

УДК 004.9+578.834.1

**А. В. Лосенко; О.М. Козачко, канд. техн. наук, доц.;**  
**І. В. Варчук, канд. техн. наук, доц.**

## **НЕЙРОМЕРЕЖЕВИЙ АНСАМБЛЬ ДЛЯ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ НА ОСНОВІ PROPHET ТА LSTM**

*У статті розглядається застосування моделей машинного навчання для оптимізації прогнозування часових рядів, що є актуальним завданням у багатьох галузях, включаючи охорону здоров'я. Особлива увага приділяється використанню моделі Prophet у поєднанні з ансамблевими методами, такими як моделі машинного навчання на основі нейронних мереж, зокрема LSTM, GRU, а також інших рекурентних нейронних мереж, для створення високоточного прогнозування кількості хворих на COVID-19 в Україні протягом 2020 – 2022 років.*

*Прогнозування часових рядів є важливим інструментом для аналізу та моделювання тенденцій, які мають складну природу залежностей. Наприклад, у сфері охорони здоров'я прогнозування кількості хворих дозволяє заздалегідь оцінити навантаження на систему охорони здоров'я та планувати відповідні ресурси. У цьому контексті використання моделей, які здатні враховувати як короткострокові, так і довгострокові тренди, є критично важливим. Prophet, відомий своєю здатністю точно моделювати сезонні компоненти, доповнюється потужністю LSTM для обробки нелінійних залежностей, що забезпечує значне покращення точності прогнозів.*

*Додатково у статті розглядається можливість використання гібридних підходів, які комбінують результати традиційних методів і моделей глибокого навчання. Такий підхід дозволяє враховувати складні закономірності у часових рядах, які не завжди можуть бути повністю враховані однією моделлю. Гібридні підходи забезпечують багаторівневий аналіз даних, де статистичні методи, такі як Prophet, моделюють основні тренди та сезонність, тоді як глибокі нейронні мережі, наприклад LSTM, обробляють нелінійні та короткострокові залежності.*

*Результати дослідження можуть бути використані для аналізу інших часових рядів, що робить запропонований підхід універсальним та перспективним для подальшого розвитку.*

**Ключові слова:** інформаційна технологія, машинне навчання, нейронні мережі, прогнозування часових рядів, Prophet, COVID-19.

### **Вступ та постановка задачі**

У сучасному світі прогнозування часових рядів відіграє критично важливу роль у багатьох сферах, таких як економіка, енергетика, кліматологія та, особливо, епідеміологія. Зростання складності систем і обсягу доступних даних робить використання алгоритмів машинного навчання необхідним для досягнення високої точності прогнозів. Зокрема, пандемія COVID-19 підкреслила значущість надійних моделей прогнозування, які можуть підтримувати оперативне прийняття рішень у сфері охорони здоров'я, оптимізацію ресурсів та впровадження ефективних заходів протидії епідеміям.

Прогнозування кількості хворих на COVID-19 в Україні у 2020–2023 роках стикалося з багатьма викликами. Основною складністю був багатохвильовий характер часового ряду, що включав періоди різких підйомів і спадів захворюваності. Додаткові ускладнення створювали аномальні події, такі як зміни карантинних заходів, тестувальної політики, вакцинаційних кампаній та сезонні фактори, особливо підвищення рівня захворюваності у зимовий період.

Для подолання цих труднощів у дослідженні було використано модель Prophet, яка здатна враховувати сезонні зміни та аномалії в даних. Для підвищення її точності було застосовано декомпозицію часового ряду, що дозволило виявити динаміку окремих хвиль захворюваності. Крім того, модель була вдосконалена за допомогою механізму коригування аномальних значень, які могли спотворювати тренди[1].

Особливе значення має визначення оптимальних гіперпараметрів моделі Prophet. Застосування методів автоматизованого пошуку, таких як `gridsearch` та стохастична оптимізація, дозволяє адаптувати модель до особливостей набору даних. Це дає змогу мінімізувати похибки прогнозів і врахувати специфічні особливості локального епідеміологічного контексту [2 – 3].

Окрім Prophet, у дослідженні розглянуто застосування нейромережевих моделей, таких як LSTM (LongShort-TermMemory), для аналізу часових рядів. Завдяки здатності нейромереж обробляти нелінійні залежності та велику кількість вхідних параметрів, LSTM потенційно доповнює класичні методи, забезпечуючи глибше розуміння довгострокових трендів і взаємозв'язків у даних.

