

УДК 004.8

DOI <https://doi.org/10.32782/tnv-tech.2024.6.6>

АНСАМБЛЕВЕ НАВЧАННЯ КЛАСИФІКАТОРІВ ДЛЯ ОНЛАЙН ВІЯВЛЕННЯ ДЕЗІНФОРМАЦІЇ

Лендюк Д. Т. – аспірант кафедри інформаційно-обчислювальних систем і управління Західноукраїнського національного університету
ORCID ID: 0009-0004-2728-7889
Scopus-Author ID: 57208671953

Ліп'яніна-Гончаренко Х. В. – доцент кафедри інформаційно-обчислювальних систем і управління Західноукраїнського національного університету
ORCID ID: 0000-0002-2441-6292
Scopus-Author ID: 59250857600

У сучасному цифровому світі, де інформація розповсюджується з неймовірною швидкістю, виявлення фейкових новин та дезінформації стає критично важливим завданням. В контексті українськомовного інформаційного простору, це завдання набуває додаткової актуальності через гібридну війну з росією. Відповідно до цього, в нашому дослідженні було розроблено та впроваджено метод "Online Learning with Sliding Windows for Text Classifier Ensembles" (OLTW-TEC), спрямований на ефективне виявлення дезінформації в українськомовних текстових даних. Метою є підвищення точності та адаптивності в ідентифікації фейкових новин, зокрема в українськомовному інформаційному просторі. Ця робота акцентує увагу на необхідності забезпечення швидкої та адаптованої до змін системи у відповідь на стрімкі зміни в інформаційному потоці. Метод OLTW-TEC використовує передові техніки машинного навчання та аналізу даних для створення адаптивної системи класифікації, яка може динамічно реагувати на зміни в інформаційному потоці. Центральним елементом методу є інтеграція ансамблю класифікаторів з методом ковзних вікон, що дає можливість постійно оновлювати модель на основі останніх даних, забезпечуючи високу точність і адаптивність до нових форм дезінформації. Метод включає етапи збору та попередньої обробки даних, аналізу тональності, емоції та векторизації тексту, що дає змогу глибше аналізувати та ефективніше виявляти фейкові новини, спираючись на унікальні лінгвістичні та культурні особливості української мови. Для аналізу ефективності OLTW-TEC було використано унікальний датасет українськомовних новин, що включає як достовірні, так і неправдиві новини. Результати дослідження продемонстрували високу ефективність методу ідентифікації дезінформації, з точністю класифікації, що сягає 93,26%. Аналіз матриці помилок та інших метрик, таких як оцінка F1, підкреслив збалансованість та надійність OLTW-TEC у виявленні фейкових новин. У порівнянні з традиційними методами класифікації, OLTW-TEC не лише показує кращі результати за більшістю метрик, але й забезпечує простір для адаптації до змін у характері даних. Вибір розміру "ковзного вікна" та можливість його регулювання залежно від специфіки даних надає методу додаткову гнучкість і точність.

Ключові слова: дезінформація, фейкові новини, онлайн навчання, ансамблі класифікаторів.

Lendiuk D. T., Lipianina-Honcharenko Kh. V. Online learning with sliding windows for text classifier ensembles

In today's digital world, where information spreads at an incredible speed, detecting fake news and disinformation is becoming a critically important task. In the context of the Ukrainian-language information space, this task becomes even more relevant due to the hybrid war with Russia. Accordingly, in our study, the "Online Learning with Sliding Windows for Text Classifier Ensembles" (OLTW-TEC) method was developed and implemented, aimed at effectively detecting disinformation in Ukrainian-language text data. The goal is to increase the accuracy and adaptability in identifying fake news, particularly in the Ukrainian-language information space. This work focuses on the need to provide a fast and adaptable system in response to rapid changes in the information flow. The OLTW-TEC method uses advanced machine learning and data analysis techniques to create an adaptive classification system that can dynamically respond

to changes in the information flow. The central element of the method is the integration of an ensemble of classifiers with the sliding window method, which makes it possible to constantly update the model based on the latest data, ensuring high accuracy and adaptability to new forms of disinformation. The method includes the stages of data collection and pre-processing, analysis of tonality, emotions and text vectorization, which allows for deeper analysis and more effective detection of fake news, relying on the unique linguistic and cultural features of the Ukrainian language. To analyze the effectiveness of OLTW-TEC, a unique dataset of Ukrainian-language news was used, which includes both reliable and false news. The results of the study demonstrated the high effectiveness of the method for identifying disinformation, with a classification accuracy of 93.26%. Analysis of the error matrix and other metrics, such as the F1 score, highlighted the balance and reliability of OLTW-TEC in detecting fake news. Compared to traditional classification methods, OLTW-TEC not only shows better results on most metrics, but also provides room for adaptation to changes in the nature of the data. The choice of the "sliding window" size and the ability to adjust it depending on the specifics of the data gives the method additional flexibility and accuracy.

Key words: *disinformation, fake news, online learning, ensembles of classifiers.*

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями. У період російсько-української війни, значення виявлення фейкових новин набуває особливої актуальності, оскільки дезінформація може мати серйозні наслідки. Дослідження [1] та [2] підкреслюють, як соціальні медіа, зокрема Twitter та Weibo, відіграють ключову роль у формуванні громадської думки під час конфлікту. Аналіз показує, що на початку війни спостерігався значний сплеск активності, який згодом знизився, але продовжував залучати увагу до України як жертви агресії. Важливість розрізнення між реальними та фейковими новинами стає ще більш важливою, враховуючи, що соціальні медіа часто використовуються як основне джерело інформації. Таким чином, зростає потреба у розробці ефективних методів виявлення та аналізу фейкових новин, щоб забезпечити достовірність інформації, і безпеці. В цьому контексті, розробка ефективних методів для виявлення дезінформації є критично важливою. Дане дослідження пропонує інноваційний підхід, який використовує переваги ансамблів класифікаторів у поєднанні з методами онлайн навчання. Цей підхід дає змогу не тільки точно ідентифікувати фейкові новини, але й адаптуватися до постійно змінюваного інформаційного середовища, забезпечуючи актуальність та ефективність виявлення дезінформації в реальному часі.

В цьому дослідженні представлена розробка та аналіз новаторського методу Online Learning with Sliding Windows for Text Classifier Ensembles (OLTW-TEC), що об'єднує переваги адаптивного онлайн навчання з динамічним ковзним вікном для ансамблів класифікаторів тексту. Метою є підвищення точності та адаптивності в ідентифікації фейкових новин, зокрема в українськомовному інформаційному просторі. Ця робота акцентує увагу на важливості розробки інструментів, здатних адекватно працювати з унікальними лінгвістичними та культурними особливостями конкретних мовних груп, а також на необхідності забезпечення швидкої та адаптованої до змін системи у відповідь на стрімкі зміни в інформаційному потоці.

Аналіз досліджень та публікацій. Автори роботи [3] досліджують зв'язок між фейковими новинами та інноваціями, орієнтованими на сталість, вказуючи на необхідність розробки цілісної концептуальної рамки для розуміння цього взаємозв'язку. Автори визначають ключові теоретичні та практичні наслідки, а також пропонують напрямки майбутніх досліджень у цій галузі.

У дослідженнях [4] та [5] проводять оглядові дослідження, аналізуючи різні підходи до виявлення фейкових новин. У [4] зосереджуються на викликах, пов'язаних з наборами даних, представленням ознак та інтеграцією даних, тоді як в [5]

розглядають атрибути, особливості та методи виявлення фейкових новин у соціальних мережах, включаючи лінгвістичний та семантичний аналіз.

У дослідженнях [6] та [7] увага акцентується на використанні глибокого навчання та графових нейронних мереж для виявлення фейкових новин. Ну та співавтори розглядають різні підходи глибокого навчання, включаючи кероване, слабokerоване та некероване навчання, та аналізують їх ефективність на основі різних наборів даних. Phan та співавтори зосереджуються на використанні графових нейронних мереж, вказуючи на їх потенціал та виклики, пов'язані зі стандартизацією даних та розробкою спеціалізованого апаратного забезпечення.

