

Paweł Buchwald, Karol Jędrasiak

WSB University / AWSB Dąbrowa Górnicza

Corresponding author / Autor korespondencyjny: pbuchwald@wsb.edu.pl

## Method for Protecting Users From Fake News Using Hybrid Evaluation Methods Combining Artificial Intelligence and User Experience

### Metoda ochrony użytkowników przed fake newsami przy pomocy hybrydowych metod oceny łączących sztuczną inteligencję oraz doświadczenie użytkowników

#### ABSTRACT

**Purpose:** In today's digital society, the growing problem of disinformation, which spreads faster than ever before through social media, poses a serious challenge. The aim of the study was to develop a method for protecting users against fake news by combining artificial intelligence solutions with human knowledge and experience. The authors assumed that effective counteraction against disinformation requires not only advanced technologies but also active involvement of users, who are able to detect subtleties that might escape automated systems.

**Project and methods:** As part of the project, a system was developed to create a database of disinformation articles. An initial verification of the content was carried out by experts, followed by user evaluations, whose responses were used to train machine learning classification models. Feedforward neural networks were applied and trained on data enriched with text complexity indicators such as the Pisarek index, FOG index, and Flesch readability scores. An important element of the system was also the profiling of users based on their knowledge and competencies, which allowed for more accurate matching of the content being evaluated.

**Results:** The results indicated that the neural network achieved a classification accuracy of 84%, which was considered a very good result given the complexity of detecting disinformation. Qualitative analysis revealed that fake news is characterized by its ubiquity, simplicity of message, and emotional appeal, making it exceptionally effective at spreading. The research also showed that even highly knowledgeable users are not completely immune to manipulation, particularly when emotionally charged social events are involved. It was confirmed that fake news most often concerns political, economic, and social topics and that its goals are both to achieve political influence and economic gain.

**Conclusions:** The conclusions drawn from the study indicate that complete protection against disinformation is impossible; however, it is possible to mitigate its effects through appropriate user education and technological development. Media literacy and the development of critical content analysis skills are essential to strengthening society's resilience to false information. The hybrid approach, combining artificial intelligence with human expertise, proved to be an effective solution, although it requires continuous improvement of models and analytical methods. The article emphasizes the necessity for further research in this area and the importance of a systemic approach combining technology, education, and social responsibility.

**Keywords:** machine learning, disinformation, fake news, artificial intelligence, user protection

**Type of article:** original scientific article

---

Received: 29.04.2025; Reviewed: 16.06.2025; Accepted: 04.07.2025;

Authors' ORCID IDs: P. Buchwald – 0000-0003-2537-7085; K. Jędrasiak – 0000-0002-2254-1030;

The authors contributed equally to this article;

Please cite as: SFT Vol. 66 Issue 2, 2025, pp. 6–23, <https://doi.org/10.12845/sft.66.2.2025.1>;

This is an open access article under the CC BY-SA 4.0 license (<https://creativecommons.org/licenses/by-sa/4.0/>).

---

#### ABSTRAKT

**Cel:** Współczesne społeczeństwo cyfrowe zmagają się z rosnącym problemem dezinformacji, która za pośrednictwem mediów społecznościowych rozprzestrzenia się szybciej niż kiedykolwiek wcześniej. Celem pracy było stworzenie metody ochrony użytkowników przed fake newsami poprzez połączenie rozwiązań sztucznej inteligencji z wiedzą i doświadczeniem ludzi. Autorzy założyli, że skuteczna walka z dezinformacją wymaga nie tylko zaawansowanych technologii, ale także aktywnego udziału użytkowników, którzy mogą wychwycić subtelności niedostrzegalne dla maszyn. Kluczowym zadaniem projektu było więc opracowanie hybrydowego podejścia, które synergicznie wykorzysta oba te potencjały.

**Projekt i metody:** W ramach realizacji projektu opracowano system umożliwiający tworzenie bazy danych artykułów dezinformacyjnych. Przeprowadzono wstępną weryfikację treści przez ekspertów, a następnie użytkowników, których odpowiedzi posłużyły do uczenia maszynowego modeli klasyfikacyjnych. Zastosowano sieci neuronowe jednokierunkowe, trenując je na danych wzbogaconych o wskaźniki trudności tekstu, takie jak indeks Pisarka, FOG i Flescha. Istotnym elementem systemu było również profilowanie użytkowników pod względem ich wiedzy i kompetencji, co umożliwiło bardziej precyzyjne dopasowanie treści ocenianych podczas badań. Proces oceniania nie ograniczał się do binarnego wskazywania prawdy lub fałszu, lecz uwzględniał skalę ocen od 1 do 10, pozwalając na uchwycenie stopnia pewności w ocenie danego materiału.

**Wyniki:** Wyniki badań wskazały, że sieć neuronowa osiągnęła dokładność klasyfikacji treści na poziomie 84%, co uznano za bardzo dobry wynik w kontekście trudności rozpoznawania dezinformacji. W analizie jakościowej zauważono, że fake newsy cechują się powszechnością, prostotą przekazu oraz emocjonalnym nacechowaniem treści, co czyni je wyjątkowo skutecznymi w rozpowszechnianiu. Badania wykazały również, że nawet użytkownicy o wysokim poziomie wiedzy nie są całkowicie odporni na manipulację, zwłaszcza w kontekście aktualnych wydarzeń budzących silne emocje społeczne. Potwierdzono, że fake newsy dotyczą najczęściej tematów politycznych, ekonomicznych i społecznych, a ich celem jest zarówno osiągnięcie wpływów politycznych, jak i zysków ekonomicznych.

**Wnioski:** Wnioski płynące z badań wskazują, że pełna ochrona przed dezinformacją jest niemożliwa, jednak możliwe jest ograniczenie jej skutków poprzez odpowiednie przygotowanie użytkowników i rozwój technologii. Edukacja medialna oraz budowanie kompetencji w zakresie krytycznej analizy treści są niezbędne, by wzmocnić odporność społeczeństwa na fałszywe informacje.

**Słowa kluczowe:** sztuczna inteligencja, dezinformacja, uczenie maszynowe, fake news, ochrona użytkowników

**Typ artykułu:** oryginalny artykuł naukowy

---

**Przyjęty:** 29.04.2025; **Zrecenzowany:** 16.06.2025; **Zaakceptowany:** 04.07.2025;

Identyfikatory ORCID autorów: P. Buchwald – 0000-0003-2537-7085; K. Jędrasiak – 0000-0002-2254-1030;

Autorzy wnieśli równy wkład merytoryczny w opracowanie artykułu;

**Proszę cytować:** SFT Vol. 66 Issue 2, 2025, pp. 6–23, <https://doi.org/10.12845/sft.66.2.2025.1>;

Artykuł udostępniany na licencji CC BY-SA 4.0 (<https://creativecommons.org/licenses/by-sa/4.0/>).

---

## Introduction

In today's world, where information spreads instantly through social media and other digital platforms, the problem of disinformation and fake news has become a serious challenge. False information, often created and disseminated to mislead or manipulate, can have severe social, political, and economic consequences [1]. Consequently, developing effective methods to protect internet users from the influence of disinformation is becoming increasingly crucial. This article focuses on hybrid evaluation methods that combine advanced artificial intelligence (AI) solutions with user experience and knowledge to effectively combat the problem of false information. On one hand, artificial intelligence offers promising tools such as machine learning and natural language processing, which can analyse vast amounts of data and identify potential disinformation based on patterns and characteristic features. On the other hand, human experience and intuition allow for the equally important recognition of subtleties and context that algorithms might miss. Integrating these two approaches creates a hybrid evaluation method, combining the advantages of both AI and human judgment. The article presents how the integration of these two elements can contribute to improving the fight against disinformation. It also outlines the challenges faced by the creators of such systems [2]. Through an analysis of various use cases and conducted research, the article sketches a picture of how hybrid evaluation methods can change the perception of digital media and contribute to creating a safer and more reliable information environment [3].

