

Бабич О.А.

аспірант кафедри міжнародних фінансів,
Навчально-науковий інститут міжнародних відносин
Київського національного університету імені Тараса Шевченка
ORCID: <https://orcid.org/0009-0004-5996-6931>

Babych Oleksandr

Educational and Scientific Institute of International Relations
Taras Shevchenko National University of Kyiv

ПРОГНОЗУВАННЯ ЦІН КРИПТОВАЛЮТ ЗА ДОПОМОГОЮ ШТУЧНОГО ІНТЕЛЕКТУ: ІНТЕГРАЦІЯ ТЕХНІЧНОГО АНАЛІЗУ ТА ТЕОРІЙ ЦИКЛІВ ІЗ МОДЕЛЯМИ МАШИННОГО НАВЧАННЯ

PREDICTING CRYPTOCURRENCY PRICE MOVEMENTS USING AI: INTEGRATING TECHNICAL ANALYSIS AND CYCLICAL THEORIES WITH MACHINE LEARNING MODELS

Анотація. У статті представлений підхід до прогнозування руху цін криптовалют, а саме Bitcoin. Проаналізовано фактори, що ускладнюють прогнозування крипто-ринків. Окреслені можливі шляхи подолання цих ускладнюючих факторів завдяки комбінуванню моделей штучного інтелекту і машинного навчання. Запропоновано комбіновану архітектуру, де WGAN створює синтетичні часові ряди, що досить точно відтворюють реальні патерни ціни, а модель BiLSTM забезпечує високоточне прогнозування. Для покращення якості синтетичних даних, WGAN враховує додаткові ринкові індикатори та часовий тренд для відтворення циклічності ринку. Представлені результати прогнозування BiLSTM навчених на історичних даних з застосуванням різноманітних метрик технічного аналізу та на синтетичних даних згенерованих WGAN. Запропонований підхід є перспективним для оптимізації інвестиційних стратегій та управління ризиками в умовах високої нестабільності криптовалютного ринку.

Ключові слова: прогнозування криптовалют, BTC, WGAN, BiLSTM, генерація синтетичних даних, багатокрокове прогнозування, технічний аналіз, RSI, MACD, рівні підтримки та опору, корекція Фібоначчі, волатильність ринку, моделі AI, аналіз часових рядів, прогнозне моделювання.

Постановка проблеми. Прогнозування цін криптовалют, зокрема BTC, залишається складним завданням через високу волатильність ринку, обмеженість історичних даних, залежність від ринкових настроїв та регуляторну невизначеність. Традиційні методи прогнозування недостатньо ефективні для врахування

цих факторів, що потребує застосування новітніх підходів, зокрема штучного інтелекту та синтетичних даних.

Аналіз останніх досліджень і публікацій.

Останні дослідження у сфері прогнозування цін криптовалют активно зосереджуються на застосуванні генеративних змагальних мереж (GAN) для моделювання складних часових рядів. Eckerli F. & Osterrieder J. [1] надали ґрунтовний огляд використання GAN у фінансах, відзначаючи їхню здатність відтворювати ринкові сценарії з високим ступенем реалістичності. Gadhi A.H.A. та ін. [2] підкреслили переваги Wasserstein GAN (WGAN) у прогнозуванні волатильності, демонструючи, що застосування градієнтного штрафу підвищує стабільність навчання та зменшує ризик виникнення проблеми “mode collapse”. Haas M., & Richter S. [3] проаналізували статистичні властивості WGAN у контексті часових рядів, підкресливши ефективність Wasserstein-функції у подоланні нестабільності навчання та відтворенні ринкових патернів.

Іншим ключовим напрямом досліджень є використання рекурентних нейронних мереж, зокрема LSTM та BiLSTM. Hamayel M.J. & Owd A.Y. [4] продемонстрували, що BiLSTM-моделі перевершують традиційні LSTM завдяки двонапрямній обробці часових рядів, що дозволяє врахувати як минулі, так і майбутні контексти послідовностей, підвищуючи точність прогнозів. Hossain M.F.B. та ін. [5] розглянули поєднання BiLSTM із аналізом ринкових

настроїв, показавши, що така інтеграція значно знижує похибку прогнозування. Дослідження Khaniki M.A.L. & Manthouri M. [6] підкреслює ефективність трансформерних нейронних мереж у поєднанні з технічними індикаторами, що сприяє виявленню складних ринкових патернів і трендів.

