-long short-term memory for short-term forecasting of the load of port power systems. *Sustainability*, 16(13), 5321. <https://doi.org/10.3390/su16135321>
4. Chen, Z. H., Zhang, R., Chen, Z., Zheng, Y., & Zhang, S. (2023). SCTCN-LightGBM: A hybrid learning method via transposed dimensionality-reduction convolution for loading measurement of industrial material. *Connection Science*. <https://doi.org/10.1080/09540091.2023.2278275>
5. Dai, S. (2023). Short-term load forecasting with deep learning techniques. *Journal of Physics: Conference Series*, 2547(1), 012025. <https://doi.org/10.1088/1742-6596/2547/1/012025>
6. Dakheel, F., & Çevik, M. (2025). Optimizing smart grid load forecasting via a hybrid long short-term memory-XGBoost framework: Enhancing accuracy, robustness, and energy management. *Energies*, 18(11), 2842. <https://doi.org/10.3390/en18112842>
7. Dong, S. (2023). Power load forecasting system based on deep hybrid learning model. *Advances in Engineering Technology Research*, 7(1), 518. <https://doi.org/10.56028/aetr.7.1.518.2023>
8. Gao, X., Song, D., Mao, Y., & He, L. (2024). Short-term load forecasting method with dynamic response to time-of-use electricity pricing. *2024 International Conference on Energy Storage Engineering and Power Systems*. <https://doi.org/10.1109/icesep62218.2024.10652197>
9. Gong, R., Wei, Z., Qin, Y., Liu, T., & Xu, J. (2024). Short-term electrical load forecasting based on IDBO-PTCN-GRU model. *Energies*, 17(18), 4667. <https://doi.org/10.3390/en17184667>
10. Hulak, H. M., Zhylytsov, O. B., Kyrychok, R. V., Korshun, N. V., & Skladannyi, P. M. (2023). Enterprise information and cyber security. Borys Grinchenko Kyiv Metropolitan University.
11. Han, H., Peng, J., Ma, J., Liu, H., & Liu, S. (2025). Research on load forecasting prediction model based on modified sand cat swarm optimization and self-attention TCN. *Symmetry*, 17(8), 1270. <https://doi.org/10.3390/sym17081270>
12. Heng, L., Cheng, H., & Liu, N. (2024). Load forecasting method based on CEEMDAN and TCN-LSTM. *PLOS ONE*, 19(7), e0300496. <https://doi.org/10.1371/journal.pone.0300496>
13. Huang, Y., Feng, Q. C., & Han, F. (2024). Short-term power load forecasting in China: A bi-SATCN neural network model based on VMD-SE. *PLOS ONE*, 19(9), e0311194. <https://doi.org/10.1371/journal.pone.0311194>
14. Khaldi, M. I., Sharma, S., Marken, G., & Singh, G. (2025). A TCN-driven framework for energy consumption prediction: The role of comprehensive feature engineering. *2025 5th International Conference on Computational Technology and Digital Convergence (ICCTDC)*. <https://doi.org/10.1109/icctdc64446.2025.11158750>
15. Kostiuk, Yu. V., Skladannyi, P. M., Bebesko, B. T., Khorolska, K. V., Rzaieva, S. L., & Vorokhob, M. V. (2025). Information and communication systems security. Borys Grinchenko Kyiv Metropolitan University.
16. Kostiuk, Yu. V., Skladannyi, P. M., Hulak, H. M., Bebesko, B. T., Khorolska, K. V., & Rzaieva, S. L. (2025). Information security systems. Borys Grinchenko Kyiv Metropolitan University.
17. Lara-Benítez, P., Carranza-García, M., Luna-Romera, J. M., & Riquelme, J. C. (2020). Temporal convolutional networks applied to energy-related time series forecasting. [Preprint]. <https://doi.org/10.20944/PREPRINTS202003.0096.V1>
18. Li, H., & Sun, J. (2022). A novel short-term load forecasting model by TCN-LSTM structure with attention mechanism. *2022 International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*. <https://doi.org/10.1109/MLBDBI58171.2022.00042>
19. Li, H., Li, S., Wu, Y., Xiao, Y., & Liu, M. (2024). Short-term power load forecasting for integrated energy system based on a residual and attentive LSTM-TCN hybrid network. *Frontiers in Energy Research*, 12. <https://doi.org/10.3389/fenrg.2024.1384142>
20. [14] Pelekis S.; Karakolis E.; Silva F.; Schoinas V.; Mouzakitis S.; Kormpakakis G. (2022). In search of deep learning architectures for load forecasting: A comparative analysis and the impact of the COVID-19 pandemic on model performance. *2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA)*. <https://doi.org/10.1109/iisa56318.2022.9904363>
21. Semmelmann, L., Henni, S., & Weinhardt, C. (2022). Load forecasting for energy communities: A novel LSTM-XGBoost hybrid model based on smart meter data. *Energy Informatics*, 5(Suppl 1), 24. <https://doi.org/10.1186/s42162-022-00212-9>
22. Torres, J. F., Jiménez-Navarro, M. J., Martínez-Álvarez, F., & Troncoso, A. (2021). Electricity consumption time series forecasting using temporal convolutional networks. *Lecture Notes in Computer Science*, 208-219. https://doi.org/10.1007/978-3-030-85713-4_21



