

**Економічна теорія**

Тетяна ЗАТОНАЦЬКА,
Олесь КОВАЛЬ,
Алім СИЗОВ,
Кіра ГОРЯЧЕВА,
Дмитро ЗАТОНАЦЬКИЙ

**ВІЙСЬКОВІ ВИДАТКИ В КОНТЕКСТІ
СТРУКТУРИЗАЦІЇ РИНКУ ПРАЦІ****Резюме**

У статті досліджено роль змін у військових видатках як чинника структурних змін на ринку праці, зокрема через їхній вплив на співвідношення зайнятих до чисельності населення (Employment-to-Population Ratio, EPR), на прикладі Німеччини, Чеської Республіки та України у період 1993–2024 рр.

© Тетяна Затонацька, Олесь Коваль, Алім Сизов, Кіра Горячева,
Дмитро Затонацький, 2025.

Затонацька Тетяна, доктор економічних наук, професор, кафедра економічної кібернетики, Київський національний університет імені Тараса Шевченка, Київ, Україна. ORCID: 0000-0001-9197-0560 Email: tetiana.zatonatska@knu.ua

Коваль Олесь, доктор філософії з фінансів, доцент, кафедра фінансів, Військовий інститут Київського національного університету імені Тараса Шевченка, Київ, Україна. ORCID: 0000-0003-2696-7204 Email: oles.koval@knu.ua

Сизов Алім, кандидат економічних наук, доцент, провідний науковий співробітник, Науково-дослідний центр, Військовий інститут Київського національного університету імені Тараса Шевченка, Київ, Україна. ORCID: 0000-0002-6400-3951 Email: alik_sizov@ukr.net

Горячева Кіра, кандидат економічних наук, доцент, Школа бізнесу, Університет Данді, Данді, Велика Британія. ORCID: 0000-0003-1503-4425 Email: khoracheva001@dundee.ac.uk

Затонацький Дмитро, доктор філософії з економіки, ДНУ «Інститут освітньої аналітики», Київ, Україна. ORCID: 0000-0002-4828-9144 Email: dzatonat@gmail.com

Відсутні дані EPR для України оцінено за допомогою моделі logit-AR(1). Для аналізу нелінійних і асиметричних ефектів розроблено та порівняно п'ять моделей машинного навчання (MLP, LSTM, 1D CNN, Random Forest, XGBoost) із гібридною автокореляційною корекцією залишків. Інтерпретацію результатів здійснено з використанням аналізу SHAP, а також проведено контрфактичний аналіз сценаріїв типу «what-if» із варіаціями $\pm\sigma$ та визначенням порогових точок чутливості. Отримані результати виявляють виражену асиметрію впливу військових видатків на структуру ринку праці: для України збільшення ME_diff на $+1\sigma$ підвищує EPR на 0,295%, тоді як зменшення на -1σ знижує його лише на 0,064%. Виявлено критичні порогові значення на рівні $\pm 0,25\sigma$, після яких ефекти набувають статистично та економічно значущого характеру. Оцінені мультиплікатори свідчать, що додаткові військові видатки асоціюються з приростом приблизно 5 робочих місць на мільйон доларів США в Німеччині та Чеській Республіці і понад 29 робочих місць на мільйон доларів США в Україні. Перевищення відповідних оцінок Світового банку та МВФ для розвинених економік відображає специфічні структурні умови та трансформаційний характер ринку праці в Україні.

Ключові слова:

SHAP; аналіз сценаріїв; асиметричні ефекти; військові видатки; машинне навчання; пороговий ефект; співвідношення зайнятих до населення.

Класифікація за JEL: E270.

7 рисунків, 24 таблиці, 21 формула та 33 джерела літератури.

Постановка проблеми

Світові військові видатки зростають, досягнувши 2,718 трлн дол. США у 2024 р. (Liang та ін., 2025). Гібридна війна посилює їхній економічний вплив, створюючи системну невизначеність та порушуючи інвестиційні й логістичні ланцюги. У цьому контексті оборонні бюджети є одночасно стабілізаторами та джерелами фіскального навантаження (Sokhatskyi та ін., 2020). Одним із ключових каналів впливу є ринок праці: військові видатки можуть стимулювати зайнятість у секторах, пов'язаних з обороною, але водночас витіснити приватні інвестиції та обмежувати ширший приріст робочих місць. Фінансування оборонного сектору України змінилося від поступового зростання до швидких перерозподілів, зумовлених геополітичними шоками, що призвело до пріоритетності військових потреб над іншими державними видатками та посилення фіскальної нестабільності (Ставицький та ін., 2023).

У цьому дослідженні розглядається нова архітектура безпеки, зосереджена на європейських державах, які виявилися більш залученими до конфлікту, ніж зазвичай вважається, зокрема на Чеській Республіці та Німеччині. Реакція Німеччини на вторгнення Росії у 2022 році ознаменувала суттєвий зсув політики від «Ostpolitik» та стратегій, заснованих на торгівлі, до відновлення військового потенціалу (Löfflmann та Riemann, 2025).

Метою цього дослідження є кількісна оцінка ролі військових видатків як чинника структурних змін на ринку праці, зокрема через вплив змін у військових видатках (ME_{diff}) на співвідношення зайнятих до чисельності населення (Employment-to-Population Ratio, EPR), на прикладі трьох європейських країн – Німеччини, Чеської Республіки та України. У роботі застосовано комплексний підхід, що охоплює: (i) прогнозування відсутніх даних EPR для України за 2022–2024 роки методом $\text{logit-AR}(1)$; (ii) навчання та порівняння п'яти класів моделей машинного навчання (MLP, LSTM, 1D CNN, Random Forest, XGBoost) із адаптивною гібридною корекцією залишків; (iii) інтерпретацію результатів за допомогою аналізу SHAP; (iv) контрфактичний аналіз сценаріїв («what-if») із варіаціями $\pm\sigma$ та визначення порогових точок чутливості; та (v) трансформацію відносних змін EPR в абсолютні показники зайнятості разом із оцінками економічної ефективності.

Огляд літератури

Holcner та ін. (2021) досліджують взаємозв'язок військових видатків, рекрутингу до збройних сил Чехії та показників ринку праці. Використовуючи дані за 2005–2019 р., науковці встановлюють, що збільшення оборонних витрат корелює з підвищенням попиту на робочу силу у військовому секторі, але має обмежений вплив на загальний рівень зайнятості. Дослідження також підкреслює необхідність адаптації освітніх програм для задоволення потреб оборонної промисловості, що стає особливо актуальним на тлі зростання військових бюджетів.

Sağın та Kocaarslan (2023) пропонують ширший регіональний погляд, аналізуючи вплив військових видатків на зайнятість у країнах Східної Європи, включно з Чеською Республікою. Їхній аналіз панельних даних показує, що оборонні витрати, як правило, мають короткостроковий позитивний ефект на створення робочих місць, особливо в галузях, пов'язаних з обороною, але ці ефекти з часом зменшуються. Це свідчить про те, що хоча збільшення військових бюджетів може тимчасово стимулювати зайнятість, вони не гарантують сталого покращення на ринку праці.

Simpertl (2024) здійснює метааналіз досліджень щодо взаємозв'язку військових видатків та економічного зростання, пропонуючи висновки, релевантні для ринків праці в Центральній та Східній Європі. Результати показують, що хоча оборонні витрати можуть забезпечувати галузеві переваги у зайнятості, їхній загальний вплив на створення робочих місць є помірним і значною мірою залежить від структури оборонних бюджетів. Це свідчить про те, що політики мають враховувати склад військових видатків, оцінюючи їхніх довгострокові наслідки для ринку праці.

Це переосмислення все ще має невизначені наслідки для оборонного сектору Німеччини, попри численні згадки про «погані новини для Бундесверу» та заклики до кращого оснащення. Після *Zeitenwende* фінансування Бундесверу поступово покращувалося, однак ознаки тривалої стагнації залишаються (Gebauer та Hammerstein, 2023). Дослідження свідчать, що оборонна політика сигналізує про відхід від пацифістської традиції Німеччини, яка характеризувалася військовою стриманістю (Stengel, 2025). Водночас деякі автори застерігають від перебільшення цього зсуву, посиляючись на участь Німеччини в операціях НАТО та місії в Афганістані (Nabers та Stengel, 2025).