## Wprowadzenie

W dzisiejszym świecie, w którym informacje rozprzestrzeniają się błyskawicznie poprzez media społecznościowe i inne platformy cyfrowe, problem dezinformacji i tzw. fake newsów stał się poważnym wyzwaniem. Nieprawdziwe informacje, często tworzone i rozpowszechniane w celu wprowadzenia w błąd lub manipulacji, mogą mieć poważne konsekwencje społeczne, polityczne i ekonomiczne [1]. W związku z tym coraz ważniejsze staje się opracowanie skutecznych metod ochrony użytkowników Internetu przed wpływem dezinformacji. Artykuł ten koncentruje się na hybrydowych metodach oceny, które w celu skutecznego zwalczania problemu fałszywych informacji łączą zaawansowane rozwiązania sztucznej inteligencji (AI) z doświadczeniem i wiedzą użytkowników. Z jednej strony sztuczna inteligencja oferuje obiecujące narzędzia, takie jak uczenie maszynowe i przetwarzanie języka naturalnego, które mogą analizować ogromne ilości danych i identyfikować potencjalne dezinformacje na podstawie wzorców i cech charakterystycznych. Z drugiej strony doświadczenie ludzi i ich intuicja pozwalają na równie ważne rozpoznawanie subtelności i kontekstu, które mogą umknąć algorytmom. Integracja tych dwóch podejść tworzy hybrydową metodę oceny, łączącą zalety zarówno AI, jak i ludzkiego osądu. W artykule przedstawiono, w jaki sposób integracja tych dwóch elementów może przyczynić się do polepszenia walki z dezinformacją. Przedstawiono również wyzwania, jakie stoją przed twórcami takich systemów [2]. Poprzez analizę różnorodnych przypadków ich wykorzystania oraz przeprowadzonych badań naszkicowano obraz tego, jak hybrydowe metody oceny mogą zmieniać postrzeganie mediów cyfrowych i przyczynić się do tworzenia bezpieczniejszego i bardziej wiarygodnego środowiska informacyjnego [3].

## Software for collecting information on the content of fake news

For the purposes of the project, software was developed to create a database of articles serving as examples of disinformation content. In the initial stage of work, data analysis involved evaluating content accuracy by specialists in relevant fields and users with the necessary knowledge and experience in specific thematic areas. The initial component of the system under development was a content classification module. This module allowed for the collection of a database of aggregated examples needed to train the artificial intelligence (AI) system.

The content classification module was used to prepare data for AI analysis and to develop the material presented for evaluation by survey participants. The designed module included, among other things:

- a form for preparing the presented content,
- a form for classifying the category of the analysed page,
- a form for tags assigned to a given website,
- a form for additional attributes,
- automatic calculation of content complexity indices.

## Oprogramowanie do kolekcjonowania informacji na temat treści typu fake news

Dla potrzeb realizacji projektu powstało oprogramowanie do utworzenia bazy danych artykułów będących przykładem treści dezinformacyjnych. Na wstępnym etapie prac analiza danych polegała na ocenie poprawności treści przez specjalistów z danej dziedziny oraz użytkowników mających niezbędną wiedzę i doświadczenie w danym obszarze tematycznym. Początkowym elementem tworzonego systemu był moduł klasyfikacji treści pozwalający na zebranie bazy danych zagregowanych przykładów na potrzeby uczenia systemu sztucznej inteligencji (AI).

Moduł klasyfikacji treści posłużył do przygotowania danych do analizy AI oraz opracowania materiału poddawanego ocenie przez odbiorców ankiety. Zaprojektowany moduł uwzględnił m.in.:

- formularz przygotowania prezentowanej treści,
- formularz klasyfikacji kategorii analizowanej strony,
- formularz tagów przypisanych do danej witryny,
- formularz dodatkowych atrybutów,
- automatyczne wyliczenie indeksów skomplikowania treści.

**Figure 1.** Form for adding article examples to the system (article title; article content)

**Rycina 1.** Formularz dodawania przykładów artykułów do systemu

**Source:** Own archive.

**Źródło:** Archiwum własne.

As a result of the conducted research and consultations with a team of psychologists, it was concluded that external factors should not influence content evaluation. These factors include advertisements on pages, information not directly related to the text being evaluated, and other materials that could falsify the research outcome. Therefore, all the aforementioned elements were removed, leaving only the context analysed by the respondents. Content preparation involved processing the original page, copying only the relevant section of the website, and eliminating unnecessary data. After this step, the content was saved to the database for further analysis. At the time of saving, the system automatically calculated the Writer's Index, FOG, and Flesch-Kincaid (FK) indices, additionally determining the word count in the article. These parameters serve as descriptors in classification algorithms. For properties of a given text that correspond to an assessment of its complexity, the following numerical descriptors (1–3) were used.

W wyniku przeprowadzonych badań oraz konsultacji z zespołem psychologów wypracowano wnioski, iż na ocenę treści nie powinny wpływać czynniki zewnętrzne – tj. reklamy zamieszczone na stronach, informacje niezwiązane bezpośrednio z ocenianym tekstem oraz inne materiały mogące zafałszować wynik badania. W związku z tym usunięto wszystkie wymienione wyżej elementy, pozostawiając sam kontekst analizowany przez respondentów. Przygotowanie treści polegało na przetworzeniu oryginalnej strony, skopiowaniu jedynie interesującego fragmentu witryny i wyeliminowaniu zbędnych danych. Po wykonaniu tej czynności treść była zapisywana do bazy danych dla potrzeb dalszej analizy. W momencie zapisu system automatycznie wyznaczał indeksy Pisarka, FOG oraz FK, dodatkowo określając liczbę słów w artykule. Są to parametry służące jako deskryptory w algorytmach klasyfikacji. Dla właściwości danego tekstu, które odpowiadają ocenie jego skomplikowania, użyto następujących deskryptorów

### 1) Pisarek index

For the purpose of obtaining the Pisarek index, an algorithm using the following formula was implemented:

$$T = \frac{\sqrt{T_w^2 + T_s^2}}{2} \quad (1)$$

where:

$T_w$  – percentage of words of four syllables or longer,

$T_s$  – average sentence length measured in words,

$T$  – degree of difficulty of the text.

### 2) FOG index

The following formula was used to obtain the FOG haze factor:

$$T = 0.4 \times (T_w + T_s) \quad (2)$$

where:

$T_w$  – average number of words in a sentence,

$T_s$  – percentage of three-syllable or longer words,

$T$  – degree of vagueness of the text.

### 3) Flesch index

A formula was used to calculate the difficulty of the text according to the Flesch scale:

$$T = 206.835 - 1.015 \times T_w - 84.6 \times T_s \quad (3)$$

where:

$T_w$  – average number of words in a sentence,

$T_s$  – average number of syllables in a word,

$T$  – degree of difficulty of the text.

A significant element of the machine learning model training was the classification of the dataset categories. Twenty-two text categories were developed, to which a given page could belong. The selection window for the available content classification groups in the system is presented in Figure 2.

Klasyfikacja:	
<input type="checkbox"/> Muzyka popularna i klasyczna	<input type="checkbox"/> Film (seriale)
<input type="checkbox"/> Teatr, opera, performance	<input checked="" type="checkbox"/> Sztuka użytkowa
<input type="checkbox"/> Gry komputerowe	<input type="checkbox"/> Medycyna
<input type="checkbox"/> Przyroda	<input type="checkbox"/> Majsterkowanie
<input type="checkbox"/> Historia	<input type="checkbox"/> Religia
<input type="checkbox"/> Bezpieczeństwo	<input checked="" type="checkbox"/> Moda, styl życia
<input checked="" type="checkbox"/> Sztuki plastyczne i malarstwo	<input type="checkbox"/> Polityka
<input type="checkbox"/> Informatyka, elektronika	<input type="checkbox"/> Sport
<input type="checkbox"/> Zdrowy tryb życia	<input type="checkbox"/> Turystyka i rekreacja
<input type="checkbox"/> Gotowanie	<input type="checkbox"/> Motoryzacja
<input type="checkbox"/> Obce kultury	<input checked="" type="checkbox"/> Informatyka i technologia

**Figure 2.** Category selection window for content classification (e.g. popular and classic music, games, history, religion, art)

**Rycina 2.** Okno wyboru kategorii dla klasyfikacji treści

Source: Own archive.

Źródło: Archiwum własne.