23. Wang, Y., Chen, J., Chen, X., Zeng, X., Kong, Y., Sun, S., Guo, Y., & Liu, Y. (2021). Short-term load forecasting for industrial customers based on TCN-LightGBM. *IEEE Transactions on Power Systems*, 36(3), 1984–1997. <https://doi.org/10.1109/TPWRS.2020.3028133>
24. Zhebka, V., et al. (2021). Stability Method of Connectivity Automated Calculation for Heterogeneous Telecommunication Network. In *Workshop on Cybersecurity Providing in Information and Telecommunication Systems*. CEUR Workshop Proceedings, vol. 3188, (pp. 282–287).
25. Zhebka, V., et al. (2024). Methods for predicting failures in a smart home. In *Digital Economy Concepts and Technologies Workshop*. CEUR Workshop Proceedings, vol. 3665, (pp. 70–78).
26. Zhou, Y., Lin, Q., & Xiao, D. (2022). Application of LSTM-LightGBM nonlinear combined model to power load forecasting. *Journal of Physics: Conference Series*, 2294(1), 012035. <https://doi.org/10.1088/1742-6596/2294/1/012035>
27. Zuo K.; Integrated forecasting models based on LSTM and TCN for short-term electricity load forecasting. (2023). 2023 5th International Conference on Energy, Electrical and Power Engineering (CEEPE). <https://doi.org/10.1109/EECR56827.2023.10149951>

**Dmytro Nishchemenko**

Postgraduate Student, Lecturer

State University of Information and Communication Technologies, Kyiv, Ukraine

ORCID: 0009-0006-1781-4109

dima.nishchemenko@gmail.com

OPTIMIZATION OF HYBRID TCN, LSTM, AND LIGHTGBM MODELS FOR ENERGY CONSUMPTION FORECASTING IN SMART HOMES

Abstract. Accurate short-term load forecasting is a key task for effective energy resource management in smart home systems. Hybrid models that combine deep learning (DL) architectures and decision tree ensembles are a leading direction in modern research. An analysis of recent publications confirms that comparing Long Short-Term Memory (LSTM) and Temporal Convolutional Network (TCN) networks is a popular topic, and hybridization with LightGBM and the use of error correction strategies ("residual forecasting") are proven practices for improving accuracy. However, a literature review reveals several unresolved parts of the general problem: 1) the lack of a systematic analysis of the trade-off between forecast accuracy and computational cost (training time, resource requirements), which is critical for implementation on Internet of Things (IoT) devices; 2) insufficient research on the impact of feature engineering, particularly feature selection, on the computational efficiency of hybrid models; 3) a tendency to focus on accuracy metrics without providing practical methodologies for selecting the optimal model depending on the specific task. This work aims to fill these gaps. A multi-stage experimental analysis was implemented. Two hybridization strategies were tested for the selected models: "peak correction" and "residual forecasting." A methodology for optimizing training time by selecting the most important features for the corrector model was developed. To ensure the statistical significance of the results, time-series cross-validation was applied. The study confirmed that hybrid models significantly outperform base models, and the "residual forecasting" strategy is the most effective. Two high-performance specialized configurations were identified. The LSTM + LightGBM hybrid demonstrated the highest overall accuracy (MAPE 13.36%). At the same time, the TCN + LightGBM hybrid proved to be more effective in forecasting critical peak loads (Peak Magnitude MAPE 16.71%) and was 21% faster to train. A key result is the proposed methodology for optimizing the TCN + LightGBM model through feature selection, which allowed for a 5.4-fold speed-up in training while maintaining high peak forecasting accuracy (Peak MAPE 16.77%). The work fills the identified gaps in the literature by providing not only quantitative results but also a practical methodology for the informed selection of a forecasting architecture depending on the priority tasks of a smart home system: maximum overall accuracy, priority management of peak loads, or balanced performance for resource-constrained devices. The proposed optimized hybrid approach is promising for practical implementation in adaptive energy management systems due to its proven balance of high accuracy and low computational costs.

