

Київський національний університет імені Тараса Шевченка

Економічний факультет

Кафедра економічної кібернетики

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

«Моделювання короткострокової динаміки валютних та криптовалютних курсів
з використанням глибоких нейронних мереж»

студентки 2 курсу магістратури
спеціальності 051 «Економіка»
ОНП «Економічна кібернетика»
денної форми навчання
Ситник Марії Євгенівни

Науковий керівник:

кандидат економічних наук, доцент
Подскребко Олександр Сергійович

Засвідчую, що в цій роботі немає запозичень із
праць інших авторів без відповідних посилань

Студент _____
(підпис)

Роботу допущено до захисту перед ЕК
рішенням кафедри економічної кібернетики
від 11 травня 2023 р., протокол № 15

Завідувач кафедри:

доктор економічних наук, професор

Ляшенко Олена Ігорівна

(підпис)

РЕФЕРАТ

Кваліфікаційна робота магістра містить: 94 ст., 31 рис., 2 табл., 63 джерела, 5 додатків

Ключові слова: прогнозування курсу фіатних валют та криптоактивів, глибокі нейронні мережі, валютний ринок, машинне навчання.

Об'єктом дослідження є процес зміни короткострокової динаміки фіатних валют та криптоактивів.

Предмет дослідження: методи та моделі прогнозування процесу зміни короткострокової динаміки фіатних валют та криптоактивів.

Мета роботи: розробка математичної моделі короткострокового прогнозування динаміки валютного ринку для підвищення точності прогнозів котирувань фіатних валют та криптоактивів за рахунок використання глибоких нейронних мереж.

Методи дослідження: в роботі використовується системний підхід для досягнення мети. Для вирішення поставлених завдань використано такі методи наукового дослідження, як узагальнення, класифікація, статистичні методи, аналіз, синтез, економіко-математичне моделювання та порівняння, машинне навчання, зокрема глибокі нейронні мережі.

RESUME

Taras Shevchenko National University of Kyiv,

Faculty of Economics, Department of Economic Cybernetics

Key words: forecasting the exchange rate of fiat currencies and crypto assets, deep neural networks, foreign exchange market, machine learning.

The graduation research of student Mariia Sytnyk “Modeling of short-term dynamics of currency and cryptocurrency rates using deep neural networks” is a development of a mathematical model for short-term forecasting of currency market dynamics to improve the accuracy of forecasts of fiat currency and cryptoassets quotes through the use of deep neural networks.

Pages 94, tables 2, bibliog. 63, append. 5.

ЗМІСТ

ВСТУП	4
РОЗДІЛ 1. ТЕОРЕТИЧНІ АСПЕКТИ ПРОГНОЗУВАННЯ СТАНУ ТА ДИНАМІКИ ВАЛЮТНИХ РИНКІВ	7
1.1. Поняття валютного ринку, його сутність та роль в сучасному світі	7
1.2. Поняття криптовалют. Види криптовалют та аналіз динаміки їх курсів	16
1.3. Огляд методологічних підходів та математичного інструментарію прогнозування короткострокової динаміки фіатних валют та криптоактивів .	26
РОЗДІЛ 2. РОЗРОБКА МАТЕМАТИЧНОЇ МОДЕЛІ ПРОГНОЗУВАННЯ ДИНАМІКИ ВАЛЮТНИХ РИНКІВ	34
2.1. Формування вимог до моделі. Опис вхідних змінних.....	34
2.2. Розробка методики проведення розрахунків	40
РОЗДІЛ 3. ПРИКЛАДНА РЕАЛІЗАЦІЯ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ДИНАМІКИ ВАЛЮТНИХ РИНКІВ	46
3.1. Апробація класичних моделей машинного навчання для прогнозування валютних ринків	46
3.2. Апробація глибоких нейронних мереж для прогнозування валютних ринків.....	51
3.3. Оцінка точності отриманих прогнозів та якості побудованих моделей	61
ВИСНОВКИ.....	67
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	70
ДОДАТКИ	77

ВСТУП

Світова економіка зазнала глобалізації та діджиталізації, найпомітнішим прикладом чого є фінансовий сектор. Ці зміни призвели до збільшення міграції капіталу та зростання волатильності на міжнародному валютному ринку, що, в свою чергу, спричинило зростання валютного ризику для українських банків та компаній, оскільки їхні майбутні грошові потоки важко передбачити. Для зменшення ризику та підвищення ефективності валютних операцій важливим є отримання надійних прогнозів валютних курсів.

Для традиційних активів, таких як фіатні валюти, існують різні методи та моделі, які використовують економетричні моделі, баланс попиту та пропозиції і навіть паритет купівельної спроможності. Незважаючи на різноманітність підходів, динаміка валютних котирувань залишається складною через безліч факторів і причинно-наслідкових зв'язків.

Особливо це стосується криптовалют, які мають власний набір латентних факторів, які ще недостатньо вивчені та ідентифіковані. Крім того, їхня волатильність і ризик роблять їх ще більш складними для прогнозування за допомогою класичних статистичних та економетричних моделей.

Актуальність даної теми обумовлена зростанням ролі криптовалют у світовому фінансовому ландшафті та потребою в більш досконалих інструментах прогнозування для управління інвестиціями та зниження ризиків. Інтеграція криптовалют в основну економіку породила нові виклики в розумінні та прогнозуванні їхньої короткострокової динаміки. Крім того, подальша глобалізація фінансових ринків призвела до створення більш взаємопов'язаного та складного світу, де здатність прогнозувати короткострокові коливання валютних курсів має вирішальне значення для прийняття обґрунтованих рішень.

Деякі українські та зарубіжні економісти зробили свій внесок у розуміння динаміки валют та криптовалют. Серед них такі відомі дослідники, як С. Плохій, О. Жолудь, А. Камінський, А. Ставицький, О. Черняк, В. Вітлінський, В. Дербенцев, В. Безкоровайний та ін.

Фундаментальні та прикладні праці в галузі машинного та глибокого навчання авторів В. Ченга, Дж. Гуо, З. Чжана, С. Хохрайтера, П. Мішри, Д. Сонга, А. Харвала, А. Нурмагамбетова, Й. Чу та ін. склали методологічну основу дослідження.

Вивчення наукової літератури з питань динаміки валютного ринку показує, що основна увага при моделюванні валютних курсів приділяється двом основним категоріям. З одного боку, акцент робиться на короткостроковому прогнозуванні котирувань, насамперед для спекулятивної діяльності на валютних біржах з використанням технічного аналізу та моделей часових рядів. З іншого боку, основна увага приділяється моделюванню довгострокових тенденцій за допомогою економетричних моделей для визначення рівноважних і реальних валютних курсів, які сприяють макроекономічній стабільності.

Проведений аналіз показав, що для вирішення завдань моніторингу та короткострокового прогнозування валютних котирувань як на традиційних, так і на криптовалютних ринках, необхідна розробка ефективного прогнозно-аналітичного інструментарію. На нашу думку, цей інструментарій має ґрунтуватися на сучасних методах моделювання, зокрема, із залученням технологій машинного навчання та інструментів глибоких нейронних мереж.

Це допомогло визначитися з науковим напрямом та вибором теми дослідження, а також його основної мети, методів дослідження та завдань, які були поставлені та вирішені в рамках дослідження.

Метою роботи є розробка математичної моделі короткострокового прогнозування динаміки валютного ринку для підвищення точності прогнозів котирувань фіатних валют та криптоактивів за рахунок використання глибоких нейронних мереж.

Для досягнення поставленої мети в роботі було сформульовано та вирішено наступні завдання:

- досліджено валютний ринок та визначено його економічну сутність, особливості функціонування та перспективи розвитку в сучасному світі;
- досліджено криптовалюти, їх види та методи аналізу динаміки їх курсів;

- здійснено порівняльний аналіз існуючих методів моделювання та прогнозування котирувань фіатних валют та криптоактивів;
- сформульовано вимоги до власної моделі, описано вхідні змінні;
- побудовано систему моделей короткострокового прогнозування динаміки фіатних валют та криптоактивів на основі обраного математичного інструментарію;
- розроблено алгоритм та здійснено програмну реалізацію побудованих моделей.

Об'єктом дослідження є процес зміни короткострокової динаміки фіатних валют та криптоактивів.

Предметом дослідження є методи та моделі прогнозування процесу зміни короткострокової динаміки фіатних валют та криптоактивів.

Наукова новизна роботи полягає у застосуванні методів глибокого навчання, зокрема глибоких нейронних мереж, для прогнозування короткострокової динаміки курсів валют та криптовалют. Запропоновані моделі мають потенціал для виявлення складних закономірностей та взаємозв'язків у даних, забезпечуючи більш точне та складне розуміння динаміки ринку.

Інформаційною базою дослідження є науково-дослідницькі роботи вітчизняних та зарубіжних авторів; періодичні видання у фахових економічних виданнях; наукова література економічного характеру; інформація, яка розміщена в мережі Інтернет, зокрема дані глобального фінансового порталу Investing.com та Yahoo! Finance.

Структура роботи. Магістерська робота складається із вступу, трьох розділів, висновків, списку використаних джерел та додатків.

РОЗДІЛ 1. ТЕОРЕТИЧНІ АСПЕКТИ ПРОГНОЗУВАННЯ СТАНУ ТА ДИНАМІКИ ВАЛЮТНИХ РИНКІВ

1.1. Поняття валютного ринку, його сутність та роль в сучасному світі

Світовий валютний ринок є невід'ємною частиною міжнародної фінансової системи. Це велика і складна мережа установ, трейдерів і операцій, які працюють в режимі 24/7, дозволяючи обмінюватися валютами між різними країнами. Світовий валютний ринок відіграє ключову роль у світовій економіці: він допомагає стабілізувати ціни, полегшує транскордонні операції та сприяє міжнародній торгівлі та інвестиціям.

З функціонального погляду валютний ринок можна розглядати як сукупність різних операцій із валютою і валютними цінностями, зокрема здійснення міжнародних розрахунків, страхування валютних ризиків, диверсифікацію валютних резервів, валютні інтервенції, спекулятивні операції.

З інституційного погляду валютний ринок є сукупністю інституційних учасників ринку, що здійснюють операції з валютою, зокрема валютних бірж, уповноважених банків, інвестиційних компаній, брокерських контор, іноземних банків.

З організаційно-технічного погляду під валютним ринком розуміється сукупність телеграфних, телефонних, електронних та інших комунікаційних систем, які пов'язують між собою учасників валютного ринку [63].

У державах із повністю закритою економікою валютного ринку немає.

При відкритій економіці, що передбачає участь у економічній міжнародної діяльності, роль валютного ринку надзвичайно велика.

Суб'єктами (учасниками) валютного ринку виступають банки, біржі, експортери та імпортери, фінансові та інвестиційні установи, урядові організації.

Об'єкт валютного ринку – будь-яка фінансова вимога, позначена у валютних цінностях.

На відміну від інших видів ринку, валютний ринок має свої особливості:

- не має чітких географічних кордонів;
- не має певного місця розташування;
- функціонує цілодобово;
- на ньому може діяти необмежена кількість учасників;
- має високий ступінь ліквідності.

Вихід на валютний ринок може переслідувати різноманітні цілі: здійснення міжнародних розрахунків, зміна структури валютних резервів, отримання спекулятивного прибутку з різниці курсів окремих валют, захист від валютних та кредитних ризиків [63].

Головна риса валютного ринку у тому, що у ньому грошові одиниці протистояють одна одній лише як записи по кореспондентським рахункам.

Основною функцією світового валютного ринку є забезпечення ліквідності міжнародних банківських і фінансових ринків. Оскільки ринок тісно взаємопов'язаний, він дозволяє інвесторам і трейдерам швидко конвертувати валюту між різними країнами, що дає їм доступ до різних ринків і можливість швидко здійснювати інвестиції.

Світовий валютний ринок також слугує механізмом ціноутворення, забезпечуючи ефективний засіб передачі цінової інформації між країнами. Крім того, він допомагає як урядам, так і приватним установам управляти валютними ризиками, дозволяючи їм хеджувати потенційні втрати через коливання валютних курсів.

Світовий валютний ринок також відіграє важливу роль у глобальній макроекономічній стабільності. Допомагаючи забезпечити узгодженість обмінних курсів між країнами, він допомагає запобігти валютним кризам і нестабільності, сприяючи фінансовій стабільності та глобальному економічному зростанню (рис.1.1).

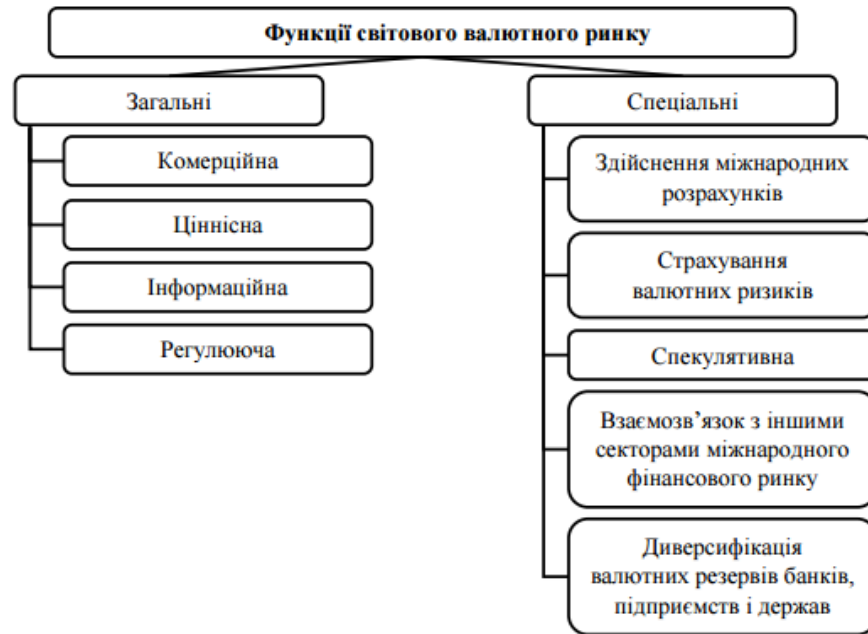


Рис. 1.1. Функції світового валютного ринку

Джерело: [49].

Валютний ринок є невід'ємною частиною світової економіки, яка дозволяє підприємствам, інвесторам та приватним особам обмінюватися валютами один з одним. Він слугує каналом для міжнародної торгівлі та інвестицій, а також сприяє глобальному руху капіталу. Валютний ринок є одним з найбільших і найліквідніших ринків у світі, щоденний обсяг торгів на якому перевищує 5 трильйонів доларів США. Він складається з мережі банків, брокерів та інших фінансових установ, які сприяють здійсненню валютних операцій.

На сучасному валютному ринку здійснюють операції різні суб'єкти: фірми, які здійснюють зовнішньоторговельні операції; компанії, які здійснюють закордонні вкладення активів; центральні банки; комерційні банки; приватні особи; валютні біржі; валютні брокерські компанії.

Найбільший вплив на світові валютні ринки має центральний банк США - Федеральна Резервна Система (US Federal Reserve або коротко FED). Далі за ним слідує центральний банк Німеччини - Бундесбанк (Deutsche Bundesbank) і Великобританії - Банк Англії (Bank of England званий також Old Lady) [9].

За сферою поширення виділяють такі валютні ринки: міжнародний та внутрішній.

Під міжнародним ринком розуміються ринки всіх країн світу, які тісно пов'язані між собою кабельними та супутниковими комунікаціями.

Внутрішній валютний ринок – ринок, що функціонує усередині цієї країни.

І міжнародний, і внутрішній валютні ринки складаються із регіональних валютних ринків.

По відношенню до валютних обмежень розрізняють: вільний та невільний валютні ринки.

Під валютними обмеженнями розуміються адміністративні, законодавчі, економічні та організаційні заходи щодо встановлення порядку під час проведення валютних операцій. До валютних обмежень відносяться:

- заходи щодо цільового регулювання платежів та переказів у іноземній та національній валюті за кордон;
- повна або часткова заборона купівлі-продажу іноземної валюти.

Валютні обмеження можуть застосовуватися як за поточними операціями, так і за операціями, пов'язаними з рухом капіталу.

Валютний ринок відіграє важливу роль у світовій економіці, оскільки дозволяє всім країнам здійснювати міжнародну торгівлю та інвестиції. Він також слугує платформою для фізичних та юридичних осіб для інвестування та хеджування своїх ризиків в іноземній валюті. Валютний ринок складається зі спотового, форвардного та ф'ючерсного ринків, які є найважливішими сегментами світового валютного ринку.

Спот-ринок – це найбільший сегмент валютного ринку, торгівля на якому відбувається в режимі реального часу. Він використовується для валютних операцій, в яких дві валюти, що беруть участь, обмінюються за поточним курсом [9].

Форвардний ринок використовується для операцій, які заплановані на більш пізній термін. Це дозволяє учасникам хеджуватися від коливань валютних курсів, які можуть відбутися в майбутньому.

Ф'ючерсний ринок – це платформа, яка використовується інвесторами для спекуляцій на напрямку руху валютного курсу. Він дозволяє учасникам укласти

контракт на купівлю або продаж валюти за заздалегідь визначеним курсом у майбутньому [9].

На даний момент співвідношення на валютному ринку між ними така: торгівля спотовими та валютними свопами продовжувала становити основну частину валютного обороту. У квітні 2022 року оборот на валютних ринках спот становив 2,1 трильйона доларів США на день, що становило 28% світового обороту, що є дещо нижчою часткою порівняно з 2019 роком (рис. 1.2). Зі свого боку, валютні свопи, які зазвичай є інструментами з коротким терміном погашення (до семи днів) й використовуються учасниками ринку для управління фінансовою ліквідністю та хеджування валютного ризику, залишався найбільш торговим інструментом з оборотом 3,8 трильйона доларів США на день. Їхня частка у світовому обороті зросла до 51% з 49% у 2019 році та 47% у 2016 році. Частка торгівлі аутрайт-форвардами залишилася незмінною на рівні 15% світового обороту в статистиці 2022 року. Оборот валютних опціонів становив 4% світового обороту, а валютних свопів – 2%. Останні, як правило, мають більший термін погашення, ніж валютні свопи або прямі форварди, отже, нижчий оборот.




Рис. 1.2. Динаміка валютного ринку

Джерело: [3]

У квітні 2022 року оборот на світових валютних ринках сягнув 7,5 трильйонів доларів США на день, що в 30 разів перевищує щоденний світовий ВВП. Трирічне дослідження Центрального банку позабіржового обороту

іноземної валюти дозволяє зазирнути в цей величезний валютний ринок. Цього року, у квітні, збір даних збігся з підвищеною волатильністю валютних курсів через сукупність факторів, таких як зміна очікувань щодо шляхів майбутніх процентних ставок в основних країнах з розвинутою економікою, зростання цін на сировинні товари та геополітична напруженість після вторгнення Росії в Україну.