**Мета дослідження** полягає у підвищенні точності прогнозування часового ряду моделлю Prophet за рахунок поєднання нейромережевих моделей з моделями часових рядів.

### Моделі машинного навчання для прогнозування часових рядів

Моделі машинного навчання, такі як рекурентні нейронні мережі (RNN), LSTM (LongShort-TermMemory), GRU (GatedRecurrentUnit) та інші, є інструментами для аналізу та прогнозування часових рядів. Ці моделі здатні вловлювати складні залежності у даних, що робить їх незамінними для роботи з великими наборами даних та нелінійними трендами.

Рекурентні нейронні мережі (RNN) є базовими моделями для обробки послідовних даних, які здатні враховувати залежності між послідовними елементами. Однак, їхній основний недолік полягає у проблемі зникнення градієнтів під час навчання, що ускладнює моделювання довготривалих залежностей у часових рядах.

Моделі LSTM (LongShort-TermMemory) були розроблені для вирішення проблеми зникнення градієнтів. Вони мають складну архітектуру з використанням механізмів забування, запису та зчитування інформації, що дозволяє зберігати довготривалі залежності. Завдяки цьому LSTM особливо добре справляються із задачами, де важливі як короткострокові, так і довгострокові залежності, наприклад, у прогнозуванні сезонних трендів або довготривалих змін у даних. GRU (GatedRecurrentUnit) є спрощеним варіантом LSTM із меншою кількістю параметрів, що знижує обчислювальні витрати. Вони підходять для задач із короткими часовими інтервалами або обмеженими обчислювальними ресурсами [4].

Первісно розроблені для задач обробки природної мови, трансформери, такі як GPT, Gemini, Claude і BERT, демонструють високу ефективність і у прогнозуванні часових рядів. Вони використовують механізми уваги, які дозволяють враховувати глобальні залежності у даних. Однак їхній головний недолік — це висока вимогливість до обчислювальних ресурсів, що може обмежувати їхнє використання у випадках із великими наборами часових рядів.

Серед розглянутих моделей LSTM виділяється своєю здатністю ефективно моделювати довготривалі залежності завдяки унікальній архітектурі з комітками пам'яті. На відміну від RNN, вони не страждають від проблеми зникнення градієнтів, що дозволяє їм працювати зі складними часовими рядами. Дослідження підтверджують, що LSTM демонструють вищу точність порівняно з RNN у прогнозуванні часових рядів завдяки здатності моделювати довгострокові залежності. Порівняно з GRU, LSTM пропонують більшу гнучкість для моделювання короткострокових та довгострокових залежностей завдяки використанню окремих механізмів запису, забування та читання. Це дозволяє досягати кращих результатів у задачах із високою мінливістю даних. Хоча трансформери є не менш доречними інструментами, їхня вимогливість до ресурсів може бути недоцільною для задач із помірними наборами даних, де LSTM залишаються оптимальним вибором [5].

Таким чином, LSTM є оптимальним вибором для прогнозування часових рядів із помірними обчислювальними ресурсами, особливо коли важливо враховувати як локальні, так і глобальні патерни у даних. Їх гнучкість, надійність та підтверджена ефективність роблять LSTM універсальним інструментом для роботи з часовими рядами.

### Інтеграція моделі машинного навчання LSTM та моделі Prophet

Одним із найперспективніших напрямків інтеграції є поєднання моделей LSTM і Prophet для створення гібридної або ансамблевої моделі, яка використовує сильні сторони обох підходів. Prophet, зокрема, забезпечує надійне врахування сезонних компонентів, включаючи ефекти свят та особливі події, тоді як LSTM відзначається своєю здатністю вловлювати складні довгострокові залежності та нелінійності в даних. Комбінуючи ці підходи, можна досягти значного підвищення точності та адаптивності прогнозування.

Таке поєднання моделей досягається за рахунок комбінування прогнозів моделі Prophet із залишковим навчанням, яке виконує LSTM. У цьому підході Prophet використовується для початкового прогнозу трендів та сезонності, після чого різниця між прогнозом та реальними значеннями подається на вхід LSTM. Таким чином, LSTM може навчитися коригувати помилки, які не були враховані Prophet, що забезпечує вищу точність та адаптивність прогнозів [6]. Такий підхід дозволяє об'єднати сильні сторони різних моделей, таких як здатність Prophet до врахування сезонних компонентів і довгострокових трендів, та здатність LSTM моделювати складні нелінійні залежності. Ансамблеві методи суттєво підвищують стабільність прогнозів завдяки тому, що результати менш схильні до похибок окремих моделей.