The system also allowed for the addition of extra parameters to describe a given webpage, which could prove useful during the training of the classification module. The window for entering these additional attributes is shown in Figure 3.

numerycznych (1–3).

### 1) Indeks Pisarka

Na potrzeby uzyskania indeksu Pisarka został zaimplementowany algorytm wykorzystujący następujący wzór:

$$T = \frac{\sqrt{T_w^2 + T_s^2}}{2} \quad (1)$$

gdzie:

$T_w$  – procent wyrazów czterosylabowych lub dłuższych,

$T_s$  – przeciętna długość zdania mierzona w wyrazach,

$T$  – stopień trudności tekstu.

### 2) Indeks FOG

Do uzyskania współczynnika mglistości FOG zastosowano następujący wzór:

$$T = 0,4 \times (T_w + T_s) \quad (2)$$

gdzie:

$T_w$  – średnia liczba wyrazów w zdaniu,

$T_s$  – procent wyrazów trój sylabowych lub dłuższych,

$T$  – stopień mglistości tekstu.

### 3) Indeks Flescha

Do obliczenia trudności tekstu według skali Flesha użyto formuły:

$$T = 206,835 - 1,015 \times T_w - 84,6 \times T_s \quad (3)$$

gdzie:

$T_w$  – średnia liczba wyrazów w zdaniu,

$T_s$  – czyli średnia liczba sylab w słowie,

$T$  – stopień trudności tekstu.

Istotny element uczenia maszynowego modelu stanowiła klasyfikacja kategorii zbioru. Opracowano 22 kategorie tekstu, do których może przynależeć dana strona. Okno wyboru dostępnych w systemie grup klasyfikacji treści przedstawiono na rycinie 2.

**Figure 3.** Window for entering the attributes of an information page (author, publisher, type of article, reviewer, publication date, emotions)  
**Rycina 3.** Okno wprowadzania atrybutów strony informacyjnej

**Source:** Own archive.

**Źródło:** Archiwum własne.

Each page could also be assigned tags to expand its description, allowing for better context analysis and enriching the collected information. The user confirmation window for such metadata is shown in Figure 4.

Każdej ze stron można było również przypisać znaczniki rozszerzające jej opis, pozwalające na lepszą analizę kontekstu oraz wzbogacenie zebranych informacji. Okno zatwierdzenia przez użytkownika takich metadanych zostało przedstawione na rycinie 4.

**Figure 4.** Metadata selection window for an article (e.g. AI, artists...)

**Rycina 4.** Okno wyboru metadanych dla artykułu

**Source:** Own archive.

**Źródło:** Archiwum własne.

Because text evaluation involves respondents' subjective perceptions and is influenced by their personal experiences and knowledge, a simple method based solely on indicating whether an article is true or false was not used. Instead, we introduced the ability to rate text on a scale from 1 to 10 with 0.5 increments, where 1 means "definitely false" and 10 means "definitely true". This approach was also due to the fact that the reader analysing the text might adopt an attitude based on a certain degree of trust or uncertainty. Only after applying an averaging function to the results collected for a given page could it be assigned to a specific category ("true", "false").

Introducing a classification threshold at the midpoint of the scale allowed for describing content as "true or false". The evaluation of informational content and the accuracy of such an assessment depend on the experience, competence, and knowledge of the users interacting with the system. User classification based on their knowledge level in a specific area was achieved through appropriate account profiling. For this task, the user data aggregation module was utilized. Through it, responses to questions created in the survey preparation module (administrative module) were collected. The answers provided by respondents were initially saved in the database (also in text form, in addition to numerical values) and then converted into a full information vector used in further processing. Thanks to the implemented interests section, in cooperation with the content classification

Ponieważ ocena tekstu wiąże się z subiektywnymi odczuciami respondentów oraz uwarunkowana jest ich osobistymi doświadczeniami i zasobem wiedzy, nie zastosowano prostej metody opierającej się jedynie na wskazaniu, czy artykuł jest prawdą, czy fałszem. Wprowadzono natomiast możliwość oceny tekstu w skali od 1 do 10 z gradacją 0,5, gdzie 1 oznacza na pewno nieprawdę, a 10 – na pewno prawdę. Uwarunkowane było to także tym, że odbiorca analizujący tekst może przyjmować wobec niego postawę opartą na pewnej dozie zaufania bądź niepewności. Dopiero po zastosowaniu funkcji uśredniającej wyniki zebrane dla danej strony można było przyporządkować do danej kategorii („prawda”, „fałsz”).

Wprowadzenie progu klasyfikacji w połowie skali skutkowało możliwością opisu treści jako „prawda lub fałsz”. Ocena treści informacyjnych oraz trafność przeprowadzenia takiej oceny zależą od doświadczenia, kompetencji oraz wiedzy użytkowników współpracujących z systemem. Zaklasyfikowanie użytkownika ze względu na poziom jego wiedzy w danym obszarze zostało zrealizowane przez odpowiednie sprofilowanie kont. Do tego zadania posłużył moduł agregacji danych użytkowników. Za jego pośrednictwem zbierano odpowiedzi na pytania utworzone w module przygotowania ankiet (moduł administracyjny). Odpowiedzi udzielone przez respondentów zapisano wstępnie w bazie danych (również w formie tekstowej, oprócz wartości numerycznych), a następnie przekonwertowano na pełny wektor informacyjny używany w dalszym przetwarzaniu.

module and the content evaluation module, the system selected materials for users to evaluate. The collected data was then used during the training phase of the AI-based content classification module.

### Machine learning methods applied to support classification of disinformation content

In typical machine learning problems, two fundamental groups of issues are distinguished: unsupervised learning and supervised learning. For supervised learning, two basic modes of model operation are identified: training and prediction. In the first, the model is trained, and in the second, it is applied. During the training phase of a supervised learning model, the parameters of a function that ensures mapping are selected, with both the output values  $y$  (also known as labels) and the  $x$  values being known. During prediction, the model automatically maps the  $x$  values to the desired output value –  $y$ . Depending on the nature of the  $y$  value, we can speak of a regression problem when  $y$  is a numerical value, or a classification problem when  $y$  is a symbolic variable.

The primary tools of the software are classification algorithms. Classifiers operate in two stages: first, model training occurs, and then prediction (see Fig. 5). This necessitates having a training dataset for which the label values are known. A potential source of labels can be information gathered from the system's operational history, in which case the data can be labelled. According to the no free lunch theory a classifier cannot be chosen directly, as its prediction quality can vary depending on the available data [4].

Dzięki zaimplementowanej sekcji zainteresowań, we współpracy z modułem klasyfikacji treści oraz modułem oceny treści, to system dobierał użytkownikom materiały poddawane ocenie. Zebrane dane wykorzystano na etapie uczenia modułu klasyfikacji treści opartego na sztucznej inteligencji.

### Metody uczenia maszynowego zastosowane do wspomagania klasyfikacji treści dezinformacyjnych

W typowych zagadnieniach uczenia maszynowego wyróżnia się dwie podstawowe grupy problemów: uczenie nienadzorowane oraz uczenie nadzorowane. W przypadku uczenia nadzorowanego wyróżnia się dwa tryby pracy modeli: uczenie oraz predykcja. W pierwszym następuje uczenie modelu, a w drugim jego zastosowanie. W uczeniu nadzorowanym, na etapie uczenia modelu, następuje dobór parametrów funkcji zapewniającej odwzorowanie, przy czym zarówno wartości wyjściowe  $y$  (zwane również etykietami), jak i wartości  $x$  są znane. W trakcie predykcji model na podstawie wartości  $x$  automatycznie dokonuje odwzorowania na pożądaną wartość wyniku –  $y$ . W zależności od charakteru wartości  $y$  można mówić o problemie regresji, gdy  $y$  ma postać wartości numerycznej lub klasyfikacji, gdy  $y$  ma postać zmiennej symbolicznej.

