

ВИКОРИСТАННЯ МЕТОДІВ КОНСТРУКТИВНО-ПРОДУКЦІЙНОГО МОДЕЛЮВАННЯ ДЛЯ ПРОГНОЗУВАННЯ ДЕТЕРМІНОВАНИХ ЧАСОВИХ РЯДІВ

Анотація. Прогнозування часових рядів є одним із ключових завдань сучасного аналізу даних та моделювання складних систем. У даній роботі розглядається застосування конструктивно-продукційного підходу для роботи з детермінованими фрактальними часовими рядами. Мета роботи полягає у відновленні конструктивної моделі, яка відображає внутрішню структуру ряду та дозволяє здійснювати його продовження за визначеними правилами генерації. Для перевірки ефективності підходу було сформовано набір синтетичних рядів, породжених конструктивними моделями різного рівня складності. У свою чергу, відновлення моделей виконувалося за допомогою спеціалізованого програмного додатку. Прогнозна здатність методу перевірялася шляхом порівняльного аналізу з класичними моделями прогнозування, зокрема ARIMA, LSTM, ARIMA-LSTM та CNN-LSTM. Точність оцінювалася за метриками MAE та MAPE. Результати показали, що конструктивно-продукційне моделювання забезпечує найвищу точність прогнозування серед усіх протестованих моделей, що є очікуваним з огляду на природу вхідних рядів. Важливо підкреслити, що на відміну від традиційних методів, даний підхід надає можливість отримати не лише прогнозні значення, але й конструктивну модель часового ряду, придатну для подальшого структурного аналізу, виявлення закономірностей та дослідження властивостей. Таким чином, проведене дослідження підтверджує ефективність і доцільність використання конструктивно-продукційного моделювання для прогнозування детермінованих фрактальних часових рядів.

Ключові слова: програмна інженерія, конструктивно-продукційне моделювання інформаційних технологій, фрактали, фрактальні часові ряди, генетичний алгоритм, L-система.

Вступ. Існує велика кількість методів опису динаміки складних систем протягом визначеного проміжку часу. Найбільш класичним і поширеним підходом є побудова часових рядів, що відображають зміну загального стану системи або окремих її показників на основі результатів спостережень. Часові ряди слугують базою для проведення детального аналізу поведінки системи.

У наукових дослідженнях виділяють три основні завдання роботи з часовими рядами: аналіз, моделювання та прогнозування [1]. Пріоритетність кожного із завдань ви-

значається кінцевою метою дослідження, однак найбільшу увагу зазвичай приділяють прогнозуванню, яке дозволяє оцінити можливі майбутні стани системи.

У сучасній практиці методи прогнозування значно еволюціонували завдяки розвитку математичних підходів і впровадженню інформаційних технологій, що забезпечило автоматизацію обчислювальних процесів.

Класичні методи прогнозування поділяються на дві основні групи: лінійні та нелінійні [2]. Лінійні моделі базуються на припущенні, що залежності між значеннями ряду можна адекватно описати лінійною комбінацією. Вони відзначаються простотою реалізації, але обмежені у точності. Нелінійні моделі, своєю чергою, здатні відображати складні та нетривіальні взаємозв'язки між значеннями ряду, що забезпечує їх більшу універсальність і точність при моделюванні реальних систем.

Прикладом складної залежності в часових рядах є наявність фрактальних властивостей. Це проявляється у повторюваних паттернах, форма яких зберігається при розгляді на різних масштабах. Водночас попередні значення ряду можуть впливати на поточні у довільних часових інтервалах [3].

Для роботи з рядами такої природи, окрім класичних методів, застосовуються підходи конструктивно-продукційного моделювання [4]. Зокрема, розроблені методики генерації синтетичних детермінованих часових рядів, а також зворотні процедури відновлення даних для формування вхідних послідовностей. Слід зазначити, даний підхід дозволяє не лише оперувати лише загальними засобами та значеннями часового ряду, але також визначає конструктивні моделі, які описуються часові ряди [5]. Дана особливість виділяє підхід конструктивізму від класичних вищезазначених методів.

Мета роботи. Метою даної роботи є порівняння ефективності використання елементів конструктивно-продукційного моделювання для подовження фрактальних детермінованих часових рядів з іншими відомими моделями прогнозування (лінійними та нелінійними) з оцінкою ефективності, здійсненою за допомогою методів оцінки MAE та MAPE [6,7].

Конструктивно-продукційне моделювання. Основний принцип конструктивно-продукційного моделювання при роботі з детермінованими часовими рядами полягає у визначенні об'єктів композитного конструктора та його складових сутностей, які разом визначають загальну поведінку системи на основі узагальненого конструктора []. Цей підхід дозволяє формалізувати структуру часових рядів і забезпечує можливість їх аналізу та передбачення подальших значень на основі заданих правил генерації.

Для відновлення конструктивної моделі часового ряду були виділені три ключових конструктора, кожен з яких виконує специфічну функцію:

- C_{MS} – формує фрактальну мультисимвольну послідовність відповідно по зазначених правил;
- C_{TS} – перетворює вищезазначену символьну послідовність у фрактальний часовий ряд відповідно за визначених початкового значення та його перетворення;
- C_{RS} – відновлює похідну модель наданого часового ряду.

Кожен з зазначених конструкторів відповідає за відповідну операцію в рамках композитного конструктора C_M , який у свою чергу має два визначених варіанти виконання: контроль якості перетворення часових рядів у конструктивну модель (MQ) та екстраполяція часових рядів для прогнозування (MF) [8].