Дослідження [8] висвітлює важливість багатоконтекстуального навчання у дослідженні дезінформації, враховуючи різні контексти, такі як зміст, емоції, користувачі та інші. Автори пропонують всебічний погляд на цю проблему, включаючи виклики, пов'язані з багатомодальністю контенту та недостатністю мічених даних. Автори [9] також підкреслюють необхідність інтердисциплінарного підходу, включаючи аналіз мереж та мови, для розуміння динаміки поширення фейкових новин та їх впливу.

У роботі [10] досліджується, як люди висловлюють свої почуття на Twitter під час конфлікту між Росією та Україною. Дослідження має дві цілі: збір унікальних даних та використання машинного навчання (ML) для класифікації твітів залежно від їх впливу на почуття людей. Перша ціль полягала у виявленні найбільш релевантних хештегів, пов'язаних з конфліктом, для знаходження датасету. Друга ціль – використання декількох відомих моделей ML для групування твітів. Експериментальні результати показали, що більшість класифікаторів ML мають вищу точність на збалансованому наборі даних. Однак результати експериментів з використанням стратегій балансування даних не обов'язково вказують на те, що всі класи будуть працювати краще. Тому важливо підкреслити важливість порівняння та контрастування стратегій балансування даних, використаних у дослідженнях SA та ML, включаючи більше класифікаторів та ширший спектр випадків використання.

У роботі [11] автори розробили новий метод виявлення фейкових новин, який враховує контекстуальну семантичну репрезентацію для аналізу багатомодальних даних у соціальних мережах. Цей метод, названий CSFND (Contextual Semantic representation learning for multimodal Fake News Detection), включає некерований етап навчання контексту для отримання локальних контекстуальних ознак новин, які потім поєднуються з глобальними семантичними ознаками для навчання контекстуальної семантичної репрезентації новин. Експерименти на двох реальних багатомодальних наборах даних показали, що CSFND значно перевершує десять сучасних методів виявлення фейкових новин, покращуючи середню точність на 2,5% порівняно з найкращими базовими методами.

У дослідженні [12] автори розробили нову модель для виявлення фейкових новин на соціальних мережах, засновану на квантовому багатомодальному злитті (QMFND). Модель QMFND інтегрує вилучені зображення та текстові ознаки, які проходять через запропоновану квантову згорткову нейронну мережу (QCNN), щоб отримати дискримінативні результати. Перевірка QMFND на двох наборах даних соціальних медіа, Gossip та Politifact, показала, що її продуктивність дорівнює або навіть перевищує продуктивність класичних моделей. Крім того, було досліджено вплив різних параметрів. QCNN виявилася не тільки високовиразною та здатною до заплутування, але й стійкою до квантового шуму.

У роботі [13] розглядається проблема виявлення фейкових новин на соціальних мережах. Автори пропонують новий підхід, який враховує схожість думок

користувачів, аналізуючи їхні позиції щодо новинних статей та взаємодії в постах. Використовуючи мережу графових трансформерів, метод одночасно вилучає глобальну структурну інформацію та взаємодії схожих позицій. Метод був оцінений на спеціально зібраних даних з Twitter та на датасеті FibVID, демонструючи значне покращення у порівнянні з традиційними методами, включаючи найсучасніші методи.

У дослідженні [14] розглядається проблема виявлення фейкових новин у мультимодальних даних. Автори вказують на виклики, пов'язані у спільному аналізі внутрішньомодальних та міжмодальних кореляцій між зображеннями та текстами, а також на необхідність більш глибокого аналізу ієрархічної семантики тексту. Для вирішення цих проблем пропонується мультимодальна мережа з урахуванням взаємозв'язків (MRAN) [[Multi-scale Residual Attention Network (MRAN) – Мультимасштабна мережа залишкової уваги (MRAN)]], яка включає в себе кілька етапів обробки. Спочатку використовується багаторівнева мережа кодування для вилучення семантичних особливостей тексту, а також VGG19 для вилучення візуальних характеристик. Потім використовується мережа залишкової уваги, яка обчислює схожість між сегментами інформації в межах модальностей та між модальностями. Нарешті, отримані характеристики передаються в детектор фейкових новин. Експерименти на трьох датасетах показали ефективність MRAN, підкреслюючи його сильну продуктивність у виявленні фейкових новин.

Робота [15] пропонує гібридний підхід, який поєднує слабкероване навчання та глибоке навчання для виявлення фейкових новин у соціальних мережах. Дослідження зосереджується на використанні методів машинного навчання, таких як SVM, для анотації великих обсягів нерозмічених даних, а також на застосуванні глибоких навчальних технік, таких як Bi-LSTM та Bi-GRU, для класифікації фейкових новин. Автори використовують TF-IDF та Count Vectorizer для вилучення ознак з текстових даних. Експериментальні результати показують, що запропонований підхід досягає високої точності у виявленні фейкових новин, що робить його ефективним інструментом у боротьбі з дезінформацією в інтернеті.

Дослідження [16] вводить концепцію «воротарів» у соціальних мережах для виявлення фейкових новин. Воротарі – це активні користувачі, які беруть участь у поширенні новин. Дослідження пропонує модель поведінки воротарів на основі рекурентної нейронної мережі (RNN), що включає навчання моделі та виявлення фейкових новин. Метод здатний виявляти фейкові новини в реальному часі, використовуючи дані з Twitter та Weibo. Експериментальні результати показують, що одиниця повторюваного воротаря (GRU) досягає найкращого загального результату. Запропонований метод перевершує декілька сучасних підходів, демонструючи ефективність у ранніх та середніх стадіях поширення новин.

У роботі [17] розглядається задача автоматизації виявлення фейкових новин та перевірки фактів для західнослов'янських мов, зокрема для чеської, польської та словацької. Автори представляють набори даних для цих мов та проводять початкові експерименти, які встановлюють базовий рівень для подальших досліджень у цій галузі. Вони використовують 10-кратну крос-валідацію для оцінки як збалансованих, так і незбалансованих наборів даних, а також проводять бінарні експерименти лише з класами «ПРАВДА» та «НЕПРАВДА». В якості вхідних даних для класифікатора використовуються текст твердження або текст твердження, доповнений текстом обґрунтування.

У дослідженні [18] досліджується ефективність використання методу зворотного перекладу (Back Translation, BT) з використанням трансформерних моделей для покращення виявлення фейкових новин румунською мовою. Дослідження

базується на даних з Factual.ro, де моделі з ВТ показали кращі результати за точністю, прецизійністю, відгуком, оцінкою F1 та AUC порівняно з моделями, навченими на оригінальному наборі даних. Використання mBART для ВТ з французькою як цільовою мовою покращило продуктивність моделі порівняно з Google Translate. Найкраще серед тестованих моделей показали себе Класифікатор Екстра Дерев та Класифікатор Випадкових Лісів. Результати свідчать про потенціал використання ВТ з трансформерними моделями, такими як mBART, для підвищення ефективності виявлення фейкових новин.

У роботі [19] досліджується проблема визначення достовірності інформації, особливо в контексті соціальних заворушень та важливих подій, таких як вибори президента США та вторгнення Росії в Україну. Автори розглядають ефективність використання нейронних мереж для виявлення фейкових новин. Для підвищення точності класифікації було створено алгоритм попередньої обробки даних на основі основних принципів обробки природної мови. В результаті дослідження були виявлені мовні шаблони фейкових новин, які стали основою для попередньої обробки даних. Описано особливості конволюційних та рекурентних нейронних мереж та їх модифікації для аналізу текстових даних. Для порівняння певних моделей було обрано набір показників, що характеризують ефективність алгоритмів. Точність класифікації цих моделей була перевірена на даних, пов'язаних з виборами президента США та масштабним вторгненням російської федерації на територію України.

