

Д.Д. Плечистий, к.т.н., доц.
М.С. Сітайло, магістр

Державний університет «Житомирська політехніка»

Дослідження застосування автоматизованого машинного навчання для порівняльного аналізу методів прогнозування курсу криптовалют

Прогнозування вартості активів завжди викликало значний інтерес, спонукаючи дослідників постійно вдосконалювати методи та інструменти вирішення цього завдання. Розвиток штучного інтелекту значно збільшив потенціал досліджень у цій сфері, приводячи до виникнення нових алгоритмів і методів, які використовують переваги швидкості обчислень та точності нейронних мереж. Це підтримало активне дослідження машинного навчання в контексті прогнозування, що призвело до появи нових варіацій і модифікацій алгоритмів. Однак велика кількість досліджень вимагає від користувачів самостійного аналізу та експериментальної перевірки їх ефективності. Стаття містить результати дослідження можливості використання автоматизованого машинного навчання для аналізу методів прогнозування курсу криптовалют. На момент проведення дослідження автоматизованого машинного навчання здебільшого використовується з метою спрощення процесу використання машинного навчання для розв'язання певних практичних задач. Проте такий підхід також дозволяє провести автоматизацію процесу порівняння результатів різноманітних досліджень й значно спрощує та пришвидшує їх узагальнення. В основу автоматизованого машинного навчання покладено взаємопов'язаний набір процесів, які об'єднуються у конвеєр. Зазвичай конвеєр містить набір автоматизованих операцій від обробки даних до генерації результатів, що значно пришвидшує та спрощує процес отримання й використання результатів. У статті описуються особливості архітектури та реалізації кожного з етапів для вирішення завдання, що надає змогу максимально автоматизувати процеси збору та обробки даних, створення й навчання моделей машинного навчання, а також генерації й обробки отриманих результатів. У підсумку користувач має змогу налаштовувати підтримувані алгоритми та методи за допомогою користувацького інтерфейсу й згодом аналізувати отримані результати за допомогою спроектованої системи.

Ключові слова: система аналізу методів; алгоритми прогнозування курсу криптовалют; нейронні мережі; машинне навчання; автоматизоване машинне навчання; AutoML.

Постановка проблеми. Завдання прогнозування ціни активів завжди було актуальним у сфері аналітики даних. Спочатку фахівці намагалися знаходити математичні закономірності у числових рядах даних, використовуючи історичні дані зміни цін або котирувань на біржі. Згодом цей напрям значно розвинувся і з'явилося поняття «технічних індикаторів», що являють собою функції на основі значень певних статистичних показників. Поява і розвиток інформаційних технологій тільки популяризували цей вид аналізу через те, що комп'ютери здатні неймовірно швидко виконувати розрахунки. Це дозволяє трейдерам швидше здійснювати торгові операції й відповідно отримувати більші прибутки.

Проблема полягає у складності та тривалості процесу об'єктивного вибору методів прогнозування курсу криптовалют через необхідність створення, навчання та оцінки великої кількості моделей нейронних мереж. Вирішення цієї проблеми може полягати у розробці системи на основі принципів автоматизованого машинного навчання (англ. Automated Machine Learning, AutoML), яка використовує конвеєр для збору, обробки даних, створення, навчання та оцінки нейронних мереж. Цей підхід сприяє значному прискоренню та спрощенню порівняння методів прогнозування курсу криптовалют, забезпечуючи більш широкий і ефективний аналіз варіантів прогнозування.

Аналіз останніх досліджень та публікацій, на які спираються автори. Спочатку дослідники намагалися застосувати популярні та універсальні алгоритми штучного інтелекту для прогнозування майбутньої ціни активів. Отримані результати досліджень доводили ефективність використання певних архітектур нейронних мереж порівняно зі звичайними математичними методами, проте точність прогнозів була недостатньо високою для можливості їх застосування при розв'язанні практичних задач. Проте ці перші результати дали змогу припустити потенційну можливість прогнозування курсу активів, яка буде набагато ефективнішою, ніж усі доступні на той момент методи.

