

A.V. БАНИК, П.П. МУЛЕСА

ПРОГНОЗУВАННЯ ЕКОНОМІЧНИХ ПОКАЗНИКІВ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ LSTM ТА ГРАФОВИХ МОДЕЛЕЙ КОРЕЛЯЦІЙНОГО АНАЛІЗУ

Досліджено застосування нейронних мереж LSTM для прогнозування макроекономічних показників України в умовах структурних змін, спричинених впливом факторів воєнного часу. Проведено порівняльний аналіз точності прогнозів LSTM, ARIMA та наївної моделі, що підтверджив перевагу глибинного навчання, особливо в умовах нестабільності. Для інтерпретації взаємозв'язків між змінними застосовано кореляційний аналіз із побудовою графових моделей, що дозволило виявити кластери макроекономічних показників та їхні структурні залежності. Досліджено виклики, з якими стикається модель у кризових умовах, та запропоновано рекомендації щодо її адаптації, зокрема введення режимних змінних, поетапного донавчання та використання гібридних архітектур. Результати підтверджують, що графові моделі кореляційного аналізу можуть посилити ефективність LSTM у прогнозуванні макроекономічних показників за умов нестабільності.

1. Вступ

Прогнозування макроекономічних показників є важливим завданням для стратегічного планування розвитку країни. Точні прогнози валового внутрішнього продукту (ВВП), інфляції, валютного курсу тощо дозволяють своєчасно приймати обґрунтовані управлінські рішення. Традиційно широко застосовуються статистичні моделі часових рядів, зокрема метод Бокса–Дженкінса (ARIMA) – один із найпопулярніших підходів до прогнозування економічних показників [1]. ARIMA-моделі успішно використовувалися для прогнозування ВВП та індексу споживчих цін (ІСЦ) багатьох країн, демонструючи малу похибку на історичних даних [1]. Водночас лінійні моделі мають обмеження: вони погано пристосовані до нелінійної динаміки та складних трендів економічних процесів [2]. Зміни режимів (структурні злами), спричинені шоками на кшталт фінансових криз чи воєн, порушують стаціонарність рядів та знижують точність традиційних прогнозів. У таких умовах виникає потреба у гнучкіших підходах, здатних засвоювати нелінійні залежності та адаптуватися до різких змін.

Сучасні методи штучного інтелекту, особливо глибокі нейронні мережі, відкривають нові можливості для аналізу економічних даних. Архітектура довгої короткочасної пам'яті (Long Short-Term Memory, LSTM), запропонована Хохрайтером і Шмідхубером у 1997 р., є розширенням рекурентних нейромереж, що здатне ефективно обробляти послідовні дані [2]. LSTM-мережі використовують механізм керованих гейтів (gates) для селекції інформації, завдяки чому вони добре вловлюють довгострокові залежності та нелінійні взаємозв'язки в часових рядах [2]. У сфері фінансів і економіки LSTM успішно застосовуються для прогнозування макропоказників і часто перевершують за точністю традиційні моделі. Наприклад, у дослідженні прогнозування ВВП США LSTM-модель показала перевагу над найкращою ARIMA-моделлю [2]. Таким чином, залучення глибинного навчання є перспективним для економічного прогнозування, особливо за умов складної динаміки.

Окрім підвищення точності прогнозу, важливим є інтерпретування взаємозв'язків між економічними показниками. Кореляційний аналіз дозволяє виявити групи змінних із тісними зв'язками та потенційними причинно-наслідковими впливами. Графові моделі на

основі кореляцій (correlation network graphs) наочно відображають структуру взаємозалежностей у багатовимірних даних: вузли відповідають показникам, а ребра – значимим кореляціям [3], [4]. За допомогою мережевого аналізу можна визначити ключові впливові змінні та кластери показників [5]. Наприклад, у роботі [5] за даними Гани побудовано граф залежностей макропоказників (на основі часткових кореляцій) та виявлено, що експорт, інфляція, валютний курс є центральними вузлами мережі, а деякі індикатори (сільське господарство, імпорт) мають найвищі показники центральності. Такий підхід сприяє економічній інтерпретації результатів прогнозування та пошуку причин можливих помилок моделі.

Особливо актуальним є прогнозування в умовах структурних зрушень, спричинених, наприклад, пандемією COVID-19 або воєнними діями. Повномасштабна війна в Україні, що розпочалася у 2022 році, викликала безпредecedентні зміни економічних показників: різке падіння ВВП, сплеск інфляції, стрибок облікової ставки та курсу гривні, надходження значних обсягів міжнародної фінансової допомоги тощо [6]. Стандартні моделі не здатні апріорно врахувати такі різкі злами [7]. Натомість сучасні підходи на основі штучного інтелекту можуть бути розширені механізмами адаптації – наприклад, навчанням на даних, отриманих після початку війни, або введенням спеціальних регресорів (індикаторних змінних режиму) для моделювання впливу факторів воєнного часу. У роботі [8] продемонстровано, що LSTM-модель з комбінованим урахуванням різночастотних даних перевершує традиційні методи під час різких економічних спадів, що підтверджує доцільність використання гнучких нейромереж для короткострокового прогнозу в кризових умовах.

Таким чином, поєднання методів глибинного навчання та графового кореляційного аналізу є перспективним для прогнозування значень показників, що характеризують стан економіки України, особливо в умовах посткризового відновлення.

2. Аналіз літературних даних і постановка проблеми дослідження

У економіці широко використовуються класичні статистичні інструменти для прогнозування часових рядів, зокрема моделі авторегресії (AR), інтегровані моделі авторегресії – ковзного середнього (ARIMA) та векторна авторегресія (VAR), а також різноманітні регресійні моделі. ARIMA тривалий час залишалася стандартним підходом до прогнозування економічних і фінансових часових рядів [9]. Однак такі моделі мають суттєві обмеження. Наприклад, ARIMA-процедура є лінійною і не здатна адекватно описувати нелінійні взаємозв'язки між показниками [7], [9]. Крім того, в простій ARIMA передбачається постійна дисперсія випадкових похибок, що на практиці часто не виконується. Хоча розширення ARIMA шляхом включення моделей GARCH може частково зняти це припущення, така комбінація ускладнює оптимізацію моделі [9].

VAR-моделі дозволяють враховувати кілька взаємопов'язаних змінних, але також будуються на лінійних залежностях. Це означає, що традиційний VAR зазвичай не здатен відобразити нелінійні відносини між економічними показниками, що є істотним недоліком, особливо коли між змінними існують складні ефекти [10]. До того ж, для стабільної роботи VAR необхідне дотримання стаціонарності рядів та вибір оптимальної лагової структури, що не завжди є тривіальним завданням. Регресійні моделі загалом вимагають апріорного визначення форми зв'язку між змінними; якщо справжня взаємодія є складнішою або змінюється з часом, точність таких прогнозів різко знижується [11]. Зокрема, після пандемії COVID-19 центральні банки зіткнулися з тим, що зосередженість на суттєво лінійних моделях не дозволила вчасно врахувати нелінійні «самопідсилювальні» ефекти, внаслідок чого спостерігалися значні похибки прогнозів інфляції у 2021–2022 роках [11]. Подібна ситуація підкреслює необхідність пошуку гнучкіших підходів до

прогнозування.

Сучасні дослідження демонструють, що інструменти глибинного навчання, зокрема мережі LSTM, здатні істотно перевершувати класичні підходи у задачах економічного прогнозування. LSTM є різновидом рекурентної нейронної мережі, яка автоматично вилучає часові залежності та нелінійні патерни з даних. Емпіричні порівняння показують значну перевагу LSTM над традиційними моделями. Зокрема, середнє зниження помилки прогнозу при використанні LSTM замість ARIMA досягає 84–87 % [9], що вказує на суттєве підвищення точності. Інше дослідження щодо прогнозування інфляції в США засвідчило, що LSTM-модель перевершує модель лінійної авторегресії, модель випадкового блукання, сезонну модель ARIMA та навіть просту штучну нейронну мережу: на всіх горизонтах прогнозу корінь середньоквадратичної помилки для LSTM був приблизно втрічі меншим, ніж для наївної моделі випадкового блукання [12]. Така висока точність пояснюється здатністю LSTM вловлювати нелінійності в даних та гнучкою архітектурою мережі [12].

Дійсно, методи глибинного навчання на основі Recurrent neural network (RNN), включаючи LSTM, в останні роки привернули значну увагу дослідників у різних галузях, зокрема у фінансах [9]. Вони здатні автоматично виявляти приховані структури і закономірності в даних – такі як нелінійні та складні взаємозв'язки, – які важко виявити традиційними моделями [9]. Переваги LSTM проявляються і в багатовимірних задачах: наприклад, підхід Deep VAR, що інтегрує нейронні мережі в структуру VAR, стабільно перевершує класичний VAR за точністю прогнозу, особливо під час періодів економічної нестабільності [10]. Це свідчить, що глибинні нейронні мережі ефективніше захоплюють складну динаміку макроекономічних показників, ніж лінійні моделі.