Останні дискусії у США посилили заклики до створення єдиної політики безпеки ЄС. Окрім тимчасового фінансування Бундесверу, потрібні комплексні заходи, незважаючи на ризики підвищення податків та скорочення видатків в інших сферах. Політика залишається непопулярною, а обмежене військове розширення Німеччини стримує створення робочих місць, що робить

заклик Мерца щодо додаткових ресурсів виправданим (Frankfurter Allgemeine, 2025).

Макроекономічні наслідки зростання військових видатків потребують оцінки їхнього фіскального впливу. Збільшення на 1% ВВП протягом трьох років корелює з двоохрічним мультиплікатором ВВП на рівні 0,93 та зростанням інфляції за індексом споживчих цін (Consumer Price Index, CPI) на 0,07 пункту (Bokan та ін., 2025). Раніше розроблені моделі показують короткострокове зростання та приріст зайнятості, хоча довгострокові ефекти залежать від очікувань (Adjemian та ін., 2024). Амбітні цілі Німеччини можуть підвищуватися, незважаючи на обмежений довгостроковий вплив.

Німецькі оборонні компанії прагнуть створити інфраструктуру світового рівня, хоча залишаються побоювання щодо довгострокових економічних наслідків (Lundgreens Investor Insights, 2025). Зайнятість може зміститися у спеціалізовані сфери з дефіцитом навичок, що потребує адаптації технологічних можливостей Німеччини та спрямування бюджетів на військову інфраструктуру для створення робочих місць.

Stamegna та ін. (2024) аналізують економічні наслідки витрат на озброєння в Німеччині, Італії та Іспанії, використовуючи модель міжгалузевого балансу. Автори стверджують, що оборонні видатки мають обмежений мультиплікативний ефект на економічне зростання та зайнятість порівняно з цивільними державними інвестиціями. Зокрема, у випадку Німеччини збільшення військових витрат сприяє створенню робочих місць переважно у високотехнологічних секторах, але не призводить до значного приросту зайнятості у традиційних галузях. Це підтверджує тезу про те, що структура оборонних видатків визначає їхній вплив на ринок праці.

Багато держав ЄС, особливо ті, що межують із Росією та Україною, збільшили оборонні видатки. Спочатку скептично ставлячись до цілі НАТО у 2% ВВП, чеські науковці аргументували необхідність контекстно-специфічних орієнтирів і запропонували рівень 3,5–4,2% як раціональне «страхування» (Šlouf та ін., 2023). На тлі зростання геополітичної напруженості Чеська Республіка вперше за два десятиліття підняла оборонні витрати до 2% і до 2030 р. планує досягти 3%. (Zachová, 2025; Reuters, 2025). Загострення військової напруженості вимагає моделей для прогнозування цих тенденцій та їхнього впливу на зайнятість, адже наявні докази асиметричних ефектів залишаються суперечливими: моделі з фіксованими ефектами та узагальнений метод моментів (Generalized Method of Moments, GMM) демонструють помірні значення мультиплікаторів, тоді як моделі порогового типу та моделі зміни режимів виявляють нелінійні закономірності.

Макроекономічні наслідки військових видатків

Військові видатки є ключовим чинником соціальної безпеки та макроекономічного розвитку. Для оцінювання їхнього впливу на зайнятість варто розглянути теоретичну перспективу. Dunne та Tian (2013) пропонують модифіковану модель зростання Солоу з технологічним прогресом типу Харрода, де оборонні витрати входять у виробничу функцію через мультиплікатор, що коригує ефективність:

$$A(t) = A_0 e^{gt} m(t)^\theta. \quad (1)$$

Досвід розвинених економік показує наявність нелінійного зв'язку між військовими видатками та економічним зростанням, що залежить від технологій та фіскальної дисципліни. Помірне збільшення може стимулювати короткострокове зростання ВВП, а надмірні асигнування створюють ризик витіснення інвестицій (Kolinets та Dluhopolskyi, 2024).

Оборонні витрати загалом чинять негативний мультиплікативний ефект на реальний ВВП на душу населення, відволікаючи ресурси від продуктивного використання (Dunne та Tian, 2016). Це твердження ґрунтується на аналізі панелі з 104 країн (1988–2010) та спирається на огляд 168 досліджень щодо військових видатків і економічного зростання у світі (Dunne та Tian, 2013).

Azam та Feng (2017) проаналізували десять азійських країн (1990–2011), підтвердивши попередні дані про те, що військове навантаження збільшує зовнішній борг у невеликих індустріальних економіках (Dunne та ін., 2004). Їхнє дослідження показує, що зростання військових видатків на 1% призводить до збільшення зовнішнього боргу приблизно на 0,13 в. п. (Azam та Feng, 2017).

Додаткові дослідження виявляють опосередковані макроекономічні ефекти, узагальнені в табл. 1.

Зайнятість демонструє змішану динаміку: військові видатки створюють робочі місця в оборонній сфері та посилюють ланцюги постачання, проте водночас перерозподіляють людський капітал із цивільних секторів, спрямовуючи економіку в бік мілітаризації.

Таблиця 1

Відстеження опосередкованих макроекономічних показників

Показники	Позитивна траєкторія впливу	Потенційно негативна траєкторія впливу
<i>Зайнятість</i>	Робочі місця в оборонному секторі, ефекти посилення ланцюгів постачання	Перенаправлення навичок / ресурсів із цивільних секторів
<i>Основний капітал</i>	Інфраструктура з потенціалом подвійного використання	«Фіксація» інвестицій у непродуктивні військові активи
<i>Відкритість торгівлі</i>	Оборонні закупівлі можуть зміцнювати торговельні зв'язки	Імпорт військової продукції негативно впливає на торговельний баланс

Джерело: Raifu та Aminu (2023).

Вплив на зайнятість та мультиплікатори

Ще одним ключовим аспектом є зайнятість. У деяких випадках зростання військових видатків на 1% (до ВВП) відповідає зниженню рівня безробіття на 1,2% у довгостроковій перспективі – ефект, що перевищує пропорційний (Azam та ін., 2016). Це підкреслює роль оборонних витрат у створенні робочих місць у регіоні Асоціації Регіонального Співробітництва Південної Азії (South Asian Association for Regional Cooperation, SAARC) та дає уявлення про мультиплікаційні ефекти. Результати подано в табл. 2.

Таблиця 2

Інтерпретація мультиплікатора

Змінна	Еластичність / безробіття	Інтерпретація мультиплікатора
Військові видатки	-1,196	Високий мультиплікатор зайнятості – кожне зростання співвідношення військових видатків до ВВП на 1% знижує рівень безробіття приблизно на 1,2%.
ВВП на душу населення	-0,005	Дуже слабкий прямий ефект на ринок праці – зростання ВВП не забезпечує значного приросту робочих місць без цільових витрат.

Джерело: Azam та ін. (2016).

У дослідженні щодо країн НАТО (18 членів, 1991–2018) застосовано тест причинності Копуа Bootstrap Panel, що дало змогу виявити різні ступені причинно-наслідкових зв'язків (Özşahin та Üçler, 2021). Інша релевантна робота аналізує причинний зв'язок між військовими видатками та безробіттям у країнах G7 (1988–2012), використовуючи підхід панельної причинності з бутстрепом для врахування міжкраїнних взаємозв'язків та гетерогенності (Zhong та ін., 2015). Sağın та Kocaarslan (2023) додають цінні висновки, зокрема щодо країн, що є ключовими для нашої моделі: дослідження охоплює Чеську Республіку та Німеччину.

Машинне навчання у макроекономічному прогнозуванні

Після розгляду панельних та динамічних моделей досліджено машинне навчання (ML) як додатковий інструмент для макроекономічного прогнозування та аналізу сценаріїв. ML дає змогу враховувати нелінійні взаємозв'язки та підвищувати точність прогнозів, пропонуючи висновки, що виходять за межі традиційних економетричних методів (Zatonatska та ін., 2025). Аналогічно Elshafei та ін. (2025) застосовують ML для прогнозування зв'язків між військовими видатками та ключовими макроекономічними показниками (зростання ВВП, зайнятість та фіскальний баланс), що дає змогу досягти вищої точності, ніж класичні моделі.

Кроки попередньої обробки охоплювали: (1) нормалізацію та стандартизацію неперервних змінних; (2) генерацію лагів для пояснювальних змінних (наприклад, ME_diff_t-1 , GDP_diff_t-1); (3) розподіл на навчальну та тестову вибірку за часом із використанням оцінки rolling-origin для уникнення упередження «lookahead»; (4) обробку пропущених значень через інтерполяцію або імпутацію.

