

<https://doi.org/10.31891/2219-9365-2024-80-22>

УДК 621.317; 658.56

АРТЕМУК Ольга-Соломія

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0002-3074-3898>

e-mail: olha-solomiia.i.korchynska@lpnu.ua

МИКИЙЧУК Микола

Національний університет «Львівська політехніка»

<https://orcid.org/0000-0002-0591-6304>

e-mail: mykolamm@ukr.net

МЕТОД ПРОГНОЗУВАННЯ МЕТРОЛОГІЧНИХ РИЗИКІВ ЯКОСТІ ПРОДУКЦІЇ

У статті розглядається застосування моделей прогнозування часових рядів для оцінки метрологічного ризику якості продукції на етапі виготовлення продукції. Метрологічний ризик, який визначається через такі параметри, як значущість ризику, ймовірність виникнення та ймовірність виявлення, виступає як часовий ряд, що потребує точного прогнозування для управління ризиками в виробничому процесі. Для прогнозування МР в даній роботі використовуються шість моделей: Facebook Prophet, Statsmodels SARIMAX, Forecaster Recursive, Forecaster Direct, LGBMRegressor та Linear Regression. Кожна з моделей була досліджена на даних, що охоплюють період з 1 січня 2023 року по 24 листопада 2024 року. Вхідні дані були поділені на два набори: для навчання нейронної мережі та для порівняння прогнозованих значень із дійсними. Результати дослідження показали, що найточніші прогнози метрологічного ризику забезпечуються моделями Facebook Prophet та Statsmodels SARIMAX, які продемонстрували найкращі результати за основними метриками точності, зокрема MAE, RMSE, MAPE та R2. Крім того, порівняння результатів прогнозування візуально продемонструвало, що ці моделі здатні точніше відображати реальні зміни в рівні ризику у часі. Логістична регресія та інші моделі, як показали результати, мають обмежену ефективність у прогнозуванні метрологічного ризику. Враховуючи результати дослідження, можна стверджувати, що використання моделей часових рядів є ефективним підходом для прогнозування метрологічних ризиків у виробничих процесах. Це дозволяє не лише знижувати ймовірність виникнення непередбачуваних ситуацій, а й оптимізувати контроль за якістю продукції. В подальшому планується удосконалення моделей для зниження рівня похибок, підвищення їх адаптивності до змінних умов виробництва та інтеграцію моделей прогнозування у системи прийняття рішень.

Ключові слова: метрологічні ризики, нейронна мережа, машинне навчання, ймовірність ризику, значущість ризику, похибка.

ARTEMUK Olha-Solomiia, MYKYCHUK Mykola

Lviv Polytechnic National University

METHOD OF FORECASTING METROLOGICAL RISKS OF PRODUCT QUALITY

The article considers the application of time series forecasting models for assessing the metrological risk of product quality at the stage of product manufacturing. Metrological risk, which is defined through such parameters as risk significance, probability of occurrence and probability of detection, acts as a time series that requires accurate forecasting for risk management in the production process. Six models are used in this paper to forecast metrological risk: Facebook Prophet, SARIMAX Statsmodels, Forecaster Recursive, Forecaster Direct, LGBMRegressor, and Linear Regression. Each model was tested on data covering the period from 1 January 2023 to 24 November 2024. The input data was divided into two sets: for training the neural network and for comparing the predicted values with the actual ones. The results of the study showed that the most accurate forecasts of metrological risk are provided by Facebook Prophet and SARIMAX Statsmodels, which demonstrated the best results in terms of the main accuracy metrics, including MAE, RMSE, MAPE, and R2. In addition, a comparison of the forecasting results visually demonstrated that these models are able to more accurately reflect real changes in risk over time. Logistic regression and other models, as shown by the results, have limited effectiveness in predicting metrological risk. Taking into account the results of the study, it can be argued that the use of time series models is an effective approach to predicting metrological risks in production processes. This allows not only to reduce the likelihood of unforeseen situations, but also to optimise product quality control. In the future, it is planned to improve the models to reduce the level of errors, increase their adaptability to changing production conditions and integrate forecasting models into decision-making systems.

Keywords: metrological risks, neural network, machine learning, risk probability, risk significance, error.