Keywords: load forecasting; smart home; hybrid models; deep learning; TCN; LSTM; LightGBM; optimization.

REFERENCES (TRANSLATED AND TRANSLITERATED)

1. Abramov, V., Astafieva, M., Boiko, M., Bodnenko, D., Bushma, A., Vember, V., Hlushak, O., Zhylytsov, O., Ilich, L., Kobets, N., Kovaliuk, T., Kuchakovska, H., Lytvyn, O., Lytvyn, P., Mashkina, I., Morze, N., Nosenko, T., Proshkin, V., Radchenko, S., & Yaskevych, V. (2021). Theoretical and practical aspects of the use of mathematical methods and information technology in education and science. <https://doi.org/10.28925/9720213284km>
2. Bouzid, M., Amayri, M., & Bouguila, N. (2023). Addressing load forecasting challenges in industrial environments using time series deep models. Proceedings of the 1st International Conference on AI-Powered IoT for Sustainable Development. <https://doi.org/10.1145/3638209.3638218>



3. Chen, G., Ma, X., & Lin, W. (2024). Multifeature-based variational mode decomposition-temporal convolutional network-long short-term memory for short-term forecasting of the load of port power systems. *Sustainability*, 16(13), 5321. <https://doi.org/10.3390/su16135321>
4. Chen, Z. H., Zhang, R., Chen, Z., Zheng, Y., & Zhang, S. (2023). SCTCN-LightGBM: A hybrid learning method via transposed dimensionality-reduction convolution for loading measurement of industrial material. *Connection Science*. <https://doi.org/10.1080/09540091.2023.2278275>
5. Dai, S. (2023). Short-term load forecasting with deep learning techniques. *Journal of Physics: Conference Series*, 2547(1), 012025. <https://doi.org/10.1088/1742-6596/2547/1/012025>
6. Dakheel, F., & Çevik, M. (2025). Optimizing smart grid load forecasting via a hybrid long short-term memory-XGBoost framework: Enhancing accuracy, robustness, and energy management. *Energies*, 18(11), 2842. <https://doi.org/10.3390/en18112842>
7. Dong, S. (2023). Power load forecasting system based on deep hybrid learning model. *Advances in Engineering Technology Research*, 7(1), 518. <https://doi.org/10.56028/aetr.7.1.518.2023>
8. Gao, X., Song, D., Mao, Y., & He, L. (2024). Short-term load forecasting method with dynamic response to time-of-use electricity pricing. *2024 International Conference on Energy Storage Engineering and Power Systems*. <https://doi.org/10.1109/icesep62218.2024.10652197>
9. Gong, R., Wei, Z., Qin, Y., Liu, T., & Xu, J. (2024). Short-term electrical load forecasting based on IDBO-PTCN-GRU model. *Energies*, 17(18), 4667. <https://doi.org/10.3390/en17184667>
10. Hulak, H. M., Zhyltsov, O. B., Kyrychok, R. V., Korshun, N. V., & Skladannyi, P. M. (2023). Enterprise information and cyber security. Borys Grinchenko Kyiv Metropolitan University.
11. Han, H., Peng, J., Ma, J., Liu, H., & Liu, S. (2025). Research on load forecasting prediction model based on modified sand cat swarm optimization and self-attention TCN. *Symmetry*, 17(8), 1270. <https://doi.org/10.3390/sym17081270>
12. Heng, L., Cheng, H., & Liu, N. (2024). Load forecasting method based on CEEMDAN and TCN-LSTM. *PLOS ONE*, 19(7), e0300496. <https://doi.org/10.1371/journal.pone.0300496>
13. Huang, Y., Feng, Q. C., & Han, F. (2024). Short-term power load forecasting in China: A bi-SATCN neural network model based on VMD-SE. *PLOS ONE*, 19(9), e0311194. <https://doi.org/10.1371/journal.pone.0311194>
