

УДК 004.8:519.246

DOI <https://doi.org/10.36994/2788-5518-2025-02-10-17>

КЛАСИЧНІ ТА ГІБРИДНІ МЕТОДИ ПРОГНОЗУВАННЯ ДАНИХ ЛІЧИЛЬНИКІВ ЗІ СПОЖИВАННЯ РЕСУРСІВ

Фуріхата Д. В., аспірант кафедри інженерії програмного забезпечення факультету, Державний університет «Житомирська політехніка», Житомир, Україна. <https://orcid.org/0000-0002-6093-664X>, fyrihata.denus@gmail.com

Вакалюк Т. А., д. пед. н., проф., завідувач кафедри інженерії програмного забезпечення, Державний університет «Житомирська політехніка», Житомир, Україна. <https://orcid.org/0000-0001-6825-4697>, tetianavakaliuk@gmail.com

Анотація. У статті проведено комплексний аналіз сучасних методів прогнозування споживання ресурсів на основі даних з лічильників, що набуває критичного значення для ефективного управління енергетичними та комунальними системами, особливо в умовах пошкодженої інфраструктури України. Досліджено три основні класи методів: традиційні статистичні моделі (ARIMA, SARIMA), евристичну модель Prophet, методи глибокого навчання (LSTM, RNN), а також гібридні підходи, що поєднують переваги різних методологій.

Виявлено, що класичні моделі ARIMA/SARIMA ефективні для короткострокового прогнозування стаціонарних рядів з лінійною структурою та чіткою сезонністю, забезпечуючи високу інтерпретованість результатів та можливість роботи з обмеженими обсягами даних. Проте ці моделі демонструють суттєві обмеження при роботі з нелінійними залежностями та динамічними змінами в структурі даних, що знижує точність прогнозів у складних реальних сценаріях. Модель Prophet демонструє переваги в автоматизації процесу моделювання, врахуванні календарних ефектів і свят, однак залишає невикористаною інформацію в автокорельованих залишках, що обмежує її застосування в завданнях, де критична максимальна точність.

Моделі LSTM показують найвищу точність при прогнозуванні складних нелінійних патернів завдяки механізму довгострокової пам'яті та здатності автоматично виявляти приховані залежності у даних. Експериментальні дослідження підтверджують суттєве підвищення точності порівняно з традиційними методами, особливо за наявності великих обсягів даних. Особливу увагу приділено гібридним підходам (ARIMA-LSTM, Prophet-LSTM), що поєднують інтерпретованість статистичних методів з потужністю нейромереж, забезпечуючи найвищу точність прогнозування. Результати дослідження мають практичне значення для оптимізації управління енергетичними ресурсами в умовах пошкодженої інфраструктури та можуть бути використані для розробки адаптивних систем прогнозування.

Ключові слова: часові ряди, прогнозування споживання, ARIMA, SARIMA, Prophet, LSTM, рекурентні нейронні мережі, гібридні моделі, глибоке навчання, лічильники ресурсів.

CLASSICAL AND HYBRID METHODS FOR FORECASTING RESOURCE CONSUMPTION METER DATA

Denys Furikhata, postgraduate student of the Department of Software Engineering, State University "Zhytomyr Polytechnic", Zhytomyr, Ukraine. <https://orcid.org/0000-0002-6093-664X>, fyrihata.denus@gmail.com

Tetiana Vakaliuk, Dr. Ped. Sc., Prof., Head of the Department of Software Engineering, State University "Zhytomyr Polytechnic", Zhytomyr, Ukraine. <https://orcid.org/0000-0001-6825-4697>, tetianavakaliuk@gmail.com

Abstract. The article provides a comprehensive analysis of modern methods for forecasting resource consumption based on meter data, which is critical for the effective management of energy and utility systems, especially in the context of Ukraine's damaged infrastructure. Three main classes of methods are investigated: traditional statistical models (ARIMA, SARIMA), the Prophet heuristic model, deep learning methods (LSTM, RNN), as well as hybrid approaches that combine the advantages of different methodologies.