В Україні також зростає зацікавленість застосуванням штучного інтелекту та глибинного навчання для макроекономічних прогнозів. Зокрема, у практиці Національного банку України методи машинного навчання вже починають використовувати поряд із традиційними моделями [11]. Хоча ці підходи ще не замінили повністю класичні методи, інтерес до їхніх можливостей явно зростає. Нещодавнє дослідження українських економістів продемонструвало ефективність алгоритмів машинного навчання для прогнозування інфляції: із застосуванням моделі XGBoost було виконано прогноз місячної інфляції в Україні, і врахування додаткових факторів (таких як інфляційні та курсові очікування) дозволило суттєво підвищити точність прогнозу [11]. Це свідчить про перспективність методів машинного навчання у задачах, де використання традиційних інструментів пов'язано із труднощами.

Окрім інфляції, дослідники застосовують нейронні мережі і для прогнозування інших макропоказників України. Так, побудовано просту штучну нейронну мережу для прогнозування реального ВВП України; ця модель достовірно відтворила динаміку історичного ряду та дала правдоподібний прогноз, зокрема вказавши на можливе зниження реального ВВП у 2022-2023 роках [13]. Для короткотермінового прогнозування рівня інфляції застосовується й гіbridні нечіткі нейромережі: наприклад, на основі п'ятишарового перцептрона було реалізовано нечітку нейронну мережу ANFIS для прогнозу індексу споживчих цін України [14]. Очікується, що кількість робіт у цій сфері зростатиме, адже такі методи вже демонструють обнадійливі результати і можуть суттєво підвищити точність прогнозів в умовах високої волатильності української економіки [11]. Проте, варто підкреслити, що загалом українські науковці тільки починають експериментувати з глибинним навчанням у макроекономіці, тож багато можливостей залишаються невивченими.

Кореляційний аналіз традиційно використовується для оцінки взаємозв'язків між

економічними показниками. Зазвичай його результати представлено у вигляді матриці парних коефіцієнтів кореляції. Проте простий перелік коефіцієнтів не завжди дозволяє зрозуміти глобальну структуру взаємозв'язків в економічній системі. Графові кореляційні моделі пропонують альтернативний підхід: представити показники у вигляді вузлів графа, з'єднаних ребрами, ваги яких відображають силу взаємозв'язку між ними. Така мережева репрезентація дає можливість застосувати інструментарій аналізу мереж для виявлення структурних властивостей економіки.

Побудова кореляційної мережі дозволяє виявляти кластери тісно пов'язаних змінних та ідентифікувати ключові вузли (хаби). Наприклад, аналіз фінансових даних показує, що акції компаній одного сектора утворюють щільно пов'язану групу в мережі, побудованій за кореляціями їхніх дохідностей [15]. Граф-модель наочно візуалізує такі групування, що важко побачити безпосередньо з числової кореляційної матриці. Крім того, мережевий підхід дає змогу відфільтровувати другорядні зв'язки і зосередитися на найсильніших взаємозалежностях, спрощуючи інтерпретацію складних систем. За допомогою алгоритмів побудови мінімального остова або інших методів «фільтрації» можна виділити базову структуру зв'язків, яка відображає ієрархію впливів в економіці [15].

В останніх розробках графові нейронні мережі (Graph Neural Network, GNN) інтегрують графові структури безпосередньо в прогнозне моделювання. GNN може навчатися на даних, де кожен об'єкт є вузлом графа, враховуючи як особливості вузлів, так і зв'язність графа [16]. Поєднуючи GNN з LSTM, можна створювати гібридні моделі, які використовують як реляційну, так і часову інформацію. Наприклад, гібридна LSTM-GNN модель для прогнозування фонового ринку використовувала LSTM для фіксації часових патернів в історії цін кожної акції, а GNN – для фіксації взаємозв'язків між акціями (побудованих на основі кореляцій та інших фінансових зв'язків) [16]. Ця інтегрована модель значно перевершила автономну LSTM (зменшивши помилку прогнозування на ~10,6 %), оскільки вона змогла врахувати, як акції впливають одна на одну, одночасно моделюючи часову динаміку [16]. Аналогічно, в економіці можна уявити, що LSTM прогнозує декілька пов'язаних часових рядів (по одному на вузол), тоді як графовий компонент інформує модель про вплив між рядами (наприклад, торговельні мережі впливають на прогнози ВВП країни). Таким чином, графові моделі можуть доповнювати LSTM-прогнозування або шляхом надання окремого шару візуалізації/аналізу, або шляхом включення в саму модель прогнозування для підвищення точності.

Аналіз літератури показує, що традиційні економетричні моделі, зокрема ARIMA та VAR, мають обмеження у випадках складної нелінійної динаміки, структурних зрушень та кризових ситуацій. Методи глибинного навчання, зокрема нейронні мережі LSTM, демонструють вищу точність у прогнозуванні економічних часових рядів, особливо за умов нестабільності. Проте більшість досліджень зосереджені лише на використанні LSTM для підвищення точності прогнозу, не приділяючи належної уваги аналізу зв'язків між макроекономічними змінними, що може допомогти в оптимізації структури моделі та виборі релевантних вхідних факторів.

Графові моделі кореляційного аналізу, які застосовуються для візуалізації взаємозалежностей між економічними показниками, дозволяють виявляти кластери змінних, визначати ключові фактори впливу та покращувати розуміння структурної організації макроекономічних процесів. Хоча, в своїй більшості, такі методи не взаємодіють безпосередньо з LSTM-прогнозуванням, вони можуть бути корисними на етапі підготовки моделі, зокрема для відбору релевантних змінних, оцінки потенційних джерел нелінійності та аналізу факторів, що спричиняють прогностичні похибки.

Попри перспективність такого підходу, у сучасній літературі недостатньо досліджень,

які комплексно розглядають використання кореляційних графів для підтримки процесу налаштування нейронних мереж у макроекономічному прогнозуванні. Дано прогалина є особливо актуальною для України, економіка якої зазнає значних кризових потрясінь та потребує гнучких підходів до моделювання. Дане дослідження спрямоване на її заповнення шляхом інтеграції LSTM для прогнозування макроекономічних показників із додатковим аналізом взаємозв'язків між ними за допомогою графових моделей, що сприятиме кращому розумінню структури економічної динаміки та підвищенню обґрунтованості прогнозних рішень.

3. Мета і задачі дослідження

Метою дослідження є підвищення точності прогнозування ключових економічних показників України засобами штучного інтелекту (на основі нейронної мережі LSTM) та інтерпретація взаємозв'язків між ними за допомогою графової моделі кореляційного аналізу.

Для досягнення поставленої мети необхідно вирішити такі задачі:

- сформувати набір вхідних даних – ключових макроекономічних змінних України – та провести їх попередній аналіз, зокрема кореляційний;
- розробити багатофакторну модель прогнозування на основі нейронної мережі LSTM, що одночасно прогнозує декілька економічних показників;
- реалізувати комбіновану функцію втрат для навчання мережі, яка враховує помилки прогнозу кількісних і якісних змінних;
- здійснити експериментальне прогнозування вибраних показників, порівняти його точність із точністю прогнозування із застосуванням базових моделей (найвідомішим однокроковим прогнозом та ARIMA) на тестовому періоді 2020Q3–2023Q4 (третій квартал 2020 – четвертий квартал 2023 року);
- побудувати кореляційну матрицю та граф залежностей між показниками, проаналізувати отримані структури зв'язків;
- провести аналіз результатів на тестовому періоді, особливо у воєнний час, і надати рекомендації щодо вдосконалення моделі для адаптації до структурних зрушень, які виникають після початку повномасштабної війни.

4. Матеріали та методи дослідження

4.1. Формування набору даних

Для дослідження сформовано квартальну вибірку макроекономічних показників України за 2002–2023 роки (88 кварталів). Розглянуто 9 змінних:

- реальний ВВП України, у доларах США [17];
- індекс споживчих цін (ІСЦ, у % до відповідного кварталу попереднього року) [18];
- середній обмінний курс гривні до долара США (грн/USD) [19];
- індикатор фіксованого валютного курсу (бінарна змінна: 1 – зафіксований офіційний курс НБУ в даному кварталі, 0 – курс формується в умовах ринкового/плаваючого режиму) [20]–[23];
- обсяг імпорту товарів, млн дол. США [24], [25];
- обсяг експорту товарів, млн дол. США [24], [25];
- середня облікова ставка НБУ по періоду, % [26];
- міжнародні резерви НБУ, млн дол. США [27];
- обсяг міжнародної фінансової допомоги (без гуманітарної та військової), млн дол. США [28], [29].

