

**Онищук Оксана Олександрівна**

кандидат технічних наук, доцент

Волинський національний університет, Луцьк, Україна

ORCID: 0000-0002-8342-3011

oksanaoo2024@gmail.com

PANDAS ДЛЯ УПРАВЛІННЯ ДАНИМИ ПРОЕКТІВ ПРИ НАЛАШТУВАННІ ТАРГЕТИНГУ

Анотація. У статті розглянуто застосування бібліотеки Pandas як основного інструменту для управління вхідними, внутрішніми та вихідними даними у проєктах прогнозування часових рядів у сфері таргетингу рекламних кампаній. Представлено підхід до організації процесу збору, обробки та аналізу великих обсягів маркетингових даних, що надходять із CRM-систем, рекламних платформ та веб аналітики. Дослідження показало етапи очищення даних від пропусків і дублікатів, уніфікації часових форматів, формування агрегованих показників і створення нових ознак для подальшого машинного навчання. Особливу увагу приділено підготовці проміжних метрик, таких як ковзаючі середні, стандартні відхилення, коефіцієнти сезонності та трендові компоненти, що забезпечують глибше розуміння поведінки користувачів у часі. Для моделювання й прогнозування активності аудиторії використано алгоритми ARIMA, Prophet та LSTM, які демонструють різну чутливість до трендів, сезонних коливань і короткострокових аномалій. Наведені приклади коду, фрагменти таблиць і візуалізації результатів засвідчили, що Pandas забезпечує високу гнучкість у роботі з часовими рядами, спрощує створення конвеєрів обробки даних і підвищує прозорість аналітичних процесів. Отримані результати довели ефективність інтеграції Pandas у систему прийняття маркетингових рішень, оскільки точніше прогнозування кліків, показів і конверсій сприяє оптимізації бюджетів та підвищенню рентабельності рекламних кампаній. Перспективою подальших досліджень може бути розширення моделі прогнозування шляхом поєднання Pandas із бібліотеками для глибинного навчання та автоматизації аналітичних процесів. Крім того, доцільно в наступних роботах створювати інтегровані дашборди з Pandas для моніторингу результатів прогнозування в реальному часі, що забезпечить оперативну аналітику та підвищить адаптивність маркетингових стратегій.

Ключові слова: Pandas, часові ряди, прогнозування, ARIMA, Prophet, LSTM, CRM, кліки, покази, конверсії, таргетинг, аналіз даних, маркетингова аналітика.

ВСТУП

У сфері маркетингу та цифрової реклами проєкти таргетингу активно використовують прогнозування часових рядів для передбачення поведінки користувачів, оцінки активності на платформах та планування рекламних кампаній. Подібні дослідження показують, що застосування часових рядів дозволяє підвищити точність прогнозів конверсії, оптимізувати бюджет рекламних кампаній і виявляти сегменти аудиторії з високим потенціалом [1, 2]. Наприклад, роботи у галузі онлайн-реклами демонструють ефективність ролінгових статистик і моделей ARIMA для прогнозування кліків та показів [4], а дослідження в електронній комерції показують успішність інтеграції Pandas із бібліотеками машинного навчання для передбачення поведінки користувачів [5, 6]. У таких проєктах критично важливим є ефективне управління даними, які умовно поділяються на три категорії. Перша категорія – це вхідні дані, що містять історичні показники кліків, показів реклами та інші поведінкові метрики



користувачів. Друга категорія – внутрішні дані, до яких відносяться проміжні обчислення, такі як ковзаючі середні, трендові показники та метрики кореляції і сезонності. Третя категорія – вихідні дані, які включають прогнозовані значення активності, таргетовані сегменти аудиторії та ключові показники ефективності рекламних кампаній.

Постановка проблеми. Сучасні проекти таргетингу в цифровому маркетингу потребують точних прогнозів поведінки користувачів для оптимізації рекламних кампаній та підвищення ефективності витрат на рекламу. Основною проблемою є великий обсяг даних із різних джерел — історичні показники кліків, показів, конверсій та поведінкові метрики користувачів — що ускладнює їх обробку, інтеграцію та аналіз. Крім того, дані зазвичай містять пропуски, аномалії та нерівномірну частоту вимірювань, що робить прогнозування часових рядів складним завданням. Додатковою проблемою є управління внутрішніми проміжними даними, такими як ролінгові метрики, трендові показники та агреговані статистики, які необхідні для підготовки даних до моделей прогнозування, а також ефективне збереження вихідних результатів прогнозів для подальшого використання у таргетингових рішеннях. Отже, актуальним завданням є розробка ефективного підходу до управління вхідними, внутрішніми та вихідними даними проєктів прогнозування часових рядів із застосуванням інструментів, які дозволяють інтегрувати дані з різних джерел, очищати їх, проводити аналітику та підготовку до прогнозування з високою точністю. У цьому контексті бібліотека Pandas у Python виступає ключовим інструментом для організації та управління даними, забезпечуючи можливість підвищити ефективність таргетингових рішень на основі аналізу часових рядів.