It was found that classical ARIMA/SARIMA models are effective for short-term forecasting of stationary series with a linear structure and clear seasonality, providing high interpretability of results and the ability to work with limited amounts of data. However, these models have significant limitations when working with nonlinear dependencies and dynamic changes in data structure, which reduces the accuracy of forecasts in complex real-world scenarios. The Prophet model demonstrates advantages in automating the modeling

process and accounting for calendar effects and holidays, but leaves unused information in autocorrelated residuals, which limits its application in tasks where maximum accuracy is critical.

LSTM models show the highest accuracy in predicting complex nonlinear patterns thanks to their long-term memory mechanism and ability to automatically detect hidden dependencies in data. Experimental studies confirm a significant increase in accuracy compared to traditional methods, especially when large amounts of data are available. Particular attention is paid to hybrid approaches (ARIMA-LSTM, Prophet-LSTM), which combine the interpretability of statistical methods with the power of neural networks, ensuring the highest prediction accuracy. The results of the study are of practical importance for optimizing energy resource management in conditions of damaged infrastructure and can be used to develop adaptive forecasting systems.

Key words: time series, consumption forecasting, ARIMA, SARIMA, Prophet, LSTM, recurrent neural networks, hybrid models, deep learning, resource meters.

Вступ

Прогнозування споживання ресурсів на основі даних з лічильників набуває критичного значення для забезпечення ефективного функціонування енергетичних, водопостачальних та комунальних систем. Точне передбачення майбутнього попиту дозволяє оптимізувати розподіл ресурсів, знижувати операційні витрати, попереджувати аварійні ситуації та підвищувати загальну надійність інфраструктурних мереж. Особливої актуальності ця проблема набула в контексті глобальних викликів, пов'язаних зі зміною клімату, зростанням енергоспоживання та необхідністю переходу до сталого розвитку. В Україні, особливо в умовах воєнного стану та пошкодженої енергетичної інфраструктури, питання точного прогнозування споживання стає питанням національної безпеки та економічної стабільності.

Традиційні статистичні методи прогнозування, такі як ARIMA та SARIMA, хоча і залишаються популярними завдяки своїй інтерпретованості, виявляють суттєві обмеження при роботі зі складними нелінійними залежностями та багатофакторними впливами. Водночас, стрімкий розвиток технологій глибокого навчання відкриває нові можливості для підвищення точності прогнозів через застосування рекурентних нейронних мереж, зокрема LSTM. Проте питання вибору оптимального методу для конкретних умов застосування залишається відкритим і потребує комплексного наукового аналізу. Крім того, зростання обсягів даних, що генеруються сучасними системами обліку (розумні лічильники, IoT-пристрої), вимагає розробки ефективних методів їх обробки та аналізу.

Аналіз останніх джерел та публікацій

Останніми роками класичні та гібридні методи прогнозування часових розглядаються як вітчизняними, так і закордонними вченими. Так, у статті [4] розглянуто три основні підходи до прогнозування часових рядів: ARIMA, SARIMA та Prophet. Модель ARIMA добре працює зі стаціонарними даними, враховує автокореляції та лінійні залежності, однак виявляє обмеження у випадках, коли дані мають виражену сезонність. Розширенням цього підходу є SARIMA, яка завдяки додатковим параметрам дозволяє ефективніше моделювати циклічні та сезонні компоненти, проте вимагає більшої складності у налаштуванні. На відміну від них, Prophet, розроблений Facebook, ґрунтується на адитивній моделі з трендом, сезонністю, впливом свят та випадковим шумом [1]. Він автоматично враховує кілька сезонних компонентів, дозволяє швидко отримати прогнози без глибокого налаштування параметрів та ефективно опрацьовує складні часові ряди, що містять як тренди, так і нерегулярні події. Автори вказали, що Prophet продемонстрував найкращі результати серед розглянутих моделей завдяки здатності автоматично враховувати нелінійні тренди, багатосезонність і святкові ефекти [4].