На основі аналізу сучасних досліджень у галузі виявлення дезінформації, можна зробити висновок, що існуючі підходи значною мірою концентруються на англійській та китайській мовах, і не надають достатнього рівня уваги українській мові. Це вказує на відсутність спеціалізованих наборів даних та моделей, які були б адаптовані до особливостей української мови. У зв'язку з цим, розроблено підхід "Online Learning with Sliding Windows for Text Classifier Ensembles" (OLTW-TEC), який спрямований на створення комплексного методу для виявлення дезінформації в українськомовному контенті. Метод включає етапи збору та попередньої обробки даних, аналізу тональності, емоцій та векторизації тексту, що дає змогу глибше аналізувати та ефективніше виявляти фейкові новини, спираючись на унікальні лінгвістичні та культурні особливості української мови.

Метою роботи є підвищення точності та адаптивності в ідентифікації фейкових новин, зокрема в українськомовному інформаційному просторі.

Для досягнення мети необхідно виконати такі задачі:

- Проаналізувати існуючий стан справ у визначенні фейкової інформації;
- Оцінити ефективність методу OLTW-TEC;
- Проаналізувати надійність OLTW-TEC як інструменту для фільтрації інформації за допомогою матриці помилок;
- Експериментально вибрати розмір «ковзного вікна», щоб надати методу додаткову гнучкість і точність.

Виклад основного матеріалу. Представимо вдосконалення ансамблю [20] адаптивних предикторів багатовимірних нестационарних послідовностей та його онлайн навчання, спрямоване на підвищення ефективності в контексті класифікації тексту. Це досягається шляхом інтеграції передових методів обробки природної мови та адаптивних алгоритмів навчання. Зокрема, використовуються векторні характеристики текстових документів, які оптимально обрані для відповідної задачі, які служать входними даними для ансамблю моделей класифікації. Оптимізація ваг цих моделей в ансамблі виконується за допомогою алгоритму

Adam. Важливим аспектом вдосконалення є впровадження методу "ковзного вікна", який забезпечує адаптивність предикторів до змін у даних. Такий підхід дає змогу забезпечити високу точність та адаптивність моделей у динамічних умовах онлайн навчання.

Введемо у розгляд ансамбль моделей для класифікації тексту $MP_1, \dots, MP_j, \dots, MP_h$, кожна з яких обробляє векторні характеристики текстового документу, отримані за допомогою моделі векторизації. Ці характеристики представляються як $x(\tau) = (x_1(\tau), \dots, x_j(\tau))^T$ для $\tau = 1, 2, \dots, T$. Оцінка, що з'являється на виході кожного з членів ансамблю, буде позначатися як $\hat{x}_j(\tau)$ для $j = 1, 2, \dots, h$, де кожна $\hat{x}_j(\tau)$ відображає оцінку класу для відповідного документу. У якості членів ансамблю можуть використовуватися як традиційні моделі класифікації тексту, такі як логістична регресія або SVM, так і складніші нейронні мережі, включаючи рекурентні мережі та глибокі навчальні структури на кшталт LSTM або трансформерів.

Оцінки $\hat{x}_j(\tau)$ від кожної моделі ансамблю надходять на вхід метамоделі, яка формує об'єднаний прогноз класифікації тексту. Прогноз метамоделі представляється у вигляді

$$x^*(\tau) = \sum_{j=1}^h c_j \hat{x}_j(\tau) = \hat{x}(\tau)c,$$

де $(c_1, \dots, c_j, \dots, c_h)^T$ є вектором ваг, що визначає внесок кожної окремої моделі в ансамблі.

Матриця $\hat{x}(\tau) = (\hat{x}_1(\tau), \dots, \hat{x}_j(\tau), \dots, \hat{x}_h(\tau))$ сформована з оцінок класів, які генеруються кожною моделлю. Параметри метамоделі задовольняють умові незміщеності:

$$\sum_{j=1}^h c_j = c^T E_h = 1,$$

де E_h – вектор, утворений одиницями. Ваги c підлаштовуються таким чином, щоб оптимізувати загальну точність класифікації метамоделі.

Для визначення оптимальних параметрів метамоделі (вектор ваг c), застосовується оптимізаційний алгоритм Adam, альтернатива традиційним методам, таким як невизначені множники Лагранжа. Функція втрат $L(c)$, що мінімізується, визначається як сума квадратів різниці між істинними класами і прогнозами метамоделі:

$$L(c) = \sum_{\tau=1}^T \|x(\tau) - \hat{x}(\tau)c\|^2,$$

де $x(\tau)$ представляє істинні мітки класів. Мінімізація функції втрат c за допомогою Adam ефективно налаштовує ваги c , що забезпечує оптимальне об'єднання прогнозів від різних моделей ансамблю для досягнення високої точності класифікації.

У випадку змінних у часі або нестационарних текстових даних, ефективність метамоделі може бути підвищена за допомогою методу "ковзного вікна". Цей метод передбачає оновлення параметрів метамоделі, використовуючи лише останні s спостережень (текстових документів) від $x(T-s+1)$ до $x(T)$. Коли надходить нове спостереження $x(T+1)$, найстаріше спостереження у «вікні» видаляється, і оцінка проводиться на основі даних від $x(T-s+2)$ до $x(T+1)$. Такий підхід дає змогу метамоделі бути більш адаптивною до змін у патернах даних та підвищує її здатність до прогнозування на основі актуальної інформації, особливо в ситуаціях, коли текстові дані відзначаються високою динамічністю або нестационарністю.

Вибір оптимального розміру «ковзного вікна» s є важливим для досягнення найвищої точності класифікації в ансамблі метамodelей. Цей вибір часто

базується на емпіричних міркуваннях, оскільки апріорні знання про природу змін у текстових даних можуть бути обмеженими. У сценаріях, де різні розміри «ковзного вікна» можуть бути оптимальними для різних типів текстових даних, ефективним підходом є створення набору метамоделей, кожна з яких побудована для певного розміру вікна.

Для визначення найкращої метамоделі може бути застосована метамодель другого рівня, яка оцінює та обирає найбільш ефективну метамодель на основі її продуктивності на всій навчальній вибірці. Такий підхід дає можливість динамічно адаптуватися до змін у текстових даних та вибирати найкращий метод класифікації залежно від конкретного контексту.

Далі представлено розроблений комплексний метод для виявлення дезінформації, від збору та попередньої обробки даних до аналізу тональності, емоцій та векторизації тексту. Метод включає в себе застосування передових технік машинного навчання та нейронних мереж, забезпечуючи глибокий аналіз текстових даних та ефективне виявлення фейкових новин. На рис. 1 представлено структуру запропонованого методу у вигляді сукупності наступних кроків:

Крок 1. Збір даних (блок 1). Збір даних є критично важливим етапом в процесі розробки методу для виявлення дезінформації. Правильно зібрані та структуровані дані дають можливість ефективно тренувати моделі машинного навчання та проводити аналітику. Розглянемо детальніший опис цього кроку:

1.1. Збір текстових даних.

1.1.1. Визначення джерел. Визначення джерел для збору даних є важливим завданням. Джерела можуть включати новинні портали, соціальні мережі, блоги, форуми та інші платформи, де користувачі можуть публікувати або ділитися інформацією.

1.1.2. Автоматизація збору даних [18]. Розробка скриптів або використання існуючих інструментів для автоматичного збору даних може включати веб-скрапінг, API запити до соціальних мереж тощо.

1.1.3. Фільтрація та валідація. Процес фільтрації та валідації даних для забезпечення їх якості та відповідності вимогам дослідження.

1.2. Збір метаданих.

1.2.1. Інформація про авторів. Збір даних про авторів текстів може включати інформацію про їхні профілі, історію публікацій, кількість підписників та інші соціальні показники, які можуть бути корисними для аналізу.