Формулювання цілей статті (постановка завдання). Мета статті – розробити гібридний підхід до прогнозування ціни BTC, що поєднує генерацію синтетичних даних за допомогою WGAN та прогнозування за допомогою моделі BiLSTM. Завдання полягає у дослідженні впливу різних технічних індикаторів на точність прогнозування та оцінці ефективності моделі за допомогою метрик MAE, RMSE, MAPE та R^2 .

Виклад основного матеріалу. Прогнозування руху фінансових ринків протягом усієї історії їх існування було одним з найскладніших завдань для аналітиків, трейдерів та інвесторів. Ця складність виникає через безліч факторів, що впливають на цінову динаміку, включаючи макроекономічні події, відсоткові ставки, геополітичні події та ринкові настрої. Ці фактори разом створюють високий рівень волатильності та непередбачувану динаміку цін, що робить точне прогнозування ринку надзвичайно складним завданням. Для нових та високоволатильних активів, таких як криптовалюти, цей виклик стає ще більш вираженим через відсутність їх внутрішньої вартості, схильність до маніпуляцій та залежність від спекуляцій, керованих настроями. Ці унікальні фактори вимагають інноваційних підходів для досягнення точного прогнозування.

Таким чином, в цій статті буде розглянуто концепцію прогнозування майбутніх рухів ціни для усталених крипто активів, які мають наступні характеристики: децентралізованість володіння, високо-ліквідність, середньострокова історія торгівлі, публічність і прозорість, а також інтерес з боку інституційних гравців.

Серед факторів складності що виникають при прогнозуванні майбутніх цін криптовалют є:

- висока волатильність: ціни можуть різко змінюватися протягом короткого періоду через настрої ринку, макроекономічні фактори чи навіть окремі твіти або новини. На відміну від традиційних активів, криптовалюти не мають сталої внутрішньої вартості, що ускладнює прогнозування цінових рухів за допомогою стандартних фінансових моделей;

- обмеженість історичних даних: порівняно з традиційними активами, такими як акції та облігації цінні метали, або індекси, криптовалюти є молодими активами, що означає обмеже-

ність історичних даних для аналізу. Ця нестача довгострокових даних ускладнює виявлення надійних закономірностей чи трендів у часі;

- залежність від ринкових настроїв: ціни на криптовалюти значною мірою залежать від настроїв інвесторів, висвітлення в медіа та дискурсу в соціальних мережах, що часто призводить до ірраціонального оптимізму або панічних розпродажів. Такі швидкі та емоційно обумовлені цінові коливання ускладнюють точне прогнозування рухів ціни за допомогою традиційних інструментів;

- комплексність факторів впливу: на ціну крипто активів впливає складний спектр змінних, включаючи макроекономічні тенденції, зміни в регулюванні, технологічні досягнення та маніпуляції ринком. Проаналізувати та оцінити всі ці фактори – є нетривіальною задачею, оскільки вони можуть впливати одночасно та в різних масштабах;

- регуляторна невизначеність: регуляторне середовище навколо криптовалют постійно розвивається, створюючи додаткову непередбачуваність. Зміни в державній політиці – наприклад, заборони криптовалют у Китаї чи посилення регуляторного нагляду в США – можуть призвести до значних ринкових потрясінь, ускладнюючи оцінку ризиків та потенційних рухів цін для інвесторів;

- ліквідність та маніпуляції: ринок криптовалют відносно малий порівняно з традиційними фінансовими ринками, і ця низька ліквідність робить його вразливим до маніпуляцій. Великі гравці, можуть суттєво впливати на ціни, шляхом купівлі чи продажу великих обсягів активу, що може призвести до цінових спотворень, які важко передбачити.

Досягнення ефективного рівня прогнозування майбутніх рухів цін за урахуванням вищезазначених факторів можливо за рахунок використання комбінованого підходу та різних типів моделей штучного інтелекту (ШІ) та машинного навчання (МН), кожна з яких спрямована на ефективне вирішення одного з факторів складності прогнозування криптовалютного активу [1].

Відтак підхід, який розглядається в цій статті, передбачає використання комбінованої стратегії, за якої враховуються теорії циклічності, метрики технічного аналізу на основі історичних даних, а нестача історичних даних компенсується синтетичними часовими рядами. Для генерації синтетичних даних використано Wasserstein Generative Adversarial Network (WGAN), що завдяки своїй архітектурі забезпечує стабільне нав-

чання та реалістичну генерацію даних у порівнянні з іншими типами GAN [2].