Дані отримано з офіційних статистичних ресурсів Національного банку України, Державної служби статистики України, міжнародних дослідницьких платформ та інформаційно-аналітичних ресурсів (таких як Кільський інститут світової економіки,

«World integrated trade solution», «Our world in data»), а також з публікацій із вільним доступом [17]-[29]. Вибрані показники охоплюють основні аспекти економіки: реальний сектор (ВВП, зовнішня торгівля), цінову динаміку (ІСЦ), валютно-фінансовий сектор (курс, резерви, ставка) та зовнішню допомогу. Для початкових років, коли дані в основних джерелах були відсутні, використано інформацію з наведених вище ресурсів. У випадках неповних даних застосовано методи для вловлювання трендів, зокрема експоненціальне згладжування, а річні значення дезагреговано до квартальних з використанням сезонних коефіцієнтів. Ці коефіцієнти розраховано як середні значення відповідних квартальних часток за періоди, для яких були доступні повні квартальні дані. Облікова ставка НБУ розрахована як середньозважене значення за квартал із урахуванням кількості днів дії кожної ставки. У табл. 1 наведено приклад фрагмента отриманих даних.

Таблиця 1
Приклад значень макроекономічних показників України

Квартал	ВВП	ІСЦ	Курс
2023Q2	40032733000	101.5	36.57
2023Q3	48630683154	98.5	36.57
2023Q4	52829237962	102	36.59
Квартал	Фіксований курс	Імпорт	Експорт
2023Q2	1	14738	8718
2023Q3	1	16178	7407
2023Q4	0	17059	8702
Квартал	Облікова ставка	Резерви	Фінансова допомога
2023Q2	25	29883	11676
2023Q3	21.33	24086	10848
2023Q4	15.82	27735	8070

Для моделювання застосовано підхід багатоцільового прогнозування: нейронна мережа LSTM одночасно передбачає значення всіх дев'яти показників на один квартал уперед, враховуючи їхній взаємний вплив через спільний прихований стан. Навчальна вибірка охоплює період 2002Q1–2020Q2 (74 спостереження), тестова – 2020Q3–2023Q4 (14 спостережень). Для подальшого тренування знадобилось нормалізувати дані до інтервалу $[0,1]$ за кожною змінною, щоб забезпечити числову стабільність при роботі мережі з показниками різного масштабу.

4.2. Нейронна мережа LSTM

Архітектура мережі складається з входного шару розмірності 9 (кількість змінних), одного прихованого шару LSTM та вихідного шару, що генерує 9 прогнозів. Розмірність внутрішнього стану LSTM обрано рівною 256, модель містить два послідовні LSTM-шари. Для уникнення перенавчання застосовано регуляризацію dropout (10 %). На відміну від класичних RNN, вузол LSTM має комірку пам'яті c_t і три керуючі гейти: входний i_t , гейт забування f_t та вихідний o_t . На кроці t вони обчислюються через афінні перетворення стану h_{t-1} та вектору входу x_t з подальшим застосуванням сигмоїдної функції активації $\sigma(\cdot)$. Відповідно, вектор входного гейта може бути представлено у вигляді:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (1)$$

де W_i – матриця ваг для входу, що навчається; x_t – вектор вхідних економічних показників на кроці t ; U_i – матриця ваг для стану, що навчається; h_{t-1} – вектор прихованого стану, що містить інформацію з попереднього кроку; b_i – вектор зміщень; $\sigma(\cdot)$ – сигмоїдна функція.

Вектор гейта забування має вигляд:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (2)$$

де W_f – матриця ваг для входу, що навчається; U_f – матриця ваг для стану, що навчається; b_f – вектор зміщення.

Відповідно, вектор вихідного гейта набуває вигляду:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (3)$$

де W_o – матриця ваг для входу, що навчається; U_o – матриця ваг для стану, що навчається; b_o – вектор зміщення.

Далі обчислюється кандидат на нове значення пам'яті

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (4)$$

який проходить через гейт i_t . Вміст пам'яті оновлюється як лінійна комбінація попереднього стану c_{t-1} (із коефіцієнтом f_t) та нового кандидата (з коефіцієнтом i_t) [30]:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (5)$$

Вихідний сигнал LSTM на цьому кроці дорівнює $h_t = o_t \cdot \tanh(c_t)$. Наведені рівняння (1)-(3) та (5) описують механізм забування та запам'ятовування інформації в LSTM-осередку. Завдяки цьому мережа може зберігати довготривалі залежності: наприклад, вплив значення показника кілька кварталів тому на поточний прогноз, що важливо для економічних даних із сезонністю чи запізненнями впливу.

4.3. Комбінована функція втрат

Навчання LSTM здійснюється шляхом мінімізації спеціально сконструйованої функції втрат, яка враховує особливості прогнозування як неперервних, так і бінарних показників. Зокрема, серед 9 цільових змінних присутня одна якісна – індикатор фіксованого курсу (0 або 1). Для неї природно використовувати логістичну функцію втрат (бінарну крос-ентропію), тоді як для кількісних показників – метрику середньоквадратичної помилки. Для поєднання цих критеріїв використано комбіновану функцію втрат у вигляді зваженої суми:

$$L = 0.8 \text{ MSE} + 0.2 \text{ BCE} \quad (6)$$

де MSE – середньоквадратична помилка по неперервних виходах; BCE – бінарна крос-ентропія по виходу фіксованого курсу валют (0 або 1). Вагові коефіцієнти 0.8 та 0.2 підібрані евристично з метою надання більшої ваги точності кількісних прогнозів, водночас враховуючи класифікаційну задачу. Таким чином, мережа одночасно навчається мінімізувати помилки прогнозу величин (ВВП, ІСЦ тощо) і правильно передбачати режим валютної політики (фіксований чи плаваючий курс). Навчання проводилося методом зворотного поширення в часі з оптимізатором Adam (швидкість навчання 0.004). Кількість епох навчання визначено з використанням раннього зупинення за метрикою валідації.

4.4. Базові моделі для порівняння

Для оцінки якості LSTM-прогнозу його результати порівнюються з результатами застосування двох базових моделей:

- наївного однокрокового прогнозу, який приймає значення показника рівним останньому відомому значенню (Persistence model);
- класичної моделі ARIMA, налаштованої однаково для всіх часових рядів.

Наївний прогноз для горизонту в один квартал ($h = 1$) фактично рівнозначний прогнозу випадкового блукання: $\hat{y}_{t+1} = y_t$. Цей простий підхід часто важко перевершити

при короткостроковому прогнозуванні фінансових рядів. Для забезпечення уніфікованого порівняння як базову специфікацію використано ARIMA (2,1,2) для всіх показників. На практиці для всіх часових рядів було підібрано згадану специфікацію, яка продемонструвала загалом конкурентну якість прогнозу, забезпечуючи баланс між гнучкістю моделі та її стійкістю до перенавчання. Водночас у подальших дослідженнях можна покращити порівняльний аналіз, оптимізувавши параметри ARIMA окрім для кожного ряду, що дозволить врахувати специфічні особливості динаміки різних економічних змінних.

4.5. Метрики оцінювання точності прогнозів

Для кількісної оцінки точності прогнозів використано три поширені метрики: середню абсолютну помилку (Mean Absolute Error, MAE), корінь середньоквадратичної помилки (Root Mean Square Error, RMSE) та коефіцієнт детермінації (R^2). MAE та RMSE оцінюють масштаби відхилення прогнозованих значень \hat{y}_t від фактичних y_t :

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (8)$$

Коефіцієнт детермінації обчислюється як:

$$R^2 = 1 - \frac{\sum (y_t - \hat{y}_t)^2}{\sum (y_t - \bar{y})^2} \quad (9)$$

де \bar{y} – середнє фактичне значення на тестовому інтервалі. R^2 інтерпретується як частка дисперсії цільової змінної, пояснена моделлю; $R^2 = 1$ відповідає ідеальному прогнозу, $R^2 = 0$ – прогнозу на рівні середнього значення, від'ємні R^2 свідчать про гіршу точність, ніж тривіальне прогнозування середнього.

Для аналізу взаємозв'язків між показниками розраховано матрицю парних кореляцій Пірсона за повним періодом 2002–2023 pp. Коефіцієнт кореляції $r_{X,Y}$ двох часових рядів X_t, Y_t визначено як:

$$r_{X,Y} = \frac{\sum_{t=1}^T (X_t - \bar{X})(Y_t - \bar{Y})}{\sqrt{\sum_{t=1}^T (X_t - \bar{X})^2 \sum_{t=1}^T (Y_t - \bar{Y})^2}} \quad (10)$$

що чисельно дорівнює вибірковому коефіцієнту Пірсона. На основі матриці побудовано граф кореляцій: вузли графу відповідають 9 змінним, а ребрами з'єднано пари змінних з високим рівнем лінійної залежності (в роботі обрано поріг $|r| \geq 0.5$ для відображення зв'язку). Для такого графу проаналізовано утворення кластерів змінних і центральність вузлів, що дозволяє інтерпретувати структурні взаємозв'язки економічних показників.