1.2.2. Інформація про джерела. Збір інформації про джерела текстів, таких як URL, дата публікації, кількість переглядів, лайків, коментарів та інші показники, які можуть бути важливими для аналізу контексту та популярності публікацій.

1.2.3. Структурування метаданих. Організація зібраних метаданих у структуровані бази даних для легкого доступу та аналізу в наступних етапах дослідження.

Крок 2. Попередня обробка даних (блок 2). Попередня обробка даних є фундаментальним етапом у процесі аналізу текстової інформації. Цей крок включає в себе різноманітні техніки та методи, які допомагають підготувати зібрані дані для подальшого аналізу. Ось більш деталізований опис цього кроку [21, 22]:

2.1. Токенізація [23]. Процес розбиття тексту на окремі слова, фрази, символи або інші значущі елементи, які називаються токенами. Це допомагає у подальшому аналізі та обробці тексту.

2.2. Стемінг [24]. Процес видалення суфіксів, префіксів та інфіксів зі слів для повернення їх до їхньої основи. Це полегшує виявлення спільних тем та патернів у тексті.

2.3. Тегування частин мови. Процес визначення частин мови кожного слова у тексті, що може бути корисним для синтаксичного аналізу та визначення семантичних відносин між словами.

2.4. Розпізнавання іменованих сутностей (Named Entity Recognition). Визначення та класифікація іменованих сутностей у тексті, таких як імена осіб, організацій, місцезнаходжень тощо.

Крок 3. Векторизація тексту (блок 3). Векторизація тексту є важливим етапом, який перетворює текстові дані в числовий формат, зручний для аналізу та обробки за допомогою методів машинного навчання [24]. Розглянемо детальніше цей процес:

3.1. Вибір методу векторизації.

3.1.1. Word2Vec [25]. Модель навчає векторні представлення слів у багатовимірному просторі таким чином, що слова, які часто зустрічаються разом, мають близькі векторні представлення.

3.1.2. GloVe. Інший підхід до векторизації слів, який використовує як локальний, так і глобальний статистичний аналіз корпусу тексту для визначення векторних представлень слів.

3.1.3. BERT. Сучасна модель, яка використовує механізм уваги для визначення відносин між словами в тексті і може вчитися глибокі контекстні представлення слів.

3.2. Процес векторизації.

3.2.1. Тренування або завантаження моделей. Моделі можна натренувати на даних або використати попередньо натреновані моделі для векторизації тексту.

3.2.2. Перетворення тексту. Застосування вибраної моделі для перетворення кожного слова в тексті в векторні представлення.

3.3. Побудова векторних представлень.

3.3.1. Векторизація слів. Отримання векторних представлень для кожного окремого слова в тексті.

3.3.2. Векторизація текстів. Агрегація векторних представлень слів для отримання векторних представлень цілих текстів. Це можна зробити за допомогою усереднення, сумування або інших методів агрегації.

Крок 4. Аналіз тональності та емоцій (блок 4). Аналіз тональності та емоцій є ключовим для розуміння настрою та відтінків, які містяться у текстових даних. Це може допомогти визначити, чи є текст позитивним, негативним, або нейтральним, а також виявити можливі емоційні відгуки, які можуть бути асоційовані з дезінформацією. Розглянемо більш детальний опис цього кроку:

4.1. Вибір моделей аналізу тональності та емоцій [26].

4.1.2. Готові моделі. Існує багато попередньо натренованих моделей для аналізу тональності та емоцій, таких як VADER, TextBlob, або моделі, засновані на BERT та інших глибоких нейронних мережах.

4.1.3. Кастомізовані моделі. Залежно від конкретного випадку, може бути корисним розробити та натренувати власні моделі на специфічних для задачі даних.

4.2. Аналіз тональності.

4.2.1. Обчислення тональності. Застосування моделей для визначення тональності кожного тексту, що дає змогу визначити, чи є текст позитивним, негативним, або нейтральним.

4.2.2. Інтерпретація результатів. Аналіз результатів для визначення загального настрою даних та ідентифікації можливих аномалій або зразків.

4.3. Аналіз емоцій.

4.3.1. Обчислення емоційного відтінку. Застосування моделей для визначення емоційного відтінку тексту, такого як радість, смуток, гнів, здивування, страх, тощо.

4.3.1. Інтерпретація результатів. Аналіз отриманих емоційних відтінків для визначення, як емоції можуть бути пов'язані з дезінформацією та як їх можна використати для подальшого аналізу.

Крок 5. Навчання методом онлайн навчання з «ковзним вікном» для ансамблів текстових класифікаторів (блок 5). Цей крок фокусується на розробці та навчанні моделі класифікації, яка може виявляти фейкову інформацію на основі аналізу тексту та інших виявлених ознак. Детальний опис цього кроку виглядає наступним чином:

5.1. Створення та навчання ансамблю моделей

5.1.1. Створення ансамблю моделей: Вибір та створення різних моделей класифікації (наприклад, логістична регресія, SVM, LSTM, трансформери).

5.1.2. Навчання моделей: Кожна модель навчається окремо на векторизованих текстових даних.

5.1.3. Формування метамоделі: Використання алгоритму, такого як Adam, для оптимізації ваг моделей у ансамблі, забезпечуючи кращу інтеграцію та вибір прогнозів від кожної моделі.

5.2. Впровадження методу «ковзного вікна» для онлайн-навчання

5.2.1. Імплементация «ковзного вікна»: Встановлення розміру «ковзного вікна» для вибору останніх текстових документів, що будуть використовуватися для постійного оновлення та навчання моделей.

5.2.2. Онлайн-оновлення моделей: Періодичне оновлення моделей ансамблю, використовуючи найсвіжіші дані, що надходять, та відкидаючи застарілі дані, для підтримання актуальності та високої точності прогнозування.

5.2.3. Адаптація до змін у даних: Неперервна адаптація метамоделі до змін у текстових даних, що забезпечує ефективну відповідь на динамічність і нестаціонарність текстових послідовностей.

Крок 6. Адаптація та перенавчання (блок 8). Цей етап має на меті забезпечити систему здатністю адаптуватися до еволюції та зміни форм дезінформації, що гарантує її тривалу ефективність у боротьбі з фейковими новинами [25]. Розглянемо деталі цього кроку:

6.1. Перенавчання системи.

6.1.1. Збір нових даних. Постійний збір нових даних з відкритих джерел для відображення останніх трендів та шаблонів дезінформації.

6.1.2. Оцінка потреби в перенавчанні. Аналіз поточної ефективності системи та визначення, чи виникла потреба в перенавчанні на основі нових даних.

6.1.3. Перенавчання моделі. Застосування процесу навчання моделі з використанням нових даних для адаптації моделі до нових форм дезінформації.

6.2. Оновлення моделей та алгоритмів.

6.2.1. Аналіз нових алгоритмів та технологій. Оцінка та аналіз нових алгоритмів та технологій, які можуть бути використані для покращення ефективності системи.

6.2.2. Оновлення алгоритмів. Внесення змін у алгоритми та методи, що використовуються на основі отриманих відомостей та аналізу результатів.

6.2.3. Тестування та валідація оновлених моделей. Проведення тестування та валідації оновлених моделей для забезпечення їхньої ефективності та надійності.

6.3. Моніторинг та оцінка.

6.3.1. Моніторинг ефективності системи. Постійний моніторинг ефективності системи для виявлення можливих проблем або областей для покращення.

6.3.2. Зворотній зв'язок та адаптація. Збір та аналіз зворотного зв'язку від користувачів та експертів для подальшого покращення та адаптації системи.



Рис. 1. Структура інтелектуального методу виявлення дезінформації в онлайн режимі

Для реалізації запропонованого методу обрано комбінований набір даних, представлений на Kaggle [27], є унікальною колекцією з більш ніж 60 тис. заголовків новин, зібраних з 24 лютого по 11 грудня 2022 року, що охоплює частину періоду повномасштабної російсько-української війни. Джерелами даних слугували такі телеграм-канали, як «СУСПІЛЬНЕ НОВИНИ», "Ререрichka NEWS" та інші.