Глобальні обсяги валютних операцій були вищими порівняно з попереднім трирічним дослідженням у 2019 році завдяки двом основним факторам. По-перше, більше торгівлі валютними деривативами з коротким терміном погашення, що механічно збільшує обіг за умови, що багато контрактів пролонговано. А більш широке використання похідних інструментів з коротким терміном погашення може відображати небажання учасників ринку брати на себе строковий ризик у більш нестабільному середовищі. По-друге, більше торгівлі між дилерами, яка, як правило, зростає з волатильністю. Насправді зростання міждилерського товарообігу було достатньо великим, щоб змінити довгострокову тенденцію зниження міждилерської частки у світовій валютній торгівлі. Навпаки, торгівля дилерів із фінансовими клієнтами стагнувала, що відображає уповільнення міжнародної фінансової інвестиційної діяльності.

Підсумовуючи, можна сказати, що валютний ринок є глобальною системою яка працює 24/7 зі своїми законами і правилами. Валютний ринок дуже важливий для світової економіки та торгівлі. Він є ключовим для регулювання та моніторингу світової валютної системи, що дозволяє країнам залагодити свої економічні відносини. Валютні курси є індикаторами макроекономічного стану країн, дозволяючи зрозуміти, як гроші впливають на інфляцію, безробіття та інші індикатори стану економіки.

Ліквідність є ключовим поняттям у світі торгівлі на валютному ринку, і воно означає легкість, з якою валютну пару можна купити або продати на ринку, не завдаючи істотного впливу на її ціну. Іншими словами, ліквідність - це міра того, наскільки швидко і легко трейдер може відкрити або вийти з позиції в певній валютній парі [61].

Концепція ліквідності особливо важлива на форекс через децентралізований характер ринку. На відміну від акцій, якими торгують на біржах, які надають централізовані книги заявок і механізми відповідності, торгівля форекс здійснюється поза біржею (ОТС), тобто центральної біржі немає. Натомість трейдери форекс покладаються на мережу банків, фінансових установ та інших учасників ринку, щоб купувати та продавати валюту.

Завдяки такій децентралізованій структурі ліквідність валютних пар може сильно змінюватися залежно від часу доби, ринкових умов та інших факторів. Деякі валютні пари є високоліквідними, що означає велику торговельну активність і велику кількість покупців і продавців, тоді як інші можуть бути менш ліквідними та важчими для торгівлі.

Ліквідність валютних пар важлива з кількох причин. По-перше, це впливає на швидкість, з якою трейдер може здійснити угоду. На високоліквідному ринку угоди можна виконувати швидко та за бажаною ціною, тоді як на менш ліквідному ринку можливі затримки або прослизання, коли ціна угоди відхиляється від запланованої ціни.

По-друге, ліквідність важлива для управління ризиком. Трейдери, які не можуть швидко вийти з позиції в певній валютній парі, можуть піддатися більшому ринковому ризику, якщо відбуваються раптові коливання ціни. На високоліквідному ринку трейдери можуть швидко виходити з позицій, якщо це необхідно, що може допомогти мінімізувати втрати та керувати ризиком.

Нарешті, ліквідність важлива для визначення вартості торгівлі. На високоліквідному ринку спред між купівлею та попитом є вузьким, що означає, що трейдери платять менше операційних витрат, щоб увійти в позицію або вийти з неї. На менш ліквідному ринку спред між покупцями та пропозиціями може бути ширшим, що може зробити торгівлю дорожчою [61].

Найбільш ліквідні валютні пари відомі як основні валютні пари, до яких належать долар США (USD), євро (EUR), японська єна (JPY), британський фунт (GBP), швейцарський франк (CHF), канадський долар (CAD) і австралійський долар (AUD). Ці валютні пари найактивніше торгуються на ринку Форекс і

мають найменший спред між покупкою та попитом, що є різницею між ціною, за якою трейдер може купити або продати валютну пару. На рис. 1.3 можна побачити як розподіляються торги на валютному ринку за валютними парами.




Рис. 1.3. Розподіл обсягів торгів за валютними парами

Джерело: [61]

Найліквідніша валютна пара – це EUR/USD, і вона займає 28% від сумарного обсягу угод на ринку Форекс, що робить її основною валютною парою Форекс. Другою за ліквідністю валютною парою є USD/JPY з часткою 13%. Третьою – GBP/USD, 11%.

Від ліквідності сильно залежить якість виконання угод та комісійні витрати, тому багато трейдерів воліють торгувати виключно такі валютні пари, а деякі взагалі «зациклюються» на EUR/USD і ніяких інших пар.

У цілому нині, різниця у ліквідності між усіма основними парами менш істотна, щоб обмежувати себе лише однієї. Ліквідність мають не самі пари, а складові її валюти.

Трейдери продають не валютну пару, а продають/купають конкретну валюту. Відповідно ліквідність валютної пари є похідною від ліквідності складових її валют. На рис. 1.4 можна побачити найбільш ліквідні валюти.




Рис. 1.4. Розподіл обсягів торгів за валютами

Джерело: [61]

Без сумніву, USD (американський долар) може вважатися однією з найвпливовіших валют на ринку Форекс. Це одна із тих незамінних валют, які входять до складу всіх основних валютних пар. Більше того, USD є валютою, яку зберігають у своїх резервах практично всі центральні банки світу.

Оскільки її обмінний курс постійно змінюється, ринок Форекс неминуче піддаватиметься інтенсивним флуктуаціям. Це пов'язано з тим, що коливання вартості американської валюти позначатимуться на валютних курсах великої кількості валютних пар, які торгуються на ринку Форекс. Роль USD у валютній торгівлі настільки велика, що навіть ті, хто торгує недоларовими валютними парами, повинні стежити за його курсом, оскільки він може опосередковано вплинути на вашу торгівлю.

Друга найбільш ліквідна валюта – EUR. Незважаючи на те, що це відносно молода валюта, EUR швидко зайняв друге місце по торговому обороту на ринку Форекс після USD. Більше того, євро є другою найбільшою резервною валютою у світі. Завдяки своїй популярності серед Форекс-трейдерів євро значною мірою сприяє підтримці ліквідності євро валютних пар.

EUR є офіційною валютою більшості країн, що входять до єврозони. Політичні події всередині єврозони можуть часто призводити до зміни курсу євро, тому це, можливо, "політизована" з усіх валют, що активно торгуються на Форексі. Ось чому вона дуже впливає на цей ринок.

Третя за впливовістю – JPY. JPY (японська ієна) є офіційною валютою Японії і займає важливе місце серед інших валют на ринку Форекс. Це валюта, що найактивніше торгується в Азії. Вона займає третє місце у світі з торговельного обороту після USD та EUR.

Крім того, японська ієна є також і резервною валютою, яка активно використовується багатьма центральними банками.

Таким чином, ліквідність валютних пар є важливою концепцією для розуміння трейдерами форекс. Високоліквідними валютними парами, такими як основні валютні пари, легше торгувати, вони пропонують швидший час виконання та менші витрати на транзакцію. Розуміння ліквідності валютних пар може допомогти трейдерам керувати ризиками та приймати більш обґрунтовані торгові рішення.

1.2. Поняття криптовалюти. Види криптовалют та аналіз динаміки їх курсів

Криптовалюта — це цифрова або віртуальна форма валюти, яка використовує криптографію з метою безпеки. На відміну від традиційних фіатних валют, криптовалюти не контролюються жодним центральним органом влади, а їхня вартість визначається ринковими силами попиту та пропозиції [51].

Існують різні типи криптовалют, включаючи Bitcoin, Ethereum, Ripple, Litecoin і Bitcoin Cash, серед інших. Біткойн є першою та найпопулярнішою криптовалютою, тоді як Ethereum відомий своїми можливостями смарт-контрактів, які дозволяють запускати децентралізовані програми в мережі блокчейну. Ripple призначений для швидких і недорогих міжнародних грошових переказів, тоді як Litecoin є швидшою та дешевшою альтернативою Bitcoin.

З моменту появи біткойна більше десяти років тому з'явилося багато нових типів криптовалют. Від стейблкоїнів до невзаємозамінних токенів (NFT) і собачих мемів – сьогодні доступна велика різноманітність криптовалют.

Спільним для них є використання технології розподіленої книги, відомої як блокчейн.

CoinMarketCap повідомляє, що існує приблизно 22 932 криптовалюти із загальною ринковою капіталізацією 1,24 трильйона доларів. Це досить багато, враховуючи, що біткойн був запущений лише в 2009 році [15].



Рис. 1.5. Загальна капіталізація крипторинку в дол. США за 2018-2023 рр.

Джерело: [15]

Перші альтернативи оригінальній криптовалюти — пізніше названі альткойнами — з'явилися на сцені лише в 2011 році, наприклад Litecoin (LTC) і Namecoin (NMC). Лише після запуску Ethereum (ETH) альткойни набули популярності.

Деякі криптовалюти, як-от Bitcoin, використовуються як інструменти інвестування. Багато покупців вважають їх засобом збереження цінності. Інші більш транзакційні, як Ethereum. Розробники можуть створювати всілякі транзакційні інструменти, сервіси та спільноти, використовуючи більш транзакційні блокчейни.

Існує також різниця між монетами та токенами. Bitcoin та альткойни, такі як Ethereum, які працюють на власному блокчейні, вважаються монетами. Коли більшість людей думають про криптовалюту, ймовірно, думають про криптовалюту, такі як Bitcoin.

Токени — це цифрові активи, що зберігаються в базі даних блокчейну. Вони створюються на блокчейнах, які вже існують, і зазвичай представляють актив або надають власнику певну послугу або доступ до програми. Токен — це цифрова одиниця, яка представляє актив або корисність. Наприклад, незліченна кількість токенів працює в мережі Ethereum [19].

Типи криптотокенів:

- *Жетони вартості*. Ці типи токенів є цінними об'єктами, такими як цифрові активи, такі як мистецтво чи музика у формі NFT.
- *Жетони корисності*. Це токени, які допомагають надавати послугу. Вони дають користувачам право виконувати дії в мережі блокчейн або децентралізованому додатку.
- *Жетони безпеки*. Цей тип токена представляє право власності на актив. Компанії можуть використовувати токени безпеки для залучення капіталу шляхом продажу токенів акцій. Оскільки вони представляють право власності на фінансовий цінний папір, ці активи регулюються Комісією з цінних паперів і бірж (SEC). Вони відрізняються від NFT і токенів вартості, оскільки є взаємозамінними.


Токени ERC-20 — назва походить від запиту Ethereum на коментар 20 — працюють у мережі Ethereum. Серед популярних токенів ERC-20 — монета-мем Shiba Inu (SHIB) і стейблкоїн DAI (DAI). ERC-20 — це технічний стандарт для взаємозамінних токенів, створених за допомогою блокчейну Ethereum. Він встановлює правила, яких мають дотримуватися розробники, щоб токен працював на платформі Ethereum.

Визначення альткойна змінилося з перших днів криптовалюти, коли існувала лише невелика кількість криптоактивів. Тоді все, крім біткойна, вважалося альткойном.

Світ криптовалюти сьогодні набагато більший, з різними монетами та токенами, варіанти використання яких виходять далеко за рамки засобу обміну. Багато з цих криптовалют не обов'язково є конкурентами біткойнів.

Провідним альткоїном сьогодні є Ethereum, ринкова капіталізація якого становить 252,14 мільярдів доларів проти 586,52 мільярдів доларів капіталізації Bitcoin. Інші основні альткоїни включають Solana (SOL) і Cardano (ADA). SOL і ADA вважаються конкурентами Ethereum.

Ринкова капіталізація Bitcoin в дол. США з 2018 до 2023



Ринкова капіталізація ETH в дол. США з 2018 до 2023




Рис. 1.6. Порівняння капіталізації Bitcoin та Ethereum за 2018-2023 рр.

Джерело: [42]

Альткоїни можуть мати різні цілі, окрім простої цифрової валюти. У той час як біткойн призначений як форма децентралізованої валюти, Ethereum — це обчислювальна мережа, яка дозволяє користувачам запускати децентралізовані програми в блокчейні та розміщувати смарт-контракти.

Стейблкоїн — це криптовалюта, вартість якої прив'язана до ціни іншого активу. Якщо стейблкоїн, прив'язаний до долара США, функціонує правильно, він завжди повинен оцінюватися в 1 долар США.

Один тип стейблкоїна випускається фінансовою організацією, яка має забезпечення застави для кожної одиниці стейблкоїна, а інший використовує похідні стратегії, щоб переконатися, що криптоактив підтримує вартість базової державної валюти».

Забезпечені стейблкоїни. Забезпечені стейблкоїни зберігають пул застави для підтримки вартості монети. Щоразу, коли хтось продає свої токени, з

резервів монет вилучається рівна кількість застави. Tether (USDT), який прив'язаний до долара США, є, мабуть, найбільш впізнаваним стейблкоїном, хоча люди сумніваються в надійності його резервів.

Алгоритмічні стейблкоїни. Ці стейблкоїни використовують алгоритми, щоб контролювати свою пропозицію та таким чином підтримувати прив'язку ціни. Прикладом є TerraUSD (UST), який спочатку був прив'язаний до 1 долара шляхом створення та знищення дочірньої монети під назвою Luna. Кожного разу, коли TerraUSD купували або продавали, створювалась або знищувалась відповідна кількість дочірнього токена Luna. Ця стратегія чудово працювала, поки трейдери не зламали прив'язку [41]. Коли паніка змусила людей заробити гроші на TerraUSD під час масового відтоку, TerraUSD відмовився від прив'язки до 1 долара та впав майже до нуля разом із Luna. На захист TerraUSD та сама паніка спричинила падіння вартості Tether з 1 долара за монету до 0,94 долара за монету.

Монети-меми, також відомі як «меметичні» монети або «жартівливі» монети, — це тип криптовалюти, який часто створюють як жартівливий або сатиричний погляд на більш серйозні цифрові валюти, такі як Bitcoin або Ethereum.

Меми-монети зазвичай мають низьку ринкову капіталізацію та низькі обсяги торгів, і часто торгуються на децентралізованих біржах, таких як Uniswap або PancakeSwap.

На відміну від інших криптовалют, які можуть мати конкретне використання або призначення, меми-монети часто створюються для розваг або як соціальний експеримент. Їхня вартість значною мірою є спекулятивною і визначається ажіотажем і настроями ринку. Таким чином, інвестиції в меми-монети можуть бути дуже ризикованими, і інвесторам слід проявляти обережність і проводити власні дослідження, перш ніж приймати будь-які інвестиційні рішення.

Варто також зазначити, що меми-монети часто схильні до високої волатильності, тобто їх вартість може різко коливатися протягом короткого

періоду часу. Це може зробити їх ризикованою інвестицією, особливо для недосвідчених інвесторів, які можуть бути не готові до потенційних втрат, які можуть виникнути в результаті інвестування в такі активи.

Оригінальною монетою-мемом, з якої все почалося, є Dogecoin (DOGE), який був названий навколо мему собаки Шiba-іну. Але те, що починалося як жарт, стало перевіреним культовим ресурсом, коли користувачі почали його переглядати. У результаті почало з'являтися більше схожих мемів.

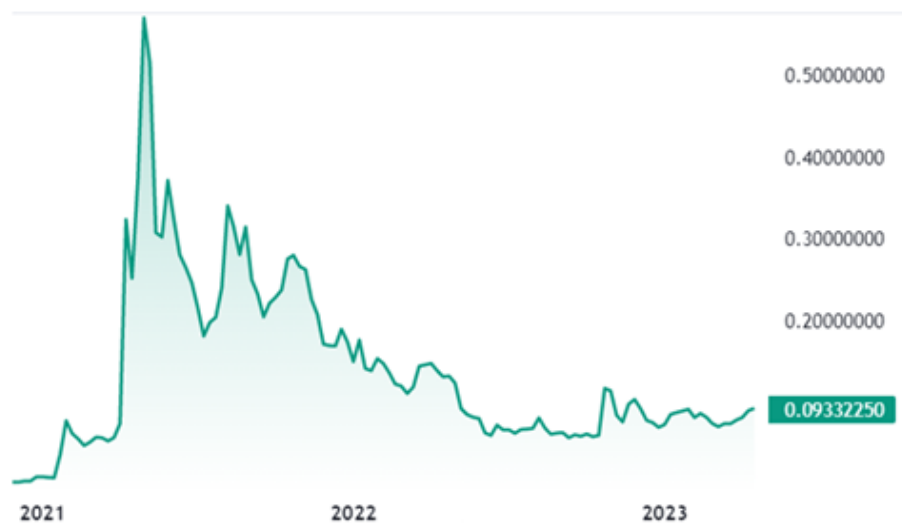


Рис. 1.7. Ринкова капіталізація Dogecoin в дол. США за 2021-2023 рр.

Джерело: [42]

З моменту запуску Dogecoin було створено понад 200 мемів. Але незважаючи на те, що концептуалізувати їх цікаво, меми-монети можуть падати так само швидко, як і рости. Сьогодні DOGE коштує лише десяту частину свого історичного максимуму трохи більше року тому. Але це важливий урок для всіх інвесторів у криптовалюту, про який слід пам'ятати.

Хоча криптоактиви є важливою технологічною, фінансовою, економічною та комп'ютерною інновацією, інвестування в них слід вважати ризикованим. Інвестори повинні інвестувати лише той капітал, який вони готові втратити, і лише в регульовані організації.

Криптовалюти відомі своєю волатильністю, і крипторинки не є винятком. Ціни на криптовалюти можуть суттєво коливатися протягом короткого періоду часу, і широкий спектр факторів, таких як економічні умови, державні

постанови, висвітлення в засобах масової інформації тощо, може спричиняти цю нестабільність.

Економічні умови: такі економічні умови, як інфляція, відсоткові ставки та безробіття, можуть вплинути на крипторинок. Наприклад, якщо інфляція висока, люди, швидше за все, інвестуватимуть у криптовалюти, щоб захиститися від інфляції.

Державне регулювання: державне регулювання може суттєво вплинути на крипторинок. Наприклад, якщо уряд запровадить суворі правила щодо використання криптовалют, це може перешкодити людям використовувати їх і спричинити занепад ринку.

Занепокоєння безпекою: лише 2022 рік припадає на понад 3 мільярди доларів збитків через кілька криптозломів і шахрайства, які завалили крипторинок. Пізніше знакова подія краху FTX – провідної централізованої криптовалютної біржі, третьою за величиною у світі в липні 2021 року, яка спеціалізувалася на деривативах і продуктах із кредитним плечем – стала останнім цвяхом у труну [37]. Це призвело до кровотечі крипторинку протягом тривалого періоду. Уразливість смарт-контракту використовує одну з головних проблем для криптоінвесторів. Тому розробникам проектів стає важливо перевіряти свої смарт-контракти надійною криптоаудиторською компанією, щоб зменшити помилки кодування та підвищити довіру користувачів.

Ажіотаж і страх: крипторинок досить мінливий. Це пов'язано з двома основними рушійними факторами: ажіотажем і страхом. Розквіт крипторинку, що створює позитивні настрої, штовхає інвесторів купувати навіть за високими цінами в надії, що ринок піде вгору. Насправді, інвестори, які використовують криптовалюту, скупчуються на ринок, незважаючи на фундаментальні показники криптовалюти. Навпаки вірно у випадку кровоточивого крипторинку, коли страх викликає масовий розпродаж, що спричиняє більш високе падіння ціни.