Podstawowym narzędziem oprogramowania są algorytmy klasyfikacji. Klasyfikatory działają dwuetapowo, tj. w pierwszym etapie następuje uczenie modelu, a w drugim – predykcja (zob. ryc. 5). Determinuje to konieczność posiadania zbioru uczącego, dla którego wartości etykiety będą znane. Potencjalnym źródłem etykiet mogą być informacje zebrane z historii eksploatacyjnej systemu, wówczas dane mogą zostać poetykietowane. Zgodnie z twierdzeniem *no free lunch* nie można bezpośrednio wybrać klasyfikatora, gdyż w zależności od dostępnych danych różne klasyfikatory mogą cechować się różną jakością predykcji [4].

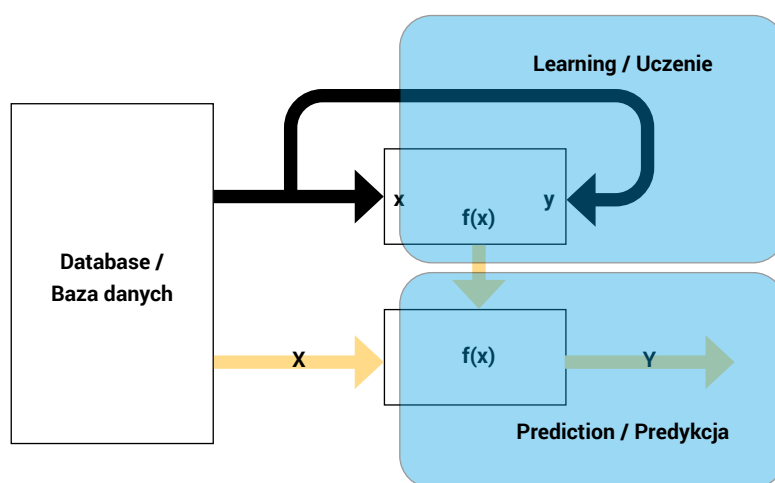


Figure 5. Illustrative diagram of the relationship between learning and prediction processes  
Rycina 5. Poglądowy schemat związku procesów uczenia i predykcji

Source: Own elaboration.

Źródło: Opracowanie własne.

The principle described above stems from the fact that classifiers typically operate using various forms of internal representation of extracted knowledge and different methods for acquiring it. Among the basic classifiers, the following should be mentioned:


- minimum-distance classifiers,
- neural networks,
- decision trees,
- kernel-based methods.

In the presented system, neural networks were used to implement the content classifier. They are currently very popular methods for building predictive models. Their operation is based on constructing a network of simple processing elements called neurons, each of which has a group of inputs and a single output. The input-to-output mapping is achieved through a nonlinear and differentiable function. Among the extensive group of neural networks, the most popular are feedforward networks, where the output of one group (layer) of neurons is passed to the input of the next layer. Such a network structure allows for its training using the backpropagation algorithm. An important feature of neural networks is the great ease with which the cost function, used to determine the network's error level, can be manipulated. Thanks to this – depending on the requirements or the specifics and nature of the predictive problem – the error function can be adapted, which enables the incorporation of features such as different norms for the range of variability of the output value during the training process. This often allows the neural network to better reflect the desired system properties. For feedforward neural networks, the most popular form of a neuron for fully connected layers is a linear neuron with a sigmoidal nonlinear function, whose diagram is shown in Figure 6.

Opisana wyżej zasada wynika z tego, że klasyfikatory działają zwykle z wykorzystaniem różnych form wewnętrznej reprezentacji wydobytej wiedzy oraz różnych metod jej pozyskania. Wśród podstawowych klasyfikatorów należy wymienić:

- klasyfikatory minimalno-odległościowe,
- sieci neuronowe,
- drzewa decyzyjne,
- metody bazujące na funkcjach jądrowych,
- modele decyzyjne i komitety modeli.

W prezentowanym systemie do realizacji klasyfikatora treści użyto sieci neuronowych. Są one obecnie bardzo popularnymi metodami budowy modeli predykcyjnych. Ich działanie opiera się na zbudowaniu sieci prostych elementów przetwarzających, zwanych neuronami, z których każdy posiada pewną grupę wejść oraz jedno wyjście, a odwzorowanie wejścia do wyjścia realizowane jest przez nieliniową i różniczkowalną funkcję. Spośród bogatej grupy sieci neuronowych najpopularniejszą stanowią tzw. sieci jednokierunkowe, w których wyjście jednej grupy (warstwy) neuronów przekazywane jest na wejście kolejnej warstwy. Taka konstrukcja sieci pozwala na jej uczenie z wykorzystaniem algorytmu wstecznej propagacji błędów. Ważną cechą sieci neuronowych jest duża łatwość manipulacji funkcji kosztu wykorzystywanej do określenia poziomu błędów sieci. Dzięki temu – w zależności od wymagań lub też specyfiki i charakteru problemu predykcyjnego – można dokonać adaptacji funkcji błędów, co umożliwia uwzględnienie w procesie uczenia takich cech, jak np. różne normy zakresu zmienności wartości wyjściowej. Powoduje to, że często sieć neuronowa jest w stanie lepiej odzwierciedlić pożądane właściwości systemu. W przypadku sieci neuronowych jednokierunkowych najbardziej popularną postacią neuronu dla warstw w pełni połączonych (ang. *fully connected*) jest neuron liniowy z sigmoidalną funkcją nieliniową, którego schemat przedstawiono na rycinie 6.



**Figure 6.** Structure of a neuron  
**Rycina 6.** Budowa neuronu

Source: Own elaboration.  
Źródło: Opracowanie własne.

The sigmoidal function has the following form:

$$f(z) = \frac{1}{1 + \exp(-\beta z)} \quad (4)$$

Sigmoidalna funkcja ma następującą postać:

$$f(z) = \frac{1}{1 + \exp(-\beta z)} \quad (4)$$

The disadvantage of this solution is the problem of the fading gradient, so ReLu-type neurons with an activation function of the form are a frequently used alternative:

$$f(z) = \max(0, x) \quad (5)$$

or a soft approximation of the above functions providing differentiability in the form:

$$f(z) = (1 + e^x) \quad (6)$$

The extended classification model was based on a five-layer feedforward neural network, including one input layer, three hidden layers, and one output layer. The input layer accepted a feature vector describing text properties and record attributes for the represented text. These included, among others, the Flesch Reading Ease index, FOG index, Pisarek Index, word count, sentence length, and other measures of linguistic and contextual complexity. Input parameters also included text type, publisher, information source, and review information. The hidden layers used 128, 64, and 32 neurons respectively, each employing a ReLU (Rectified Linear Unit) activation function. This ensured nonlinear processing and robustness against the vanishing gradient problem. Increasing the network's depth allowed for better capture of complex dependencies between input variables and enhanced the model's representational power. The output layer contained a single neuron with a sigmoid activation function, enabling the output to be interpreted as the probability of a given sample belonging to the "disinformation" class. The model was implemented using the TensorFlow library with the high-level Keras API, which allows for flexible construction and training of deep learning models. For optimization, binary cross-entropy was used as the loss function, along with the Adam optimizer, which dynamically adjusts learning rates based on gradients. Training was conducted in batches of 32 samples (batch size = 32), allowing for efficient weight updates while maintaining the stability of the learning process. The model was trained for 200 epochs, deliberately omitting the early stopping mechanism to allow for observation of the full training process and analysis of changes in performance metrics (precision, recall, F1-score) over time. This network architecture allowed for better mapping of complex linguistic structures in informational texts and increased the model's effectiveness in detecting disinformation content. The neural network training process was conducted using the system. Testing of the classification model was performed using a separate test set (20% of the total dataset), which was not used in the training process. The purpose of this procedure was an independent evaluation of the model's generalization ability, i.e. its effectiveness in classifying previously unseen data. Comparing the results obtained on the training and test sets allowed for the identification of potential overfitting issues and an assessment of model stability. The analysed metrics – precision, recall, and F1-score – showed similar values for both sets, indicating a good model fit and its ability to maintain high effectiveness even outside the training set. Additionally, a high AUC (Area Under the Curve) of the ROC (Receiver Operating Characteristic) curve confirmed the classifier's effectiveness in distinguishing cases belonging to different classes. The obtained results indicate that the adopted model architecture

Wadą takiego rozwiązania jest problem zanikającego gradientu, dlatego też często stosowaną alternatywą są neurony typu ReLu z funkcją aktywacji w postaci:

$$f(z) = \max(0, x) \quad (5)$$

lub też miękka aproksymacja powyższej funkcji zapewniająca różniczkowalność w postaci:

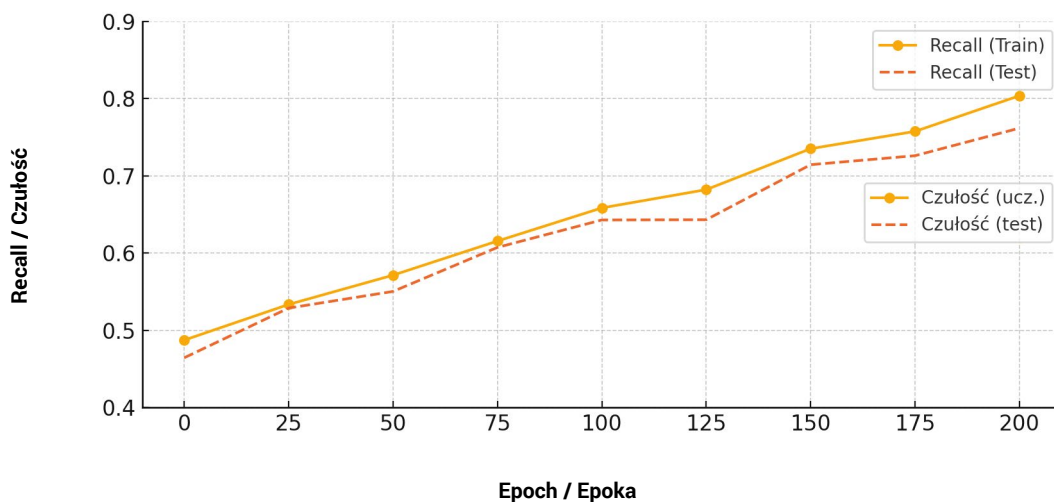
$$f(z) = (1 + e^x) \quad (6)$$

Rozbudowany model klasyfikacyjny oparto na pięciowarstwowej sieci neuronowej typu *feedforward*, w której uwzględniono jedną warstwę wejściową, trzy warstwy ukryte oraz jedną warstwę wyjściową. Warstwa wejściowa przyjmowała wektor cech opisujących właściwości tekstu oraz atrybutów rekordu dla reprezentowanego tekstu. Są to m.in. indeks Flescha, wskaźnik FOG, indeks Pisarka, liczba słów, długość zdań oraz inne miary złożoności językowej i kontekstowej. Jako parametry wejściowe uwzględniono również m.in. rodzaj tekstu, wydawcę, źródło informacji i informację o recenzji. W warstwach ukrytych zastosowano odpowiednio 128, 64 i 32 neurony, z których każdy wykorzystywał funkcję aktywacji ReLU (ang. *Rectified Linear Unit*), zapewniającą nieliniowość przetwarzania i odporność na problem zanikającego gradientu. Zwiększenie głębokości sieci pozwoliło na lepsze uchwycenie złożonych zależności między zmiennymi wejściowymi oraz zwiększenie reprezentacyjności modelu. Warstwa wyjściowa zawierała jeden neuron z funkcją aktywacji sigmoidalnej, umożliwiającą interpretację wyjścia jako prawdopodobieństwa przynależności danej próbki do klasy „dezinformacja”. Model zaimplementowano z użyciem biblioteki TensorFlow z wykorzystaniem wysokopoziomowego interfejsu Keras, który umożliwia elastyczne konstruowanie i trenowanie modeli głębokiego uczenia. Do optymalizacji wykorzystano funkcję straty binary cross-entropy oraz algorytm Adam, który dostosowuje współczynniki uczenia dynamicznie w zależności od gradientów. Trening przeprowadzono w partiach po 32 próbki (ang. *batch size = 32*), co pozwalało na wydajną aktualizację wag modelu przy zachowaniu stabilności procesu uczenia. Model uczono przez 200 epok, celowo rezygnując z mechanizmu wczesnego zatrzymania (ang. *early stopping*), aby umożliwić obserwację pełnego przebiegu procesu uczenia i analizę zmian metryk skuteczności (precyzji, czułości, F1) w czasie. Taka konstrukcja sieci pozwoliła na lepsze odwzorowanie złożonych struktur językowych w tekstach informacyjnych i zwiększyła efektywność modelu w detekcji treści dezinformacyjnych. Przy pomocy systemu przeprowadzono proces uczenia sieci neuronowej. Testowanie modelu klasyfikacyjnego przeprowadzono z wykorzystaniem wyodrębnionego zbioru testowego (20% całkowitego zbioru danych), który nie był wykorzystywany w procesie uczenia. Celem tej procedury była niezależna ocena zdolności modelu do generalizacji, czyli skutecznego klasyfikowania wcześniej nieznanymi danych. Porównanie wyników uzyskanych na zbiorze uczącym oraz testowym pozwoliło na identyfikację potencjalnych problemów przeuczenia (ang. *overfitting*), a także na ocenę stabilności modelu. Analizowane metryki – precyzja, czułość oraz miara F1 – wykazały podobne wartości dla obu zbiorów, co świadczy o dobrym dopasowaniu modelu oraz jego zdolności do zachowania wysokiej

and training procedure allow for the development of an effective tool for detecting disinformation content.

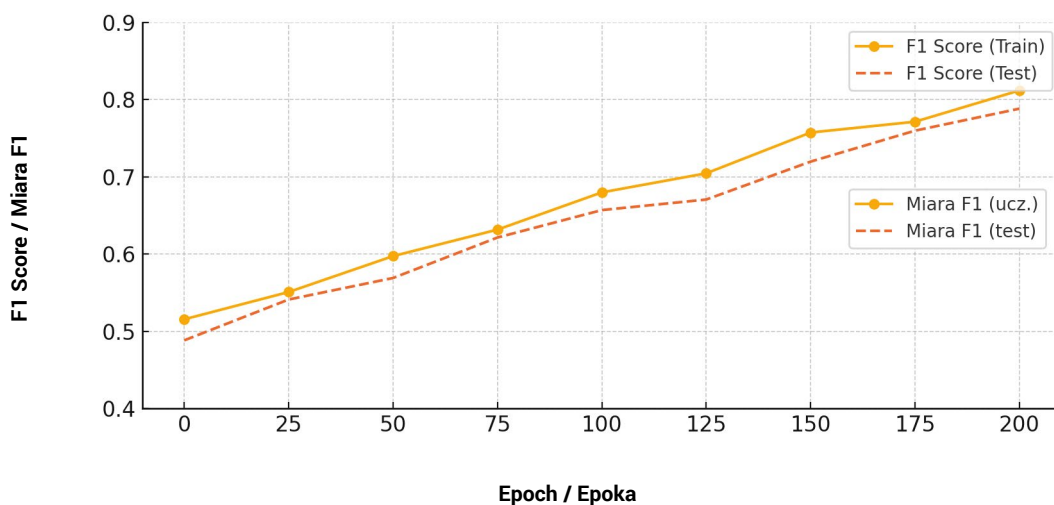
skuteczności, także poza zbiorem treningowym. Dodatkowo wysoka wartość AUC krzywej ROC potwierdziła skuteczność klasyfikatora w rozróżnianiu przypadków należących do różnych klas. Otrzymane rezultaty wskazują, że zastosowana architektura modelu oraz procedura uczenia pozwalają na budowę efektywnego narzędzia do detekcji treści dezinformacyjnych.