В схожому дослідженні [7], але у сфері електричних показів, класична модель ARIMA виявилася менш ефективною для короткострокового прогнозування електричних навантажень, оскільки вона чутлива до аномалій і не здатна якісно відображати різкі зміни в даних. Натомість модель LSTM продемонструвала значно вищу точність завдяки здатності враховувати нелінійні залежності та виявляти складні патерни, проте її результативність суттєво залежить від обсягу та якості вхідних даних. Найкращі результати показала гібридна модель ARIMA-LSTM, яка об'єднала сильні сторони обох підходів, оскільки ARIMA забезпечила коректне відображення загального тренду, тоді як LSTM поліпшила прогнозування пікових і нестабільних значень. Це дозволило зменшити похибки та підвищити стійкість прогнозу до шуму, що робить ARIMA-LSTM найбільш придатним методом для практичного застосування в енергосистемах.

Дослідження виключно по нейронних мережах [2] показало, що використання глибоких рекурентних моделей, зокрема LSTM, забезпечує істотно кращі результати в короткостроковому прогнозуванні навантажень у порівнянні з класичними нейронними мережами. LSTM завдяки механізму пам'яті ефективно відображає як короткострокові, так і довгострокові залежності, що робить її оптимальною для прогнозування в умовах сезонних і добових коливань попиту. Водночас RNN також показує добрі результати, хоча й поступається LSTM за точністю. Включення додаткових факторів (погодних умов, типу дня та часу доби) підвищує якість прогнозів. Загалом дослідження [2] підкреслює, що LSTM є найефективнішим інструментом для задач короткострокового прогнозування енергоспоживання,

тоді як класичні RNN можуть бути використані як базовий орієнтир, але не відповідають сучасним вимогам до точності.

Отже, прогнозування майбутніх значень на основі часових рядів є критично важливим для прийняття рішень у різних галузях. Цей процес вимагає глибокого розуміння природи даних, що характеризуються послідовним часовим порядком, наявністю трендів (довгострокові зміни), сезонності (повторювані патерни), циклічності (нерегулярні коливання) та випадкового шуму (залишки).

Тому, метою статті є огляд класичних статистичних моделей (ARIMA/SARIMA), евристичних процедур (Prophet) та сучасних моделей глибокого навчання (LSTM, RNN, CNN) для прогнозування даних з часовими рядами.

Дослідження

Існує широкий спектр підходів до прогнозування споживання в лічильниках. Аналіз джерел дав змогу узагальнити їх у вигляді моделі наявних методів та алгоритмів для прогнозування даних [2; 4; 7] (див. рис. 1). Розглянемо їх детально.




Рис. 1. Узагальнена класифікація методів прогнозування даних.

Традиційні статистичні моделі (ARIMA, SARIMA). Моделі ARIMA (Autoregressive Integrated Moving Average) та SARIMA (Seasonal ARIMA) є класичними лінійними статистичними підходами, що десятиліттями використовуються для аналізу та прогнозування часових рядів. Модель ARIMA ґрунтується на трьох основних компонентах: авторегресії (AR), що використовує минулі значення для прогнозування, інтеграції (I), що застосовує диференціювання для досягнення стаціонарності даних та ковзного середнього (MA), що враховує минулі помилки прогнозування [8]. SARIMA є розширенням ARIMA, що додає сезонні компоненти для моделювання періодичних патернів у даних [4]. До основних переваг цих моделей відносяться їхня інтерпретовність та ефективність.

Традиційні статистичні моделі ARIMA та SARIMA є класичними інструментами прогнозування часових рядів. ARIMA-модель (авторегресійна інтегрована модель ковзного середнього) застосовується для аналізу даних з інтегрованою різницею та ковзним середнім.

Модель характеризується трьома основними параметрами: оператором зсуву, параметрами моделі та випадковим шумом. Ці параметри можна представити у канонічній формі авторегресійно-ковзного середнього [8].

Для врахування сезонності застосовується модель SARIMA, яка є розширенням базової моделі ARIMA. До неї додаються сезонні параметри з періодом для сезонної авторегресії, різниці та ковзного

середнього відповідно. Математично модель записується через поліноми сезонних параметрів. Ідентифікація моделі здійснюється за допомогою аналізу графіків автокореляційної та часткової автокореляційної функцій або шляхом застосування інформаційних критеріїв. Оцінка параметрів проводиться методом максимальної правдоподібності, а перевірка адекватності моделі – через аналіз автокореляції залишків [4].