Ефективність ансамблевих методів підтверджується численними дослідженнями [7 – 9], які демонструють їхню здатність знижувати ризик перенавчання шляхом об'єднання різноманітних підходів. Наприклад, моделі, які враховують локальні тенденції, можуть бути доповнені моделями, що краще аналізують глобальні закономірності в даних. Це забезпечує більш точні й адаптивні прогнози навіть у складних часових рядах, таких як дані про захворюваність на COVID-19.

Обравши тип моделі для інтеграції з моделлю Prophet, проведемо детальніший огляд математичного апарату, закладеного в моделі LSTM, а саме опишемо типові шари такої нейромережі:

Оновлення прихованого стану виконується за допомогою рівняння [10]:

$$h_t = \tanh(W_u * x_t + W_h * h_{t-1} + b_h) \quad (1)$$

Цей шар формує попередню версію прихованого стану  $h_t$ , використовуючи поточний вхід  $x_t$ , попередній прихований стан  $h_{t-1}$ , відповідні вагові коефіцієнти  $W_u$ ,  $W_h$  та зміщення  $b_h$ . Воно задає основу для подальшої обробки, забезпечуючи початкову оцінку стану на кожному часовому кроці.

Ще одним типовим шаром є шар забування (ForgetGate), який визначається наступним чином:

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2)$$

В цьому шарі виконується визначення частини попереднього стану комірки  $c_{t-1}$ , яку необхідно "забути". Використання сигмоїдної активаційної функції дозволяє гнучко зберігати чи видаляти інформацію, обчислюючи значення від 0 (забути) до 1 (зберегти).

В свою чергу, вхідний шар (InputGate) представлений нижче:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (3)$$

Вхідний шар визначає обсяг нової інформації, яка має бути додана до стану комірки. Цей процес є ключовим для оновлення комірки відповідно до нових даних, що надходять на поточному часовому кроці.

Далі, ще одним типовим шаром є шар оновлення стану комірки (CellLayer):

$$C_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (4)$$

В цьому шарі відбувається оновлення стану комірки  $C_t$ , комбінуючи "забуті" частини старого стану (через  $f_t$ ) із новими кандидатними значеннями (через  $i_t$ ). Операція  $\odot$  позначає елементне множення.

Вихідний шар (OutputGate) описується таким чином:

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

У цьому шарі відбувається визначення частини оновленого стану комірки  $c_t$ , що повинні впливати на шар кінцевого прихованого стану  $h_t$ .

Зрештою, кінцевий прихований стан має наступне представлення:

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

Результат шару кінцевого прихованого стану обчислюється шляхом модуляції активованого значення стану комірки  $\tanh(c_t)$  рішеннями вихідного шару  $o_t$ .

Математичний апарат моделі Prophet, в свою чергу, був розглянутий у минулих роботах та дослідженнях, але в загальному вигляді, ця модель може бути зображена з урахуванням трьох основних складових, на прикладі мультиплікативного режиму роботи моделі:

$$y_{prop\ het}(t) = g(t)s(t)h(t)\epsilon_t, \quad (7)$$

де  $g(t)$  – тренд ряду,  $s(t)$  – сезонна складова,  $h(t)$  – складова, яка враховує вплив свят чи інших аномалій,  $\epsilon_t$  – похибка з нульовим середнім, розподілена за нормальним законом.

Ґрунтуючись на наведених вище описах шарів та моделі Prophet, опишемо їх поєднання в ансамблеву модель, врахувавши послідовність обробки часового ряду моделлю Prophet, та обробкою результатів за допомогою LSTM:

$$\begin{aligned} e_t &= y(t) - y_{prop\ het}(t) \\ e_{lstm}(t) &= LSTM(e_t) \\ y_{final}(t) &= y_{prop\ het}(t) + e_{lstm}(t) \end{aligned} \quad (8)$$

В цій послідовності операцій відбувається обробка результатів прогнозування моделі Prophet, після чого вираховуються залишки або помилки в прогнозуванні, після чого ця інформація передається на вхід моделі LSTM, а результати роботи LSTM компонується з попередньо отриманими прогнозами Prophet.