Генератор моделі WGAN створює синтетичні часові ряди, які відтворюють історичні патерни ціни BTC, тоді як критик оцінює їхню схожість із реальними даними, використовуючи метод Wasserstein з градієнтним штрафом для уникнення проблеми “mode collapse” [2]. У дослідженні були додані додаткові ринкові метрики (RSI, обсяг торгів, волатильність) та умова часу (time condition), що забезпечило моделі контекстуальне розуміння ринку та покращило якість синтетичних даних [3].

Гібридний підхід, що поєднує WGAN для генерації синтетичних даних та LSTM для прогнозування, дозволяє адаптувати модель до волатильності криптовалютного ринку. Отримані результати підтверджують, що інтеграція синтетичних даних може компенсувати нестачу історичних ринкових даних, а правильний вибір технічних індикаторів значно впливає на точність передбачень.

В рамках дослідження було протестовано різні комбінації технічного аналізу з моделями машинного навчання, що дозволило визначити оптимальні параметри для підвищення прогнозовної точності. Подальші дослідження можуть бути спрямовані на вдосконалення методів синтетичного генеративного навчання та їх інтеграцію в комплексні ШІ-стратегії прогнозування.

У ході даного дослідження було протестовано кілька варіантів ШІ-моделей, які поєднують технічний аналіз та гібридні методи навчання, а також здійснено аналіз впливу додаткових параметрів (індикаторів) на точність прогнозування.

Навчання моделі BiLSTM на основі на історичних даних BTC з додаванням метрик технічного аналізу.

У дослідженні було використано модель BiLSTM, яка здатна враховувати часові залежності в обох напрямках: від минулого до майбутнього та навпаки. Це надає моделі перевагу у прогнозуванні фінансових часових рядів,

зокрема ціни Bitcoin [4]. Для підвищення точності прогнозування було проведено інтеграцію різних технічних індикаторів, таких як RSI, MACD, рівні підтримки та опору, хвилі Елліотта та рівні Фібоначчі. Кожен з індикаторів надає додатковий контекст для розуміння ринкових тенденцій [5; 6].

У дослідженні було використано багатокрокове прогнозування, при якому модель прогнозує значення на кілька кроків уперед. Такий підхід є складним через накопичення похибок і виникнення шумів у даних при прогнозуванні на тривалі періоди. Особливо це проявляється при прогнозах на інтервали більше двох днів, де результати стають менш точними через високу волатильність та непередбачуваність ринку.

Для подолання цієї проблеми було застосовано метод усереднення прогнозів. Суть методу полягає у використанні середнього значення прогнозів кількох моделей або усереднення результатів по різних періодах прогнозування. Це дозволяє згладити вплив випадкових коливань та зменшити рівень шумів, забезпечуючи більш стабільні та точні результати.

Історичні ринкові дані цін BTC для проведення досліджень було отримано з біржі Binance [7]. Для горизонту прогнозування були використанні останні 10% даних цін закриття з 2017–2025 рік, перші 80% даних для тренування моделей, наступні 10% для валідації.

Аналіз результатів та висновки. Результати моделювання продемонстрували, що використання технічних індикаторів покращує якість прогнозування. Найкращі результати були отримані при інтеграції індикатора RSI (табл. 1):

- **MAE (Mean Absolute Error):** Середня абсолютна похибка, що відображає середнє відхилення прогнозованих значень від фактичних.
- **RMSE (Root Mean Square Error):** Корінь середньоквадратичної похибки, що більше штрафувє великі відхилення.
- **MAPE (%) (Mean Absolute Percentage Error):** Середня абсолютна відносна похибка у

Таблиця 1

Порівняння якості прогнозу BiLSTM з різними комбінаціями вхідних характеристик

Назва моделі	MAE	RMSE	MAPE (%)	R ²
BiLSTM	4716.65	6180.07	6.00	0.85
BiLSTM + RSI	3675.26	4473.08	4.97	0.92
BiLSTM + MACD	4353.40	5519.35	5.68	0.88
BiLSTM + рівні підтримки та опору	5149.49	5943.61	6.83	0.86
BiLSTM + хвилі Елліотта	4998.80	5742.48	6.53	0.87
BiLSTM + Фібоначчі (корекції та розширення тренду)	5564.46	6747.88	7.23	0.82

Джерело: складено автором на основі отриманих результатів тестування

відсотках, що дозволяє оцінити точність незалежно від масштабу даних.