Узагальнюючи математичну модель, автори [7] наводять схему алгоритму роботи моделі ARIMA (див. рис. 2). Згідно з цим алгоритмом спостерігається покроковий процес створення прогнозової моделі ARIMA. На першому етапі за допомогою статистичного тесту перевіряється стаціонарність даних, тобто встановлюється наявність стабільних статистичних характеристик у часі. У разі не-стаціонарності даних застосовується метод диференціювання для приведення їх до стаціонарного вигляду. На наступному етапі здійснюється визначення параметрів моделі. Для цього аналізуються два графіки: діаграма автокореляційної функції та діаграма часткової автокореляційної функції. Ці візуалізації сприяють виявленню внутрішньої структури даних і дозволяють підібрати оптимальні параметри для моделі. На завершальному етапі для вибору найкращої з альтернативних моделей застосовується інформаційний критерій Байєса. Модель, що характеризується найменшим значенням цього критерію, визнається найефективнішою і обирається як остаточна для побудови прогнозів.




Рис. 2. Схему алгоритму роботи моделі ARIMA [7]

Попри свою популярність, моделі ARIMA/SARIMA мають значні наукові обмеження. Головний недолік полягає в їхньому припущенні про лінійні взаємозв'язки між змінними [4]. Це робить їх неефективними для моделювання складних нелінійних патернів, що є поширеними у реальних даних, наприклад, у прогнозуванні попиту на електроенергію, що залежить від динамічних та нелінійних факторів, таких як погодні умови чи економічна активність.

Обмеження ARIMA/SARIMA стали рушійною силою для розвитку гібридних моделей. Адже більшість реальних часових рядів містять як лінійні, так і нелінійні патерни. Один з відомих підходів полягає у моделюванні лінійної частини даних (тренди та сезонність), з подальшою передачею залишків, що містять нелінійні патерни, нелінійній моделі для подальшого аналізу та прогнозування [7]. Таким чином, нелінійна модель фокусується виключно на патернах, пропущених лінійним підходом, що призводить до значного підвищення загальної точності.

Прогностична модель Prophet – розроблена Facebook, є прогностичною моделлю, що ґрунтується на регресійній моделі та розкладає часовий ряд на три основні компоненти: тренд, сезонність (річну, тижневу, денну) та свята. Тренд може бути лінійним або логістичним, а сезонність моделюється за допомогою рядів Фур'є [4].

Модель була розроблена для бізнес-користувачів і вимагає мінімального досвіду в аналізі часових рядів, що робить її надзвичайно зручним інструментом [1]. Prophet автоматично обробляє пропущені значення, викиди та зміни трендів, що значно спрощує етап попередньої обробки даних [6]. Крім того, модель легко дозволяє включати зовнішні фактори, такі як свята та спеціальні події, через «додаткові регресори» [1].

Prophet фокусує увагу на декомпозиції ряду. Спочатку він підлаштовує глобальний тренд $g(t)$ (з можливими логістичними обмеженнями), відокремлює компонент сезонності $s(t)$ за допомогою Фур'є-базисів та додає фіксовані ефекти $h(t)$. Така структура робить модель частково інтерпретованою, оскільки можна окремо розглядати тренд та внесок сезонностей/свят [1; 4]. Після оцінки ці компоненти екстраполюються на майбутнє, після чого сумуються для отримання прогнозу. Модель Prophet можна записати як:

$$y_t = g(t) + s(t) + h(t) + \varepsilon_t,$$

де $g(t)$ – тренд (тут рісесевіс-лінійний або логістичний), $s(t)$ – сумарна сезонна компонента (різні періодичності), $h(t)$ – ефект свят / спеціальних подій, а ε_t – шум. Точки змінного тренду підбираються автоматично, або задаються вручну, а за потреби $g(t)$ може бути логістичним зі строгим насичен-

ням. Сезонність $s(t)$ задається набором тригонометричних базисів для річних, тижневих та інших циклів (за замовчуванням порядок 10 для року, 3 – для тижня). Оцінка моделі проводиться байєсівським методом, що автоматично налаштовує чутливість до змін тренду та інших параметрів [1]. Дослідження показують, що, попри ефективне моделювання трендів та сезонності, залишки моделі Prophet часто містять патерни, що свідчать про наявність невивчених залежностей між послідовними помилками [7].