Основною метою режиму MQ є визначення процесу верифікації роботи побудованого процесу за рахунок випробувань на синтетичних часових рядах, згенерованих за задалегідь визначеною конструктивною моделлю. Він включає наступні етапи:

- випадково генерує правило підстановки;
- послідовно ініціює виконання конструкторів C_{MS} , C_{TS} та C_{RS} ;
- передає параметри та отримує згенеровані структури (правило підстановки, зрештою знайдене конструктором C_{RS});
- порівнює дані, передані конструктору C_{MS} , та отримані від C_{RS} правила підстановки, та визначає різницю між результатами;
- неодноразово виконує попередні кроки.

Виконання в режимі MF описує загальний процес обробки наданого ряду з генерацією його конструктивної моделі та на її основі продовженням його значень на визначений проміжок. Порядок виконання включає наступні етапи:

- отримує часовий ряд;
- послідовно ініціює виконання конструкторів C_{RS} , C_{MS} та C_{TS} ;
- отримує сформовані структури та часовий ряд з продовженням.

Ключовим елементом, що визначає ітеративну поведінку системи, є генетичний алгоритм. Відповідно до його класичної реалізації з урахуванням необхідних модифікацій відповідно до області використання, процес включає фази: генерації початкової популяції хромосом, кросовера та мутацію, оцінку життєздатності кожного представника та подальшу селекцію.

Структура хромосоми відповідає набору параметрів конструктивної моделі часового ряду, та включає наступні сутності:

$$X = \langle f, P, V_f, dV_f \rangle, \quad (1)$$

де f – аксіома L-системи, P – визначені правила заміщення, V_f – початкове значення часового ряду та dV_f – його приріст. Визначений алфавіт системи включає термінальні символи, кожному з яких відповідає операція інтерпретації (табл. 1) при перетворенні фінального мультисимвольного рядка у часовий ряд (рис. 1).

На етапі селекції з кожної хромосоми формується часовий ряд, який порівнюється з вхідним за допомогою МНК. Отримане значення виступає у ролі фітнес-функції, оцінюючи точність відповідності моделі та визначаючи її життєздатність у популяції [8].

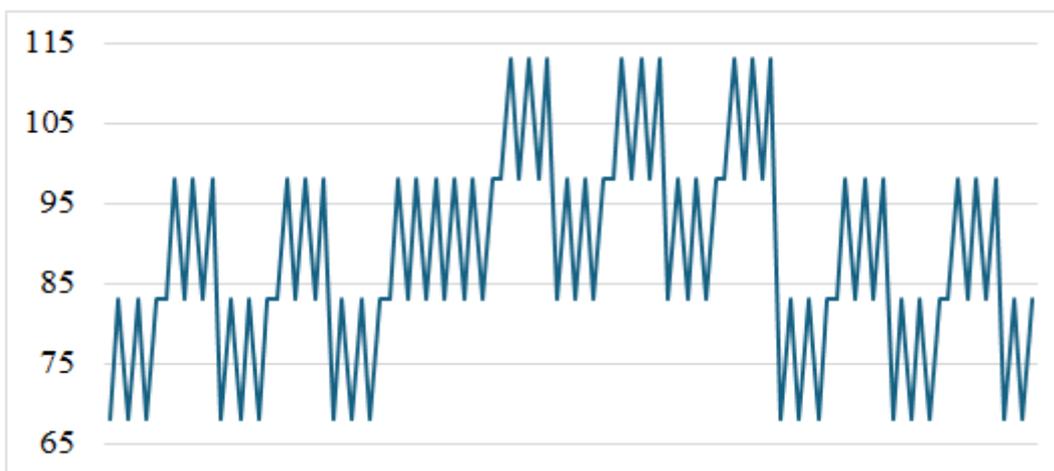


Рисунок 1 – Ряд заданий моделлю з параметрами
 $\{P: f \rightarrow f + f + f - f-; V_f = 68, dV_f = 15\}$

Таблиця 1

Опис набору терміналів та їх відповідних операції

Термінальний символ	Відповідна операція
f	Додає нову точку до часового ряду, значення якої дорівнює поточному значенню V_f
+	Збільшує поточне значення параметру V_f відповідно до значення dV_f .
-	Зменшує поточне значення параметру V_f відповідно до значення dV_f .

Фрактальність рядів породжених конструктивною моделлю. Аналіз властивостей рядів, породжених конструктивною моделлю, свідчить про їх фрактальну природу. Це підтверджується на основі загальновідомих показників, зокрема через дві ключові характеристики: самоподібність та фрактальну розмірність, що оцінюється за допомогою показника Херста [9].

Самоподібність у даному випадку може бути наочно продемонстрована шляхом ітеративної розгортки породжуючої L-системи [10] конструктивної моделі. У процесі послідовної заміни терміналів відповідними правими частинами правил заміщення відтворюється глобальний патерн, що повторює себе на різних масштабах і визначає самоподібну структуру часового ряду (рис. 2).

Додаткове підтвердження фрактальності було отримано на основі розрахунку показника Херста. Для часових рядів, породжених конструктивною моделлю, значення

цього показника стабільно перевищують 0,8. Це свідчить про персистентність та виражену тенденцію до продовження поточного руху значень ряду та означає, що поведінка системи в майбутньому суттєво залежить від її попередніх станів.