4.6. Граф залежностей

У той час як LSTMs досягають успіху в прогнозуванні послідовності, графові моделі доповнюють їх, фіксуючи та візуалізуючи взаємозв'язки між різними економічними змінними. У графовому (або мережевому) представленні кожному економічному показнику відповідає вузол, а ребра між вузлами відображають певну залежність або зв'язок (наприклад, кореляцію, причинно-наслідковий зв'язок або вплив) [31]. Наприклад, можна побудувати граф, де вузлами є ВВП, інфляція, відсоткові ставки та безробіття, і з'єднати їх ребрами, для кожного з яких повинен бути встановлений ваговий коефіцієнт, що відображує силу історичних кореляцій або причинно-наслідкових зв'язків (наприклад, на основі причинно-наслідкового зв'язку Грейнджа). Графічні моделі (в імовірнісному

сенсі) використовують такі ребра для кодування умовних залежностей – якщо дві змінні не пов'язані безпосередньо, вони є умовно незалежними з огляду на інші [31].

Важливо, що ці графічні зображення є не лише аналітичними інструментами, але й засобами візуалізації. Побудувавши мережу економічних змінних, аналітики можуть інтуїтивно побачити мережу зв'язків, визначити спільноти (групи змінних з сильними внутрішніми зв'язками) і простежити, як шоки можуть поширюватися в економіці. Таке візуальне розуміння важко отримати з необроблених часових рядів або вагових коефіцієнтів нейронної мережі.

5. Результати дослідження

5.1. Навчання та валідація моделі LSTM

Побудовану LSTM-модель було налаштовано на багатофакторний прогноз трьох основних економічних показників: облікової ставки, експорту та ІСЦ. Архітектура містила 2 шари LSTM зі 256 нейронами у прихованому стані, з урахуванням механізму регуляризації dropout (10 %) для запобігання перенавчанню [32]. Навчання тривало 35 епох зі швидкістю навчання (learning rate) 0.004, реалізованою алгоритмом Adam. Застосовувалося раннє зупинення (early stopping) за ознакою мінімізації валідаційних втрат. Найкраще значення функції втрат на валідації (0.008894) досягнуто на епосі 11.

На рис. 1 представлена динаміка зменшення тренувальної та валідаційної втрат. До епоси 11 спостерігається суттєве зниження показника помилки; подальше навчання не дало покращення, тож модель зафіксувана на епосі 11.

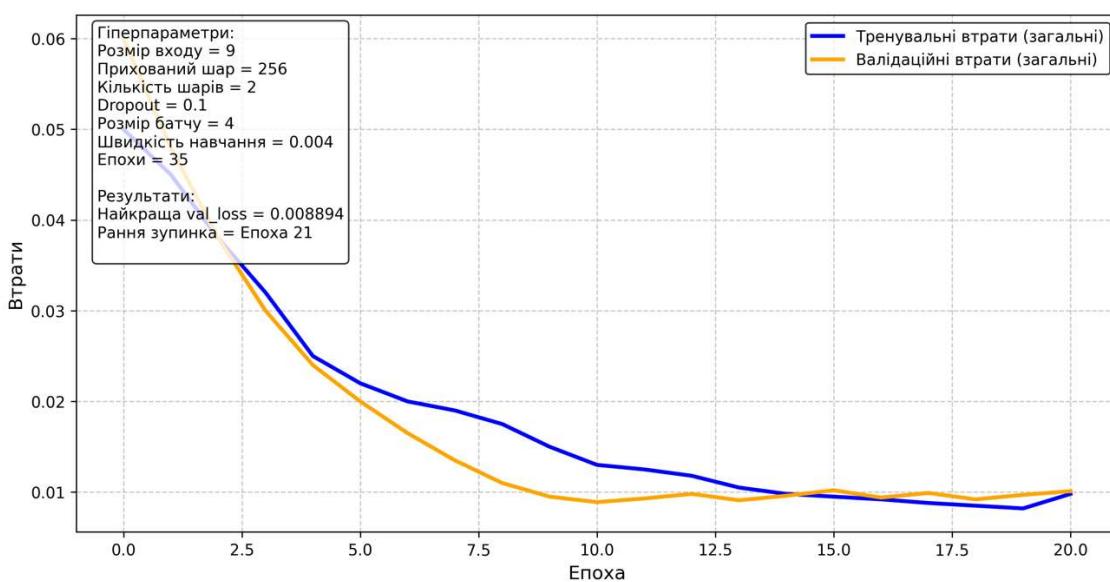


Рис. 1. Динаміка втрат моделі LSTM під час навчання

5.2. Порівняльний аналіз точності прогнозу

Для оцінювання точності застосовано три метрики: MAE, RMSE та R^2 . Для порівняння були застосовані метод найвного однокрокового прогнозу ($y_{t+1} = y_t$) та модель ARIMA(2,1,2) з однаковою специфікацією для кожного ряду.

Таблиця 2 узагальнює результати прогнозування для трьох ключових показників.

Аналіз результатів таблиці 2 показав, що для ІСЦ мережа LSTM зменшує середню абсолютну помилку (MAE=0.08) порівняно з найвним прогнозом (MAE=0.11) та ARIMA (MAE=0.10), а також має вищий R^2 (0.11) проти Naive (- 0.20) і ARIMA (- 0.04), що вказує на кращу пояснену варіацію, хоча загалом усі моделі слабко прогнозують цей показник.

Таблиця 2

Порівняння точності LSTM, найвного прогнозу та ARIMA

Метрика	ІСЦ			Експорт			Облікова ставка		
	LSTM	Naive	ARIMA	LSTM	Naive	ARIMA	LSTM	Naive	ARIMA
MAE	0.08	0.11	0.10	0.11	0.13	0.20	0.11	0.11	0.31
RMSE	0.12	0.13	0.13	0.15	0.16	0.27	0.14	0.17	0.34
R ²	0.11	-0.20	-0.04	0.48	0.34	0.23	0.82	0.74	-0.05

Для експорту LSTM суттєво краща, ніж обидві базові моделі, що підтверджується найнижчими MAE (0.11) і RMSE (0.15) та найвищим R² (0.48), порівняно з Naive (MAE=0.13, RMSE=0.16, R²=0.34) і ARIMA (MAE=0.20, RMSE=0.27, R²=0.23), демонструючи помітну перевагу в точності та поясненої варіації. Для облікової ставки LSTM випереджає ARIMA, помітно зменшуючи MAE (0.11 проти 0.31) і RMSE (0.14 проти 0.34) та суттєво підвищуючи R² (0.82 проти -0.05). Результати застосування LSTM та найвного підходу за показником MAE однакові (0.11), проте загальний рівень похибки (RMSE) у LSTM нижчий (0.14 проти 0.17), а R² вищий (0.82 проти 0.74), що вказує на кращу загальну продуктивність і високу частку поясненої варіації.

Було проведено порівняння LSTM із методом, який продемонстрував другу за точністю оцінку серед розглянутих вище способів вирішення задачі прогнозування. Таке порівняння дозволило інформативніше аналізувати результати прогнозування. На рис. 2 показано прогноз динаміки облікової ставки. LSTM забезпечує точніше наближення до фактичних значень, що підтверджується високим коефіцієнтом детермінації. Незважаючи на те, що найвна модель у певних точках має аналогічну середню абсолютну похибку, вона поступається LSTM у відтворенні деталей коливань, особливо у фазі різкого зростання ставки.