ПОСТАНОВКА ПРОБЛЕМИ У ЗАГАЛЬНОМУ ВИГЛЯДІ ТА ЇЇ ЗВ'ЯЗОК ІЗ ВАЖЛИВИМИ НАУКОВИМИ ЧИ ПРАКТИЧНИМИ ЗАВДАННЯМИ

На сучасному етапі розвитку промисловості забезпечення високої якості продукції є ключовою умовою конкурентоспроможності та ефективності виробництва. Одним із критичних аспектів цього завдання є точність вимірювань, яка залежить від надійності метрологічного забезпечення. Відхилення у вимірювальних процесах, спричинені зовнішніми або внутрішніми факторами впливу на технологічний процес, можуть призводити до дефектів продукції, зниження продуктивності або втрати репутації підприємства [1].

Ризик-менеджмент невід'ємна складова системи управління якістю продукції на етапі виробництва та має бути інтегрованим у структуру, операційні процеси й діяльність підприємства [2]. В умовах автоматизації та підвищення складності виробничих систем вдосконалення ризик-менеджменту стає

невід'ємною частиною управління якістю на підприємстві. Прогнозування метрологічних ризиків на етапі виготовлення є важливим інструментом для виявлення потенційних загроз та запобігання їхньому впливу на кінцеву якість продукції. Це особливо актуально для підприємств, де навіть невеликі похибки у вимірюваннях можуть призвести до серйозних технічних або фінансових наслідків.

Застосування сучасних технологій, таких як нейронні мережі, відкриває нові можливості для вдосконалення ризик-менеджменту. Завдяки здатності аналізувати великі обсяги даних, виявляти приховані закономірності та прогнозувати ризики в реальному часі, такі технології дозволяють мінімізувати ймовірність метрологічних відхилень, підвищуючи стабільність виробничих процесів та забезпечуючи відповідність продукції встановленим стандартам.

Нейронні мережі можуть бути частиною автоматизованих систем моніторингу, які в реальному часі оцінюють ймовірність виникнення метрологічних ризиків і пропонують заходи щодо їхньої мінімізації.

У цій статті розглядаються підходи до прогнозування метрологічних ризиків на етапі виготовлення продукції із застосуванням нейронних мереж, аналізуються їхні переваги та роль у забезпеченні безперервного вдосконалення систем управління якістю.

Прогнозування метрологічних ризиків якості продукції вимагає врахування численних змінних, які можуть впливати на точність вимірювань. Традиційні методи прогнозування стикаються з низкою труднощів, таких як обмеженість у обробці великих обсягів даних, складність у виявленні нелінійних залежностей та впливі невизначених внутрішніх та зовнішніх факторів. Більшість існуючих систем працює на основі статичних моделей, які не можуть оперативного враховувати поточні умови експлуатації. Це обмежує можливість запобігати метрологічним ризикам до їхнього виникнення. Нейронні мережі можуть працювати в режимі реального часу, обробляючи дані, що надходять без затримок, та негайно коригувати прогнози. Це дозволяє оперативного виявити потенційні метрологічні ризики та вживати необхідних заходів до того, як вони матимуть серйозні наслідки на якість та підприємство.

Використання нейронних мереж дозволяє досягти більш точних, надійних та швидких прогнозів, що є ключовим для зменшення метрологічних ризиків на етапі виготовлення та підвищення ефективності метрологічних процесів.

ФОРМУЛЮВАННЯ ЦІЛЕЙ СТАТТІ

Метою даного дослідження є застосування моделей прогнозування часових рядів для оцінки та прогнозування метрологічного ризику (МР) у процесі виготовлення продукції. Основна увага приділяється порівнянню ефективності різних моделей для прогнозування МР та визначення найточніших методів для прогнозування ризиків.

ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Нейронні мережі є потужними інструментами для вирішення різноманітних завдань в області машинного навчання та штучного інтелекту. Існує кілька типів нейронних мереж, кожен з яких підходить для специфічних задач. Основні типи нейронних мереж включають: Multi-Layer Perceptron (MLP), Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), Generative Adversarial Networks (GAN) та Time Series forecasting.