У свою чергу, розрахована фрактальна розмірність Гаусдорфа [11] для таких рядів становить близько $D \approx 1.2$. Дане значення підтверджує їх фрактальну природу та узгоджується з виявленою властивістю самоподібності.

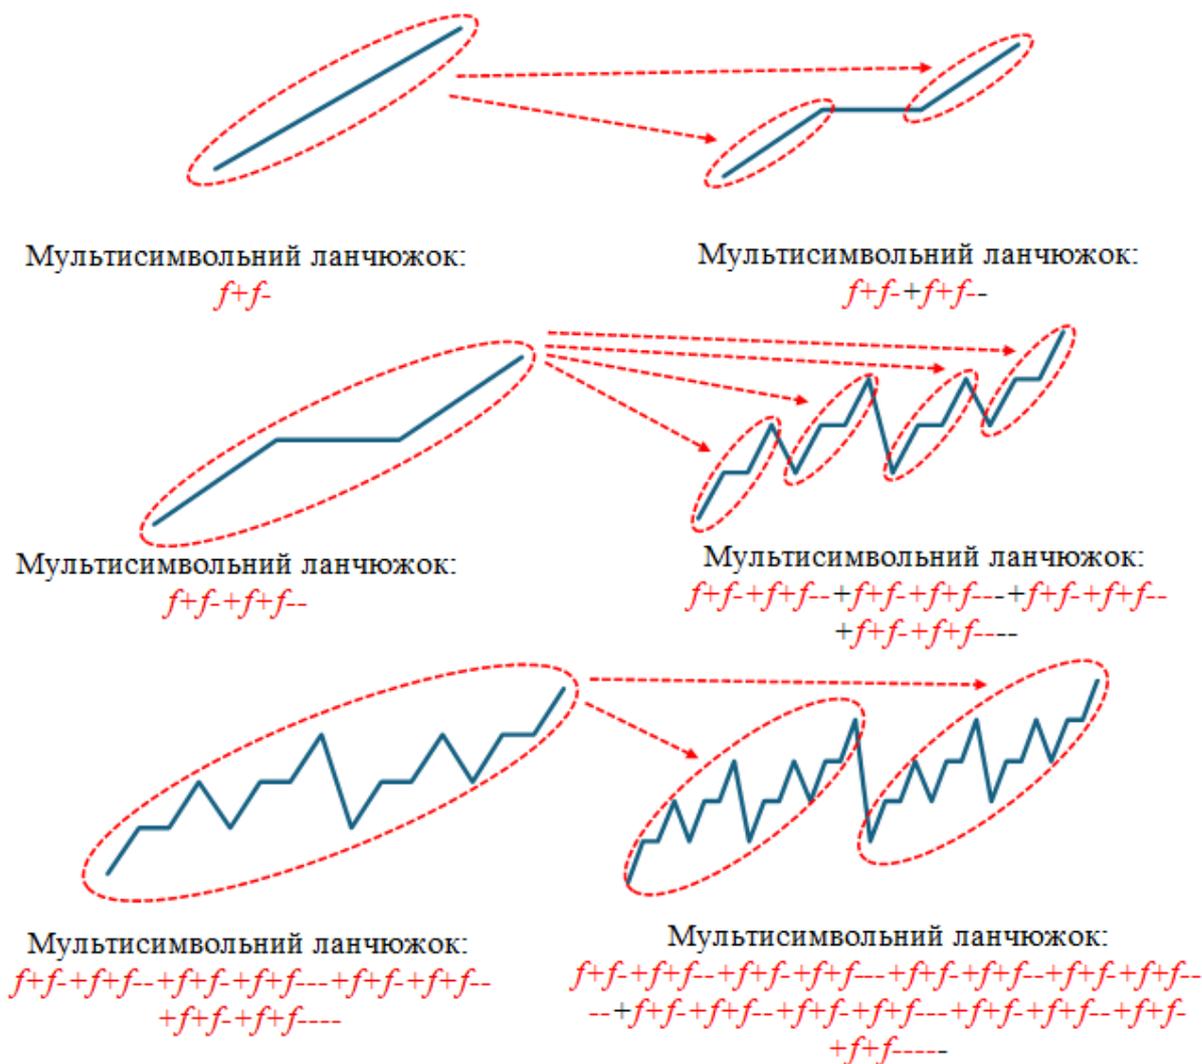


Рисунок 2 – Покрокова розгортка ряду заданого моделлю з параметрами

$$\{f, P: f \rightarrow f + f-; V_f = 15, dV_f = 10\}$$

Обрані моделі для порівняння ефективності. У протиположності до підходу конструктивізму, для оцінки ефективності операції передбачення подальших значень ряду були обрані загальновідомі лінійні та нелінійні моделі. Одними з найпопулярніших лінійних моделей прогнозування часових рядів є моделі типу ARIMA (Autoregressive Integrated Moving Average) [12]. Вона являє собою узагальненням моделі авторегресійної ковзної середньої (ARMA) й стала класичним підходом для роботи з часовими рядами.

Загальне позначення описується як $ARIMA(p, d, q)$, де параметр p визначає порядок (кількість часових затримок) компоненту авторегресії, параметр d – кількість ра-

зів, коли з даних віднімали попередні значення (порядок диференціювання), а параметр q – порядок моделі ковзного середнього.

