

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ  
Кафедра прикладної математики та моделювання складних систем

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА  
спеціальності «Прикладна математика»

**МОДЕЛЮВАННЯ ПРИЧИННО-НАСЛІДКОВИХ ЗВ'ЯЗКІВ ІНСТРУМЕНТІВ  
ФІНАНСОВОГО РИНКУ**

Завідуючий випускною кафедрою

професор,  
доктор фіз.-мат. наук  
О.В. Лисенко

Керівник роботи

к.е.н., доцент кафедри  
ПМ та МСС  
Т.О. Маринич

Виконавець

студент гр. ПМ-51  
С.В. Смоленко

Затверджено на засіданні кафедри «\_\_\_» \_\_\_\_\_ 2019 р.,  
протокол № \_\_\_\_\_

Суми - 2019

## РЕФЕРАТ

Назва документа: кваліфікаційна робота бакалавра на тему «Моделювання причинно-наслідкових зв'язків інструментів фінансового ринку».

Ключові слова: МОДЕЛЮВАННЯ, ФІНАНСОВИЙ РИНОК, ВАЛЮТНИЙ КУРС, ПРОГНОЗУВАННЯ, КАУЗАЛЬНІСТЬ, АНАЛІЗ ДАНИХ, «PROXY» ЗМІННІ.

Метою даної роботи є підбір оптимальних методів моделювання нестійких часових рядів, які забезпечують високі прогностні властивості та враховують вплив зовнішніх факторів з використанням «проху» змінних.

Предметом даного дослідження є моделі авторегресії, каузальні моделі, моделі машинного навчання, які в подальшому можуть бути використані для опису і прогнозування часових рядів в умовах обмеженої інформації.

Об'єктом дослідження є соціально-економічні явища, що виникають в процесі функціонування валютного ринку країни.

Аналітичний огляд містить відомості про механізми функціонування фінансового ринку; короткий опис класичних моделей прогнозування часових рядів разом з моделями машинного навчання та аналіз джерел походження даних. Основна частина складається з практичної реалізації, в якій було виконано попередній аналіз часового ряду, досліджено кореляційні та причинно-наслідкові зв'язки між змінними, побудовано різного роду моделі для прогнозування офіційного курсу долара, серед яких: TBATS, ARIMA та нейронні мережі.

У кінці документа описані отримані висновки та виділені оптимальні моделі.

У додатках містяться коди програм, перша з яких отримувала та обробляла дані про офіційний валютний курс, а інша передбачала підготовку даних та їх аналіз. Також в додатках є результати проведення тесту Грейнджера на каузальність.

Кількість сторінок: 90.

Кількість рисунків: 28.

Кількість таблиць: 19.

Кількість формул: 36.

Кількість використаних джерел: 46.

Кількість додатків: 5.

## ЗМІСТ

ВСТУП .....	4
1 АНАЛІТИЧНИЙ ОГЛЯД .....	6
1.1 Механізм функціонування фінансового ринку.....	6
1.2 Підходи та методи моделювання часових рядів.....	10
1.2.1 Класичні моделі часових рядів.....	10
1.2.2 Аналіз часових рядів методами машинного навчання.....	17
1.3 Огляд джерел даних соціально-економічних процесів.....	20
2 ПРАКТИЧНА РЕАЛІЗАЦІЯ .....	23
2.1 Опис даних .....	23
2.2 Підготовка даних для аналізу.....	26
2.3 Аналіз даних.....	29
2.3.1 Візуалізація та початковий аналіз .....	29
2.3.2 Побудова базової моделі.....	35
2.3.3 Модель TBATS .....	38
2.3.4 Моделі ARIMA без урахування впливових факторів .....	42
2.3.5 Моделі ARIMA з урахуванням впливових факторів.....	44
2.3.6 Нейронні мережі без урахування впливових факторів .....	47
2.3.7 Нейронні мережі з урахуванням впливових факторів .....	49
2.3.8 Вибір кращої моделі та її дослідження.....	51
ВИСНОВКИ.....	58
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ .....	59
ДОДАТОК А.....	64
ДОДАТОК Б .....	66
ДОДАТОК В .....	85
ДОДАТОК Г .....	87
ДОДАТОК Д.....	89

## ВСТУП

Людство завжди прагне бути готовим до будь-яких ситуацій. Прогнозування різного роду явищ стало неодмінною часткою багатьох наукових досліджень. Прогрес не стоїть на місці, технології змінюються дуже швидко. Використання потужностей сучасних комп'ютерів із вміло підібраними математичними методами та характеристиками згідно доменної галузі дають можливість доволі точно прогнозувати динаміку змінних, що мають високу мінливість.

Валютний курс в Україні через проблеми з економікою, нестабільною політичною ситуацією в країні, соціальні настрої та інші негативні фактори є надзвичайно нестабільним показником. Прогнозування валютного курсу є актуальним як на макрорівні – для укладання бюджету країни, оцінювання потоків платіжного балансу, формування цін, так і на мікрорівні – як орієнтир фінансової стабільності та співвідношення цін і доходу.

Надзвичайно широке коло факторів, неструктурованість даних, обмеженість у доступі та затримка у часі з їх оприлюдненням, ускладнюють аналіз і моделювання даних валютного курсу. Це актуалізує задачу пошуку нестандартних методів визначення «ргоху» змінних, що за умови обмеженої інформації щодо вхідних даних. Останнім часом все більше уваги дослідників приділяється вивченню чинників, що демонструють очікування щодо того чи іншого показника, або опису семантики новин та їх обговорень у різних медіа. Відповідно, моделювання таких часових рядів потребує пошуку нових інструментів та методів прогнозування, каузального аналізу, що враховують зміну даних в режимі реального часу.

*Метою* даної роботи є підбір оптимальних методів моделювання нестійких часових рядів, які забезпечують високі прогнозні властивості та враховують вплив зовнішніх факторів з використанням «ргоху» змінних.

*Предметом* даного дослідження є моделі авторегресії, каузальні моделі, моделі машинного навчання, які в подальшому можуть бути використані для опису і прогнозування часових рядів в умовах обмеженої інформації.

*Об'єктом* дослідження є соціально-економічні явища, що виникають в процесі функціонування валютного ринку країни.

Емпіричними даними в роботі виступають дані Національного банку України (НБУ) щодо офіційного курсу гривні до долара США у період з 1 листопада 2013 року по 1 січня 2019 року. В якості чинників, що мають вплив на коливання валютного курсу, були використані фінансові показники НБУ; індекси умов торгівлі, висвітлені Державною службою статистики України; дані про міжнародні ціни на основні імпорتنі та експортні товари, узяті з сайту [investing.com](http://investing.com); «проху» змінними, які б відображали очікування, були дані щодо індексів популярності запитів у пошуковій системі Google. Програмна реалізація здійснена у інтегрованому середовищі RStudio та Python Notebook, використане програмне забезпечення EViews.

Відповідно до мети дослідження, у роботі досліджуються такі *задачі*:

1. Вивчення доменної галузі (механізм роботи фінансового та валютного ринків; формування валютного курсу; визначення впливових факторів та «проху» змінних).
2. Пошук джерел даних для дослідження соціально-економічних явищ та валютного ринку, зокрема.
3. Огляд традиційних методів моделювання та моделей машинного навчання для аналізу нестійких часових рядів з обмеженими вхідними даними.
4. Підготовка та попередній статистичний аналіз даних дослідження.
5. Аналіз лінійних стохастичних та каузальних (причинно-наслідкових) зв'язків.
6. Специфікація, оцінювання, верифікація та порівняння моделей.
7. Прогнозування валютного курсу.
8. Підведенні підсумків дослідження.

# 1 АНАЛІТИЧНИЙ ОГЛЯД

## 1.1 Механізм функціонування фінансового ринку

Сучасна економіка розвинутих країн має ринковий характер, оскільки саме ринкова система виявилась найбільш ефективною та гнучкою для вирішення економічних проблем. Фінансовий ринок є доволі загальним поняттям, яке описує певне особливе та необхідне середовище для успішного функціонування економіки розвинутої країни, що відображає попит і пропозицію фінансових ресурсів та має на меті звести одне з одним постачальників і споживачів фінансів. Свій регуляторний вплив на діяльність ринку держава здійснює шляхом установаження облікової ставки, обсягів грошової маси, регулювання валютного курсу тощо [1, с. 6; 2, с. 19].

Зв'язок між економіками різних країн здійснюється через торгівлю товарами, послугами та через фінансові операції. Основами валютних відносин виступають товарне виробництво, торгівля, надання послуг, рух капіталу між країнами тощо. Посередниками в них виступають гроші. В результаті складаються валютні відносини, пов'язані з функціонуванням грошей у світовому господарстві. Саме вони відображають обмін результатами діяльності національних господарств та міжнародних інститутів [3, с. 663].

Таким чином, неодмінною ланкою загального фінансового ринку є валютний ринок, де товаром для купівлі та продажу стають національні валюти різних країн та платіжні документи, виражені в іноземній валюті. Незважаючи на те, що в міжнародних обмінах валют беруть участь різноманітні валюти, більшість угод (приблизно 70%) являє собою обмін валюти країни на долар США. Завдяки такій ролі долар називають резервною валютою [4, с. 109; 5, с. 648]. Зважаючи на цей факт, ми і вирішили в нашому аналізі досліджувати саме співвідношення української гривні та долара США.

Валютним курсом є певне співвідношення між грошовими одиницями (валютами) різних країн. Він являє собою своєрідну «ціну» валюти однієї країни, виражену у валютах інших країн. Залежно від типу грошової системи країни

валютний курс може визначатися ринком або встановлюватися уповноваженими державою органами [4, с. 89].

Формування валютного курсу залежить від режиму валютного курсу, що підтримується центральним банком країни. Відрізняють *плаваючий* та *фіксований* режими тим, що в режимі плаваючого валютного курсу він вільно коливається згідно ринкової ситуації, а під час режиму фіксованого валютного курсу він є офіційно встановленим співвідношенням між національними валютами, заснованим на валютних паритетах, які визначаються в законодавчому порядку [6].

В Україні діє режим плаваючого валютного курсу, причому регуляторну роль на ринку валюти займає Національний банк України, а основним його механізмом є формування офіційного курсу валют.

Валюта, по суті, є товаром, на який існує певний попит та пропозиція, тому її ціна формується згідно із законом попиту та пропозиції. Виходячи з концепцій і теорій валютного курсу, еволюція яких налічує вже майже 100 років (теорії платіжного балансу, макроекономічної рівноваги, паритету купівельної спроможності, гіперреакції валютного курсу, грошової і загальної теорії, моделі П. Кругмана), можна виділити чинники, що впливають на попит і пропозицію на іноземну валюту, а отже, і на динаміку валютного курсу:

- 1) внутрішні структурні фактори (темпи зростання внутрішнього кредиту, реального ВВП (валовий внутрішній продукт), пропозиції грошей, темпів інфляції, рівень цін і відсоткових ставок, відношення профіциту/дефіциту бюджету до ВВП);
- 2) міжнародні фактори (показники зовнішнього боргу, золотовалютних резервів, стану платіжного балансу, умови торгівлі);
- 3) зовнішні фактори (середньозважена ставка відсотку в індустріальних країнах, темпи зростання реального ВВП в країнах Організації економічного співробітництва і розвитку);
- 4) кон'юнктурні фактори (державне регулювання валютного курсу, ступінь довіри до валюти на національному і світових ринках, спекулятивні потоки капіталів) [7, с. 187].

До попиту можна віднести імпорт, збільшення міжнародних активів, повернення міжнародних зобов'язань, процентні виплати за міжнародними зобов'язаннями, а також зняття іноземної валюти населенням; до пропозиції – експорт, збільшення міжнародних зобов'язань, повернення іноземних активів, процентний дохід від іноземних активів та нові депозити в іноземній валюті [8]. Закон попиту та пропозиції можна відобразити за допомогою наступної схеми (Рис. 1.1).

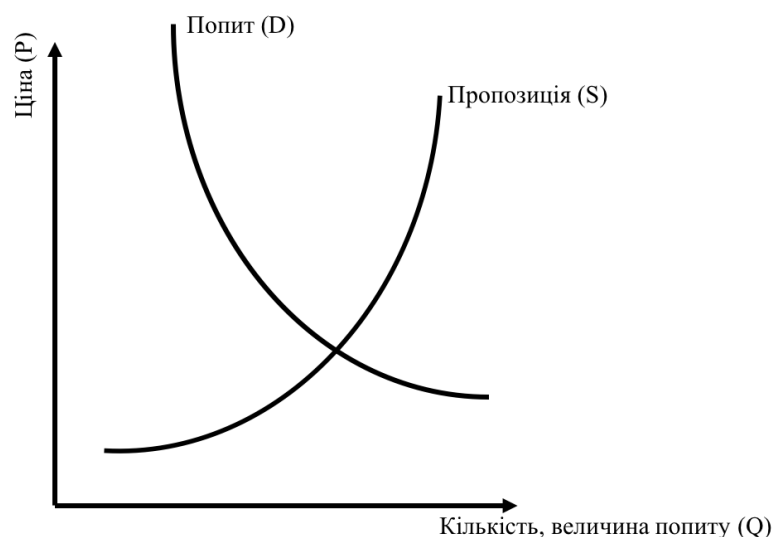


Рисунок 1.1 – Графічне відображення закону попиту та пропозиції

Рівноважна ціна на ринку встановлюється в точці перетину кривих попиту та пропозиції. Проте, ця ціна не завжди є прийнятною для економіки з боку регулюючого органу. Тому, центральні банки країн (для України – НБУ), які застосовують фіксований валютний курс, зобов'язані підтримувати його шляхом здійснення валютних інтервенцій у випадку руху точки перетину кривих попиту та пропозиції від необхідної ціни [6]. Тобто, у випадку занадто великої пропозиції іноземної валюти НБУ буде викупати на ринку її надлишки, тим самим поповнюючи свої резерви та не допускаючи здешевлення валюти; у випадку занадто високого попиту НБУ буде змушений виступати продавцем валюти, спустошуючи свої резерви та не допускаючи подорожчання валюти. Звісно, якщо резерви центрального банку не дозволяють йому виступати на ринку тим, хто продає валюту, курс буде мати тенденцію до стрімкого росту.



Вітчизняні фахівці у своїх дослідженнях підтверджують значну роль як фундаментальних, так і ситуаційних факторів на формування валютного курсу гривні. Наприклад, у дисертаційному дослідженні Маринич Т.О. встановлено довгострокові зв'язки міжбанківського валютного курсу гривні до долара США з такими економічними показниками:

- сальдо бюджету;
- рівень монетизації M2/ВВП;
- рівень доларизації;
- грошова база;
- відношення золотовалютних резервів до імпорту товарів і послуг;
- норматив банківського капіталу H2;
- індекс зростання реального ВВП;
- відношення зовнішнього боргу до ВВП [7, с. 13].

Говорячи про неочевидні фактори впливу на валютний курс, можна звернутися до книги Імада А. Моза та Рацаке Х. Бхатті (Imad A. Moosa & Razzaque H. Bhatti) «The theory and empirics of exchange rates», де вони одному із розділів підсумовують висновки багатьох досліджень щодо того, як очікування на валютному ринку впливає на нього. Автори торкаються теми того, що учасники ринку скоріше пасивно прогнозують події, а не викликають їх. Саме цей зв'язок і є цікавим для нас. Тобто, наводячи приклад із населенням країни – якщо населення, засновуючись на своїх спостереженнях, отриманої інформації чи чогось іншого, очікує зростання величини валютного курсу та починає масово скуповувати іноземну валюту, то саме це і викличе її подорожчання [9].

Отже, зрозуміло, що ціна іноземної валюти залежить від багатьох факторів, які впливають на попит та пропозицію на ринку. У нашій роботі пропонуємо ознайомитися із впливом на валютний курс як фундаментальних (тобто, очевидних економічних) факторів, так і факторів очікування населення. Використані нами дані будуть детально описані у наступному розділі.

## 1.2 Підходи та методи моделювання часових рядів

### 1.2.1 Класичні моделі часових рядів

Часовий ряд – це послідовність упорядкованих у часі числових показників, що характеризують рівень стану та зміни досліджуваного явища [10].

Для часових, як і для звичайних, рядів існують основні числові характеристики: математичне сподівання (середнє значення) та дисперсія (тобто, міра розкиду значень навколо середнього), які обчислюються за формулами для періоду часу  $t$  [11, с.9]:

$$\mu_t = E(y_t) = \int_{-\infty}^{\infty} x dF_t(x), \text{ де } F_t = P\{y_t < x\}, \quad (1.1)$$

$$\text{var}(y_t) = E(y_t - E(y_t))^2. \quad (1.2)$$

Попередній аналіз часових рядів включає:

- перевірку стаціонарності (тобто, відсутність тренду та сталість середнього із дисперсією);
- дослідження розподілу;
- декомпозиція компонентів ряду;
- вивчення можливих зв'язків між змінними:
  - кореляційний аналіз – дослідження лінійних стохастичних адитивних зв'язків;
  - каузальний аналіз - оцінювання причинно-наслідкових зв'язків.

Часто стаціонарність легко перевірити, виконавши візуальний аналіз – після побудови графічного зображення ряду даних визначити наявність сезонності та трендів (лінійного чи нелінійного). Для перевірки правильності висновку, зробленого на основі візуального аналізу, можна використати формальні економетричні методики, серед яких:

- автокореляційна (корелограма) та часткова автокореляційна функція для рівнів часових рядів, їх перших та других різниць;
- тест на наявність одиничних коренів – розширений тест Дікі-Фуллера (ADF).

Для стаціонарних рядів корелограма та графік часткової автокореляційної функції мають стрімко спадати зі збільшенням  $t$ . Причому, гіпотеза про відсутність

автокореляції до  $k$ -го лагу перевіряється за використанням  $Q$ -статистики Лjung-Бокса та її  $p$ -значення [7, с. 282].

Стаціонарність є однією з ключових передумов для побудови параметричних моделей прогнозування. Якщо ряд не є стаціонарним, то, зазвичай, стаціонарність таких часових рядів забезпечується одним із методів усунення тренду, наприклад, за допомогою різниць першого або вищого порядків.

Декомпозицію часового ряду можна описати наступними формулами, перша з яких є адитивною, а друга – мультиплікативною, вибір на користь яких залежить від конкретних часових рядів:

$$TS = L + Tr + S + \varepsilon, \quad (1.3)$$

$$TS = L \cdot Tr \cdot S \cdot \varepsilon, \quad (1.4)$$

де  $TS$  – часовий ряд;  $L$  – «рівень», значення середнього;  $Tr$  – тренд (тенденція);  $S$  – компонента сезонності;  $\varepsilon$  – шум, випадкова складова [12].

Для кореляційного аналізу використовується коефіцієнт кореляції Пірсона, що показує наявність та характер лінійної залежності між факторами та обчислюється за формулою:

$$r_{XY} = \text{corr}(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad (1.5)$$

де  $X_i, Y_i$  –  $i$ -ті спостереження відповідних факторів;  $\bar{X}, \bar{Y}$  – математичні очікування відповідних факторів.

Звісно, існування цього зв'язку не гарантує причинно-наслідкових взаємозв'язків між двома факторами, проте це дозволяє виявити статистично залежні величини.

Враховуючи те, що дані, використані у дослідженнях є факторами змінними у часі та відсортованими за часовим показником (часові ряди), причому ми намагаємося виявити причинно-наслідкові між ними, то в дослідженні також було оцінено коефіцієнт кореляції Пірсона між  $n$ -ми (в сенсі періоду) значеннями офіційного валютного курсу та  $(n - 1)$ -ми значеннями інших факторів. Тобто, я аналізував ступінь зв'язку попередніх даних про фактор  $X$  та поточного значення  $Y$  за формулою:

$$r_{XY_{-1}} = \text{corr}(X, Y_{-1}) = \frac{\sum_{i=2}^n (X_i - \bar{X}) \cdot (Y_{i-1} - \bar{Y})}{\sqrt{\sum_{i=2}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^{n-1} (Y_i - \bar{Y})^2}}. \quad (1.6)$$

Кореляція лише констатує наявність спільного тренду, а не відображає причинно-наслідкові зв'язки між досліджуваними змінними [19, с. 111-120]. Це обумовлено нестационарністю більшості часових рядів макроекономічних змінних, яка проявляється у залежності їх математичного сподівання, дисперсії та автоковаріації від часу [20, с. 5-38]. Для дослідження каузальності можна звернутися до *тесту Грейнджера* на наявність причинно-наслідкового зв'язку між ними. Ідея даного тесту полягає в тому, що змінна  $X$  є каузальною по відношенню до  $Y$ , якщо за інших рівних умов, значення  $Y$  можуть бути краще передбачені минулими значеннями  $X$ , ніж без них [24, с. 424-438]. При цьому мають виконуватися дві умови:

- фактор  $X$  має робити внесок у прогноз фактора  $Y$ ;
- $Y$  не повинен значно впливати на прогноз  $X$ .