Він включає в себе як перевірені, так і неправдиві новини, зібрані з українських телеграм-каналів та російських каналів з фейками, роблячи його найбільшим відкритим джерелом відповідних даних. Також на основі цієї колекції новин було відділено всі фейкові та правдиві новини на дві окремі категорії, перемішано, та сформовано новий датасет у пропорції 38% для фейкових новин та 62% для правдивих новин. Загалом, він містить 4522 записів із міткою "False" та 7235 записи із міткою "True".

Для навчання моделі та перевірки її на тестовому наборі даних дану колекцію було перемішано та розділено на пропорції 60% даних для навчання та 40% даних

для тестової вибірки. Процес перемішування та сепарації даних є важливим етапом підготовки даних для задач машинного навчання. Перемішування забезпечує випадковість вибірки, що запобігає можливим впливам порядку даних на тренування моделі. Поділ даних на навчальну та тестову вибірки дозволяє здійснити оцінку узагальнюючої здатності моделі, що є важливою складовою процесу валідації в машинному навчанні. Стратегічний вибір частки даних для тестування та навчання забезпечує ефективну та надійну оцінку результатів моделі, знижуючи ймовірність перетренування (overfitting) та дозволяючи здійснити належний контроль за її здатністю до узагальнення.

У рамках реалізації на початковому етапі проведено підготовку даних, де текстові матеріали були перетворені на числовий формат за допомогою методу векторизації TF-IDF. Далі, на основі цих даних, було треновано кілька індивідуальних моделей, включаючи логістичну регресію, SVM, випадковий ліс, градієнтний бустинг, KNN, дерево рішень, XGBoost та AdaBoost. Кожна модель була адаптована та оптимізована для вирішення задачі класифікації з використанням тренувального набору даних. На другому етапі реалізації було сформовано метамодель на основі XGBoost, яка була тренована з використанням прогнозів, отриманих від індивідуальних моделей через механізм стекінгу. Оцінка точності класифікації була здійснена на тестовому наборі даних, де результати представлені через звіт про класифікацію та матрицю помилок, візуалізовану у вигляді теплової карти. Цей підхід демонструє високий потенціал ансамблевих методів та стекінгу для підвищення ефективності машинного навчання у складних задачах класифікації тексту, зокрема у виявленні дезінформації.

Отримані результати класифікації представлені у форматі звіту (рис. 2), який включає такі показники, як точність (precision), повнота (recall), оцінку F1 (F1-score), та підтримка (support) для двох класів: "False" (фейкові новини) та "True" (правдиві новини).

У процесі оцінки ефективності моделі класифікації новин було проведено аналіз її здатності диференціювати фактично правдиві від фейкових повідомлень. Згідно з отриманими результатами, модель демонструє високу загальну точність класифікації на рівні 93,26%. Для класу "False", який умовно призначений щоб визначати фейкові новини, точність (precision) склала 92,58%, що свідчить про високу вірогідність коректної класифікації новини як фейкової, коли модель так визначає. Водночас, показник відновлення (recall) для цього класу становить 89,41%, що вказує на те, що 11,59% фейкових новин було пропущено моделлю. З іншого боку, для класу "True", який відповідає правдивим новинам, модель показала вражаючий показник відновлення на рівні успішної ідентифікацію 93,66% правдивих новин. Така здатність моделі ефективно класифікувати правдиві новини є важливою характеристикою в контексті боротьби з дезінформацією.

Аналітичний підхід до оцінки роботи моделі також охоплював аналіз матриці помилок. У цій матриці відзначено 1596 істинно-негативних результатів (True Negative), що підтверджує коректну класифікацію фейкових новин. Однак, виявлено 189 хибно-негативних результатів (False Negative), що вказує на існування певної кількості фейкових новин, які модель помилково класифікувала як правдиві. Для класу правдивих новин зареєстровано 2790 істинно-позитивних результатів (True Positive) та 128 хибно-позитивних (False Positive), демонструючи високу точність виявлення фактично правдивого контенту. Оцінка F1 для обох класів, яка гармонізує точність і відновлення, виявилась на рівні 89,41% для "False" і 95,61% для "True", що в цілому підтверджує збалансованість та надійність моделі.

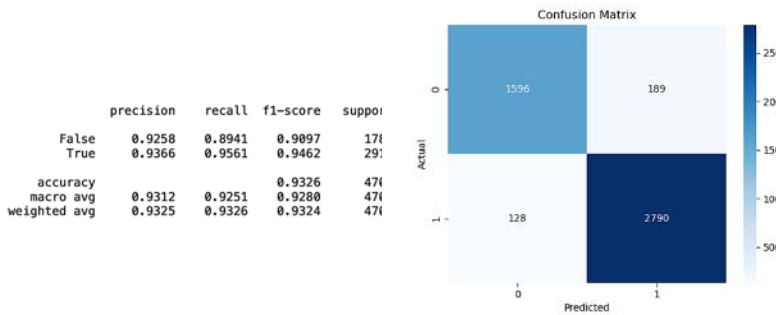


Рис. 2. Результати оцінювання

Аналізуючи результати, представлені в Таблиці 1, можна зробити науково обґрунтовані висновки про ефективність методу OLTW-TEC у порівнянні з класичними підходами класифікації. Розглядаючи кожну метрику окремо, бачимо, що метод OLTW-TEC демонструє суттєві поліпшення за більшістю параметрів.

У контексті точності (precision) для класу "True", OLTW-TEC досягає значення 93,66%, що перевершує всі представлені класичні методи. Це свідчить про високу здатність OLTW-TEC коректно ідентифікувати фейкові новини. Щодо класу "False", точність OLTW-TEC становить 92,58%, що вищим показником порівно з іншими більшістю представлених моделей, є порівнянним з Random Forest, проте нижчим ніж SVM та Logistic Regression.

Показник відновлення (recall) для класу "False" у OLTW-TEC на рівні 89,41% значно вищий, ніж у всіх представлених моделей та KNN, який майже досягає такого ж показника, що вказує на здатність моделі виявляти фейкові новини серед негативного класу. Для класу "True" показник відновлення становить 95,61%, що підкреслює здатність до ідентифікації правдивих новин.

Гармонійне середнє між точністю та відновленням, визначене як оцінка F1, для OLTW-TEC складає 90,97% для класу "False" та 94,62% для класу "True". Значення оцінки F1 є найкращим результатом серед представлених класичних методів, що ефективно підтверджує збалансованість моделі між цими двома важливими показниками.

Загальна точність OLTW-TEC становить 93,26%, що є найвищим показником серед усіх розглянутих моделей (Таблиця 1), підтвержуючи її сильні позиції як надійного інструмента для класифікації новин. Матриця помилок також свідчить про високу кількість коректно класифікованих екземплярів для обох класів.

Розглядаючи результати, представлені у Таблиці 1, ми виявили значні досягнення у галузі виявлення фейкових новин за допомогою різноманітних підходів, що варіюються від глибокого навчання до мультимодального аналізу. Проте, виявлено важливу прогалину в наявних дослідженнях, що полягає у недостатній увазі до українськомовного контенту. Запропонований метод OLTW-TEC, зосереджений на українськомовному датасеті, заповнює цю прогалину, що свідчить про важливість розробки спеціалізованих рішень для конкретних мовних та культурних контекстів.