Основні висновки із застосування машинного навчання (machine learning, ML) можна поділити на три напрями:

- Ефективність: (a) моделі градієнтного бустингу та Long Short-Term Memory (LSTM) перевершують традиційні економетричні підходи у прогнозах поза вибіркою, особливо в періоди економічної нестабільності; (b) Random Forest (RF) забезпечує надійну інтерпретованість, хоча має нижчу точність прогнозування.
- Висновки: (a) нелінійна динаміка та взаємодійні ефекти між ME_diff і GDP_diff є статистично значущими; (b) простежується пороговий характер – незначні зміни у військових видатках майже не вплива-

ють на макроекономічні показники, а великі шоки спричиняють непропорційні макроекономічні реакції.

- Політична релевантність: моделі ML можуть функціонувати як інструменти раннього попередження, дозволяючи політикам прогнозувати макроекономічні коригування, що виникають унаслідок змін оборонного бюджету.

Таким чином, на основі огляду літератури можна визначити кілька дослідницьких прогалин: (a) відсутність єдиної моделі, здатної одночасно порівнювати асиметричні та порогові ефекти; (b) обмежена інтеграція результатів моделювання ML із класичними економетричними доказами щодо мультиплікаторів (Basu та Jha, 2024; García-Peñalvo та ін., 2018; Knaus та ін., 2022; Wei та ін., 2023).

Методологія

Щодо джерел даних, ми зібрали річні дані для Німеччини, Чеської Республіки та України за період 1993–2024 років. Розглянуті показники охоплюють:

- співвідношення зайнятих до чисельності населення (Employment-to-Population Ratio, EPR, %);
- військові видатки (ME, у доларах США)»
- темп зростання валового внутрішнього продукту (ВВП, %);
- валові нагромадження основного капіталу (Gross Fixed Capital Formation GFCF, % від ВВП);
- додана вартість промисловості (Industrial Value Added, IVA, % від ВВП);

Для України, однак, ряд EPR доступний лише до 2021 р. Щоб усунути пропущені значення за 2022–2024 роки, згенеровано прогнози за допомогою моделі logit-AR(1).

У дослідженні використано моделі для різних підзадач. Зокрема, виконано три кроки: по-перше, модель часових рядів logit-AR(1) застосовано для відновлення пропущених даних EPR для України; по-друге, вивчено та порівняно набір моделей машинного навчання (MLP, LSTM, 1D-CNN, Random Forest, XGBoost), щоб обрати найбільш точний прогнозник змін EPR; і по-третє, деревоподібну модель з найкращими показниками використано як основну для інтерпретації (аналіз SHAP) та моделювання контрфактичних сценаріїв.

Багаторівнева структура моделі дає змогу ефективно застосовувати кожен групу моделей у найбільш відповідному контексті. Це охоплює використання моделей часових рядів для інтерполяції коротких рядів, послідовних моделей для порівняльного аналізу динамічних патернів та деревоподібних моделей для стабільних, інтерпретованих ефектів, що мають значення для політики. Такий підхід підвищує надійність моделі.

Під час передобробки та трансформації даних гармонізовано й очищено вихідні ряди за такими кроками:

- Пропущені значення макроекономічних змінних оброблені за допомогою лінійної інтерполяції, а 2020–2021 рр. вилучено для поза-вибіркового тестування.
- До показника EPR застосована логіт-трансформація таким чином:

$$z = \ln\left(\frac{p}{100 - p}\right), p \in (0, 100). \quad (2)$$

Інверсія:

$$\frac{e^z}{1 + e^z}. \quad (3)$$

Перші різниці макроекономічних змінних обчислені таким чином:

$$\Delta X_t = X_t - X_{t-1}, \in \{GDP, GFCG, IVA, ME\}. \quad (4)$$

Усі ознаки та цільові змінні стандартизовані до нульового середнього та одиничної дисперсії перед навчанням моделі.

У контексті створення ознак для врахування часових залежностей згенеровано такі змінні:

- лаги: EPR_lag1, EPR_lag2, ME_lag1, ME_lag2;
- ковзні середні: EPR_roll3_mean, EPR_roll6_mean;
- фіктивні змінні для країн.

Це формує матрицю ознак для прогнозування:

$$X \in R^{N \times K}, K \approx 11. \quad (5)$$

Здійснено прогнозування EPR для України, використовуючи AR(1) та моделювання Монте-Карло. Модель logit-AR(1) оцінена на ряді EPR України (1993–2021 рр.):

$$z_t = \alpha + \varphi, z_{t-1} + \varepsilon_t, \varepsilon_t \sim N(0, \sigma^2). \quad (6)$$

Далі згенеровано 10 000 траєкторій Монте-Карло (2022–2024) через вибірку:

$$\varphi \text{ from } N(\hat{\varphi}, SE_{\varphi}^2). \quad (7)$$

Змодельовані значення (z) перетворені назад у відсотковий EPR, а також обчислено 95% довірчі інтервали прогнозу. Залишки перевірялися за допомогою ACF та тестів Ljung-Box на серійну кореляцію.

Моделі навчалися на даних за 1993–2019 рр. та валідувалися на 2020–2021 рр. із використанням MAE, RMSE та R^2 . Гіперпараметри налаштовувалися за допомогою GridSearchCV та ковзних вікон; тести Diebold-Mariano застосовувалися для оцінювання переваги прогнозів.

Діагностика залишків та гібридне моделювання охоплювали перевірку ACF; якщо автокореляція зберігалася, до залишків підбиралася модель AR(4):

$$e_t = \sum_{i=1}^4 \varphi_i e_{t-i} + \eta_t. \quad (8)$$

Первинний прогноз, отриманий за допомогою моделей машинного навчання, було подано як:

$$\hat{y}_{t+h}^{ML} \quad (9)$$

з прогнозом залишків, скоригованих за автокореляцією (AR-corrected residual forecast):

$$\hat{e}_{t+h} \quad (10)$$

щоб отримати гібридні прогнози:

$$\hat{y}_{t+h}^{hyb} = \hat{y}_{t+h}^{ML} + \hat{e}_{t+h}. \quad (11)$$

Фінальний етап охоплював аналіз важливості ознак та оцінювання сценаріїв, зокрема:

- обчислення значень SHAP для XGBoost для кількісного визначення граничного внеску кожної ознаки;
- побудову графіків часткової залежності та залежності для ME_diff і лагових змінних;
- контрфактичні сценарії типу «what-if»:

$$\pm 1\sigma \text{ and } \pm 0.25\sigma \quad (12)$$

для ME_diff and GDP_diff. Відповідні зміни фіксувалися як середнє ΔEPR .

Результати дослідження

Прогноз EPR для України на 2022–2024 рр.

Для прогнозування EPR України на 2022–2024 рр. використано історичні дані за 1993–2021 рр., навчили моделі LSTM та 1D CNN й усереднили їхні прогнози. Отримані прогнози повторно інтегровані в набір даних. Архітектури LSTM та 1D-CNN застосовуються тільки на етапі прогнозування EPR для України, щоб оцінити ефективність нелінійних послідовних моделей у відтворенні пропущених значень за період 2022–2024 рр.

Натомість фінальні траєкторії EPR, використані в аналізі політики, отримані за допомогою моделі logit-AR(1) – методу, що забезпечує стаціонарність, реалістичні інтервали прогнозування та прозору діагностику часових рядів.

Таблиця 3

Показники ефективності моделей у процесі навчання (epochs)

Метрика	Епоха 1 (MAE)	Епоха 100 (MAE)	Зміна (Δ)
Втрата на навчанні	51,90	47,02	–4,88
Втрата на валідації	50,32	45,57	–4,75


Джерело: розраховано авторами.

У табл. 3 показано, що тренувальні та валідаційні втрати послідовно зменшуються протягом епох, причому валідаційна втрата є нижчою за тренувальну, що свідчить про відсутність перенавчання. Механізм ранньої зупинки не спрацював, і модель відпрацювала всі 100 епох із поступовим покращенням.

Середнє покращення на епоху було незначним (≈ 0.05 MAE), що вказує на зменшення віддачі за наявної архітектури. Рис. 1 підтверджує стабільне зниження втрат без ознак перенавчання.