Якщо між факторами  $X$  та  $Y$  існує взаємний зв'язок, тобто кожна змінна робить значний внесок у прогноз іншої, то скоріше за все існує третя змінна  $Z$ , що впливає на попередні дві [7, с. 281].

Тест Грейнджера передбачає побудову двовимірних авторегресійних моделей:

$$\begin{aligned} Y_t &= a_0 + a_1 Y_{t-1} + \dots + a_p Y_{t-p} + b_1 X_t + \dots + b_p X_{t-p} \\ X_t &= a_0 + a_1 X_{t-1} + \dots + a_p X_{t-p} + b_1 Y_t + \dots + b_p Y_{t-p}, \end{aligned} \quad (1.7)$$

де  $p$  – порядок авторегресії кожної пари часових рядів  $X_t, Y_t$  [18, с. 275].

Нульовою гіпотезою в даному випадку є гіпотеза про рівність усіх коефіцієнтів нулю, тобто відсутність впливу  $X$  на  $Y$  та  $Y$  на  $X$ . Для її відхилення застосовується  $F$ -статистика та показник імовірності  $p$  (від слова probability – ймовірність) на рівні значущості 5%. Також необхідно зазначити, що тест Грейнджера дає різні результати відповідно до кількості лагів (лаг є величиною, яка характеризує кількість періодів «запізнення» у впливі фактора на результуючу змінну) у моделі. З точки зору економічної теорії доцільно проводити тест до шести операторів лагу (лаговий оператор позначається літерою  $p$ ) [7, с. 281].

Після попереднього аналізу часових рядів, можна переходити до їх прогнозування. Вибір найкращої моделі для використання залежить від характеру та розміру історичних даних, міцності взаємозв'язків між змінною прогнозу та будь-яких пояснювальних змінних, а також способу використання прогнозів. Звичайно, найкращою тактикою є побудова декількох моделей з подальшим їх порівнянням. Кожна модель сама по собі є штучною конструкцією, яка базується на наборі припущень (явних і неявних) і зазвичай включає один або більше параметрів, які повинні бути оцінені з використанням відомих історичних даних [13].

Найпростішими моделями для такого роду досліджень є звичайні *лінійні регресійні*. На меті вони мають пошук лінійного зв'язку між цільовою та пояснювальними змінними.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon, \quad (1.8)$$

причому одним із найчастіше використовуваних методів для оцінки коефіцієнтів даної моделі є метод найменших квадратів, який передбачає мінімізацію величини суми квадратів відхилень прогнозів від реальних значень. Серед переваг лінійної регресії є висока інтерпретативність, можливість використовувати для прогнозу різні фактори та компоненти часового ряду, серед недоліків – висока чутливість до викидів та необхідність виконання припущень [13, 14].

Наступними моделями є *моделі експоненціального згладжування*. Прогнози, отримані за допомогою експоненціальних методів згладжування, – це середньозважені величини минулих спостережень, причому ваги розподіляються в геометричній прогресії з «старінням» спостережень. Іншими словами, чим новіше спостереження, тим вища пов'язана з ним вага. В математичній формі можна виразити наступним чином:

$$S_t = \alpha y_{t-1} + (1 - \alpha) S_{t-1}, \quad 0 < \alpha \leq 1, \quad (1.9)$$

де в  $S_t$  – згладжене спостереження,  $y_{t-1}$  – оригінальне спостереження за минулий період,  $\alpha$  – константа згладжування [13, 15].

Ця структура генерує надійні прогнози швидко і для широкого кола часових рядів, що є великою перевагою і має велике значення для застосування в

промисловості. Серед недоліків виділяють чутливість до викидів та вузьку ширину довірчих інтервалів [13, 14].

*Моделі ARIMA* забезпечують інший підхід до прогнозування часових рядів. Хоча експоненціальні моделі згладжування базуються на описі тенденцій і сезонності даних, моделі ARIMA мають на меті описати автокореляції в самих даних. Вони поєднують в собі обидві моделі авторегресії (AR) і ковзного середнього (MA), а також етап диференційованої попередньої обробки послідовності, щоб зробити послідовність стаціонарною (називають інтеграцією (I)) [13, 16]. Зважаючи на те, що ARIMA моделі є комбінацією вищезазначених, то математичне підґрунтя може бути вираженим наступним чином:

- авторегресійна модель:

$$X_t = c + \sum_{i=1}^p \varphi_i \cdot X_{t-i} + \varepsilon_t, \quad (1.10)$$

де  $p$  – параметр, який вказує, скільки минулих (лагових) спостережень необхідно прийняти до аналізу;  $\varphi_i$  – вагові коефіцієнти;

- інтегрування (перетворення, що застосовується до даних часових рядів, щоб зробити його стаціонарним):

$$y_t^* = y_t' - y_{t-1}' = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) = y_t - 2y_{t-1} + y_{t-2}; \quad (1.11)$$

- ковзне середнє (використовує залежність між спостереженням і залишковою помилкою від моделі ковзного середнього, застосованої до лагових спостережень):

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \quad (1.12)$$

де  $q$  – параметр, який вказує, скільки минулих спостережень необхідно прийняти до аналізу [17].

ARIMA моделі можна описати наступним чином:

$$X_t' = c + \sum_{i=1}^p \varphi_i \cdot X_{t-i}' + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \quad (1.13)$$

де  $X_t'$  – диференційований часовий ряд, а інші змінні відповідають своїм попереднім значенням з формул (1.7) – (1.9) [13].

До переваг моделей ARIMA відносять високу інтерпретативність, реалістичні довірчі інтервали, об'єктивні прогнози, серед недоліків – необхідність наявності

доволі великої кількості спостережень, складність повної автоматизації, необхідне дотримання строгих обмежень та припущень [14].

Описані моделі часових рядів опираються на інформацію з попередніх спостережень, але не враховують інші параметри, які також можуть бути важливими. Наприклад, вплив свят, діяльності конкурентів, зміни в законах, економіці в цілому або інші зовнішні змінні можуть пояснити деякі історичні відмінності та призвести до більш точних прогнозів. Саме таке враховують *динамічні регресійні моделі*:

$$Y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_n X_{n,t} + \eta_t, \quad (1.14)$$

причому у звичайній регресії похибка за припущенням не є корельованою ні з чим, а в даній моделі припускається, що похибка  $\eta_t$  може бути автокорельованою та відповідати моделі ARIMA [13].

Переваги динамічних регресійних моделей – висока інтерпретативність, вважаються більш прозорими за інші моделі, доволі добре працюють в умовах невизначеності, контролюють дисперсію пояснювальних змінних, недоліки включають в себе велику кількість часу на навчання і оцінку, вищу “holdout” помилку (помилка прогнозу моделі після її валідації на даних, які модель не «бачила») [14].

Аналіз та прогнозування часових рядів також проводиться на базі моделей *векторних авторегресій (VAR)* та *моделей корекції помилки (VEC)*. Говорячи про прогнозування соціально-економічних явищ, для країн з перехідною економікою, де більшість економічних законів не працює через недостатній розвиток інститутів фінансового ринку, політичну заангажованість суб’єктів грошово-кредитного регулювання та постійні структурні зміни економіки, використання таких підходів набуло особливої актуальності. Зазначені моделі використовують для оцінювання причинно-наслідкових зв’язків коротких часових рядів із значною варіацією статистичних даних, вони виступають альтернативою структурним моделям.

При переході до регресійних моделей, що базуються на рядах, заданих у різницях (наприклад, перших логарифмічних різницях, які приблизно відповідають темпам приросту), на виході отримуємо лише короткострокової прогнозні дані, інформація довгострокового характеру, яка міститься в рівнях відповідних змінних, при цьому

втрачається [21]. Вказана проблема успішно розв'язується за допомогою нового напрямку економетрії – *моделей корекції помилки (Vector Error Correction, VEC)*, які включають у рівняння регресії поряд із першими різницями, що відображають короткострокову динаміку, механізм корекції помилки, який характеризує довгострокові економічні ефекти [22, с. 111-153]. Перевагою VEC є використання інформації в рівнях, приймаючи до уваги причинні взаємозв'язки, а також проблеми нестационарності і значні випадкові збурення рядів даних [23, с. 498-523].



### 1.2.2 Аналіз часових рядів методами машинного навчання

Хоча методи машинного навчання беруть свою історію з кінця 20 сторіччя, високу популярність вони починають набувати саме зараз, коли потужності обчислювальної техніки зростають.

Машинне навчання є формою штучного інтелекту, яка дозволяє системі навчатися на даних, а не через явне програмування з боку людини. Машинне навчання використовує різні алгоритми, які ітеративно вивчають дані для їх поліпшення чи опису та прогнозування необхідних результатів, засновуючись на певній інформації [25, с. 4].

Через те, що практичній частині ми будемо прогнозувати офіційний курс гривні та шукати зв'язки між факторами, що на нього впливають, то у цьому підрозділі пропоную розглянути таке застосування машинного навчання як регресія (точніше, її пошук). Регресія є формою зв'язку між величинами. Тут ми маємо на меті оцінити значення однієї змінної, опираючись на значення інших. Наприклад, можна оцінювати рівень здоров'я спортсменів, опираючись на показники їх аналізів; можна прогнозувати величину зміни однієї величини за умови зміни іншої тощо [26, с. 11].

У роботі Спіроса Макрідакіса та ін. наводиться ранжований список з восьми сімейств моделей машинного навчання. Вони відсортовані за спаданням їх експериментально визначеної точності:

1. Багатошаровий перцептрон (Multi-Layer Perceptron, MLP).
2. Байєсові нейронні мережі (Bayesian Neural Network, BNN).
3. Радіальні базисні функції (Radial Basis Functions, RBF).
4. Узагальнені регресійні нейронні мережі (Generalized Regression Neural Networks, GRNN).
5. Регресія К-найближчих сусідів (K-Nearest Neighbor regression, KNN).
6. Регресійні та класифікаційні дерева (Classification And Regression Trees, CART).
7. Метод опорних векторів (Support Vector Regression, SVR).
8. Гаусові процеси (Gaussian Processes, GP) [27, с. 4].

В якості показника точності використовувався sMAPE (symmetric Mean Absolute Percentage Error) – симетрична середня абсолютна помилка у відсотках, яка обчислювалась за наступною формулою:

$$sMAPE = \frac{2}{k} \cdot \sum_{t=1}^k \frac{|Y_t - \hat{Y}_t|}{|Y_t| + |\hat{Y}_t|} \cdot 100\%, \quad (1.15)$$

де  $k$  – кількість періодів для прогнозу (forecasting horizon),  $Y_t$  – фактичні значення спостережень,  $\hat{Y}_t$  – оцінки значень спостережень [27, с. 5].

Зважаючи на те, що найкраще себе показала модель багатошарового перцептрона (Multi-Layer Perceptron, MLP), ми вирішили використати саме її в нашому подальшому дослідженні.

Багатошаровий перцептрон (MLP) є нейронною мережею, яка з'єднує кілька шарів в орієнтованому графі. Це означає, що шлях сигналу через вузли йде лише в одному напрямку. Кожен вузол, крім вхідних вузлів, може мати функцію нелінійної активації чи вагу. MLP використовує зворотне поширення помилки як методику навчання із вчителем (supervised learning). Оскільки існує кілька шарів нейронів, MLP вважається технікою глибокого навчання (deep learning). MLP широко використовується для вирішення завдань, які включають розпізнавання мовлення, розпізнавання зображень, прогнозування, класифікацію та машинний переклад [28].

Схематичне зображення перцептрона із одним прихованим шаром знаходиться на Рис. 1.2.




Рисунок 1.2 – Схематичне зображення перцептрона із одним прихованим шаром [29]

MLP видає на виході одне значення, засноване на декількох реальних вхідних потоках, формуючи їх лінійну комбінацію, використовуючи свої вхідні ваги (і іноді передаючи вихід через нелінійну функцію активації). За допомогою математики це можна записати наступним чином:

$$y = \varphi(\sum_{i=1}^n \omega_i x_i + b) = \varphi(W^T X + B), \quad (1.16)$$

де  $W$  позначає вектор ваг,  $X$  – вхідний вектор,  $B$  – зміщення (bias), а  $\varphi$  – нелінійна активаційна функція [30].

Говорячи про переваги та недоліки моделей машинного навчання в прогнозуванні, необхідно сказати, що серед переваг є те, що такі моделі містять меншу кількість припущень та обмежень; дають можливість мати справу із складними нелійними зв'язками, високу прогнозовну силу та можливість легкої автоматизації, а серед недоліків мають майже відсутню можливість інтерпретувати коефіцієнти моделі та виділити довірчі інтервали; також такі моделі потребують велику кількість даних для тренування [14].

### 1.3 Огляд джерел даних соціально-економічних процесів

Через те, що дана кваліфікаційна робота спрямована на дослідження причинно-наслідкових зв'язків інструментів фінансового ринку, в аналітичному огляді пропонуємо ознайомитися з джерелами походження даних, які дають можливість виявити бажані зв'язки між факторами, які мають вплив на соціально-економічні явища.

Державним органом, який організовує та проводить статистичні спостереження за соціально-економічними та демографічними явищами та процесами, екологічною ситуацією в Україні та її регіонах, є Державна служба статистики України, яка через свої ресурси надає доступ до такого роду даних. Дані Держстату доступні для завантаження та перегляду через головний веб-сайт <http://ukrstat.gov.ua> та через сайти регіональних представництв, якщо необхідно здобути дані в розрізі регіонів, які відсутні на загальноукраїнському рівні. За допомогою вказаних ресурсів можна здобути дані, наприклад, щодо кількості населення в Україні, середньої зарплатні, кількість викидів забруднюючих речовин у повітря, ВВП, кількості скоєних злочинів тощо [31].

Іншим державним органом, який забезпечує збирання, складання та поширення даних фінансового та зовнішнього секторів економіки, є Національний банк України (НБУ). За допомогою розділу «Статистика» на сайті офіційного інтернет-представництва можна знайти, переглянути та завантажити дані щодо грошово-кредитної та фінансової статистики (наприклад, огляди фінансових корпорацій, депозити, кредити, процентні ставки депозитних корпорацій, цінні папери, фінансові рахунки сектору фінансових корпорацій); статистики платіжного балансу, міжнародної інвестиційної позиції та зовнішнього боргу; міжнародних резервів та курсів обміну валют; статистики індикаторів фінансової стійкості тощо [32].

Джерелами даних, що відображають фінансове, політичне, соціальне та екологічне благополуччя різних країн та світу в цілому можуть стати веб-сайти міжнародних організацій, таких як: Світовий банк, ООН, ЮНЕСКО, НАТО тощо.

Також для оцінки економічної ситуації часто в аналіз беруть дані про котирування цін на товари та цінні папери на міжнародних фінансових та товарних

ринках. Прикладом ресурсів для отримання такого роду даних можуть бути веб-сайти міжнародних бірж (фондові, товарні, валютні, ф'ючерсні, криптовалюти, універсальні); сайти-агрегатори, що збирають інформації з різних джерел та відображають її у зручному для користувача форматі (наприклад, у вигляді графіків часових рядів) з можливістю завантажити ці дані на безоплатній чи платній основі, в залежності від ресурсів.

Оскільки наш світ стає все більше і більше діджиталізованим, то для аналізу соціально-економічних явищ важливими стають дані про населення, що відображаються у наших цифрових слідах, які ми залишаємо, будучи «он-лайн». Пости у Twitter, Facebook, Instagram, переглянуті відео в YouTube, звичайні пошуки в Google, інформація про покупки в інтернет-магазинах, кількість та довжина наших розмов у Skype та навіть у звичайних мобільних операторів – все це збирається великими корпораціями. Проте, необхідно зазначити, що вищезазначені дані майже завжди є недосяжними для звичайних користувачів. Наприклад, Twitter за допомогою API (application programming interface) дозволяє виконувати пошук та аналізувати кількість постів з конкретними хештегами лише за обмежений короткий період (безкоштовно – 7 днів, платно – від 30 днів) [33]; дані щодо покупок в інтернет-магазинах є конфіденційними та відкриті тільки для цих магазинів чи інших компаній, з якими у платформ продажу існують договори (наприклад, для таргетування реклами) тощо.

Останнім часом популярними стають дослідження даних, що включають в себе обробку природної мови (natural language processing). Тобто, аналізуючи наші коментарі, пости в соціальних мережах, текст новин тощо з боку самої мови, її структур, синтаксису, морфології можна робити певні висновки щодо настрою коментаря, наявності в ньому образи чи, навпаки, похвали [34]. Наприклад, у дослідженні Аїтора Гарсія-Паблоса описаний автоматичний аналіз відгуків клієнтів готелів, який дозволяє оцінити рівень задоволеності відвідуванням та «настрій» відповідного відгуку. Дійсно, тільки уявіть, що відносно невеликими зусиллями можна проаналізувати дописи клієнтів щодо певного готелю та, опираючись на отримані результати, більш раціонально та таргетовано приймати рішення в

управлінні відносинами з клієнтами в індустрії гостинності, наприклад, щодо зменшення/збільшення кількості певних продуктів у барі, зміна постачальника текстилю для номерів, оцінка чистоти номерів та інше [35].

Підсумовуючи, необхідно сказати, що в даному розділі були описані найбільш використовувані джерела даних, що мають вплив на соціально-економічні явища. Проте, так як вже було зазначено, деякі дані досить складно дістати у відкритому доступі або взагалі неможливо, тому для дослідження в даній роботі будуть використані тільки ті дані, які ми можемо знайти у вільному доступі. Їх опис знаходиться в наступному розділі.

## 2 ПРАКТИЧНА РЕАЛІЗАЦІЯ

### 2.1 Опис даних

В роботі досліджено тижневі часові ряди з 1 листопада 2013 р. по 1 січня 2019 р.

Так як більшість ІТ компаній не дають можливість отримання відкритого доступу до даних щодо користувачів, що було сказано у підрозділі про джерела даних, наше дослідження щодо очікувань населення було обмежено тими даними, що надає компанія Google в рамках свого сервісу Тренди. Google Тренди – це веб-сервіс компанії, що, базуючись на кількості користувацьких пошуків, надає інформацію про популярність того чи іншого пошукового запиту.

В рамках нашого інтервалу Google надає щотижневу інформацію з індексом популярності запиту, де це число визначає рівень інтересу до теми по відношенню до найбільш високого показника для певного регіону і періоду часу. 100 балів означають найвищий рівень популярності запиту в даному інтервалі, 50 – рівень популярності запиту, вдвічі менший в порівнянні з першим випадком. 0 балів означає, що Google має недостатньо даних про даний пошуковий запит [36].

Отримані мною дані відображають щотижневу інформацію про популярність пошукових запитів на території України з 1 листопада 2013 року по 1 січня 2019 року. Причому, тижнем тут вважається період з неділі по суботу, а не з понеділка по неділю (цей факт також було використано далі для приведення щоденних даних НБУ до щотижневих).

Отже, в якості даних про очікування населення було використано дані про популярність наступних 17 пошукових запитів, які ми вважаємо такими, що відображають саме очікування населення щодо фінансової ситуації в країні:

- «военное положение»;
- «військовий стан»;
- «курс доллара»;
- «курс долара»;
- «курс валют»;
- «майдан»;

- «транш»;
- «внешний долг»;
- «зовнішній борг»;
- «девальвация»;
- «девальвація»;
- «инфляция»;
- «інфляція»;
- «золотовалютные резервы»;
- «золотовалютні резерви»;
- «война Украина»;
- «війна Україна».