На основі цього науковці та фахівці галузі намагалися видозмінювати базові алгоритми з метою їх оптимізації саме для задачі прогнозування ціни активів. Також було проведено велику кількість досліджень з метою визначення наборів даних та взаємозалежностей між цими даними й іншими активами, щоб згодом використовувати найбільш ефективні набори для навчання нейронних мереж.

Аналіз різних джерел та типів даних займає окремий напрям у дослідженні такого виду задач, й багато фахівців намагаються визначити найефективніші параметри для кожного окремого виду активів. Більшість досліджень, які належать до прогнозування курсу криптоактивів, поділяються на категорії:

1. Дослідження алгоритмів машинного навчання та їх оптимізація;
2. Використання та аналіз статистичної інформації блокчейну;
3. Аналіз соціальних та економічних факторів.

Аналіз різних варіацій алгоритмів машинного навчання є дуже популярним напрямком досліджень. Загалом науковці у дослідженнях [1, 2] намагаються зрозуміти природу і особливості формування ціни криптоактивів та використати цю інформацію для прогнозування майбутньої ціни за допомогою штучного інтелекту. Проте є достатньо велика кількість досліджень, які орієнтуються більше на аналіз ефективності використання певних даних та їх вплив на результат прогнозування. Наприклад, у своїй роботі [3] К.Ларасаті досліджує ефективність застосування статистичних даних блокчейну для прогнозування вартості криптовалюти Bitcoin. Окрім цього, достатньо популярними є дослідження впливу соціальних факторів на курс цього виду активів. Росмен Т. та Якар С. у своїй роботі [4] досліджують вплив настроїв користувачів Twitter на ціну та об'єм торгів криптовалюти шляхом сентиментального аналізу твітів.

Окремим важливим і популярним напрямом дослідження прогнозування курсу криптовалют є аналіз методів та алгоритмів, які можуть застосовуватися для ефективного вирішення досліджуваної проблеми.

Найпростішим інструментом для прогнозування курсу активів є лінійна регресія. М.Алі та С.Шатабда у своїй роботі [5] дослідили процес прогнозування курсу Bitcoin з використанням лінійної регресії, а також застосування певної методології до створення набору даних для її навчання.

Окрім лінійної регресії, науковці часто аналізують застосування ансамблевих методів машинного навчання, модифікацію їх параметрів та порівняння ефективності й точності їх роботи між собою. Здебільшого у цих роботах досліджується зміна архітектури або параметрів алгоритму, використання різних алгоритмів оптимізації та гіперпараметрів мережі. Прикладом однієї з таких робіт є публікація Д.Ву та С.Гуо [6], в якій вони дослідили використання XGBoost для прогнозування курсу Bitcoin у короткостроковій перспективі.

Також достатньо популярним інструментом прогнозування, який досліджується і здобуває популярність останнім часом, є ARIMA. Її застосовують для розв'язання задач, які пов'язані з прогнозуванням часових рядів й передбаченням майбутньої ціни криптоактивів, не є виключенням. Одним з прикладів цього напрямку дослідження є робота Й.Сі [7], в якому він досліджує й використовує ARIMA для прогнозування вартості Bitcoin.

Розвиток глибокого машинного навчання сприяв вирішенню та автоматизації великої кількості завдань, тому цей інструмент знайшов застосування і у цій сфері. Багато дослідників аналізували й розглядали різні архітектури нейронних мереж для вирішення проблеми прогнозування. С.Бісвас та М.Павар у роботі [8] провели аналіз використання методу глибокого машинного навчання для прогнозування ціни криптоактивів. Найбільш популярною архітектурою цього виду машинного навчання для прогнозування часових рядів є LSTM. Вона доводить свою ефективність порівняно з іншими архітектурами і при вирішенні цього виду завдань. Ця ефективність привертає більшу увагу науковців, що мотивує їх шукати методи для досягнення кращих результатів за допомогою зміни моделі або параметрів нейронної мережі та оптимізації вхідного набору даних. Наприклад, В.Хуан та В.Чжан у праці [9] використали згадану архітектуру з метою дослідження ефективності використання сентиментальних даних для прогнозування вартості ціни цього виду цифрових активів, а Я.Яо у роботі [10] дослідив залежність ефективності моделі на основі LSTM від розміру вхідного часового ряду.