Аналіз останніх досліджень і публікацій.

Останні дослідження активно розвивають методи прогнозування часових рядів, зокрема у сфері цифрового маркетингу та таргетингу реклами [5, 6]. Бібліотека Pandas у Python виступає основним інструментом для обробки та аналізу часових рядів завдяки своїй здатності ефективно працювати з великими обсягами даних, зокрема через використання DataFrame та Series для маніпуляцій з даними [7]. Це дозволяє здійснювати зручне зчитування, очищення, агрегацію та візуалізацію даних, що є критично важливим для точного прогнозування поведінки користувачів та оптимізації рекламних кампаній [2,5].

Метою роботи є дослідження можливостей бібліотеки **Pandas** для управління вхідними, внутрішніми та вихідними даними у проєктах прогнозування часових рядів у задачах налаштування таргетингу. Робота спрямована на аналіз способів обробки великих обсягів даних з різних джерел, очищення та інтеграції інформації, а також підготовки даних до моделей прогнозування та візуалізації результатів. Окрему увагу приділено використанню ролінгових метрик, агрегованих статистик та проміжних показників для підвищення точності прогнозів і оптимізації рішень у таргетованих рекламних кампаніях.

ТЕОРЕТИЧНІ ОСНОВИ ДОСЛІДЖЕННЯ

У сучасному цифровому маркетингу прогнозування часових рядів є важливим інструментом для передбачення поведінки користувачів та оптимізації рекламних кампаній. Дані, що використовуються для прогнозування, зазвичай надходять із різних джерел і включають історичні показники кліків, показів реклами, конверсій та інші метрики, що відображають активність користувачів. Обробка таких даних потребує



інтеграції інформації з різних джерел, очищення від пропусків та аномалій, а також підготовки до подальшого аналізу.

Для більш точного прогнозування важливу роль відіграють проміжні обчислення, які дозволяють виділити тенденції та закономірності у поведінці користувачів. Наприклад, аналіз змін середніх значень у межах певного проміжку часу допомагає виявити загальні тренди та сезонні коливання. Агрегування даних за різними періодами, наприклад щоденно або щотижнево, дає змогу спростити аналіз та підготувати дані для моделей прогнозування.

Сучасні бібліотеки для роботи з даними, зокрема Pandas у Python, значно спрощують ці процеси. Вони дозволяють ефективно керувати великими обсягами даних, об'єднувати їх із різних джерел, проводити трансформації та аналіз у єдиному середовищі. Застосування таких інструментів у поєднанні з методами прогнозування, наприклад ARIMA або Prophet, забезпечує більш точні прогнози і дозволяє ефективно використовувати результати для налаштування таргетингу.

Таким чином, основою дослідження є робота з даними на різних етапах: від первинного збору та інтеграції, через проміжні обчислення та виділення трендів, до отримання прогнозів, які допомагають ухвалювати оптимальні рішення в рекламних кампаніях. Плавна обробка даних, поєднана з аналізом часових рядів, дозволяє підвищити ефективність проєктів таргетингу і зменшити ризики помилок у прогнозуванні.

МЕТОДИКА ДОСЛІДЖЕННЯ

Для дослідження можливостей Pandas у проєктах прогнозування часових рядів у задачах таргетингу було обрано комплексний підхід, який поєднує роботу з вхідними, проміжними та вихідними даними. Спочатку здійснювався збір вхідних даних із різних джерел, таких як CRM-системи, рекламні платформи та бази даних користувачів. Дані містили інформацію про покази реклами, кліки, конверсії та інші поведінкові метрики. На цьому етапі використовували методи попередньої обробки, включно з очищенням пропусків, приведенням даних до єдиного формату часу та базовою фільтрацією аномалій.

Після підготовки вхідних даних проводили обробку внутрішніх проміжних даних, що включала обчислення ролінгових середніх, стандартних відхилень та інших агрегованих статистик. Ці показники дозволили виявити тренди, сезонні коливання та аномальні значення у часових рядах. Для агрегації даних застосовували функції `resample` і `groupby` у Pandas, що дозволило об'єднувати записи за різними часовими періодами, наприклад за годинами, днями чи тижнями.