Найчастіше ARIMA використовується з часовими рядами обмеженої довжини [13], які не мають чіткої сезонності значень [14] та мають явну тенденцію. Також дана модель може виступати як один з компонентів більш складного підходу, як ARIMA-LSTM, де використовується для визначення трендів та кореляції [15].

Основними недоліками зазначеної моделі полягає сама у вузькості області використання. У протизвагу цьому вона пропагує низьку складність та ефективність у застосуванні з відповідними наборами даних.

Для прогнозування рядів які мають складніші зв'язки між своїми значеннями на поточний момент досить широко застосовують засоби машинного навчання. Найбільш популярним є використання рекурентних нейронних мереж [16]. Найпопулярнішими серед них визначають LSTM моделі [17].

Їх суть полягає у наявності каналу довготривалої пам'яті, керування яким визначається трьома основними затворами:

- вхідний затвор, який визначає набір даних поточного кроку, який буде записаний у канал пам'яті;
- затвор забування, який визначає частину збережених даних яку потрібно видалити;
- вихідний затвор, який контролює селекцію даних з каналу пам'яті, які необхідно передати на вихід.

За допомогою зазначених компонентів модель крок за кроком зчитує значення часового ряду, формуючи стан у каналі пам'яті. Протягом цього процесу зберігаються коротко строкові та довго строкові зв'язки на основі чого зберігається загальний тренд разом з окремими коливаннями значень часового ряду.

Сфера використання моделей типу LSTM досить широка. Її класична реалізація найчастіше використовується при прогнозуванні фінансових часових рядів, таких як індекси фондових бірж [18] та інших часових рядів зі складними та довготривалими залежностями [19]

Окрім класичного підходу до реалізації даної моделі, існує велика кількість її варіацій, які включають к себе додаткові шари нейронної мережі разом із статистичними моделями, такі як CNN-LSTM [20] та вже зазначена ARIMA-LSTM.

Особливістю першої є наявність додаткового шару згорткової мережі (CNN). Завдяки ньому, модель обробляє локальні патерни, які у випадку часових рядів, являють собою аномальні стани системи. На їх основі формується відповідний набір даних, відображаючи ознаки часового ряду. На основі нього, вже LSTM-модель формує вихідний набір даних, виходячи з визначення довготривалих зв'язків між ознаками часового ряду.

Основною перевагою даної моделі є її можливість працювати з наборами даних, які мають велику шумність значень. Завдяки цьому вона має більш широку область використання, починаючи з вже зазначеного прогнозування показників фондових

бірж [21], та продовжуючи транспортним трафіком [22] та показниками навколишнього середовища [23].

У свою чергу, модель ARIMA-LSTM працює за принципом, подібним до CNN-LSTM. На першому етапі, ARIMA будує лінійний прогноз можливих значень часового ряду. На основі цих даних формується набір залишків, який формується на основі різниці реального значення та лінійного прогнозу.

На наступному етапі, LSTM-частина будує свій прогноз на основі саме залишкових значень. Результуючий прогноз формується як сума двох отриманих наборів двох компонентів моделі. Це дозволяє отримати точніший прогноз за рахунок охоплення лінійних показників та обробку можливих шумів.

Дана модель показала ефективність прогнозування цінних показників з явним проявом сезонності [24] та показників захворюваності інфекційними захворюваннями [25].

Опис експериментальної частини. Для підтвердження сформованої теорії та отримання статистично значущих результатів було сформовано початковий набір експериментальних синтетичних детермінованих часових рядів, що генеруються конструктивними моделями різного рівня складності. На поточному етапі дослідження складність структури конструктивної моделі визначається за довжиною правої частини правила заміщення породжуючої L-системи. Поряд із цим, кількість правил заміщення встановлюється рівною одному. Ця умова обумовлена методом генерації кінцевої послідовності символів.

Загалом було визначень 15 конструктивних моделей відповідної структури. На основі кожної з них, був побудований часовий ряд довжиною в 500 точок.

На основі кожного сформованого часового ряду було проведено процес відновлення конструктивної моделі із застосуванням спеціалізованого автоматизованого програмного додатку [26]. На цьому етапі випробувань для побудови моделі використовувалися лише перші 400 точок ряду, що розглядалися як навчальна вибірка. Решта 100 точок відкладалася для подальшої верифікації прогнозної здатності моделі. Перевірка здійснювалася шляхом оцінки відповідності прогнозованих значень фактичним даним із використанням обраних метрик точності, що дозволяло кількісно оцінити рівень наближення моделі до реальних результатів.

Відповідно до поставленої мети дослідження, були проведені паралельні випробування з використанням зазначених класичних підходів прогнозування. Для забезпечення коректності порівняння експерименти здійснювалися за однаковою методикою:

- перші 400 точок часового ряду використовувалися для навчання моделей;
- останні 100 точок застосовувалися для побудови прогнозу та подальшої оцінки точності, що дозволяло визначити близькість результатів до еталонних значень.

Такий підхід забезпечує можливість безпосереднього порівняння ефективності конструктивно-продукційного моделювання із традиційними методами прогнозування та дозволяє зробити обґрунтовані висновки щодо переваг або обмежень кожного з підходів.

Результати проведених випробувань. Після завершення першого етапу випробувань для всіх вхідних часових рядів було успішно відновлено породжуючі конструктивні моделі (табл. 2). Це свідчить про коректність застосованої методики реконструкції та її здатність відтворювати внутрішню структуру рядів різної складності.