Метою статті є дослідження можливості використання автоматизованого машинного навчання для аналізу алгоритмів прогнозування курсу криптовалют. З одного боку, наявність великої кількості досліджень у цій галузі сприяє розвитку й покращенню методів вирішення проблеми, але, з іншого боку, відсутність систематизації цих досліджень та взаємозалежності між отриманими результатами часто ускладнюють процес вирішення певного практичного завдання й потребує перевірки й експериментального випробовування ідей запропонованих у цих роботах з метою створення найефективнішого рішення.

Така ситуація породжує потребу автоматизації процесу застосування різних ідей та підходів при пошуку найбільш оптимального рішення для прогнозування курсу криптовалют. Одним із варіантів автоматизації цього процесу є автоматизоване машинне навчання. Воно може спростити процес створення, навчання та розгортання систем аналізу даних й покращити аналіз різних алгоритмів прогнозування вартості криптоактивів.

Викладення основного матеріалу. Системи прогнозування належать до окремого типу задач інтелектуального аналізу даних і мають власні методи та алгоритми, які є найбільш ефективними для вирішення такого виду задач.

У процесі дослідження було розглянуто такі алгоритми:

1. Лінійна регресія;
2. Random Forest;
3. XG Boost;
4. ARIMA;
5. LSTM.

Лінійна регресія – алгоритм машинного навчання, який знаходить лінійну залежність між залежною та незалежною змінною. Процес навчання полягає в оптимізації параметрів формули прямої задля того, щоб отримана пряма найбільш оптимально описувала залежність між змінними. Згаданий вид алгоритму є дуже популярним і простим у застосуванні для розв’язання задач, проте використання прямої дуже часто спричиняє занадто консервативні прогнози щодо майбутньої ціни активу.

Random Forest – вид ансамблевого методу машинного навчання, що полягає у побудові певної кількості дерев прийняття рішень під час тренування моделі. Процес прогнозування за допомогою такого алгоритму полягає у генерації результату кожним зі створених дерев і визначення результату шляхом обробки отриманих даних.

XG Boost – алгоритм, який також використовує дерева прийняття рішень, проте, на відміну від Random Forest, який базується на ансамблі створених паралельно у процесі навчання дерев, цей алгоритм створює послідовні дерева, кожне з яких вчиться на помилках попередника. В результаті формується набір дерев прийняття рішень, які були покращені шляхом навчання на помилках інших.

ARIMA – алгоритм прогнозування майбутніх значень на основі попередніх з використанням методів статистичного аналізу рядів даних. В основу цього методу покладені такі компоненти:

1. Авторегресія (AR) – модель, яка відображає зміну параметра, що регресує з попередніми значеннями;
2. Інтеграція (I) – представляє різницю між даними, що дозволяє зробити часовий ряд стаціонарним;
3. Середня ковзна (MA) – містить залежність між різницею спостережень і ковзною середньою.

Зазначений метод дозволяє провести аналіз попередніх даних, визначати параметри кожного компонента й створити власні прогнози за допомогою згаданих статистичних компонентів, що сприяє застосуванню цього алгоритму для завдань регресії.

LSTM – більш складний алгоритм порівняно з попередніми, але налічує значну кількість переваг. Ця архітектура є підтипом рекурентної нейронної мережі, які застосовують за необхідності визначення залежності порядку елементів під час прогнозування послідовностей.

Ідея цього виду мережі полягає у збереженні та використанні попередніх елементів послідовності для прогнозування наступних. Врахування попередніх даних є дуже важливою особливістю, що сприяє використанню такого виду нейронних мереж майже у всіх видах задач, які належать до часових рядів.

Ціна криптовалют є результатом впливу великої кількості факторів. Врахування попередніх даних часового ряду допомагає аналізувати зміну кожного параметра та робити прогноз, використовуючи знайдені закономірності та взаємозв’язки.

Одним із завдань дослідження є аналіз можливості створення системи для проведення порівняльного аналізу ефективності методів прогнозування курсу криптовалют з використанням AutoML. Основною метою цієї системи є автоматизація процесу навчання нейронних мереж з можливістю зручного й швидкого налаштування обраних мереж та гнучкого вибору різноманітних даних для аналізу. Такі особливості системи допоможуть автоматизувати більшість процесів роботи з нейронними мережами й отримати простий та ефективний інструмент аналізу.