- **R² Score (Коефіцієнт детермінації):** Показує, яка частка варіації залежної змінної пояснюється моделлю. Значення, близьке до 1, свідчить про високу точність.

На рисунку 1 представлено прогнозування цін BTC за допомогою моделі BiLSTM та її модифікацій з інтеграцією різних технічних індикаторів. Суцільна лінія відображає фактичну ціну BTC/USD, тоді як пунктирні лінії позначають прогнози моделей. Кожна модифікація BiLSTM включає окремі технічні метрики: RSI, MACD, рівні підтримки та опору, хвилі Елліотта та рівні Фібоначчі. Графік демонструє, що додавання індикаторів дозволяє моделі точніше відтворювати динаміку ціни, зменшуючи відхилення від фактичних значень. Найкращу точність показала модель BiLSTM з індикатором RSI, яка забезпечила найнижчі значення помилок MAE та RMSE. Це вказує на ефективність використання технічних індикаторів для підвищення якості прогнозування цін на криптовалюту.

Дослідження підтвердило ефективність інтеграції технічних індикаторів у BiLSTM-модель для прогнозування ціни Bitcoin. Найвищу точність було досягнуто при використанні RSI. Однак результати також показали, що не всі індикатори однаково покращують якість прогнозу – наприклад, інтеграція рівнів Фібоначчі не продемонструвала очікуваного покращення.

Використання багатокрокового прогнозування з методами усереднення дозволило мінімізувати проблеми шумів і підвищити стійкість моделі до ринкових коливань. Таким чином, комбінований підхід із застосуванням BiLSTM та релевантних технічних індикаторів має потенціал стати ефективним інструментом для прогнозування цін на ринку криптовалют.

Навчання моделі BiLSTM на основі синтетичних даних та порівняння результатів з BiLSTM начаної на історичних даних.

У межах цього дослідження було розроблено підхід до генерування синтетичних часових рядів ціни біткоїна (BTC) з використанням моделі WGAN (Wasserstein GAN) та наступним навчанням BiLSTM-моделі для прогнозування ціни. Нижче наведено ключові етапи та результати дослідження.

1. Архітектура WGAN та покращення якості синтетичних даних

Для генерування синтетичних даних було застосовано WGAN, що передбачає два складові елементи:

- **Генератор (Generator):** створює штучні вікна часових рядів, навчаючись відтворювати розподіл реальних цін BTC. У дослідженні було додано умову часу (time condition), а також використано гібридний підхід із залученням рекурентних (LSTM) і згорткових (CNN) шарів, аби краще захопити як короткострокову волатильність, так і довгострокові тренди.



Рис. 1. Прогнозування цін BTC моделями BiLSTM

Джерело: складено автором на основі отриманих результатів тестування

- **Критик (Critic):** оцінює, наскільки згенеровані дані схожі на реальні. Використання методу Wasserstein з градієнтним штрафом (gradient penalty) підвищує стабільність навчання та зменшує проблему “mode collapse”.

Щоб модель WGAN навчилася генерувати більш реалістичні коливання, були додані:

1. **Додаткові канали (Volume, RSI, Volatility)** – для кращого моделювання ринкових умов.

2. **Врахування часового тренду (time condition)** – щоб штучні дані демонстрували характерний для BTC поступовий (або циклічний) ріст.

3. **Варіаційна санкція (variance matching)** – спеціальний штраф у функції втрат генератора, який зближує дисперсію доходності (returns) синтетичних даних із реальними.

Після навчання WGAN було згенеровано синтетичний набір із 5000 днів цін BTC. Порівняння волатильності (дисперсії доходності) дало такі результати (рис. 2):

- Реальна дисперсія доходності: 0.000668
- Синтетична дисперсія доходності: 0.006313

Попри те, що синтетична волатильність усе ще вища за реальну, загальний розподіл та структура ряду наблизилися до реальних характеристик.

2. Аналіз результатів з BiLSTM-моделлю

Для оцінювання корисності згенерованих даних було використано модель **BiLSTM (Bidirectional LSTM)**, що є рекурентною нейронною мережею з двобічною обробкою послідовностей. Мета – порівняти результати передбачення, коли:

1. Модель навчалася на **реальних історичних даних (BTC/USD)**.

2. Модель навчалася на **синтетичних даних**, згенерованих WGAN.