На другому етапі експериментів було проведено прогнозування подальших значень часових рядів із використанням усіх обраних методів (табл. 3).

Таблиця 2

Порівняння наданих та відновлених параметрів рядів

Параметри модельного ряду	Параметри відновленого ряду
$P: f \rightarrow +ff - ff$ $V_f = 54, dV_f = 43$	$P: f \rightarrow ff - ff + ff$ $V_f = 24.95, dV_f = 34.96$
$P: f \rightarrow +ff - ff + f -$ $V_f = 42, dV_f = 31$	$P: f \rightarrow ++ff --ff + +f --$ $V_f = 42.9, dV_f = 15.49$
$P: f \rightarrow +f - f + f -$ $V_f = 78, dV_f = 29$	$P: f \rightarrow +f - f + f -$ $V_f = 75.81, dV_f = 28.98$
$P: f \rightarrow ff - f + +ff -$ $V_f = 24, dV_f = 15$	$P: f \rightarrow ff - f + +ff -$ $V_f = 23.97, dV_f = 14.56$
$P: f \rightarrow f + f + f - f -$ $V_f = 36, dV_f = 45$	$P: f \rightarrow f + f + f - f -$ $V_f = 36.69, dV_f = 44.79$

Таблиця 3

Порівняння точності передбачення подальших значень ряду

№	Метрика	КПМ	ARIMA	LSTM	ARIMA-LSTM	CNN-LSTM
1	MAE	0.24	29.9	2.33	15.3122	5.2323
	MAPE	0.14%	22.08%	1.49%	9.71%	3.30%
2	MAE	0.87	49.6	1.77	17.112	2.6026
	MAPE	1.02%	67.34%	2.32%	15.44%	3.37%
3	MAE	2.27	31.18	3.61	12.4109	4.0443
	MAPE	1.23%	15.57%	1.86%	5.39%	2.28%
4	MAE	0.82	22.49	2.91	9.677	5.9627
	MAPE	1.72%	51.71%	6.02%	15.46%	15.77%
5	MAE	0.5	69.87	8.77	19.3636	9.0058
	MAPE	0.16%	22.98%	3.73%	6.57%	3.94%

Аналіз значень метрик свідчить, що прогнозування на основі конструктивно-продукційних моделей забезпечує найвищу точність при роботі з синтетичними детермінованими часовими рядами.

Разом із тим, результати також демонструють, що нелінійні методи прогнозування (наприклад, нейронні мережі чи інші алгоритми машинного навчання) здатні забезпечувати досить високий рівень точності відтворення часових рядів. Це свідчить про їхню адаптивність та здатність якісно відображати складні внутрішні залежності між значеннями.

Найгірші результати були отримані у випадку застосування ARIMA-моделі, за винятком тих ситуацій, коли вхідний часовий ряд наближався до майже повністю лінійного. Такий результат є закономірним, оскільки область застосування лінійних моделей обмежена рядами з простою структурою та слабко вираженими нелінійними залежностями. У випадку складних фрактальних систем можливості ARIMA є недостатніми для відтворення їх динаміки.

Висновки. У даній роботі було проведено дослідження застосування конструктивно-продукційного підходу для роботи з детермінованими фрактальними часовими рядами з метою прогнозування їх подальших значень. Основна ідея полягала у використанні відновленої конструктивної моделі, що відображає внутрішню структуру часового ряду та дозволяє здійснювати його продовження за рахунок визначених правил генерації.

Експериментальні випробування виконувалися на основі спеціально сформованого набору синтетичних детермінованих часових рядів, породжених конструктивними моделями різного рівня складності. Для перевірки ефективності запропонованого підходу було проведено порівняльний аналіз з результатами роботи відомих класичних та сучасних моделей прогнозування часових рядів, зокрема: ARIMA, LSTM, ARIMA-LSTM та CNN-LSTM.

Відповідно до отриманих результатів, конструктивно-продукційне моделювання продемонструвало високу ефективність при прогнозуванні подальших значень часових рядів. Для кожного з розглянутих випадків точність прогнозування за метриками MAE та MAPE перевищувала результати, отримані іншими обраними моделями. Такий результат є очікуваним з огляду на специфіку постановки задачі та природу вхідних рядів, які мають фрактальну детерміновану структуру, що добре відтворюється конструктивними моделями.

Важливо підкреслити, що на відміну від класичних методів, конструктивно-продукційний підхід забезпечує не лише можливість прямого прогнозування, а й формує конструктивну модель часового ряду, яка може бути використана для подальшого структурного аналізу, виявлення закономірностей та формальних властивостей ряду. Це відкриває додаткові можливості для дослідження внутрішньої організації часових процесів.

Перспективи подальших досліджень у цій галузі пов'язані з генералізацією підходу та його розширенням на більш складні типи часових рядів. Зокрема, подальша робота може бути спрямована на адаптацію методу для роботи зі стохастичними часовими рядами та дослідження рядів, породжених L-системами з кількома правилами заміщення, що забезпечить відтворення більш складних структурних закономірностей;

Таким чином, результати дослідження підтверджують доцільність використання конструктивно-продукційного моделювання для роботи з детермінованими фрактальними часовими рядами та окреслюють напрями його подальшого розвитку.