AutoML – підхід, що автоматизує використання моделей машинного навчання для розв’язання різноманітних задач. Він містить процеси вибору та обробки даних, ініціалізацію нейронних мереж, їх навчання та вимірювання ефективності. Це дозволяє користувачам, які не є фахівцями у сфері штучного інтелекту та машинного навчання, застосовувати новітні технології для вирішення певних завдань. Взаємодія з такими системами зазвичай відбувається за допомогою графічного інтерфейсу вебсервісу, що не потребує написання коду й самостійного впровадження алгоритмів.

AutoML стає дуже популярним, оскільки цей вид систем спрощує й автоматизує весь процес аналізу від збору даних до розгортання створеної моделі. Цей інструмент здобуває популярність як у початківців, так і досвідчених аналітиків даних, оскільки він дозволяє швидко протестувати певні ідеї та підходи для вирішення практичних завдань. Звичайний процес розробки нейронних мереж складається з багатьох етапів, які потребують створення програмних рішень, що вимагає часу та відповідного рівня експертності. В той же час автоматизоване машинне навчання зменшує кількість етапів і пришвидшує більшість з них, що дозволить приділяти більше часу саме дослідженню й порівнянню різних алгоритмів, а також перевіряти власних припущень.

Зазвичай AutoML – рішення становить собою конвеєр, який складається з послідовних операцій, що дозволяє перетворити набір даних та певні вхідні параметри в очікуваний результат. Кожний етап може різнитися залежно від поставленого завдання, проте основний підхід та порядок виконання процесів є

подібним: збір даних, обробка даних, створення моделі нейронної мережі, навчання створеної моделі з використанням отриманих даних, генерація прогнозу та вимірювання ефективності (рис. 1).

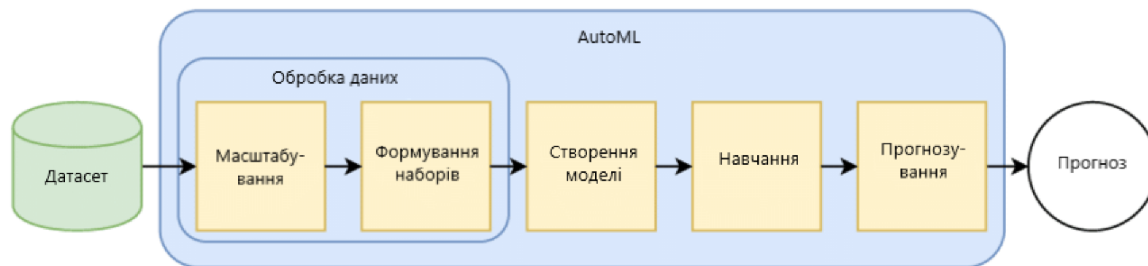


Рис. 1. Принцип роботи конвеєра AutoML

Оскільки рішення на основі AutoML може забезпечити системі, що створюється, багато переваг шляхом оптимізації процесу порівняння методів прогнозування курсу криптовалют, важливим етапом дослідження є аналіз можливості вирішення завдання відповідно до вимог та особливостей цього виду машинного навчання.

Першим етапом навчання нейронної мережі є збір даних. У системі збір даних може бути автоматизований та проведений за допомогою створення відповідних програмних модулів, які дозволять зібрати дані з різноманітних джерел та зберегти їх у спільну базу даних для подальшого проведення технічного, фундаментального та сентиментального аналізу.

Наступним етапом конвеєра є обробка даних. Цей етап може поділятися на різну кількість підпроцесів, що залежать від типу даних. Відповідно до особливостей поставленого завдання було виокремлено 2 підпроцеси: масштабування та формування наборів даних. Вони можуть видозмінюватися відповідно до обраного алгоритму та його параметрів, проте набір процесів етапу обробки даних є стандартизованим.

Наступним етапом обробки є формування тестових наборів даних. Система працюватиме з різними типами нейронних мереж й кожний з них вимагає обробки та приведення даних до певної структури. Загалом їх можна поділити на 2 групи:

- алгоритми, які приймають вектор, що являє собою скалярне значення кожного параметра моделі;
- лінійна регресія, Random Forest, XG Boost, ARIMA;
- алгоритми, які приймають проміжок даних, які містять в собі певну кількість наборів векторів параметрів моделі – LSTM.