Рисунок 1

Тренувальні та валідаційні втрати LSTM протягом епох



Джерело: розраховано авторами.

Примітка: Training Loss – тренувальна втрата; Validation Loss – валідаційна втрата.

Для дослідження динаміки навчання на пізніх етапах визначено п'ять епохових переходів, що продемонстрували найбільше зниження валідаційної втрати. Узагальнені результати наведено в табл. 4.

Таблиця 4

П'ять епохових переходів із найбільшим зниженням валідаційної втрати (LSTM)

Рейтинг	Перехід між епохами	Δval_loss
1	98 → 99	0,0646
2	97 → 98	0,0633
3	92 → 93	0,0622
4	96 → 97	0,0614
5	94 → 95	0,0607

Джерело: розраховано авторами.

Примітка: Δval_loss позначає зменшення валідаційної втрати між послідовними епохами.

Результати, наведені в табл. 4, свідчать, що найбільш суттєві покращення відбуваються на пізньому етапі навчання (епохи 92–99), що підкреслює потенціал для точного налаштування моделі. Для зменшення залишкової варіації протестовано введення 20% dropout у LSTM.

Таку саму процедуру проведено для моделі 1D CNN. Відповідні епохи переходу подано в табл. 5.

Таблиця 5

П'ять найкращих переходів між епохами з найбільшим зниженням втрат на валідації (1D CNN)

Рейтинг	Перехід між епохами	Δval_loss
1	98 → 99	0,0741
2	96 → 97	0,0738
3	99 → 100	0,0737
4	93 → 94	0,0735
5	92 → 93	0,0732

Джерело: розраховано авторами.

Примітка: Δval_loss позначає зниження втрат на валідації між послідовними епохами.

Нарешті, порівняльна ефективність моделей LSTM та 1D CNN за однакових налаштувань (20% dropout, ті самі callback-и) наведена в табл. 6.

Таблиця 6

Порівняльна ефективність моделей LSTM та 1D CNN (20% dropout)

Модель	Підсумковий тренувальний MAE	Підсумковий валідаційний MAE	Розрив узагальнення (Train – Val)
LSTM	47,29	46,69	0,60
1D CNN	45,00	41,86	3,14

Джерело: розраховано авторами.

Примітка: Розрив узагальнення обчислюється як різниця між тренувальною та валідаційною MAE (Train – Val).

Модель 1D CNN демонструє значно нижчу MAE як на тренувальній, так і на валідаційній вибірках порівняно з LSTM, що свідчить про її вищу здатність відтворювати патерни EPR за однакових умов регуляризації та навчання.

Для подальшої перевірки надійності прогнозного конвеєра проведено трес-тест, вилучивши дані за 2020 і 2021 роки, ітеративно спрогнозувавши ці значення та порівнявши прогнози з фактичними спостереженнями. Результати наведено в табл. 7.

Таблиця 7

Порівняння прогнозованих та фактичних значень EPR

Рік	Прогнозований EPR	Фактичний EPR	Абсолютна похибка
2020	30,3361	49,868	19,5319
2021	89,8315	49,266	40,5655

Джерело: розраховано авторами.
Примітка: Two-Step MAE = 30,0487.

Абсолютна похибка становила 19,53 у 2020 р. та 40,57 у 2021 р., що дало двокрокову MAE на рівні 30,05. Така відносно висока похибка підкреслює складність багатокрокового прогнозування у малих макроекономічних вибірках.

Далі ще раз проведено оцінювання, безпосередньо порівнюючи прогнозовані та фактичні значення для 2020–2022 рр. Відповідні результати наведено в табл. 8.

Таблиця 8

Прогнозовані та фактичні значення EPR за 2020–2022 роки


Рік	Прогнозований EPR	Фактичний EPR
2020	51,74886	49,868
2021	50,76049	49,266
2022	50,48414	—

Джерело: розраховано авторами.
Примітка: RMSE: 1,699; MAPE: 3,4%.

Відповідні часові траєкторії наведено на рис. 2.

Рисунок 2

Прогнозоване та фактичне співвідношення зайнятості до чисельності населення (EPR) для України



Джерело: розраховано авторами.

Примітка: True EPR (%) – істинне співвідношення зайнятості до чисельності населення; Predicted EPR (%) – прогнозоване співвідношення зайнятості до чисельності населення.

Як показано на рис. 2, модель систематично переоцінює фактичний EPR приблизно на 1,6%, причому прогнози стабільно перевищують спостережувані значення як у 2020, так і у 2021 рр.

Наступним кроком було перенавчання найефективнішої моделі на всіх доступних даних до 2022 р. та формування прогнозу для цього року. У межах цього процесу насамперед проведено аналіз важливості ознак (рис. 3).


Побудова процесу обробки даних із масштабуванням, вбудованим відбором ознак та Random Forest, із оптимізацією гіперпараметрів за допомогою GridSearchCV дає такі результати:

CV RMSE: 0,74

Модель враховувала всі ознаки на кожному розщепленні ($\text{max_features} = 1,0$), водночас відсікаючи приблизно половину з них за порогом медіанного значення важливості.

Рисунок 3

Оцінки важливості ознак у моделі Random Forest



Джерело: розраховано авторами.

Результати кодування на Python додатково свідчать, що серед розроблених макроекономічних предикторів достатній сигнал для проходження відбору ознак зберегли лише GFCF_diff та ME_diff.

Test RMSE (2020–21): 1,76

Тестування на відкладеній вибірці за 2020–2021 рр. дало тестовий RMSE на рівні 1,76, що підтверджує: після очищення даних і повторного навчання на повній 27-річній вибірці до 2020 р. модель досягла суттєвого покращення точності прогнозування. Порівняння між базовою та запропонованою моделлю наведено в табл. 9.

Таблиця 9

Порівняння тестового RMSE між базовою та запропонованою моделлю

Модель	Тестовий RMSE
Базова модель	2,639
Запропонована модель	1,761

Джерело: розраховано авторами.

Примітка: нижче значення RMSE означає кращу точність прогнозування.

Як показано в табл. 9, запропонована модель зменшує помилку прогнозу приблизно на 33% порівняно з базовою, що свідчить про її здатність відображати ключову динаміку співвідношення зайнятих до населення в Україні.

Фінальний підхід використовує два процеси (pipelines): окремі моделі Random Forest для даних до 2020 р. та після 2020 р. Спостережувані та прогнозовані значення EPR за 2017–2021 рр. наведено в табл. 10.

Таблиця 10

Спостережувані та прогнозовані значення EPR (2017–2021)

Рік	Значення EPR, яке спостережується	Прогнозоване значення EPR
2017	50,956	51,1057
2018	51,357	51,4437
2019	51,703	51,6531
2020	49,868	49,7235
2021	49,266	49,4225

Джерело: розраховано авторами.

Примітка: прогнозовані значення наведено з точністю до чотирьох знаків після коми для збереження точності виходу моделі.

Для оцінювання загальної точності прогнозування підходу з двома процесами обчислено метрики точності для всієї вибірки та окремо для періодів до і після 2020 року. Ці результати наведено в табл. 11.

Таблиця 11

Показники ефективності моделі прогнозування


Період	MAE	RMSE
Загальний	0,216	0,405
До 2020 року	0,221	0,418
Після 2020 року	0,151	0,151

Джерело: розраховано авторами.

Модель для періоду після 2020 р. демонструє нижчі показники помилки, але це слід інтерпретувати обережно, оскільки вона ґрунтується лише на двох спостереженнях, що може завищувати точність. Для прогнозів після 2021 р. Застосовано модель для періоду після 2020 р., оскільки всі майбутні роки належать до цього режиму.

Рисунок 4

Важливість ознак у моделі Random Forest



Джерело: розраховано авторами.

Примітка: EPR (Actual) – фактичне співвідношення зайнятості до чисельності населення; EPR_pred (Forecast) – прогнозоване співвідношення зайнятості до чисельності населення.

Як показано на рис. 4, прогноз EPR для 2022–2024 рр. залишається стабільним у діапазоні 49–49,5%. Щоб кількісно оцінити невизначеність навколо цих точкових прогнозів, побудовано інтервали прогнозування.

Для цього застосовуємо моделювання Монте-Карло, додаючи шум до нашого часового ряду та повторно прогнозуючи траєкторії. Для моделювання компонент шуму можна подати у такій формі:

$$\varepsilon_e = \varphi \varepsilon_{e-1} + \eta_e. \quad (13)$$

Оцінені параметри шумового процесу AR(1) наведено в табл. 12.