Метрологічний ризик (МР) є показником ймовірності виникнення та значущості наслідків в результаті відхилень якості продукції через похибки вимірювань, недотримання стандартів або інших факторів, що впливають на точність та стабільність виробничих процесів. Цей ризик може змінюватися з часом в залежності від умов виробництва, обладнання та інших технологічних аспектів. Оскільки метрологічний ризик може бути представлений як часовий ряд, де значення ризику змінюються в часі залежно від різних факторів, для його прогнозування найкраще підходять моделі прогнозування часових рядів (Time Series forecasting). Прогнозування таких часових рядів дозволяє отримати точні оцінки ймовірності виникнення та значущості наслідків ризикової події на різних етапах виробництва, що є критично важливим для забезпечення високої якості продукції.

В даній роботі використано шість різних моделей для прогнозування значень МР, а саме: Facebook Prophet [3], Statsmodels SARIMAX [4], Forecaster Recursive [5], Forecaster Direct [6], LGBMRegressor та Linear Regression [7]. Кожна з моделей має свої переваги та недоліки в залежності від задачі. Наприклад, Facebook Prophet є дуже ефективним для даних з вираженою сезонністю, в той час як SARIMAX добре працює для складних часових рядів з екзогенними змінними. LGBMRegressor та Linear Regression можуть бути корисними для більш простих та лінійних задач, але вони можуть бути менш ефективними для складних, нелінійних часових рядів.

Структура вхідних даних для навчання моделей. Для навчання моделей прогнозування використовуються дані у вигляді матриці $m \times k$, де m - кількість ризиків, а k - кількість параметрів, що характеризують кожен МР, а саме: значущість наслідків (S), ймовірність виникнення (O) та ймовірність виявлення (D). З цих даних формують часові ряди (*англ. time series*) за певний період часу. На рисунку 1 представлено графік часового ряду для одного з МР, який відображає зміну значень S, O та D в період з 1

січня 2023 року до 24 листопада 2024 року. Цей графік демонструє структуру вхідних даних і характер їх варіативності.

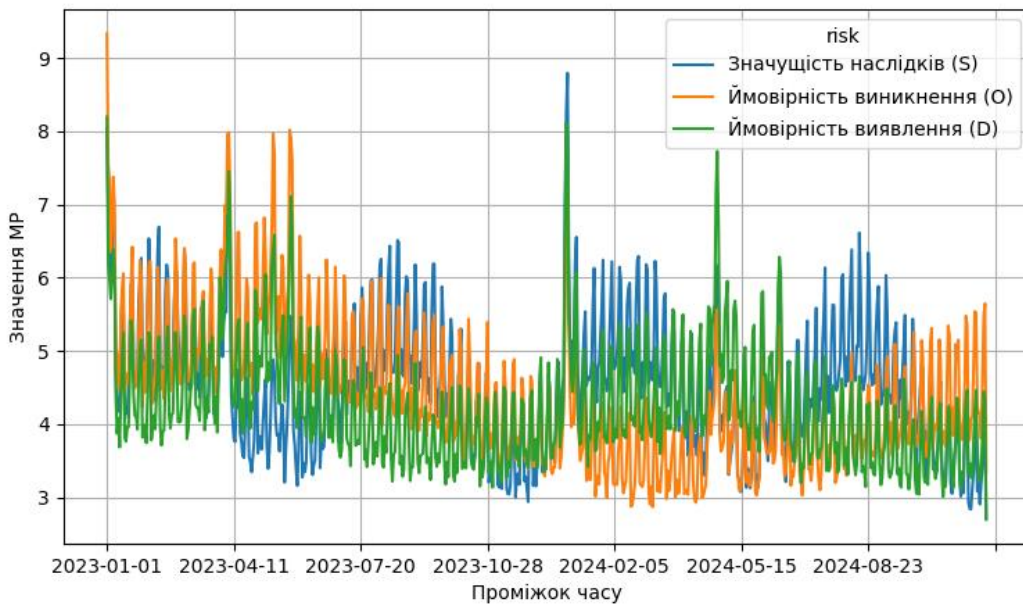


Рис. 1. Зміна параметрів ризику (S, O, D) у часовому проміжку

Для забезпечення можливості навчання моделей і оцінювання їх ефективності вхідні дані поділено на набір для навчання та перевірки. Набір для навчання містить значення параметрів ризику за період з 1 січня 2023 року до 30 вересня 2024 року. Цей набір використовується нейронною мережею для побудови моделі і визначення її параметрів. Набір для перевірки складається з даних за період з 1 жовтня 2024 року до 24 листопада 2024 року. Цей набір використовується для оцінки точності прогнозів нейронної мережі. Графічне представлення поділу даних наведено на рисунку 2, де чітко показано межу між наборами для навчання та перевірки.