Процентна ставка федерального банку: вища процентна ставка обернено пропорційна апетиту до високоризикових активів, таких як криптовалюта.

Теоретично це означає зниження кількості криптоінвесторів. 2022 рік був таким же, і можна легко спостерігати ведмежий крипториннок протягом тривалого часу. Однак на це вплинули й інші фактори.

Технологічний розвиток: технологічний розвиток, наприклад удосконалення технології блокчейн або розробка нових криптовалют, може вплинути на крипториннок. Наприклад, припустимо, що розроблено нову криптовалюту зі значними перевагами над існуючими. У такому випадку це може змусити людей перевести свої інвестиції в нову криптовалюту, що призведе до змін на ринку.

Висвітлення в ЗМІ: висвітлення крипторинку в ЗМІ також може суттєво вплинути на настрої ринку. Наприклад, якщо ЗМІ повідомляють позитивні новини про ринок, це може спонукати більше людей інвестувати в криптовалюту та спричинити зростання ринку.

Перейдемо до розгляду динаміки найбільших за капіталізацією криптовалют.

1. Bitcoin — це децентралізована цифрова валюта, створена в 2009 році невідомою особою або групою під псевдонімом «Сатоші Накамото». Валюта заснована на одноранговій мережі, яка дозволяє користувачам відправляти та отримувати транзакції без необхідності центрального органу чи посередника.

Історія Bitcoin починається з публікації технічного документу в 2008 році, в якому детально описується концепція децентралізованої цифрової валюти, яку можна використовувати для однорангових транзакцій. Перша транзакція відбулася 12 січня 2009 року, коли Сатоші Накамото надіслав 10 біткойнів Хелу Фінні, комп'ютерному програмісту та одному з перших, хто прийняв цю валюту.

З роками Bitcoin набув популярності серед перших користувачів і ентузіастів технологій, які бачили потенціал для валюти, яка могла б працювати незалежно від урядів і центральних банків. Вартість валюти також почала зростати, її ціна піднялася від кількох центів до кількох доларів у перші роки її існування.

У 2013 році Bitcoin привернув увагу, коли ціна одного біткойна вперше перевищила 1000 доларів. Це призвело до сплеску інтересу та інвестицій у валюту, і все більше людей і компаній почали приймати Bitcoin як законну форму оплати [35].

Незважаючи на зростаючу популярність, протягом багатьох років Bitcoin також стикався з неабиякою часткою викликів і суперечок. Валюта була пов'язана з незаконною діяльністю, такою як торгівля наркотиками та відмивання грошей, через її анонімність і децентралізований характер. Крім того, Bitcoin зазнав кількох гучних хакерів і порушень безпеки, що призвело до втрати мільйонів доларів.

Незважаючи на ці проблеми, Bitcoin залишається однією з найвідоміших і найпоширеніших криптовалют у світі. Його успіх також призвів до створення багатьох інших криптовалют і проектів на основі блокчейну, багато з яких спрямовані на вирішення деяких проблем і обмежень Bitcoin.

2. Ethereum — це децентралізована блокчейн-платформа, створена Віталіком Бутеріним у 2013 році. Рідною криптовалютою платформи є ефір (ETH), який використовується для оплати комісій за транзакції та обчислювальних послуг у мережі Ethereum.

Історія Ethereum починається з ідеї створення блокчейн-платформи, яка дозволить розробникам створювати децентралізовані програми (dapps) і смарт-контракти. Бутерін, якому на той час було лише 19 років, запропонував цю ідею в офіційному документі, опублікованому наприкінці 2013 року. У документі було викладено бачення блокчейну, який міг би виконувати складні сценарії та програми, що виходять за межі можливостей блокчейну біткойна.

У 2014 році Бутерін і команда розробників запустили мережу Ethereum. Запуск супроводжувався первинною пропозицією монет (ICO), яка лише за кілька тижнів зібрала біткойн на суму понад 18 мільйонів доларів. Це ICO стало одним із перших великих прикладів використання криптовалюти для фінансування проекту блокчейн.

Мережа Ethereum швидко набула популярності серед розробників завдяки своїй здатності виконувати смарт-контракти та підтримувати децентралізовані програми. Смарт-контракти — це самовиконувані програми, які можна запрограмувати на автоматичний запуск певних дій, коли виконуються певні умови. Це дає змогу створювати децентралізовані програми, які можуть працювати незалежно від посередників, таких як банки чи онлайн-ринки [20].

Популярність Ethereum призвела до створення багатьох інших криптовалют і проектів на основі блокчейну, багато з яких побудовані на платформі Ethereum. У 2017 році ціна ефіру підскочила до історичного максимуму понад 1400 доларів США завдяки зростанню попиту на децентралізовані додатки та збільшенню первинних пропозицій монет (ICO).

Сьогодні Ethereum залишається однією з найбільш широко використовуваних і шанованих блокчейн-платформ у світі, з великою та активною спільнотою розробників, яка працює над новими та інноваційними проектами. Платформа також перебуває в процесі переходу на новий механізм консенсусу, відомий як Ethereum 2.0, який обіцяє покращити масштабованість, безпеку та ефективність мережі.

3. Tether — це криптовалюта, яка призначена для підтримки стабільної вартості шляхом прив'язки до курсу долара США. Криптовалюта була запущена в 2014 році компанією під назвою Tether Limited, яка базується в Гонконгу.

Історія Tether починається з ідеї створення криптовалюти, яка могла б забезпечити переваги криптовалют, такі як швидкі та дешеві транзакції, зберігаючи при цьому стабільну вартість. Щоб досягти цього, Tether Limited створила цифровий токен, який забезпечено еквівалентною сумою доларів США, які зберігаються компанією в резерві.

Спочатку Tether був створений як спосіб для користувачів конвертувати свої криптовалюти, такі як біткойн, у стабільну та широко прийнятну валюту, таку як долар США. Однак з часом Tether також став популярною криптовалютою для трейдерів та інвесторів, які використовують її як засіб

переміщення коштів між криптовалютами біржами без необхідності конвертувати їх у фіатну валюту.

Незважаючи на свою популярність, протягом багатьох років Tether також стикався з численними суперечками та проблемами. Одним із найбільш значних суперечок було твердження про те, що Tether Limited не має достатніх резервів, щоб підтримати токени в обігу. У 2018 році Генеральна прокуратура Нью-Йорка почала розслідування щодо Tether Limited та її дочірньої компанії Bitfinex, яка є біржею криптовалют, тісно пов'язаною з Tether.

Розслідування стверджувало, що Tether Limited використовувала свої резерви, щоб прикрити великі та нерозголошені збитки Bitfinex. Хоча Tether Limited заперечує звинувачення, суперечка призвела до зниження довіри до Tether і тимчасового падіння вартості криптовалюти [40].

Незважаючи на ці проблеми, Tether залишається однією з найбільш широко використовуваних і популярних криптовалют у світі з ринковою капіталізацією понад 60 мільярдів доларів США станом на квітень 2023 року. Стабільна вартість і широке визнання валюти роблять її привабливою для користувачів, які шукають надійний і зручний засіб здійснення транзакцій у криптовалютному просторі.

1.3. Огляд методологічних підходів та математичного інструментарію прогнозування короткострокової динаміки фіатних валют та криптоактивів

Прогнозування короткострокової динаміки фіатних валют і криптоактивів є складним завданням через їх високу волатильність і наявність багатьох факторів, які впливають на їх вартість. Для прогнозування можна використовувати кілька методичних підходів і математичних інструментів, які можна побачити на рис. 1.8.

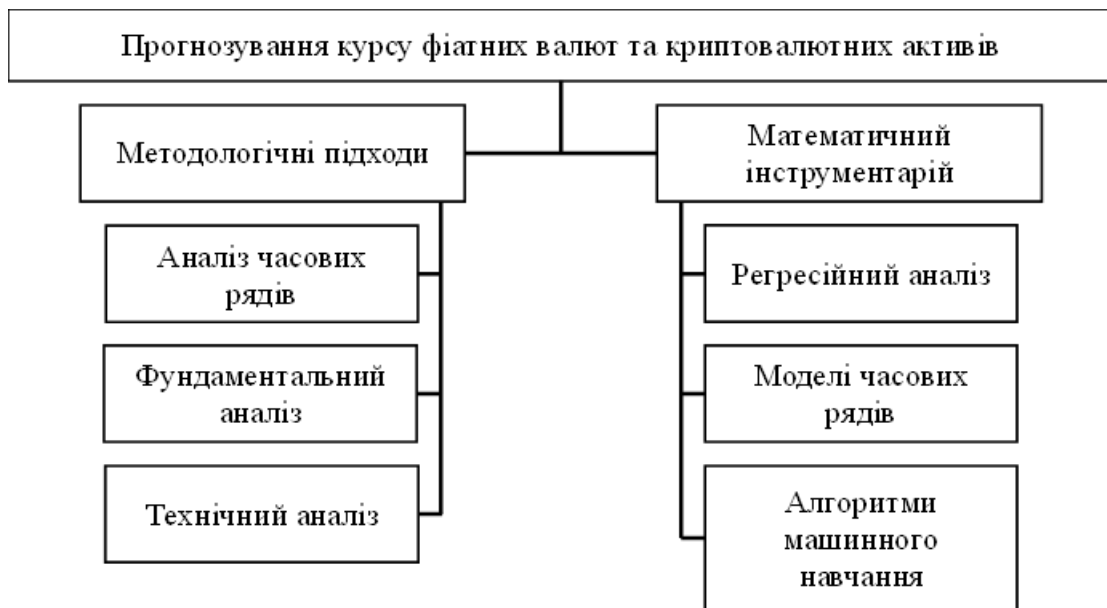


Рис. 1.8. Методологічні підходи та математичний інструментарій для прогнозування курсу фіатних валют та криптоактивів

Джерело: складено автором на основі [17, 26, 49].

Аналіз часових рядів – це статистичний метод, який використовується для аналізу минулих даних для виявлення закономірностей і тенденцій, які можна використовувати для прогнозування майбутнього. У контексті прогнозування короткострокової динаміки фіатних валют і криптоактивів аналіз часових рядів передбачає аналіз минулих даних про ціни та обсяги для виявлення моделей і тенденцій, які можуть допомогти передбачити майбутні рухи.

Для аналізу часових рядів використовується кілька методів, зокрема:

1. Ковзні середні: ця техніка передбачає обчислення середньої ціни або обсягу активу за певний період часу. Ковзні середні можуть допомогти визначити тенденції та потенційні рівні підтримки та опору.
2. Експоненціальне згладжування: цей метод використовується для створення короткострокових прогнозів, надаючи більшої ваги останнім спостереженням і меншої ваги старішим спостереженням. Експоненціальне згладжування можна використовувати для визначення тенденцій і потенційних точок повороту в ціні активу.

3. Авторегресія: ця техніка передбачає використання минулих значень змінної для прогнозування майбутніх значень. Авторегресія може бути використана для визначення тенденцій і потенційних поворотних моментів у ціні активу.

У дослідженні Аль-Ях'яї та Менсі (2021) використовувалося ковзне середнє та техніка експоненціального згладжування для прогнозування короткострокової динаміки обмінного курсу долара США до ріалу Саудівської Аравії. Дослідження показало, що обидва методи забезпечують точні прогнози, причому експоненціальне згладжування є трохи точнішим [1].

Ще в одному дослідженні Е.Бурі та ін. (2020) використовували модель авторегресійної інтегрованої ковзної середньої (ARIMA) для прогнозування короткострокової динаміки біткойна. Дослідження показало, що модель ARIMA була ефективною для прогнозування руху цін на біткойни до 30 днів наперед [6].

Фундаментальний аналіз – це підхід, який використовується для аналізу основних економічних і фінансових факторів, які впливають на вартість валюти або криптовалюти. У контексті прогнозування короткострокової динаміки фіатних валют і криптоактивів фундаментальний аналіз передбачає аналіз економічних даних, ринкових новин та інших факторів для прогнозування майбутніх коливань цін.

Є кілька ключових факторів, які зазвичай аналізуються у фундаментальному аналізі, зокрема:

1. Процентні ставки: Зміни процентних ставок можуть мати значний вплив на вартість валют і криптоактивів. Коли процентні ставки зростають, вартість валюти може зрости, а вартість криптоактиву може зменшитися.
2. Темпи інфляції: високий рівень інфляції може знизити вартість валюти, тоді як дефляція може збільшити вартість валюти. Для криптоактивів інфляція не є суттєвим фактором, але важливо враховувати динаміку попиту та пропозиції, що впливає на ціну.
3. Політична стабільність: політична нестабільність, наприклад громадянські заворушення або зміни в уряді, може вплинути на вартість валюти або

криптовалюти. Стабільні політичні умови можуть допомогти підтримати вартість валюти чи криптоактиву.

4. Ринкові настрої: ринкові настрої стосуються загального настрою або ставлення інвесторів до певної валюти чи криптоактиву. Позитивні настрої можуть підвищити вартість активу, а негативні — спричинити її зниження.

У дослідженні Цзяо та Чжана (2020) використовувався підхід фундаментального аналізу для прогнозування короткострокової динаміки обмінного курсу долара США до китайського юаня. Дослідження показало, що процентні ставки, темпи інфляції та ринкові настрої були важливими факторами для прогнозування майбутніх коливань цін [24].

В своєму дослідженні В.Лю та ін. (2021) використали підхід фундаментального аналізу для прогнозування короткострокової динаміки біткойна. Дослідження показало, що зміни процентних ставок, темпів інфляції та глобальних економічних умов є важливими факторами для прогнозування майбутніх коливань цін [31].

Технічний аналіз — це метод, який використовується для аналізу минулих ринкових даних, таких як ціна та обсяг, для виявлення закономірностей і тенденцій, які можна використовувати для прогнозування майбутніх рухів цін. У контексті прогнозування короткострокової динаміки фіатних валют і криптоактивів технічний аналіз передбачає аналіз графіків та інших технічних індикаторів для визначення потенційних рівнів підтримки та опору, ліній тренду та інших моделей.

Існує кілька ключових технічних індикаторів, які зазвичай використовуються в технічному аналізі, зокрема:

1. Ковзні середні: Ковзні середні використовуються для визначення тенденцій у ціні активу шляхом згладжування короткострокових коливань. Різні періоди часу, наприклад 50-денні або 200-денні ковзні середні, можна використовувати для визначення короткострокових і довгострокових тенденцій.

2. Індекс відносної сили (RSI): RSI – це індикатор моментуму, який вимірює силу руху ціни активу. Його можна використовувати для виявлення умов перекупленості або перепроданості, що може допомогти передбачити потенційні розвороти ціни.
3. Смуги Боллінджера: смуги Боллінджера – це смуги, розташовані вище та нижче ковзного середнього активу. Їх можна використовувати для визначення потенційних рівнів підтримки та опору, а також потенційних проривів або розворотів трендів.
4. Корекція Фібоначчі: корекція Фібоначчі – це техніка, яка використовує горизонтальні лінії для позначення областей потенційної підтримки або опору на основі ключових рівнів, визначених послідовністю Фібоначчі.

У дослідженні З.Зейбека та Л.Гюндюза (2021) використовувався підхід технічного аналізу для прогнозування короткострокової динаміки обмінного курсу EUR/USD. Дослідження показало, що ковзні середні, RSI та смуги Боллінджера були корисними для прогнозування майбутніх рухів цін [45].

В іншому дослідженні Д.Кутмос та П.Каціампа (2018) використовували технічний аналіз для прогнозування короткострокової динаміки біткойна. Дослідження показало, що ковзні середні, смуги Боллінджера та корекція Фібоначчі були корисними для прогнозування майбутніх рухів цін [27].

Регресійний аналіз — це статистичний метод, який використовується для визначення та кількісного визначення взаємозв'язків між однією або декількома незалежними змінними та залежною змінною. У контексті прогнозування короткострокової динаміки фіатних валют і криптоактивів регресійний аналіз передбачає аналіз історичних даних для виявлення факторів, які мають значний вплив на рух цін на актив, і використання цих факторів для прогнозування майбутніх рухів цін.

Існує кілька типів регресійного аналізу, які можна використовувати для прогнозування, включаючи просту лінійну регресію, множинну регресію та регресію часових рядів.

Проста лінійна регресія передбачає визначення лінійного зв'язку між двома змінними, такими як ціна активу, та макроекономічним фактором, таким як інфляція чи процентні ставки. Множинна регресія передбачає визначення зв'язків між ціною активу та кількома незалежними змінними, такими як ВВП, процентні ставки та інфляція. Регресія часових рядів передбачає аналіз зв'язків між ціною активу та його власними минулими цінами.

У дослідженні Дж.Чен та ін. (2019) використали множинний регресійний аналіз для прогнозування короткострокової динаміки обмінного курсу китайського юаня (CNY). Дослідження показало, що такі змінні, як індекс долара США, зведений індекс Шанхайської фондової біржі та індекс споживчих цін у Китаї, є важливими провісниками обмінного курсу юаня [10].

Ще в одному дослідженні Ю.Чена та Ю.Лу (2021) використовували регресійний аналіз часових рядів для прогнозування короткострокової динаміки біткойна. Дослідження показало, що минулі ціни на біткойн, хеш-рейт мережі біткойн і обсяг торгів були важливими факторами прогнозування майбутніх цін на біткойн [11].

Моделі часових рядів — це статистичні моделі, які використовують історичні дані для прогнозування майбутніх значень змінної з часом. У контексті прогнозування короткострокової динаміки фіатних валют і криптоактивів моделі часових рядів передбачають аналіз історичних даних про ціни та обсяги, щоб визначити тенденції, сезонність та інші закономірності, які можна використовувати для прогнозування майбутніх коливань цін.

Існує кілька типів моделей часових рядів, які можна використовувати для прогнозування, зокрема:

1. Моделі авторегресійної інтегрованої ковзної середньої (ARIMA): моделі ARIMA використовуються для моделювання залежності між спостереженням і кількістю спостережень із запізненням. Їх можна використовувати для фіксації тенденцій, сезонності та інших закономірностей у даних часових рядів.

2. Моделі векторної авторегресії (VAR): моделі VAR використовуються для моделювання зв'язку між кількома змінними часових рядів. Їх можна використовувати для фіксації взаємодії між різними економічними та ринковими факторами, які впливають на ціни активів.
3. Рекурентні нейронні мережі (RNN): RNN — це тип моделі глибокого навчання, розроблений для охоплення часових залежностей у послідовних даних. Їх можна використовувати для фіксації складних моделей і зв'язків у даних часових рядів.

У дослідженні Е.Бурі та ін. (2020) використовували моделі ARIMA для прогнозування короткострокової динаміки біткойна. Дослідження показало, що моделі ARIMA були ефективними у відловленні тенденцій і сезонності цін на біткойн і могли робити точні короткострокові прогнози [5].