Таблиця 12

Оцінки параметрів моделі AR(1)

Параметр	Оцінка
Intercept (const)	-0,0244
AR(1) coefficient ($\hat{\phi}$)	0,4233
Innovation variance (σ^2)	0,0342

Джерело: розраховано авторами.

Примітка: $\hat{\phi}$ позначає оцінений коефіцієнт авторегресії першого порядку; σ^2 позначає дисперсію інноваційного члена.

Коефіцієнт AR(1) (0,4233) свідчить про помірну інерційність у залишках, а дисперсія інновацій є низькою (0,0342). Ці параметри використано у генераторі шуму на основі AR(1) у межах циклу Монте-Карло для формування інтервалів прогнозування. Базові прогнози EPR разом із 95% інтервалами прогнозування для 2020–2021 рр. наведено в табл. 13.

Таблиця 13

Базові прогнози EPR та 95% інтервали прогнозування (2020–2021)

Рік	Прогноз	2.5 % PI	97.5 % PI	Медіана (MC)
2020	51,754	51,3234	52,1027	51,7257
2021	50,8986	50,4571	51,2690	50,8720

Джерело: розраховано авторами.


Примітка: PI – інтервал прогнозування; MC – Монте-Карло.

Таким чином, прогнозований EPR для 2020 р, становить 51,75%, із 95% інтервалом у межах від 51,32% до 52,10%, а прогноз для 2021 р, становить 50,90% з інтервалом від 50,46% до 51,27%, Медіанні прогнози Монте-Карло тісно узгоджуються з базовими точковими оцінками, що підтверджує надійність процедури,

Результати візуалізовано на рис. 5, який демонструє базову траєкторію прогнозу разом із прогнозними смугами.

Рисунок 5

Базовий прогноз



Джерело: розроблено авторами.

Рис. 5 демонструє прогнозну смугу $\pm 0,4$ відсоткового пункту, що свідчить про низький рівень шуму та високу стабільність прогнозу. Навіть з урахуванням залишкових коливань очікується лише помірне зниження. Емпірична ACF тісно відповідає теоретичному спаданню AR(1), що підтверджує коректність роботи симулятора. Для кількісної оцінки цього обчислено середньоквадратичну похибку (MSE) між емпіричною та теоретичною ACF для лагів 1–20:

ACF MSE (lags 1–20): 0,0039.

MSE на рівні 0.0039 є прийнятним, але також свідчить про те, що змодельована ACF дещо відхиляється від теоретичної ϕ^k . Тому може бути потрібна стратегія вдосконалення, наприклад збільшення довжини змодельованого ряду.

ACF MSE = 1,20e-02 exceeds 1,00e-03

ACF MSE = 1,58e-02 exceeds 1,00e-03

ACF MSE = 9,55e-03 exceeds 1,00e-03

Усі три країни спершу демонстрували значення MSE, що суттєво перевищували поріг « 1×10^{-3} », що вказувало на значну наявність шуму у вибірках обмеженої довжини. За $n = 2000$ результати суттєво покращилися:

$n = 2000 \rightarrow \text{ACF MSE} = 7,85e-04 \pm 1,73e-04$.

Таким чином, MSE автокореляційної функції зменшилася нижче порогу 1×10^{-3} , що підтверджує: симулятор AR(1) тепер генерує залишки з автокореляційною структурою, яка тісно відповідає теоретичній ϕ^k .

Отримані базові прогнози EPR із 95% інтервалами прогнозування та медіанами Монте-Карло для 2020–2021 рр. наведено в табл. 14.

Таблиця 14

Базові прогнози EPR із 95% інтервалами прогнозування та медіанами Монте-Карло (2020–2021)

Рік	Базовий прогноз	Нижня межа 95 % PI	Верхня межа 95 % PI	Медіана (MC)
2020	51,754	51,3733	52,1372	51,7531
2021	50,8986	50,5047	51,2825	50,9007

Джерело: розраховано авторами.

Примітка: PI – інтервал прогнозування; MC – Монте-Карло.

Прогнозний інтервал для 2020 р. охоплює приблизно 0,76 в. п., а для 2021 р. – трохи ширший, 0,78, що свідчить: хоча вибірковий шум зменшено, певна помірна невизначеність усе-таки залишається.

Наступним кроком є проведення аналізу чутливості коефіцієнта AR(1) ϕ щодо його впливу на MSE ACF та ширину інтервалів. Для цього ϕ проаналізовано у діапазоні $\pm 10\%$ від оціненого $\hat{\phi}$, а також обчислено (i) діагностичне MSE ACF та (ii) середню ширину інтервалу для кожного року (що показує чутливість смуг невизначеності до невеликих помилок у ϕ). Результати наведено в табл. 15.

Діагностичні результати показують, що ACF MSE зростає разом зі збільшенням ϕ : вища стійкість призводить до більшого відхилення від теоретичного еталона через вибірковий шум. Ширина інтервалу прогнозування також збільшується нелінійно – підвищення ϕ на 10% більш ніж удвічі розширює середню ширину. За початкових налаштувань ($n = 500$, runs = 5) жодне значення ϕ не відповідало строгому порогу $\text{MSE} < 1 \times 10^{-3}$. Щоб вирішити цю проблему, включено невизначеність ϕ до інтервалів, здійснюючи вибірку з його розподілу та пропускаючи її через прогнози Монте-Карло. У табл. 16 узагальнено отримані значення та 95% інтервали.

Таблиця 15

Вплив коефіцієнта AR(1) на ACF MSE та ширину 95% PI

ϕ	ACF MSE	ACF MSE Std	Width 2020	Width 2021	Mean Width
0,765	0,00150	0,00071	1,16	1,18	1,17
0,8075	0,00171	0,00097	1,26	1,27	1,27
0,85	0,00204	0,00140	1,41	1,44	1,43
0,8925	0,00254	0,00202	1,62	1,65	1,64
0,935	0,00300	0,00266	2,02	2,07	2,04

Джерело: розраховано авторами.

Примітка: ϕ – коефіцієнт AR(1); ACF MSE – середньоквадратична похибка вибіркової автокореляційної функції; Width – ширина 95% інтервалу прогнозування для відповідного року.

Таблиця 16

Прогнозовані значення та 95% інтервали прогнозування

Рік	Нижня межа 95% PI	Значення	Верхня межа 95% PI	Ширина інтервалу
2020	95,89	102,27	108,57	12,68
2021	132,69	149,28	164,27	31,58

Джерело: розраховано авторами.

Примітка: PI – інтервал прогнозування; Ширина інтервалу – верхня межа 95% PI – нижня межа 95% PI.

Результати показують, що ширина прогнозного інтервалу для 2020 р. становить 108,6, із середнім значенням 102,3. У 2021 р. рівень невизначеності зростає ще на 31,6 пункту, що відображає як довший горизонт прогнозування, так і накопичену варіацію ϕ .

Порівняно з інтервалами за фіксованого ϕ (середня ширина $\approx 1,42$), ці ϕ -чутливі діапазони є суттєво ширшими, що свідчить: ризик параметра робить значно більший внесок у розсіювання прогнозу, ніж лише стохастичний шум.

Щоб зменшити обчислювальне навантаження великих симуляцій Монте-Карло для експериментів масштабу Big B \times R, оптимізовано стратегію вибірки. Оптимізаційні результати наведені нижче:

Elapsed wall-clock time: 0,121 seconds

Output shape: (200, 10000)

Mean of simulations: -0,0074

Оскільки основною метою нашого аналізу є прогнози EPR України на 2022–2024 рр., використання векторизації NumPy забезпечує суттєве прискорення з мінімальним збільшенням складності.

Очевидно, що для підвищення надійності варто застосувати масштабування та логіт-трансформацію залежної змінної:

$$z_t = \log\left(\frac{p_t}{1-p_t}\right). \quad (14)$$

Усе моделювання AR(1) та подальші симуляції Монте-Карло виконуються у цьому логіт-трансформованому просторі. Після цього прогнози перетворюються назад у відсоткові значення за допомогою оберненої трансформації:

$$\hat{p}_t = \frac{e^{z_t}}{1 + e^{z_t}} \times 100\%. \quad (15)$$

Таке коригування забезпечує перебування прогнозів у допустимому діапазоні. Після оцінювання параметрів AR(1) у логіт-просторі використано векторизовані симуляції на основі NumPy, а потім застосовано обернену трансформацію для повернення значень у вихідний простір EPR. У табл. 17 подано результати для 2022–2024 рр., демонструючи вузькі прогнозні інтервали (≈ 2 –4 пункти) та незначне зростання медіанного EPR – від 49.61% у 2022 р. до 50.08% у 2024 р. Рисунок 6 ілюструє ці динаміки, відображаючи фактичний EPR поряд із прогнозами logit-AR(1) та їхніми 95% інтервалами.