Також для аналізу було використані наступні офіційні дані Національного банку України [32]:

- Середньозважені курси на готівковому валютному ринку України (грн. за 100 доларів США) – щоденна інформація;
- Процентна інтегральна ставка за строковими депозитами, залученими банками у фізичних осіб (середньозважені ставки в річному обчисленні, %) – щомісячна інформація;
- Міжнародні резерви – офіційні резервні активи (млн. дол. США) – щомісячна інформація;
- Грошовий агрегат М2 (млн. грн.) – щомісячна інформація. Грошовий агрегат М2 – це спосіб оцінки розрахунку сукупної грошової маси в обігу в Україні. М2 включає в себе готівку в обігу (банкноти, монети), кошти на поточних банківських рахунках та строкові й ощадні вклади в комерційних банках (до чотирьох років) [4, с. 87].

Основний показник – офіційний курс гривні до долара США, встановлений НБУ, є щоденною інформацією, що була отримана за допомогою програми, написаної мовою програмування Python (програма знаходиться в Додатку А), що,



використовуючи АРІ НБУ, отримувала дані щодо щоденного курсу гривні та робила його усереднення за тижнями.

Також на нашу думку було важливим врахувати індекс умов торгівлі (кількісний та ціновий) у зовнішній торгівлі України товарами (% до відповідного місяця попереднього року). Щомісячні дані для цього були взяті з офіційного сайту Державної служби статистики України [31]. Індекс умов торгівлі показує динаміку індексів середніх цін експорту та імпорту змінного складу [37].

Враховуючи той факт, що фактори імпорту та експорту надзвичайно сильно впливають на кількість валюти у фінансовій системі України, ми вирішили також додати до аналізу дані щодо міжнародних цін на основні імпортні та експортні товари, узяті з сайту [investing.com](http://investing.com), а саме:

- London Wheat Futures (фунтів стерлінгів за 1 тонну) – щотижнева інформація про ціни на ф'ючерси на пшеницю [38];
- US Corn Futures (доларів США за 1 бушель – приблизно 35 л) – щотижнева інформація про ціни на ф'ючерси на кукурудзу [39];
- Iron ore fines 62% Fe CFR Futures (доларів США за 1 тонну) – щотижнева інформація про ціни на ф'ючерси на залізну руду [40];
- Coal Futures (доларів США за 1 тонну) – щотижнева інформація про ціни на ф'ючерси на вугілля [41];
- Brent Oil Futures (доларів США за 1 барель – приблизно 159 л) – щотижнева інформація про ціни на ф'ючерси на нафту [42];

## 2.2 Підготовка даних для аналізу

Як було зазначено в попередньому підрозділі, в дослідженні було використано багато часових рядів, які в свою чергу мали неоднакову частоту (щоденні, щотижневі та щомісячні дані). Першим етапом підготовки даних було зведення їх до одного формату (програма, яка передбачала підготовку та аналіз даних, знаходиться в Додатку Б). Нами було вирішено зводити усі наші дані до щотижневих, тому ми використали наступне:

- щоденна інформація була усереднена за тижнями, причому так як дані про пошуки в Google мали тижневий характер, де тижнем є період з неділі по суботу, а не з понеділка по неділю, то саме таке трансформування і мало місце; також, так як щоденні дані були усереднені за тижнями, то пропущені дні (найчастіше це були святкові та вихідні дні, коли банківські установи не працювали) знівелювалися цим усередненням;
- щомісячні дані були трансформовані наступним чином – тижням «всередині» місяця були поставлені у відповідність дані відповідного місяця, а тижням «переходу» між двома місяцями – усереднене значення показника за сусідніми місяцями.

Таким чином, із щоденної інформації щотижневими стали середньозважені курси на готівковому валютному ринку України; щомісячні дані про процентну інтегральну ставку за строковими депозитами, залученими банками у фізичних осіб, офіційні резервні активи, грошовий агрегат M2 та індекс умов торгівлі стали щотижневими. Дані про ціни на ф'ючерси на різні товари вже було в щотижневому форматі, тому такого трансформування не потребували.

Як вже було описано в пункті про опис даних, щоденний офіційний курс гривні до долара США, встановлений НБУ, також був також усереднений за тижнями.

Заздалегідь знаючи про сильну кореляцію між величиною грошового агрегату M2 та золотовалютними резервами центрального банку (див. розділ 1.1 про інтервенції НБУ), в дослідженні ми вирішили використовувати їх відношення, причому, зважаючи на подальшу уніфікацію даних, приведення вищеназваних показників до однієї валюти не було використано.

Слід зазначити, що хоч і значення динаміки популярності пошукових запитів в Google коливаються від 0 до 100, між значеннями 0 та 1 існує показник «<1», який для зручності аналізу та відходу від категоріальних змінних було замінено на проміжне значення 0.5.

Так як для проведення аналізу була використана мова програмування R, яка найзручніше працює з файлами з форматом .csv, то і наші дані в дослідженні були зібрані у загальну csv-таблицю з кодовими назвами, які наведено в Табл. 2.1.

Таблиця 2.1 – Опис змінних дослідження

Показник	Кодова назва, змінна	
Динаміка популярності пошукового запиту в Google	«военное положение»	martialLawRus
	«військовий стан»	martialLawUkr
	«курс доллара»	dollarRateRus
	«курс долара»	dollarRateUkr
	«курс валют»	exchangeRates
	«майдан»	maidan
	«транш»	tranche
	«внешний долг»	externalDebtRus
	«зовнішній борг»	externalDebtUkr
	«девальвация»	devaluationRus
	«девальвація»	devaluationUkr
	«инфляция»	inflationRus
	«інфляція»	inflationUkr
	«золотовалютные резервы»	reserveRus
	«золотовалютні резерви»	reserveUkr
	«война Украина»	warRus
«війна Україна»	warUkr	
Среднезвешені курси на готівковому валютному ринку України (грн. за 100 доларів США) – купівля	avRateBuy	
Среднезвешені курси на готівковому валютному ринку України (грн. за 100 доларів США) – продаж	avRateSell	
Brent Oil Futures (доларів США за 1 барель)	brent	
Coal Futures (доларів США за 1 тонну)	coal	
Iron ore fines 62% Fe CFR Futures (доларів США за 1 тонну)	iron	
London Wheat Futures (фунтів стерлінгів за 1 тонну)	wheat	

## Продовження таблиці 2.1

<b>Показник</b>	<b>Кодова назва, змінна</b>
US Corn Futures (доларів США за 1 бушель)	corn
Офіційний курс гривні до долара США	officialRate
Індекс умов торгівлі (%) – кількісний	tradeQuant
Індекс умов торгівлі (%) – ціновий	tradePrice
Процентна інтегральна ставка за строковими депозитами, залученими банками у фізичних осіб (середньозважені ставки в річному обчисленні, %)	interestRate
Відношення грошового агрегату М2 до міжнародних резервів (грн. / дол. США)	M2_reserve

## 2.3 Аналіз даних

### 2.3.1 Візуалізація та початковий аналіз

Статистичний аналіз часового ряду передбачає дослідження описової статистики та візуалізацію динаміки та розподілу ряду. На Рис. 2.1 показано динаміку часового ряду офіційного валютного курсу UAH/USD 1 листопада 2013 р. по 1 січня 2019 р. (код програми з аналізом даних знаходиться в Додатку Б).



Рисунок 2.1 – Офіційний обмінний курс НБУ ( гривень за 1 долар США )  
Джерело: bank.gov.ua [32]

Стаціонарність часового ряду передбачає незмінність середнього значення, дисперсії та коваріації в будь-який момент часу. Візуалізація допомогла нам впевнитися в тому, що наш часовий ряд є нестаціонарним, тобто було зроблено висновок щодо волатильності валютного курсу. Наступним кроком я оцінив стаціонарність ряду вже за допомогою спеціалізованих тестів в R – тест Дікі-Фуллера:

```
Augmented Dickey-Fuller Test
data: rateTs
Dickey-Fuller = -1.9321, Lag order = 6, p-value = 0.6046
alternative hypothesis: stationary
```

Даний тест показав нам, що ряд не є стаціонарним. Після використання функції `ndiffs` було визначено, що вже перші різниці дають стаціонарний ряд. Проведений тест Дікі-Фуллера для перших різниць виглядає наступним чином:

## Augmented Dickey-Fuller Test

```
data: diff(rateTs, differences = 1)
Dickey-Fuller = -7.4163, Lag order = 6, p-value = 0.01
alternative hypothesis: stationary
```

Отже, ряд перших різниць є стаціонарним. Цей факт буде використано для побудови моделей, що вимагають стаціонарності прогнозованого ряду.

Після візуалізації самого по собі часового ряду та дослідження його стаціонарності я вирішив виконати декомпозицію та відобразити її на наступному графіку.




Рисунок 2.2 – Декомпозиція часового ряду

З графіку на Рис. 2.2 видно тренд до зростання, очевидна сезонність, притаманна валютному курсу – зростання в січні, падіння до кінця літа та зростання з осені.

Після декомпозиції я побудував графіки автокореляційної та частинної автокореляційної функцій часового ряду курсу та його перших різниць (Рис. 2.3) та гістограми (Рис. 2.4).

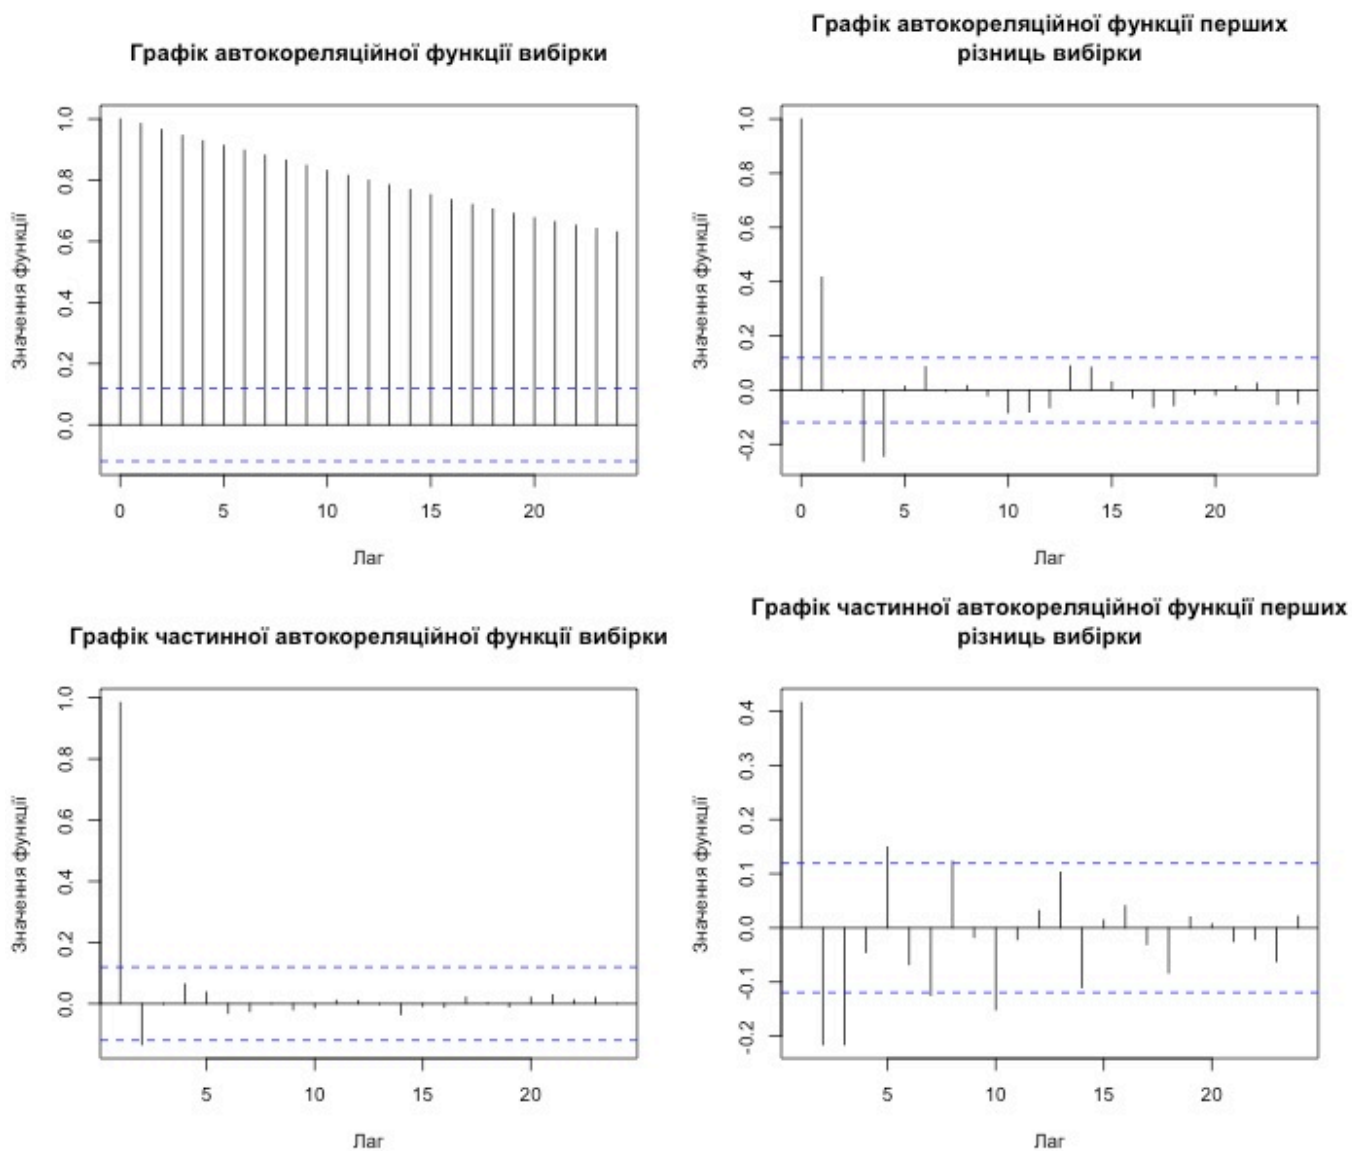


Рисунок 2.3 – Графіки автокореляційної та частинної автокореляційної функцій часового ряду курсу та його перших різниць




Рисунок 2.4 – Гістограми розподілу офіційного валютного курсу з та без урахування різкого підвищення курсу взимку 2015 року

Очевидно, що присутня автокореляція у даних – це можна пояснити тим, що поточні значення курсу залежать від його попереднього значення. Гістограми допомогли нам впевнитися в тому, що офіційний курс долара США в даному інтервалі не є розподіленим за нормальним розподілом.

Два Q-Q графіка (Рис. 2.5) підтвердили наші попередні висновки щодо того, що курс не є розподіленим нормально.

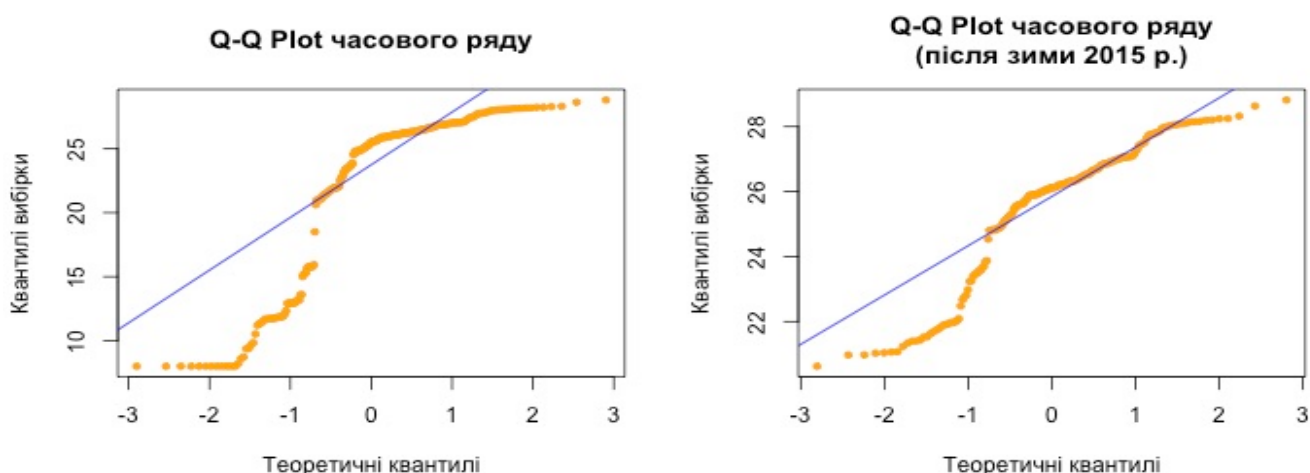


Рисунок 2.4 – Q-Q plot часового ряду офіційного валютного курсу з та без урахування різкого підвищення курсу взимку 2015 року

Наступний крок складався із аналізу кореляції між змінними. Спочатку було побудоване графічне відображення кореляції (Рис. 2.6):




Рисунок 2.6 – Графічне відображення кореляції між змінними



Після візуального аналізу останнього рисунку можна зробити наступні висновки:

- відобразилася очевидна залежність між динамікою популярності пошукових запитів одного контексту, проте українською та російською мовами;
- доволі цікавим виявилось те, що існує висока лінійна залежність між динамікою популярності пошукового запиту «золотовалютные резервы» в Google та:
  - ціновим індексом умов торгівлі;
  - відношенням грошового агрегату M2 до міжнародних резервів;
- виявлено, що офіційний курс доволі суттєво корелює з багатьма факторами.

Зважаючи на останній факт, було вирішено розрахувати кореляцію між офіційним валютний курсом та усіма показниками. Факторами з найбільшими коефіцієнтами кореляції виявилися (див. Табл. 2.2, Lag 0):

- Brent Oil Futures;
- процентна інтегральна ставка за строковими депозитами;
- Iron ore fines 62% Fe CFR Futures;
- індекс умов торгівлі – кількісний;
- US Corn Futures;
- середньозважені курси на готівковому валютному ринку України – купівля;
- середньозважені курси на готівковому валютному ринку України – продаж;
- динаміка популярності запиту «война»;
- динаміка популярності запиту «девальвация».

Після цього я оцінював кореляцію між попередніми значеннями (минулий тиждень) факторів впливу та поточними значення офіційного курсу долара США. В даних розрахунках показниками, що найбільше корелюють із значеннями курсу, виявилися ті ж самі показники, причому коефіцієнти кореляції в сенсі сотих не змінилися, крім тих, які відображали iron, tradeQuant та warRus, хоча і вони змінилися незначно (див. Табл. 2.2, Lag 1).

Таблиця 2.2 – Результати оцінки кореляції між змінними та курсом з лагом 0 та 1

	brent	interestRate	iron	tradeQuant	corn	avRateBuy	avRateSell	warRus	devaluationRus
Lag 0	-0.76	-0.73	-0.72	-0.69	-0.63	-0.57	-0.55	-0.54	-0.51
Lag 1	-0.76	-0.73	-0.71	-0.70	-0.63	-0.57	-0.55	-0.55	-0.51

Наступним етапом було проведення тесту Грейнджера на каузальність. Проведення тесту Грейнджера на лагах 1, 2 та 3 було виконано за допомогою програмного забезпечення EViews, адже саме воно дає найзручніші для інтерпретування результати. Отримані значення показників імовірності  $p$  для відповідних гіпотез на трьох лагах знаходяться в Додатках В, Г, Д. Проаналізувавши результати тестів, було зроблено висновок про те, що наступні фактори найбільше роблять внесок у прогноз валютного курсу (рівень довіри було обрано за 95%):

- brent (лаг = 1 та лаг = 2) – Brent Oil Futures;
- dollarRateUkr (лаг = 1) – динаміка популярності запиту «курс долара».

### 2.3.2 Побудова базової моделі

Після отриманих результатів щодо причинно-наслідкових зв'язків між факторами я перейшов до прогнозування.

Для побудов моделей я використовував два поділи вибірки на тестову та тренінгову:

- 255 тренувальних та 15 тестових тижнів, тобто прогнозування на приблизно 3,5 місяці;
- 266 тренувальних та 4 тестових тижнів, тобто прогнозування приблизно на 1 місяць.