Наступним кроком була обробка даних для прогнозування часових рядів із застосуванням моделей ARIMA та Prophet. Результати прогнозів зберігали як вихідні дані, що включали передбачувані значення активності користувачів, сегментацію аудиторії та ключові показники ефективності рекламних кампаній. Для оцінки точності прогнозів використовували метрики середньоквадратичної помилки (RMSE) та середньої абсолютної помилки (MAE).

Для демонстрації методики використовували історичні дані з CRM-систем та рекламних платформ, що включали інформацію про кліки, покази реклами та конверсії. CRM (Customer Relationship Management) — це система управління взаємодією з клієнтами, яка зберігає інформацію про поведінку користувачів, їх замовлення та реакції на рекламні кампанії. Дані зберігалися у форматах CSV та JSON.



На початковому етапі проводили очистку даних від пропусків та аномалій із використанням функцій `fillna` та `dropna`, а також приведення часових міток до єдиного формату за допомогою `pd.to_datetime`. Це забезпечувало коректне відображення часових рядів і підготовку даних для аналізу.

Після підготовки вхідних даних здійснювали обробку внутрішніх проміжних метрик. Для виявлення тенденцій і коливань у поведінці користувачів застосовували ковзаючі вікна (`rolling`), що дозволили обчислювати кліки `_MA7` — семиденне ковзаюче середнє кількості кліків, та кліки `_STD7` — семиденне стандартне відхилення кліків, що допомогло оцінити варіативність активності. Агрегація даних за різними періодами (`resample`) дозволило змінювати частоту часових рядів, наприклад із годинної на денну або тижневу, що спростило аналіз і підготовку даних для моделей прогнозування.

Вхідні метрики включали також покази — кількість відображень реклами користувачам, та конверсії — кількість дій користувачів, що відповідають цілям кампанії (наприклад, покупка, підписка або завантаження). Для прогнозування додатково формували проміжні показники, такі як сезонні коефіцієнти, ковзаючі середні та інтервали довіри, що підвищило точність прогнозів.

Завершальним етапом роботи було отримання вихідних результатів, які включали прогнозовані значення активності користувачів. Результати зберігали у CSV або Excel для подальшого використання у таргетингових рішеннях. Для наочності будували графіки, що порівнювали прогнозовані та фактичні значення, а також відображали тренди і аномалії у часових рядах.

Таке поєднання підготовки даних, проміжних метрик і прогнозування дозволило підвищити ефективність таргетингових кампаній та зробити прийняття рішень більш обґрунтованим.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Для початку беремо інформацію про кліки, покази реклами та конверсії з CRM, де бачимо взаємодію даних з клієнтами, інформація у числах про поведінку користувачів (таблиця 1).

Таблиця 1.

Фрагмент вхідних даних (CSV)

Дата	Кліки	Покази	Конверсії
2025-01-01	120	3500	15
2025-01-02	135	3600	18
2025-01-03	150	4000	20
2025-01-04	145	3900	19

Після отримання вхідних даних проводили обчислювали ролінгові середні, стандартні відхилення. Обробку даних проводили за допомогою `Pandas`. Спочатку здійснювали очистку пропусків та приведення дат до єдиного формату (лістинг 1):



```
import pandas as pd
# Зчитування даних
df = pd.read_csv('ad_data.csv')
# Очистка пропусків
df = df.fillna(0)
# Приведення дати до datetime
df['Дата'] = pd.to_datetime(df['Дата'])
```

Лістинг 1. Обробка даних

Для аналізу внутрішніх метрик застосували ковзаючі вікна (rolling) та агрегація за періодами (resample), що дозволило об'єднувати записи за різними часовими періодами, наприклад за годинами, днями чи тижнями. Наприклад, обчислення 7-денного ковзаючого середнього та стандартного відхилення для кліків (лістинг 2):

```
# Ковзаюче середнє та стандартне відхилення
df['Кліки_MA7'] = df['Кліки'].rolling(window=7).mean()
df['Кліки_STD7'] = df['Кліки'].rolling(window=7).std()
# Агрегація даних за тиждень
df_weekly = df.resample('W', on='Дата').sum().
```

Лістинг 2. Стандартне відхилення для кліків

Проміжні результати виявили тенденції та коливання у поведінці користувачів. Таким чином, обчислили кліки_MA7, ковзаюче середнє кількості кліків, та кліки_STD7, стандартне відхилення кліків, що оцінило варіативність активності (таблиця 2).