**Recall: Train vs Test / Czułość: Zbiór uczący vs testowy**

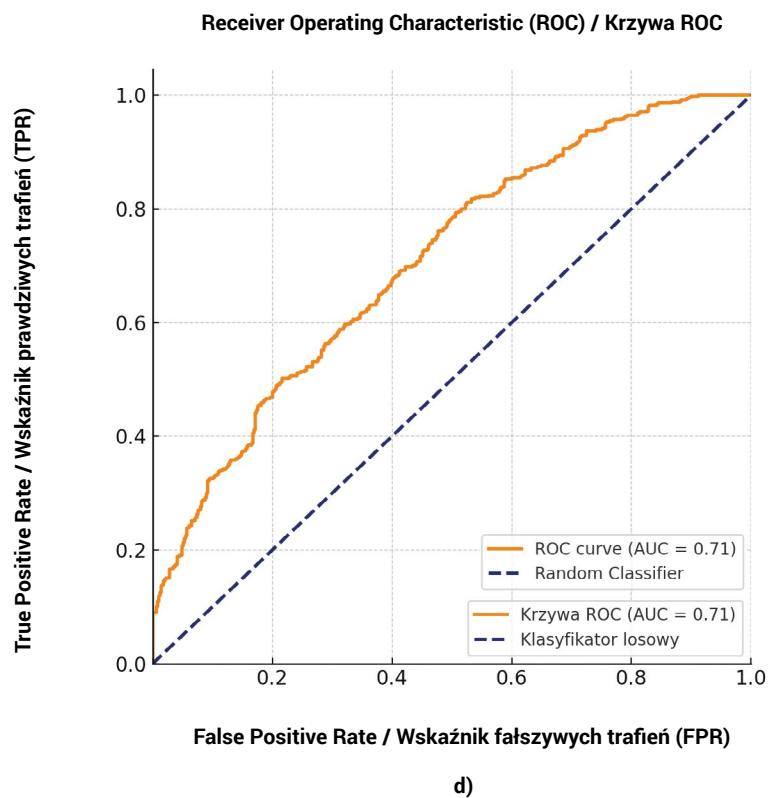
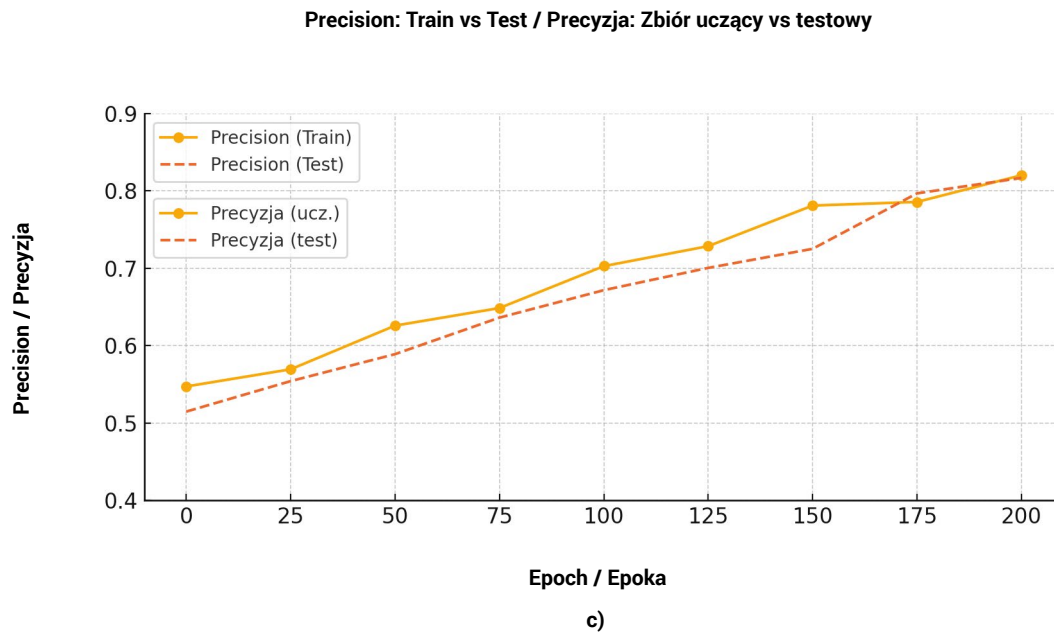


a)

**F1 Score: Train vs Test / Miara F1: Zbiór uczący vs testowy**



b)



**Figure 7.** Values of statistical measures for the evaluation of the neural network model: a) czułość b) miara F1 c) precyzja d) krzywa ROC  
**Rycina 7.** Wartości miar statystycznych oceny modelu sieci neuronowej: a) recall, b) F1 score, c) precyzja, d) receiver operating characteristic  
**Source:** Own elaboration.  
**Źródło:** Opracowanie własne.

The performance results of the classification model are presented in Figure 7, which contains graphs illustrating the variability of effectiveness metrics across successive training epochs.

Wyniki działania modelu klasyfikacyjnego zaprezentowano na rycinie 7 zawierającej wykresy przedstawiające zmienność metryk skuteczności w kolejnych epokach uczenia. Analizie poddano trzy

Three key measures were analysed: precision, recall, and F1-score, differentiated for both the training and test sets. On the precision graph (see Fig. 7c), a systematic increase in this metric's value can be observed as epochs progress. Initially, the model's precision was relatively low (around 0.55 for the training set and 0.50 for the test set), indicating a high proportion of false positive classifications. As the model learned, precision increased, reaching values oscillating around 0.83 for the training set and 0.81 for the test set. This trend demonstrates the model's ability to identify positive cases more accurately over time. For recall (see Fig. 7a), which is the model's ability to detect actual positive cases, a similar dynamic was observed – initial values at 0.48–0.50 systematically increased, reaching approximately 0.78 for the test set in the final training phase. The relatively small differences between the training and test sets suggest good model generalization and a minor impact of overfitting. The F1-score (see Fig. 7b), being the harmonic mean of precision and recall, also shows a positive upward trend. The final values of this metric (around 0.80 for the test set) indicate a balanced effectiveness of the classifier, both in reducing false alarms and detecting actual cases of disinformation. Finally, the ROC curve (see Fig. 7d) illustrates the relationship between the false positive rate and the true positive rate. An Area Under the Curve (AUC) of 0.80 indicates good classification ability – the model effectively distinguishes between cases belonging to the two classes, significantly outperforming a random classifier (dashed line).

podstawowe miary: precyzję, czułość (ang. *recall*) oraz miarę F1, z rozróżnieniem na zbiór uczący i testowy. Na wykresie precyzji (zob. ryc. 7c) zaobserwować można systematyczny wzrost wartości tej metryki w miarę postępujących epok. Początkowo precyzja modelu była stosunkowo niska (ok. 0,55 dla zbioru uczącego i 0,50 dla testowego), co oznaczało duży odsetek fałszywie pozytywnych klasyfikacji. W miarę uczenia się modelu precyzja rosła, osiągając wartości oscylujące wokół 0,83 dla zbioru uczącego i 0,81 dla testowego. Taka tendencja świadczy o zdolności modelu do coraz trafniejszego identyfikowania pozytywnych przypadków. W przypadku czułości (zob. ryc. 7a), czyli zdolności modelu do wykrywania rzeczywistych przypadków pozytywnych, zaobserwowano podobną dynamikę – wartości początkowe na poziomie 0,48–0,50 wzrastały systematycznie, osiągając ok. 0,78 dla zbioru testowego w końcowej fazie uczenia. Relatywnie niewielkie różnice między zbiorami uczącym a testowym sugerują dobrą generalizację modelu i niewielki wpływ przeuczenia. Miara F1 (zob. ryc. 7b), będąca średnią harmoniczną precyzji i czułości, również pokazuje pozytywny trend wzrostowy. Ostateczne wartości tej miary (ok. 0,80 dla zbioru testowego) wskazują na zrównoważoną skuteczność klasyfikatora zarówno w zakresie ograniczania fałszywych alarmów, jak i wykrywania rzeczywistych przypadków dezinformacji. Wreszcie, krzywa ROC (zob. ryc. 7d) przedstawia relację między wskaźnikiem fałszywych trafień (ang. *false positive rate*) a prawdziwych trafień (ang. *true positive rate*). Obszar pod krzywą ROC (AUC) wynoszący 0,80 świadczy o dobrej zdolności klasyfikacyjnej modelu – model skutecznie odróżnia przypadki należące do dwóch klas, znacznie przewyższając efektywność klasyfikatora losowego (linia przerywana).