ЛІТЕРАТУРА

1. Weigend A. Time Series Prediction: Forecasting the Future and Understanding the Past. London, 2018. URL: <https://doi.org/10.4324/9780429492648>.
2. Park M.-J., Yang H.-S. Comparative Study of Time Series Analysis Algorithms Suitable for Short-Term Forecasting in Implementing Demand Response Based on AMI. Sensors. 2024. Vol. 24, No. 22. P. 7205. URL: <https://doi.org/10.3390/s24227205>.
3. Shu Z., Chan P.W. Application of fractal analysis on wind speed time series: A review. Advances in Wind Engineering, 2025, vol. 2, no. 1, p. 100028. ISSN 2950-6018. URL: <https://doi.org/10.1016/j.awe.2024.100028>.
4. Skalozub V., Ilman V., Bilyy B. Constructive multiplayer models for ordering a set of sequences, taking into account the complexity operations of formations. Science and Transport Progress. Bulletin of Dnipropetrovsk National University of Railway Transport, 2020, pp. 61–76. URL: <https://doi.org/10.15802/stp2020/213232>.
5. Shynkarenko K., Lytvynenko R., Chyhir I., Nikitina I. Modeling of lightning flashes in thunderstorm front by constructive production of fractal time series. In: Advances in Intelligent Systems and Computing, vol. 1080, Springer, 2020, pp. 173–185. URL: https://doi.org/10.1007/978-3-030-33695-0_13.
6. Foroutan P., Lahmiri S. Deep learning systems for forecasting the prices of crude oil and precious metals. Financial Innovation, 2024, vol. 10, p. 111. URL: <https://doi.org/10.1186/s40854-024-00637-z>.
7. Khan A.M., Osinska M. Comparing forecasting accuracy of selected grey and time series models based on energy consumption in Brazil and India. Expert Systems with Applications, 2023, vol. 212, p. 118840. ISSN 0957-4174. URL: <https://doi.org/10.1016/j.eswa.2022.118840>.
8. Shynkarenko V., Zhadan A. Modeling of the deterministic fractal time series by one rule constructors. 2020 IEEE 15th International Conference on Computer Sciences and Information Technologies (CSIT), Zbarazh, Ukraine, 2020, pp. 336–339. URL: <https://doi.org/10.1109/CSIT49958.2020.9321923>.
9. Serletis A., Rosenberg A.A. The Hurst exponent in energy futures prices. Physica A: Statistical Mechanics and its Applications, 2007, vol. 380, pp. 325–332.
10. Prusinkiewicz P., Lindenmayer A. The algorithmic beauty of plants. Springer Science & Business Media, 2012.
11. Tsukamoto M. Mean Hausdorff dimension of some infinite-dimensional fractals. Journal d'Analyse Mathématique, 2025, vol. 155, pp. 235–286. URL: <https://doi.org/10.1007/s11854-024-0353-0>.
12. Ospina R., Gondim J.A.M., Leiva V., Castro C. An overview of forecast analysis with ARIMA models during the COVID-19 pandemic: Methodology and case study in Brazil. Mathematics, 2023, vol. 11, p. 3069. URL: <https://doi.org/10.3390/math11143069>.

13. Tarmanini C., Sarma N., Gezegin C., Ozgonenel O. Short term load forecasting based on ARIMA and ANN approaches. *Energy Reports*, 2023, vol. 9, suppl. 3, pp. 550–557. ISSN 2352-4847. URL: <https://doi.org/10.1016/j.egy.2023.01.060>.
14. Bhalla V., Bhalla A., Jain R. A comparison of ARIMA, SARIMA, and statistical models for estimating. In: *Sustainable Computing and Intelligent Systems: Proceedings of SCIS 2024*, vol. 2, 1296, 2025, p. 185.
15. Ray S., Lama A., Mishra P., Biswas T., Das S.S., Gurung B. An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique. *Applied Soft Computing*, 2023, vol. 149, part A, p. 110939. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2023.110939>.
16. Salem F.M. Recurrent Neural Networks (RNN). In: *Recurrent Neural Networks*. Cham: Springer, 2022. URL: https://doi.org/10.1007/978-3-030-89929-5_3.
17. Al-Selwi S.M., Hassan M.F., Abdulkadir S.J., Muneer A., Sumiea E.H., Alqushaibi A., Ragab M.G. RNN-LSTM: From applications to modeling techniques and beyond—Systematic review. *Journal of King Saud University - Computer and Information Sciences*, 2024, vol. 36, no. 5, p. 102068. ISSN 1319-1578. URL: <https://doi.org/10.1016/j.jksuci.2024.102068>.
18. Md A.Q., Kapoor S., Junni A.V.C., Sivaraman A.K., Tee K.F., Sabireen H., Janakiraman N. Novel optimization approach for stock price forecasting using multi-layered sequential LSTM. *Applied Soft Computing*, 2023, vol. 134, p. 109830. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2022.109830>.
19. Wang K., Zhang J., Li X., Zhang Y. Long-term power load forecasting using LSTM-Informer with ensemble learning. *Electronics*, 2023, vol. 12, p. 2175. URL: <https://doi.org/10.3390/electronics12102175>.
20. Elmaz F., Eyckerman R., Casteels W., Latré S., Hellinckx P. CNN-LSTM architecture for predictive indoor temperature modeling. *Building and Environment*, 2021, vol. 206, p. 108327. ISSN 0360-1323. URL: <https://doi.org/10.1016/j.buildenv.2021.108327>.
21. Wu J.M.T., Li Z., Herencsar N., et al. A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems*, 2023, vol. 29, pp. 1751–1770. URL: <https://doi.org/10.1007/s00530-021-00758-w>
22. Wang J.-D., Susanto C.O.N. Traffic flow prediction with heterogenous data using a hybrid CNN-LSTM model. *Computers, Materials and Continua*, 2023, vol. 76, no. 3, pp. 3097–3112. ISSN 1546-2218. URL: <https://doi.org/10.32604/cmc.2023.040914>.
23. Zha W., Liu Y., Wan Y., Luo R., Li D., Yang S., Xu Y. Forecasting monthly gas field production based on the CNN-LSTM model. *Energy*, 2022, vol. 260, p. 124889. ISSN 0360-5442. URL: <https://doi.org/10.1016/j.energy.2022.124889>.
24. Ray S., Lama A., Mishra P., Biswas T., Das S.S., Gurung B. An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique. *Applied Soft Computing*, 2023, vol. 149, part A, p. 110939. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2023.110939>.
25. Jin Y.-C., Cao Q., Wang K.-N., Zhou Y., Cao Y.-P., Wang X.-Y. Prediction of COVID-19 data using improved ARIMA-LSTM hybrid forecast models. *IEEE Access*, 2023, vol. 11, pp. 67956–67967. URL: <https://doi.org/10.1109/ACCESS.2023.3291999>.