В наступному розділі розглянемо такий підхід на практиці.

### Застосування моделі LSTM для оптимізації прогнозу моделі Prophet

Поєднання моделі Prophet із моделлю LSTM дозволяє значно покращити точність прогнозування часових рядів завдяки використанню переваг кожної з них. Prophet відзначається своєю здатністю точно моделювати сезонні компоненти та довгострокові тренди, тоді як LSTM ефективно обробляє складні нелінійні та довготривалі залежності у даних [7].

У цій архітектурі Prophet використовується для формування первинного прогнозу на основі історичних даних, після чого залишкові похибки, що залишаються після роботи Prophet, аналізуються і коригуються за допомогою моделі LSTM. Цей підхід дозволяє LSTM зосередитися на обробці складних взаємозв'язків та залежностей, що не враховані Prophet, що суттєво підвищує загальну точність прогнозу. Наприклад, у контексті прогнозування захворюваності на COVID-19 ансамбль враховує як довгострокові тенденції, так і короткострокові сплески, викликані локальними факторами, такими як зміни у політиці тестування чи сезонні ефекти.

Архітектура моделі LSTM у цьому ансамблі може бути розширена завдяки використанню багат шарових структур, які включають додаткові рекурентні шари. Це дає змогу краще розпізнавати складні закономірності у даних та підвищує стійкість моделі до аномалій. Застосування методів регуляризації, таких як Dropout, допомагає уникнути перенавчання та підвищує надійність моделі, що є критично важливим під час роботи з обмеженими обсягами даних. Регуляризація сприяє створенню узагальненої моделі, яка може адаптуватися до нових сценаріїв і даних.

Для покращення навчання LSTM у складі ансамблю важливим кроком є нормалізація даних. Використання BatchNormalization допомагає стабілізувати процес навчання, зменшити варіативність у розподілі вхідних значень і прискорити збіжність моделі. Це особливо актуально для великих і варіативних наборів даних, які характерні для задач прогнозування епідеміологічних процесів [11].

Оптимізація гіперпараметрів, таких як розмір вікна входу, кількість нейронів у прихованих шарах та швидкість навчання, виконується за допомогою методів GridSearch або BayesianOptimization. Це дозволяє налаштувати модель LSTM відповідно до специфіки даних, що суттєво покращує її продуктивність [12].

Ще однією важливою перевагою гібридного підходу є його здатність враховувати контекстні особливості даних. Наприклад, під час аналізу часових рядів захворюваності на COVID-19 LSTM може ефективно обробляти раптові зміни, пов'язані з новими хвилями пандемії або змінами в системах охорони здоров'я. Prophet, у свою чергу, забезпечує стабільний фундамент для довгострокового прогнозування, що є особливо корисним для стратегічного планування.

Окрім цього, інтеграція цих моделей дозволяє ефективно працювати з аномаліями у даних, які можуть бути спричинені несподіваними подіями. Адаптивність LSTM дозволяє швидко враховувати ці аномалії, мінімізуючи їхній вплив на результати прогнозування. Завдяки цьому гібридний підхід стає цінним інструментом для управлінців і аналітиків, які працюють із непередбачуваними даними [13].

Розширена діаграма архітектури використання LSTM з моделлю Prophet в якості ансамблю наведено на рис. 1:



Рис. 1. Розширена діаграма архітектури ансамблю моделі LSTM та Prophet

У перспективі застосування більш просунутих нейронних мереж, таких як трансформери, у поєднанні з Prophet може відкрити нові горизонти для аналізу часових рядів. Такі моделі мають здатність обробляти ще складніші залежності й масштабуватися на великі обсяги даних, що може стати значним проривом у задачах прогнозування.

### Результати застосування LSTM та моделі Prophet

Модель Prophet забезпечила стабільність у моделюванні трендів і сезонних коливань, що створило основу для базового прогнозу. LSTM, у свою чергу, дозволила коригувати залишкові помилки базової моделі, зосереджуючись на складних нелінійних взаємозв'язках, які важко виявити за допомогою традиційних статистичних підходів. Завдяки цьому комбінація моделей продемонструвала високу ефективність навіть для часових рядів із значними аномаліями.