## Characteristics of disinformation content on the basis of research conducted

The research was conducted at the WSB Academy in Dąbrowa Górnicza. It was divided into two rounds. The first research group of 218 people took part in the experiment between March and June 2018. The second group of 62 people was included in the study between September and December 2024. The characteristics of the people taking part in the study are shown in Table 1

## Cechy treści dezinformacyjnych na podstawie przeprowadzonych badań

Badania przeprowadzono w Akademii WSB w Dąbrowie Górniczej. Podzielono je na dwie tury. Pierwsza grupa badawcza licząca 218 osób wzięła udział w eksperymencie w okresie od marca do czerwca 2018 roku. Druga grupa, licząca 62 osoby, została włączona do badań w okresie od września do grudnia 2024 roku. Cechy osób biorących udział w badaniu przedstawiono w tabeli 1.

**Table 1.** Characteristics of the group of people taking part in the survey  
**Tabela 1.** Charakterystyka grupy osób biorących udział w ankiecie

Gender / Płeć	Women / Kobiety		Men / Mężczyźni	
Number of participants	145		135	
Education/ Wykształcenie	Primary / Podstawowe	Secondary / Średnie	Higher / Wyższe	
Number of participants / Liczba osób	2	179	99	
Age / Wiek	From 18 to 25 / Od 18 do 25 lat	From 26 to 35 / Od 26 do 35 lat	From 36 to 45 / Od 36 do 45	Over 45 / Powyżej 45 lat
Number of participants / Liczba osób	170	20	66	24

Source: Own elaboration.  
Źródło: Opracowanie własne.

In the literature, concepts such as disinformation, propaganda, and fake news are defined and distinguishable. Fake news refers to deliberately fabricated or misleading information presented as news to influence audiences – often for political, financial, or social purposes. It is characterized by its media form imitating authentic news (e.g. articles, videos, posts), but intentionally distorted to manipulate public opinion [5–6]. Disinformation is the deliberate creation and dissemination of false information with the intent to deceive the recipient. It is characterized by planning and strategy – it can contain false data, manipulations, or content taken out of context, often used in political, wartime, and ideological activities [5–8]. Propaganda is the systematic transmission of information – whether true or false – in a manipulative way, aimed at shaping the attitudes and beliefs of recipients in accordance with a specific political, ideological, or social goal. Unlike disinformation, propaganda does not have to be false; it can use persuasive and rhetorical techniques even with true facts [9–10].

For the purposes of the conducted research, false content related to disinformation, propaganda, and fake news, regardless of definitional differences, was treated as negative content. This content was jointly classified as harmful and marked in the constructed system's database with the value "false". The research utilized selected content present on news portal websites; however, to simplify the model, the origin of the information (whether it was initially a media report or originally from other forms of communication) was not evaluated. Research in this direction could yield additional conclusions, but it falls outside the primary objectives of the system being built. Participants in the study particularly emphasized the prevalence of fake news in the daily lives of every individual. From the moment they join the global community via the internet and use other forms of media, they become subject to the influence of disinformation.

The conducted research and the interviews with the participants made it possible to identify some common features of disinformation content:

### 1) Pervasiveness and Effectiveness of Fake News

The phenomenon of disinformation is sometimes attributed to the actions of individuals operating in various areas of social life, including those specializing in creating false narratives. At the same time, it is pointed out that their spread can result from the unintentional replication of content by recipients who have no ill intentions [11]. All research participants reported encountering fake news, indicating its pervasiveness as its most characteristic feature. Disinformation content is present in all social environments and communication channels – both traditional and digital. Its structure facilitates easy replication, which contributes to its effectiveness and rapid dissemination. The widespread nature of fake news is a consequence of the topicality of the issues it addresses [12].

### 2) Structure and Dissemination Mechanisms of Fake News

Fake news is crafted to reach a wide audience. It features catchy headlines that grab attention through shocking or definitively judgmental phrasing. The message relies heavily on

W literaturze przedmiotu pojęcia, takie jak dezinformacja, propaganda czy fake news, są definiowane i rozróżnialne. Fake news to celowo sfabrykowane lub wprowadzające w błąd informacje, które udają wiadomości, aby wywierać wpływ na odbiorców – często w celach politycznych, finansowych lub społecznych. Charakterystyczna jest forma medialna imitująca autentyczne wiadomości (np. artykuły, filmy, posty), ale zniekształcona intencjonalnie, aby manipulować opinią publiczną [5–6]. Dezinformacja to celowe tworzenie i rozpowszechnianie fałszywych informacji z intencją oszukania odbiorcy. Cechuje ją planowość i strategia – może zawierać fałszywe dane, manipulacje lub treści wyjęte z kontekstu, często używane w działaniach politycznych, wojennych i ideologicznych [5–8]. Propaganda to systematyczne przekazywanie informacji – prawdziwych lub fałszywych – w sposób manipulujący, mający na celu ukształtowanie postaw i przekonań odbiorców zgodnie z określonym celem politycznym, ideologicznym lub społecznym. W odróżnieniu od dezinformacji, propaganda nie musi być fałszywa – może używać technik perswazji i retoryki nawet przy prawdziwych faktach [9–10].

Na potrzeby przeprowadzonych badań nieprawdziwe treści związane z dezinformacją, propagandą i fake newsami, niezależnie od różnic wynikających z ich definicji, potraktowano jako treści negatywne, które zostały sklasyfikowane wspólnie jako szkodliwe i oznaczone w bazie danych konstruowanego systemu wartością „fałsz”. W przeprowadzonych badaniach wykorzystano wybrane treści obecne w Internecie na stronach webowych portali informacyjnych, jednak ze względu na uproszczenie modelu nie podjęto oceny źródła ich pochodzenia (czy była to początkowo wiadomość medialna, czy pierwotnie pochodząca z innych form przekazu). Badania w tym kierunku mogłyby przynieść dodatkowe wnioski, jednak wykraczają one poza główne cele konstruowanego systemu. Osoby biorące udział w przeprowadzonych badaniach zwracały szczególnie uwagę na powszechność występowania fake newsów w codzienności każdego człowieka, który od momentu włączenia się do społeczności globalnej poprzez sieć internetową i korzystanie z innych środków przekazu staje się podmiotem oddziaływania dezinformacji.

Przeprowadzone badania i wywiady z uczestnikami pozwoliły na wyodrębnienie pewnych wspólnych cech treści dezinformacyjnych:

### 1) Powszechność i skuteczność jako cechy fake newsów

Zjawisko dezinformacji bywa przypisywane działaniom jednostek funkcjonujących w różnych obszarach życia społecznego, w tym również specjalizujących się w tworzeniu fałszywych przekazów. Jednocześnie wskazuje się, że ich rozpowszechnianie może wynikać z nieświadomego powielania treści przez odbiorców, którzy nie mają złych intencji [11]. Wszyscy uczestnicy badań deklarowali styczność z fake newsami, wskazując powszechność jako ich najbardziej charakterystyczną cechę. Treści dezinformacyjne są obecne we wszystkich środowiskach społecznych oraz kanałach komunikacji – zarówno tradycyjnych, jak i cyfrowych. Ich struktura sprzyja łatwemu powielaniu, co wpływa na ich skuteczność i szybkie rozprzestrzenianie się. Powszechność fake newsów pozostaje konsekwencją aktualności poruszanych tematów [12].

emotional content and often highlights controversial issues. The content might include visual materials taken from other contexts or the past, yet, upon a cursory glance, appear credible. The simple form of the message facilitates its immediate distribution, enabling easy and rapid sharing. Due to the sensational or captivating nature of the content, audiences are more likely to further disseminate it [13].

### 3) Falsity and Manipulative Nature of the Message

Fake news consists of content deliberately manipulated for the purpose of disinformation, eliciting emotions, or shaping specific social attitudes. It often contains elements of true information that are, however, distorted through manipulation. Respondents equated fake news with propaganda, imprecise information, rumours, and messages designed to create chaos. This type of content frequently reaches audiences who limit themselves to reading only headlines or summaries, without deeper analysis. In this communication model, the user becomes an uncritical recipient and an unwitting conveyor of disinformation. An analogy was also drawn between fake news and advertising, where fragments of truth are used to elicit a desired effect. Properly selected images and content can – despite their inauthenticity – create an illusion of credibility [14].