В своєму дослідженні Ю.Чжанг та ін. (2021) використовували моделі VAR для прогнозування короткострокової динаміки обмінного курсу китайського юаня (CNY). Дослідження показало, що моделі VAR, які включали такі змінні, як індекс долара США, композитний індекс Шанхайської фондової біржі та індекс споживчих цін у Китаї, змогли зробити точні короткострокові прогнози обмінного курсу CNY [23].

Алгоритми машинного навчання є потужним інструментом для прогнозування короткострокової динаміки фіатних валют і криптоактивів. Ці алгоритми можуть аналізувати великі обсяги історичних даних, визначати закономірності та тенденції та робити прогнози на основі цих закономірностей. Деякі алгоритми машинного навчання, які зазвичай використовуються для прогнозування, включають:

1. Випадковий ліс (RF): популярний алгоритм для задач регресії та класифікації, RF – це тип ансамблевого навчання, який поєднує кілька дерев рішень для прогнозування. Його можна використовувати для фіксації нелінійних зв'язків між змінними та обробки відсутніх даних.
2. Бустінг (Gradient Boosting): ще один популярний алгоритм ансамблевого навчання, бустінг, ітеративно додає дерева рішень, щоб мінімізувати помилки

та покращити прогнози. Його можна використовувати для фіксації складних взаємодій між змінними та обробки нелінійних зв'язків.

3. Метод опорних векторів (SVM): SVM — це тип алгоритму контрольованого навчання, який можна використовувати для завдань регресії та класифікації. Вони працюють, знаходячи гіперплощину, яка найкраще розділяє точки даних, і їх можна використовувати для фіксації складних зв'язків між змінними.
4. Довга короткочасна пам'ять (LSTM): тип рекурентної нейронної мережі (RNN), LSTM призначені для обробки послідовних даних і можуть фіксувати тимчасові залежності в даних часових рядів. Їх можна використовувати для фіксації складних моделей і взаємозв'язків у фіатних валютах і даних про ціни на криптовалюту.

У дослідженні Х.Лі та ін. (2019) використовували бустінг та SVM для прогнозування короткострокової динаміки біткойна. Дослідження показало, що обидва алгоритми були ефективними для фіксації складних взаємозв'язків між змінними та могли робити точні короткострокові прогнози [30].

У дослідженні В.Ченг, Дж.Гуо та З.Чжан (2020) використовували LSTM для прогнозування короткострокової динаміки Ethereum. Дослідження показало, що LSTM зміг охопити складні часові залежності в даних про ціни Ethereum і зробити точні короткострокові прогнози [12].

РОЗДІЛ 2. РОЗРОБКА МАТЕМАТИЧНОЇ МОДЕЛІ ПРОГНОЗУВАННЯ ДИНАМІКИ ВАЛЮТНИХ РИНКІВ

2.1. Формування вимог до моделі. Опис вхідних змінних

Криптовалюти та фіатні валюти є як цифровими, так і фізичними активами, які стали популярним вибором для інвесторів завдяки їх потенціалу високої прибутковості. Однак мінлива природа криптовалют та економічна невизначеність фіатних валют ускладнюють їх прогнозування. Тому інвестори часто звертаються до моделей машинного навчання, щоб спрогнозувати рух цін на ці валюти.

Для побудови моделі на основі якої будемо робити короткострокове прогнозування необхідно описати вимоги до моделі та вхідні змінні, що будуть використовуватися для її побудови.

Модель повинна відповідати наступним вимогам:

- Точність. Основною вимогою до будь-якої моделі прогнозування є точність. Модель повинна робити надійні прогнози на основі нових даних, щоб бути корисною для прийняття рішень. Точність моделі залежить від кількох факторів, таких як якість і кількість навчальних даних, архітектура моделі, використаний алгоритм оптимізації та вибрані гіперпараметри. Модель з високою точністю може допомогти інвесторам приймати зважені рішення та уникнути потенційних втрат.
- Узагальненість. Модель прогнозування повинна добре узагальнювати нові та ще невідомі дані. Це означає, що модель не повинна перевищувати або недоповнювати навчальні дані, але вона повинна мати можливість охопити базові закономірності та тенденції в даних. Переобладнання відбувається, коли модель добре працює з навчальними даними, але погано з новими даними, тоді як недообладнання відбувається, коли модель не в змозі охопити базові закономірності в даних. Узагальнення має вирішальне значення для

того, щоб модель робила точні прогнози на основі нових даних і була корисною для прийняття рішень.

- Аналіз часових рядів. Ціни як на криптоактиви, так і на фіатні валюти залежать від часу, і модель прогнозування повинна мати можливість обробляти дані часових рядів і фіксувати часові залежності та кореляції між різними змінними. Аналіз часових рядів є важливою вимогою для ефективності моделі прогнозування.
- Вибір функцій. Модель прогнозування має вибирати найбільш релевантні характеристики, які мають значний вплив на рух цін як на криптоактиви, так і на фіатні валюти. Це важливо, щоб уникнути переобладнання та підвищити точність моделі. Відповідні характеристики можуть включати настрої ринку, обсяг торгів, новинні статті, настрої в соціальних мережах та економічні показники. Вибір функцій має вирішальне значення для того, щоб модель могла робити точні прогнози та бути корисною для прийняття рішень.
- Можливість інтерпретації. Модель прогнозування має бути доступною для інтерпретації та давати розуміння основних факторів, які обумовлюють рух цін як на криптоактиви, так і на фіатні валюти. Це важливо, щоб завоювати довіру до моделі та приймати обґрунтовані рішення на основі її прогнозів. Можливість інтерпретації також може допомогти визначити фактори, які мають найбільш суттєвий вплив на ціни валюти та керувати інвестиційними рішеннями.
- Надійність. Модель прогнозування має бути стійкою до шуму, викидів і відсутніх даних. Це означає, що модель повинна мати можливість обробляти варіації в даних і робити точні прогнози. Валютні ринки дуже нестабільні, і надійна модель може допомогти мінімізувати ризик потенційних втрат.
- Прогнозування в режимі реального часу. Ціни на валюту швидко змінюються, і модель прогнозування повинна мати можливість робити прогнози в режимі реального часу, щоб охопити характер ринку, що швидко змінюється. Прогнозування в режимі реального часу має важливе значення для інвесторів, щоб своєчасно приймати рішення та використовувати потенційні можливості.

- Інтеграція з ринковими даними. Модель прогнозування повинна мати можливість інтегруватися із зовнішніми джерелами ринкових даних, щоб охопити вплив зовнішніх факторів, таких як новини, настрої в соціальних мережах та економічні показники на валютному ринку. Інтеграція з джерелами ринкових даних може допомогти підвищити точність моделі та зробити її кориснішою для прийняття рішень[22].

Вхідними змінними моделі є щоденні коритування криптоактивів та фіатних валют.

Вихідними змінними є прогнозовані курси обраних криптоактивів та фіатних валют.

Вибір відповідних курсів валют для моделювання та прогнозування має вирішальне значення для забезпечення точності та доречності аналізу. При виборі валютних пар необхідно враховувати такі фактори:

- Ліквідність ринку: висока ліквідність у валютній парі гарантує, що ринок може поглинати великі операції з мінімальним впливом на обмінний курс, що робить ринок менш сприйнятливим до маніпуляцій і більш надійним для аналізу. Вибрані валютні пари BTC/USD, ETH/USD, USDT/USD, EUR/USD, USD/JPY та GBP/USD є одними з найбільш ліквідних пар як на криптовалютному, так і на валютному ринках.
- Обсяг торгів: валютні пари з високим обсягом торгів більше підходять для цілей моделювання та прогнозування, оскільки вони менш схильні до нестабільних коливань цін і надають більше точок даних для аналізу. Вибрані валютні пари представляють одні з найактивніших пар на фінансових ринках, надаючи достатньо даних для навчання та оцінки моделей прогнозування.
- Економічне значення: вибрані валютні пари представляють основні світові економіки, включаючи Сполучені Штати, єврозону, Японію та Сполучене Королівство. Їхні обмінні курси значно впливають на міжнародну торгівлю, інвестиції та стабільність фінансового ринку. Крім того, Bitcoin та Ethereum є двома найбільшими криптовалютами за ринковою капіталізацією, що робить

їх обмінні курси важливими індикаторами загального здоров'я ринку криптовалют.

- **Різноманітні класи активів:** використовуючи в аналізі як криптовалюти, так і фіатні валюти, моделі можуть фіксувати динаміку та взаємодію між різними типами активів. Це дозволяє отримати більш повне розуміння факторів, що впливають на курси валюти та криптовалюти, і може дати цінну інформацію про кореляції та потенційні переваги диверсифікації між цими класами активів.
- **Волатильність:** волатильність є важливим фактором, який слід враховувати при виборі валютних пар, оскільки вона може вплинути на ефективність моделей прогнозування. Висока волатильність може надати більше можливостей для отримання прибутку, але також створює більші ризики. Вибрані валютні пари демонструють різний ступінь волатильності, що дозволяє моделям вчитися та адаптуватися до різних ринкових умов[42].

Для побудови моделі та виводу результату було обрано наступні криптовалюти: BTC/USD, ETH/USD, USDT/USD. Цей вибір пояснюється тим, що Bitcoin, Ethereum та Tether є найбільшими криптовалютами за капіталізацією, що розглядалося у розділі 1. Нижче можна побачити щоденну динаміку курсів цих криптоактивів за 2022-2023 роки у дол. США.




Рис. 2.1. Динаміка курсу Bitcoin за 2022-2023 рр. у дол. США

Джерело: побудовано автором на основі [44].




Рис. 2.2. Динаміка курсу Ethereum за 2022-2023 рр. у дол. США

Джерело: побудовано автором на основі [44].




Рис. 2.3. Динаміка курсу Tether за 2022-2023 рр. у дол. США

Джерело: побудовано автором на основі [44].

Серед фіатних валют було обрано наступні пари: EUR/USD, USD/JPY та GBP/USD. Такий вибір також пояснюється тим, що ці валютні пари є найліквіднішими, а сумарний обсяг угод на Форекс сягає близько 52%. Нижче наведено графіки динаміки курсу за цими валютами.




Рис. 2.4. Динаміка курсу євро за 2022-2023 рр. у дол. США

Джерело: побудовано автором на основі [44].




Рис. 2.5. Динаміка курсу долара США за 2022-2023 рр. у японській єні

Джерело: побудовано автором на основі [44].



Рис. 2.6. Динаміка курсу британського фунту за 2022-2023 рр. у дол. США
Джерело: побудовано автором на основі [44].

Підсумовуючи, курси валют для BTC/USD, ETH/USD, USDT/USD, EUR/USD, USD/JPY та GBP/USD були обрані на основі їх ринкової ліквідності, обсягу торгів, економічного значення, різноманітності класів активів, і волатильність. Враховуючи ці фактори, аналіз спрямований на отримання більш точних і надійних результатів прогнозування, які можна застосовувати на різних фінансових ринках.

2.2. Розробка методики проведення розрахунків

В останні роки методи глибокого навчання привернули значну увагу в галузі фінансового прогнозування, зокрема для прогнозування обмінних курсів. У цьому розділі представлено всебічне дослідження чотирьох різних архітектур нейронних мереж: довгострокової короткочасної пам'яті (LSTM), згорткової нейронної мережі (CNN), CNN у поєднанні з LSTM (CNN+LSTM) і CNN у поєднанні зі стробованим рекурентним модулем (CNN+GRU).

Модель довгострокової короткочасної пам'яті (LSTM), запроваджена Хохрейтером і Шмідхубером у 1997 році, є різновидом рекурентної нейронної мережі (RNN), призначеної для подолання обмежень традиційних RNN у

навчанні довгострокових залежностей. LSTM досягають цього шляхом включення механізму стробування, який контролює потік інформації в часі. Щоб описати модель LSTM з математичної точки зору, нам потрібно визначити її компоненти та пов'язані з ними рівняння[16].

Блок LSTM складається з кількох компонентів:

- Комірка пам'яті (c_t): Комірка пам'яті відповідає за збереження та підтримку внутрішнього стану блоку LSTM протягом тривалого часу.
- Вхідний шлюз (i_t): Вхідні ворота контролюють потік нової інформації в комірку пам'яті.
- Забутий шлюз (f_t): Забутий шлюз визначає ступінь, до якої комірка пам'яті зберігає свій попередній стан.
- Вихідний шлюз (o_t): вихідний шлюз контролює потік інформації від комірки пам'яті до решти мережі.
- Блок LSTM отримує три входи на кожному кроці часу t :
- Вхідний вектор (x_t): представляє вхідні дані на поточному кроці часу.
- Прихований стан (h_{t-1}): це вихід блоку LSTM на попередньому кроці часу.
- Стан комірки (c_{t-1}): це внутрішній стан комірки пам'яті на попередньому кроці часу.

Враховуючи ці вхідні дані, блок LSTM обчислює такі рівняння на кожному кроці часу:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \text{ де} \quad (2.1)$$

σ — сигмоїдна функція активації,

W_i — вагова матриця, пов'язана з вхідним шлюзом,

b_i — член зміщення.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f), \text{ де} \quad (2.2)$$

W_f — вагова матриця, пов'язана з забутим шлюзом,

b_f — член зміщення.

$$c'_t = \tanh(W_c[h_{t-1}, x_t] + b_c), \text{ де} \quad (2.3)$$

\tanh — гіперболічна дотична функція активації,

W_c — вагова матриця, пов'язана зі станом комірки,

b_c — член зміщення.

$$c_t = f_t \odot c_{t-1} + i_t \odot c'_t, \text{ де} \quad (2.4)$$

\odot — поелементне множення.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \text{ де} \quad (2.5)$$

W_o — вагова матриця, пов'язана з вихідним вентилям,

b_o — член зміщення.

$$h_t = o_t \odot \tanh(c_t) \quad (2.6)$$

Отриманий прихований стан (h_t) служить виходом блоку LSTM на поточному кроці часу та використовується як вхід для наступного кроку часу. Стан клітинки (c_t) також переноситься на наступний часовий крок. Вивчаючи відповідні ваги та зміщення в процесі навчання, блок LSTM може ефективно моделювати довгострокові залежності в даних часових рядів. Для наших даних архітектура LSTM містить один прихований шар із заданою кількістю нейронів, за яким слідує щільний вихідний шар для створення остаточного прогнозу.

Модель згорткової нейронної мережі (CNN), представлена ЛеКуном та ін. у 1998 році — це тип прямої нейронної мережі, призначений для обробки даних із просторовою структурою, таких як зображення чи часові ряди. CNN досягають цього, використовуючи шари згортки та об'єднання, які можуть вивчати та витягувати локальні особливості з вхідних даних. Щоб описати модель CNN з математичної точки зору, нам потрібно визначити її компоненти та пов'язані з ними рівняння [13].

Основним компонентом CNN є згортковий рівень, який застосовує набір фільтрів або ядер до вхідних даних, що призводить до створення карт функцій. Математично операцію згортки для даного фільтра (k) і входу (X) можна описати так:

$$Y_{i,j}^k = (X * K^k)_{i,j} = \sum_m \sum_n X_{i+m,j+n} K_{m,n}^k, \text{ де} \quad (2.7)$$

$*$ — операцію згортки,

$Y_{i,j}^k$ — вихідна карта ознак у позиції (i, j) для фільтра k ,

$K_{m,n}^k$ — коефіцієнти фільтра для фільтра k .

Кожен фільтр у згортковому шарі має пов'язаний елемент зміщення, а функція активації (наприклад, ReLU) застосовується поелементно до вихідних карт ознак.

Шари об'єднання використовуються для зменшення просторових розмірів карт об'єктів і контролю надлишкового облаштування. Двома поширеними типами операцій об'єднання є максимальне об'єднання та об'єднання середніх значень. Математично для заданої вхідної карти функцій (X) операцію об'єднання можна описати так:

$$\text{Максимальне об'єднання: } Y_{i,j} = \max_{i_s \leq a \leq i_{s+f}, j_s \leq b \leq j_{s+f}} X_{a,b} \quad (2.8)$$

$$\text{Середнє об'єднання: } Y_{i,j} = \left(\frac{1}{f * f}\right) \sum_{a=i_s}^{i_{s+f}-1} \sum_{b=j_s}^{j_{s+f}-1} X_{a,b}, \text{ де} \quad (2.9)$$

$Y_{i,j}$ — вихідний сигнал у позиції (i, j),

s — крок (розмір кроку) операції об'єднання,

f — розмір фільтра (ширина та висота) операції об'єднання.

Після серії згорткових шарів і шарів об'єднання остаточні карти функцій вирівнюються та пропускаються через один або кілька повністю пов'язаних шарів для отримання остаточного прогнозу. Вихід повністю підключеного шару можна розрахувати за допомогою:

$$Y = W * X + b, \text{ де} \quad (2.10)$$

Y — вихід,

W — вагова матриця,

X — вхід,

b — зміщення.

Функцію активації, таку як sigmoid або softmax, можна застосувати до виходу залежно від конкретного завдання.

Вивчаючи відповідні ваги, зміщення та коефіцієнти фільтрації в процесі навчання, модель CNN може ефективно фіксувати та витягувати просторові характеристики з вхідних даних, що робить її особливо придатною для завдань, пов'язаних із зображеннями, відео або даними часових рядів.

Модель CNN+LSTM поєднує в собі сильні сторони архітектур CNN і LSTM для створення гібридної моделі, яка може охоплювати як просторові, так і часові залежності в даних. Ця архітектура була успішно застосована для різних завдань прогнозування часових рядів[18].

Модель CNN+LSTM спочатку обробляє вхідні дані за допомогою згорткових шарів, а потім шарів об'єднання. Отримані карти функцій потім подаються в шари LSTM для фіксації часових залежностей. Нарешті, щільний вихідний шар використовується для створення остаточного прогнозу.

Gated Recurrent Unit (GRU), представлений Чо та ін. (2014), є іншим типом RNN, який може пом'якшити проблему зникнення градієнта. Він має простішу архітектуру порівняно з LSTM, але все ще зберігає можливість моделювати довгострокові залежності [34].

Модель CNN+GRU — це архітектура гібридної нейронної мережі, яка поєднує в собі переваги згорткових нейронних мереж (CNN) і мереж Gated Recurrent Unit (GRU). Ця гібридна модель розроблена для обробки даних як з просторовою, так і з часовою структурою, таких як часові ряди або відеодані. У цій архітектурі рівні CNN навчаються витягувати локальні просторові характеристики, тоді як рівні GRU фіксують тимчасові залежності в даних.

Щоб описати модель CNN+GRU з математичної точки зору, ми визначимо компоненти та пов'язані з ними рівняння, спираючись на математичні описи, надані для моделей CNN і GRU.

Вхідні дані спочатку проходять через один або кілька згорткових шарів (за якими слідує функції активації та необов'язкові шари об'єднання) для вилучення просторових характеристик. Математичний опис шарів згортки та об'єднання можна знайти в попередній відповіді про модель CNN.