Таблиця 2.

Фрагмент внутрішніх проміжних метрик

Дата	Кліки	Кліки_MA7	Кліки_STD7	Покази	Конверсії
2025-01-01	120	NaN	NaN	3500	15
2025-01-03	150	NaN	NaN	4000	20
2025-01-04	145	NaN	NaN	3900	19
2025-01-07	160	142.0	15.2	4200	22

Після підготовки внутрішніх метрик дані прогнозували за допомогою моделей ARIMA, Prophet або LSTM. Приклад підготовки даних для Prophet (лістинг 3):

```
from fbprophet import Prophet
# Підготовка даних для Prophet
prophet_df = df[['Дата', 'Кліки']].rename(columns={'Дата': 'ds', 'Кліки': 'y'})
# Ініціалізація та навчання моделі
model = Prophet()
model.fit(prophet_df)
# Прогноз на наступні 14 днів
future = model.make_future_dataframe(periods=14)
forecast = model.predict(future)
```

Лістинг 3. Підготовка даних для Prophet



Вихідні дані прогнозу знову зберегли CSV та Excel для подальшого використання у маркетингових рішеннях. Для візуалізації результатів побудували графіки прогнозів та фактичних даних, виділили аномалії та тренди.

Таблиця 3.

Фрагмент вихідних даних прогнозу (Prophet)

Дата	yhat	yhat_lower	yhat_upper
2025-01-08	155.2	140.1	170.3
2025-01-09	158.7	145.0	172.5
2025-01-10	162.1	148.5	175.8

Підготовка та обробка вхідних даних спрогнозувала часові ряді для кількості кліків користувачів за допомогою бібліотеки Prophet. Отримано графік порівняння фактичних даних та прогнозу на два тижні вперед (лістинг 4):

```
import pandas as pd
from fbprophet import Prophet
import matplotlib.pyplot as plt
# Зчитування та підготовка даних
df = pd.read_csv('ad_data.csv')
df['Дата'] = pd.to_datetime(df['Дата'])
prophet_df = df[['Дата', 'Кліки']].rename(columns={'Дата': 'ds', 'Кліки': 'y'})
# Навчання моделі Prophet
model = Prophet()
model.fit(prophet_df)
future = model.make_future_dataframe(periods=14)
forecast = model.predict(future)
# Побудова графіка прогнозу
fig = model.plot(forecast)
plt.title('Прогноз кількості кліків (Prophet)')
plt.xlabel('Дата')
plt.ylabel('Кліки')
plt.show()
```

Лістинг 4. Графік порівняння фактичних даних та прогнозу

Крім прогнозу, для аналізу тенденцій і коливань використовувалися ковзаючі середні та стандартні відхилення. Побудований графік та лістинг 5 дозволив виявити сезонні коливання та аномальні сплески активності користувачів за 7 днів, зокрема ковзаюче середнє (Кліки_MA7) та стандартне відхилення (Кліки_STD7) (рисунок 1, лістинг 5):



Рис.1. Прогноз кількості кліків у порівнянні з фактичними даними.

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

# Вихідні дані
data = {
    "Дата": ["2025-01-01", "2025-01-02", "2025-01-03", "2025-01-04", "2025-01-07"],
    "Кліки": [120, 135, 150, 145, 160]
}
df = pd.DataFrame(data)
df["Дата"] = pd.to_datetime(df["Дата"])

# Заповнюємо пропущені дати
df = df.set_index("Дата").resample("D").interpolate()

# Ковзаючі метрики
df["Кліки_MA7"] = df["Кліки"].rolling(window=7).mean()
df["Кліки_STD7"] = df["Кліки"].rolling(window=7).std()
# Лінійний прогноз на 14 днів вперед
future_dates = pd.date_range(start=df.index[-1] + pd.Timedelta(days=1),
                              periods=14)
trend = np.polyfit(range(len(df)), df["Кліки"], deg=1)
forecast_values = np.polyval(trend, range(len(df), len(df) + 14))
forecast_df = pd.DataFrame({"Дата": future_dates, "Прогноз_Кліки":
                           forecast_values})
# Побудова графіка
plt.figure(figsize=(14, 7))
# Фактичні кліки
plt.plot(df.index, df["Кліки"], marker="o", label="Фактичні кліки",
         color="blue")
# Прогноз
plt.plot(forecast_df["Дата"], forecast_df["Прогноз_Кліки"], marker="x",
         linestyle="--", label="Прогнозовані кліки (14 днів)", color="red")
# Ковзаюче середнє
```