26. Shynkarenko V., Zhadan A. Multiservice architecture of software for stochastic fractal time series forecasting. 2024 IEEE Conference on Computer Sciences and Information Technologies, 2024, pp. 1–4. URL: <https://doi.org/10.1109/CSIT65290.2024.10982626>.

REFERENCES

1. Weigend A. Time Series Prediction: Forecasting the Future and Understanding the Past. London, 2018. URL: <https://doi.org/10.4324/9780429492648>.
2. Park M.-J., Yang H.-S. Comparative Study of Time Series Analysis Algorithms Suitable for Short-Term Forecasting in Implementing Demand Response Based on AMI. Sensors. 2024. Vol. 24, No. 22. P. 7205. URL: <https://doi.org/10.3390/s24227205>.
3. Shu Z., Chan P.W. Application of fractal analysis on wind speed time series: A review. Advances in Wind Engineering, 2025, vol. 2, no. 1, p. 100028. ISSN 2950-6018. URL: <https://doi.org/10.1016/j.awe.2024.100028>.
4. Skalozub V., Ilman V., Bilyy B. Constructive multiplayer models for ordering a set of sequences, taking into account the complexity operations of formations. Science and Transport Progress. Bulletin of Dnipropetrovsk National University of Railway Transport, 2020, pp. 61–76. URL: <https://doi.org/10.15802/stp2020/213232>.
5. Shynkarenko K., Lytvynenko R., Chyhir I., Nikitina I. Modeling of lightning flashes in thunderstorm front by constructive production of fractal time series. In: Advances in Intelligent Systems and Computing, vol. 1080, Springer, 2020, pp. 173–185. URL: https://doi.org/10.1007/978-3-030-33695-0_13.
6. Foroutan P., Lahmiri S. Deep learning systems for forecasting the prices of crude oil and precious metals. Financial Innovation, 2024, vol. 10, p. 111. URL: <https://doi.org/10.1186/s40854-024-00637-z>.
7. Khan A.M., Osinska M. Comparing forecasting accuracy of selected grey and time series models based on energy consumption in Brazil and India. Expert Systems with Applications, 2023, vol. 212, p. 118840. ISSN 0957-4174. URL: <https://doi.org/10.1016/j.eswa.2022.118840>.
8. Shynkarenko V., Zhadan A. Modeling of the deterministic fractal time series by one rule constructors. 2020 IEEE 15th International Conference on Computer Sciences and Information Technologies (CSIT), Zbarazh, Ukraine, 2020, pp. 336–339. URL: <https://doi.org/10.1109/CSIT49958.2020.9321923>.
9. Serletis A., Rosenberg A.A. The Hurst exponent in energy futures prices. Physica A: Statistical Mechanics and its Applications, 2007, vol. 380, pp. 325–332.
10. Prusinkiewicz P., Lindenmayer A. The algorithmic beauty of plants. Springer Science & Business Media, 2012.
11. Tsukamoto M. Mean Hausdorff dimension of some infinite-dimensional fractals. Journal d'Analyse Mathématique, 2025, vol. 155, pp. 235–286. URL: <https://doi.org/10.1007/s11854-024-0353-0>.
12. Ospina R., Gondim J.A.M., Leiva V., Castro C. An overview of forecast analysis with ARIMA models during the COVID-19 pandemic: Methodology and case study in Brazil. Mathematics, 2023, vol. 11, p. 3069. URL: <https://doi.org/10.3390/math11143069>.