Перш ніж перейти до побудови класичних моделей для прогнозування мого часового ряду я вирішив побудувати прогноз за допомогою середнього значення. Очевидно, що найпростішою приблизною оцінкою для будь-якого прогнозу буде просто середнє значення спостережуваних даних. Виконавши даний прогноз для двох поділів, я отримав наступні графіки:




Рисунок 2.7 – Прогнозування за допомогою середнього (train/test: 255/15)



Рисунок 2.8 – Прогнозування за допомогою середнього (train/test: 266/4)

Після графіку також була побудована Табл. 2.3, яка містить різні оцінки точності попередньої моделі на тестовій вибірці за умови різного розподілу на тестову та тренувальну вибірки.

Таблиця 2.3 – Оцінки точності моделі прогнозування середнім на тестових вибірках

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	6,116201	6,120313	6,116201	21,87692	21,87692	1,439361	0,595255
Тестова 266/4	5,569255	5,570966	5,569255	20,13182	20,13182	1,358293	0,011081

У Таблиці 2.3 наведені наступні оцінки точності прогнозу:

- ME (Mean Error) – середня похибка:

$$ME = \text{mean}(e_t); \quad (2.1)$$

- RMSE (Root Mean Squared Error) – середньоквадратична похибка;

$$RMSE = \sqrt{\text{mean}(e_t^2)}; \quad (2.2)$$

- MAE (Mean Absolute Error) – середня абсолютна похибка:

$$MAE = \text{mean}(|e_t|); \quad (2.3)$$

- MPE (Mean Percentage Error) – середня відсоткова похибка:

$$MPE = \text{mean} \left( \frac{e_t}{y_t} \right) \cdot 100\%; \quad (2.4)$$

- MAPE (Mean Absolute Percentage Error) – середня абсолютна відсоткова похибка:

$$MAPE = \text{mean} \left( \left| \frac{e_t}{y_t} \right| \right) \cdot 100\%; \quad (2.5)$$

- MASE (Mean Absolute Scaled Error) – середня абсолютна шкалована похибка:

$$MASE = \text{mean} \left( \left| \frac{e_t}{\frac{1}{T-1} \cdot \sum_{t=2}^T |y_t - y_{t-1}|} \right| \right); \quad (2.6)$$

- ACF1 – значення автокореляції похибок (лаг = 1):

$$ACF1 = r_1 = \frac{\sum_{t=2}^T (y_t - \bar{y})(y_{t-1} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (2.7)$$

де  $e_t$  – значення похибки прогнозу,  $y_t$  – фактичне значення прогнозованої величини,  $T$  – кількість періодів [13, 43].

Таким чином, якщо будь яка з наступних моделей буде показувати себе гірше (тобто, буде мати більші значення похибок прогнозу) за попередній прогноз середнім значенням, вона не має сенсу.

### 2.3.3 Модель TBATS

Першою моделлю, яку я побудував після вибору базової, була модель TBATS. Вона використовує комбінацію термінів Фур'є з моделлю експоненціального згладжування з трансформацією Вох-Сох, ARMA похибками, компонентами тренду та сезонності в повністю автоматичному режимі. Модель TBATS відрізняється від динамічної гармонійної регресії тим, що тут сезонність може повільно змінюватися з часом, тоді як терміни (проміжки) гармонійної регресії періодично повторюють сезонні закономірності без змін. Одним із недоліків моделей TBATS є те, що цей метод може бути занадто повільним для прогнозування, особливо для великих часових рядів, однак така модель має високу точність [13, 44].

Модель TBATS вимагає стаціонарності ряду, тому для прогнозування були використані перші різниці, які, згідно із нашими попередніми дослідженнями, роблять ряд стаціонарним. Було отримано графіки (Рис. 2.9, Рис. 2.10) та значення оцінок точності, які знаходяться в Табл. 2.4.

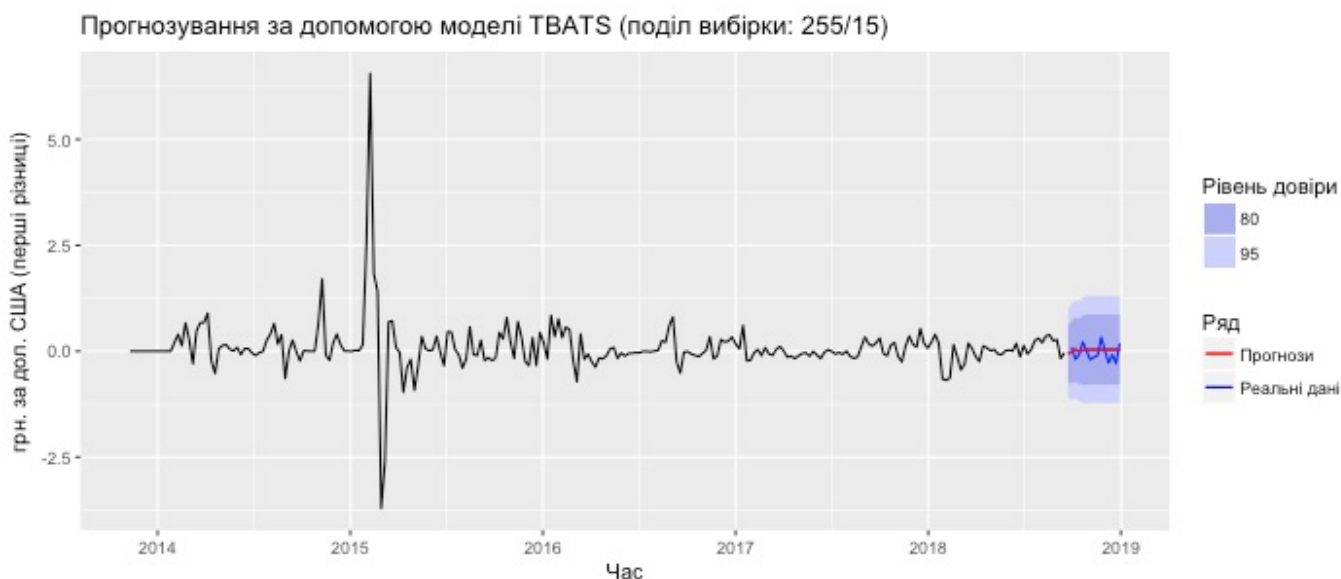


Рисунок 2.9 – Прогноз, виконаний за допомогою TBATS (train/test: 255/15)




Рисунок 2.10 – Прогноз, виконаний за допомогою TBATS (train/test: 266/4)

Таблиця 2.4 – Оцінки точності моделі TBATS

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	-0,06733	0,197028	0,173601	47,43369	146,1928	0,384719	-0,105842
Тестова 266/4	-0,007883	0,182701	0,149786	65,70555	65,70555	0,344787	-0,512218

Отже, дана модель показала себе набагато краще ніж простий прогноз середнім значенням (усі похибки прогнозу суттєво зменшились, крім відсоткових, що пояснюється тим, що тут були використані перші різниці, а не абсолютні значення валютного курсу, а в даних присутній стрибок – різке зростання курсу на початку 2015 року).

Для даних моделей також був розрахований інформаційний критерій Акаїке AIC (Табл. 2.5), що обчислюється за формулою:

$$AIC = -2l + 2n_{par}, \quad (2.8)$$

де  $l$  – значення логарифмічної функції правдоподібності моделі,  $n_{par}$  – кількість параметрів, використаних у моделі [45].

Таблиця 2.5 – Порівняння інформаційних критеріїв моделей TBATS

	AIC
255/15	1105,632
266/4	1154,602

Отже, хоча і модель 266/4 мала кращу точність (Табл. 2.4), вона має більше значення інформаційного критерію (Табл. 2.5), що свідчить про те, що модель 255/15 є кращою в рамках оцінки «точність-складність» моделі.

Загальний вигляд математичної моделі TBATS можна представити наступним чином:

$$y_t = l_{t-1} + \phi b_{t-1} + \sum_{i=1}^T s_t^{(i)} + d_t, \quad (2.9)$$

$$l_t = l_{t-1} + \phi b_{t-1} + \alpha d_t, \quad (2.10)$$

$$b_t = (1 - \phi)b + \phi b_{t-1} + \beta d_t, \quad (2.11)$$

$$s_t^{(i)} = s_{t-m_i}^{(i)} + \gamma_i d_t, \quad (2.12)$$

$$d_t = \sum_{i=1}^p \varphi_i d_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t, \quad (2.13)$$

де  $m_i$  – періоди сезонних циклів;  $d_t$  – білий шум випадкової змінної, що відображає похибку прогнозу;  $\varepsilon_t$  – гаусовий шум;  $l_t$  – рівень;  $b_t$  – тренд;  $b$  – довгостроковий тренд;  $s_t^{(i)}$  –  $i$ -та сезонна компонента ряду;  $\alpha, \beta, \gamma_i$  – коефіцієнти згладжування;  $\phi$  – коефіцієнт згладжування тренду;  $l_0, b_0, \{s_{t-m_i}^{(i)}, \dots, s_0^{(i)}\}$  – початкові змінні стану [46, с. 9-10].

Таблиця 2.6 – Структура моделей TBATS

	255/15	266/4
Модель	(1, {2,4}, -, -)	(1, {2,1}, 0.907, -)
Використовувати Вох-Сох	ні	ні
Вох-Сох лямбда	не використовується	не використовується
Згладжуючий параметр $\phi$	не використовується	0.907362
Параметри	$\alpha$ : - 0.004057599 $\beta$ : не використовується $\gamma_i$ : не використовуються $p$ : 0.438069; -0.103398 $q$ : 0.040619; 0.109502; -0.225179; -0.320053	$\alpha$ : - 0.1242484 $\beta$ : 0.01575129 $\gamma_i$ : не використовуються $p$ : 0.929468; -0.3848 $q$ : - 0.390874



В нашому випадку були отримані наступні моделі TBATS:

- для розподілу вибірки 255/15:

$$y_t = l_t + 1.004057599(0.438069d_{t-1} - 0.103398d_{t-2} + 0.040619\varepsilon_{t-1} + 0.109502\varepsilon_{t-2} - 0.225179\varepsilon_{t-3} - 0.320053\varepsilon_{t-4} + \varepsilon_t) \quad (2.14)$$

- для розподілу вибірки 266/4:

$$y_t = l_{t-1} + 1.1242484(0.929468d_{t-1} - 0.3848d_{t-2} - 0.390874\varepsilon_{t-1} + \varepsilon_t), \quad (2.15)$$

$$b_t = 0.092638b + 0.907362b_{t-1} + 0.01575129d_t, \quad (2.16)$$

### 2.3.4 Моделі ARIMA без урахування впливових факторів

Даний підрозділ присвячений побудованим ARIMA моделям, які не враховували екзогенні фактори, а опиралися лише на аналіз часового ряду офіційного курсу долара в Україні (Рис. 2.11, Рис. 2.12, Табл. 2.7).



Рисунок 2.11 – Прогноз, виконаний за допомогою моделі ARIMA без урахування впливових факторів (test/train: 255/15)



Рисунок 2.12 – Прогноз, виконаний за допомогою моделі ARIMA без урахування впливових факторів (test/train: 266/4)

Таблиця 2.7 – Оцінки точності моделі ARIMA без урахування впливових факторів

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	-0,723048	0,899672	0,735542	-2,60121	2,645492	0,173099	0,769117
Тестова 266/4	-0,515735	0,553894	0,515735	-1,867697	1,867697	0,125783	0,282471

Для даних моделей також були розраховані критерії AIC:

Таблиця 2.8 – Порівняння інформаційних критеріїв моделей ARIMA без урахування впливових факторів

	AIC
255/15	404,62
266/4	412

Після аналізу похибок та критеріїв AIC стає зрозумілим, що кращою моделлю є ARIMA модель, побудована на 255 тестових значеннях, проте важко сказати, чи краща вона за моделі TBATS. Тут необхідно зазначити, що маючи за ціль максимально точну модель треба обирати TBATS, адже вона краща за прогнозними якостями, але для досить точної та не дуже складної моделі буде досить ARIMA 255/15, адже вона краща з точки зору адекватності та оцінки «точність-складність».

Таблиця 2.9 – Структура моделей ARIMA

	255/15	266/4
Модель	ARIMA(0,1,5) with drift	ARIMA(0,1,5) with drift
Порядок AR	0	0
Порядок диференціювання	1	1
Порядок MA	5	5
Drift, константа	0.0794	0.0763
Параметри	<i>p</i> : не використовуються <i>q</i> : 0.4886; 0.2439; -0.1699; -0.4266; -0.1324	<i>p</i> : не використовуються <i>q</i> : 0.488; 0.2417; -0.1713; -0.425; -0.1301

В нашому випадку були отримані наступні моделі ARIMA:

- для розподілу вибірки 255/15:

$$y_t - y_{t-1} = 0.0794 + 0.4886\varepsilon_{t-1} + 0.2439\varepsilon_{t-2} - 0.1699\varepsilon_{t-3} - 0.4266\varepsilon_{t-4} - 0.1324\varepsilon_{t-5} + \varepsilon_t \quad (2.17)$$

- для розподілу вибірки 266/4:

$$y_t - y_{t-1} = 0.0763 + 0.488\varepsilon_{t-1} + 0.2417\varepsilon_{t-2} - 0.1713\varepsilon_{t-3} - 0.425\varepsilon_{t-4} - 0.1301\varepsilon_{t-5} + \varepsilon_t \quad (2.18)$$

### 2.3.5 Моделі ARIMA з урахуванням впливових факторів

Після звичайних моделей ARIMA були побудовані моделі (Рис. 2.13, Рис. 2.14, Табл. 2.10), що враховували вплив факторів, які ми попередньо за допомогою тесту Грейнджера виділили як «впливові» – *brent* та *dollarRateUkr*.



Рисунок 2.13 – Прогноз, виконаний за допомогою моделі ARIMA з урахуванням впливових факторів (test/train: 255/15)

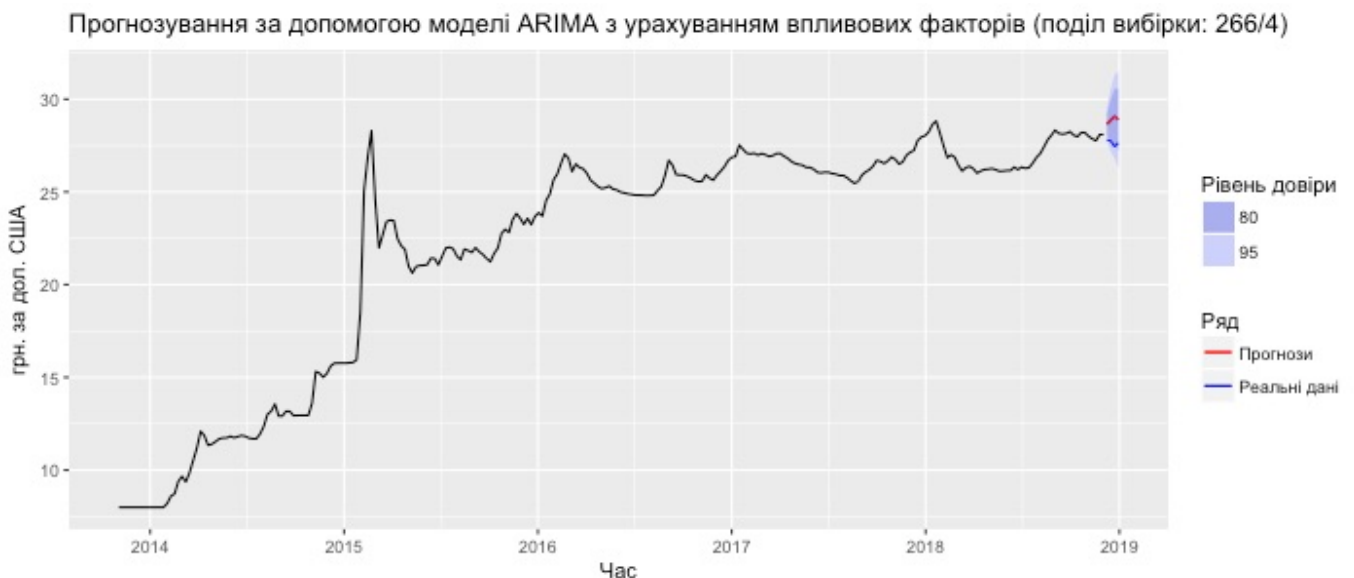


Рисунок 2.14 – Прогноз, виконаний за допомогою моделі ARIMA з урахуванням впливових факторів (test/train: 266/4)

Таблиця 2.10 – Оцінки точності моделі ARIMA з урахуванням впливових факторів

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	-0,781712	0,959274	0,781712	-2,809519	2,809519	0,183965	0,682827
Тестова 266/4	-1,209294	1,241945	1,209294	-4,376956	4,376956	0,294936	0,052502

Аналогічно, для даних ARIMA моделей були розраховані критерії AIC:

Таблиця 2.11 – Порівняння інформаційних критеріїв моделей ARIMA з урахуванням впливових факторів

	AIC
255/15	348,56
266/4	359,39

Після аналізу похибок та критеріїв AIC можна зробити висновок, що дані моделі «програють» звичайним ARIMA моделям за значеннями похибок (тут вони більші), проте критерії AIC – менші. Тобто, кращими з точки зору адекватності є ARIMA моделі з урахуванням впливових факторів (*brent* та *dollarRateUkr*), що навчалася на 255 спостереженнях, проте за прогностичними якостями TBATS залишається найкращою.

Таблиця 2.12 – Структура моделей ARIMA з урахуванням впливових факторів

	255/15	266/4
Модель	Regression with ARIMA(0,1,4) errors	Regression with ARIMA(0,1,4) errors
Порядок AR	0	0
Порядок диференціювання	1	1
Порядок MA	4	4
Drift, константа	0.0781	0.0775
Параметри	<i>p</i> : не використовуються <i>q</i> : 0.593; -0.0447; -0.1398; -0.2503	<i>p</i> : не використовуються <i>q</i> : 0.5728; -0.0047; -0.1453; -0.2556
Коефіцієнт біля <i>brent</i>	0.0074	0.01
Коефіцієнт біля <i>dollarRateUkr</i>	0.0364	0.0313

У даному випадку були отримані наступні регресійні моделі з ARIMA похибками:

- для розподілу вибірки 255/15:

$$y_t = y_{t-1} + 0.0074 \cdot \text{brent} + 0.0364 \cdot \text{dollarRateUkr} + 0.0781 + 0.593\varepsilon_{t-1} - 0.0447\varepsilon_{t-2} - 0.1398\varepsilon_{t-3} - 0.2503\varepsilon_{t-4} + \varepsilon_t \quad (2.19)$$

- для розподілу вибірки 266/4:

$$y_t = y_{t-1} + 0.01 \cdot \text{brent} + 0.0313 \cdot \text{dollarRateUkr} + 0.0775 + 0.5728\varepsilon_{t-1} - 0.0047\varepsilon_{t-2} - 0.1453\varepsilon_{t-3} - 0.2556\varepsilon_{t-4} + \varepsilon_t \quad (2.20)$$

Аналізуючи побудовані моделі, можна зробити наступні висновки: *ceteris paribus* (за інших рівних умов) в моделі 255/15 підвищення ціни на ф'ючерси на нафту на 1 долар США та підвищення популярності пошукового запиту «курс долара» на 1 одиницю призведе до зростання валютного курсу долара на 0,0074 та 0,0364 гривні відповідно, аналогічно для моделі 266/4 – на 0,01 та 0,0313 гривні відповідно.

### 2.3.6 Нейронні мережі без урахування впливових факторів

Першою моделлю прогнозування за допомогою нейронних мереж був прогноз тільки за оригінальним часовим рядом, тобто без урахування зовнішніх факторів. Так як серед специфікацій обраної нейронної мережі є кількість вузлів у прихованому шарі та кількість повторів побудов моделей для усереднення їх результатів, то було виконано підбір цих оптимальних (за MAPE) параметрів – вони обиралися за допомогою циклу від 1 до 56 із кроком 5. Побудовані графіки прогнозів знаходяться на Рис. 2.15 та Рис. 2.16, оцінки похибок – у Табл. 2.13.