Для оцінки точності прогнозів використовувалися різні метрики, зокрема: MeanAbsoluteError (MAE): оцінює середнє абсолютне відхилення між прогнозованими та фактичними значеннями, що дозволяє визначити загальну точність прогнозу, RootMeanSquaredError (RMSE): квадратний корінь із середнього квадрату відхилень, який підкреслює великі помилки, що особливо важливо для аналізу аномалій, MeanAbsolutePercentageError (MAPE): показує середній відсоток відхилення прогнозу від фактичних даних, що дозволяє оцінити якість прогнозу у відносних величинах, R-squared ( $R^2$ ): метрика, яка визначає, наскільки добре модель пояснює варіативність даних. Високі значення  $R^2$  свідчать про високу точність прогнозування, WeightedAbsolutePercentageError (WAPE): враховує загальну суму фактичних значень у знаменнику, забезпечуючи більш стабільну оцінку точності прогнозу для часових рядів з великими коливаннями. Порівняння метрик оцінювання точності прогнозування наведені на рис. 2:

	MAPE	RMSE	WAPE	R2
Prophet	1.4587	11101.2679	0.5784	0.125
LSTM	0.2149	4633.4434	0.1902	0.8476
Ensemble	0.7704	7050.8463	0.3495	0.647

Рис. 2. Порівняння результатів прогнозування на основі відповідних метрик

Отримані результати свідчать про те, що ансамблевий підхід забезпечує значне зменшення похибок порівняно з використанням окремих моделей, ґрунтуючись на значеннях обчислених метрик, наведених у рис. 2, ансамблева модель має кращі показники порівняно зі звичайною моделлю Prophet, а саме за метрикою MAPE зменшення похибки сягає 47%, за метрикою RMSE 36%, за метрикою WAPE 39%, а за метрикою  $R^2$  59%.

Візуалізація результатів застосування моделі Prophet та ансамблю моделі Prophet та LSTM наведено на рис. 3:

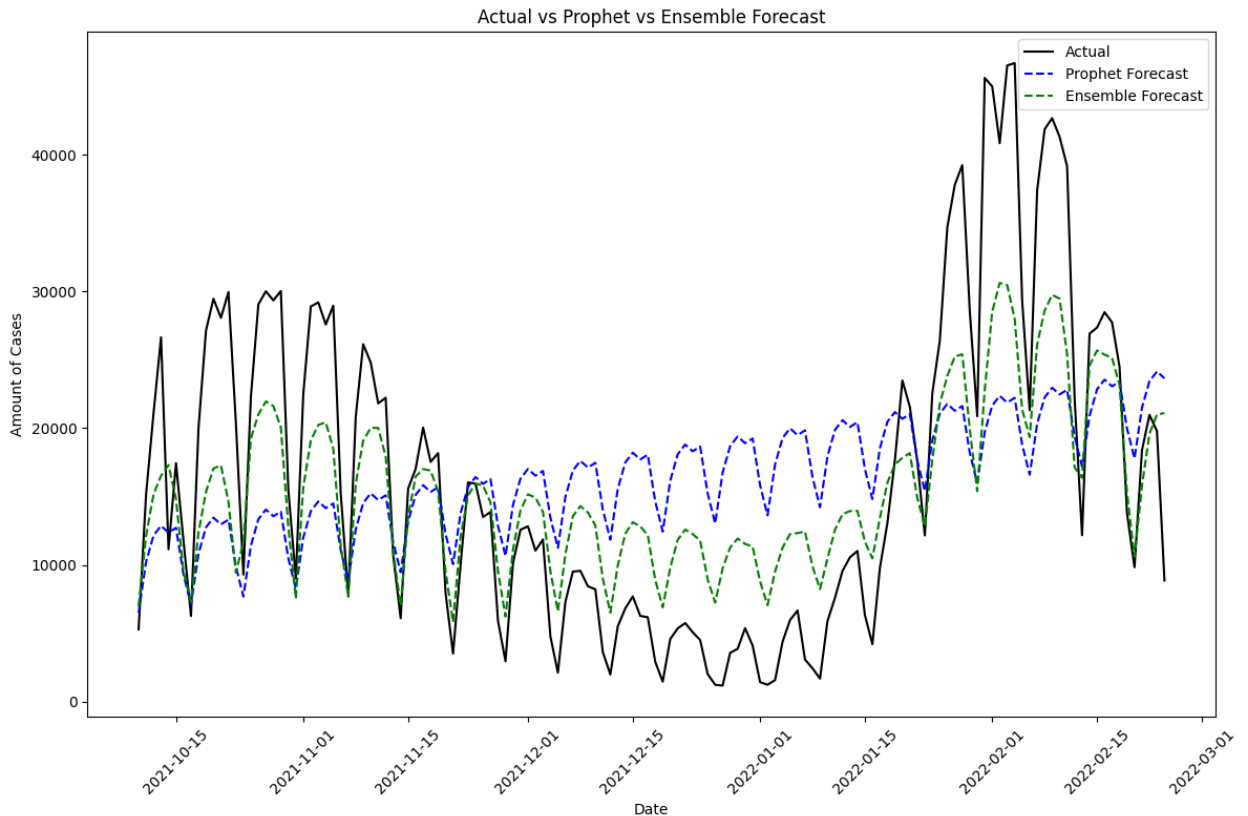


Рис. 3. Візуалізація результатів роботи моделі Prophet та ансамблю Prophet та LSTM

Крім того, візуалізація результатів показала, що модель ефективно враховує сезонні коливання, пікові значення та поступове зниження захворюваності після піків пандемії. Гнучкість моделі дозволяє адаптувати її до різних часових інтервалів і специфічних умов, що робить її універсальним інструментом для прогнозування.

Таким чином, результати демонструють, що інтеграція моделей LSTM та Prophet є перспективним підходом для аналізу часових рядів із високою мінливістю, таких як дані про захворюваність на COVID-19.

### Висновки

У цій статті було розглянуто інтеграцію моделей LSTM та Prophet для прогнозування часових рядів захворюваності на COVID-19 в Україні за період 2020 – 2022 років. Гібридний підхід продемонстрував високу ефективність у врахуванні як довгострокових трендів і сезонних коливань, так і короткострокових сплесків, що є характерними для складних часових рядів.

Поєднання моделі Prophet, яка забезпечує стабільність базового прогнозу, з моделлю LSTM, здатною моделювати нелінійні залежності, дозволило досягти значного зниження похибок. Це було підтверджено через використання метрик точності, таких як MAPE, RMSE, WAPE та  $R^2$ , які продемонстрували переваги ансамблевого підходу порівняно з окремими моделями. На основі наведених метрик, застосування ансамблевої моделі дає відчутне зменшення похибки (за метрикою MAPE похибка зменшена на 47%, за метрикою RMSE на 36%, за метрикою WAPE на 39%, а за метрикою  $R^2$  на 59%).

Особливий акцент зроблено на важливості обробки аномалій і адаптації моделі до змін у динаміці даних. Використання регуляризації, нормалізації даних і оптимізації гіперпараметрів забезпечило стійкість моделі навіть у нестабільних умовах. Візуалізація результатів показала, що модель успішно враховує сезонні ефекти та аномалії, що дозволяє забезпечити точні прогнози навіть у складних сценаріях.

Результати дослідження демонструють, що інтеграція моделей LSTM та Prophet є перспективним підходом для прогнозування часових рядів із високою мінливістю. Застосування цього ансамблю дозволяє не лише підвищити точність прогнозів, але й адаптувати їх до специфічних умов, що має значний практичний потенціал для управлінців та аналітиків у сфері охорони здоров'я.

У перспективі розвиток цього підходу може включати інтеграцію трансформерних моделей, які здатні працювати з ще складнішими залежностями та великими обсягами даних. Це відкриває нові можливості для прогнозування у різних сферах, включаючи епідеміологію, економіку та кліматологію.