Показники якості прогнозу (MAE, RMSE, MAPE, R²) наведено нижче в таблиці 2:

На рисунку 3 зображено порівняння реальної ціни BTC (зелена лінія) з прогнозами двох моделей BiLSTM: одна була навчена на історичних (реальних) даних (синя пунктирна лінія), а інша – на синтетичних, згенерованих WGAN (червона лінія). Обидва прогнози загалом відтворюють зростаючий тренд BTC, хоча модель, навчена на історичних даних, місяцями недооцінює окремі піки, тоді як синтетична модель демонструє дещо вищу амплітуду коливань. При цьому обидві криві доволі близько прилягають до фактичної ціни, що свідчить про потенційну ефективність використання синтетичних часових рядів у завданнях прогнозування.

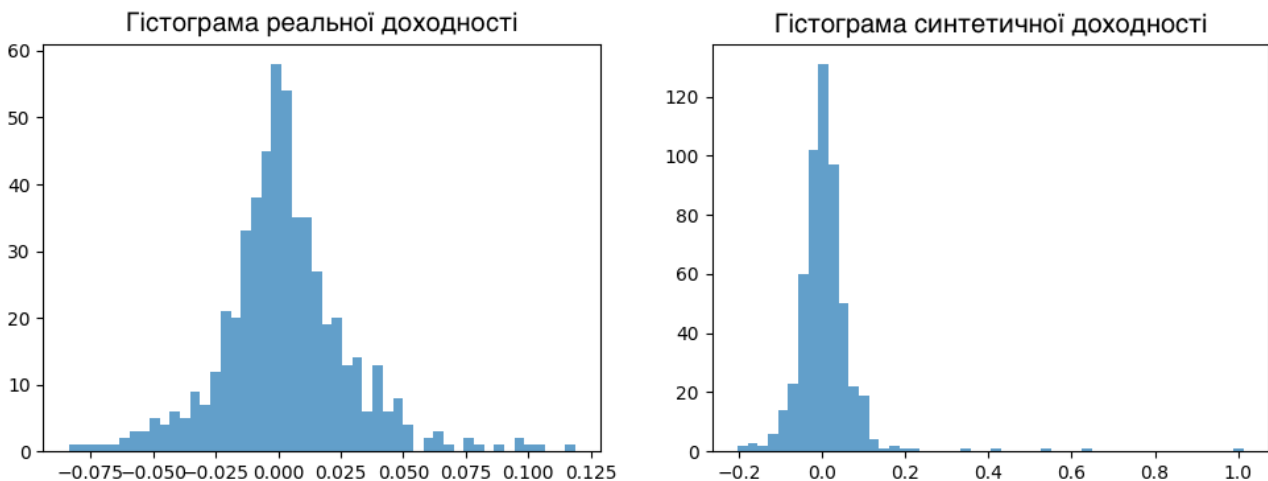


Рис. 2. Порівняння гістограм доходностей синтетичних та історичних даних цін BTC

Джерело: складено автором на основі отриманих результатів тестування

Таблиця 2

Показники якості прогнозу (MAE, RMSE, MAPE, R²) BiLSTM навченої на історичних даних та синтетичних

Назва моделі	MAE	RMSE	MAPE (%)	R ²
BiLSTM (BTC/USD)	5372.64	6777.63	6.64	0.85
BiLSTM (синтетичні дані)	2361.39	3123.08	2.97	0.97