Це означає, що модель може ігнорувати інформацію, що міститься у нелінійних та автокорельованих помилках [7]. Як наслідок, для досягнення найвищої точності її часто потрібно комбінувати з іншими, більш технічно складними методами.

Моделі глибокого навчання, такі як LSTM (Long Short-Term Memory), RNN (Recurrent Neural Networks) та CNN (Convolutional Neural Networks), розвинули прогнозування часових рядів, оскільки вони здатні автоматично вивчати складні, нелінійні залежності без ручного відбору ознак. RNN є фундаментальною архітектурою для послідовних даних, але залежить від проблеми зникаючого градієнта, що перешкоджає моделюванню довгострокових залежностей. LSTM – це різновид рекурентних нейронних мереж, створений для подолання проблеми затухання градієнта та забезпечення довготривалої пам'яті [2].

LSTM – це глибока нейронна мережа, що обробляє часову послідовність по кроках. На відміну від традиційного ARIMA, LSTM «вчиться» прямо на вхідних даних, без явного розділення на тренд чи сезонність. Зазвичай мережа складається з одного або кількох шарів LSTM, за якими слідує щільний шар для прогнозу. Вхід може містити кілька вхідних ознак (наприклад, попередні витрати, температуру тощо). Після навчання мережа прогнозує наступні значення послідовності, використовуючи свої збережені ваги. LSTM відрізняються великою гнучкістю, адже вони можуть захоплювати складні нелінійні залежності у даних і «пам'ятати» тривалі часові зв'язки [3]. Також LSTM підтримують онлайн-оновлення, що полягає у тому, що ваги мережі можна підлаштовувати по мірі надходження нових даних, а також використовувати перенавчання (transfer learning) на схожих задачах [3]. Дослідження показують, що LSTM можуть добре навчатися навіть на відносно невеликому обсязі даних (кілька днів чи тижнів спостережень достатньо для «розігріву» моделі), а також зазвичай забезпечують вищу точність прогнозів порівняно з простими моделями чи однорівневими RNN [5]. Зокрема, у задачі короткострокового прогнозу енергоспоживання LSTM давали менші помилки, ніж звичайні RNN [5], а у прогнозуванні водоспоживання LSTM показали найкращі результати серед традиційних методів [3]. LSTM можуть вивчати нелінійні ефекти, включно з багаторазовими сезонностями чи впливом додаткових ознак.

Гібридні моделі поєднують сильні сторони різних підходів, зазвичай – статистичних і нейромережних. Зокрема, дієвим поєднанням ARIMA (SARIMA) з LSTM чи Prophet з LSTM. У відповідності до даного алгоритму спочатку окреслюється лінійна складова ряду за допомогою ARIMA, після чого залишки моделі (невраховані нерегулярні коливання) прогнозуються LSTM. Сукупний прогноз отримується як сума прогнозу ARIMA та поправок LSTM. Такий підхід дозволяє ARIMA захопити тренд та сезонність, а LSTM – нелінійну флуктуацію. У дослідженні [6] <https://www.mdpi.com/1996-1073/16/12/4739-#:~:text=combined%20to%20provide%20the%20final,90%2C%20respectively> на прикладі пікового споживання електроенергії гібридна модель ARIMA-LSTM дала кращі результати (RMSE гібриду становив 7.35, тоді як ARIMA – 49.90, LSTM – 18.74) [6].

Інша гібридна модель Prophet+LSTM працює аналогічно, спочатку Prophet моделює тренд, сезонність і ефекти свят, потім LSTM навчається на залишках після віднімання прогнозу Prophet [1]. В гібридній моделі Prophet+LSTM тренд і сезонність моделі стають прозорими (як у Prophet), а їх результати доповнюються «інтелектом» нейромережі для нестандартних коливань [1].