Після останнього згорткового (і необов'язково об'єднаного) шару отримані карти об'єктів змінюються на послідовність векторів об'єктів. Цього можна досягти за допомогою операції сплющування з наступною зміною форми:

$$X_t = Flatten(FeatureMap_t), \text{ де} \quad (2.11)$$

X_t — вектор вхідних ознак на кроці часу t ,

FeatureMap_t — вихідна карта ознак на кроці часу t .

Змінена послідовність векторів ознак потім подається на один або кілька рівнів GRU для моделювання часових залежностей у даних. Підрозділ GRU схожий на підрозділ LSTM, але має простішу архітектуру. Він складається з двох воріт: шлюзу скидання (r_t) і шлюзу оновлення (z_t). Математичні рівняння для рівня GRU такі:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (2.12)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (2.13)$$

$$h'_t = \tanh(W_h[r_t \odot h_{t-1}, x_t] + b_h) \quad (2.14)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot h'_t, \text{ де} \quad (2.15)$$

σ — сигмоїдна функція активації,

\odot — поелементне множення,

W і b — відповідні вагові матриці та члени зміщення для шлюзу скидання, шлюзу оновлення та прихованого стану кандидата.

Після шарів GRU кінцевий прихований стан (h_t) передається через повністю зв'язаний (щільний) вихідний рівень для отримання остаточного прогнозу. Вихід можна розрахувати за допомогою:

$$Y = W * X + b, \text{ де} \quad (2.16)$$

Y — результат,

W — вагова матриця,

h_t — остаточний прихований стан рівнів GRU,

b — член зміщення.

Залежно від конкретного завдання до виходу може бути застосована функція активації, наприклад сигмоїдна, softmax або лінійна.

Вивчаючи відповідні ваги, зміщення та коефіцієнти фільтрації в процесі навчання, модель CNN+GRU може ефективно фіксувати як просторові характеристики, так і часові залежності у вхідних даних, що робить її придатною для завдань, пов'язаних із часовими рядами або відеоданими зі складною структурою.

РОЗДІЛ 3. ПРИКЛАДНА РЕАЛІЗАЦІЯ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ДИНАМІКИ ВАЛЮТНИХ РИНКІВ

3.1. Апробація класичних моделей машинного навчання для прогнозування валютних ринків

Для побудови моделей буде використовуватися середовище Google Colaboratory або скорочено Google Colab — це безкоштовна хмарна служба від Google, яка дозволяє користувачам запускати й ділитися Jupyter Notebooks в інтерактивному середовищі. Jupyter Notebooks — це популярний формат для створення та обміну живим кодом, рівняннями, візуалізаціями та описовим текстом, які особливо корисні для аналізу даних, машинного навчання та наукових досліджень.

Для прогнозування за допомогою класичних моделей було обрано випадковий ліс та AutoARIMA. Дослідження буде відбуватись на основі бібліотеки Python PyCaret [16, 18, 34, 49].

```
import pandas as pd
import numpy as np
from matplotlib import style
import matplotlib.pyplot as plt
import yfinance as yf
from google.colab import files
from pycaret.time_series import *

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')
```

Рис. 3.1. Імпорт бібліотек для побудови випадкового лісу та AutoARIMA

Джерело: розрахунки автора

PyCaret – це високорівнева бібліотека з відкритим вихідним кодом, яка автоматизує робочий процес машинного навчання. Вона призначена для того, щоб допомогти аналітикам даних швидко та ефективно створювати та розгортати наскрізні конвеєри машинного навчання, використовуючи простий та інтуїтивно зрозумілий синтаксис.

Random Forest – це ансамблевий метод навчання, який будує кілька дерев рішень і об'єднує їхні прогнози для отримання більш точного і стабільного результату. AutoARIMA – це модель прогнозування часових рядів, яка автоматично обирає найкращу конфігурацію ARIMA на основі заданих даних.

Наступним кроком є завантаження бази даних, а саме валютних котирувань для подальшого моделювання. При завантаженні курсів криптоактивів та фіатних валют є різниця, оскільки для криптовалют йде щоденне відстеження курсів, а для курсів фіатних валют такі спостереження відсутні у вихідні дні (субота, неділя).

Для криптовалют дані було завантажено за допомогою бібліотеки `yfinance` (рис. 3.2), тоді як для фіатних валют було котирування було вивантажено спочатку у файл Excel, а потім за допомогою бібліотеки `google.colab` завантажено у робоче середовище (рис. 3.3).

Всі кроки, починаючи з завантаження даних, крім поділу на навчальні та тестові множини та результатів, будуть пояснюватися на прикладі BTC/USD та EUR/USD, оскільки для інших котирувань вони були зроблені аналогічним чином. Повний код реалізації моделей можна побачити у додатку А.

```
stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()
```

Рис. 3.2. Імпортування даних для BTC/USD в середовище Google Colab

Джерело: розрахунки автора

```
uploaded = files.upload()

Выбрать файлы База_диплом.csv
• База_диплом.csv(text/csv) - 22113 bytes, last modified: 23.04.2023 - 100% done
Saving База_диплом.csv to База_диплом.csv

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1, inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr
```

Рис. 3.3. Імпортування даних для EUR/USD в середовище Google Colab

Джерело: розрахунки автора

Для моделей випадкового лісу та AutoARIMA налаштування даних буде наступним:

```
ts = setup(stock_data['Close'], fh = 68, fold_strategy = 'sliding')
ts = setup(df_curr['EURUSD'], fh = 51, fold_strategy = 'sliding')
```

Рис. 3.4. Налаштування даних для побудови моделей випадкового лісу та AutoARIMA для валют BTC/USD (зліва) EUR/USD (справа)

Джерело: розрахунки автора

Як видно з рис. 3.4 ми маємо різні показники для криптовалют та фіатних валют, а саме різну кількість періодів прогнозування. Оскільки ми маємо різну кількість початкових даних (у криптовалют – 454 спостереження, у фіатних валют – 338 спостережень), ці параметри обиралися у відношенні 85/15. Тобто у результаті матимемо прогноз на тестову вибірку.

Параметр `fold_strategy` визначає стратегію перехресної перевірки, яка використовується для оцінки моделі. При прогнозуванні часових рядів дуже важливо зберігати часовий порядок даних під час перехресної перевірки. Стратегія «ковзного» згортання робить це, створюючи рухоме вікно для навчальних і перевірочних наборів. Навчальний набір завжди передує валідаційному набору в часі, а вікно зсувається на один крок вперед при кожному згинанні. Такий підхід допомагає запобігти витоку даних і гарантує, що модель оцінюється в реалістичних умовах.

Наступним кроком є налаштування моделей. Для моделей випадкового лісу та AutoARIMA навчання проходитиме так:

```
rf = create_model('rf_cds_dt')
auto_arima = create_model('auto_arima')
```

Рис. 3.5. Навчання моделей випадкового лісу та AutoARIMA

Джерело: розрахунки автора

Останнім кроком реалізації моделей є візуалізація результатів. Для моделей випадкового лісу та AutoARIMA візуалізація буде реалізована наступним чином:

```
plot_model(rf)
plot_model(auto_arima)
```

Рис. 3.6. Візуалізація отриманих результатів для моделей випадкового лісу та AutoARIMA

Джерело: розрахунки автора

У результаті маємо такі графіки для моделей:

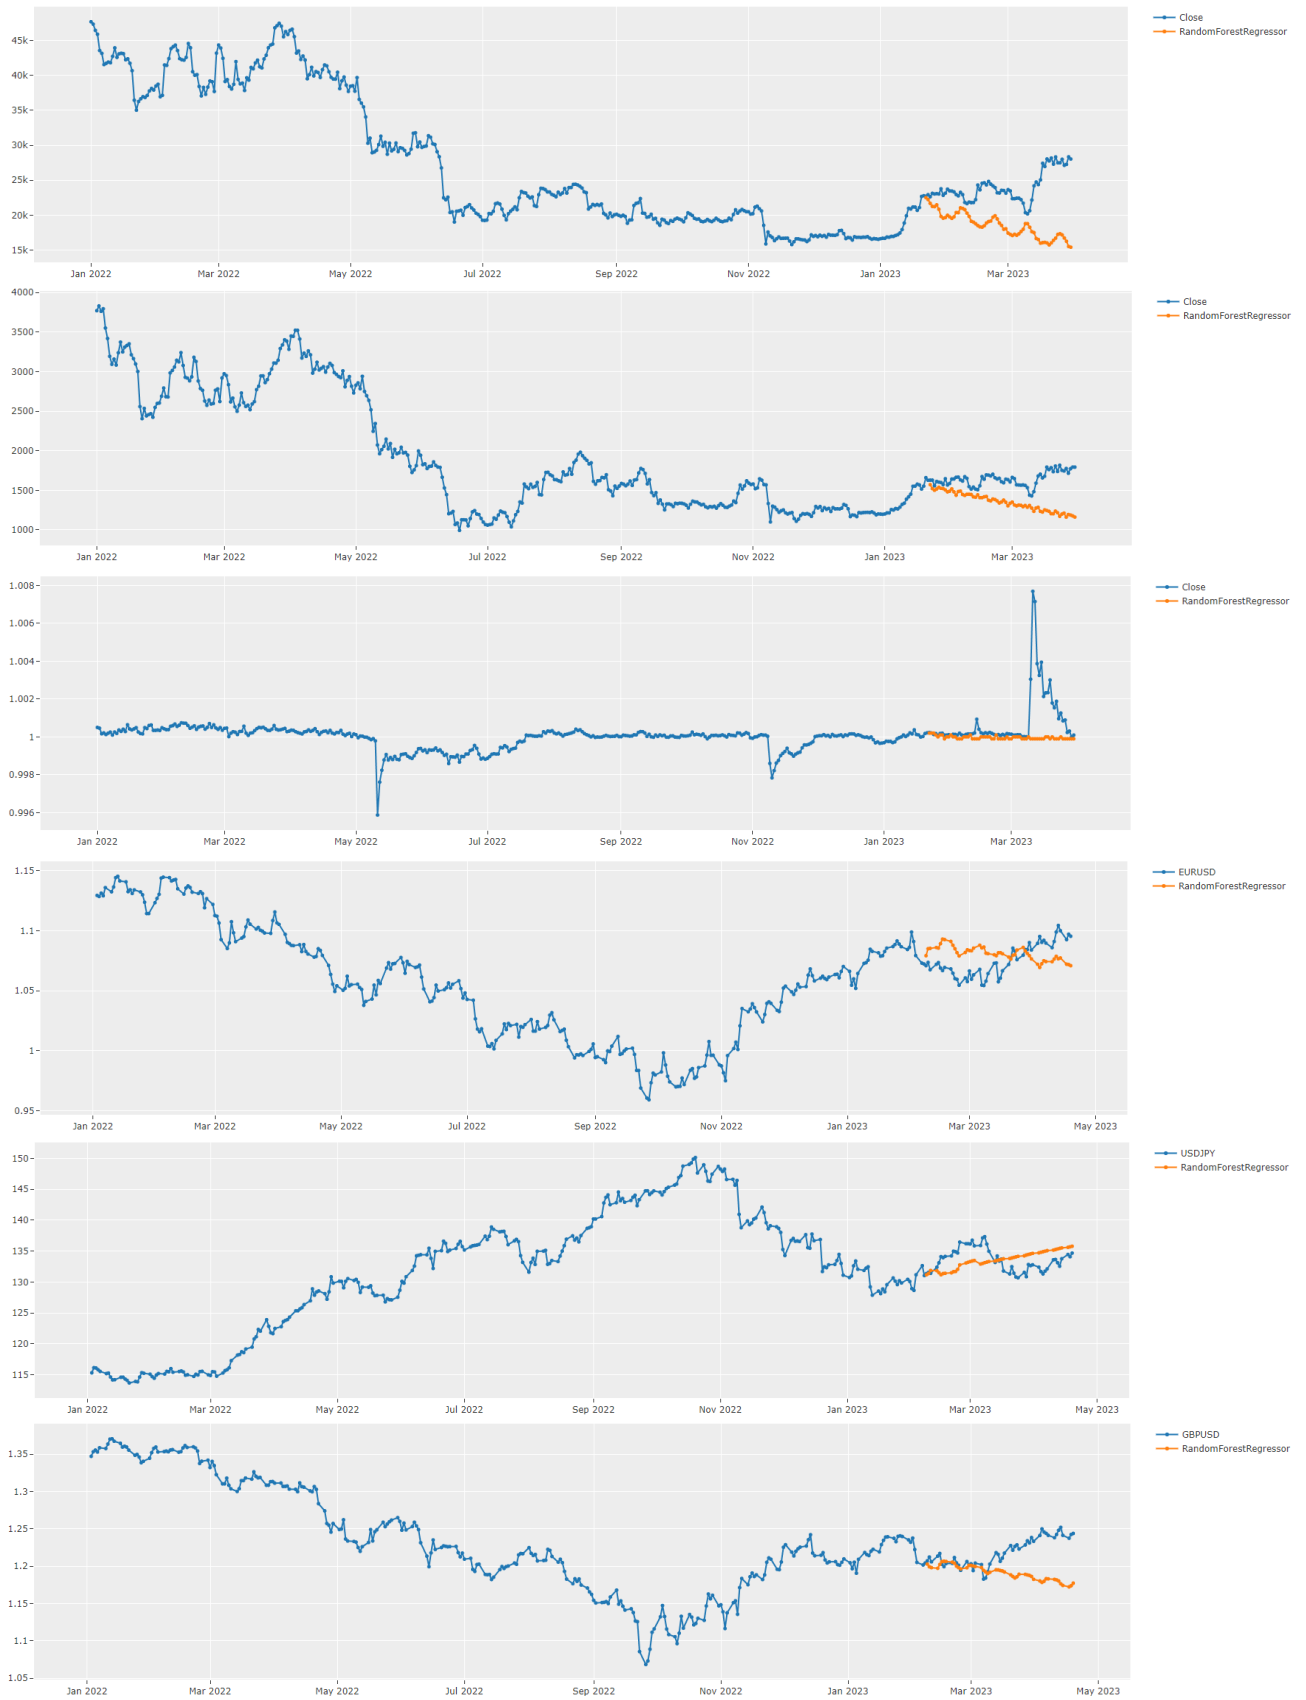


Рис. 3.7. Результати моделювання випадкового лісу для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора

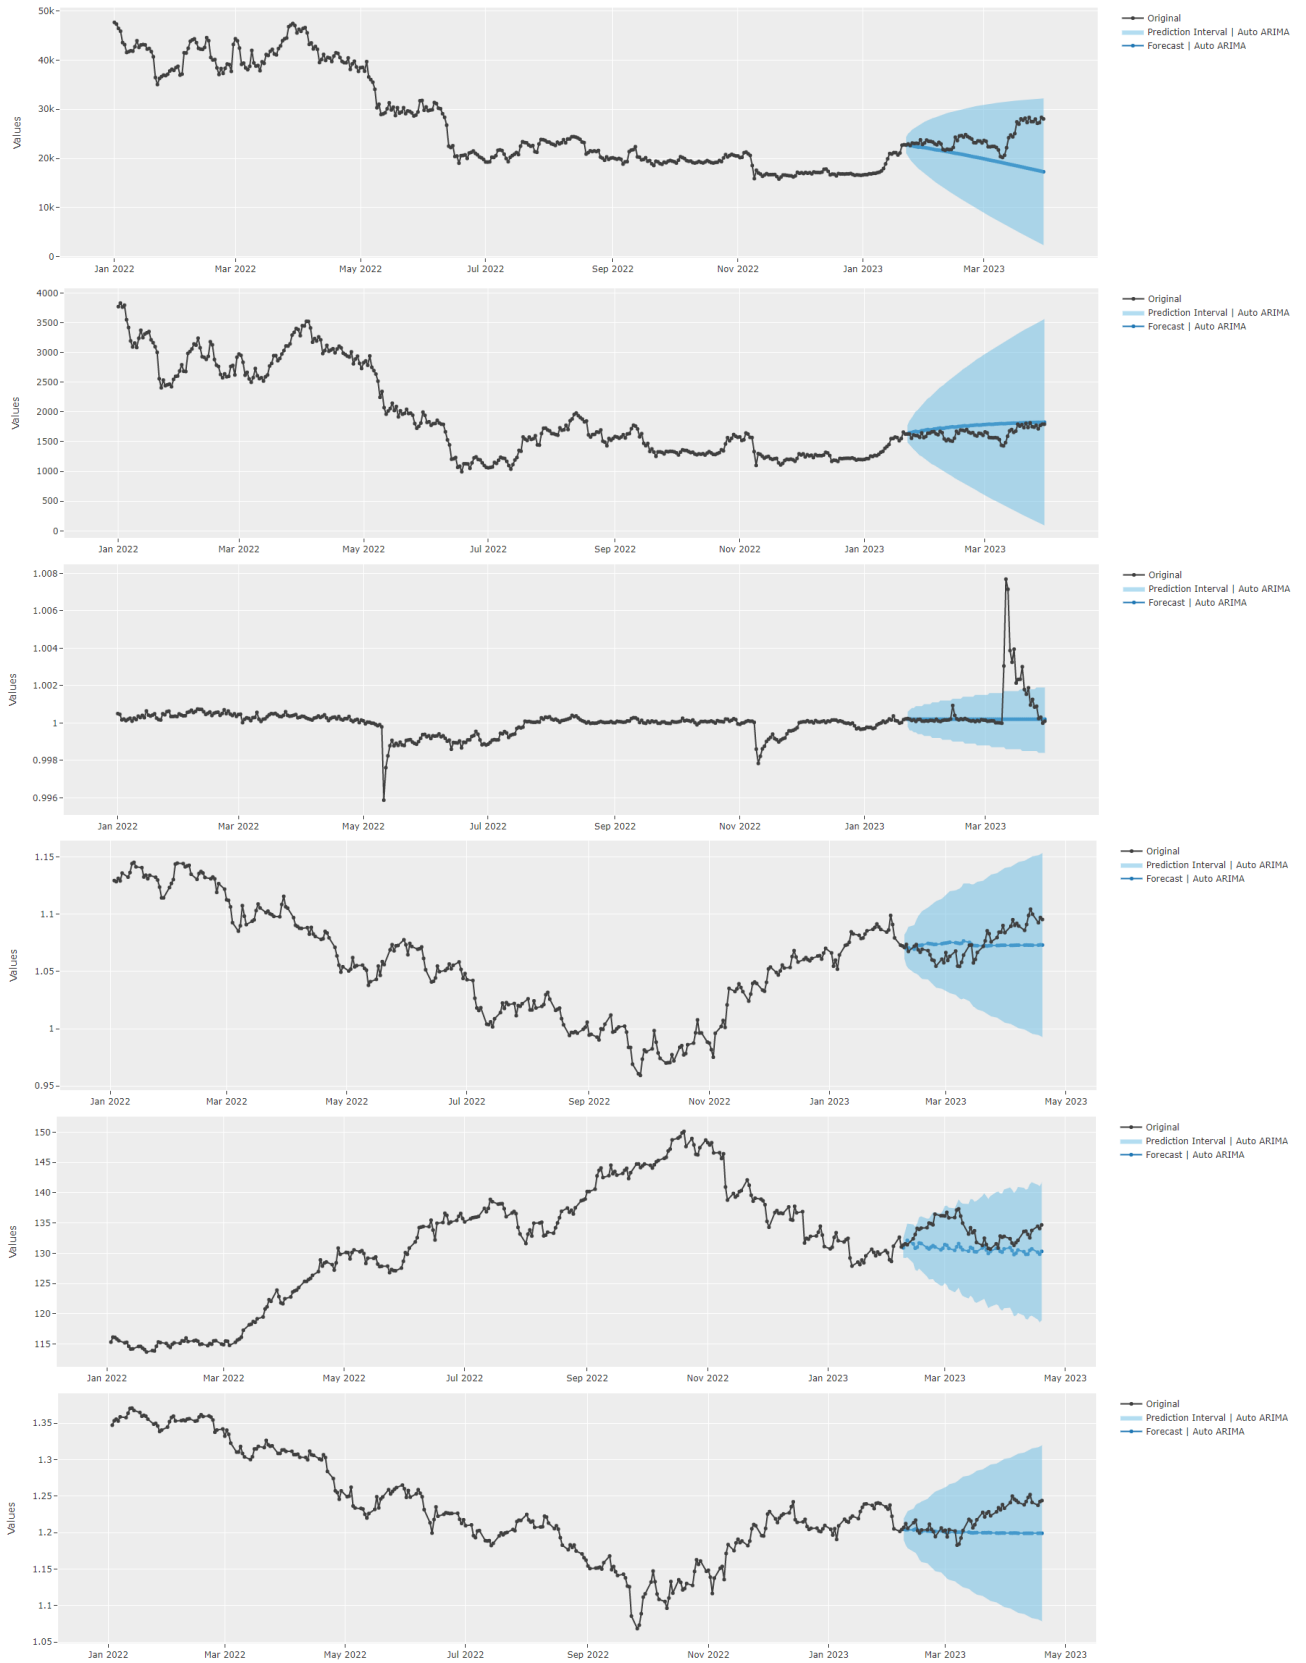


Рис. 3.8. Результаты моделирования AutoARIMA для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора

З отриманих діаграм можна зробити наступні висновки, що для лінійної регресії прогнозовані ціни на валюти точно слідують тенденції реальних цін, що показує ефективність даної моделі для роботи з часовими рядами або послідовними даними. З іншого боку, моделі випадкового лісу та AutoARIMA мають погані прогнозовані ціни. Це може бути пов'язано з популярністю даних валютних пар, а також з тим, що вони сильно реагують на зміни у зовнішньому середовищі, тому є менш стабільними. У пункті 3 цього розділу розглянемо метрики цих моделей.