Таблиця 17


Прогнозовані значення EPR із 95% інтервалами прогнозування (2022–2024)

Рік	Нижня межа 95% PI	Медіанний EPR	Верхня межа 95% PI
2022	48,25	49,61	50,98
2023	48,07	49,88	51,66
2024	48,00	50,08	52,11

Джерело: розраховано авторами.

Рисунок 6

Прогнози logit-AR для EPR України



Джерело: розраховано авторами.

На підставі табл. 17 та рис. 6 можна спостерігати, що отримані прогнози є узгодженими та лежать у правдоподібному діапазоні. Прогнозовані значення стабілізуються навколо останнього спостереженого рівня EPR (близько 50%), що свідчить про відсутність нереалістичних відхилень. Крім того, 95% інтервали прогнозування залишаються порівняно вузькими ($\pm 1-2$ в. п.), що відображає низьку оцінену дисперсію логіт-інновацій ($\sigma = 0,027$) та стаціонарний коефіцієнт авторегресії ($\hat{\phi} = 0,77$).

Моделювання впливу військових видатків на EPR за допомогою методів машинного навчання

Тепер переходимо до методів машинного навчання, щоб кількісно оцінити, як зміни у військових видатках (МЕ) впливають на EPR у Німеччині, Чехії та Україні.

Набір даних розділено на тренувальну та тестову підвибірки:

X_{train} shape: (76, 11)

X_{test} shape: (20, 11)

Для забезпечення оцінювання на відкладених даних процедура, яку було застосовано під час навчання, відтворюється.

Xte_seq shape: (16, 4, 9)

yte_seq shape: (16,)

Реалізовано просту послідовну модель у Keras, коригуючи розміри та конфігурації шарів під час ітерацій. Архітектуру мережі LSTM узагальнено в табл. 18.

Таблиця 18

Короткий опис архітектури моделі LSTM для прогнозування EPR

Назва шару	Тип шару	Вихідна форма	Параметри
seq_input	InputLayer	(None, 4, 9)	0
lstm_6	LSTM	(None, 64)	18944
dropout_5	Dropout	(None, 64)	0
dense_9	Dense	(None, 32)	2080
forecast	Dense	(None, 1)	33
Total	—	—	21057

Джерело: розраховано авторами.

Під час навчання всі метрики приймали значення NaN з 1-ї до 10-ї епохи. Валідаційні втрати не покращувалися порівняно з початковим нескінченним значенням, що спричинило передчасну зупинку на 11-й епосі та відновлення ваг моделі зі стану 1-ї епохи.

Етап прогнозування завершується приблизно за 316 мс на батч. Таким чином, рекурентна нейронна мережа EPR_LSTM застосована для прогнозування значень EPR. Детальну архітектуру моделі узагальнено в табл. 19.

Динаміку тренувальних і валідаційних значень втрат та MAE протягом 100 епох наведено в табл. 20. Як тренувальні, так і валідаційні метрики демонструють поступове покращення, що свідчить про стабільну збіжність. Під час валідаційного вибіркового прогнозування NaN-значень не простежувалося.

Таблиця 19

Архітектура моделі **EPR_LSTM**

Назва шару	Тип	Вихідна форма	Кількість параметрів
seq_input	InputLayer	(None, 4, 9)	0
lstm_6	LSTM(64)	(None, 64)	18944
dropout_5	Dropout(0.2)	(None, 64)	0
dense_9	Dense(32)	(None, 32)	2080
forecast	Dense(1)	(None, 1)	33
Total	–	–	21057

Джерело: розраховано авторами.

Примітка: оптимізатор – Adam (швидкість навчання = $1e-5$, clipvalue = 0.5); функція втрат – Huber ($\delta = 1.0$); метрика навчання – середня абсолютна помилка (MAE).

Таблиця 20

Динаміка тренувальних і валідаційних значень втрат та MAE протягом епох

Епоха	Тренувальні втрати	Тренувальний MAE	Валідаційні втрати	Валідаційний MAE
1	0,3304	0,6821	1,0094	1,5094
...
100	0,2829	0,6312	0,9196	1,4196

Джерело: розраховано авторами.

Отримані результати такі:

- Тренувальна втрата (синя лінія) стабілізується на рівні 0,3–0,4 після фази розігріву, з незначними коливаннями.
- Валідаційна втрата (помаранчева) починається близько 1,0 і поступово знижується до приблизно 0,9 до 100-ї епохи. Така динаміка свідчить, що модель навчається (оскільки val_loss зменшується), проте стійкий розрив ($val_loss > train_loss$) вказує на недонавчання та обмежену здатність до узагальнення.

Для подолання цієї проблеми введено адаптивне зменшення швидкості навчання та побудовано глибшу стековану LSTM-модель, узагальнену в табл. 21.

Таблиця 21

Побудова моделі LSTM зі стекованими шарами

Шар	Тип	Вихідна форма	Параметри
seq_input	InputLayer	(None, 4, 9)	0
lstm_1	LSTM(64, return_sequences=True)	(None, 4, 64)	18944
lstm_2	LSTM(32)	(None, 32)	12416
dropout	Dropout(0.1)	(None, 32)	0
dense_1	Dense(32, relu)	(None, 32)	1056
forecast	Dense(1)	(None, 1)	33
Total	—	—	32449

Джерело: розраховано авторами.

Використано два LSTM-шари. Перший шар виводить усю послідовність, щоб другий шар міг уловлювати більш високорівневі часові залежності.

У результаті навчання отримано такі результати:

- під час тестування на 32 вибірках не простежувалось жодних NaN-значень;
- планувальник швидкості навчання (ReduceLROnPlateau) зменшив LR в 2–3 рази: з $1e-5 \rightarrow 5e-6 \rightarrow 2,5e-6$;
- валідаційна втрата стабільно зменшувалася від $\approx 1,00$ на початку до $\approx 0,90$ наприкінці;
- валідаційний MAE знизився приблизно від 1,50 до 1,40.

Загалом розширення архітектури до двошарової LSTM разом із застосуванням адаптивного зменшення швидкості навчання забезпечило кращу збіжність до локальних мінімумів і помірне зниження похибки порівняно з одношаровим варіантом.

Для відтворюваності зафіксовано випадкове зерно, використано оптимізатор Adam із малою швидкістю навчання ($1e-5$), кліппінг градієнта ($\text{clipvalue} = 0,5$) та функцію втрат Huber ($\delta = 1,0$). Результати узагальнено в табл. 22.

Таблиця 22

Результати після 1-ї та 100-ї епох

Метрики	Епоха 1	Епоха 100	Зміна
Training Huber loss	0,3661	0,3322	–9,3 %
Validation Huber loss	0,9557	0,9141	–4,4 %
Training MAE	0,7344	0,6979	–4,9 %
Validation MAE	1,4533	1,4116	–2,9 %

Джерело: розраховано авторами.

Результати показують, що (1) валідаційна помилка стабільно зменшилася приблизно від 0,956 до 0,914 (втрата Huber) та від приблизно 1,453 до 1,412 (MAE). Різниця між тренувальним і валідаційним MAE залишається сталою (валідаційний MAE приблизно вдвічі більший за тренувальний), що свідчить про те, що модель все ще має потенціал до узагальнення.

Щодо результатів: модель відтворює тренувальні дані ефективніше, ніж валідаційні, проте обидві криві покращуються.