Джерело: складено автором на основі отриманих результатів тестування

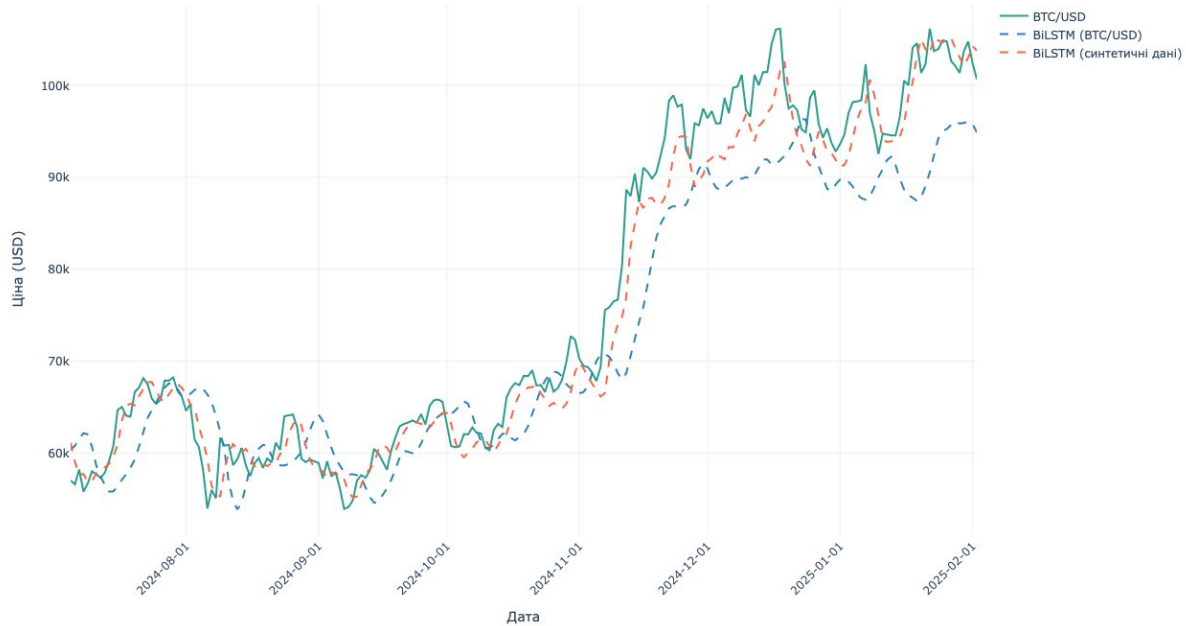


Рис. 3. Прогнозування цін BTC моделлю BiLSTM навченою на історичних даних та синтетичних

Джерело: складено автором на основі отриманих результатів тестування

Таким чином, застосування WGAN для генерування синтетичного часового ряду BTC дозволило:

1. Отримати штучні дані з досить реалістичними характеристиками розподілу та волатильності.
2. Покращити навчання BiLSTM-моделі, яка, тренуючись на цих синтетичних даних, показала високі показники точності ($R^2=0.97$).

Водночас, певне перевищення волатильності синтетичного ряду свідчить про можливі подальші кроки покращення WGAN-моделі: більш точне налаштування варіаційної санкції або включення додаткових ринкових/макроекономічних факторів. Загалом, результати демонструють перспективність використання генеративних моделей для розширення чи синтезу фінансових часових рядів, а також для підготовки навчальних вибірок при прогнозуванні динаміки курсу BTC.

Висновки. У ході проведеного дослідження було розглянуто гібридний підхід до прогнозування ціни BTC, який поєднує генерацію синтетичних даних за допомогою моделі WGAN та прогнозування із використанням BiLSTM-моделі. Дослідження довело, що застосування генеративних моделей, зокрема WGAN, дозволяє ефективно компенсувати нестачу історичних ринкових даних, створюючи синтетичні часові ряди з реалістичними характеристиками.

Порівняльний аналіз результатів показав, що навчання BiLSTM-моделі на синтетичних даних забезпечило кращі показники точності прогно-

зування (MAE: 2361.39, RMSE: 3123.08, MAPE: 2.97%, R^2 : 0.97), у порівнянні з навчанням на реальних даних (MAE: 5372.64, RMSE: 6777.63, MAPE: 6.64%, R^2 : 0.85). Це свідчить про високу якість синтетичних даних, які не лише відтворюють характерні патерни ринку, але й знижують рівень «шуму», властивого реальним ринковим даним.

Крім того, дослідження впливу технічних індикаторів на точність прогнозування виявило неоднозначні результати. Додавання індексу відносної сили (RSI) значно покращило прогностичні показники моделі (R^2 : 0.92), тоді як використання інших індикаторів, таких як MACD, рівні підтримки та опору або Фібоначчі, показало різну ефективність залежно від горизонту прогнозування. Це підкреслює важливість ретельного відбору технічних індикаторів для конкретних завдань прогнозування.

Загалом, результати дослідження підтверджують ефективність гібридного підходу, що поєднує генеративні моделі (WGAN) та рекурентні мережі (BiLSTM) у прогнозуванні динаміки цін на ринку криптовалют. Такий підхід демонструє високу гнучкість та адаптивність до волатильності ринку, забезпечуючи високу точність передбачень навіть за умов обмеженої історичної інформації. Подальші дослідження можуть бути спрямовані на вдосконалення архітектури WGAN для зниження надмірної волатильності синтетичних даних, інтеграцію додаткових макроекономічних факторів та оптимізацію набору технічних індикаторів залежно від цілей прогнозування.