Рисунок 2.15 – Прогноз, виконаний за допомогою нейронних мереж без урахування впливових факторів (test/train: 255/15)



Рисунок 2.16 – Прогноз, виконаний за допомогою нейронних мереж без урахування впливових факторів (test/train: 266/4)

Таблиця 2.13 – Оцінки точності прогнозів за допомогою нейронних мереж без урахування впливових факторів

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	0,202445	0,317631	0,267181	0,717622	0,952816	0,062877	0,660583
Тестова 266/4	0,011861	0,129753	0,108874	0,04278	0,393921	0,026553	-0,380971

Специфікації моделей знаходяться у Табл. 2.14:

Таблиця 2.14 – Структура моделей нейронних мереж без урахування впливових факторів

	255/15	266/4
Модель	NNAR(2,1,11)[52]	NNAR(2,1,6)[52]
Кількість моделей для побудови для усереднення результатів	1	21
Кількість вхідних параметрів	3	3
Кількість вузлів у прихованому шарі	11	6
Загальна кількість вагових коефіцієнтів	56	31
Кількість несезонних лагів, що використовуються для аналізу	2	2
Кількість сезонних лагів, що використовуються для аналізу	1	1

Дуже важно оцінити, яка з побудованих вище моделей є кращою в сенсі адекватності, адже критерії АІС не застосовні до нейронних мереж. Проте, очевидно, що нейронна мережа, яка навчалась на 266 спостереженнях, за значеннями похибок «виграє» у ТВАТС.



### 2.3.7 Нейронні мережі з урахуванням впливових факторів

В даному підрозділі були побудовані нейронні мережі вже з урахуванням впливових факторів (*brent* та *dollarRateUkr*). Як і попередні моделі, підбір оптимальних (за MAPE) параметрів моделей було виконано за допомогою циклу від 1 до 56 із кроком 5. Побудовані графіки прогнозів знаходяться на Рис. 2.17 та Рис. 2.18, оцінки похибок – у Табл. 2.15.




Рисунок 2.17 – Прогноз, виконаний за допомогою нейронних мереж з урахуванням впливових факторів (test/train: 255/15)




Рисунок 2.18 – Прогноз, виконаний за допомогою нейронних мереж з урахуванням впливових факторів (test/train: 266/4)

Таблиця 2.15 – Оцінки точності прогнозів за допомогою нейронних мереж з урахуванням впливових факторів

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Тестова 255/15	0,175527	0,360584	0,224085	0,626986	0,800474	0,052735	0,623754
Тестова 266/4	-0,024803	0,115354	0,10267	-0,089606	0,371348	0,02504	-0,33383

Специфікації моделей знаходяться у Табл. 2.16:

Таблиця 2.16 – Структура моделей нейронних мереж з урахуванням впливових факторів

	255/15	266/4
Модель	NNAR(2,1,6)[52]	NNAR(2,1,6)[52]
Кількість моделей для побудови для усереднення результатів	56	11
Кількість вхідних параметрів	5	5
Кількість вузлів у прихованому шарі	6	6
Загальна кількість вагових коефіцієнтів	43	43
Кількість несезонних лагів, що використовуються для аналізу	2	2
Кількість сезонних лагів, що використовуються для аналізу	1	1

Аналогічно, в даному випадку дуже важно оцінити, яка з побудованих моделей нейронних мереж є кращою в сенсі адекватності, адже критерії АІС не застосовні до них. Проте, нейронна мережа, яка навчалась на 266 спостереженнях, за значеннями усіх похибок, крім ME та MPE «виграє» у попередньо обраної «найкращою» нейронної мережі 266/4 без урахування впливових зовнішніх факторів.

## 2.3.8 Вибір кращої моделі та її дослідження

Для порівняння побудованих моделей я вирішив створити загальну таблицю з похибками їх прогнозів та інформаційних критеріїв.

Таблиця 2.17 – Зведена таблиця оцінок моделей

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	AIC
Mean 255/15	6,116201	6,120313	6,116201	21,87692	21,87692	1,439361	0,595255	NA
Mean 266/4	5,569255	5,570966	5,569255	20,13182	20,13182	1,358293	0,011081	NA
TBATS 255/15	-0,06733	0,197028	0,173601	47,43369	146,1928	0,384719	-0,105842	1105,632
TBATS 266/4	-0,007883	0,182701	0,149786	65,70555	65,70555	0,344787	-0,512218	1154,602
ARIMA 255/15	-0,723048	0,899672	0,735542	-2,60121	2,645492	0,173099	0,769117	404,62
ARIMA 266/4	-0,515735	0,553894	0,515735	-1,867697	1,867697	0,125783	0,282471	412
ARIMA з впливовими факторами 255/15	-0,781712	0,959274	0,781712	-2,809519	2,809519	0,183965	0,682827	348,56
ARIMA з впливовими факторами 266/4	-1,209294	1,241945	1,209294	-4,376956	4,376956	0,294936	0,052502	359,39
Нейронна мережа 255/15	0,202445	0,317631	0,267181	0,717622	0,952816	0,062877	0,660583	NA
Нейронна мережа 266/4	0,011861	0,129753	0,108874	0,04278	0,393921	0,026553	0,380971	NA
Нейронна мережа з впливовими факторами 255/15	0,175527	0,360584	0,224085	0,626986	0,800474	0,052735	0,623754	NA
Нейронна мережа з впливовими факторами 266/4	-0,024803	0,115354	0,10267	-0,089606	0,371348	0,02504	-0,33383	NA

Найкращою моделлю за точністю виявилася нейронна мережа з урахуванням впливових факторів (*brent* та *dollarRateUkr*), яка навчалася на 266 спостереженнях. Саме вона давала більшість найменших значень похибок прогнозу. Найкращою моделлю в сенсі адекватності була модель ARIMA з урахуванням впливових факторів, яка навчалася на 255 спостереженнях.

Через те, що на мою думку в прогнозуванні офіційного валютного курсу долара в Україні важливою є саме точність прогнозу, а складність моделі є не першим пріоритетом, оптимальною моделлю прогнозування в рамках свого дослідження я вважаю нейронну мережу, яка враховує впливові фактори.

Наступним кроком я досліджував залишки даної моделі на:

- нормальність:




Рисунок 2.19 – Q-Q plot

З графіку Q-Q plot видно, що залишки не є нормально розподіленими.

- гетероскедастичність (тобто, наявності різної дисперсії):



Рисунок 2.20 – Графік залишків оптимальної моделі

Аналогічно, з графіку залишків моделі видно, що вони мають різну дисперсію.

- автокореляцію:



Рисунок 2.21 – Графік функції автокореляції (ACF)

З останнього графіку можна зробити висновок, що залишки відносно сильно корелюють (лаг = 1).

Усі вищезазначені «недоліки» залишків моделі можна пояснити природою даних; тим, що деякі щоденні та щомісячні вхідні дані в рамках дослідження були трансформовані в щотижневі; також на початку 2015 року були присутні різкі коливання офіційного курсу долара в Україні. Для того, щоб не враховувати останнє, було побудовано дві нові моделі:

- нова нейронна мережа, яка використовувала усі специфікації попередньої оптимальної моделі та навчалася на даних, які починаються після стрибка взимку 2015 року. Графік її прогнозів знаходиться на Рис. 2.22.

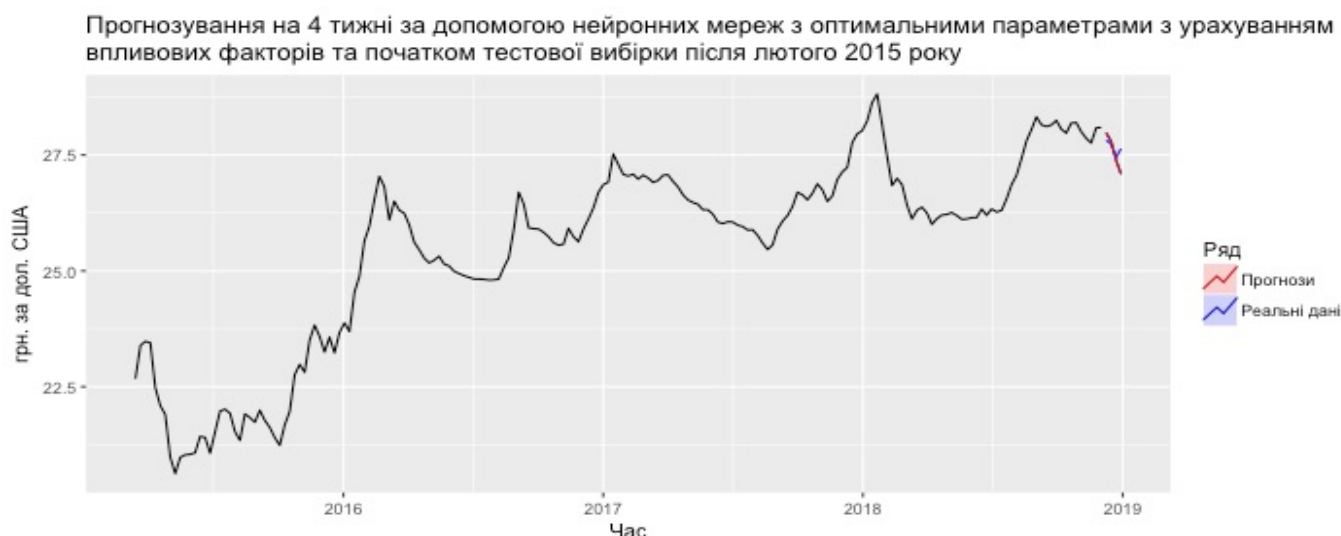


Рисунок 2.22 – Графік прогнозів оптимальної моделі, що навчалась на даних після лютого 2015 року

- зовсім нова нейронна мережа, в якій знову було виконано підбір параметрів (кількість моделей для усереднення та кількість вузлів у прихованому шарі), що навчалася на даних без стрибка. Графік її прогнозів знаходиться на Рис. 2.23.




Рисунок 2.23 – Графік прогнозів повністю нової моделі, що навчалась на даних після лютого 2015 року

На Рис. 2.24 знаходяться графіки Q-Q plot нових моделей, на Рис. 2.25 – графіки залишків моделей, на Рис. 2.26 – графіки функцій автокореляції.

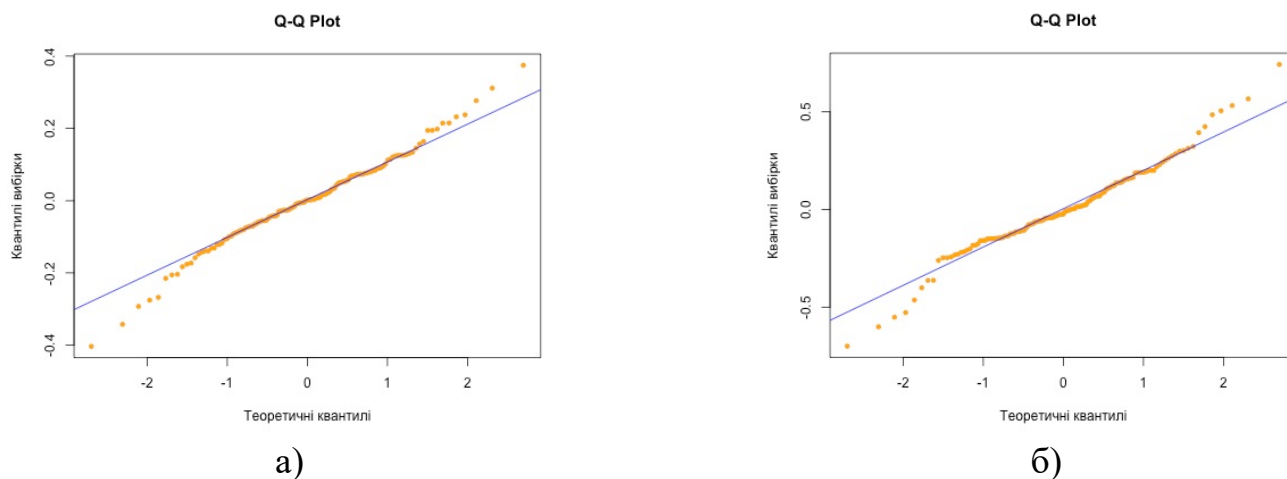



Рисунок 2.24 – Q-Q plot:

а) нейронна мережа з оптимальними специфікаціями; б) нова нейронна мережа

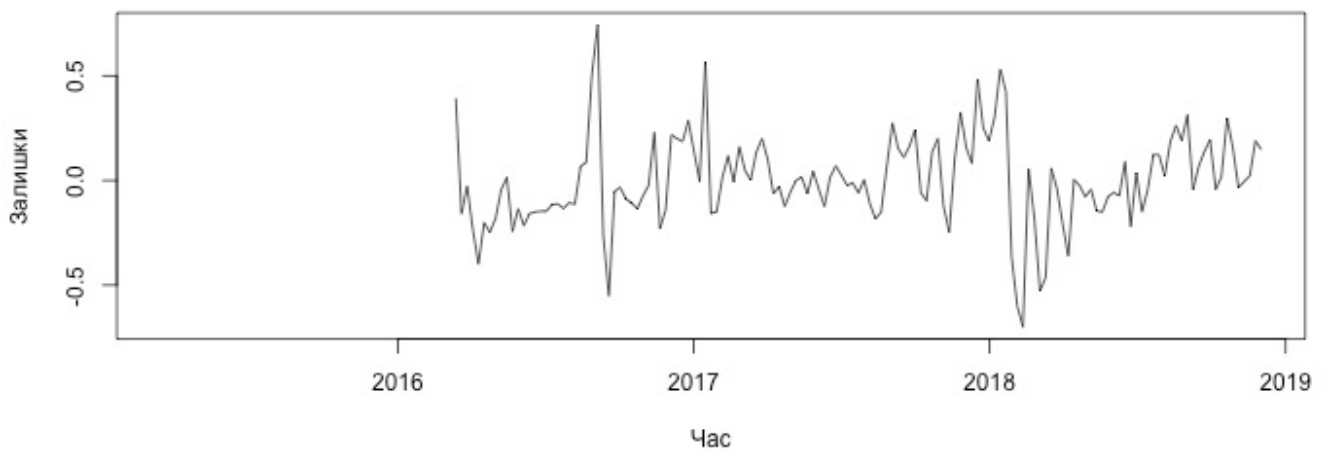
Q-Q plot показав, що залишки нових моделей також не є розподіленими за нормальним законом.

**Графік залишків моделі з оптимальними параметрами  
та початком тестової вибірки після лютого 2015 року**



а)

**Графік залишків моделі з новими параметрами  
та початком тестової вибірки після лютого 2015 року**




б)

Рисунок 2.25 – Графік залишків:  
а) нейронна мережа з оптимальними специфікаціями; б) нова нейронна мережа

Останні графіки дали нам змогу впевнитися, що гомоскедастичними залишки нових моделей також не стали.

**Графік автокореляційної функції залишків моделі з оптимальними параметрами та початком тестової вибірки після лютого 2015 року**



**Графік автокореляційної функції залишків моделі з новими параметрами та початком тестової вибірки після лютого 2015 року**




Рисунок 2.26 – Графік функції автокореляції (ACF):

а) нейронна мережа з оптимальними специфікаціями; б) нова нейронна мережа

Автокореляція при лаг = 1 також не зникла, та навіть з'явилася на інших лагах.

В Табл. 2.18 знаходяться оцінки точності прогнозів попередньої оптимальної моделі з вищепобудованими за допомогою навчання на даних, що не містили стрибка 2015 року.

Таблиця 2.18 – Порівняльна таблиця точності прогнозів моделей

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Оптимальна модель	-0,024803	0,115354	0,10267	-0,089606	0,371348	0,02504	-0,33383
Оптимальна модель, яка не враховувала стрибок	0,098585	0,289444	0,207353	0,358224	0,749505	0,119905	0,099572
Нова модель, яка не враховувала стрибок	-0,116912	0,151726	0,116912	-0,423881	0,423881	0,067606	-0,62677



Аналізуючи результати, необхідно зазначити, що моделі машинного навчання не вимагають строгого дотримання передумов, які властиві класичним моделям, тому в даному випадку я вирішив фокусуватися на порівнянні точності моделей.

Після оцінки точності моделей в Табл. 2.18, можна сміливо сказати, що в точності дві нові моделі гірші за обрану оптимальною нейронну мережу. Таким чином, підводячи підсумки нашого дослідження, найоптимальнішою моделлю *в сенсі точності прогнозів* офіційного валютного курсу долара США в Україні виявилася нейронна мережа з наступними специфікаціями:

Таблиця 2.19 – Структура оптимальної моделі

Модель	NNAR(2,1,6)[52]
Кількість моделей для побудови для усереднення результатів	11
Кількість вхідних параметрів	5
Кількість вузлів у прихованому шарі	6
Загальна кількість вагових коефіцієнтів	43
Кількість несезонних лагів, що використовуються для аналізу	2
Кількість сезонних лагів, що використовуються для аналізу	1
Кількість зовнішніх регресорів	2
Зовнішні регресори	brent dollarRateUkr

## ВИСНОВКИ

Підводячи підсумки дослідження, необхідно сказати, що усі завдання даної кваліфікаційної роботи були виконані. В даній роботі були проаналізовані джерела даних, які можуть бути використані для дослідження соціально-економічних явищ. Вивчено різні моделі прогнозування часових рядів. Було розглянуто сутність та інструменти фінансового і валютного ринків; описано процес формування валютного курсу та політику центрального банку щодо цього в Україні; були виділені ключові фактори попиту та пропозиції на ринку валюти, що мають вплив на її коливання.

В рамках аналізу було обрано оптимальний метод моделювання нестійких часових рядів, що забезпечив високі прогностні властивості та врахував вплив зовнішніх факторів з використанням «ргоху» змінних. Оптимальною в сенсі точності прогнозів моделлю виявилася нейронна мережа, яка навчалася на попередніх спостереженнях офіційного валютного курсу долара США за 266 тижнів, приймаючи в якості вхідних параметрів ціну на ф'ючерси на нафту (Brent Oil Futures) та дані щодо динаміки популярності пошукового запиту «курс долара» в Google разом з лагами основного часового ряду. Оптимальною в сенсі оцінки «точність-складність» стала модель ARIMA з урахуванням зовнішніх факторів (теж цін на ф'ючерси на нафту та динаміки популярності запиту «курс долара»), що навчалась на 255 спостереженнях.

Емпіричним шляхом було доведено, що включення в модель факторів, які є впливовими за Грейнджером, покращує точність її прогнозів та зменшує значення інформаційних критеріїв (де вони є застосовними). У такий спосіб гіпотеза про вплив на офіційний валютний курс долара очікувань серед населення була підтверджена експериментально – в нашому дослідженні це було відображено «ргоху» змінною, яка уособлювала динаміку популярності пошукового запиту «курс долара».

На мою думку, результати даного дослідження можуть бути використаними для короткострокового прогнозування офіційного валютного курсу долара в Україні за умови обмеженої інформації щодо вхідних даних. Я вважаю, що дана робота може стати підґрунтям подальшого аналізу з використанням структурних моделей векторних авторегресій (VAR) та моделей корекції помилки (VEC), які оцінюють взаємний вплив факторів.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Школьник І.О. Фінансовий ринок України: сучасний стан і стратегія розвитку: Монографія. – Суми: ВВП “Мрія-1” ЛТД, УАБС НБУ, 2008. – 348 с.
2. Дема Д.І. Фінансовий ринок : навч. посібник / Д94 Д. І. Дема, І. В. Абрамова, Л.В. Недільська; за заг. ред. Д.І. Деми. – Житомир: ЖНАЕУ, 2017. – 448 с.
3. Экономическая теория: Учебник / Под общ. ред. акад. В.И. Видяпина, А.И. Добрынина, Г.П. Журавлевой, Л.С. Тарасевича. - М.: ИНФРА-М, 2003. - 714 с.
4. Предборський В.А., Гарін Б.Б., Кухаренко В.Д. Економічна теорія /Під редакцією Предборського В.А. – К.: Кондор, 2003. – 492с.
5. Курс экономической теории: учебник - 4-е дополненное и переработанное издание - Киров: «АСА», 2000 г. - 752 с.
6. Моторнюк У.І., Гуцуляк У.П.. ЧИННИКИ ФОРМУВАННЯ ВАЛЮТНОГО КУРСУ В УКРАЇНІ. - Національний університет ”Львівська політехніка”, Інститут управління природними ресурсами, “Університет економіки та права “КРОК”. – 2012.
7. Маринич Т.О. ВАЛЮТНА ПОЛІТИКА В СИСТЕМІ ЗАБЕЗПЕЧЕННЯ ФІНАНСОВОЇ СТАБІЛЬНОСТІ ЕКОНОМІКИ: Дисертація на здобуття наукового ступеня кандидата економічних наук. – Суми: СумДУ, 2014. – 311 с.
8. Фарина О. І. ОЦІНКА ФАКТОРІВ ФОРМУВАННЯ ВАЛЮТНОГО КУРСУ В УКРАЇНІ / О. І. ФАРИНА // НАУКОВІ ЗАПИСКИ НАУКМА. ЕКОНОМІЧНІ НАУКИ. – 2015.
9. The theory and empirics of exchange rates / edited by Imad A. Moosa & Razzaque H. Bhatti. - World Scientific Publishing Co. Pte. Ltd, 2009.
10. Афанасьев В.Н., Юзбашев М.М. Анализ временных рядов и прогнозирование: Учебник. – М.: Финансы и статистика, 2001. – 228 с.
11. Чернова Н. И. Математическая статистика: Учеб. пособие. – Новосибир. гос. ун., Новосибирск: 2007. - 148 с.
12. How to Decompose Time Series Data into Trend and Seasonality [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://machinelearningmastery.com/decompose-time-series-data-trend-seasonality/>.