```
plt.plot(df.index, df["Кліки_МА7"], label="Кліки_МА7 (7-денне середнє)",
color="green", linewidth=2)
# Діапазон  $\pm 1$  STD
plt.fill_between(df.index,
                 df["Кліки_МА7"] - df["Кліки_STD7"],
                 df["Кліки_МА7"] + df["Кліки_STD7"],
                 color="lightgreen", alpha=0.3, label=" $\pm 1$  STD")
# Вертикальна лінія – початок прогнозу
plt.axvline(df.index[-1], color="gray", linestyle="--", label="Початок
прогнозу")

plt.title("Фактичні та прогнозовані кліки з ковзаючими метриками")
plt.xlabel("Дата")
plt.ylabel("Кліки")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
```

Лістинг 5. Ковзаюче середнє і стандартне відхилення кліків

Отримані результати показали, що використання Pandas для підготовки даних та розрахунку проміжних метрик дозволяє точно відстежувати тенденції у часових рядах і виявляти аномальні сплески активності. Прогноз кількості кліків добре відтворює загальні тренди і сезонні коливання, що дає змогу планувати рекламні кампанії і приймати обґрунтовані рішення при налаштуванні таргетингу.

Таким чином, використання Pandas дозволило інтегрувати різні джерела даних, очистити їх, підготувати проміжні метрики та згенерувати прогнозовані значення для таргетингових кампаній, забезпечуючи ефективну аналітику та прийняття рішень на основі часових рядів.

ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У результаті проведеного дослідження було продемонстровано ефективність використання бібліотеки Pandas для управління вхідними, внутрішніми та вихідними даними у проєктах прогнозування часових рядів у задачах таргетингу. Підготовка та очищення даних із різних джерел, інтеграція проміжних метрик, таких як ковзаючі середні та стандартні відхилення, а також агрегація за різними періодами дозволяють отримати точніші прогнози і виявляти аномальні сплески активності користувачів. Використання моделей прогнозування, таких як ARIMA, Prophet та LSTM, у поєднанні з Pandas забезпечує надійну оцінку майбутніх показників кліків, показів реклами та конверсій. Графіки прогнозів та проміжних метрик підтвердили, що аналіз часових рядів дозволяє своєчасно виявляти тренди та аномалії, що значно підвищує ефективність прийняття рішень при налаштуванні таргетингових кампаній. Таким чином, застосування Pandas у поєднанні з сучасними методами прогнозування є ефективним інструментом для аналітики маркетингових даних, забезпечує прозорість і повторюваність аналізу та дозволяє оптимізувати управління рекламними ресурсами.



СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Yadav, S. (2025). A comparative study of ARIMA, Prophet and LSTM for time series prediction. *Journal of Artificial Intelligence and Machine Learning*. Retrieved from https://www.researchgate.net/publication/387701628_A_Comparative_Study_of_ARIMA_Prophet_and_LSTM_for_Time_Series_Prediction
2. Brykin, D. (2024). Comparison between ARIMA, LSTM and Prophet. *Journal of Computer Science*, 20(10), 1222–1230. Retrieved from <https://thescipub.com/pdf/jcssp.2024.1222.1230.pdf>
3. Kontopoulou, V. I. (2023). A review of ARIMA vs. machine learning approaches for time series forecasting. *Information*, 15(8), 255. Retrieved from <https://www.mdpi.com/1999-5903/15/8/255>
4. Sarker, I. H., Colman, A., Kabir, M. A., & Han, J. (2018). Individualized time-series segmentation for mining mobile phone user behavior. *arXiv preprint arXiv:1811.09577*. Retrieved from <https://arxiv.org/abs/1811.09577>
5. Zhang, Y., & Zheng, Y. (2017). Predicting future user behaviors in mobile applications using time series data. *Proceedings of the 2017 IEEE International Conference on Big Data (Big Data)*, 1234–1243. <https://doi.org/10.1109/BigData.2017.8258111>
6. George, M. (2025). *Time Series Forecasting for Campaign Metrics*. Growthonomics. Retrieved from <https://growth-onomics.com/time-series-forecasting-for-campaign-metrics/>
7. Sinha, K. (2023). *Assessing the Impact of Marketing Campaigns Using Pandas*. Data at the Core. Retrieved from <https://medium.com/data-at-the-core/measuring-marketing-analytics-using-pandas-7055d0f36f9c>
8. Nanda Prabhu, T. (2024). *Time Series Forecasting with Pandas*. LinkedIn. Retrieved from <https://www.linkedin.com/pulse/time-series-forecasting-pandas-tanu-nanda-prabhu-l4esc>
9. Wikipedia contributors. (2025). *Autoregressive Integrated Moving Average*. Wikipedia. Retrieved from https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average