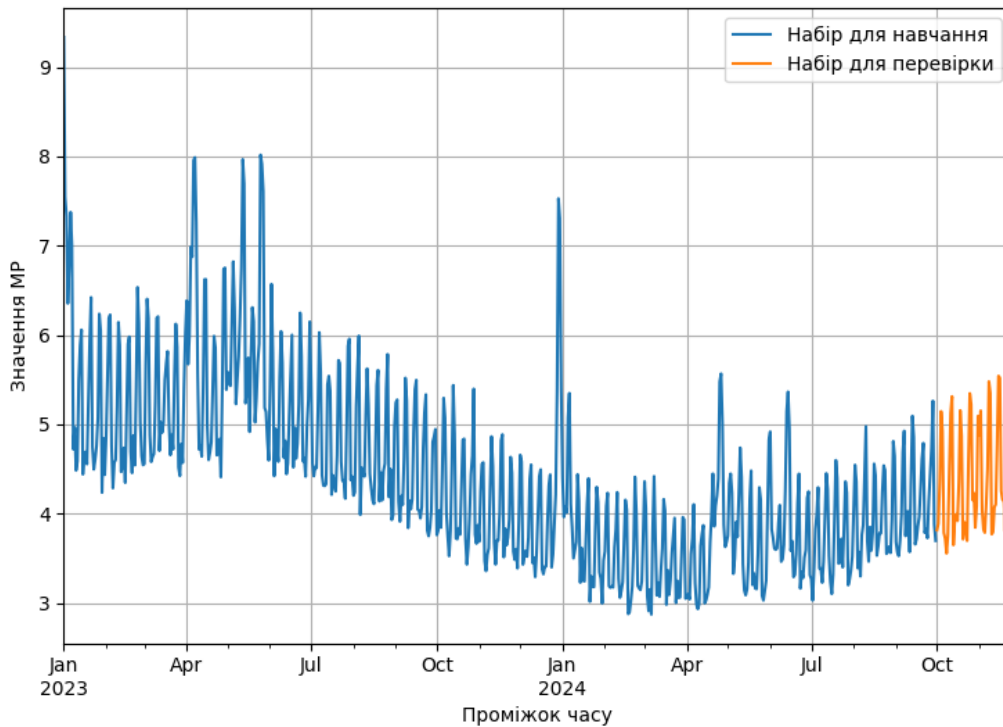


Рис. 2. Поділ вхідних на набори для навчання та перевірки

Після поділу даних здійснюється навчання нейронної мережі із використанням навчального набору. Навчена нейронна мережа застосовується для побудови прогнозу на вказаний проміжок часу. Цей проміжок часу відповідає проміжку часу набору для перевірки, який містить дійсні значення МР. Масиви з прогнозованими та дійсними значеннями МР використовуються для оцінки точності прогнозів, шляхом їх порівняння та застосування різних метрик, які дозволяють кількісно оцінити похибку моделі.

Оцінювання якості моделей для прогнозування МР. У задачах прогнозування часових рядів, таких як оцінка метрологічного ризику (МР), важливо використовувати метрики, які надають інформативну і зрозумілу оцінку якості прогнозу. Для цього були обрані такі метрики: середня абсолютна похибка (англ. *Mean Absolute Error or MAE*), середня відносна похибка (англ. *Mean Absolute Percentage Error or MAPE*), коренева середньоквадратична похибка (англ. *Root Mean Square Error or RMSE*) та коефіцієнт кореляції (англ. *R square or R2*). Вибір цих метрик обґрунтований їх здатністю враховувати різні аспекти якості моделі, такі як масштаб похибки, чутливість до великих відхилень і загальна пояснювальна здатність моделі.

MAE відображає середню абсолютну помилку прогнозу в тих самих одиницях, що й значення МР, тобто в балах. У контексті метрологічного ризику це означає середнє відхилення прогнозу від фактичного значення в балах. Менші значення MAE вказують на точніші прогнози. MAE розраховується за формулою [8]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (1)$$

де y_i - дійсне значення МР, \hat{y}_i - спрогнозоване значення МР, n - кількість спостережень.