Гібридна модель може забезпечити вищу точність прогнозу, комбінуючи переваги обох методів. За рахунок ARIMA/Prophet вона не втрачає інтерпретованості щодо основних компонент, а LSTM дає змогу моделювати складні залишкові патерни. Науковці довели, що гібридні моделі часто перевершують одиночні моделі (згаданий ARIMA-LSTM дав помітний приріст точності) [6]. Однак гібридні моделі значно складніші і ресурсомісткіші у реалізації, оскільки потрібно тренувати дві моделі, що вимагає більше обчислень. Вибір структури гібриду (послідовний чи паралельний) та баланс ваг може додатково ускладнити налаштування.

Гібридні моделі часто застосовують у задачах прогнозування енергоспоживання, де потрібна висока точність. Так, ARIMA+LSTM успішно використано для прогнозу пікових навантажень електромереж [6]. Пропозиції Prophet+LSTM з'являються у задачах, де важливі як календарні ефекти, так і складні залишки (наприклад, у прогнозуванні попиту на пропускну спроможність у веб-сервісах) [1]. Гібридні моделі доцільно застосовувати, коли є помітна лінійна складова (яку варто виділити) та одночасно необхідно моделювати складніші залежності. При цьому слід пам'ятати про збільшені обчислювальні витрати і необхідність узгодження двох частин моделі.

Узагальнена класифікація гібридних моделей на основі Prophet представлена на рис. 3.




Рис. 3. Класифікація гібридних моделей на основі Prophet

Висновки. Проведене дослідження методів прогнозування даних з лічильників дозволяє стверджувати, що вибір оптимального підходу залежить від специфіки конкретного завдання, характеристик вхідних даних та вимог до точності та інтерпретованості результатів. Класичні статистичні моделі ARIMA та SARIMA залишаються ефективним інструментом для короткострокового прогнозування стаціонарних часових рядів з чіткою лінійною структурою та сезонністю. Їхня головна перевага полягає у високому рівні інтерпретованості та можливості роботи з відносно невеликими обсягами даних, що робить їх придатними для застосування в умовах обмежених обчислювальних ресурсів. Модель Prophet демонструє значні переваги як практичний інструмент для бізнес-застосувань завдяки автоматизації процесу моделювання та можливості врахування впливу календарних подій і свят. Моделі глибокого навчання, зокрема LSTM, відкривають якісно нові можливості для прогнозування складних нелінійних часових рядів завдяки здатності автоматично виявляти приховані патерни та враховувати довгострокові залежності.

Особливої уваги заслуговують гібридні підходи, що поєднують сильні сторони різних методологій. Комбінація ARIMA та LSTM або Prophet і LSTM дозволяє використовувати переваги статистичних моделей для виявлення глобальних трендів і сезонності з одночасним застосуванням потужності нейронних мереж для моделювання складних нелінійних залишків. Дослідження демонструють, що гібридні моделі забезпечують найвищу точність прогнозування, хоча й ціною підвищеної обчислювальної складності та ускладненого процесу розробки й підтримки моделей.

В контексті українських реалій, зокрема необхідності ефективного управління енергетичними ресурсами в умовах пошкодженої інфраструктури, питання вибору методу прогнозування набуває критичного значення.

Подальші дослідження можуть бути спрямовані на розробку адаптивних систем прогнозування, здатних автоматично обирати оптимальний метод залежно від характеристик вхідних даних та поточних умов функціонування системи.

Література

1. Guruge Pasan Bhanu, Priyadarshana Y. H. P. P. Time series forecasting-based Kubernetes autoscaling using Facebook Prophet and Long Short-Term Memory. *Frontiers in Computer Science*. 2025. Vol. 7. DOI: 10.3389/fcomp.2025.1509165.
2. Islam, Badar ul, Ahmed, Shams Forruque. Short-Term Electrical Load Demand Forecasting Based on LSTM and RNN Deep Neural Networks. *Mathematical Problems in Engineering*. 2022. Vol. 2022. Article ID 2316474. DOI: 10.1155/2022/2316474.
3. Kühnert C., Gonuguntla N. M., Krieg H., Nowak D., Thomas J. A. (2021). Application of LSTM Networks for Water Demand Prediction in Optimal Pump Control. *Water*. 2021. Vol. 13. No. 5. Article ID 644. DOI: 10.3390/w13050644.
4. Kwarteng S. B., Andreevich P. A. Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting. *Research & Development*. 2024. Vol. 5, No. 4. P. 110–120. DOI: 10.11648/j.rd.20240504.13.
5. Mahjoub S., Chrifi-Alaoui L., Marhic B., Delahoche L. (2022). Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks *Sensors*. 2022. Vol. 22. No. 11. Article ID. 4062. DOI: 10.3390/s22114062.