Процес підготовки даних для алгоритмів першого типу становить простий розподіл даних на набори для тренування та валідації. В той же час алгоритми другого типу потребують додаткової обробки даних. У цьому випадку використовується параметр, який відповідає за розмір проміжку даних. На основі значення цього параметра відбувається генерація наборів даних для тренування та валідації з врахуванням особливостей типу вхідних даних для відповідної нейронної мережі. В результаті отримуються набори, які містять інформацію про попередні періоди, що дозволяє моделям прогнозування знайти певні закономірності в часових рядах та покращити свою ефективність.

Наступним кроком автоматизованого машинного навчання є створення моделі. Як було згадано раніше, однією з переваг обраної архітектури програмного забезпечення є можливість налаштування та керування усім процесом за допомогою графічного інтерфейсу. Задля цього у системі буде розроблений вебдодаток, який надасть можливість швидко й просто налаштувати параметри алгоритму, обрати архітектуру нейронної мережі, вид криптовалют, інтервал періодів, а також необхідні параметри обраних нейронних мереж та типів даних.

Після налаштування алгоритму за допомогою графічного інтерфейсу він буде створюватися за допомогою відповідного програмного модуля. Кожна модель нейронної мережі має бути реалізована таким чином, щоб вона підтримувала динамічну кількість даних і могла конфігуруватися програмним кодом шляхом застосування параметрів обраних користувачем за допомогою вебдодатка. Згаданий модуль звертатиметься до бази даних вебсервісу через мережевий інтерфейс та буде отримувати інформацію про нові або оновлені алгоритми. Після цього такий модуль буде створювати моделі нейронних мереж, завантажувати та оброблювати дані й виконувати наступний крок конвеєра – процес навчання.

Кожна модель має певні власні особливості та вимоги, проте основна мета їх навчання – зменшення середньої квадратичної похибки, що сприяє покращенню точності результатів і, як наслідок, дозволяє генерувати більш точні прогнози вартості курсу криптовалют. Етап навчання полягає у покращенні ефективності нейронної мережі шляхом зміни параметрів алгоритму задля зменшення похибки.

Після навчання вагові коефіцієнти та параметри певних нейронних мереж зберігатимуться. Після чого буде відбуватися фінальний етап – прогнозування. Прогнозування буде виконуватися для усіх нових або оновлених алгоритмів окремим програмним модулем. Всі результати прогнозування зберігатимуться у базу даних, що дозволить потім використовувати ці дані для вимірювання ефективності кожного алгоритму та їх порівняння.

Генерація результату є фінальним етапом AutoML. Результат конвеєру може використовуватися залежно від потреб користувача. Оскільки система буде надавати можливість порівнювати різні методи прогнозування курсу криптовалют, необхідною вимогою буде наявність відповідного функціоналу для графічного представлення результатів порівняння.

Отже, використання архітектури типу AutoML у системі дозволить зручно й швидко створювати різні методи прогнозування та конфігурувати їх відповідно до своїх потреб за допомогою вебдодатка. Це позбавить необхідності постійно впроваджувати певні ідеї та підходи у програмному коді й спростить процес порівняння різних видів алгоритмів між собою.

Важливим завданням у проєктуванні та розробці системи відповідно до принципів автоматизованого машинного навчання є створення системи, яка буде максимально проста і швидка у використанні. Саме це дозволяє пришвидшити, спростити та автоматизувати певні рутинні або ресурсоємні процеси. В той же час ця зручність не має впливати на гнучкість та ефективність системи.

Усі розглянуті алгоритми, використання яких повинно бути автоматизованим, мають певні параметри і налаштування, які дозволяють модифікувати алгоритм й таким чином пристосувати його для вирішення певного завдання.

Задля того, щоб система надавала змогу конфігурації цих параметрів, необхідно визначити їх набір для кожного з описаних алгоритмів.

Для налаштування лінійної регресії були обрані такі параметри: параметр регуляризації, епсілон SVR-моделі та *tolerance*. Параметр регуляризації використовується при розрахунку похибки моделі, де похибка є L2 метрикою, яка розраховується як середнє квадратичне відхилення між прогнозованими та реальними даними. Епсілон SVR-моделі застосовується для визначення ширини «коридору» для функціональної межі SVR. *Tolerance* визначає допустиму похибку між прогнозованими і реальними даними.