13. Rob J Hyndman and George Athanasopoulos. Forecasting: Principles and Practice [Электронный ресурс]: [Веб-сайт]. – Электронні дані. – Режим доступу: <https://otexts.com/fpp2>.
- 14.7 Ways Time Series Forecasting Differs from Machine Learning [Электронный ресурс]: [Веб-сайт]. – Электронні дані. – Режим доступу: <https://www.datascience.com/blog/time-series-forecasting-machine-learning-differences>.
15. What is Exponential Smoothing? Single Exponential Smoothing [Электронный ресурс]: [Веб-сайт]. – Электронні дані. – Режим доступу: <https://www.itl.nist.gov/div898/handbook//pmc/section4/pmc431.htm>.
- 16.11 Classical Time Series Forecasting Methods in Python (Cheat Sheet) [Электронный ресурс]: [Веб-сайт]. – Электронні дані. – Режим доступу: <https://machinelearningmastery.com/time-series-forecasting-methods-in-python-cheat-sheet/>.
17. Time Series: ARIMA Model [Электронный ресурс]: [Веб-сайт]. – Электронні дані. – Режим доступу: <https://medium.com/@kangeugine/time-series-arima-model-11140bc08c6>.
18. Магнус Я.Р., Катышев П.К., Пересецкий А.А. Эконометрика: начальный курс: Учеб. – 6-е изд., перераб. и доп. – М.: Дело, 2004. – 576 с.
19. Granger C. Spurious Regression in Econometrics / C. Granger, P. Newbold // Journal of Econometrics. – 1974. – № 2.
20. Пелипась И. В. Денежная масса и цены в Беларуси: результаты эконометрического анализа // Квартальный бюллетень клуба экономистов: Выпуск 3. - Минск: ПроPILEI, 2000.
21. Charemza W., Deadman D. New Directions in Econometric Practice // Edward Elgar Publishing. – 1992. – 370 p.
22. Швайко П. Эконометрические модели анализа и прогнозирования емкости первичного рынка ГКО / П. Швайко // Экоинвест. – 2002. – № 2.
23. Канторович Г.Г. Анализ временных рядов: лекционные и методические материалы / Г. Г. Канторович // Экономический журнал ВШЭ. – 2002. – № 4.

24. Granger C. W. Investigating Casual Relations by Econometric Methods and Cross-Spectral Methods / C.W. Granger // *Econometrica*. – 1969. – Vol.37.
25. *Machine Learning For Dummies*, IBM Limited Edition. - John Wiley & Sons, Inc., 2018.
26. Alex Smola and S.V.N. Vishwanathan. *Introduction to Machine Learning*. - Cambridge University Press, 2008.
27. Makridakis S, Spiliotis E, Assimakopoulos V. Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE* 13(3), 2018.
28. Multilayer Perceptron (MLP) [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.techopedia.com/definition/20879/multilayer-perceptron-mlp>.
29. Wikimedia Commons. File:MultiLayerPerceptron.svg [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://commons.wikimedia.org/wiki/File:MultiLayerPerceptron.svg>.
30. A Beginner's Guide to Multilayer Perceptrons (MLP) [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://skymind.ai/wiki/multilayer-perceptron>.
31. Державна служба статистики України [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <http://ukrstat.gov.ua>.
32. Офіційне Інтернет-представництво Національного банку України [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://bank.gov.ua/>.
33. Twitter. Search Tweets [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://developer.twitter.com/en/docs/tweets/search/overview>.
34. Abdeljalil Elouardighi, Mohcine Maghfour, Hafdalla Hammia. *Collecting and Processing Arabic Facebook Comments for Sentiment Analysis*. - Springer International Publishing AG, 2017.
35. Aitor Garcia-Pablos, Montse Cuadros, Maria Teresa Linaza. Automatic analysis of textual hotel reviews. - *Information Technology & Tourism*. March 2016, Volume 16, Issue 1, p. 45–69.

36. Google Trends [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://trends.google.com>.
37. Ковтун Н.В., Бабірад-Лазунін В.О. МЕТОДОЛОГІЧНІ ЗАСАДИ ТА ПРАКТИКА ОЦІНЮВАННЯ УМОВ І ЕФЕКТИВНОСТІ ЗОВНІШНЬОЇ ТОРГІВЛІ УКРАЇНИ. - Зовнішня торгівля: економіка, фінанси, право. Науковий журнал. Серія: Економічні науки. № 5-6 (82-83), 2015.
38. London Wheat Futures Historical Data [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.investing.com/commodities/london-wheat-historical-data>.
39. US Corn Futures Historical Data [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.investing.com/commodities/us-corn-historical-data>.
40. Iron ore fines 62% Fe CFR Futures Historical Data [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.investing.com/commodities/iron-ore-62-cfr-futures-historical-data>.
41. Coal Futures Historical Data [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.investing.com/commodities/coal-cme-futures-historical-data>.
42. Brent Oil Futures Historical Data [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.investing.com/commodities/brent-oil-historical-data>.
43. accuracy. Accuracy Measures For A Forecast Model [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.rdocumentation.org/packages/forecast/versions/8.7/topics/accuracy>.
44. tbats. TBATS Model (Exponential Smoothing State Space Model With Box-Cox Transformation, ARMA Errors, Trend And Seasonal Components) [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.rdocumentation.org/packages/forecast/versions/8.7/topics/tbats>.

45. AIC. Akaike's An Information Criterion [Електронний ресурс]: [Веб-сайт]. – Електронні дані. – Режим доступу: <https://www.rdocumentation.org/packages/forecast/versions/8.7/topics/tbats>.
46. Alysha M De Livera, Rob J Hyndman and Ralph D Snyder. Forecasting time series with complex seasonal patterns using exponential smoothing. - Working Paper 15/09, 28 October 2010. = 39 p.

## ДОДАТОК А

Код програми, яка, використовуючи АРІ НБУ, отримувала дані щодо щоденного курсу гривні та робила його усереднення за тижнями

```
import requests
from bs4 import BeautifulSoup

dayCount = 0
avRate = 0.

rateList = []

for year in ['2013', '2014', '2015', '2016', '2017', '2018', '2019']:

    months = ['01', '02', '03', '04', '05', '06', '07', '08', '09',
             '10', '11', '12']

    if year == '2013':
        months = ['11', '12']
    elif year == '2019':
        months = ['01']

    for month in months:

        days = ['01', '02', '03', '04', '05', '06', '07', '08',
               '09', '10', '11', '12', '13', '14', '15', '16',
               '17', '18', '19', '20', '21', '22', '23', '24',
               '25', '26', '27', '28', '29', '30', '31']

        if year == '2013' and month == '11':
            days = ['03', '04', '05', '06', '07', '08',
                   '09', '10', '11', '12', '13', '14', '15', '16',
                   '17', '18', '19', '20', '21', '22', '23', '24',
                   '25', '26', '27', '28', '29', '30', '31']
        elif year == '2019':
            days = ['01', '02', '03', '04', '05']
```



```

for day in days:

    link =
"https://bank.gov.ua/NBUStatService/v1/statdirectory/exchange?valcode=
USD&date=" + year + month + day
    r = requests.get(link)
    soup = BeautifulSoup(r.content, "html")

    mes = soup.find_all("message")
    if len(mes) != 0 and mes[0].text == u'Wrong parameters
format':

        continue

    dayCount = dayCount + 1

    for rate in soup.find_all("rate"):
        avRate = avRate + float(rate.text)

    if dayCount == 7:
        avRate = avRate / 7.0
        rateList.append(avRate)
        print year, month, day
        dayCount = 0
        avRate = 0.

print len(rateList)
rateList

import pandas as pd
rateDF = pd.DataFrame(data=[rateList])
rateDF = rateDF.transpose()
rateDF.head()

rateDF.to_csv("officialRate.csv", index_label=False, index=False)

```

## ДОДАТОК Б

## Код програми для підготовки та попереднього аналізу даних (мова програмування – R)

```

fullData = read.csv("../data/fullData.csv", header = TRUE, sep = ";", dec = ",") # завантаження
даних в програму
head(fullData)
##           week martialLawRus martialLawUkr dollarRateRus dollarRateUkr
## 1 03.11.2013           0.0           0.0           4           2
## 2 10.11.2013           0.0           0.0           4           2
## 3 17.11.2013           0.0           0.0           4           2
## 4 24.11.2013           0.5           0.0           4           2
## 5 01.12.2013           0.5           0.5           7           5
## 6 08.12.2013           0.5           0.5           6           4
##  exchangeRates maidan  tranche externalDebtRus externalDebtUkr
## 1           8    0.5      2           11           17
## 2           8    0.5      0           23           50
## 3           7    4.0      2           17           41
## 4           8   17.0      5           22           32
## 5          10   39.0      2           11           32
## 6          10   38.0      0           32           24
##  devaluationRus devaluationUkr inflationRus inflationUkr reserveRus
## 1           16           37           26           25           10
## 2           26           15           25           50           13
## 3            7           43           22           38           0
## 4           41           43           39           33           13
## 5           51           35           23           28           16
## 6           47           35           26           52           16
##  reserveUkr warRus warUkr avRateBuy avRateSell  brent  coal  iron  wheat
## 1           0      1    33  2762.378  2789.879 105.12 59.40 135.25 163.25
## 2          23      4    28  2749.395  2774.238 108.50 59.35 135.71 164.00
## 3           0      4    27  2761.880  2783.279 111.05 60.25 136.33 164.25
## 4          22      7    31  2778.856  2798.395 109.69 60.10 136.32 164.50
## 5          65      5    27  2789.668  2809.067 111.61 60.75 138.10 164.70
## 6           0      7    18  2807.552  2837.935 108.83 64.75 137.40 165.40
##  corn officialRate tradeQuant tradePrice interestRate M2_reserve
## 1 426.75           7.993           104.1           96.0           12.8  46.62637
## 2 422.00           7.993           104.1           96.0           12.8  46.62637
## 3 422.25           7.993           104.1           96.0           12.8  46.62637
## 4 415.25           7.993           104.1           96.0           12.8  46.62637
## 5 424.00           7.993           122.6           95.2           13.6  48.17350

```

```
## 6 420.50          7.993          122.6          95.2          13.6  44.38917

# видалення допоміжного стовпця з тижнем
fullData = fullData[-1]
head(fullData)

##      martialLawRus martialLawUkr dollarRateRus dollarRateUkr exchangeRates
## 1             0.0             0.0             4             2             8
## 2             0.0             0.0             4             2             8
## 3             0.0             0.0             4             2             7
## 4             0.5             0.0             4             2             8
## 5             0.5             0.5             7             5            10
## 6             0.5             0.5             6             4            10

##      maidan tranche externalDebtRus externalDebtUkr devaluationRus
## 1      0.5      2             11             17             16
## 2      0.5      0             23             50             26
## 3      4.0      2             17             41              7
## 4     17.0     5             22             32             41
## 5     39.0     2             11             32             51
## 6     38.0     0             32             24             47

##      devaluationUkr inflationRus inflationUkr reserveRus reserveUkr warRus
## 1                 37             26             25             10             0             1
## 2                 15             25             50             13             23             4
## 3                 43             22             38              0             0             4
## 4                 43             39             33             13             22             7
## 5                 35             23             28             16             65             5
## 6                 35             26             52             16              0             7

##      warUkr avRateBuy avRateSell  brent  coal  iron  wheat  corn
## 1      33  2762.378  2789.879 105.12 59.40 135.25 163.25 426.75
## 2      28  2749.395  2774.238 108.50 59.35 135.71 164.00 422.00
## 3      27  2761.880  2783.279 111.05 60.25 136.33 164.25 422.25
## 4      31  2778.856  2798.395 109.69 60.10 136.32 164.50 415.25
## 5      27  2789.668  2809.067 111.61 60.75 138.10 164.70 424.00
## 6      18  2807.552  2837.935 108.83 64.75 137.40 165.40 420.50

##      officialRate tradeQuant tradePrice interestRate M2_reserve
## 1          7.993          104.1          96.0          12.8  46.62637
## 2          7.993          104.1          96.0          12.8  46.62637
## 3          7.993          104.1          96.0          12.8  46.62637
## 4          7.993          104.1          96.0          12.8  46.62637
## 5          7.993          122.6          95.2          13.6  48.17350
## 6          7.993          122.6          95.2          13.6  44.38917
```

```
# візуалізація часового ряду з курсом
```

```
library(lubridate)
```

```

rateTs = ts(fullData$officialRate, freq=365.25/7, start=decimal_date(ymd("2013-11-03"))) # пер
етворення в об'єкт "часовий ряд"

jpeg("Official_rate.jpg", width = 700, height = 300)
plot(rateTs, main = 'Офіційний обмінний курс НБУ', ylab = "грн. за дол. США", xlab = "Час")
dev.off()

## quartz_off_screen
##           2

# перевірка на стаціонарність
library(tseries)
library(forecast)
adf.test(rateTs)

##
## Augmented Dickey-Fuller Test
##
## data: rateTs
## Dickey-Fuller = -1.9321, Lag order = 6, p-value = 0.6046
## alternative hypothesis: stationary
ndiffs(rateTs) # визначення порядку диференціювання для стаціонарності
## [1] 1
adf.test(diff(rateTs, differences = 1))

##
## Augmented Dickey-Fuller Test
##
## data: diff(rateTs, differences = 1)
## Dickey-Fuller = -7.4163, Lag order = 6, p-value = 0.01
## alternative hypothesis: stationary

# декомпозиція та візуалізація
library(forecast)

jpeg("Decomposition.jpg", width = 700, height = 500)
plot(decompose(rateTs), xlab = "Час")
title("Декомпозиція часового ряду")
dev.off()

## quartz_off_screen
##           2

# автокореляційна та частинна автокореляційна функції
jpeg("ACF_PACF.jpg", width = 700, height = 600)
par(mfrow=c(2,2))

acf(fullData$officialRate, main = "Графік автокореляційної функції вибірки", xlab = "Лag", yla
b = "Значення функції")

```

```

acf(diff(fullData$officialRate, differences = 1), main = "Графік автокореляційної функції перш
их\нпрізниць вибірки", xlab = "Лар", ylab = "Значення функції")

pacf(fullData$officialRate, main = "Графік частинної автокореляційної функції вибірки", xlab =
"Лар", ylab = "Значення функції")

pacf(diff(fullData$officialRate, differences = 1), main = "Графік частинної автокореляційної ф
ункції перших\нпрізниць вибірки", xlab = "Лар", ylab = "Значення функції")

dev.off()

## quartz_off_screen
##
##          2

# гістограми
jpeg("hist.jpg", width = 700, height = 300)
par(mfrow=c(1,2))
hist(rateTs, main = "Гістограма вибірки", xlab = "грн. за дол. США", ylab = "Частота")
hist(window(rateTs, start=decimal_date(ymd("2015-03-08"))), main = "Гістограма вибірки\n(після
зими 2015 р.)", xlab = "грн. за дол. США", ylab = "Частота")
dev.off()

## quartz_off_screen
##
##          2

# Q-Q plots часового ряду
jpeg("Q-Q plot Official rate.jpg", width = 700, height = 300)
par(mfrow=c(1,2))
qqnorm(rateTs, col="orange", pch=20, main = "Q-Q Plot часового ряду", xlab = "Теоретичні квант
или", ylab = "Квантилі вибірки")
qqline(rateTs, col = "blue")
qqnorm(window(rateTs, start=decimal_date(ymd("2015-03-08"))), col="orange", pch=20, main = "Q-
Q Plot часового ряду\n(після зими 2015 р.)", xlab = "Теоретичні квантилі", ylab = "Квантилі ви
бірки")
qqline(window(rateTs, start=decimal_date(ymd("2015-03-08"))), col = "blue")
dev.off()

## quartz_off_screen
##
##          2

# оцінка кореляції між змінними
corrLag0 = cor(fullData)
# побудова візуального відображення кореляції між змінними
library(corrplot)
jpeg("Correlation.jpg", width = 500, height = 500)
corrplot(cor(fullData))
dev.off()

## quartz_off_screen
##
##          2

# розрахунок конкретних цікавих кореляцій
cor(fullData$reserveRus, fullData$tradePrice) # динаміка запиту «золотовалютные резервы» та ці
новий індекс умов торгівлі
## [1] -0.6401047

```

```

cor(fullData$reserveRus, fullData$M2_reserve) # динаміка запиту «золотовалютные резервы» та M2
/резерви
## [1] 0.6969957

# розрахунок кореляцій офіційного валютного курсу з іншими факторами
cor(fullData$officialRate, fullData[c(1:24, 26:29)])

##      martialLawRus martialLawUkr dollarRateRus dollarRateUkr exchangeRates
## [1,]    0.05134308    0.04809758   -0.04464088    0.1634142   -0.2131167
##      maidan      tranche externalDebtRus externalDebtUkr devaluationRus
## [1,] -0.4107937 0.005151305   -0.4281388   -0.2826938   -0.5072037
##      devaluationUkr inflationRus inflationUkr reserveRus reserveUkr
## [1,]   -0.3079081   -0.3434426   -0.244403 -0.1699943 -0.1999582
##      warRus      warUkr  avRateBuy avRateSell      brent      coal
## [1,] -0.5389455 -0.4580582 -0.5730004 -0.5531983 -0.7595326 -0.04460548
##      iron      wheat      corn tradeQuant tradePrice interestRate
## [1,] -0.7209214 -0.02707711 -0.6284149 -0.6882907  0.3565265   -0.7250629
##      M2_reserve
## [1,]  0.1009114

# кореляція між попередніми значеннями (минулий тиждень) факторів впливу та поточними значення
офіційного курсу долара США
lastWeek = fullData[-1, ]
lastWeek$officialRate = fullData$officialRate[2:270]
cor(lastWeek$officialRate, lastWeek[c(1:24, 26:29)])

##      martialLawRus martialLawUkr dollarRateRus dollarRateUkr exchangeRates
## [1,]    0.05045857    0.04734289   -0.05777662    0.1530033   -0.2253408
##      maidan      tranche externalDebtRus externalDebtUkr devaluationRus
## [1,] -0.4168129 0.001196048   -0.4353605   -0.2869424   -0.5109152
##      devaluationUkr inflationRus inflationUkr reserveRus reserveUkr
## [1,]   -0.3037821   -0.3446961   -0.2479699 -0.1757282 -0.2070631
##      warRus      warUkr  avRateBuy avRateSell      brent      coal
## [1,] -0.550373 -0.4575812 -0.5720492 -0.5521494 -0.7563346 -0.04095801
##      iron      wheat      corn tradeQuant tradePrice interestRate
## [1,] -0.7145916 -0.01677633 -0.6251702 -0.6953501  0.3567474   -0.7279368
##      M2_reserve
## [1,]  0.09213781

corrLag1 = cor(lastWeek)

```

## Split: 255 train, 15 test

```

# прогнозування середнім значенням
fullData_ts = ts(fullData, freq=365.25/7, start=decimal_date(ymd("2013-11-03"))) # перетворення
я в об'єкт "часовий ряд"

train = window(fullData_ts, end=2018.725) # перші 255 тижнів