3.2. Апробація глибоких нейронних мереж для прогнозування валютних ринків

Спершу, імпортуємо всі необхідні бібліотеки у середовище (рис.3.9). Для завантаження та обробки даних та побудови моделей LSTM, CNN, CNN+LSTM та CNN+GRU нам знадобляться наступні моделі [16, 18, 34, 49]:

- pandas: потужна бібліотека обробки даних, що використовується для обробки даних у табличному форматі (наприклад, електронні таблиці Excel). У цьому сценарії він використовується для обробки даних і попередньої обробки.
- numpy: популярна бібліотека для чисельних обчислень на Python. Він надає інструменти для роботи з масивами та матрицями, що корисно для машинного навчання та аналізу даних.
- datetime: модуль для роботи з датами та часом у Python. Ймовірно, він використовується для обробки пов'язаних із датою функцій у наборі даних.
- matplotlib.pyplot: модуль для створення різних типів графіків і діаграм на Python. Його часто використовують для візуалізації даних і результатів моделі.
- keras: бібліотека нейронних мереж високого рівня, яка працює поверх TensorFlow. Це спрощує процес побудови, навчання та оцінки моделей глибокого навчання.
- keras.models.Model і keras.layers: модулі для створення різних типів шарів нейронної мережі та визначення архітектури моделі.

- `sklearn.preprocessing.MinMaxScaler`: модуль для масштабування функцій набору даних за допомогою методу масштабування Min-Max, який часто використовується для покращення продуктивності моделей машинного навчання.
- `sklearn.metrics`: Модулі для обчислення різних показників для оцінки ефективності моделі, таких як MSE та MAPE.
- `math`: модуль для виконання різноманітних математичних операцій у Python. Його можна використовувати для обчислень під час попередньої обробки даних або оцінки моделі.
- `yfinance`: бібліотека для отримання фінансових даних із Yahoo Finance. Ймовірно, він використовується для отримання фінансових даних для набору даних.
- `tensorflow`: основна бібліотека з відкритим кодом для розробки та навчання моделей машинного навчання, зокрема моделей глибокого навчання. Keras, як згадувалося раніше, побудований на основі TensorFlow.
- `google.colab.files`: модуль для роботи з файлами в Google Colab. Його можна використовувати для завантаження файлів у середовище Colab або з нього.
- `warnings`: модуль для керування відображенням попереджень у Python. Сценарій налаштовано на ігнорування попереджень, щоб вихід був чистим і зосередженим на результатах.

```

import pandas as pd
import numpy as np
import datetime
from matplotlib import style
import matplotlib.pyplot as plt
import keras
from keras.models import Model
from keras.layers import LSTM, Flatten, GRU, Dense, Dropout, Input, Activation
from keras.layers.convolutional import Conv1D, MaxPooling1D
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error, mean_absolute_error
import math
import yfinance as yf
import tensorflow as tf
from google.colab import files

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

```

Рис. 3.9. Імпорт бібліотек Python у середовище Google Colab

Джерело: розрахунки автора

Наступним кроком є завантаження бази даних, а саме валютних котирувань для подальшого моделювання. Імпорт даних відбувався за тією ж схемою, що й у минулому пункті.

Всі кроки, починаючи з завантаження даних, крім результатів, будуть пояснюватися на прикладі BTC/USD та EUR/USD, оскільки для інших котирувань вони були зроблені аналогічним чином. Повний код реалізації моделей можна побачити у додатках Б-Д.

Щоб побудувати обрані нейронні мережі, нам потрібно розділити наші дані про курси валют на набір для навчання та набір для тестування. Було вирішено використовувати розподіл 85/15, тобто 85% даних виділено під навчальну вибірку, а 15% - під тестову. Крім того, ми також нормалізуємо наші дані, щоб усі значення були в діапазоні від 0 до 1 (рис.3.10).

```

close_prices = stock_data['Close']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

close_prices = df_curr['EURUSD']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

```

Рис. 3.10. Розділ даних на тестову та навчальну вибірки та нормалізація даних для BTC/USD (зліва) та EUR/USD (справа)

Джерело: розрахунки автора

Наступним кроком є налаштування мережевої архітектури для моделей. Для цього будемо використовувати бібліотеку машинного навчання з відкритим вихідним кодом TensorFlow. На рис. 3.11 можна побачити як саме встановлювалися параметри для моделей.

```

model = keras.Sequential()
model.add(LSTM(100, return_sequences=True, input_shape=(x_train.shape[1], 1)))
model.add(LSTM(100, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
model.summary()

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(Flatten())
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(LSTM(units=100, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(GRU(units=100, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

```

Рис.3.11. Налаштування мережевої архітектури: 1 – LSTM, 2 – CNN, 3 – CNN+LSTM, 4 – CNN+GRU

Джерело: розрахунки автора

Для моделі LSTM налаштування було зроблено наступним чином:

1. Визначимо послідовну модель, яка складається з лінійного стеку шарів.
2. Додаємо рівень LSTM, надавши йому 100 мережевих одиниць, а для `return_sequences` встановимо значення `true`, щоб результатом шару була інша послідовність такої ж довжини.
3. Додаємо ще один шар LSTM із також 100 мережевими одиницями, але ми встановлюємо для `return_sequences` значення `false` на цей час, щоб повертати лише останній вихід у вихідній послідовності.
4. Додаємо щільно зв'язаний рівень нейронної мережі з 25 мережевими одиницями.
5. Додаємо щільно пов'язаний рівень, який визначає вихід 1 одиниці мережі.

Для моделі CNN налаштування було зроблено наступним чином:

1. Створюємо послідовну модель, що складається з лінійного стеку шарів.

2. Додаємо 1D шар згортки зі 100 фільтрами, розміром ядра 2 і функцією активації ReLU. Цей шар буде приймати вхідні дані у вигляді (`x_train.shape[1]`, `x_train.shape[2]`).
3. Додаємо шар 1D max-pooling з розміром пулу 2, щоб зменшити просторові розміри вихідних даних попереднього згорткового шару.
4. Додаємо шар Flatten, щоб перетворити багатовимірний вихід шару з максимальним об'єднанням в одномірний масив, який можна подати на наступний щільний шар.
5. Додаємо щільно зв'язаний рівень нейронної мережі з 25 мережевими одиницями.
6. Додаємо щільно пов'язаний рівень, який визначає вихід 1 одиниці мережі.

Для моделі CNN+LSTM налаштування було наступним:

1. Створюємо послідовну модель, що складається з лінійного стеку шарів.
2. Додаємо шар 1D згортки зі 100 фільтрами, розміром ядра 2 і функцією активації ReLU. Цей шар буде приймати вхідні дані у вигляді (`x_train.shape[1]`, `x_train.shape[2]`).
3. Додаємо шар 1D max-pooling з розміром пулу 2, щоб зменшити просторові розміри вихідних даних попереднього шару згортки.
4. Додаємо шар LSTM зі 100 одиницями та функцією активації ReLU. Цей шар обробляє послідовну інформацію, отриману від попередніх шарів.
5. Додаємо шар Dropout з коефіцієнтом відсіву 0,2, який допомагає запобігти перенавчанню, випадково встановлюючи 20% вхідних одиниць в 0 при кожному оновленні під час навчання.
6. Додаємо шар щільно пов'язаної нейронної мережі з 25 одиницями.
7. Додаємо щільно пов'язаний рівень, який визначає вихід 1 одиниці мережі.

Для моделі CNN+GRU налаштування було наступним:

1. Створюємо послідовну модель, що складається з лінійного стеку шарів.
2. Додаємо шар 1D згортки зі 100 фільтрами, розміром ядра 2 і функцією активації ReLU. Цей шар буде приймати вхідні дані у вигляді (`x_train.shape[1]`, `x_train.shape[2]`).

3. Додаємо 1D шар з максимальним об'єднанням з розміром пулу 2, щоб зменшити просторові розміри вихідних даних попереднього згорткового шару.
4. Додаємо шар Gated Recurrent Unit (GRU) зі 100 одиницями та функцією активації ReLU. Цей шар обробляє послідовну інформацію, отриману з попередніх шарів. GRU - це тип рекурентних нейронних мереж (RNN), які схожі на LSTM, але зазвичай мають менше параметрів і є менш дорогими в обчислювальному плані.
5. Додаємо шар відсіву з коефіцієнтом відсіву 0,2, який допомагає запобігти надмірному пристосуванню, випадковим чином встановлюючи 20% вхідних одиниць в 0 при кожному оновленні під час навчання.
6. Додаємо шар щільно пов'язаної нейронної мережі з 25 одиницями.
7. Додаємо щільно пов'язаний рівень, який визначає вихід 1 одиниці мережі.

Архітектуру моделей та їхній опис можна побачити на рис. 3.12.

Model: "sequential_6"			Model: "sequential_5"		
Layer (type)	Output Shape	Param #	Layer (type)	Output Shape	Param #
lstm_12 (LSTM)	(None, 30, 100)	40800	conv1d_5 (Conv1D)	(None, 29, 100)	300
lstm_13 (LSTM)	(None, 100)	80400	max_pooling1d_5 (MaxPooling1D)	(None, 14, 100)	0
dense_12 (Dense)	(None, 25)	2525	flatten_5 (Flatten)	(None, 1400)	0
dense_13 (Dense)	(None, 1)	26	dense_5 (Dense)	(None, 25)	35025
Total params: 123,751 Trainable params: 123,751 Non-trainable params: 0			Total params: 35,351 Trainable params: 35,351 Non-trainable params: 0		
Model: "sequential"			Model: "sequential_1"		
Layer (type)	Output Shape	Param #	Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 29, 100)	300	conv1d_1 (Conv1D)	(None, 29, 100)	300
max_pooling1d (MaxPooling1D)	(None, 14, 100)	0	max_pooling1d_1 (MaxPooling1D)	(None, 14, 100)	0
lstm (LSTM)	(None, 100)	80400	gru_1 (GRU)	(None, 100)	60600
dropout (Dropout)	(None, 100)	0	dropout_1 (Dropout)	(None, 100)	0
dense (Dense)	(None, 25)	2525	dense_1 (Dense)	(None, 25)	2525
dense_1 (Dense)	(None, 1)	26	dense_2 (Dense)	(None, 1)	26
Total params: 83,251 Trainable params: 83,251 Non-trainable params: 0			Total params: 63,451 Trainable params: 63,451 Non-trainable params: 0		

Рис. 3.12. Архітектура та опис моделей: 1 – LSTM, 2 – CNN, 3 – CNN+LSTM, 4 – CNN+GRU

Джерело: розрахунки автора

На цьому етапі ми майже готові до навчання наших моделей, встановивши їх з навчальним набором. Перед цим ми повинні встановити оптимізатор (було вирішено прийняти оптимізатор «adam» і функцію втрат для наших моделей (було вирішено встановити середньоквадратичну помилку як функцію втрат).

Далі ми навчаємо моделі, підігнавши до них навчальний набір даних. Ми можемо спробувати з `batch_size` 1 і запустити навчання протягом 100 епох (рис. 3.13).

```
model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(x_train, y_train, batch_size= 1, epochs=100)
```

Рис. 3.13. Навчання моделей

Джерело: розрахунки автора

Налаштування та навчання моделей є ідентичним як для криптовалют, так і для фіатних.

Нашим наступним завданням є оцінка навчених моделей за допомогою тестового набору, а потім застосування метрики середньоквадратичної помилки (RMSE), середньої абсолютної похибки (MAE) та середньої абсолютної відсоткової похибки (MAPE) для перевірки ефективності моделі та візуалізація отриманих результатів. Цей блок є ідентичним для всіх моделей та валютних котирувань, а також є ідентичним тому, що ми прописували для лінійної регресії.

У результаті маємо такі графіки для моделей:



Рис. 3.14. Результаты моделирования LSTM для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора

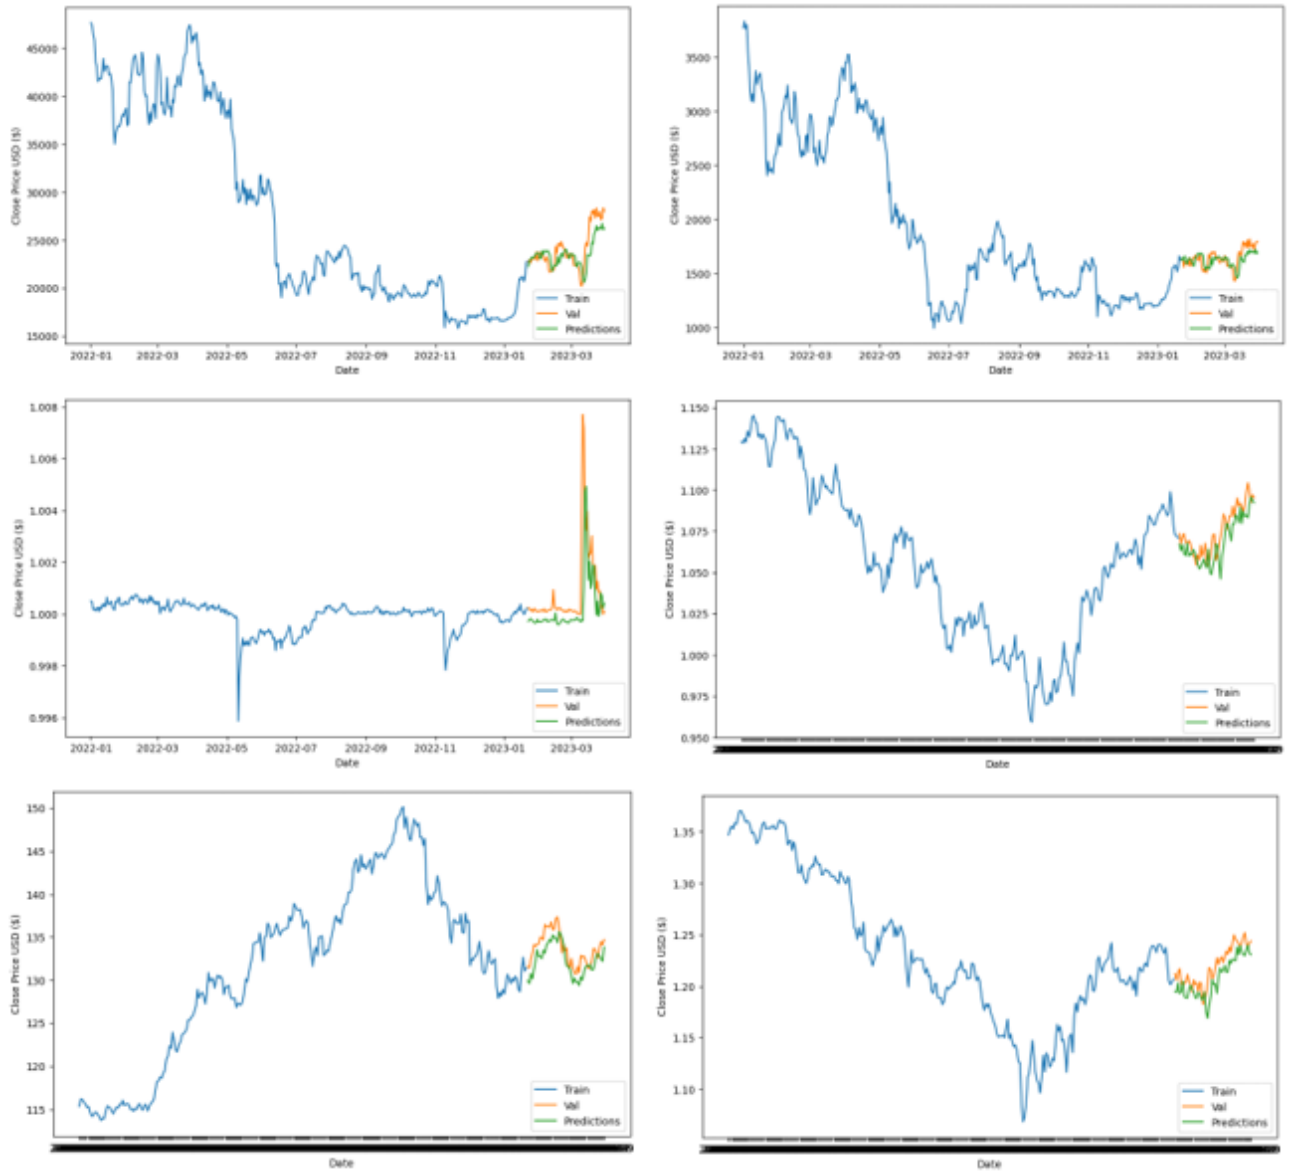


Рис. 3.15. Результати моделювання CNN для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора



Рис. 3.16. Результати моделювання CNN+LSTM для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора



Рис. 3.17. Результати моделювання CNN+GRU для: 1 – BTC/USD, 2 – ETH/USD, 3 – USDT/USD, 4 – EUR/USD, 5 – USD/JPY, 6 – GBP/USD

Джерело: розрахунки автора

З отриманих діаграм вище ми бачимо, що прогнозовані ціни на валюти точно слідують тенденції реальних цін. Це показує ефективність LSTM, CNN, CNN+LSTM та CNN+GRU для роботи з часовими рядами або послідовними даними.