## СПИСОК ЛІТЕРАТУРИ

1. Мокін В. Б., Дратований М. В. Наука про дані: машинне навчання та інтелектуальний аналіз даних : електронний навчальний посібник комбінованого (локального та мережевого) використання. Вінниця : ВНТУ, 2024. 258 с. URL: [https://pdf.lib.vntu.edu.ua/books/2024/Mokin\\_2024\\_263.pdf](https://pdf.lib.vntu.edu.ua/books/2024/Mokin_2024_263.pdf).
2. Comparison Analysis of Facebook's Prophet, Amazon's DeepAR+ and CNN-QR Algorithms for Successful Real-World Sales Forecasting / E. Žunić et al. *arXiv*. May 2021. URL: <https://arxiv.org/abs/2105.00694>. (Last accessed: 23.11.2024).
3. Neural Prophet: Explainable Forecasting at Scale / O. Triebe et al. *arXiv*. Nov. 2021. URL: <https://arxiv.org/abs/2111.15397>. (Last accessed: 23.11.2024).
4. Berlo Van B., Ross M. A. S., Hsia D. Univariate Long-Term Municipal Water Demand Forecasting. *arXiv*. May 2021. URL: <https://arxiv.org/abs/2105.08486>. (Last accessed: 23.11.2024).
5. Ganaie M. A. Amazon AI Researchers Introduce Chronos: A New Machine Learning Framework for Pretrained Probabilistic Time Series Models. *MarkTechPost*. Mar. 2024. URL: <https://www.marktechpost.com/2024/03/15/amazon-ai-researchers-introduce-chronos-a-new-machine-learning-framework-for-pretrained-probabilistic-time-series-models/>. (Last accessed: 23.11.2024).
6. Long B., Tan F., Newman, M. Forecasting the monkeypox outbreak using ARIMA, prophet, NeuralProphet, and LSTM models in the United States. *Forecasting*. 2023. №5 (1). P. 127 – 137. <https://doi.org/10.3390/forecast5010005>.
7. Meng F., Dou R. Prophet-LSTM-BP Ensemble Carbon Trading Price Prediction Model. *Computational Economics*. 2023. №63. P. 1805 – 1825. <https://doi.org/10.1007/s10614-023-10384-5>.
8. Sande de van S. N. P., Alshahag A. M. M., Mohammadi Ziabari S. S. Enhancing the Predictability of Wintertime Energy Demand in The Netherlands Using Ensemble Model Prophet-LSTM. *Processes*. 2023. №12 (11). Article 2519. <https://doi.org/10.3390/pr12112519>.
9. Mozaffari L., Zhang, J. Predictive Modeling of Stock Prices Using Transformer Model. In *Proceedings of the 2024 9th International Conference on Machine Learning Technologies (ICMLT)*. Oslo, Norway, May 2024. <https://doi.org/10.1145/3674029.3674037>.
10. Shivakumar Z. V. Wind Speed and Direction Prediction Using LSTM, ARIMA, and Prophet. *GitHub Repository*. URL: <https://github.com/shivakumarzishnuviknesh7/Wind-Speed-and-Direction-Prediction-Using-LSTM-ARIMA-and-Prophet>.
11. Sepp Hochreiter, Jürgen Schmidhuber. Long short-term memory. *Neural Computation*. 1997. Vol. 9, № 8. P. 1735 – 1780. doi:10.1162/neco.1997.9.8.1735. – PMID 9377276.
12. Chen W., Zhao Y. Guo, N. Time-Series Prediction Research Based on Combined Prophet-LSTM Models. In *Proceedings of the 2023 IEEE 5th International Conference on Computer Science and Educational Informatization (CSEI)*. P. 123 – 128. <https://doi.org/10.1109/CSEI56712.2023.10091270>.
13. Wang L. Zhang H. Multivariate Time Series with Prophet Facebook and LSTM Algorithm to Predict Energy Consumption. In *Proceedings of the 2023 IEEE 4th International Conference on Big Data and Artificial Intelligence (BD AI)*. 2023. P. 98 – 103. <https://doi.org/10.1109/BD AI56712.2023.10127735>.
14. Shohan J. Forecasting of Electric Load Using a Hybrid LSTM-Neural Prophet Model. *Energies*. 2022. №15 (6). Article 2158. <https://doi.org/10.3390/en15062158>.

Рекомендовано кафедрою системного аналізу та інформаційних технологій.

Стаття надійшла до редакції 22.12.2024.

Стаття пройшла рецензування 24.12.2024.



**Лосенко Арсен Володимирович** – PhD, асистент кафедри системного аналізу та інформаційних технологій, e-mail: [arsenloosenko@protonmail.com](mailto:arsenloosenko@protonmail.com).

**Козачко Олексій Миколайович** – канд. техн. наук, доцент, викладач кафедри системного аналізу та інформаційних технологій, e-mail: [lekoz80@gmail.com](mailto:lekoz80@gmail.com).

**Варчук Ілона В'ячеславівна** – канд. техн. наук, доцент, викладач кафедри системного аналізу та інформаційних технологій, e-mail: [ilonavarchuk@gmail.com](mailto:ilonavarchuk@gmail.com).

Вінницький національний технічний університет.