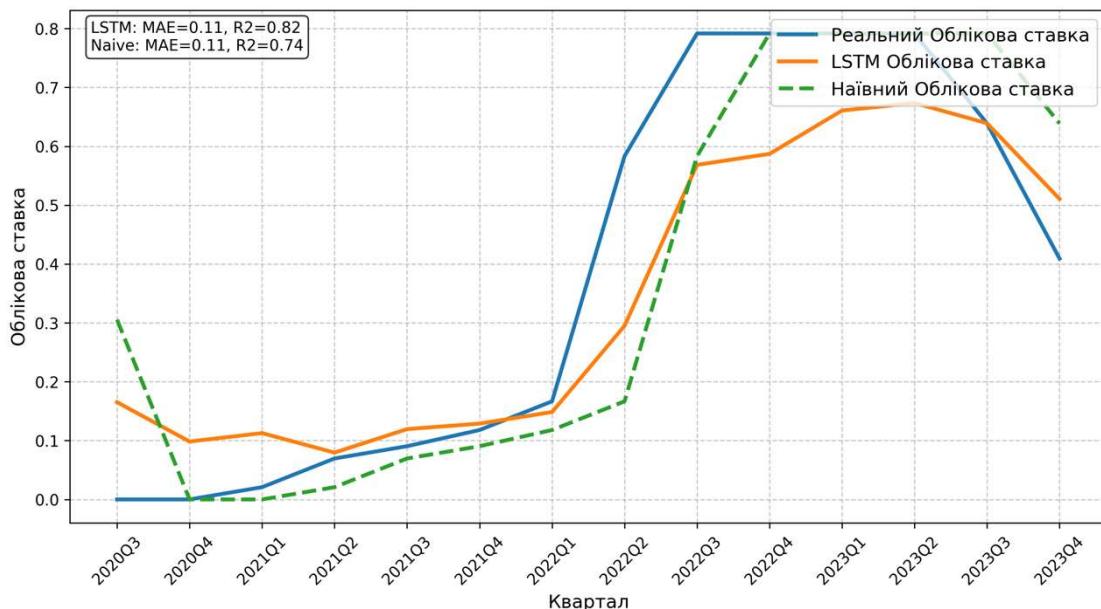


Рис. 2. Реальні та прогнозовані значення облікової ставки

На рис. 3 зображені динаміки фактичного та прогнозованого значень індексу споживчих цін за різними підходами. Нейромережева модель демонструє зменшенну середню абсолютну похибку та кращий коефіцієнт детермінації порівняно з найвним прогнозом. Вона точніше відображає загальну тенденцію зміни ІСЦ, однак варто

відзначити, що обидві моделі демонструють обмежену точність прогнозування, особливо в періоди значних коливань. Найвний метод має суттєві відхилення під час зростання та спаду, що свідчить про його низьку адаптивність до змін тренду. Попри спроби оптимізації гіперпараметрів LSTM, покращення якості прогнозу залишалося обмеженим, що, ймовірно, зумовлено недостатністю доступних даних для навчання.

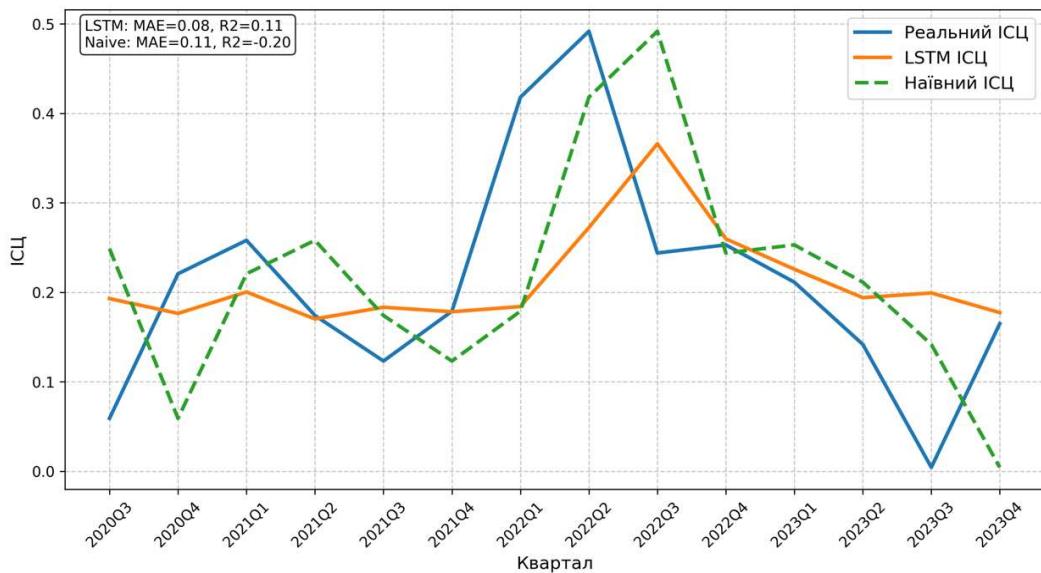


Рис. 3. Реальні та прогнозовані значення індексу споживчих цін

На рис. 4 представлено прогнозування експорту у порівнянні з емпіричними даними. LSTM-модель демонструє нижчу похибку та вищий рівень відповідності тренду порівняно з найвною моделлю. Вона краще передбачає ключові передломні моменти, хоча все ще має певні неточності у періоди різких коливань. Найвний підхід значно відхиляється від реальних значень, особливо під час пікових змін, що свідчить про його обмеженість у прогнозуванні нестабільних періодів.

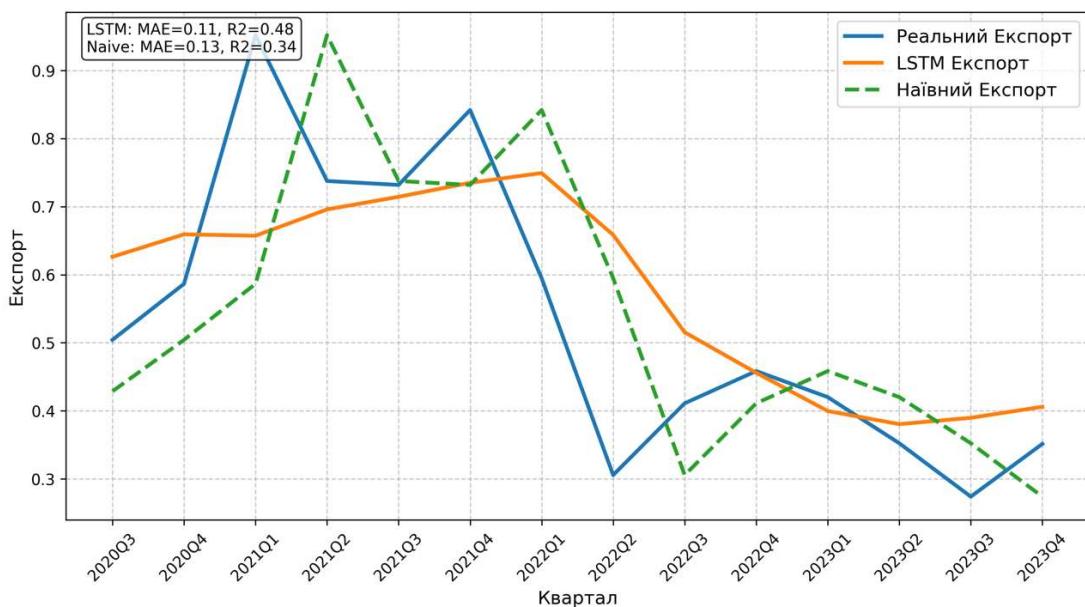


Рис. 4. Реальні та прогнозовані значення експорту

5.3. Кореляційний аналіз

Для виявлення структурних взаємозв'язків між дев'ятьма ключовими показниками побудовано кореляційну матрицю (рис. 5) та мережу кореляцій із порогом 0.3 (рис. 6) [33]. Значення коефіцієнтів, що перевищують зазначений поріг, вказують на помірну чи сильну взаємодію між змінними та дають змогу групувати їх у блоки за мірою схожості динамік.