```

```

test = window(fullData_ts, start=2018.725) # останні 15 тижнів

library(ggplot2)
meanModel = meanf(train[, "officialRate"], h = 15)

jpeg("Mean_forecast_255_15.jpg", width = 700, height = 300)
autoplot(meanModel) +
  ggtitle("Прогнозування середнім значенням (поділ вибірки: 255/15)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(meanModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##           2

meanAccuracy = accuracy(meanModel, test[, "officialRate"]) # створення таблиці з оцінками похибок моделі
meanAccuracy

##           ME           RMSE           MAE           MPE           MAPE           MASE
## Training set 1.621500e-15 6.337029 5.284226 -15.03945 35.10124 1.243568
## Test set     6.116201e+00 6.120313 6.116201  21.87692 21.87692 1.439361
##           ACF1 Theil's U
## Training set 0.983836      NA
## Test set     0.595255 33.08901

# TBATS Model (Exponential Smoothing State Space Model With Box-Cox Transformation, ARMA Error
s, Trend And Seasonal Components)
tbatsData = tbats(diff(train[, "officialRate"], differences = 1))
tbatsModel = forecast(tbatsData, h = 15)

jpeg("TBATS_255_15.jpg", width = 700, height = 300)
autoplot(tbatsModel) +
  ggtitle("Прогнозування за допомогою моделі TBATS (поділ вибірки: 255/15)") +
  xlab("Час") +
  ylab("грн. за дол. США (перші різниці)") +
  autolayer(diff(test[, "officialRate"], differences = 1), series="Реальні дані") +
  autolayer(tbatsModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen

```

```
##                2
tbatsAccuracy = accuracy(tbatsModel, diff(test[, "officialRate"], differences = 1)) # створення
таблиці з оцінками похибок моделі
tbatsAccuracy
##                ME          RMSE          MAE          MPE          MAPE          MASE
## Training set  0.03770533 0.5234342 0.2864995        -Inf          Inf 0.6349157
## Test set     -0.06733004 0.1970277 0.1736007 47.43369 146.1928 0.3847190
##                ACF1 Theil's U
## Training set -0.007430594          NA
## Test set     -0.105842282  1.113428

# ARIMA Model
arimaModel = forecast(auto.arima(train[, "officialRate"], ic = 'aicc', stepwise = FALSE), h = 15)

jpeg("ARIMA_255_15.jpg", width = 700, height = 300)
autoplot(arimaModel) +
  ggtitle("Прогнозування за допомогою моделі ARIMA (поділ вибірки: 255/15)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(arimaModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2
arimaAccuracy = accuracy(arimaModel, test[, "officialRate"]) # створення таблиці з оцінками похибок моделі
arimaAccuracy
##                ME          RMSE          MAE          MPE          MAPE
## Training set -0.0003598446 0.5199528 0.2962842  0.04616764 1.473032
## Test set     -0.7230477903 0.8996720 0.7355419 -2.60121024 2.645492
##                MASE          ACF1 Theil's U
## Training set 0.06972631 -0.01514717          NA
## Test set     0.17309939  0.76911741  5.079691

# ARIMA Model with additional features
arima2Model = forecast(auto.arima(train[, "officialRate"], ic = 'aicc', stepwise = FALSE, xreg = train[, c("brent", "dollarRateUkr")]), h = 15, xreg = test[, c("brent", "dollarRateUkr")])

jpeg("ARIMA_with_add_255_15.jpg", width = 700, height = 300)
autoplot(arima2Model) +
  ggtitle("Прогнозування за допомогою моделі ARIMA з урахуванням впливових факторів (поділ вибірки: 255/15)") +
```



```

xlab("Час") +
ylab("грн. за дол. США") +
autolayer(test[, "officialRate"], series="Реальні дані") +
autolayer(arima2Model$mean, series="Прогнози") +
guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##
##                2
arima2Accuracy = accuracy(arima2Model, test[, "officialRate"]) # створення таблиці з оцінками п
охибок моделі
arima2Accuracy
##
##                ME        RMSE        MAE        MPE        MAPE
## Training set -0.0001425948 0.4640261 0.2551791 0.0351082 1.288193
## Test set     -0.7817120712 0.9592741 0.7817121 -2.8095194 2.809519
##
##                MASE        ACF1 Theil's U
## Training set 0.06005279 0.005028447        NA
## Test set     0.18396489 0.682826981 5.419067

# прогнозування за допомогою нейронних мереж БЕЗ урахування впливових факторів
minMAPE = 100.
optRepeats = 10
optSize = 1
for (i in seq(1, 56, 5)){
  for (j in seq(1, 56, 5)){
    set.seed(5)
    nnFit = nnetar(y = train[, "officialRate"], repeats = j, size = i)
    nnModel = forecast(nnFit, h = 15)
    nnAccuracy = accuracy(nnModel, test[, "officialRate"]) # створення таблиці з оцінками похиб
ок моделі
    if (nnAccuracy["Test set", "MAPE"] < minMAPE){
      minMAPE = nnAccuracy["Test set", "MAPE"]
      optSize = i
      optRepeats = j
    }
  }
}
set.seed(5)
nnFit = nnetar(y = train[, "officialRate"], repeats = optRepeats, size = optSize)
nnModel = forecast(nnFit, h = 15)

jpeg("NN_255_15.jpg", width = 700, height = 300)
autoplot(nnModel) +

```

```

ggtitle("Прогнозування за допомогою нейронних мереж (поділ вибірки: 255/15)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(nnModel, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2

nnAccuracy = accuracy(nnModel, test[, "officialRate"]) # створення таблиці з оцінками похибок м
оделі
nnAccuracy
##                ME          RMSE          MAE          MPE          MAPE
## Training set -0.001169757 0.3089955 0.2184058 -0.03638851 0.9599169
## Test set      0.202445221 0.3176311 0.2671811  0.71762211 0.9528155
##                MASE          ACF1 Theil's U
## Training set 0.05139873 0.0144830          NA
## Test set     0.06287730 0.6605829  1.751523

optRepeats
## [1] 1

optSize
## [1] 11

# 1 - 11

# прогнозування за допомогою нейронних мереж з урахуванням впливових факторів
minMAPE = 100.
optRepeats = 10
optSize = 1
for (i in seq(1, 56, 5)){
  for (j in seq(1, 56, 5)){
    set.seed(5)
    nn2Fit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], re
peats = j, size = i)
    nn2Model = forecast(nn2Fit, xreg = test[, c("brent", "dollarRateUkr")], h = 15)
    nn2Accuracy = accuracy(nn2Model, test[, "officialRate"]) # створення таблиці з оцінками пох
ибок моделі
    if (nn2Accuracy["Test set", "MAPE"] < minMAPE){
      minMAPE = nn2Accuracy["Test set", "MAPE"]
      optSize = i
      optRepeats = j
    }
  }
}

```

```

}

set.seed(5)

nn2Fit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], repeat
s = optRepeats, size = optSize)

nn2Model = forecast(nn2Fit, xreg = test[, c("brent", "dollarRateUkr")], h = 15)

jpeg("NN_with_infl_255_15.jpg", width = 700, height = 300)

autoplot(nn2Model) +
  ggtitle("Прогнозування за допомогою нейронних мереж з урахуванням впливових факторів (поділ
вибірки: 255/15)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(nn2Model, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2

nn2Accuracy = accuracy(nn2Model, test[, "officialRate"]) # створення таблиці з оцінками похибок
моделі
nn2Accuracy
##                ME        RMSE        MAE        MPE        MAPE
## Training set -0.0001389597 0.2554168 0.1844433 -0.01783701 0.7947347
## Test set      0.1755266351 0.3605841 0.2240848  0.62698590 0.8004739
##                MASE        ACF1 Theil's U
## Training set 0.04340613 0.1076496         NA
## Test set     0.05273520 0.6237540  2.023297

optRepeats
## [1] 56

optSize
## [1] 6

# 56 - 6

```

## Split: 266 train, 4 test

```

# прогнозування середнім значенням

fullData_ts = ts(fullData, freq=365.25/7, start=decimal_date(ymd("2013-11-03"))) # перетворенн
я в об'єкт "часовий ряд"

train = window(fullData_ts, end=2018.936) # перші 266 тижнів
test = window(fullData_ts, start=2018.936) # останні 4 тижні

library(ggplot2)

```

```

meanModel = meanf(train[, "officialRate"], h = 4)

jpeg("Mean_forecast_266_4.jpg", width = 700, height = 300)
autoplot(meanModel) +
  ggtitle("Прогнозування середнім значенням (поділ вибірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(meanModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2

meanAccuracy = accuracy(meanModel, test[, "officialRate"]) # створення таблиці з оцінками похибок моделі
meanAccuracy

```

	ME	RMSE	MAE	MPE	MAPE	MASE
## Training set	8.617435e-16	6.327132	5.238207	-14.83797	34.58546	1.277553
## Test set	5.569255e+00	5.570966	5.569255	20.13182	20.13182	1.358293

```

##                ACF1 Theil's U
## Training set 0.98426645      NA
## Test set    0.01108124    26.9929

# TBATS Model (Exponential Smoothing State Space Model With Box-Cox Transformation, ARMA Errors, Trend And Seasonal Components)

tbatsData = tbats(diff(train[, "officialRate"], differences = 1))
tbatsModel = forecast(tbatsData, h = 4)

jpeg("TBATS_266_4.jpg", width = 700, height = 300)
autoplot(tbatsModel) +
  ggtitle("Прогнозування за допомогою моделі TBATS (поділ вибірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США (перші різниці)") +
  autolayer(diff(test[, "officialRate"], differences = 1), series="Реальні дані") +
  autolayer(tbatsModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2

tbatsAccuracy = accuracy(tbatsModel, diff(test[, "officialRate"], differences = 1)) # створення таблиці з оцінками похибок моделі

```

```

tbatsAccuracy
##              ME      RMSE      MAE      MPE      MAPE      MASE
## Training set -0.018238505 0.5205442 0.2762446      NaN      Inf 0.6358798
## Test set     -0.007883819 0.1827013 0.1497856 65.70555 65.70555 0.3447873
##              ACF1 Theil's U
## Training set -0.02556417      NA
## Test set     -0.51221797 0.9789996

# ARIMA Model
arimaModel = forecast(auto.arima(train[, "officialRate"], ic='aicc', stepwise=FALSE), h=4)

jpeg("ARIMA_266_4.jpg", width = 700, height = 300)
autoplot(arimaModel) +
  ggtitle("Прогнозування за допомогою моделі ARIMA (поділ вибірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(arimaModel$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##              2

arimaAccuracy = accuracy(arimaModel, test[, "officialRate"]) # створення таблиці з оцінками пох
ибок моделі
arimaAccuracy
##              ME      RMSE      MAE      MPE      MAPE
## Training set -0.0003244849 0.5107796 0.2896074 0.04901319 1.430737
## Test set     -0.5157346869 0.5538939 0.5157347 -1.86769671 1.867697
##              MASE      ACF1 Theil's U
## Training set 0.07063274 -0.01508503      NA
## Test set     0.12578323 0.28247139 3.033938

# ARIMA Model with additional features
arima2Model = forecast(auto.arima(train[, "officialRate"], ic = 'aicc', stepwise = FALSE, xreg
= train[,c("brent", "dollarRateUkr")])), h = 4, xreg = test[,c("brent", "dollarRateUkr")])

jpeg("ARIMA_with_add_266_4.jpg", width = 700, height = 300)
autoplot(arima2Model) +
  ggtitle("Прогнозування за допомогою моделі ARIMA з урахуванням впливових факторів (поділ виб
ірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +

```

```

autolayer(arima2Model$mean, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд"), fill = guide_legend(title = "Рівень довіри")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##           2

arima2Accuracy = accuracy(arima2Model, test[, "officialRate"]) # створення таблиці з оцінками п
охибок моделі
arima2Accuracy
##           ME      RMSE      MAE      MPE      MAPE
## Training set -0.0001482636 0.461079 0.2493229 0.03721694 1.243245
## Test set     -1.2092936943 1.241945 1.2092937 -4.37695644 4.376956
##           MASE      ACF1 Theil's U
## Training set 0.0608077 0.008833214      NA
## Test set     0.2949363 0.052501740 6.609762

# прогнозування за допомогою нейронних мереж БЕЗ урахування впливових факторів
minMAPE = 100.
optRepeats = 10
optSize = 1
for (i in seq(1, 56, 5)){
  for (j in seq(1, 56, 5)){
    set.seed(5)
    nnFit = nnetar(y = train[, "officialRate"], repeats = j, size = i)
    nnModel = forecast(nnFit, h = 4)
    nnAccuracy = accuracy(nnModel, test[, "officialRate"]) # створення таблиці з оцінками похиб
ок моделі
    if (nnAccuracy["Test set", "MAPE"] < minMAPE){
      minMAPE = nnAccuracy["Test set", "MAPE"]
      optSize = i
      optRepeats = j
    }
  }
}
set.seed(5)
nnFit = nnetar(y = train[, "officialRate"], repeats = optRepeats, size = optSize)
nnModel = forecast(nnFit, h = 4)

jpeg("NN_266_4.jpg", width = 700, height = 300)
autoplot(nnModel) +
  ggtitle("Прогнозування за допомогою нейронних мереж (поділ вибірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США") +

```

```

autolayer(test[, "officialRate"], series="Реальні дані") +
autolayer(nnModel, series="Прогнози") +
guides(colour = guide_legend(title = "Ряд")) +
scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##
##                2
nnAccuracy = accuracy(nnModel, test[, "officialRate"]) # створення таблиці з оцінками похибок м
оделі
nnAccuracy
##
##                ME        RMSE        MAE        MPE        MAPE
## Training set -7.522756e-05 0.3364444 0.2364243 -0.05835327 1.0271513
## Test set      1.186128e-02 0.1297532 0.1088737  0.04278026 0.3939208
##
##                MASE        ACF1 Theil's U
## Training set 0.05766183  0.04611306        NA
## Test set     0.02655336 -0.38097094 0.6871281

optRepeats
## [1] 21

optSize
## [1] 6

# 21 - 6
# прогнозування за допомогою нейронних мереж з урахуванням впливових факторів
minMAPE = 100.
optRepeats = 10
optSize = 1
for (i in seq(1, 56, 5)){
  for (j in seq(1, 56, 5)){
    set.seed(5)
    nn2Fit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], re
peats = j, size = i)
    nn2Model = forecast(nn2Fit, xreg = test[, c("brent", "dollarRateUkr")], h = 4)
    nn2Accuracy = accuracy(nn2Model, test[, "officialRate"]) # створення таблиці з оцінками пох
ибок моделі
    if (nn2Accuracy["Test set", "MAPE"] < minMAPE){
      minMAPE = nn2Accuracy["Test set", "MAPE"]
      optSize = i
      optRepeats = j
    }
  }
}
set.seed(5)
nn2Fit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], repeat
s = optRepeats, size = optSize)

```

```

nn2Model = forecast(nn2Fit, xreg = test[,c("brent", "dollarRateUkr")], h = 4)

jpeg("NN_with_infl_266_4.jpg", width = 700, height = 300)
autoplot(nn2Model) +
  ggtitle("Прогнозування за допомогою нейронних мереж з урахуванням впливових факторів (поділ
вибірки: 266/4)") +
  xlab("Час") +
  ylab("грн. за дол. США") +
  autolayer(test[, "officialRate"], series="Реальні дані") +
  autolayer(nn2Model, series="Прогнози") +
  guides(colour = guide_legend(title = "Ряд")) +
  scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2
nn2Accuracy = accuracy(nn2Model, test[, "officialRate"]) # створення таблиці з оцінками похибок
моделі
nn2Accuracy
##                ME        RMSE        MAE        MPE        MAPE
## Training set -0.001010529 0.2602270 0.1857432 -0.02122490 0.8046307
## Test set     -0.024802796 0.1153539 0.1026702 -0.08960613 0.3713483
##                MASE        ACF1 Theil's U
## Training set 0.04530117 0.1299571        NA
## Test set     0.02504036 -0.3338301 0.5421243

optRepeats
## [1] 11

optSize
## [1] 6
# 11 - 6

```

## Оптимальна модель

```

fullData_ts = ts(fullData, freq=365.25/7, start=decimal_date(ymd("2013-11-03")))

train = window(fullData_ts, end=2018.936) # перші 266 тижнів
test = window(fullData_ts, start=2018.936) # останні 4 тижні

set.seed(5)

optimalFit = nnetar(y = train[, "officialRate"], xreg = train[,c("brent", "dollarRateUkr")], re
peats = 11, size = 6)

optimalModel = forecast(optimalFit, xreg = test[,c("brent", "dollarRateUkr")], h = 4)

optimalAccuracy = accuracy(optimalModel, test[, "officialRate"]) # створення таблиці з оцінками
похибок моделі

```



```

optimalAccuracy
##                ME      RMSE      MAE      MPE      MAPE
## Training set -0.001010529 0.2602270 0.1857432 -0.02122490 0.8046307
## Test set     -0.024802796 0.1153539 0.1026702 -0.08960613 0.3713483
##                MASE      ACF1 Theil's U
## Training set 0.04530117 0.1299571      NA
## Test set     0.02504036 -0.3338301 0.5421243

# Q-Q plot
jpeg("QQplot_optimal.jpg", width = 500, height = 400)
qqnorm(optimalModel$residuals, col="orange", pch=20, main = "Q-Q Plot", xlab = "Теоретичні квантилі", ylab = "Квантилі вибірки")
qqline(optimalModel$residuals, col = "blue")
dev.off()

## quartz_off_screen
##                2

# Heteroscedasticity
jpeg("Heteroscedasticity_optimal.jpg", width = 700, height = 300)
plot(optimalModel$residuals, main = "Графік залишків оптимальної моделі", xlab = "Час", ylab = "Залишки")
dev.off()

## quartz_off_screen
##                2

jpeg("ACF_optimal.jpg", width = 700, height = 300)
acf(na.remove(optimalModel$residuals), main = "Графік автокореляційної функції залишків оптимальної моделі", xlab = "Лар", ylab = "Значення функції")
dev.off()

## quartz_off_screen
##                2

```

## Removing 2015's “jump” for model with optimal parameters

```

train = window(fullData_ts, start=decimal_date(ymd("2015-03-08")), end=2018.936)
test = window(fullData_ts, start=2018.936)

set.seed(5)

optimalNew = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], p = 2, P = 1, repeats = 11, size = 6)

optimalModelNew = forecast(optimalNew, xreg = test[, c("brent", "dollarRateUkr")], h = 4)

jpeg("NN_optimal_without_jump.jpg", width = 700, height = 300)
autoplot(optimalModelNew) +
  ggtitle("Прогнозування на 4 тижні за допомогою нейронних мереж з оптимальними параметрами з урахуванням впливових факторів та початком тестової вибірки після лютого 2015 року") +
  xlab("Час") +

```

```

ylab("грн. за дол. США") +
autolayer(test[, "officialRate"], series="Реальні дані") +
autolayer(optimalModelNew, series="Прогнози") +
guides(colour = guide_legend(title = "Ряд")) +
scale_color_manual(values = c("red", "blue"))
dev.off()

## quartz_off_screen
##                2

optimalNewAccuracy = accuracy(optimalModelNew, test[, "officialRate"]) # створення таблиці з оцінками похибок моделі
optimalNewAccuracy

##                ME        RMSE        MAE        MPE        MAPE
## Training set -7.100715e-05 0.1210914 0.09065349 -0.00286381 0.3415999
## Test set      9.858476e-02 0.2894444 0.20735385  0.35822442 0.7495046
##                MASE        ACF1 Theil's U
## Training set 0.05242161 0.05990230        NA
## Test set     0.11990518 0.09957166  1.582463

# Q-Q plot optimal new
jpeg("QQplot_optimal_without_jump.jpg", width = 500, height = 400)
qqnorm(optimalModelNew$residuals, col="orange", pch=20, main = "Q-Q Plot", xlab = "Теоретичні квантилі", ylab = "Квантилі вибірки")
qqline(optimalModelNew$residuals, col = "blue")
dev.off()

## quartz_off_screen
##                2

# Heteroscedasticity optimal new
jpeg("Heteroscedasticity_optimal_without_jump.jpg", width = 700, height = 300)
plot(optimalModelNew$residuals, main = "Графік залишків моделі з оптимальними параметрами \nпід початком тестової вибірки після лютого 2015 року", xlab = "Час", ylab = "Залишки")
dev.off()

## quartz_off_screen
##                2

# ACF optimal new
jpeg("ACF_optimal_without_jump.jpg", width = 700, height = 300)
acf(na.remove(optimalModelNew$residuals), main = "Графік автокореляційної функції залишків моделі з оптимальними параметрами \nпід початком тестової вибірки після лютого 2015 року", xlab = "Лag", ylab = "Значення функції")
dev.off()

## quartz_off_screen
##                2