14. Khaldi, M. I., Sharma, S., Marken, G., & Singh, G. (2025). A TCN-driven framework for energy consumption prediction: The role of comprehensive feature engineering. *2025 5th International Conference on Computational Technology and Digital Convergence (ICCTDC)*. <https://doi.org/10.1109/icctdc64446.2025.11158750>
15. Kostiuk, Yu. V., Skladannyi, P. M., Bebesko, B. T., Khorolska, K. V., Rzaieva, S. L., & Vorokhob, M. V. (2025). Information and communication systems security. Borys Grinchenko Kyiv Metropolitan University.
16. Kostiuk, Yu. V., Skladannyi, P. M., Hulak, H. M., Bebesko, B. T., Khorolska, K. V., & Rzaieva, S. L. (2025). Information security systems. Borys Grinchenko Kyiv Metropolitan University.
17. Lara-Benítez, P., Carranza-García, M., Luna-Romera, J. M., & Riquelme, J. C. (2020). Temporal convolutional networks applied to energy-related time series forecasting. [Preprint]. <https://doi.org/10.20944/PREPRINTS202003.0096.V1>
18. Li, H., & Sun, J. (2022). A novel short-term load forecasting model by TCN-LSTM structure with attention mechanism. *2022 International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*. <https://doi.org/10.1109/MLBDBI58171.2022.00042>
19. Li, H., Li, S., Wu, Y., Xiao, Y., & Liu, M. (2024). Short-term power load forecasting for integrated energy system based on a residual and attentive LSTM-TCN hybrid network. *Frontiers in Energy Research*, 12. <https://doi.org/10.3389/fenrg.2024.1384142>
20. Pelekis S.; Karakolis E.; Silva F.; Schoinas V.; Mouzakitis S.; Kormpakis G. (2022). In search of deep learning architectures for load forecasting: A comparative analysis and the impact of the COVID-19 pandemic on model performance. *2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA)*. <https://doi.org/10.1109/iisa56318.2022.9904363>
21. Semmelmann, L., Henni, S., & Weinhardt, C. (2022). Load forecasting for energy communities: A novel LSTM-XGBoost hybrid model based on smart meter data. *Energy Informatics*, 5(Suppl 1), 24. <https://doi.org/10.1186/s42162-022-00212-9>
22. Torres, J. F., Jiménez-Navarro, M. J., Martínez-Álvarez, F., & Troncoso, A. (2021). Electricity consumption time series forecasting using temporal convolutional networks. *Lecture Notes in Computer Science*, 208-219. https://doi.org/10.1007/978-3-030-85713-4_21



23. Wang, Y., Chen, J., Chen, X., Zeng, X., Kong, Y., Sun, S., Guo, Y., & Liu, Y. (2021). Short-term load forecasting for industrial customers based on TCN-LightGBM. *IEEE Transactions on Power Systems*, 36(3), 1984–1997. <https://doi.org/10.1109/TPWRS.2020.3028133>
24. Zhebka, V., et al. (2021). Stability Method of Connectivity Automated Calculation for Heterogeneous Telecommunication Network. In *Workshop on Cybersecurity Providing in Information and Telecommunication Systems*. CEUR Workshop Proceedings, vol. 3188, (pp. 282–287).
25. Zhebka, V., et al. (2024). Methods for predicting failures in a smart home. In *Digital Economy Concepts and Technologies Workshop*. CEUR Workshop Proceedings, vol. 3665, (pp. 70–78).
26. Zhou, Y., Lin, Q., & Xiao, D. (2022). Application of LSTM-LightGBM nonlinear combined model to power load forecasting. *Journal of Physics: Conference Series*, 2294(1), 012035. <https://doi.org/10.1088/1742-6596/2294/1/012035>
27. Zuo K.; Integrated forecasting models based on LSTM and TCN for short-term electricity load forecasting. (2023). 2023 5th International Conference on Energy, Electrical and Power Engineering (CEEPE). <https://doi.org/10.1109/EECR56827.2023.10149951>