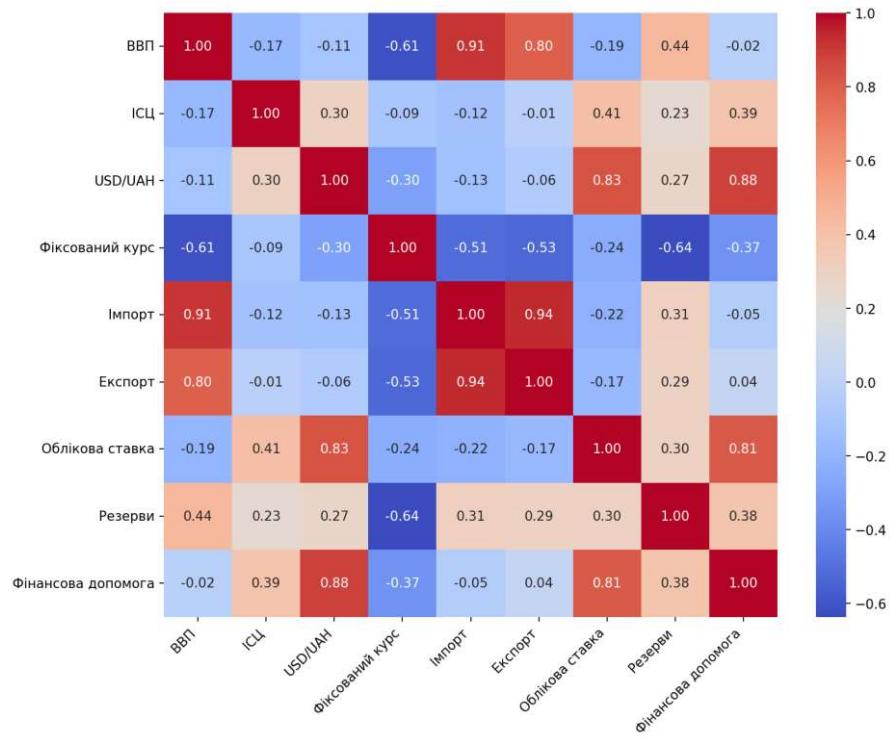


Рис. 5. Кореляційна матриця

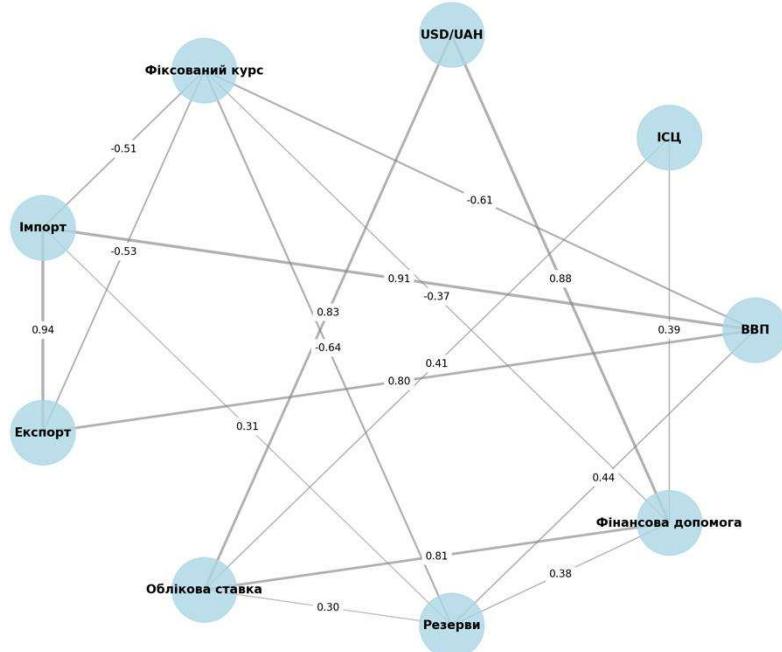


Рис. 6. Граф кореляційних зв'язків

Серед найвиразніших зв'язків варто виділити високі коефіцієнти між експортом й імпортом (0.94), що підтверджує тісне переплетення зовнішньоторговельних потоків, а також міцну кореляцію експорту з ВВП (0.80). Ці результати узгоджуються з теоретичними уявленнями про важливість зовнішнього сектора для економічного зростання. Виявлено помірний зв'язок між ІСЦ та обліковою ставкою (0.41), що вказує на вплив монетарної політики на інфляційні процеси. Цікавою є висока кореляція між обліковою ставкою та курсом USD/UAH (0.83), а також між курсом і обсягом міжнародної фінансової допомоги (0.88), що може відображати вплив зовнішніх валютних надходжень на підтримку стабільності обмінного курсу. Це може свідчити про тісний вплив зовнішніх фінансових чинників на внутрішній курс і процентну політику.

Окрім сильних позитивних кореляцій, слід відзначити наявність відчутних негативних взаємозв'язків, зокрема між фіксованою ставкою та кількома економічними показниками. Така полярність кореляцій указує на можливі компенсаторні механізми між різними сегментами економіки й може бути корисною при формуванні багатофакторних моделей. У сукупності матриця та граф кореляцій (рис. 5 та рис. 6) дозволяють виявляти найщільніше взаємопов'язані підгрупи змінних (наприклад, «імпорт – експорт – ВВП», а також «курс – облікова ставка – фінансова допомога»). Подібне розбиття має практичне значення для відбору вхідних факторів у моделюванні та інтерпретації потенційних аномальних прогнозів.

5.4. Рекомендації щодо адаптації моделі до структурних змін економіки

Період після 2022 року супроводжувався безprecedентними макроекономічними шоками, що істотно трансформували взаємозв'язки між ключовими економічними показниками. На тестовому інтервалі 2022Q1–2023Q4 спостерігалися значні розбіжності між прогнозними та фактичними значеннями, особливо в компонентах, чутливих до зовнішніх і внутрішніх дисбалансів: валютного курсу, рівня ІСЦ, зовнішньої фінансової допомоги та міжнародних резервів.

Аналіз похибок моделі LSTM у порівнянні з похибками найвного прогнозу та ARIMA-моделі вказує на зростання середньої помилки прогнозування (MAE, RMSE) на 25-30% у воєнний період. Основними причинами цього є:

- порушення історичних трендів і кореляцій. Параметри, які до війни мали стійкі залежності, різко змінили поведінку. Наприклад, відбулося зростання кореляції між рівнем міжнародних резервів та обсягами фінансової допомоги, що свідчить про зростання ролі зовнішнього фінансування у стабілізації валютного ринку;
- недостатність релевантних даних у нових умовах. До 2022 року модель навчалася на умовах відносно стабільної економіки. Наявність лише кількох квартальних спостережень після воєнного шоку не дозволяє повністю переорієнтувати прогнозні механізми;
- неврахування специфічних режимних змінних. Використання лише класичних макропоказників виявилося недостатнім для адекватного відображення впливу факторів воєнного часу.

З метою підвищення точності прогнозування в умовах структурних зрушень пропонується комплексний підхід, що включає такі напрями вдосконалення:

- a) введення режимних змінних та спеціалізованих індикаторів. Для підвищення адаптивності моделі до різких змін слід інтегрувати до вхідних параметрів спеціальні індикатори, які відображають перехід до воєнної економіки та ключові макроекономічні зміни. Це можуть бути: бінарна змінна, яка набуває значення 1 з моменту початку повномасштабної війни, показник інтенсивності бойових дій (наприклад, зростання/зменшення площі території, що перебуває під окупацією),

зовнішньоекономічний ризик-фактор, заснований на індексах ділових очікувань або змінах в експортно-імпортних потоках. Ці змінні допоможуть моделі розрізняти традиційні економічні фази та періоди кризових трансформацій, покращуючи якість прогнозу в екстремальних умовах;

б) групування змінних за кореляційною структурою та кластерне прогнозування. Кореляційний аналіз показав, що низка макроекономічних показників утворює тісно пов'язані групи: кластер зовнішньої торгівлі (експорт, імпорт, ВВП), монетарний кластер (облікова ставка, валютний курс, міжнародні резерви), інфляційний блок (ІСЦ, облікова ставка, фіксована валютна політика). З огляду на це, доцільно згадати два підходи до покращення прогнозування:

1) кластерне прогнозування: навчання окремих моделей для кожного кластеру, що може зменшити розмірність вхідних даних і покращити локальну точність прогнозів;

2) гібридизація архітектури: використання графових нейронних мереж GNN разом із LSTM для кращого урахування міжкластерних взаємозв'язків;

в) метод «заморожування ваг» і поетапного перенавчання. Один зі способів адаптації моделі до структурних змін – використання поетапного перенавчання (fine-tuning), що передбачає:

1) навчання базової моделі на довосніх даних (2002Q1–2021Q4);

2) заморожування внутрішніх ваг LSTM (зокрема, перших шарів, які відповідають за загальні патерни динаміки);

3) донавчання верхніх шарів моделі на обмеженому наборі даних після початку війни (2022Q1–2023Q4).

Це може дозволити зберегти інформацію про базові закономірності економіки, водночас коригуючи прогнозний механізм відповідно до нових умов;

г) використання методів розпізнавання режимних змін. Окрім оновлення самої LSTM, перспективним є застосування механізмів автоматичного розпізнавання «зламів» у часових рядах, зокрема: метод Бай-Перрона (Bai-Perron break test) для виявлення структурних змін у трендах; Марковської моделі перемикань (Markov-switching model), що дозволяють розрізняти економічні режими (зростання/криза) і підлаштовувати прогнозування відповідно до поточного стану економіки.

6. Обговорення результатів дослідження

Результати проведеного дослідження демонструють ефективність нейронних мереж LSTM у прогнозуванні макроекономічних показників України, особливо в умовах нестабільноті та структурних змін. Запропонована модель перевершила традиційні методи, такі як ARIMA, за ключовими метриками точності, що узгоджується з висновками попередніх досліджень щодо переваг глибинного навчання в економічному прогнозуванні [9], [10]. Водночас використання графових кореляційних моделей дозволило глибше проаналізувати взаємозв'язки між показниками та покращити інтерпретацію результатів прогнозування, що є важливим доповненням до суто машинного навчання.