Порівняльний аналіз з іншими дослідженнями показав, що OLTW-TEC досягає значних результатів у точності, що демонструє значення в 92,58% для класу "False" та 93,66% для класу "True". Ці показники вказують на високу ефективність методу

у виявленні фейкових новин та правдивих повідомлень відповідно. Особливо цінною є здатність OLTW-TEC забезпечувати високу відновленість (recall) для класу "False" на рівні 89,41% та 95,61% для класу "True", що в сумі вирізняє результати серед представлених моделей на користь OLTW-TEC. Це вказує на ефективність методу в контексті виявлення фейкових новин, які часто мають складні патерни та можуть бути марковані як достовірні. Оцінки F1, які гармонізують точність і відновленість, також виділяють OLTW-TEC серед інших досліджень, підкреслюючи його збалансованість і надійність та демонструють найвищі показники для класів "True" та "False".

Загальна точність 93,26% свідчить про те, що OLTW-TEC може бути ефективним інструментом для боротьби з дезінформацією та виявлення фейкових новин. Матриця помилок підтверджує високу точність моделі з мінімальною кількістю помилкових класифікацій, що особливо важливо у ситуаціях, коли потрібно забезпечити достовірність інформації для запобігання паніки або дезінформації в критичні моменти.

Варто зазначити, що хоча OLTW-TEC показує значні результати у порівнянні з класичними методами, існують певні обмеження, які слід розглядати при інтерпретації цих результатів. По-перше, використання ансамблевих методів та техніки "ковзного вікна" вимагає значних обчислювальних ресурсів, що може обмежити широке застосування OLTW-TEC у реальному часі, особливо на пристроях з обмеженою обчислювальною потужністю.

По-друге, метод може бути чутливим до розміру «ковзного вікна», оскільки неправильний вибір розміру може призвести до перенавчання або недонавчання моделі,

Таблиця 1

Порівняння з розробленим методом

Model	Precision (False)	Precision (True)	Recall (False)	Recall (True)	F1-score (False)	F1-score (True)	Accuracy	Confusion Matrix (False, True)
Logistic Regression	94,80%	89,14%	80,62%	97,29%	87,13%	93,04%	90,96%	(1439, 346), (79, 2839)
SVM	96,91%	91,11%	84,31%	98,36%	90,17%	94,59%	93,03%	(1505, 280), (48, 2870)
Random Forest	92,65%	92,61%	87,51%	95,75%	90,00%	94,15%	92,62%	(1562, 223), (124, 2794)
Gradient Boosting	91,34%	85,14%	72,66%	95,78%	80,94%	90,15%	87,01%	(1297, 488), (123, 2795)
KNN	76,77%	92,59%	89,08%	83,52%	82,47%	87,82%	85,63%	(1590, 195), (481, 2437)
Decision Tree	80,51%	92,19%	87,96%	86,98%	84,07%	89,51%	87,35%	(1570, 215), (380, 2538)
XGBoost	87,11%	91,87%	86,67%	92,15%	86,89%	92,01%	90,07%	(1547, 238), (229, 2689)
AdaBoost	86,11%	87,88%	79,22%	92,19%	82,52%	89,98%	87,26%	(1414, 371), (228, 2690)
OLTW-TEC	92,58%	93,66%	89,41%	95,61%	90,97%	94,62%	93,26%	(1596, 189), (128, 2790)

особливо в умовах, де динаміка даних швидко змінюється. Це вимагає додаткових досліджень для оптимізації параметрів і вдосконалення адаптивності моделі.

По-третє, хоча OLTW-TEC продемонстрував високу ефективність на українськомовних даних, його універсальність і ефективність на датасетах інших мов і культурних контекстів ще не були повністю досліджені. Потрібні подальші експерименти для визначення, чи зможе метод зберегти аналогічні показники продуктивності в інших лінгвістичних середовищах.

Нарешті, враховуючи швидкість розвитку технологій і зміну манери поширення дезінформації, існує потреба в постійному оновленні та адаптації моделі для підтримання її актуальності. Це стосується не тільки алгоритмічних удосконалень, а й збору та інтеграції нових даних для тренування, що в свою чергу вимагає додаткових зусиль для забезпечення достовірності та якості вхідних даних.

В цілому, хоча OLTW-TEC показує обнадійливі результати, важливо підкреслити необхідність продовження розвитку та адаптації методу, щоб він міг ефективно відповідати на постійно змінювані виклики у галузі виявлення дезінформації.

У майбутніх наукових дослідженнях акцент буде зроблено на вдосконаленні методу OLTW-TEC, зокрема на розширенні його обчислювальної ефективності та адаптивності. Одним з пріоритетів є оптимізація алгоритмів для зменшення вимог до обчислювальної потужності, щоб метод міг бути застосований у ширшому спектрі застосунків, включаючи мобільні та інші пристрої з обмеженими ресурсами. Також буде зосереджено увагу на точнішому налаштуванні параметрів «ковзного вікна» з метою підвищення точності прогнозування в різноманітних умовах динамічного потоку даних. Іншим важливим напрямком є розширення валідації методу на різноманітних мовних датасетах, що дасть можливість визначити його універсальність та ефективність у глобальному контексті. Додатково, передбачається впровадження механізмів для постійного оновлення тренувального набору даних, що дасть змогу системі адаптуватися до нових патернів та форм дезінформації. Ці заходи мають на меті не лише поліпшити точність та надійність OLTW-TEC, а й забезпечити його стійкість до швидких змін у цифровому інформаційному просторі.

Висновки з даного дослідження і перспективи подальших досліджень у даному напрямі. У ході проведеного дослідження було детально розглянуто та оцінено ефективність методу OLTW-TEC (Online Learning with Sliding Windows for Text Classifier Ensembles), що представляє собою інноваційний підхід до задачі класифікації тексту в умовах нестационарності даних та динамічного онлайн навчання. Методика включає в себе використання ансамблю адаптивних класифікаторів, векторних представлень текстів, оптимізацію ваг класифікаторів за допомогою алгоритму Adam, а також впровадження механізму "ковзного вікна" для підтримки актуальності моделі.

За результатами оцінювання, представленими у звіті класифікації, OLTW-TEC продемонстрував високу загальну точність, досягнувши показника в 93,26%. Точність (precision) і відновлення (recall) для класу "False" виявилися відповідно 92,58% та 89,41%, що свідчить про високу ефективність виявлення фейкових новин з мінімальним відсотком помилкових пропусків. Для класу "True", модель забезпечила точність та відновлення з показниками 93,66% та 95,61%, тим самим підтверджуючи свою здатність до розпізнавання правдивих новин. Отримані результати ілюструють, що OLTW-TEC володіє високою збалансованістю між різними метриками, забезпечуючи надійну та ефективну класифікацію в реальних умовах.

Аналіз матриці помилок вказує на високий ступінь точності класифікації, з мінімальною кількістю хибно-позитивних та хибно-негативних результатів. Це демонструє надійність OLTW-TEC як інструменту для фільтрації інформації, що є особливо актуальним у контексті боротьби з дезінформацією.