Додатково застосовано тест Льюнга–Бокса для оцінювання «білизни» залишків. Результати:

$$LB_stat=49,757, p\text{-}value=1,3\times 10^{-5}$$

свідчать, що LSTM не охопила всіх часових залежностей у даних, оскільки $p\text{-}value < 0,05$. Щоб скоригувати цю ненамодельовану автокореляцію, застосовано авторегресійну модель AR(4) до залишків:

$$e_t = \phi_1 e_{t-1} + \phi_2 e_{t-2} + \phi_3 e_{t-3} + \phi_4 e_{t-4} + e_t. \quad (16)$$

$$e_t = y_t - \hat{y}_t. \quad (17)$$

На основі цієї моделі згенеровано коригувальний прогноз для кожного горизонту h :

$$\hat{e}_{t+h}. \quad (18)$$

Фінальний гібридний прогноз поєднав первинний прогноз LSTM із AR-корекцією:

$$\hat{y}_{t+h}^{(hybrid)} = \hat{y}_{t+h}^{(LSTM)} + \hat{e}_{t+h}. \quad (19)$$

Для порівняння точності та її оцінювання використано дві стандартні метрики – середню абсолютну помилку (MAE) та корінь середньоквадратичної помилки (RMSE):

$$MAE = \frac{1}{H} \sum_{h=1}^H |y_{T+h} - \hat{y}_{T+h}|. \quad (20)$$

$$RMSE = \sqrt{\frac{1}{H} \sum_{h=1}^H (y_{T+h} - \hat{y}_{T+h})^2}. \quad (21)$$

Результати цього порівняння узагальнено в табл. 23.

Таблиця 23
Порівняння чистої LSTM-моделі та гібридної LSTM+AR

Модель	MAE	RMSE	Зменшення MAE	Зменшення RMSE
Pure LSTM	4,6213	4,7346	–	–
Hybrid LSTM+AR(4)	2,0178	2,2126	56,4 %	53,2 %

Джерело: розраховано авторами.

Зменшення помилок більш ніж на 50% свідчить про те, що гібридна модель уловила часові патерни, які чиста LSTM не змогла відтворити.

Сценарний аналіз

Коли визначено, як ME_diff впливає на модель через SHAP, можна побудувати сценарії та пряме моделювання.

- 1. Визначити сценарні вектори.
- 2. Пропустити дані через модель.
- 3. Отримати результати:

Average ΔEPR at +1σ ME_diff: 0,125

Average ΔEPR at −1σ ME_diff: -0,038

Результати свідчать, що:

- сценарій +1σ для ME_diff (значне збільшення військових видатків) підвищує прогнозований EPR у середньому на 0,125%;

- сценарій -1σ (помірне скорочення видатків) знижує прогноз EPR лише на 0,038%.

Далі здійснено сегментацію за країнами, об'єднавши військові видатки та співвідношення зайнятості до чисельності населення (EPR) з ключовими макроекономічними показниками, такими як ВВП, валове нагромадження основного капіталу (GFCF) та валова додана вартість (IVA).

Після цього застосовано sklearn/XGBoost для навчання на узгодженому наборі даних $X_matched$ зі змінною $y = EPR$.

Результати узагальнено в табл. 24, де наведено інтерпретацію ΔEPR для різних країн.

Таблиця 24


Інтерпретація ΔEPR за країнами

Країна	$\Delta EPR_{+1\sigma}$	$\Delta EPR_{-1\sigma}$
Чеська Республіка	0,0400	0,0034
Німеччина	0,0441	-0,0489
Україна	0,2947	-0,0636

Джерело: розраховано авторами.

Рисунок 7

Результати сценарного аналізу



Джерело: розраховано авторами.

Як зображено на рис. 7, сценарний аналіз демонструє неоднорідні ефекти змін у країнах у військових видатках на EPR.

- У Чеській Республіці збільшення оборонних видатків на $+1\sigma$ додає в середньому лише $+0,04\%$ до EPR, а зменшення на -1σ практично не впливає ($+0,003\%$).
- У Німеччині вплив більш симетричний: $+1\sigma$ збільшує EPR на $+0,044\%$, водночас -1σ знижує його приблизно на $-0,049\%$.
- Найсильніший ефект простежується в Україні: $+1\sigma$ приводить до суттєвого зростання на $+0,295\%$, а -1σ відповідає зниженню на $-0,064\%$.

Висновки

Отримані результати свідчать, що зміни у військових видатках є важливим чинником структурних зрушень на ринку праці, що проявляється через асиметричний вплив на співвідношення зайнятих до чисельності населення (EPR). В Україні збільшення ME_diff на $+1\sigma$ супроводжується зростанням EPR на $0,295\%$, а його зменшення на -1σ призводить до скорочення EPR лише на $0,064\%$. Така виражена асиметрія вказує на підвищену чутливість структури зайнятості до позитивних безпекових і фінансових шоків. Водночас Чеська Республіка та Німеччина демонструють значно менші та більш симетричні реакції ринку праці ($\pm 0,04\%$ у Чеській Республіці; $+0,044\%$ проти $-0,049\%$ у Німеччині), що відповідає стабільнішій структурі зайнятості в розвинених економіках.

Оцінки оборонних мультиплікаторів додатково підтверджують структурні відмінності між країнами. Для України «оборонний мультиплікатор» становить приблизно 29 робочих місць на кожен мільйон доларів США додаткових військових видатків (або близько 46 400 робочих місць на кожне зростання EPR на 1%), тоді як для Чеської Республіки та Німеччини цей показник не перевищує 5 робочих місць на мільйон доларів США. Отримані значення суттєво перевищують більшість традиційних макроекономічних оцінок: за даними Світового банку, еластичності зайнятості за оборонними видатками зазвичай перебувають у межах $0,1\text{--}0,2\%$ на кожне зростання витрат на 1% ВВП, а оцінки МВФ для розвинених економік коливаються на рівні $0,05\text{--}0,1\%$. Виявлений ефект для України ($0,295\%$ при $+1\sigma$ ME_diff, що в окремі періоди відповідає приблизно $0,5\%$ ВВП) суттєво перевищує ці орієнтири, що підкреслює трансформаційний характер та високу структурну чутливість її ринку праці до військово-бюджетних шоків.

Результати можуть бути корисними для Міністерства фінансів та Міністерства оборони, пропонуючи каліброване збільшення військових бюджетів на $+0,5\sigma$ до $+1\sigma$ від історичної волатильності для максимізації доходів на ринку праці без запуску ефекту спадної віддачі. Для України це означає близько 30 робочих місць на кожен додатковий мільйон доларів оборонних витрат, що значно перевищує віддачу від інфраструктурних або освітніх проєктів.

Ринок праці України характеризується значно вищою чутливістю до зростання військових видатків порівняно з їх скороченням, що відображає специфіку його трансформаційного стану. Виявлені порогові ефекти на рівні $\pm 0,25\sigma$ вказують на те, що навіть помірні бюджетні коригування можуть генерувати економічно значущі прирости зайнятості. Водночас міжкраїнні відмінності в оцінених мультиплікаторах підкреслюють необхідність диференційованих підходів до формування оборонно-бюджетної політики: для України найбільш ефективними є масштабні оборонні інвестиції як інструмент структурної перебудови ринку праці, а для Чеської Республіки та Німеччини доцільним є поєднання помірного зростання військових видатків із додатковими регіональними та секторальними програмами зайнятості.

Список використаної літератури

- Ставицький, А., Харламова, Г., & Шпирко, В. (2023). Фінансування оборонних витрат України: нова геополітична парадигма чи збереження сталих тенденцій? *Вісник Київського національного університету імені Тараса Шевченка. Економіка*, 1(1), 126–140. <https://doi.org/10.17721/1728-2667.2023/222-1/16>
- Adjemian, S., Bogan, N., Darracq Pariès, M., Müller, G., & Zimic, S. (2024). *ECB-(RE)BASE: Heterogeneity in expectation formation and macroeconomic dynamics* (ECB Working Paper No. 2024/2965). SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.4912627>
- Azam, M., & Feng, Y. (2017). Does military expenditure increase external debt? Evidence from Asia. *Defence and Peace Economics*, 28(5), 550–567. <https://doi.org/10.1080/10242694.2015.1072371>
- Azam, M., Khan, F., Zaman, K., & Rasli, A. Md. (2016). Military expenditures and unemployment nexus for selected South Asian countries. *Social Indicators Research*, 127(3), 1103–1117. <https://doi.org/10.1007/s11205-015-0993-7>
- Basu, A., & Jha, R. (2024). ERP adoption prediction using machine learning techniques and ERP selection among SMEs. *International Journal of Business Performance Management*, 25(2), 242–270. <https://doi.org/10.1504/IJBPM.2024.137005>