References:

1. Eckerli, F., & Osterrieder, J. (2021). Generative adversarial networks in finance: an overview. *arXiv preprint arXiv:2106.06364*. Available at: <https://arxiv.org/abs/2106.06364> (accessed February 20, 2025)
2. Gadhi, A. H. A., Peiris, S., & Allen, D. E. (2024). Improving Volatility Forecasting: A Study through Hybrid Deep Learning Methods with WGAN. *Journal of Risk and Financial Management*, 17 (9), 380. DOI: <https://doi.org/10.3390/jrfm17090380> (accessed February 20, 2025)
3. Haas, M., & Richter, S. (2020). Statistical analysis of wasserstein gans with applications to time series forecasting. *arXiv preprint arXiv:2011.03074*. Available at: https://arxiv.org/abs/2011.03074?utm_source=chatgpt.com (accessed February 20, 2025)
4. Hamayel, M. J., & Owda, A. Y. (2021). A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms. *Ai*, 2 (4), 477–496. Available at: <https://www.mdpi.com/2673-2688/2/4/30> (accessed February 20, 2025)
5. Hossain, M. F. B., Lamia, L. Z., Rahman, M. M., & Khan, M. M. (2024). FinBERT-BiLSTM: A Deep Learning Model for Predicting Volatile Cryptocurrency Market Prices Using Market Sentiment Dynamics. *arXiv preprint arXiv:2411.12748*. Available at: <https://arxiv.org/abs/2411.12748> (accessed February 20, 2025)
6. Khaniki, M. A. L., & Manthouri, M. (2024). Enhancing Price Prediction in Cryptocurrency Using Transformer Neural Network and Technical Indicators. *arXiv preprint arXiv:2403.03606*. Available at: <https://arxiv.org/abs/2403.03606> (accessed February 20, 2025)
7. Binance. (n.d.). *Historicalcryptocurrencymarketdata(BTC/USD)*. Available at: <https://www.binance.com> (accessed February 20, 2025)

Summary. The increasing complexity of forecasting cryptocurrency price movements, especially Bitcoin, necessitates the development of innovative approaches that address high market volatility, dependency on investor sentiment, limited historical data, and regulatory uncertainty. This article aims to provide a robust forecasting framework that integrates advanced AI models and synthetic data generation techniques. The relevance of this research lies in the growing influence of cryptocurrencies in the global financial market, where accurate price prediction remains a key challenge. The proposed methodology combines the generative capabilities of a WGAN with the predictive strength of a BiLSTM network. The WGAN model was specifically designed to generate synthetic time series data that replicate real BTC price patterns. To enhance data quality and realism, the model incorporates additional market indicators, including trading volume, RSI, and volatility metrics, as well as time-conditioned parameters that reflect market cycles. The synthetic dataset generated by WGAN closely mirrors real market dynamics, providing a solid foundation for predictive modeling. The BiLSTM model was trained using both real and synthetic data, enabling a comparative analysis of predictive performance. Evaluation metrics such as MAE, RMSE, MAPE, and the R² score were employed to assess model accuracy. The results demonstrated a significant improvement in predictive performance when the BiLSTM model was trained on synthetic data, with the R² score reaching 0.97 and error rates considerably lower than those observed in models trained solely on real data. This outcome highlights the potential of synthetic data to overcome the limitations imposed by scarce historical data and improve the generalization capability of forecasting models. Furthermore, the study analyzed the impact of incorporating technical indicators into the prediction process. The inclusion of RSI led to enhanced predictive accuracy, while other indicators, such as MACD, support and resistance levels, and Fibonacci retracement, showed varying degrees of influence. The practical value of this study lies in its demonstration that the hybrid integration of WGAN and BiLSTM provides a scalable and adaptable framework for forecasting cryptocurrency prices. By effectively compensating for limited historical data and adapting to the unique characteristics of the crypto market, this approach offers practical benefits for institutional investors, financial analysts, and trading platforms seeking to optimize investment strategies and manage risks in highly volatile environments.

Keywords: Cryptocurrency forecasting, Bitcoin (BTC), WGAN, BiLSTM, synthetic data generation, multistep prediction, technical analysis, RSI, MACD, support and resistance levels, Fibonacci retracement, market volatility, AI models, time series analysis, predictive modeling.