3.3. Оцінка точності отриманих прогнозів та якості побудованих моделей

Використання алгоритмів машинного навчання для прогнозування обмінних курсів фіатних валют і криптовалют стає все більш популярним в

останні роки. Точне прогнозування валютних курсів може мати значні переваги для фізичних та юридичних осіб, які беруть участь у міжнародній торгівлі або інвестують у фінансові ринки. Однак оцінка якості та точності цих моделей має важливе значення для забезпечення їхньої ефективності та надійності.

RMSE (середньоквадратична помилка), MAE (середня абсолютна помилка), MAPE (середня абсолютна помилка у відсотках) та R-квадрат (R^2) - це популярні метрики ефективності, які використовуються для оцінки точності та відповідності регресійних моделей. Розглянемо всі метрики більш детально [49, 56].

RMSE (середньоквадратична похибка):

- RMSE – це міра різниці між прогнозованими значеннями і фактичними (спостережуваними) значеннями. Він обчислює квадратний корінь із середнього квадрата різниці між прогнозованими та фактичними значеннями.
- RMSE надає більшої ваги більшим похибкам, оскільки різниці зводяться в квадрат перед усередненням. Це робить RMSE чутливим до викидів і великих помилок.
- Чим нижче значення RMSE, тим краще модель відповідає даним. Значення RMSE, що дорівнює 0, вказує на ідеальну відповідність, хоча на практиці це малоймовірно.

MAE (середня абсолютна похибка):

- MAE вимірює середнє значення абсолютної різниці між прогнозованими і фактичними значеннями. На відміну від RMSE, вона не зводить різниці в квадрат.
- MAE менш чутлива до викидів і великих помилок, ніж RMSE, оскільки вона бере абсолютне значення різниць, а не зводить їх у квадрат.
- Як і RMSE, нижче значення MAE вказує на кращу відповідність моделі. Значення MAE, що дорівнює 0, вказує на ідеальну відповідність, але на практиці це також малоймовірно.

MAPE (середня абсолютна відсоткова похибка):

- MAPE – це відносна міра точності моделі, виражена у відсотках. Він обчислює середнє значення абсолютної різниці між прогнозованими і фактичними значеннями, ділиться на фактичні значення, а потім множиться на 100.
- MAPE корисний для порівняння ефективності моделей у різних масштабах або одиницях виміру, оскільки він представляє похибку у відсотках від фактичних значень.
- Нижчі значення MAPE вказують на кращу продуктивність моделі. Значення MAPE, що дорівнює 0%, вказує на ідеальну відповідність, але на практиці це малоймовірно.

У попередніх двох пунктах ми вже розрахували ці показники. У таблицях 3.1 та 3.2 показано розраховані метрики для кожної моделі та валютних котирувань.

Таблиця 3.1

Розрахунок метрик для оцінки точності та якості побудованих класичних моделей

Моделі	Валютні пари	RMSE	MAE	MAPE
Випадковий ліс	BTC/USD	5414,335	4714,855	0,234
	ETH/USD	475,039	398,322	0,254
	USDT/USD	0,001	0,001	0,001
	EUR/USD	0,037	0,031	0,030
	USD/JPY	10,016	8,515	0,064
	GBP/USD	0,032	0,035	0,030
AutoARIMA	BTC/USD	5092,064	4397,607	0,210
	ETH/USD	407,613	368,361	0,248
	USDT/USD	0,001	0,001	0,001
	EUR/USD	0,027	0,025	0,024
	USD/JPY	5,532	4,333	0,032
	GBP/USD	0,036	0,029	0,024

Джерело: розрахунок автора

Порівняння ефективності моделей Random Forest та AutoARIMA для кожної валютної пари:

Для валютних пар BTC/USD, ETH/USD, EUR/USD, USD/JPY, GBP/USD модель AutoARIMA має дещо кращі результати, ніж модель Random Forest, з нижчими значеннями RMSE, MAE та MAPE.

Для валютної пари USDT/USD обидві моделі мають порівнянну ефективність з дуже схожими значеннями RMSE, MAE та MAPE.

Таким чином, модель AutoARIMA в цілому перевершує модель Random Forest для цих валютних пар. AutoARIMA спеціально розроблена для прогнозування часових рядів і краще справляється з часовими залежностями в даних.

Таблиця 3.2

Розрахунок метрик для оцінки точності та якості побудованих глибоких нейронних мереж

Моделі	Валютні пари	RMSE	MAE	MAPE
LSTM	BTC/USD	23,568	542,381	9,185
	ETH/USD	5,017	39,168	5,898
	USDT/USD	0,000	0,000	0,116
	EUR/USD	0,002	0,005	1,445
	USD/JPY	0,360	0,718	1,556
	GBP/USD	0,003	0,007	1,734
CNN	BTC/USD	483,109	1110,740	7,879
	ETH/USD	17,010	59,413	5,136
	USDT/USD	0,001	0,001	0,119
	EUR/USD	0,007	0,009	1,538
	USD/JPY	1,345	1,465	1,731
	GBP/USD	0,012	0,013	1,940
CNN+LSTM	BTC/USD	1018,760	1125,531	9,553
	ETH/USD	78,343	84,708	6,751
	USDT/USD	0,000	0,001	0,141
	EUR/USD	0,001	0,007	1,539
	USD/JPY	0,445	1,201	1,732
	GBP/USD	0,006	0,011	1,925
CNN+GRU	BTC/USD	275,498	885,883	10,277
	ETH/USD	17,629	58,297	6,690
	USDT/USD	0,000	0,001	0,141
	EUR/USD	0,014	0,015	1,966
	USD/JPY	2,339	2,375	2,334
	GBP/USD	0,016	0,018	2,245

Джерело: розрахунок автора

Проаналізуємо дані моделі для кожної валютної пари за цими метриками.

BTC/USD: Для пари BTC/USD модель LSTM має найкращі показники RMSE і MAE, в той час як модель CNN має найнижчий показник MAPE.

ETH/USD: Для пари ETH/USD модель LSTM має найкращі показники RMSE і MAE, в той час як модель CNN має найнижчий показник MAPE.

USDT/USD: Для пари USDT/USD модель LSTM має найкращі показники RMSE, MAE та MAPE.

EUR/USD: Для пари EUR/USD модель LSTM має найкращі показники RMSE та MAE, тоді як модель CNN+LSTM має найнижчий показник MAPE.

USD/JPY: Для пари USD/JPY модель LSTM має найкращі показники RMSE, MAE та MAPE.

GBP/USD: Для пари GBP/USD модель LSTM має найкращі показники RMSE, MAE і MAPE.

Підсумовуючи, для проаналізованих валютних пар:

- LSTM модель має найкращі загальні показники для BTC/USD, ETH/USD, USDT/USD, EUR/USD, USD/JPY та GBP/USD за RMSE та MAE.
- Модель CNN має найнижчий MAPE для пар BTC/USD та ETH/USD.
- Модель CNN+LSTM має найнижчий MAPE для пари EUR/USD.

Випадковий ліс: Random Forest має дуже високі показники для деяких валютних пар, особливо криптовалют. Це вказує на те, що він погано вловлює часові залежності в даних часових рядів, що робить його менш придатним для прогнозування фінансових часових рядів.

AutoARIMA: AutoARIMA має кращі показники для традиційних валютних пар, таких як EUR/USD та USD/JPY, але показує погані результати для криптовалют. Вона може бути більш придатною для стаціонарних даних часових рядів, але має проблеми з високо волатильними фінансовими даними, такими як криптовалюти.

LSTM: модель стабільно показує хороші результати для всіх валютних пар, часто маючи найнижчі RMSE і MAE, а також конкурентні значення MAPE. Це відмінний вибір для фінансових часових рядів завдяки здатності відображати складні закономірності та часові залежності.

CNN: CNN показав змішані результати. У деяких випадках він показав хороші результати, особливо для криптовалют, але в багатьох випадках його перевершили LSTM і CNN+GRU. CNN може краще підходити для завдань, де

просторові закономірності є важливими, але він все ще може бути корисним для прогнозування часових рядів.

CNN+LSTM: модель також має змішану продуктивність, причому моделі LSTM і CNN+GRU часто перевершують її. Поєднуючи сильні сторони як CNN, так і LSTM, ця модель може вловлювати як просторові, так і часові закономірності в даних, але може вимагати ретельної архітектури та налаштування гіперпараметрів.

CNN+GRU: CNN+GRU, як правило, добре показує себе на всіх валютних парах, часто перевершуючи інші моделі за показниками RMSE, MAE і MAPE. Ця модель поєднує в собі сильні сторони як CNN, так і GRU, що робить її гарним вибором для прогнозування часових рядів.

Виходячи з аналізу, моделі LSTM та CNN+GRU видаються найкращим вибором для прогнозування фінансових часових рядів, оскільки вони стабільно показують хороші результати для різних валютних пар та метрик. Вони чудово вловлюють складні закономірності та часові залежності, присутні у даних фінансових часових рядів.

Деякі моделі мають дуже високі показники (наприклад, >1000) для певних валютних пар, особливо для криптовалют, таких як біткоїн. Криптовалюти дуже волатильні, що ускладнює точне прогнозування їхніх цін. Традиційні моделі, такі як випадковий ліс і AutoARIMA, можуть не впоратися з таким високим ступенем волатильності. Також на фінансові ринки впливають численні фактори, такі як макроекономічні показники, новини та настрої інвесторів. Ці фактори можуть спричинити раптові зміни цін, які деяким моделям важко точно передбачити.

ВИСНОВКИ

У роботі наведено теоретичне узагальнення та підхід до вирішення науково-практичної задачі створення математичного інструментарію та інформаційних технологій прогнозування валютних курсів. На основі проведеного дослідження можна зробити наступні висновки:

1. Ринки фіатних валют і криптовалют стають все більш взаємопов'язаними, оскільки все більше фінансових установ, інвесторів і споживачів приймають цифрові валюти поряд з традиційними валютами. Ця зростаюча взаємозалежність призвела до більш складного фінансового ландшафту, де динаміка одного ринку може впливати на інший.

2. Хоча ринок криптовалют стрімко зростає в останні роки, він все ще відносно молодий порівняно з традиційними фінансовими ринками. Як наслідок, ринок схильний до спекуляцій, маніпулювання цінами та ринкової неефективності, що може призвести до значних коливань у короткостроковій динаміці цін на криптовалюти.

3. Ринки як фіатних валют, так і криптовалют продовжують демонструвати значну короткострокову волатильність і непередбачуваність. Це може бути пов'язано з різними факторами, включаючи макроекономічний розвиток, геополітичні події, ринкові настрої та регуляторні зміни, серед іншого.

4. З огляду на складність і волатильність ринків фіатних валют і криптовалют, зростає потреба в більш досконалих моделях прогнозування, які можуть точно передбачати короткострокову динаміку. Досягнення в галузі машинного навчання та методів глибоких нейронних мереж відкривають багатообіцяючі шляхи для розробки таких моделей і поглиблення нашого розуміння цих ринків.

5. Комплексний огляд існуючих методологій та інструментів прогнозування валютних котирувань, розглянутих у цій роботі, дозволяє зробити висновок, що практична цінність традиційних підходів, заснованих на технічному аналізі, економетричних моделях та методах обробки часових рядів,

є обмеженою. На противагу цьому, моделі машинного навчання, зокрема, глибокі нейронні мережі, виявляються більш ефективними для прогнозування валютних курсів. Це пов'язано з тим, що вони дозволяють виявляти закономірності в динаміці цінових кривих, які потім можуть бути використані для майбутніх прогнозів.

6. У цьому дослідженні було побудовано три класичні моделі: випадковий ліс та AutoARIMA. Random Forest має дуже високі показники для деяких валютних пар, особливо криптовалют. Це вказує на те, що він погано вловлює часові залежності в даних часових рядів, що робить його менш придатним для прогнозування фінансових часових рядів. AutoARIMA має кращі показники для традиційних валютних пар, але показує погані результати для криптовалют. Вона може бути більш придатною для стаціонарних даних часових рядів, але має проблеми з високо волатильними фінансовими даними, такими як криптовалюти.

7. У цьому дослідженні було побудовано чотири моделі глибоких нейронних мереж: LSTM, CNN, CNN+LSTM та CNN+GRU. Ці моделі були обрані завдяки їхнім унікальним можливостям у вирішенні завдань прогнозування траєкторій руху валютних котирувань, що є важливим для визначення потенційних точок входу в торгові стратегії та оптимізації прибутку. Модель LSTM була використана через її ефективність в обробці даних часових рядів і здатність фіксувати довгострокові залежності. Вона долає проблему зникаючого градієнта, яка часто зустрічається в традиційних рекурентних нейронних мережах, що робить її особливо придатною для прогнозування валютних котирувань. Модель CNN була обрана через її виняткову ефективність у вилученні та ідентифікації ознак. Вона може автоматично навчатися та ідентифікувати відповідні ознаки з вхідних даних, що робить її ідеальним вибором для побудови предикторів в контексті прогнозування валютних котирувань. Гібридна модель CNN+LSTM поєднує в собі сильні сторони моделей CNN і LSTM. Компонент CNN відповідає за вилучення релевантних ознак з вхідних даних, в той час як компонент LSTM обробляє аспект часових

рядів даних і фіксує довгострокові залежності. Така комбінація дозволяє більш надійно і точно прогнозувати траєкторії валютних котирувань. Подібно до моделі CNN+LSTM, гібридна модель CNN+GRU використовує можливості CNN щодо вилучення особливостей та обробки часових рядів рекурентною нейронною мережею. Компонент GRU, однак, пропонує більш спрощену архітектуру порівняно з LSTM, що може призвести до швидшого навчання та порівнянної продуктивності.

8. Кожна з цих моделей була побудована і навчена з використанням історичних даних валютних котирувань для прогнозування траєкторії валютних котирувань. Ефективність моделей була оцінена і порівняна, за 4 показниками, а саме RMSE, MAE, MAPE, що дозволило зрозуміти відносні сильні і слабкі сторони кожного підходу в контексті прогнозування валютних котирувань. Вивчаючи ці різні архітектури глибоких нейронних мереж, дослідження мало на меті визначити найефективнішу модель для прогнозування валютних котирувань та оптимізації торгових стратегій.

9. Виходячи з аналізу, моделі LSTM та CNN+GRU видаються найкращим вибором для прогнозування фінансових часових рядів, оскільки вони стабільно показують хороші результати для різних валютних пар та метрик. Вони чудово вловлюють складні закономірності та часові залежності, присутні у даних фінансових часових рядів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Al-Yahyaee, K. H., & Mensi, W. (2021). Forecasting short-term USD/SAR exchange rates: Evidence from moving average and exponential smoothing techniques. *Journal of Quantitative Economics*, 19(1), 123-138.
2. Ballas, N., Yao, L., Pal, C., & Courville, A. (2016). Delving deeper into convolutional networks for learning video representations. In ICLR (Poster).
3. Bank for International Settlements. URL: <https://www.bis.org/>
4. Bloomenthal A. What Determines Bitcoin's Price? [Електронний ресурс] / А. Bloomenthal // Investopedia.com. – 2022. – Режим доступу до ресурсу: <https://www.investopedia.com/tech/what-determines-value-1-bitcoin/>.
5. Bouri, E., Azzi, G., & Roubaud, D. (2020). Bitcoin price forecasting using ARIMA, ANN, and Prophet models. *Journal of Risk and Financial Management*, 13(7), 143.
6. Bouri, E., Shahzad, S. J. H., Roubaud, D., & Kristoufek, L. (2020). Bitcoin returns and risk estimation: A study of autoregressive conditional heteroscedasticity, generalized autoregressive conditional heteroscedasticity and nonparametric approaches. *Finance Research Letters*, 36, 101308.
7. Bouronikos V. What Are the Factors Influencing the Crypto Market Today? [Електронний ресурс] / V. Bouronikos // Institute of Entrepreneurship Development. – 2022. – Режим доступу до ресурсу: <https://ied.eu/blog/technology-blog/what-are-the-factors-influencing-the-crypto-market-today/>.
8. Build a Bitcoin price prediction program using machine learning and Python [Електронний ресурс]. – 2019. – Режим доступу до ресурсу: <https://randerson112358.medium.com/build-a-bitcoin-price-prediction-program-using-machine-learning-and-python-89f3dc6cb3b1>.
9. Chapter 7: Foreign Exchange and the Global Capital Markets. // *International Business*.
10. Chen, J., Li, M., & Yang, S. (2019). Multiple regression analysis of CNY exchange rate. *Open Journal of Business and Management*, 7(4), 1414-1424.

11. Chen, Y., & Lu, Y. (2021). Forecasting Bitcoin prices using time-series regression analysis. *Journal of Risk and Financial Management*, 14(5), 187.
12. Cheng, W., Guo, J., & Zhang, Z. (2020). LSTM neural network for short-term prediction of Ethereum price. *Journal of Intelligent & Fuzzy Systems*, 38(4), 4683-4692.
13. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
14. Coyne A. Super simple neural network for Bitcoin price prediction in Python [Электронный ресурс] / Alan Coyne // Python in Plain English. – 2022. – Режим доступа до ресурсу: <https://python.plainenglish.io/super-simple-neural-network-for-bitcoin-price-prediction-in-python-8c2cd46d11a7>.
15. CoinMarketCap. URL: <https://coinmarketcap.com/>
16. Cryptocurrency Price Prediction using Deep Learning in LSTM Neural Network [Электронный ресурс] // IEEE Xplore Digital Library. – 2018. – Режим доступа до ресурсу: <https://ieeexplore.ieee.org/document/8800959>.
17. Derbentsev V. Forecasting of Cryptocurrency Prices Using Machine Learning [Электронный ресурс] / V. Derbentsev, A. Matviychuk, V. N. Soloviev // Springer Nature Singapore Pte Ltd. – 2020. – Режим доступа до ресурсу: https://doi.org/10.1007/978-981-15-4498-9_12.
18. Donahue, J., Hendricks, L. A., Rohrbach, M., Venugopalan, S., Guadarrama, S., Saenko, K., & Darrell, T. (2017). Long-term recurrent convolutional networks for visual recognition and description. *IEEE transactions on pattern analysis and machine intelligence*, 39(4), 677-691.
19. Hicks C. Different Types of Cryptocurrencies [Электронный ресурс] / C. Hicks // Forbes.com. – 2023. – Режим доступа до ресурсу: <https://www.forbes.com/advisor/investing/cryptocurrency/different-types-of-cryptocurrencies/>.