MAPE визначає середню похибку у відсотках. Для метрологічного ризику ця метрика показує, на скільки відсотків в середньому прогноз відхиляється від фактичного значення. Оптимальними є менші значення, які свідчать про високий рівень точності. Проте MAPE може бути нестабільним для малих значень y_i , що потребує обережного застосування. MAPE визначається як [9]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \%. \quad (2)$$

RMSE враховує квадрати похибок, що робить цю метрику чутливою до великих відхилень. Для прогнозів метрологічного ризику це дозволяє виявляти випадки значних похибок, які можуть бути критичними для прийняття рішень. RMSE виражається в тих самих одиницях, що й значення МР, тобто в балах. Менші значення RMSE свідчать про кращу якість моделі. Для визначення RMSE використано наступну формулу [10]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (3)$$

R2 показує частку варіації метрологічного ризику, яку пояснює модель. Значення $R2 \in [0,1]$, де 1 означає ідеальний прогноз, а 0 означає, що модель завжди прогнозує середнє значення y_i , не враховуючи вхідні характеристики. Вищі значення R2 вказують на кращу здатність моделі відображати тенденції та зміни в метрологічному ризику та враховувати його динаміку з часом. R2 визначається як [11]:

$$R2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (4)$$

де \bar{y} - середнє значення дійсних значень МР.

Використання цих метрик у комплексі дозволяє отримати повну картину якості прогнозу, враховуючи як середні похибки, так і чутливість до великих відхилень.

Аналіз результатів моделей прогнозування МР. Враховуючи інформацію, подану в попередніх розділах, було проведено експеримент, основною метою якого було оцінювання точності прогнозування моделей для визначення МР. Для цього використано наступні моделі: Facebook Prophet, Statsmodels SARIMAX, Forecaster Recursive, Forecaster Direct, LGBMRegressor та Linear Regression. На рисунках 3-5 наведено результати експерименту. На рисунку 3 зображено порівняння прогнозів моделей Facebook Prophet та Statsmodels SARIMAX із дійсними значеннями МР.

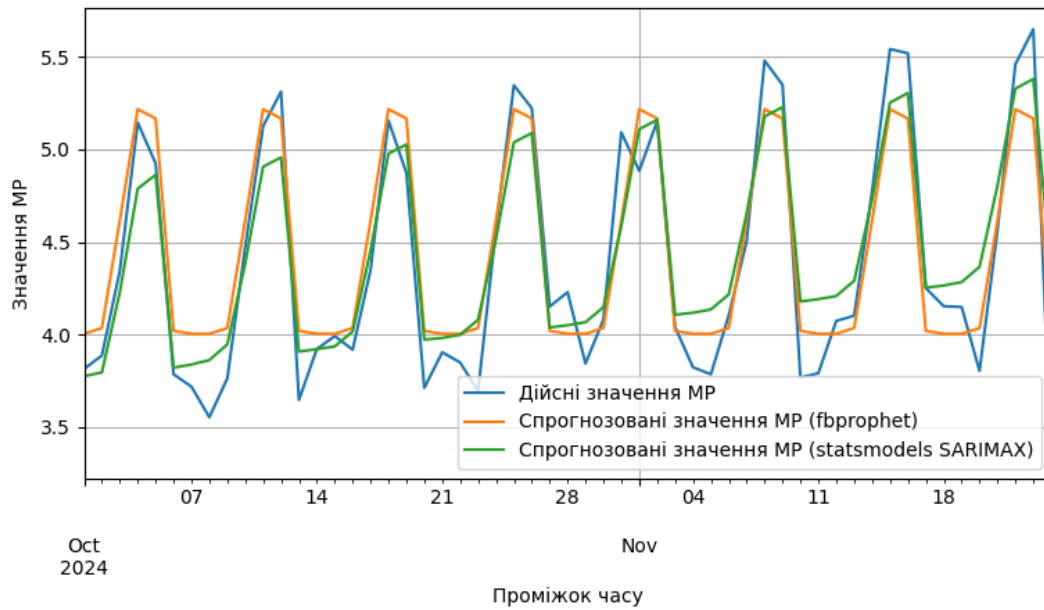


Рис. 3. Графік прогнозованих значень МР: Facebook Prophet та Statsmodels SARIMAX

Обидві моделі досить точно відображають загальну динаміку змін МР, проте модель Facebook Prophet забезпечує точніше повторення пікових значень, тоді як Statsmodels SARIMAX має деяке відхилення.