13. Tarmanini C., Sarma N., Gezegin C., Ozgonenel O. Short term load forecasting based on ARIMA and ANN approaches. *Energy Reports*, 2023, vol. 9, suppl. 3, pp. 550–557. ISSN 2352-4847. URL: <https://doi.org/10.1016/j.egy.2023.01.060>.
14. Bhalla V., Bhalla A., Jain R. A comparison of ARIMA, SARIMA, and statistical models for estimating. In: *Sustainable Computing and Intelligent Systems: Proceedings of SCIS 2024*, vol. 2, 1296, 2025, p. 185.
15. Ray S., Lama A., Mishra P., Biswas T., Das S.S., Gurung B. An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique. *Applied Soft Computing*, 2023, vol. 149, part A, p. 110939. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2023.110939>.
16. Salem F.M. Recurrent Neural Networks (RNN). In: *Recurrent Neural Networks*. Cham: Springer, 2022. URL: https://doi.org/10.1007/978-3-030-89929-5_3.
17. Al-Selwi S.M., Hassan M.F., Abdulkadir S.J., Muneer A., Sumiea E.H., Alqushaibi A., Ragab M.G. RNN-LSTM: From applications to modeling techniques and beyond—Systematic review. *Journal of King Saud University - Computer and Information Sciences*, 2024, vol. 36, no. 5, p. 102068. ISSN 1319-1578. URL: <https://doi.org/10.1016/j.jksuci.2024.102068>.
18. Md A.Q., Kapoor S., Junni A.V.C., Sivaraman A.K., Tee K.F., Sabireen H., Janakiraman N. Novel optimization approach for stock price forecasting using multi-layered sequential LSTM. *Applied Soft Computing*, 2023, vol. 134, p. 109830. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2022.109830>.
19. Wang K., Zhang J., Li X., Zhang Y. Long-term power load forecasting using LSTM-Informer with ensemble learning. *Electronics*, 2023, vol. 12, p. 2175. URL: <https://doi.org/10.3390/electronics12102175>.
20. Elmaz F., Eyckerman R., Casteels W., Latré S., Hellinckx P. CNN-LSTM architecture for predictive indoor temperature modeling. *Building and Environment*, 2021, vol. 206, p. 108327. ISSN 0360-1323. URL: <https://doi.org/10.1016/j.buildenv.2021.108327>.
21. Wu J.M.T., Li Z., Herencsar N., et al. A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems*, 2023, vol. 29, pp. 1751–1770. URL: <https://doi.org/10.1007/s00530-021-00758-w>
22. Wang J.-D., Susanto C.O.N. Traffic flow prediction with heterogenous data using a hybrid CNN-LSTM model. *Computers, Materials and Continua*, 2023, vol. 76, no. 3, pp. 3097–3112. ISSN 1546-2218. URL: <https://doi.org/10.32604/cmc.2023.040914>.
23. Zha W., Liu Y., Wan Y., Luo R., Li D., Yang S., Xu Y. Forecasting monthly gas field production based on the CNN-LSTM model. *Energy*, 2022, vol. 260, p. 124889. ISSN 0360-5442. URL: <https://doi.org/10.1016/j.energy.2022.124889>.
24. Ray S., Lama A., Mishra P., Biswas T., Das S.S., Gurung B. An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique. *Applied Soft Computing*, 2023, vol. 149, part A, p. 110939. ISSN 1568-4946. URL: <https://doi.org/10.1016/j.asoc.2023.110939>.
25. Jin Y.-C., Cao Q., Wang K.-N., Zhou Y., Cao Y.-P., Wang X.-Y. Prediction of COVID-19 data using improved ARIMA-LSTM hybrid forecast models. *IEEE Access*, 2023, vol. 11, pp. 67956–67967. URL: <https://doi.org/10.1109/ACCESS.2023.3291999>.

Shynkarenko V., Zhadan A. Multiservice architecture of software for stochastic fractal time series forecasting. 2024 IEEE Conference on Computer Sciences and Information Technologies, 2024, pp. 1–4. URL: <https://doi.org/10.1109/CSIT65290.2024.10982626>.

Received 12.09.2025.

Accepted 15.09.2025.

***Use of constructive-production modeling methods
for forecasting deterministic time series***

Time series forecasting is one of the key tasks of modern data analysis and complex systems modeling. This paper considers the application of a constructive-production approach to deterministic fractal time series. The aim of the study is to reconstruct a constructive model that reflects the internal structure of the series and allows its continuation according to defined generation rules. To verify the effectiveness of the approach, a set of synthetic series generated by constructive models of varying levels of complexity was formed. In turn, the reconstruction of the models was carried out using a specialized software application. The forecasting capability of the method was tested by comparative analysis with classical forecasting models, in particular ARIMA, LSTM, ARIMA-LSTM, and CNN-LSTM. Accuracy was evaluated using MAE and MAPE metrics. The results showed that constructive-production modeling provides the highest forecasting accuracy among all tested models, which is expected given the nature of the input series. It is important to emphasize that, unlike traditional methods, this approach makes it possible to obtain not only forecast values, but also a constructive model of the time series, which can be used for further structural analysis, identification of patterns, and study of properties. Thus, the study confirms the efficiency and feasibility of using constructive-production modeling for forecasting deterministic fractal time series.

Keywords: software, information technologies, constructive-production modeling, fractals, fractal time series, genetic algorithm, L-system.

Жадан Артем Анатолійович – аспірант кафедри комп'ютерних інформаційних технологій, Український державний університет науки і технологій, ORCID: <https://orcid.org/0009-0003-1133-1630>

Шинкаренко Віктор Іванович – професор кафедри комп'ютерних інформаційних технологій, д.т.н., Український державний університет науки і технологій, ORCID: <https://orcid.org/0000-0001-8738-7225>

Artem Zhadan – PhD student of Department of Computer Information Technologies, Ukrainian State University of Science and Technology, ORCID: <https://orcid.org/0009-0003-1133-1630>

Viktor Shynkarenko – Professor of Department of Computer Information Technologies, Doctor of Technical Sciences, Ukrainian State University of Science and Technology, ORCID: <https://orcid.org/0000-0001-8738-7225>