20. History of ETH: The rise of the Ethereum blockchain [Электронный ресурс] // Cointelegraph. – 2023. – Режим доступа до ресурсу: <https://cointelegraph.com/learn/history-of-ethereum-blockchain>.
21. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
22. Hussain A. Deep Learning Approach for Cryptocurrency Price Prediction [Электронный ресурс] / Aliakbar Hussain // IEEE Xplore Digital Library. – 2020. – Режим доступа до ресурсу: <https://ieeexplore.ieee.org/document/9075133>.
23. Jiang, Y., Zhu, L., & Zhang, J. (2021). Short-term forecasting of CNY exchange rate based on VAR model. *Applied Sciences*, 11(3), 1174.
24. Jiao, J., & Zhang, Q. (2020). Short-term exchange rate forecasting based on fundamental analysis. *Journal of Applied Statistics*, 47(10), 1889-1906.
25. Jinyeong Y. Interpretable Cryptocurrency Price Prediction with LASSO-based LSTM Model [Электронный ресурс] / Y. Jinyeong, S. Dong-II // *Journal of Financial Markets*. – 2019. – Режим доступа до ресурсу: <https://www.sciencedirect.com/science/article/pii/S1364815219300122>.
26. Kirgizbaev S. Comparative Analysis of the Volatility of Cryptocurrencies, Fiat Money and Other Assets [Электронный ресурс] / S. Kirgizbaev, F. Zakirov. – 2020. – Режим доступа до ресурсу: <https://doi.org/10.13140/RG.2.2.29108.68480>.
27. Koutmos, D., Katsiampa, P. (2018). Bitcoin returns and transaction activity. *Finance Research Letters*, 26, 145-150.
28. Kharwal A. Cryptocurrency Price Prediction with Machine Learning [Электронный ресурс] / Aman Kharwal. – 2021. – Режим доступа до ресурсу: <https://thecleverprogrammer.com/2021/12/27/cryptocurrency-price-prediction-with-machine-learning/>.
29. LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
30. Li, X., Wang, H., & Zhang, X. (2019). Short-term bitcoin price prediction using gradient boosting and support vector regression. *Applied Sciences*, 9(5), 853.

31. Liu, W., Han, X., Zhang, X., & Wang, Y. (2021). Forecasting bitcoin price dynamics: A fundamental approach. *Applied Economics Letters*, 28(1), 28-32.
32. Mishra P. *Practical explainable AI using Python* / Pradeepta Mishra., 2022. – 298 с.
33. Moradi E. *Deep Learning for Cryptocurrency Trading* [Электронный ресурс] / E. Moradi, M. Ghasemzadeh // *IEEE Xplore Digital Library*. – 2019. – Режим доступа до ресурсу: <https://ieeexplore.ieee.org/document/8963998>.
34. Nurmagambetov A. *Deep Learning for Cryptocurrency Price Prediction: A Comparative Study of LSTM and GRU Architectures* [Электронный ресурс] / Abubakar Nurmagambetov // *IEEE Xplore Digital Library*. – 2020. – Режим доступа до ресурсу: <https://ieeexplore.ieee.org/document/9121741>.
35. Pinkerton J. *The History of Bitcoin, the First Cryptocurrency* [Электронный ресурс] / J. Pinkerton // *U.S.News*. – 2023. – Режим доступа до ресурсу: <https://money.usnews.com/investing/articles/the-history-of-bitcoin>.
36. Proposal for a REGULATION OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL on Markets in Crypto-assets, and amending Directive (EU) 2019/1937 24.09.2020. URL: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52020PC0593>
37. Reiff N. *The Collapse of FTX: What Went Wrong with the Crypto Exchange?* [Электронный ресурс] / N. Reiff // *Investopedia.com*. – 2023. – Режим доступа до ресурсу: <https://www.investopedia.com/what-went-wrong-with-ftx-6828447>.
38. Royal J. *12 most popular types of cryptocurrency* [Электронный ресурс] / J. Royal, B. Baker // *Bankrate*. – 2023. – Режим доступа до ресурсу: <https://www.bankrate.com/investing/types-of-cryptocurrency/>.
39. Song J. *Programming bitcoin* / Jimmy Song., 2020. – 368 с.
40. Tether - Overview, History, Reserves [Электронный ресурс] // *CFI*. – 2023. – Режим доступа до ресурсу: <https://corporatefinanceinstitute.com/resources/cryptocurrency/tether/>.
41. *The Trades That Triggered TerraUSD's Collapse* [Электронный ресурс] // *Chainanalysis*. – 2022. – Режим доступа до ресурсу: <https://blog.chainanalysis.com/reports/how-terrausd-collapsed/>.
42. *TradingView*. URL: <https://www.tradingview.com>.

43. VanderPlas J. Python Data Science Handbook / Jake VanderPlas // O'Reilly Media. – 2017. – P. 548.
44. Yahoo! Finance [Електронний ресурс]. – Режим доступу: <https://finance.yahoo.com/>.
45. Zeybek, Z., & Gündüz, L. (2021). A comparative analysis of technical analysis indicators for forecasting exchange rates: A case study of EUR/USD. *Journal of Risk and Financial Management*, 14(6), 233.
46. Базилевич В.Д. Цінні папери: підручник / В.Д. Базилевич, В.М. Шелудько, Н.В. Ковтун та ін., за ред. В.Д. Базилевича. К.: Знання, 2011. – 1094 с.
47. Безкоровайний В.С. Моделювання динаміки ринку криптовалют / Безкоровайний В.С., Дербенцев В.Д. // Моделювання та інформаційні системи в економіці : – 2018. – Вип. 96. – С. 16–27.
48. Безкоровайний В.С. Моніторинг стану валютного ринку з використанням кусково-неперервних функцій / В.С. Безкоровайний, В.Д. Дербенцев // Проблеми системного підходу в економіці. – 2017. – № 6(62). – С. 162-166.
49. Безкоровайний В. С. Моніторинг та прогнозування стану та динаміки валютного ринку: дис. канд. ек. наук : 08.00.11 / Безкоровайний В. С. – Київ, 2021. – 160 с.
50. Версаль Н. І. Підходи до визначення фінансових шоків / Н. І. Версаль // Финансовые услуги. – 2017. – № 1. – С. 15-20.
51. Криптовалюта — що це таке, як вона працює і навіщо потрібна. [Електронний ресурс] – Режим доступу до ресурсу: <https://termin.in.ua/kryptovaliuta/>.
52. Політов М. В. Моделювання курсу криптовалют на основі нейронних мереж з еволюційною оптимізацією [Електронний ресурс] / М. В. Політов, С. В. Діденко. – 2018. – Режим доступу до ресурсу: <https://cyberleninka.org/article/n/modeliuvannia-kursu-kryptovaliut-na-osnovi-neyronnykh-merez-z-evoliutsiinoiu-optimizatsiiei>.
53. Про віртуальні активи: Закон України від 17.02.2022 р. № 2074-IX. URL: <https://zakon.rada.gov.ua/laws/show/2074-20>

- 54.Ставицький А.В. Навчально-методичний комплекс з курсів "Прогнозування" та "Фінансове прогнозування". - К., 2006. - 107 с.
- 55.Тадєєв Ю. П. Моделювання динаміки курсу криптовалют та їх вплив на фінансову систему України / Ю. П. Тадєєв, А. М. Лукач. // Економічний вісник НТУУ "Київський політехнічний інститут". – 2021. – №19. – С. 182–186.
- 56.Тенденції розвитку криптовалют і фундаментальні економічні індикатори: аналіз кореляції та регресії / [О. І. Барановський, М. О. Кужелєв, Д. М. Жерліцин та ін.]. // Financial and credit activities: problems of theory and practice. – 2021. – №3. – С. 249–261.
- 57.Фондовий ринок : підручник : у 2 кн. – Кн.1 / В.Д.Базилевич, В.М.Шелудько, В.В.Вірченко та ін. ; за ред. В.Д.Базилевича; Київ. нац. ун-т ім. Т.Шевченка. – К. : Знання, 2015. – 621 с.
- 58.Черкаський В. В. Прогнозування курсу біткоїна за допомогою нейронних мереж [Електронний ресурс] / В. В. Черкаський, О. М. Кожем'яка. – 2018. – Режим доступу до ресурсу: <https://cyberleninka.org/article/n/prohnozuvannia-kursu-bitkoina-za-dopomohoiu-neyronnykh-merezh>.
- 59.Черняк О.І. Теорія ймовірностей та математична статистика. Збірник задач: [навч. посібник] / О.І. Черняк, О.М. Обушна, А.В. Ставицький. – 2-ге вид. – К.: Знання, КОО, 2002. – 199 с.
- 60.Шарікова Р. Я. Прогнозування курсу криптовалют з використанням моделі LSTM та багатошарових перцептронів [Електронний ресурс] / Р. Я. Шарікова, В. О. Комаров. – 2020. – Режим доступу до ресурсу: <https://ieeexplore.ieee.org/document/9329889>.
- 61.Андриенко И. Лучшие валютные пары Форекс для прибыльной торговли - Исследование МОФТ [Електронний ресурс] / И. Андриенко // Traders Union. – 2023. – Режим доступу до ресурсу: <https://tradersunion.com/ru/interesting-articles/best-forex-currency-pairs/>.

- 62.Лоза С. Самые ликвидные валютные пары на рынке Форекс [Электронный ресурс] / S. Loza // FXSSI. – 2023. – Режим доступа до ресурсу: <https://ru.fxssi.com/samye-likvidnye-valyutnye-pary>.
- 63.Финансы и финансовый рынок. Финансовый рынок: практ. пособие для студ. спец.: 1 – 25 01 10 «Коммерческая деятельность», 1 – 25 01 07 «Экономика и управление на предприятии», 1 – 25 01 03 «Мировая экономика» / Л.В. Федосенко и др.; М-во образования РБ, Гомельский гос. Ун-т им. Ф. Скорины. – Гомель: ГГУ им. Ф. Скорины, 2013. – 44 с. https://core.ac.uk/display/75999993?utm_source=pdf&utm_medium=banner&utm_campaign=pdf-decoration-v1

ДОДАТКИ

Додаток А

Реалізація випадкового лісу та AutoARIMA за допомогою мови програмування
Python на прикладі BTC/USD та EUR/USD

```

import pandas as pd
import numpy as np
from matplotlib import style
import matplotlib.pyplot as plt
import yfinance as yf
from google.colab import files
from pycaret.time_series import *

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()

plt.figure(figsize=(8, 4))
plt.title('Bitcoin Prices History')
plt.plot(stock_data['Close'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

ts = setup(stock_data['Close'], fh = 68, fold_strategy = 'sliding')

check_stats()

rf = create_model('rf_cds_dt')
plot_model(rf)

auto_arima = create_model('auto_arima')
plot_model(auto_arima)

uploaded = files.upload()

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1,
inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr.head()

```

Продовження додатку А

```
plt.figure(figsize=(8, 4))
plt.title('EUR/USD Prices History')
plt.plot(df_curr['EURUSD'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

ts = setup(df_curr['EURUSD'], fh = 51, fold_strategy = 'sliding')

check_stats()

rf = create_model('rf_cds_dt')
plot_model(rf)

auto_arima = create_model('auto_arima')
plot_model(auto_arima)
```

Реалізація моделі LSTM за допомогою мови програмування Python на прикладі BTC/USD та EUR/USD

```
import pandas as pd
import numpy as np
import datetime
from matplotlib import style
import matplotlib.pyplot as plt
import keras
from keras.models import Model
from keras.layers import LSTM, Flatten, Dense, Dropout, Input, Activation, BatchNormalization
from keras.layers.convolutional import Conv1D, MaxPooling1D
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error, r2_score, mean_absolute_error
import math
import yfinance as yf
import tensorflow as tf
from google.colab import files

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

model = keras.Sequential()
model.add(LSTM(100, return_sequences=True, input_shape=(x_train.shape[1], 1)))
model.add(LSTM(100, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
model.summary()

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(x_train, y_train, batch_size=1, epochs=100)

stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()

plt.figure(figsize=(8, 4))
plt.title('Bitcoin Prices History')
plt.plot(stock_data['Close'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')
close_prices = stock_data['Close']
```

Продовження додатку Б

```

values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape

data = stock_data.filter(['Close'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['Close', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()

```

Продовження додатку Б

```

uploaded = files.upload()

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1,
inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr.head()

plt.figure(figsize=(8, 4))
plt.title('EUR/USD Prices History')
plt.plot(df_curr['EURUSD'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

close_prices = df_curr['EURUSD']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))
predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse
mae = mean_absolute_error(y_test, predictions)
mae

```

Продовження додатку Б

```
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape

data = df_curr.filter(['EURUSD'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['EURUSD', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()
```

Реалізація моделі CNN за допомогою мови програмування Python на прикладі BTC/USD та EUR/USD

```

import pandas as pd
import numpy as np
import datetime
from matplotlib import style
import matplotlib.pyplot as plt
import keras
from keras.models import Model
from keras.layers import LSTM, Flatten, Dense, Dropout, Input, Activation, BatchNormalization
from keras.layers.convolutional import Conv1D, MaxPooling1D
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error, r2_score, mean_absolute_error
import math
import yfinance as yf
import tensorflow as tf
from google.colab import files

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(Flatten())
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(x_train, y_train, batch_size=1, epochs=100)

stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()

plt.figure(figsize=(8, 4))
plt.title('Bitcoin Prices History')
plt.plot(stock_data['Close'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

```

Продовження додатку В

```

close_prices = stock_data['Close']
values = close_prices.values
training_data_len = math.ceil(len(values) * 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape
data = stock_data.filter(['Close'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['Close', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()

```

Продовження додатку В

```

uploaded = files.upload()

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1,
inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr.head()

plt.figure(figsize=(8, 4))
plt.title('EUR/USD Prices History')
plt.plot(df_curr['EURUSD'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

close_prices = df_curr['EURUSD']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse

```

Продовження додатку В

```
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape

data = df_curr.filter(['EURUSD'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['EURUSD', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()
```

Реалізація моделі CNN+LSTM за допомогою мови програмування Python на прикладі BTC/USD та EUR/USD

```

import pandas as pd
import numpy as np
import datetime
from matplotlib import style
import matplotlib.pyplot as plt
import keras
from keras.models import Model
from keras.layers import LSTM, Flatten, Dense, Dropout, Input, Activation, BatchNormalization
from keras.layers.convolutional import Conv1D, MaxPooling1D
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error, r2_score, mean_absolute_error
import math
import yfinance as yf
import tensorflow as tf
from google.colab import files

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(LSTM(units=100, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(x_train, y_train, batch_size= 1, epochs=100)

stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()

plt.figure(figsize=(8, 4))
plt.title('Bitcoin Prices History')
plt.plot(stock_data['Close'])
plt.xlabel('Date')

```

Продовження додатку Г

```

plt.ylabel('Prices ($)')
close_prices = stock_data['Close']
values = close_prices.values
training_data_len = math.ceil(len(values) * 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape
data = stock_data.filter(['Close'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['Close', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()

```

Продовження додатку Г

```

uploaded = files.upload()

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1,
inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr.head()

plt.figure(figsize=(8, 4))
plt.title('EUR/USD Prices History')
plt.plot(df_curr['EURUSD'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

close_prices = df_curr['EURUSD']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse

```

Продовження додатку Г

```
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape

data = df_curr.filter(['EURUSD'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['EURUSD', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()
```

Реалізація моделі CNN+GRU за допомогою мови програмування Python на прикладі BTC/USD та EUR/USD

```
import pandas as pd
import numpy as np
import datetime
from matplotlib import style
import matplotlib.pyplot as plt
import keras
from keras.models import Model
from keras.layers import LSTM, Flatten, Dense, Dropout, Input, Activation, BatchNormalization
from keras.layers.convolutional import Conv1D, MaxPooling1D
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_percentage_error, r2_score, mean_absolute_error
import math
import yfinance as yf
import tensorflow as tf
from google.colab import files

# Ignore warnings
import warnings
warnings.filterwarnings('ignore')

model = keras.Sequential()
model.add(Conv1D(filters=100, kernel_size=2, activation='relu', input_shape=(x_train.shape[1], x_train.shape[2])))
model.add(MaxPooling1D(pool_size=2))
model.add(GRU(units=100, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(units=25))
model.add(Dense(units=1))
model.summary()

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(x_train, y_train, batch_size=1, epochs=100)

stock_data = yf.download('BTC-USD', start='2022-01-01', end='2023-03-31')
stock_data.head()

plt.figure(figsize=(8, 4))
plt.title('Bitcoin Prices History')
plt.plot(stock_data['Close'])
plt.xlabel('Date')
```

Продовження додатку Д

```

plt.ylabel('Prices ($)')
close_prices = stock_data['Close']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape
data = stock_data.filter(['Close'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['Close', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()

```

Продовження додатку Д

```

uploaded = files.upload()

df_curr = pd.read_csv('База_диплом.csv', sep=',')
df_curr = df_curr.set_index(['Date'])
df_curr.drop(['BTCUSD', 'ETHUSD', 'USDTUSD', 'USDJPY', 'GBPUSD'], axis = 1,
inplace = True)
df_curr = df_curr.sort_values('Date')
df_curr.head()

plt.figure(figsize=(8, 4))
plt.title('EUR/USD Prices History')
plt.plot(df_curr['EURUSD'])
plt.xlabel('Date')
plt.ylabel('Prices ($)')

close_prices = df_curr['EURUSD']
values = close_prices.values
training_data_len = math.ceil(len(values)* 0.85)

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(values.reshape(-1,1))
train_data = scaled_data[0: training_data_len, :]

x_train = []
y_train = []

for i in range(30, len(train_data)):
    x_train.append(train_data[i-30:i, 0])
    y_train.append(train_data[i, 0])

x_train, y_train = np.array(x_train), np.array(y_train)
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))

test_data = scaled_data[training_data_len-30: , : ]
x_test = []
y_test = values[training_data_len:]

for i in range(30, len(test_data)):
    x_test.append(test_data[i-30:i, 0])

x_test = np.array(x_test)
x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)
rmse = np.sqrt(np.mean(predictions - y_test)**2)
rmse

```

Продовження додатку Д

```
mae = mean_absolute_error(y_test, predictions)
mae
mape=np.mean(np.abs((y_test-predictions)/y_test))*100
mape

data = df_curr.filter(['EURUSD'])
train = data[:training_data_len]
validation = data[training_data_len:]
validation['Predictions'] = predictions
plt.figure(figsize=(10,6))
plt.title('Model')
plt.xlabel('Date')
plt.ylabel('Close Price USD ($)')
plt.plot(train)
plt.plot(validation[['EURUSD', 'Predictions']])
plt.legend(['Train', 'Val', 'Predictions'], loc='lower right')
plt.show()
```