На рисунку 4 відображено результати порівняння прогнозів моделей Forecaster Recursive та Forecaster Direct.

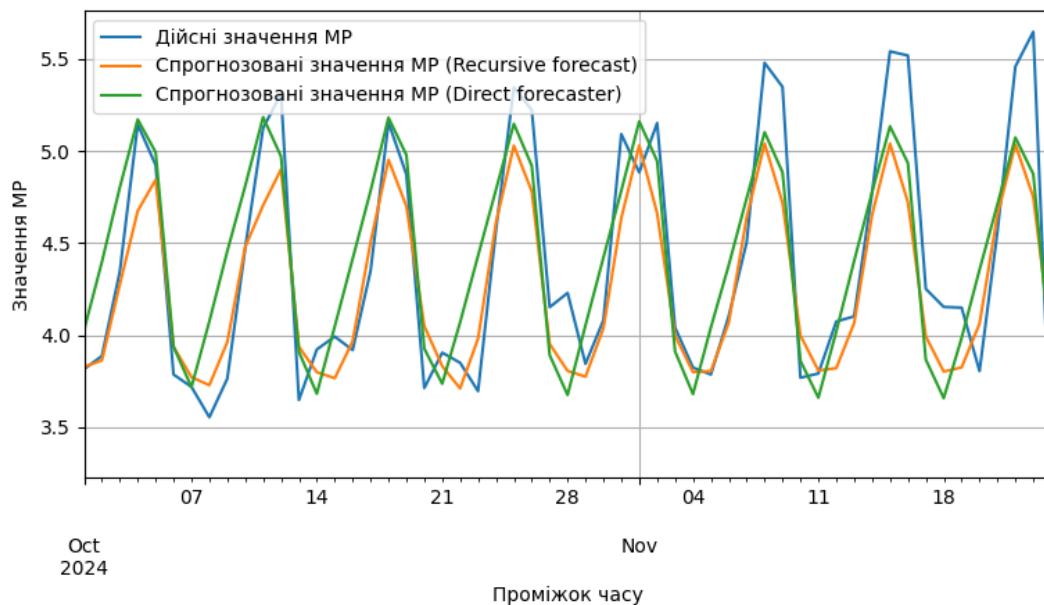


Рис. 4. Графік прогнозованих значень МР: Forecaster Recursive та Forecaster Direct

Обидві моделі демонструють меншу точність у порівнянні з моделями з попереднього графіка. Помітно, що вони не завжди коректно передбачають пікові значення, особливо у випадках різкого зростання або спаду.

На рисунку 5 наведено результати прогнозування моделей LGBMRegressor та Linear Regression.

Модель LGBMRegressor демонструє кращу адаптацію до змін МР, зокрема під час піків. Тоді як Linear Regression показує значні відхилення і суттєво гірше повторює дійсні значення.