```

## New model on new data

```
train = window(fullData_ts, start=decimal_date(ymd("2015-03-08")), end=2018.936)
```

```

test = window(fullData_ts, start=2018.936)

minMAPE = 100.
optRepeats = 10
optSize = 1
for (i in seq(1, 56, 5)){
  for (j in seq(1, 56, 5)){
    set.seed(5)

    newFit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], re
peats = j, size = i)

    newModel = forecast(newFit, xreg = test[, c("brent", "dollarRateUkr")], h = 4)

    newAccuracy = accuracy(newModel, test[, "officialRate"]) # створення таблиці з оцінками пох
ибок моделі

    if (newAccuracy["Test set", "MAPE"] < minMAPE){
      minMAPE = newAccuracy["Test set", "MAPE"]
      optSize = i
      optRepeats = j
    }
  }
}

set.seed(5)

newFit = nnetar(y = train[, "officialRate"], xreg = train[, c("brent", "dollarRateUkr")], repeat
s = optRepeats, size = optSize)

newModel = forecast(newFit, xreg = test[, c("brent", "dollarRateUkr")], h = 4)

jpeg("NN_NEW_without_jump.jpg.jpg", width = 700, height = 300)
autoplot(newModel) +

  ggtitle("Прогнозування на 4 тижні за допомогою нейронних мереж з новими параметрами з урахув
анням\ впливових факторів та початком тестової вибірки після лютого 2015 року") +

  xlab("Час") +

  ylab("грн. за дол. США") +

  autolayer(test[, "officialRate"], series="Реальні дані") +

  autolayer(newModel, series="Прогнози") +

  guides(colour = guide_legend(title = "Ряд")) +

  scale_color_manual(values = c("red", "blue"))

dev.off()

## quartz_off_screen
##           2

newAccuracy = accuracy(newModel, test[, "officialRate"]) # створення таблиці з оцінками похибок
моделі

newAccuracy

##           ME           RMSE           MAE           MPE           MAPE
## Training set -1.508439e-05 0.2169632 0.1605995 -0.01211516 0.6035965

```

```

## Test set      -1.169121e-01 0.1517264 0.1169121 -0.42388109 0.4238811
##              MASE          ACF1 Theil's U
## Training set 0.09286883 0.4482712          NA
## Test set     0.06760603 -0.6267701 0.7980554
optRepeats
## [1] 21
optSize
## [1] 1
# 21 1
# Q-Q plot new
jpeg("QQplot_NEW_without_jump.jpg", width = 500, height = 400)
qqnorm(newModel$residuals, col="orange", pch=20, main = "Q-Q Plot", xlab = "Теоретичні квантил
i", ylab = "Квантили вибірки")
qqline(newModel$residuals, col = "blue")
dev.off()
## quartz_off_screen
##              2
# Heteroscedasticity new
jpeg("Heteroscedasticity_NEW_without_jump.jpg", width = 700, height = 300)
plot(newModel$residuals, main = "Графік залишків моделі з новими параметрами \nта початком тес
тової вибірки після лютого 2015 року", xlab = "Час", ylab = "Залишки")
dev.off()
## quartz_off_screen
##              2
# ACF optimal new
jpeg("ACF_NEW_without_jump.jpg", width = 700, height = 300)
acf(na.remove(newModel$residuals), main = "Графік автокореляційної функції залишків моделі з н
овими параметрами \nта початком тестової вибірки після лютого 2015 року", xlab = "Лар", ylab =
"Значення функції")
dev.off()
## quartz_off_screen
##              2

```

## ДОДАТОК В

## Результати тесту Грейнджера на каузальність (лаг = 1)

Null Hypothesis:	Obs	F-Statistic	Prob.
OFFICIALRATE does not Granger Cause AVRATEBUY AVRATEBUY does not Granger Cause OFFICIALRATE	269	1,4169500 0,0196500	0,2350000 0,8886000
OFFICIALRATE does not Granger Cause AVRATESELL AVRATESELL does not Granger Cause OFFICIALRATE	269	1,3412300 0,0341400	0,2479000 0,8536000
OFFICIALRATE does not Granger Cause BRENT BRENT does not Granger Cause OFFICIALRATE	269	0,1241400 4,9809600	0,7249000 0,0265000
OFFICIALRATE does not Granger Cause COAL COAL does not Granger Cause OFFICIALRATE	269	2,6946600 0,4961900	0,1019000 0,4818000
OFFICIALRATE does not Granger Cause CORN CORN does not Granger Cause OFFICIALRATE	269	2,7429100 1,5136700	0,0989000 0,2197000
OFFICIALRATE does not Granger Cause DEVALUATIONRUS DEVALUATIONRUS does not Granger Cause OFFICIALRATE	269	22,3654000 0,9973900	0,0000040 0,3189000
OFFICIALRATE does not Granger Cause DEVALUATIONUKR DEVALUATIONUKR does not Granger Cause OFFICIALRATE	269	13,0244000 2,0888900	0,0004000 0,1496000
OFFICIALRATE does not Granger Cause DOLLARRATERUS DOLLARRATERUS does not Granger Cause OFFICIALRATE	269	1,0796400 3,7319900	0,2997000 0,0544000
OFFICIALRATE does not Granger Cause DOLLARRATEUKR DOLLARRATEUKR does not Granger Cause OFFICIALRATE	269	0,6950200 13,7149000	0,4052000 0,0003000
OFFICIALRATE does not Granger Cause EXCHANGERATES EXCHANGERATES does not Granger Cause OFFICIALRATE	269	4,3959000 4,9215800	0,0370000 0,0274000
OFFICIALRATE does not Granger Cause EXTERNALDEBTRUS EXTERNALDEBTRUS does not Granger Cause OFFICIALRATE	269	23,3960000 0,1488800	0,0000020 0,6999000
OFFICIALRATE does not Granger Cause EXTERNALDEBTUKR EXTERNALDEBTUKR does not Granger Cause OFFICIALRATE	269	17,0710000 0,6659900	0,0000500 0,4152000
OFFICIALRATE does not Granger Cause INFLATIONRUS INFLATIONRUS does not Granger Cause OFFICIALRATE	269	9,6773800 11,0811000	0,0021000 0,0010000
OFFICIALRATE does not Granger Cause INFLATIONUKR INFLATIONUKR does not Granger Cause OFFICIALRATE	269	4,3634600 5,6951300	0,0377000 0,0177000

OFFICIALRATE does not Granger Cause INTERESTRATE INTERESTRATE does not Granger Cause OFFICIALRATE	269	0,9798800 0,9590100	0,3231000 0,3283000
OFFICIALRATE does not Granger Cause IRON IRON does not Granger Cause OFFICIALRATE	269	1,2011100 2,9534500	0,2741000 0,0869000
OFFICIALRATE does not Granger Cause M2_RESERVE M2_RESERVE does not Granger Cause OFFICIALRATE	269	4,8923000 5,7717300	0,0278000 0,0170000
OFFICIALRATE does not Granger Cause MAIDAN MAIDAN does not Granger Cause OFFICIALRATE	269	23,3883000 0,0112200	0,0000020 0,9157000
OFFICIALRATE does not Granger Cause MARTIALLRUS MARTIALLRUS does not Granger Cause OFFICIALRATE	269	0,4433700 0,1452800	0,5061000 0,7034000
OFFICIALRATE does not Granger Cause MARTIALLRUKR MARTIALLRUKR does not Granger Cause OFFICIALRATE	269	0,3280800 0,3824400	0,5673000 0,5368000
OFFICIALRATE does not Granger Cause RESERVERUS RESERVERUS does not Granger Cause OFFICIALRATE	269	1,1698600 0,0010100	0,2804000 0,9747000
OFFICIALRATE does not Granger Cause RESERVEUKR RESERVEUKR does not Granger Cause OFFICIALRATE	269	8,8600000 6,7095200	0,0032000 0,0101000
OFFICIALRATE does not Granger Cause TRADEPRICE TRADEPRICE does not Granger Cause OFFICIALRATE	269	1,2785400 0,3543300	0,2592000 0,5522000
OFFICIALRATE does not Granger Cause TRADEQUANT TRADEQUANT does not Granger Cause OFFICIALRATE	269	7,9307200 0,3532900	0,0052000 0,5528000
OFFICIALRATE does not Granger Cause TRANCHE TRANCHE does not Granger Cause OFFICIALRATE	269	0,0005900 2,6667400	0,9806000 0,1036000
OFFICIALRATE does not Granger Cause WARRUS WARRUS does not Granger Cause OFFICIALRATE	269	16,8549000 0,2990700	0,0000500 0,5849000
OFFICIALRATE does not Granger Cause WARUKR WARUKR does not Granger Cause OFFICIALRATE	269	16,4091000 1,8877900	0,0000700 0,1706000
OFFICIALRATE does not Granger Cause WHEAT WHEAT does not Granger Cause OFFICIALRATE	269	3,1569900 0,0090300	0,0767000 0,9244000

## ДОДАТОК Г

## Результати тесту Грейнджера на каузальність (лаг = 2)

Null Hypothesis:	Obs	F-Statistic	Prob.
OFFICIALRATE does not Granger Cause AVRATEBUY AVRATEBUY does not Granger Cause OFFICIALRATE	268	0,7209900 0,1754900	0,4872000 0,8391000
OFFICIALRATE does not Granger Cause AVRATESELL AVRATESELL does not Granger Cause OFFICIALRATE	268	0,7102500 0,1126400	0,4925000 0,8935000
OFFICIALRATE does not Granger Cause BRENT BRENT does not Granger Cause OFFICIALRATE	268	0,2342900 3,3995900	0,7913000 0,0349000
OFFICIALRATE does not Granger Cause COAL COAL does not Granger Cause OFFICIALRATE	268	1,0791100 0,8440500	0,3414000 0,4311000
OFFICIALRATE does not Granger Cause CORN CORN does not Granger Cause OFFICIALRATE	268	1,6936900 1,4924700	0,1858000 0,2267000
OFFICIALRATE does not Granger Cause DEVALUATIONRUS DEVALUATIONRUS does not Granger Cause OFFICIALRATE	268	16,8258000 3,7704100	0,0000001 0,0243000
OFFICIALRATE does not Granger Cause DEVALUATIONUKR DEVALUATIONUKR does not Granger Cause OFFICIALRATE	268	6,0285000 2,1951400	0,0028000 0,1134000
OFFICIALRATE does not Granger Cause DOLLARRATERUS DOLLARRATERUS does not Granger Cause OFFICIALRATE	268	7,8652900 9,1907700	0,0005000 0,0001000
OFFICIALRATE does not Granger Cause DOLLARRATEUKR DOLLARRATEUKR does not Granger Cause OFFICIALRATE	268	9,3413800 17,8974000	0,0001000 0,0000001
OFFICIALRATE does not Granger Cause EXCHANGERATES EXCHANGERATES does not Granger Cause OFFICIALRATE	268	11,5795000 10,6387000	0,0000200 0,0000400
OFFICIALRATE does not Granger Cause EXTERNALDEBTRUS EXTERNALDEBTRUS does not Granger Cause OFFICIALRATE	268	7,8193000 0,0208200	0,0005000 0,9794000
OFFICIALRATE does not Granger Cause EXTERNALDEBTUKR EXTERNALDEBTUKR does not Granger Cause OFFICIALRATE	268	5,6375000 0,5562600	0,0040000 0,5740000
OFFICIALRATE does not Granger Cause INFLATIONRUS INFLATIONRUS does not Granger Cause OFFICIALRATE	268	13,0995000 9,6875600	0,0000040 0,0000900
OFFICIALRATE does not Granger Cause INFLATIONUKR INFLATIONUKR does not Granger Cause OFFICIALRATE	268	2,0180700 3,1602400	0,1350000 0,0440000

OFFICIALRATE does not Granger Cause INTERESTRATE	268	3,1763400	0,0433000
INTERESTRATE does not Granger Cause OFFICIALRATE		24,2437000	0,0000000
OFFICIALRATE does not Granger Cause IRON	268	0,4565700	0,6340000
IRON does not Granger Cause OFFICIALRATE		1,7017400	0,1844000
OFFICIALRATE does not Granger Cause M2_RESERVE	268	14,3084000	0,0000010
M2_RESERVE does not Granger Cause OFFICIALRATE		0,2935100	0,7459000
OFFICIALRATE does not Granger Cause MAIDAN	268	12,1481000	0,0000090
MAIDAN does not Granger Cause OFFICIALRATE		0,5431600	0,5816000
OFFICIALRATE does not Granger Cause MARTIALLRUS	268	0,3812700	0,6834000
MARTIALLRUS does not Granger Cause OFFICIALRATE		0,2229900	0,8003000
OFFICIALRATE does not Granger Cause MARTIALLRUKR	268	0,9405400	0,3917000
MARTIALLRUKR does not Granger Cause OFFICIALRATE		0,4713600	0,6247000
OFFICIALRATE does not Granger Cause RESERVERUS	268	2,1415900	0,1195000
RESERVERUS does not Granger Cause OFFICIALRATE		0,0159400	0,9842000
OFFICIALRATE does not Granger Cause RESERVEUKR	268	4,0414300	0,0187000
RESERVEUKR does not Granger Cause OFFICIALRATE		6,1503200	0,0025000
OFFICIALRATE does not Granger Cause TRADEPRICE	268	1,4843300	0,2285000
TRADEPRICE does not Granger Cause OFFICIALRATE		2,3879100	0,0938000
OFFICIALRATE does not Granger Cause TRADEQUANT	268	8,7144100	0,0002000
TRADEQUANT does not Granger Cause OFFICIALRATE		0,8190100	0,4420000
OFFICIALRATE does not Granger Cause TRANCHE	268	1,5995200	0,2040000
TRANCHE does not Granger Cause OFFICIALRATE		1,7704100	0,1723000
OFFICIALRATE does not Granger Cause WARRUS	268	10,9858000	0,0000300
WARRUS does not Granger Cause OFFICIALRATE		1,7577600	0,1744000
OFFICIALRATE does not Granger Cause WARUKR	268	7,1745600	0,0009000
WARUKR does not Granger Cause OFFICIALRATE		0,6544100	0,5206000
OFFICIALRATE does not Granger Cause WHEAT	268	1,8698500	0,1562000
WHEAT does not Granger Cause OFFICIALRATE		0,2746300	0,7601000



## ДОДАТОК Д

## Результати тесту Грейнджера на каузальність (лаг = 3)

Null Hypothesis:	Obs	F-Statistic	Prob.
OFFICIALRATE does not Granger Cause AVRATEBUY AVRATEBUY does not Granger Cause OFFICIALRATE	267	0,8213800 0,0795700	0,4831000 0,9711000
OFFICIALRATE does not Granger Cause AVRATESELL AVRATESELL does not Granger Cause OFFICIALRATE	267	0,7676700 0,0502300	0,5130000 0,9851000
OFFICIALRATE does not Granger Cause BRENT BRENT does not Granger Cause OFFICIALRATE	267	1,2406900 2,6035800	0,2954000 0,0524000
OFFICIALRATE does not Granger Cause COAL COAL does not Granger Cause OFFICIALRATE	267	1,1489800 0,8148600	0,3298000 0,4866000
OFFICIALRATE does not Granger Cause CORN CORN does not Granger Cause OFFICIALRATE	267	1,8751100 0,7768300	0,1342000 0,5078000
OFFICIALRATE does not Granger Cause DEVALUATIONRUS DEVALUATIONRUS does not Granger Cause OFFICIALRATE	267	14,6378000 1,7646300	0,0000000 0,1543000
OFFICIALRATE does not Granger Cause DEVALUATIONUKR DEVALUATIONUKR does not Granger Cause OFFICIALRATE	267	8,8145700 1,3797800	0,0000100 0,2494000
OFFICIALRATE does not Granger Cause DOLLARRATERUS DOLLARRATERUS does not Granger Cause OFFICIALRATE	267	29,4057000 6,4401200	0,0000000 0,0003000
OFFICIALRATE does not Granger Cause DOLLARRATEUKR DOLLARRATEUKR does not Granger Cause OFFICIALRATE	267	55,4811000 13,4833000	0,0000000 0,0000000
OFFICIALRATE does not Granger Cause EXCHANGERATES EXCHANGERATES does not Granger Cause OFFICIALRATE	267	36,7925000 7,0427000	0,0000000 0,0001000
OFFICIALRATE does not Granger Cause EXTERNALDEBTRUS EXTERNALDEBTRUS does not Granger Cause OFFICIALRATE	267	4,9350100 1,3273300	0,0024000 0,2659000
OFFICIALRATE does not Granger Cause EXTERNALDEBTUKR EXTERNALDEBTUKR does not Granger Cause OFFICIALRATE	267	2,9856900 0,9564000	0,0317000 0,4139000
OFFICIALRATE does not Granger Cause INFLATIONRUS INFLATIONRUS does not Granger Cause OFFICIALRATE	267	24,3131000 5,0903600	0,0000000 0,0019000
OFFICIALRATE does not Granger Cause INFLATIONUKR INFLATIONUKR does not Granger Cause OFFICIALRATE	267	2,0126300 1,8851800	0,1126000 0,1325000

OFFICIALRATE does not Granger Cause INTERESTRATE INTERESTRATE does not Granger Cause OFFICIALRATE	267	1,4945100 15,3572000	0,2164000 0,0000000
OFFICIALRATE does not Granger Cause IRON IRON does not Granger Cause OFFICIALRATE	267	0,2656900 1,1269200	0,8501000 0,3386000
OFFICIALRATE does not Granger Cause M2_RESERVE M2_RESERVE does not Granger Cause OFFICIALRATE	267	19,9953000 1,4455800	0,0000000 0,2300000
OFFICIALRATE does not Granger Cause MAIDAN MAIDAN does not Granger Cause OFFICIALRATE	267	5,8157500 0,4699700	0,0007000 0,7035000
OFFICIALRATE does not Granger Cause MARTIALLRUS MARTIALLRUS does not Granger Cause OFFICIALRATE	267	0,2835400 0,1221000	0,8373000 0,9470000
OFFICIALRATE does not Granger Cause MARTIALLRUKR MARTIALLRUKR does not Granger Cause OFFICIALRATE	267	0,6622800 0,2252700	0,5759000 0,8788000
OFFICIALRATE does not Granger Cause RESERVERUS RESERVERUS does not Granger Cause OFFICIALRATE	267	7,5722100 2,5647900	0,0000700 0,0551000
OFFICIALRATE does not Granger Cause RESERVEUKR RESERVEUKR does not Granger Cause OFFICIALRATE	267	4,7533400 3,8649700	0,0030000 0,0099000
OFFICIALRATE does not Granger Cause TRADEPRICE TRADEPRICE does not Granger Cause OFFICIALRATE	267	0,7137500 1,7698900	0,5445000 0,1533000
OFFICIALRATE does not Granger Cause TRADEQUANT TRADEQUANT does not Granger Cause OFFICIALRATE	267	5,0828200 0,4079700	0,0020000 0,7474000
OFFICIALRATE does not Granger Cause TRANCHE TRANCHE does not Granger Cause OFFICIALRATE	267	8,1536300 0,8402400	0,0000300 0,4729000
OFFICIALRATE does not Granger Cause WARRUS WARRUS does not Granger Cause OFFICIALRATE	267	7,8809000 1,4200500	0,0000500 0,2373000
OFFICIALRATE does not Granger Cause WARUKR WARUKR does not Granger Cause OFFICIALRATE	267	4,2702900 0,5998500	0,0058000 0,6156000
OFFICIALRATE does not Granger Cause WHEAT WHEAT does not Granger Cause OFFICIALRATE	267	1,1518600 0,0741400	0,3287000 0,9738000