Для можливості налаштування Random Forest важливим є проведення аналізу впливу параметрів на результат у контексті певної задачі. У випадку прогнозування курсу криптовалют ефективними виявилися такі параметри:

- кількість дерев, які будуть використовуватися у ансамблі;
- максимальна глибина кожного дерева;
- мінімальна кількість елементів, за якої відбувається внутрішній поділ вузла;
- мінімальна кількість елементів, яка має бути у листовому вузлі.

Для моделі на основі XGBoost були обрані такі параметри, як швидкість навчання, кількість оцінювачів та *gamma*. Швидкість навчання відповідає за розмір кроку, який використовується при оновленні вагових коефіцієнтів з використанням методу градієнтного спуску. Кількість оцінювачів використовується для визначення кількості дерев, які будуть створені та навчені у процесі навчання. Параметр *gamma* застосовується для визначення мінімального зменшення значення цільової функції, за якого відбувається поділ вузла.

На відміну від лінійної регресії, Random Forest та XGBoost також повинні мати можливість автоматичного підбору найкращого набору параметрів. Це може бути досягнутим завдяки перебору можливих значень для кожного з них з відповідної сітки параметрів та вимірювання ефективності отриманої моделі.

Правильне налаштування параметрів є дуже важливим процесом при створенні моделі ARIMA. Тому для того, щоб її можна було ефективно використовувати у системі на основі AutoML, важливим є крок вибору цих параметрів відповідно до вхідних даних. Необхідними для модифікації моделі є такі параметри:

- *p* – вказує кількість попередніх спостережень, які використовуються для прогнозу;
- *d* – дозволяє перетворити вихідний часовий ряд у стаціонарний;
- *q* – параметр для врахування зв'язку між поточними даними і попередніми випадковими коливаннями;
- сезонний *p* – параметр сезонної авторегресії для сезонної компоненти часу;
- сезонний *d* – параметр сезонної різниці для сезонної компоненти часу;
- сезонний *q* – параметр сезонної МА для сезонної компоненти часу.

Архітектура LSTM є найскладнішою з усіх попередньо згаданих й відповідно має більшу кількість параметрів та варіантів налаштування. Конфігурацію моделі на основі такої архітектури глибинних нейронних мереж можна розглядати у двох напрямках: параметри моделі та будова нейронної мережі. Основними параметрами було обрано кількість епох навчання, кількість епох для зупинки (навчання зупиняється, якщо впродовж визначеної кількості попередніх епох модель не зазнала поліпшень),

параметр швидкості навчання та алгоритм оптимізації. Окрім цього, важливим є впровадження функцій зворотнього зв'язку, які дозволяють вчасно зупинити навчання за потреби або динамічно змінювати швидкість навчання. Налаштування будови моделі має відбуватися за допомогою клієнтського інтерфейсу у вигляді конструктора. Це дозволяє додавати нові або видаляти зайві шари нейронної мережі (LSTM, Dense, Dropout), а також налаштовувати параметри кожного з них (кількість нейронів, функція активації, значення dropout).

Отже, кожний з розглянутих алгоритмів має свої особливості, параметри та вимоги, проте можливість їх налаштування є невід'ємним етапом створення моделі у конвеєрі AutoML.

Висновки. Процес об'єктивного порівняння алгоритмів прогнозування вимагає створення, навчання та оцінки значної кількості конфігурацій нейронних мереж, що значно уповільнює й ускладнює цей процес. З цією метою було вирішено провести дослідження можливості застосування принципів AutoML у системі, що зможе допомогти значно пришвидшити і спростити порівняння алгоритмів прогнозування курсу криптовалют за допомогою інструментів автоматизації.

Під час аналізу був розглянутий конвеєр автоматизованого машинного навчання і досліджені основні його етапи. Базуючись на отриманій інформації, було спроектовано конвеєр збору та обробки даних, створення, навчання нейронних мереж та вимірювання результатів, який може бути застосований для вирішення досліджуваної проблеми. На основі отриманих даних було підтверджено можливість використання цього підходу при розробці системи аналізу алгоритмів прогнозування курсу криптовалют, що дозволить провести їх більш широке та ефективне порівняння.