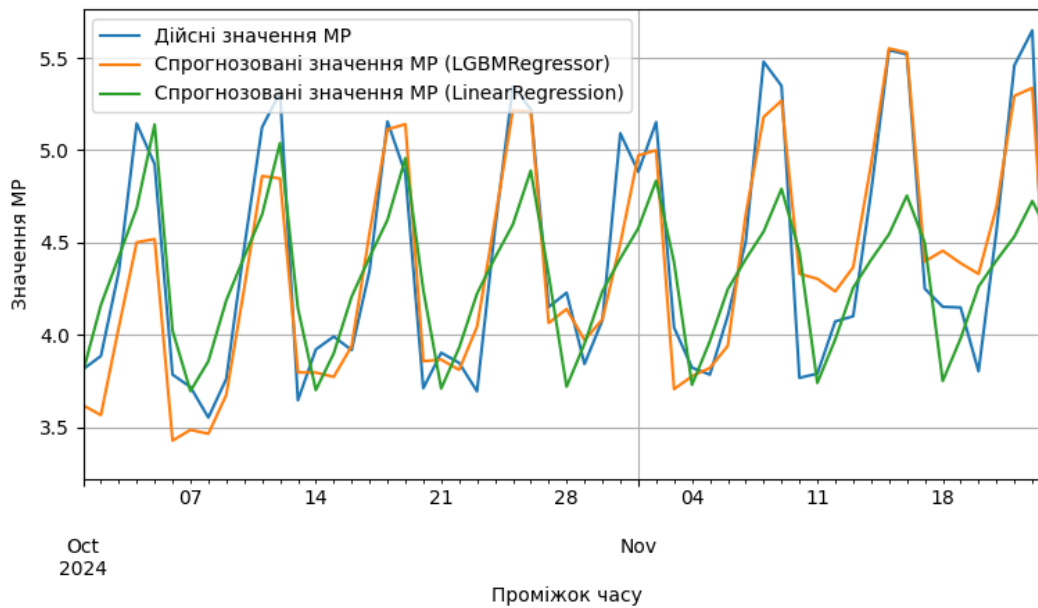


Рис. 5. Графік прогнозованих значень МР: LGBMRegressor та LinearRegression

В таблиці 1 наведено кількісну оцінку точності моделей із використанням метрик описаних в попередньому підрозділі.

Таблиця 1.

Оцінка точності для шести моделей прогнозування

Назва моделі	MAE	MAPE, %	R2	RMSE
Facebook Prophet	0.199	4.692	0.861	0.239
Statsmodels SARIMAX	0.201	4.752	0.835	0.261
Forecaster Recursive	0.241	5.269	0.756	0.317
Forecaster Direct	0.293	6.823	0.705	0.349
LGBMRegressor	0.212	4.953	0.825	0.268
LinearRegression	0.352	7.875	0.509	0.449

За результатами аналізу таблиці можна сказати, що найкращою є модель Facebook Prophet. Ця модель має найнижче значення MAE (0.199) та RMSE (0.239), що вказує на найменшу середню похибку прогнозування. Також вона демонструє найвищий R2 (0.861), що свідчить про її високу здатність враховувати тенденції та зміни в метеорологічному ризику з часом. Statsmodels SARIMAX поступається Facebook Prophet за всіма показниками, але зберігає прийнятний рівень точності (MAE = 0.201, RMSE = 0.261, R2 = 0.835). Forecaster Recursive та Forecaster Direct демонструють значно гірші результати, зокрема вищі значення MAE (0.241 та 0.293 відповідно) та MAPE (5.269% і 6.823%), що свідчить про вищу середню похибку прогнозування. LGBMRegressor показує хороші результати (MAE = 0.212, R2 = 0.825), проте поступається моделям Facebook Prophet і SARIMAX. LinearRegression є найменш точною серед усіх моделей. Її MAE становить 0.352, RMSE = 0.449, а R2 = 0.509, що вказує на низьку здатність до врахування складних варіацій вхідних даних.

У підсумку, найкращі результати демонструють моделі Facebook Prophet та Statsmodels SARIMAX, які забезпечують як високу точність прогнозування, так і стабільну адаптацію до змін у часовому ряді. Модель Facebook Prophet є лідером за всіма метриками, що робить її оптимальним вибором для прогнозування МР у запропонованій задачі. З іншого боку, моделі LinearRegression та Forecaster Direct продемонстрували найгірші результати, що свідчить про їх обмежену ефективність для даного типу задач.

ВИСНОВКИ З ДАНОГО ДОСЛІДЖЕННЯ І ПЕРСПЕКТИВИ ПОДАЛЬШИХ РОЗВІДОК У ДАНОМУ НАПРЯМІ

Сучасні технології на основі нейронних мереж трансформують метрологію, роблячи її проактивною, автоматизованою й високоефективною. Це сприяє підвищенню точності вимірювань, зниженню витрат і забезпеченню безперервного вдосконалення технологічних процесів у будь-якій галузі.

Результати проведеного дослідження підтвердили, що моделі прогнозування часових рядів є ефективними інструментами для прогнозування значень метрологічного ризику. Високі значення метрики R2, що перевищували 0.8 для більшості моделей, свідчать про здатність моделей коректно відображати динаміку зміни ризиків. Крім того, низькі значення MAE, MAPE та RMSE вказують на прийнятний рівень точності прогнозів, що дає змогу впроваджувати такі моделі у практичні системи оцінювання метрологічних ризиків.