- Bokan, N., Jacquinot, P., Lalik, M., Müller, G., Priftis, R., & Rigato, R. (2025). Macroeconomic impacts of higher defence spending: A model-based assessment. *ECB Economic Bulletin*, (6). https://www.ecb.europa.eu/press/economic-bulletin/articles/2025/html/ecb.ebart202506_01~d41c118e13.en.html
- Dunne, J. P., & Tian, N. (2013). Military expenditure and economic growth: A survey. *The Economics of Peace and Security Journal*, 8(1), 5–11. <https://doi.org/10.15355/epsj.8.1.5>
- Dunne, J. P., & Tian, N. (2016). Military expenditure, economic growth and heterogeneity. In C. Kollias & H. E. Ali (Eds.), *Defense spending, natural resources, and conflict* (1st ed.). Routledge. <https://doi.org/10.4324/9781315678511>
- Dunne, J. P., Perlo-Freeman, S., & Soydan, A. (2004). Military expenditure and debt in small industrialised economies: A panel analysis. *Defence and Peace Economics*, 15(2), 125–132. <https://doi.org/10.1080/1024269032000110504>
- Elshafei, A. S. M. A., Shrahili, M., Kayid, M., & Mohammad, S. (2025). Military expenditure and economic growth in the largest military spending country: Using machine learning analysis. *Journal of Radiation Research and Applied Sciences*, 18(2), Article 101429. <https://doi.org/10.1016/j.jrras.2025.101429>
- Frankfurter Allgemeine. (2025, February 25). *Merz will offenbar 200 Milliarden Euro für Aufrüstung* [Merz apparently wants to spend 200 billion euros on rearmament]. <https://www.faz.net/aktuell/wirtschaft/bundeswehr-soll-potenziell-mit-200-milliarden-sondervermoegen-gestaerkt-werden-110319262.html>
- García-Peñalvo, F. J., Cruz-Benito, J., Martín-González, M., Vázquez-Ingelmo, A., Sánchez-Prieto, J. C., & Theron, R. (2018). Proposing a machine learning approach to analyze and predict employment and its factors. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(2), 39–45. https://drupal.ijimai.org/journal/sites/default/files/journals/IJIMAI20185_2.pdf
- Gebauer, M., & von Hammerstein, K. (2023, January 17). The bad news Bundeswehr: An examination of the truly dire state of Germany's military. *Spiegel International*. <https://www.spiegel.de/international/germany/the-bad-news-bundeswehr-an-examination-of-the-truly-dire-state-of-germany-s-military-a-df92eaaf-e3f9-464d-99a3-ef0c27dcc797>
- Holcner, V., Davidová, M., Neubauer, J., Kubínyi, L., & Flachbart, A. (2021). Military recruitment and Czech labour market. *Prague Economic Papers*, 30(4), 489–505. <https://doi.org/10.18267/j.pep.778>
- Knaus, M. C., Lechner, M., & Strittmatter, A. (2022). Heterogeneous employment effects of job search programs: A machine learning approach. *Journal of Human Resources*, 57(2), 597–636. <https://doi.org/10.3368/jhr.57.2.0718-9615R1>

- Kolinets, L., & Dluhopolskyi, O. (2024, May 16-17). Military spending and economic growth: Is there an interdependence? Case of developed countries. In *New trends in contemporary economics, business and management: Selected proceedings of the 14th International Scientific Conference «Business and Management 2024»* (pp. 80–87). Vilnius Gediminas Technical University, Vilnius, Lithuania. <https://doi.org/10.3846/bm.2024.1261>
- Liang, X., Tian, D. N., Lopes da Silva, D., Scarazzato, L., Karim, Z. A., & Guiberteau Ricard, J. (2025, April). *Trends in world military expenditure, 2024*. SIPRI Publications. <https://doi.org/10.55163/AVEC8366>
- Löfflmann, G., & Riemann, M. (2025). «If I could turn back time»: Temporal security narratives, ontological disruption, and Germany's Zeitenwende. *European Journal of International Security*, 1–19. <https://doi.org/10.1017/eis.2025.10008>
- Lundgreens Investor Insights. (2025, August 15). *Defence sector: A bright spot in Germany's economy*. <https://www.lundgreensinvestorinsights.com/defence-sector-a-bright-spot-in-germanys-economy/>
- Nabers, D., & Stengel, F. A. (2025). Crisis and change in post-Zeitenwende German security policy. *Politische Vierteljahresschrift*, 66(1), 19–44. <https://doi.org/10.1007/s11615-024-00584-5>
- Özşahin, Ş., & Üçler, G. (2021). The relationship between defense expenditures and employment in NATO member states: Bootstrap panel causality test. *Istanbul Journal of Economics*, 71(1), 231–249. <https://dergipark.org.tr/en/pub/istjecon/issue/64179/972521>
- Raifu, I. A., & Aminu, A. (2023). The effect of military spending on economic growth in MENA: Evidence from method of moments quantile regression. *Future Business Journal*, 9(1), Article 7. <https://doi.org/10.1186/s43093-023-00181-9>
- Reuters. (2025, March 5). *Czech Republic to lift defence spending to 3% of GDP by 2030, PM says*. <https://www.reuters.com/world/czech-government-gradually-lift-defence-spending-3gdp-by-2030-pm-says-2025-03-05/>
- Sağın, A., & Kocaarslan, B. (2023). Military spending and employment in eastern European countries: New evidence from panel data analysis. *Istanbul University Journal of Sociology*, 43(2), 259–274. <https://doi.org/10.26650/SJ.2023.43.2.0043-1>
- Simpertl, J. (2024). *Military expenditure and economic growth: A meta-analysis* (Working Paper No. 8/2024). Charles University, Institute of Economic Studies (IES). <https://www.econstor.eu/bitstream/10419/300142/1/1885028733.pdf>
- Šlouf, V., Blaha, M., Pekař, O., Brizgalová, L., & Müllner, V. (2023). An alternative model for determining the rational amount of funds allocated to defence of the Czech Republic in conditions of expected risk. *Obrana a Strategie*,

- 23(1), 149–172. <https://www.obranaastrategie.cz/en/archive/volume-2023/1-2023/articles/an-alternative-model-for-determining-the-rational-amount-of-funds-allocated-to-defence-of-the-cr.html>
- Sokhatskyi, O., Dluhopolskyi, O., Movchan, R., & Taranukha, O. (2020). Military expenditures and world economic growth under hybrid warfare conditions. *International Journal of Industrial Engineering & Production Research*, 31(4), 511–522. <https://doi.org/10.22068/ijiepr.31.4.511>
- Stamegna, M., Bonaiuti, C., Maranzano, P., & Pianta, M. (2024). The economic impact of arms spending in Germany, Italy, and Spain. *Peace Economics, Peace Science and Public Policy*, 30(4), 393–422. <https://doi.org/10.1515/peps-2024-0019>
- Stengel, F. A. (2025). German «pacifism» and the Zeitenwende [Accepted for publication]. *Defense & Security Analysis*. <https://doi.org/10.2139/ssrn.5164607>
- Wei, Y., Rao, X., Fu, Y., Song, L., Chen, H., & Li, J. (2023). Machine learning prediction model based on enhanced bat algorithm and support vector machine for slow employment prediction. *PLoS ONE*, 18(11), Article e0294114. <https://doi.org/10.1371/journal.pone.0294114>
- Zachová, A. (2025, January 7). *Czechia reaches 2% GDP defence spending target for first time in 20 years*. Euractiv. <https://www.euractiv.com/news/czechia-reaches-2-gdp-defence-spending-target-for-first-time-in-20-years/>
- Zatonatska, T., Artiushenko, O., Liashenko, O., Syzov, A., Dyachenko, S., & Horiacheva, K. (2025). Leveraging artificial intelligence in public procurement of dual-use goods (pp. 407–412). In *2025 15th International Conference on Advanced Computer Information Technologies (ACIT)*, Šibenik, Croatia. IEEE. <https://doi.org/10.1109/ACIT65614.2025.11185737>
- Zhong, M., Chang, T., Tang, D. P., & Wolde-Rufael, Y. (2015). The causal nexus between military spending and unemployment in the G7: A bootstrap panel causality test. *Defence and Peace Economics*, 26(6), 609–622. <https://doi.org/10.1080/10242694.2014.994835>

Отримано: 4 листопада 2025 р.

Рецензовано: 21 листопада 2025 р.

Рекомендовано до друку: 15 грудня 2025 р.