6. Pierre A. A., Akim S. A., Semeny A. K., Babiga B. (2023). Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches. *Energies*. 2023. Vol. 16. No. 12. Article ID 4739. DOI: 10.3390/en16124739.
7. Ruiyan Zhou, Xingchen Zhang. Short-term power load forecasting based on ARIMA-LSTM. *Journal of Physics: Conference Series*. 2024. Vol. 2803. Article ID 012002. DOI: 10.1088/1742-6596/2803/1/012002.
8. Samuel John Parreño. Forecasting Electricity Consumption in the Philippines Using ARIMA Models. *International Journal of Machine Learning and Computing*. 2022. Vol. 12. No. 6. P. 279–285. DOI: 10.18178/ijmlc.2022.12.6.1112.
9. Wang W., Shao J., Jumahong H. Fuzzy inference-based LSTM for long-term time series prediction. *Scientific Reports*. 2023. Vol. 13. Article ID 20359. DOI: 10.1038/s41598-023-47812-3.

References

1. Guruge P. B., Priyadarshana Y. H. P. P. (2025). Time series forecasting-based Kubernetes autoscaling using Facebook Prophet and Long Short-Term Memory. *Frontiers in Computer Science*. 7. DOI: <https://doi.org/10.3389/fcomp.2025.1509165>.
2. Islam B. U., Ahmed S. F. (2022). Short-term electrical load demand forecasting based on LSTM and RNN deep neural networks. *Mathematical Problems in Engineering*. 2022. Article 2316474. DOI: <https://doi.org/10.1155/2022/2316474>.
3. Kühnert C., Gonuguntla N. M., Krieg H., Nowak D., Thomas J. A. (2021). Application of LSTM networks for water demand prediction in optimal pump control. *Water*. 13 (5). 644. DOI: <https://doi.org/10.3390/w13050644>.
4. Kwarteng S. B., Andreevich P. A. (2024). Comparative analysis of ARIMA, SARIMA and Prophet model in forecasting. *Research & Development*. 5 (4). 110–120. DOI: <https://doi.org/10.11648/j.rd.20240504.13>.
5. Mahjoub S., Chrifi-Alaoui L., Marhic B., Delahoche L. (2022). Predicting energy consumption using LSTM, multi-layer GRU and Drop-GRU neural networks. *Sensors*. 22 (11). 4062. DOI: <https://doi.org/10.3390/s22114062>.
6. Pierre A. A., Akim S. A., Semeny A. K., Babiga B. (2023). Peak electrical energy consumption prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU approaches. *Energies*. 16 (12). 4739. DOI: <https://doi.org/10.3390/en16124739>.
7. Zhou R., Zhang X. (2024). Short-term power load forecasting based on ARIMA-LSTM. *Journal of Physics: Conference Series*. 2803, 012002. DOI: <https://doi.org/10.1088/1742-6596/2803/1/012002>.
8. Parreño S. J. (2022). Forecasting electricity consumption in the Philippines using ARIMA models. *International Journal of Machine Learning and Computing*. 12 (6). 279–285. DOI: <https://doi.org/10.18178/ijmlc.2022.12.6.1112>.
9. Wang W., Shao J., Jumahong H. (2023). Fuzzy inference-based LSTM for long-term time series prediction. *Scientific Reports*. 13. Article 20359. DOI: <https://doi.org/10.1038/s41598-023-47812-3>.

Дата першого надходження статті до видання: 20.10.2025

Дата прийняття статті до друку після рецензування: 24.11.2025

Дата публікації (оприлюднення) статті: 26.12.2025