У порівнянні з традиційними методами класифікації, OLTW-TEC не лише показує кращі результати за більшістю метрик, але й забезпечує простір для адаптації до змін у характері даних. Вибір розміру «ковзного вікна» та можливість його регулювання залежно від специфіки даних надає методу додаткову гнучкість і точність.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. Tao, W. & Peng, Y. Differentiation and unity: A cross-platform comparison analysis of online posts' semantics of the Russian–Ukrainian war based on Weibo and Twitter. *Communication and the Public*, 2023. 8(2), 105-124. DOI: <https://doi.org/10.1177/20570473231165563>.
2. Mainych, S., Bulhakova, A., & Vysotska, V. Cluster analysis of discussions change dynamics on twitter about war in Ukraine. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems. Volume II: Computational Linguistics Workshop Kharkiv, Ukraine*, 2023. 3396, 490–530. URL: <https://ceur-ws.org/Vol-3396/paper39.pdf>.
3. Vasist, P. N., & Krishnan, S. Fake news and sustainability-focused innovations: A review of the literature and an agenda for future research. *Journal of Cleaner Production*, 2023. 388, 135933. DOI: <https://doi.org/10.1016/j.jclepro.2023.135933>.
4. Hamed, S. K., Ab Aziz, M. J., & Yaakub, M. R. A review of fake news detection approaches: A critical analysis of relevant studies and highlighting key challenges associated with the dataset, feature representation, and data fusion. *Heliyon*, e20382. 2023. DOI: <https://doi.org/10.1016/j.heliyon.2023.e20382>.
5. Kondamudi, M. R., Sahoo, S. R., Chouhan, L., & Yadav, N. A comprehensive survey of fake news in social networks: Attributes, features, and detection approaches. *Journal of King Saud University – Computer and Information Sciences*, 2023. 35(6), 101571. DOI: <https://doi.org/10.1016/j.jksuci.2023.101571>.
6. Hu, L., Wei, S., Zhao, Z., & Wu, B. Deep learning for fake news detection: A comprehensive survey. *AI Open*, 2022. 3, 133-155. DOI: <https://doi.org/10.1016/j.aiopen.2022.09.001>.
7. Phan, H. T., Nguyen, N. T., & Hwang, D. Fake news detection: A survey of graph neural network methods. *Applied Soft Computing*, 2023. 139, 110235. DOI: <https://doi.org/10.1016/j.asoc.2023.110235>.
8. Das, B., & Sudarshan, T. S. Multi-contextual learning in disinformation research: A review of challenges, approaches, and opportunities. *Online Social Networks and Media*, 2023. 34-35, 100247. DOI: <https://doi.org/10.1016/j.osnem.2023.100247>.
9. Ruffo, G., Semeraro, A., Giachanou, A., & Rosso, P. Studying fake news spreading, polarisation dynamics, and manipulation by bots: A tale of networks and language. *Computer Science Review*, 2023. 47, 100531. DOI: <https://doi.org/10.1016/j.cosrev.2022.100531>.
10. Baker, M., Jihad, K., & Taher, Y. Prediction of people sentiments on Twitter using machine learning classifiers during Russian aggression in Ukraine. *Jordanian Journal of Computers and Information Technology*, 2023. 9(3), 189-206. DOI: <https://doi.org/10.5455/jjcit.71-1676205770>.
11. Peng, L., Jian, S., Kan, Z., Qiao, L., & Li, D. Not all fake news is semantically similar: Contextual semantic representation learning for multimodal fake news detection. *Information Processing & Management*, 2023. 61(1), 103564. DOI: <https://doi.org/10.1016/j.ipm.2023.103564>.

12. Qu, Z., Meng, Y., Muhammad, G., & Tiwari, P. QMFND: A quantum multimodal fusion-based fake news detection model for social media. *Information Fusion*, 2023. 104, 102172. DOI: <https://doi.org/10.1016/j.inffus.2023.102172>.
13. Soga, K., Yoshida, S., & Muneyasu, M. Exploiting stance similarity and graph neural networks for fake news detection. *Pattern Recognition Letters*, 2024. 177, 26-32. DOI: <https://doi.org/10.1016/j.patrec.2023.11.019>.
14. Yang, H., Zhang, J., Zhang, L., Cheng, X., & Hu, Z. MRAN: Multimodal relationship-aware attention network for fake news detection. *Computer Standards & Interfaces*, 2024. 89, 103822. DOI: <https://doi.org/10.1016/j.csi.2023.103822>.
15. Syed, L., Alsaedi, A., Alhuri, L. A., & Aljohani H. R. Hybrid weakly supervised learning with deep learning technique for detection of fake news from cyber propaganda. *Array*, 2023. 19, 100309. DOI: <https://doi.org/10.1016/j.array.2023.100309>.
16. Xie, B., & Li, Q. Detecting fake news by RNN-based gatekeeping behavior model on social networks. *Expert Systems with Applications*, 2023. 231, 120716. DOI: <https://doi.org/10.1016/j.eswa.2023.120716>.
17. Přibán, P., Hercig, T., & Steinberger, J. Machine learning approach to fact-checking in west slavic languages. *Proceedings of the Recent Advances in Natural Language Processing*, (973-979). Incoma Ltd., Shoumen, Bulgaria. 2019. DOI: https://doi.org/10.26615/978-954-452-056-4_113.
18. Bucos, M., & Drăgulescu, B. Enhancing fake news detection in Romanian using transformer-based back translation augmentation. *Applied Sciences*, 2023. 13(24), 13207. DOI: <https://doi.org/10.3390/app132413207>.
19. Afanasieva, I., Golian, N., Golian, V., Khovrat, A., & Onyshchenko, K. Application of neural networks to identify of fake news. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems, Volume II: Computational Linguistics Workshop*, 2023. vol-3396, (346–358). Kharkiv, Ukraine. URL: <https://ceur-ws.org/Vol-3396/paper28.pdf>.
20. Bodyanskiy, Y. V., Lipianina-Honcharenko, K. V., & Sachenko, A. O. Ensemble of adaptive predictors for multivariate nonstationary sequences and its online learning. *Radio Electronics, Computer Science, Control*, 2022. 4(67), 91–97. DOI: <https://doi.org/10.15588/1607-3274-2023-4-9>.
21. Gramyak, R., Lipyanina-Goncharenko, H., Sachenko, A., Lendyuk, T., & Zahorodnia, D. Intelligent method of a competitive product choosing based on the emotional feedbacks coloring. *Proceedings of the 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security with CEUR-WS*, 2021. (246-257). Khmelnytskyi, Ukraine. URL: <https://ceur-ws.org/Vol-2853/paper31.pdf>.
22. Lipianina-Honcharenko, K., Savchyshyn, R., Sachenko, A., Chaban, A., Kit, I., & Lendiuk, T. Concept of the intelligent guide with AR support. *International Journal of Computing*, 2022. 21(2), 271–277. DOI: <https://doi.org/10.47839/ijc.21.2.2596>.
23. Lipianina-Honcharenko, K., Wolff, C., Sachenko, A., Desyatnyuk, O., Sachenko, S., & Kit, I. Intelligent information system for product promotion in internet market. *Applied Sciences*, 2023. 13(17), 9585. DOI: <https://doi.org/10.3390/app13179585>.
24. Lipyanina, H., Sachenko, O., Lendyuk, T., Sachenko, A., & Vasylyuk, N. Intelligent method of forming the HR management short-term project. in: Shakhovska, N., Medykovskyy, M.O. (eds) *Advances in Intelligent Systems and Computing V. CSIT 2020*, Advances in Intelligent Systems and Computing, 2021. vol. 1293, (1045–1055), Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-63270-0_71.
25. Golovko, V., Kroshchanka, A., Komar, M., & Sachenko, A. Neural network approach for semantic coding of words. *Advances in Intelligent Systems and Computing*, 2020. 1020, 647–658. DOI: https://doi.org/10.1007/978-3-030-26474-1_45.
26. Lipianina-Honcharenko, K., Lendiuk, T., Sachenko, A., Osolinskyi, O., Zahorodnia, D., & Komar, M. An intelligent method for forming the advertising content of higher education institutions based on semantic analysis, in: *Ignatenko, O., et al. ICTERI 2021 Workshops. ICTERI 2021, Communications in Computer and Information Science*,

2022. vol. 1635, (169–182), Springer, Cham. DOI: https://doi.org/10.1007/978-3-031-14841-5_11.