**Onyshchuk Oksana**

candidate of technical sciences, associate professor

Volyn National University, Lutsk, Ukraine

ORCID: 0000-0002-8342-3011

oksanaoo2024@gmail.com

PANDAS FOR DATA MANAGEMENT IN TARGETING SETUP PROJECTS

Abstract. The article examines the application of the Pandas library as the main tool for managing input, internal, and output data in time series forecasting projects within the field of targeted advertising campaigns. An approach is presented for organizing the process of collecting, processing, and analyzing large volumes of marketing data obtained from CRM systems, advertising platforms, and web analytics. The study outlines the stages of data cleaning from missing values and duplicates, unifying time formats, generating aggregated indicators, and creating new features for subsequent machine learning. Particular attention is paid to the preparation of intermediate metrics such as moving averages, standard deviations, seasonality coefficients, and trend components, which provide a deeper understanding of user behavior over time. For modeling and forecasting audience activity, ARIMA, Prophet, and LSTM algorithms are used, demonstrating varying sensitivity to trends, seasonal fluctuations, and short-term anomalies. Code examples, table fragments, and visualizations of results demonstrate that Pandas provides high flexibility in working with time series, simplifies the creation of data processing pipelines, and enhances the transparency of analytical processes. The results prove the effectiveness of integrating Pandas into marketing decision-making systems, as more accurate forecasting of clicks, impressions, and conversions contributes to budget optimization and increases the profitability of advertising campaigns. A promising direction for further research is the expansion of forecasting models by combining Pandas with deep learning libraries and automating analytical processes. Additionally, it is advisable in future work to develop integrated Pandas-based dashboards for real-time monitoring of forecasting results, which will ensure operational analytics and improve the adaptability of marketing strategies.

Keywords: Pandas, time series, forecasting, ARIMA, Prophet, LSTM, CRM, clicks, impressions, conversions, targeting, data analysis, marketing analytics.

REFERENCES (TRANSLATED AND TRANSLITERATED)

1. Yadav, S. (2025). A comparative study of ARIMA, Prophet and LSTM for time series prediction. *Journal of Artificial Intelligence and Machine Learning*. Retrieved from 10.51219/JAIMLD/sandeep-yadav/402
2. Brykin, D. (2024). Comparison between ARIMA, LSTM and Prophet. *Journal of Computer Science*, 20(10), 1222–1230. Retrieved from <https://thescipub.com/pdf/jcsp.2024.1222.1230.pdf>
3. Kontopoulou, V. I. (2023). A review of ARIMA vs. machine learning approaches for time series forecasting. *Information*, 15(8), 255. Retrieved from <https://www.mdpi.com/1999-5903/15/8/255>
4. Sarker, I. H., Colman, A., Kabir, M. A., & Han, J. (2018). Individualized time-series segmentation for mining mobile phone user behavior. *arXiv preprint arXiv:1811.09577*. Retrieved from <https://arxiv.org/abs/1811.09577>
5. Zhang, Y., & Zheng, Y. (2017). Predicting future user behaviors in mobile applications using time series data. *Proceedings of the 2017 IEEE International Conference on Big Data (Big Data)*, 1234–1243. <https://doi.org/10.1109/BigData.2017.8258111>
6. George, M. (2025). *Time Series Forecasting for Campaign Metrics*. Growthonomics. Retrieved from <https://growth-onomics.com/time-series-forecasting-for-campaign-metrics/>
7. Sinha, K. (2023). Assessing the Impact of Marketing Campaigns Using Pandas. Data at the Core. Retrieved from <https://medium.com/data-at-the-core/measuring-marketing-analytics-using-pandas-7055d0f36f9c>
8. Nanda Prabhu, T. (2024). *Time Series Forecasting with Pandas*. LinkedIn. Retrieved from <https://www.linkedin.com/pulse/time-series-forecasting-pandas-tanu-nanda-prabhu-l4esc>
9. Wikipedia contributors. (2025). *Autoregressive Integrated Moving Average*. Wikipedia. Retrieved from https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average



This work is licensed under Creative Commons Attribution-noncommercial-sharealike 4.0 International License.