На основі проведеного аналізу точності, найкращою моделлю для прогнозування значень метрологічного ризику виявилася Facebook Prophet. Ця модель демонструє найнижче середнє абсолютне відхилення (MAE = 0.199) та найменшу середньоквадратичну похибку (RMSE = 0.239), що свідчить про її здатність забезпечувати високий рівень точності прогнозів. Високий показник R2=0.861 підтверджує здатність цієї моделі враховувати складні тренди та варіації вхідних даних. Таким чином, Facebook Prophet рекомендується як оптимальний інструмент для задач прогнозування метрологічного ризику в умовах, подібних до умов даного дослідження.

У подальшому планується розробка методів та заходів для мінімізації метрологічного ризику на основі отриманих прогнозів. Це включатиме визначення оптимальних стратегій управління ризиками та інтеграцію моделей прогнозування у системи прийняття рішень.

Література

1. О-С. Корчинська, М. Микийчук, "Джерела метрологічних ризиків як фактори впливу на технологічний процес". «Вісник Черкаського державного технологічного університету», т. 28, №1, с. 61-71, 2023. Режим доступу: <https://doi.org/10.24025/2306-4412.1.2023.273708>
2. O-S. Korchynska, T. Hut, "Metrological risks in management system of product quality at the manufacturing stage", *Vymiriuvalna tekhnika ta metrolohiia*, vol. 83, no. 1, pp. 29-34, 2022. [Online]. Available: <https://doi.org/10.23939/istcm2022.01.029>
3. "Prophet: Automatic Forecasting Procedure", Facebook. [Online]. Available: https://facebook.github.io/prophet/docs/quick_start.html
4. "SARIMAX: Introduction", Statsmodels [Online]. Available: https://www.statsmodels.org/stable/examples/notebooks/generated/statespace_sarimax_stata.html
5. "Forecaster Recursive", Skforecast [Online]. Available: <https://skforecast.org/0.14.0/api/forecasterrecursive>
6. "Forecaster Direct", Skforecast [Online]. Available: <https://skforecast.org/0.14.0/api/forecasterdirect>
7. "Scalable machine learning for time series forecasting", Mlforecast [Online]. Available: <https://nixtlaverse.nixtla.io/mlforecast/index.html>
8. "Mean absolute error", Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.mean_absolute_error.html
9. "Mean absolute percentage error", Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.mean_absolute_percentage_error.html
10. "Root mean squared error", Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.root_mean_squared_error.html
11. "R2 score", Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.r2_score.html

References

1. O-S. Korchynska, M. Mykyuchuk, "Sources of metrological risks as factors of influence on the technological process". «*Bulletin of Cherkasy State Technological University*», vol. 28, no. 1, pp. 61-71, 2023. [Online]. Available: <https://doi.org/10.24025/2306-4412.1.2023.273708>;
2. O-S. Korchynska, T. Hut, "Metrological risks in management system of product quality at the manufacturing stage", *Vymiriuvalna tekhnika ta metrolohiia*, vol. 83, no. 1, pp. 29-34, 2022. [Online]. Available: <https://doi.org/10.23939/istcm2022.01.029>;
3. "Prophet: Automatic Forecasting Procedure", Facebook. [Online]. Available: https://facebook.github.io/prophet/docs/quick_start.html;
4. "SARIMAX: Introduction", Statsmodels [Online]. Available: https://www.statsmodels.org/stable/examples/notebooks/generated/statespace_sarimax_stata.html;
5. "Forecaster Recursive", Skforecast [Online]. Available: <https://skforecast.org/0.14.0/api/forecasterrecursive>;
6. "Forecaster Direct", Skforecast [Online]. Available: <https://skforecast.org/0.14.0/api/forecasterdirect>;
7. "Scalable machine learning for time series forecasting", Mlforecast [Online]. Available: <https://nixtlaverse.nixtla.io/mlforecast/index.html>;

8. “Mean absolute error”, Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.mean_absolute_error.html;
9. “Mean absolute percentage error”, Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.mean_absolute_percentage_error.html;
10. “Root mean squared error”, Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.root_mean_squared_error.html;
11. “R2 score”, Scikit-learn, Machine Learning in Python [Online]. Available: https://scikit-learn.org/1.5/modules/generated/sklearn.metrics.r2_score.html.