References:

1. Yiying, W. and Yeze, Y. (2019), «Cryptocurrency price analysis with artificial intelligence», pp. 97–101.
2. Saad, M., Choi, J., Nyang, D. et al. (2020), «Toward characterizing blockchain-based cryptocurrencies for highly accurate predictions», pp. 321–332.
3. Larasati, K. and Primandari, A. (2021), «Forecasting Bitcoin price based on blockchain information using long-short term method», pp. 1–5.
4. Rothman, T. and Yakar, C. (2019), «Empirical analysis towards the effect of social media on cryptocurrency price and volume», 52 p.
5. Ali, M. and Shatabda, S. (2020), «A data selection methodology to train linear regression model to predict bitcoin price», *2nd International Conference on Advanced Information and Communication Technology (ICAICT)*, IEEE, pp. 330–335.
6. Wu, J., Guo, X., Fang, M. and Zhang, J. (2022), «Short term return prediction of cryptocurrency based on XGBoost algorithm», *International Conference on Big Data, Information and Computer Network (BDICN)*, Sanya, China, pp. 39–42.
7. Si, Y. (2022), «Using ARIMA model to analyse and predict bitcoin price», *DCP Business and Management*, No. 34, pp. 1210–1216.
8. Biswas, S., Pawar, M., Badole, S. et al. (2021), «Cryptocurrency price prediction using neural networks and deep learning», *7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, IEEE, Vol. 1, pp. 408–413.
9. Huang, X., Zhang, W., Huang, Y. et al. (2021), «Lstm based sentiment analysis for cryptocurrency prediction», *ArXiv*, Vol. abs/2103.14804.
10. Yao, Y. and Wang, L. (2021), «Combination of window-sliding and prediction range method based on LSTM model for predicting cryptocurrency», *ArXiv*, Vol. abs/2102.05448.

Плечистий Дмитро Дмитрович – кандидат технічних наук, доцент, доцент кафедри комп'ютерних наук Державного університету «Житомирська політехніка».

<https://orcid.org/0000-0002-4803-159X>.

Наукові інтереси:

- комбінаторна оптимізація;
- інформаційні технології.

E-mail: kkn_pdd@ztu.edu.ua.

Сігайло Максим Сергійович – магістр Державного університету «Житомирська політехніка».

Наукові інтереси:

- інтелектуальний аналіз даних;
- інформаційні технології.

E-mail: ipzm221_sms@student.ztu.edu.ua

Plechystyy D., Sitailo M.

Research of the application of automated machine learning for the comparative analysis of cryptocurrency rate forecasting methods

The forecasting of asset values has always attracted significant interest, prompting researchers to continuously refine methods and tools for addressing this task. The advancement of artificial intelligence has greatly enhanced research potential in this field, leading to the emergence of new algorithms and methods that leverage the advantages of computational speed and the accuracy of neural networks. This has fueled active research in machine learning for forecasting, resulting in the development of new variations and modifications of algorithms. However, the abundance of research necessitates users to independently analyze and experimentally verify their effectiveness. This article explores the possibility to apply automated machine learning (AutoML) to analyze and compare methods for cryptocurrency price predictions. At the time of the research, AutoML is mostly used to simplify the process of using machine learning to solve general practical problems. However, this approach allows automating the process of comparing the results of various studies and significantly simplifying the process of their generalization. Automated machine learning is based on a predefined set of interdependent processes that are combined into a pipeline. Usually, the pipeline consists of automated operations from data processing till the results generation, that significantly improves the process of results obtaining and analysis. The article describes the main principles and features of the system and how each pipeline's phase was modified to accomplish our task. The described architecture makes it possible to automate such processes as data collection and processing, creation and training of machine learning models, generation and processing of the received outputs. As a result, the user of the designed system can configure any of the supported algorithms using the user interface and later analyze the obtained results using the corresponding program modules.

Keywords: system for methods analysis; cryptocurrency rate forecasting methods; neural networks; machine learning; automated machine learning; AutoML.

Стаття надійшла до редакції 07.03.2024.