Отримані результати підтвердили, що глибинні нейромережі мають здатність захоплювати нелінійні зв'язки в економічних часових рядах, що відповідає висновкам досліджень, у яких LSTM-моделі показували перевагу над ARIMA та VAR у макроекономічному прогнозуванні [9]. Однак порівняно з попередніми роботами, що зосереджувалися переважно на довгостроковій стабільноті моделей, у даному дослідженні було проведено оцінку їхньої ефективності в умовах екстремальних шоків, спричинених повномасштабною війною. Це дозволило виявити нові виклики, які не були достатньо висвітлені у попередніх дослідженнях: зокрема, порушення історичних трендів, зміна взаємозв'язків між основними макроекономічними змінними та необхідність

введення додаткових режимних факторів для корекції прогнозів.

Аналіз точності прогнозування в умовах впливу факторів воєнного часу показав, що LSTM-модель зберігає кращі характеристики порівняно з ARIMA навіть за нестабільних умов. Це узгоджується з результатами попередніх робіт, у яких було доведено перевагу нейромережевих підходів у періоди різких економічних спадів [8]. Водночас точність прогнозів у період 2022-2023 років знизилася, що частково пояснюється нестачею релевантних навчальних даних. У цьому аспекті можна провести паралелі з дослідженням [11], де було показано, що для підвищення точності прогнозу інфляції необхідне використання додаткових факторів, які коригують модель відповідно до змін економічної політики та очікувань ринку.

Головною перевагою отриманих результатів є можливість комплексного підходу до прогнозування, що поєднує LSTM-архітектуру з кореляційним аналізом для відбору релевантних факторів. Зокрема, побудова графових моделей дозволила виокремити ключові макроекономічні кластери, що можуть бути корисними для подальшого вдосконалення прогнозних алгоритмів. Подібні підходи вже застосовувалися в контексті фінансових ринків [16], однак у макроекономічному прогнозуванні вони залишаються недостатньо дослідженими, що робить дане дослідження одним із перших, де графові моделі застосовані для структурного аналізу макропоказників України.

Водночас важливо відзначити обмеження отриманих результатів. Основною проблемою є обмежений обсяг навчальних даних для воєнного періоду, що ускладнює стабільність моделі під час прогнозування після різких змін у макроекономічному середовищі. Крім того, хоча LSTM продемонструвала вищу точність, інтерпретованість нейромережевих моделей залишається проблемним аспектом, що обмежує їх використання в регуляторній і стратегічній економічній аналітиці. Дослідження [11] вказує, що традиційні економетричні моделі, попри нижчу точність, все ще характеризуються кращою інтерпретованістю. Отже, інтеграція LSTM з пояснювальними методами (наприклад, SHAP-аналіз) може бути наступним кроком для покращення інтерпретованості прогнозів.

Подальший розвиток цього напряму досліджень повинен включати вдосконалення моделей адаптації до структурних змін. У даній роботі було запропоновано підхід із використанням fine-tuning, коли модель спочатку навчається на довоєнних даних, після чого її внутрішні ваги частково заморожуються, а верхні шари донавчаються на нових спостереженнях. Такий підхід може бути ефективним для врахування довгострокових закономірностей економіки, водночас адаптуючи модель до нових режимів.

Крім того, перспективним напрямом дослідження є інтеграція LSTM із графовими нейронними мережами, що дозволить не лише прогнозувати окремі змінні, а й враховувати їхні взаємозалежності у динаміці. Попередні роботи довели ефективність таких підходів у фінансових системах [15], однак їх застосування в макроекономічному аналізі ще не було достатньо вивчене. Додатково варто дослідити можливості автоматичного виявлення точок структурних зламів у часових рядах.

7. Висновки

Проведене дослідження дозволило вирішити актуальну наукову задачу підвищення точності прогнозування макроекономічних показників України шляхом поєднання методів глибинного навчання та результатів інтерпретації взаємозв'язків між показниками за допомогою графової моделі кореляційного аналізу.

У ході дослідження було сформовано та проаналізовано комплексний набір макроекономічних даних України за 2002-2023 рр. (88 кварталів), що включає 9 ключових показників. Проведений кореляційний аналіз виявив значущі структурні взаємозв'язки між

змінними, зокрема між експортом та імпортом (0.94), експортом і ВВП (0.80), обліковою ставкою та валютним курсом (0.83). Встановлення цих залежностей дозволило обґрунтувати важливість комплексного підходу до прогнозування макроекономічних змінних, особливо в умовах структурних трансформацій української економіки.

Розроблено багатофакторну прогностичну модель на основі нейронної мережі LSTM, що одночасно прогнозує декілька економічних показників. Особливістю моделі є архітектура з двома послідовними LSTM-шарами (256 нейронів у прихованому стані) та механізмом регуляризації dropout (10 %), що забезпечує ефективне виявлення довгострокових нелінійних залежностей. На відміну від оглянутих традиційних лінійних моделей, запропонована нейромережа демонструє підвищену гнучкість при моделюванні структурних зрушень економіки, що підтверджується її вищою прогностичною точністю в періоди економічної нестабільності.

Реалізовано комбіновану функцію втрат для навчання нейронної мережі, яка одночасно оптимізує точність прогнозування кількісних показників (через MSE) та класифікацію якісних змінних (через BCE) з ваговими коефіцієнтами 0.8 та 0.2 відповідно. Такий підхід дозволив ефективно навчати модель для одночасного прогнозування показників різної природи, що особливо важливо для комплексного моделювання макроекономічної системи, де взаємодіють як кількісні, так і режимні змінні.

Експериментально підтверджено перевагу розробленої LSTM-моделі порівняно з базовими моделями (найвіншим прогнозом та ARIMA) на тестовому періоді 2020Q3-2023Q4. Для ІСЦ досягнуто зниження MAE на 20% порівняно з ARIMA (0.08 проти 0.10), для експорту – на 45% (0.11 проти 0.20), для облікової ставки R² підвишився до 0.82 проти - 0.05 у ARIMA. Емпіричні результати демонструють, що перевага LSTM над класичними методами є особливо значною для показників з вираженою нелінійністю, що узгоджується з теоретичними властивостями архітектури цієї нейромережі.

Для аналізу макроекономічних показників України побудовано графову модель взаємозв'язків між показниками на основі кореляційної матриці з порогом значущості 0.3. Аналіз графа виявив два чіткі макроекономічні кластери: «імпорт – експорт – ВВП», «курс – облікова ставка – фінансова допомога». Такий аналіз дозволив не лише візуалізувати економічні взаємозалежності, але й обґрунтувати методологічний підхід до кластерного прогнозування на основі виявлених кластерів показників, що заповнює виявлену в літературі прогалину щодо використання кореляційних графів для налаштування нейронних мереж у макроекономічному прогнозуванні.

На основі аналізу результатів прогнозування виявлено, що після початку повномасштабної війни відбулося порушення історичних економічних взаємозв'язків, що призвело до збільшення похиби прогнозування на 25-30 %. Розроблено комплексні рекомендації щодо вдосконалення моделі в умовах структурних зрушень, включно з:

- а) впровадженням режимних змінних та індикаторів воєнного часу;
- б) кластерним прогнозуванням на основі виявлених груп показників;
- в) застосуванням методу «заморожування ваг» і поетапного перенавчання;
- г) використанням методів автоматичного розпізнавання режимних змін.

Запропоновані підходи мають потенціал покращити адаптацію прогностичної моделі до макроекономічних шоків без потреби повного перенавчання, що особливо важливо для української економіки в умовах воєнних викликів.

Отримані результати доводять, що поставлену мету дослідження – підвищення точності прогнозування макроекономічних показників України із застосуванням LSTM-мереж та інтерпретація взаємозв'язків між ними за допомогою графового кореляційного аналізу – досягнуто. Це демонструє перспективність у застосуванні глибинного навчання

в економічному прогнозуванні, особливо в умовах структурних зрушень, і може слугувати основою для подальших досліджень, спрямованих на покращення адаптивності моделей до кризових періодів.