27. Ukrainian news. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/zeppo/ukrainian-fake-and-true-news?resource=download>

REFERENCES:

1. Tao, W. & Peng, Y. (2023). Differentiation and unity: A cross-platform comparison analysis of online posts' semantics of the Russian–Ukrainian war based on Weibo and Twitter. *Communication and the Public*, 8(2), 105-124. DOI: <https://doi.org/10.1177/20570473231165563>.
2. Mainych, S., Bulhakova, S. A., & Vysotska, V. (2023). Cluster analysis of discussions change dynamics on twitter about war in Ukraine. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems. Volume II: Computational Linguistics Workshop Kharkiv, Ukraine, 3396*, 490–530. URL: <https://ceur-ws.org/Vol-3396/paper39.pdf>
3. Vasist, P. N., & Krishnan, S. (2023). Fake news and sustainability-focused innovations: A review of the literature and an agenda for future research. *Journal of Cleaner Production*, 388, 135933. DOI: <https://doi.org/10.1016/j.jclepro.2023.135933>.
4. Hamed, S. K., Ab Aziz, M. J., & Yaakub, M. R. (2023). A review of fake news detection approaches: A critical analysis of relevant studies and highlighting key challenges associated with the dataset, feature representation, and data fusion. *Heliyon*, e20382. DOI: <https://doi.org/10.1016/j.heliyon.2023.e20382>.
5. Kondamudi, M. R., Sahoo, S. R., Chouhan, L., & Yadav, N. (2023). A comprehensive survey of fake news in social networks: Attributes, features, and detection approaches. *Journal of King Saud University – Computer and Information Sciences*, 35(6), 101571. DOI: <https://doi.org/10.1016/j.jksuci.2023.101571>.
6. Hu, L., Wei, S., Zhao, Z., & Wu, B. (2022). Deep learning for fake news detection: A comprehensive survey. *AI Open*, 3, 133-155. DOI: <https://doi.org/10.1016/j.aiopen.2022.09.001>.
7. Phan, H. T., Nguyen, N. T., & Hwang, D. (2023). Fake news detection: A survey of graph neural network methods. *Applied Soft Computing*, 139, 110235. DOI: <https://doi.org/10.1016/j.asoc.2023.110235>.
8. Das, B., & Sudarshan, T. S. B. (2023). Multi-contextual learning in disinformation research: A review of challenges, approaches, and opportunities. *Online Social Networks and Media*, 34-35, 100247. DOI: <https://doi.org/10.1016/j.osnem.2023.100247>.
9. Ruffo, G., Semeraro, A., Giachanou, A., & Rosso, P. (2023). Studying fake news spreading, polarisation dynamics, and manipulation by bots: A tale of networks and language. *Computer Science Review*, 47, 100531. DOI: <https://doi.org/10.1016/j.cosrev.2022.100531>.
10. Baker, M., Jihad, K., & Taher, Y. (2023). Prediction of people sentiments on Twitter using machine learning classifiers during Russian aggression in Ukraine. *Jordanian Journal of Computers and Information Technology*, 9(3), 189-206. DOI: <https://doi.org/10.5455/jjcit.71-1676205770>.
11. Peng, L., Jian, S., Kan, Z., Qiao, L., & Li, D. (2023). Not all fake news is semantically similar: Contextual semantic representation learning for multimodal fake news detection. *Information Processing & Management*, 61(1), 103564. DOI: <https://doi.org/10.1016/j.ipm.2023.103564>.
12. Qu, Z., Meng, Y., Muhammad, G., & Tiwari, P. (2023). QMFND: A quantum multimodal fusion-based fake news detection model for social media. *Information Fusion*, 104, 102172. DOI: <https://doi.org/10.1016/j.inffus.2023.102172>.
13. Soga, K., Yoshida, S., & Muneyasu, M. (2024). Exploiting stance similarity and graph neural networks for fake news detection. *Pattern Recognition Letters*, 177, 26-32. DOI: <https://doi.org/10.1016/j.patrec.2023.11.019>.

14. Yang, H., Zhang, J., Zhang, L., Cheng, X., & Hu, Z. (2024). MRAN: Multimodal relationship-aware attention network for fake news detection. *Computer Standards & Interfaces*, 89, 103822. DOI: <https://doi.org/10.1016/j.csi.2023.103822>.
15. Syed, L., Alsaeedi, A., Alhuri, L. A., & Aljohani H. R. (2023). Hybrid weakly supervised learning with deep learning technique for detection of fake news from cyber propaganda. *Array*, 19, 100309. DOI: <https://doi.org/10.1016/j.array.2023.100309>.
16. Xie, B., & Li, Q. (2023). Detecting fake news by RNN-based gatekeeping behavior model on social networks. *Expert Systems with Applications*, 231, 120716. DOI: <https://doi.org/10.1016/j.eswa.2023.120716>.
17. Příbáň, P., Hercig, T., & Steinberger, J. (2019). Machine learning approach to fact-checking in west slavic languages. *Proceedings of the Recent Advances in Natural Language Processing*, (973-979). Incoma Ltd., Shoumen, Bulgaria. DOI: https://doi.org/10.26615/978-954-452-056-4_113.
18. Bucos, M., & Drăgulescu, B. (2023). Enhancing fake news detection in Romanian using transformer-based back translation augmentation. *Applied Sciences*, 13(24), 13207. DOI: <https://doi.org/10.3390/app132413207>.
19. Afanasieva, I., Golian, N., Golian, V., Khovrat, A., & Onyshchenko, K. (2023). Application of neural networks to identify of fake news. *Proceedings of the 7th International Conference on Computational Linguistics and Intelligent Systems, Volume II: Computational Linguistics Workshop*, vol-3396, (346–358). Kharkiv, Ukraine. URL: <https://ceur-ws.org/Vol-3396/paper28.pdf>.
20. Bodyanskiy, Y. V., Lipianina-Honcharenko, K. V., & Sachenko, A. O. (2022). Ensemble of adaptive predictors for multivariate nonstationary sequences and its online learning. *Radio Electronics, Computer Science, Control*, 4(67), 91–97. DOI: <https://doi.org/10.15588/1607-3274-2023-4-9>.
21. Gramyak, R., Lipyanina-Goncharenko, H., Sachenko, A., Lendyuk, T., & Zahorodnia, D. (2021). Intelligent method of a competitive product choosing based on the emotional feedbacks coloring. *Proceedings of the 2nd International Workshop on Intelligent Information Technologies & Systems of Information Security with CEUR-WS*, (246-257). Khmelnytskyi, Ukraine. URL: <https://ceur-ws.org/Vol-2853/paper31.pdf>.
22. Lipianina-Honcharenko, K., Savchyshyn, R., Sachenko, A., Chaban, A., Kit, I., & Lendiuk, T. (2022). Concept of the intelligent guide with AR support. *International Journal of Computing*, 21(2), 271–277. DOI: <https://doi.org/10.47839/ijc.21.2.2596>.
23. Lipianina-Honcharenko, K., Wolff, C., Sachenko, A., Desyatnyuk, O., Sachenko, S., & Kit, I. (2023). Intelligent information system for product promotion in internet market. *Applied Sciences*, 13(17), 9585. DOI: <https://doi.org/10.3390/app13179585>.
24. Lipyanina, H., Sachenko, O., Lendyuk, T., Sachenko, A., & Vasylykiv, N. (2021). Intelligent method of forming the HR management short-term project. in: Shakhovska, N., Medykovskyy, M.O. (eds) *Advances in Intelligent Systems and Computing V. CSIT 2020*, *Advances in Intelligent Systems and Computing*, vol. 1293, (1045–1055), Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-63270-0_71.
25. Golovko, V., Kroshchanka, A., Komar, M., & Sachenko, A. (2020). Neural network approach for semantic coding of words. *Advances in Intelligent Systems and Computing*, 1020, 647–658. DOI: https://doi.org/10.1007/978-3-030-26474-1_45.
26. Lipianina-Honcharenko, K., Lendiuk, T., Sachenko, A., Osolinskyi, O., Zahorodnia, D., Komar, M. (2022). An intelligent method for forming the advertising content of higher education institutions based on semantic analysis, in: *Ignatenko, O., et al. ICTERI 2021 Workshops. ICTERI 2021, Communications in Computer and Information Science*, vol. 1635, (169–182), Springer, Cham. DOI: https://doi.org/10.1007/978-3-031-14841-5_11.
27. Ukrainian news. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/zepopo/ukrainian-fake-and-true-news?resource=download>