Перелік посилань:

1. Ma, Y. (2024). Analysis and Forecasting of GDP Using the ARIMA Model. *Information Systems and Economics*, 5 (1). <http://doi.org/10.23977/infse.2024.050112>
2. Hamiane, S., Ghanou, Y., Khalifi, H., Telmem, M. (2024). Comparative Analysis of LSTM, ARIMA, and Hybrid models for Forecasting Future GDP. *Ingénierie des systèmes d'information*, 29 (03), 853–861. <http://doi.org/10.18280/isi.290306>
3. Holtz, Y. Clustering result visualization with network diagram. URL: <https://www.r-graph-gallery.com/250-correlation-network-with-igraph.html>
4. Alboukadel (2019). Easily Create a Correlation Network in R using the Corrr Package. URL: <https://www.datanovia.com/en/blog/easily-create-a-correlation-network-in-r-using-the-corrr-package/>
5. Atindana, E., Engmann, G. M., Azaare, J. (2024). Statistical Network Analysis of Macroeconomic Variables in Ghana. *American Journal of Theoretical and Applied Statistics*, 13 (6), 227–241. <http://doi.org/10.11648/j.ajtas.20241306.15>
6. Трекер економіки України під час війни. *Centre for Economic Strategy*. URL: <https://ces.org.ua/tracker-economy-during-the-war/>
7. Ampountolas, A. (2024). Forecasting Orange Juice Futures: LSTM, ConvLSTM, and Traditional Models Across Trading Horizons. *Journal of Risk and Financial Management*, 17 (11), 475. <http://doi.org/10.3390/jrfm17110475>
8. Kamolthip, S. (2021). Macroeconomic forecasting with LSTM and mixed frequency time series data. *arXiv*. <http://doi.org/10.48550/arXiv.2109.13777>
9. Siami-Namini, S., Tavakoli, N., Siami Namin, A. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. B: *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*. Orlando, FL: IEEE, 1394–1401. <http://doi.org/10.1109/ICMLA.2018.00227>
10. Agustí, M., Costa, I. V.-Q., Altmeyer, P. (2023). Deep vector autoregression for macroeconomic data. *IFC Bulletins chapters*, 59. URL: <https://ideas.repec.org/h/bis/bisifc/59-39.html>
11. Dziubanovska, N., Koziuk, V., Hural, D., Danyliuk, I. (2024) Does Expectations Affect Inflation Forecasting Abilities of Machine Learning Techniques: Case of Ukraine. *The First International Workshop of Young Scientists on Artificial Intelligence for Sustainable Development; May 10-11, 2024, Ternopil, Ukraine*. URL: <https://ceurws.org/Vol-3716/paper10.pdf>
12. Almosova, A., Andresen, N. (2023). Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42 (2), 240–259. <http://doi.org/10.1002/for.2901>
13. The Bohdan Khmelnytsky National University of Cherkasy, Munka, S., Kyryliuk, Y., The Bohdan Khmelnytsky National University of Cherkasy (2022). Forecasting Indicators of Economic Development of Ukraine Using an Artificial Neural Network. *Path of Science*, 8 (1), <http://doi.org/10.22178/pos.78-11>
14. Новоселецький, О. М., Лопацька, І. В. (2012). Прогнозування рівня інфляції в Україні на основі нейронечітких мереж. *Scientific Notes of Ostroh Academy National University, «Economics» Series*, (19), URL: <https://journals.oa.edu.ua/Economy/article/view/1390>
15. Tumminello, M., Lillo, F., Mantegna, R. N. (2010). Correlation, hierarchies, and networks in financial markets. *Journal of Economic Behavior & Organization*, 75 (1), 40–58. <http://doi.org/10.1016/j.jebo.2010.01.004>
16. Sonani, M. S., Badii, A., Moin, A. (2025). Stock Price Prediction Using a Hybrid LSTM-GNN Model: Integrating Time-Series and Graph-Based Analysis. *arXiv*. <http://doi.org/10.48550/ARXIV.2502.15813>
17. ВВП України за роками. URL: <https://nabu.ua/ua/vvp-2.html>
18. Ціни і тарифи. URL: https://www.ukrstat.gov.ua/operativ/menu/menu_u/cit.htm
19. Офіційний курс гривні щодо іноземних валют. URL: <https://bank.gov.ua/ua/markets/exchangerate-chart?cn%5B%5D=USD&endDate=10.03.2025&startDate=01.01.2000>
20. Про роботу банківської системи та валютного ринку з 24 лютого 2022 року в умовах воєнного стану по всій території України. URL: <https://bank.gov.ua/ua/news/all/pro-robotu-bankivskoyi-sistemi-ta-valyutnogo-rinku-z-24-lyutogo-2022-roku-za-umovi-voyennogo-stanu-po-vsii-teritoriyi-ukrayini>
21. НБУ впроваджує керовану гнучкість обмінного курсу, що посилює стійкість валютного ринку та економіки. URL: <https://bank.gov.ua/ua/news/all/nbu-vprovadjuje-kerovanu-gnuchkist-obminnogo-kursu-schoposilit-stiykist-valyutnogo-rinku-ta-ekonomiki>
22. Slaviuk, N. (2023). *Exchange rate of Ukraine: tendencies and problems*. Kyiv-Mohyla Academy Publishing House, URL: <https://ekmair.ukma.edu.ua/handle/123456789/31880>
23. Fix the Hryvnia? Never Again! URL: <https://voxukraine.org/en/fix-the-hryvnia-never-again>

24. Ukraine Trade Summary 2002. WITS. URL: <https://wits.worldbank.org/CountryProfile/en/Country/UKR/Year/2002/Summarytext>
25. Національний банк України URL: https://bank.gov.ua/files/ES/BOP_m.xlsx
26. Облікова ставка Національного банку. URL: <https://bank.gov.ua/ua/monetary/archive-rish>
27. Динаміка міжнародних резервів. URL: <https://bank.gov.ua/ua/markets/international-reserves-allinfo/dynamics?endDate=01.02.2025&startDate=01.02.2003>
28. Foreign aid received. URL: <https://ourworldindata.org/grapher/foreign-aid-received-net?tab=chart&country=UKR>
29. Trebesch, C., Bompuzzi, P., Kharitonov, I. (2025). Ukraine Support Tracker Data. URL: <https://www.ifw-kiel.de/publications/ukraine-support-tracker-data-20758/>
30. Lu, Y. (2016). Empirical Evaluation of A New Approach to Simplifying Long Short-term Memory (LSTM). *arXiv*. <http://doi.org/10.48550/arXiv.1612.03707>
31. Oberoi, J. S., Pittea, A., Tapadar, P. (2020). A graphical model approach to simulating economic variables over long horizons. *Annals of Actuarial Science*, 14 (1), 20–41. <http://doi.org/10.1017/S1748499519000022>
32. Баник, А., Мулеса, П. (2025). Візуалізація кореляційних зв'язків та прогнозування макроекономічних змін в Україні. В: *Proceedings of VIII International Scientific and Practical Conference*. Boston, USA: BoScience Publisher, 211–215. URL: <https://sci-conf.com.ua/viii-mizhnarodna-naukovo-praktichna-konferentsiya-current-trends-in-scientific-research-development-13-15-03-2025-boston-ssha-arhiv/>
33. Баник, А., Мулеса, П. (2025). Технічна основа прогнозування за допомогою LSTM та кореляційний аналіз на етапі підготовки даних. В: *Collection of Scientific Papers «International Scientific Unity» with Proceedings of the 2nd International Scientific and Practical Conference*. Bucharest, Romania, 79–82. URL: <https://isu-conference.com/en/archive/modern-science-economy-and-digital-innovation-12-03-25/>

Надійшла до редколегії 08.03.2025 р.

Баник Андрій Вікторович, аспірант кафедри кібернетики і прикладної математики, факультет математики та цифрових технологій, УжНУ, м. Ужгород, Україна, e-mail: andrii.banyk@uzhnu.edu.ua, ORCID: <https://orcid.org/0000-0002-8991-310X>

Мулеса Павло Павлович, доктор педагогічних наук, доцент, завідувач кафедри кібернетики і прикладної математики, факультет математики та цифрових технологій, УжНУ, м. Ужгород, Україна, e-mail: pavlo.mulesa@uzhnu.edu.ua, ORCID: <https://orcid.org/0000-0002-3437-8082>

УДК 004.9

DOI: 10.30837/0135-1710.2025.184.039

A.B. MIXNOVA, K.S. ЧИРКОВА, О.Д. MIXNOVA

МЕТОД УПРАВЛІННЯ ЗАПАСАМИ КОМПОНЕНТІВ ДОНОРСЬКОЇ КРОВІ

Розглянуто особливості управління запасами компонентів крові. Метою дослідження є розробка методу управління запасами компонентів донорської крові. Реалізація методу дозволяє здійснювати розподіл запасів компонентів крові кожної групи та резус-належності в заклади охорони здоров'я з урахуванням таких чинників управління запасами, як щоденна, щотижнева, річна потреба у компонентах крові за груповою та резус-належністю; період часу між замовленнями закладів охорони здоров'я; можливі обсяги та частота заготівлі компонентів крові за кожною групою крові та резус-належністю центром крові; запаси компонентів крові в інших закладах охорони здоров'я за кожною групою крові та резус-належністю. Розроблений метод управління запасами компонентів донорської крові використовується при проєктуванні реалізації функціонального модуля інформаційної системи для забезпечення оптимального розподілу компонентів крові центром крові між закладами охорони здоров'я з урахуванням визначених чинників.

1. Вступ

Заклади охорони здоров'я щохвилини мають потребу в запасах компонентів крові задля можливості виконувати переливання при важких травмах, післяпологових кровотечах, ургентних операціях та інших маніпуляціях [1]. Наявність компонентів донорської крові в закладах охорони здоров'я під час проведення планових та ургентних