### 4) Thematic Scope of Fake News

The research was conducted during a period when the issue of disinformation predominantly revolved around the COVID-19 pandemic and the war in Ukraine (since 24 February 2022). These narratives dominated both traditional and digital media. For years, particularly exploited disinformation topics have also included politics and the public lives of well-known individuals. Beyond these consistent themes, fake news also addresses dynamic and current social phenomena – such as protests, economic decisions, and interest rate hikes – which attract attention due to their unusual nature. Cases of local disinformation are also observed. In addition to the political dimension, respondents highlighted the use of fake news for economic and ideological purposes. These indicated areas often intertwine, especially where political issues connect with worldviews and economic interests [15].

### 5) Goals of Creating False Information

The primary aim of producing and disseminating fake news is to achieve specific benefits, most often political or economic. Disinformation can take the form of propaganda, serving to win elections, shape public opinion, or persuade society to make particular decisions. Simultaneously, actions geared towards financial gain are observed, for instance, by generating “clickbait” to increase advertising revenue. False information is also sometimes used to distract from important events, incite fear, chaos, or antagonize society. For a recipient with limited information literacy, fake news can confirm their own beliefs without the need for verification or confrontation with differing viewpoints. The consequences of such actions are both individual (e.g. destroying the reputation of politicians or activists) and societal (e.g. increased polarization, hostility towards those with different views). While

### 2) Struktura i mechanizmy rozpowszechniania fake newsów

Fake newsy są konstruowane w sposób umożliwiający dotarcie do szerokiego grona odbiorców. Zawierają chwytliwe tytuły, które przyciągają uwagę poprzez szokujące lub jednoznacznie oceniające sformułowania. Przekaz opiera się na silnym nacechowaniu emocjonalnym i często eksponuje kontrowersyjne kwestie. Treści mogą zawierać materiały wizualne pochodzące z innych kontekstów lub przeszłości, a mimo to – w ocenie pobieżnej – wydają się wiarygodne. Prosta forma przekazu sprzyja jego natychmiastowej dystrybucji, umożliwiając łatwe i szybkie udostępnianie. Dzięki sensacyjnemu lub błyskotliwemu charakterowi treści, odbiorcy częściej decydują się na dalsze ich rozpowszechnianie [13].

### 3) Falszywość i manipulacyjny charakter przekazu

Fake newsy są treściami świadomie zmanipulowanymi w celu dezinformacji, wzbudzenia emocji lub ukształtowania określonych postaw społecznych. Zawierają elementy prawdziwych informacji, które jednak zostają wypaczone w wyniku manipulacji. W ocenie respondentów fake newsy utożsamiane są z propagandą, nieprecyzyjnymi informacjami, plotkami i przekazami wywołującymi chaos. Tego typu treści często trafiają do odbiorców, którzy ograniczają się jedynie do przeczytania nagłówków lub skrótów, bez głębszej analizy. W tym modelu komunikacji użytkownik staje się bezkrytycznym odbiorcą oraz nieświadomym przekaznikiem dezinformacji. Wskazywano również analogię między fake newsami a reklamą, w której wykorzystuje się fragmenty prawdy w celu wywołania oczekiwanego efektu. Właściwie dobrane obrazy i treści mogą – mimo swej nieautentyczności – stworzyć pozór wiarygodności [14].

### 4) Zakres tematyczny fake newsów

Badania prowadzone były w okresie, w którym problematyka dezinformacji koncentrowała się wokół pandemii COVID-19 oraz działań wojennych w Ukrainie (od 24 lutego 2022 roku). Przekazy te dominowały zarówno w mediach tradycyjnych, jak i cyfrowych. Od lat szczególnie eksploatowanymi tematami dezinformacyjnymi są również polityka oraz życie publiczne znanych osób. Oprócz tematów stałych, fake newsy dotyczą również dynamicznych i aktualnych zjawisk społecznych – takich jak protesty, decyzje ekonomiczne, podwyżki stóp procentowych – które przyciągają uwagę ze względu na swoją niecodzienność. Obserwowane są również przypadki dezinformacji lokalnej. Poza wymiarem politycznym, badani zwracali uwagę na wykorzystanie fake newsów do celów ekonomicznych oraz ideologicznych. Wskazane obszary wzajemnie się przenikają, szczególnie tam, gdzie kwestie polityczne łączą się ze światopoglądem i interesami gospodarczymi [15].

### 5) Cele tworzenia fałszywych informacji

Podstawowym celem produkcji i rozpowszechniania fake newsów jest osiągnięcie określonych korzyści – najczęściej politycznych lub ekonomicznych. Dezinformacja może przyjmować formę propagandy, służącej wygrananiu wyborów, ukształtowaniu opinii publicznej lub przekonaniu społeczeństwa do konkretnych decyzji. Równolegle obserwuje się działania nastawione

much fake news is created with the intention of causing division, it is worth noting that it can also lead to unintended effects, such as panic or a sense of threat. There have also been reported cases where exposure to disinformation resulted in a positive response from the recipient – for example, prompting them to verify information and independently seek knowledge. However, the deliberate manipulation of content, even to achieve a “positive” outcome, raises ethical concerns [16].

## Conclusion

The verification of online content confirmed the characteristics of fake news disinformation found in the aggregated database used during the research. It was simultaneously demonstrated that 100% protection against disinformation content does not exist. According to the authors, effective protection lies in adequately preparing users to receive content through education. Advanced technologies, such as neural networks, can assist in this by achieving quite good content evaluation results through training with appropriate, reliable examples. However, developing methods to protect users from disinformation requires not only advanced data processing technologies but also the knowledge of experts and authorities in specific thematic and problem areas. During the research presented in the study, a significant group of individuals willingly participated, confirming substantial interest in the topic of disinformation content. At the same time, the development of a user profile showed that no surveyed group was completely immune to disinformation, which is corroborated by literature reviews. An analysis of the actual dynamics of false information dissemination in social networks, presented in [2], shows the superior reach of fake news over truthful news. Research results in [17] indicate that even people with moderate political views can thoughtlessly share false content due to a lack of critical judgment regarding information. A comprehensive overview of the cognitive mechanisms that prevent the complete elimination of disinformation content is presented in [18]. Evidence that demographic and ideological factors only influence susceptibility to false information, but do not negate it, was demonstrated by Roozenbeek et al. in the “Journal of Risk Research” [19]. Experimental confirmation of the impossibility of completely eliminating disinformation was also shown in [20]. These examples indicate that even individuals with high digital and media literacy and advanced verification systems do not entirely eliminate the risk of misidentifying

na zysk finansowy, np. poprzez generowanie tzw. klikalności, której celem jest zwiększenie przychodów z reklam. Fałszywe informacje bywają także wykorzystywane do odwracania uwagi od ważnych wydarzeń, wzbudzania strachu, chaosu lub antagonizowania społeczeństwa. Dla odbiorcy o ograniczonych kompetencjach informacyjnych fake news może stanowić potwierdzenie własnych przekonań, bez potrzeby ich weryfikacji czy konfrontacji z odmiennymi poglądami. Konsekwencje tego typu działań mają charakter zarówno jednostkowy (np. niszczenie reputacji polityków lub aktywistów), jak i społeczny (np. wzrost polaryzacji, wrogość wobec osób o innych poglądach). Chociaż wiele fake newsów tworzonych jest z intencją wywoływania podziałów, należy zauważyć, że mogą one również prowadzić do niezamierzonych efektów, takich jak panika czy poczucie zagrożenia. Zgłaszano także przypadki, w których kontakt z dezinformacją skutkował pozytywną reakcją odbiorcy – np. skłonił go do weryfikacji informacji i samodzielnego poszukiwania wiedzy. Wątpliwości etyczne budzi jednak celowe manipulowanie treścią nawet dla osiągnięcia „pozytywnego” rezultatu [16].

## Podsumowanie

Przeprowadzona weryfikacja treści dostępnych w Internecie potwierdziła cechy treści dezinformacyjnych typu fake news zebranych w zagregowanej bazie danych użytej podczas badań. Wykazano jednocześnie, iż nie istnieje stuprocentowa ochrona przed treściami dezinformacyjnymi. Skutecznym zabezpieczeniem jest, zdaniem autorów, odpowiednie przygotowanie użytkowników do odbioru danej treści poprzez edukację. Pomóc mogą w tym zaawansowane technologie, takie jak sieci neuronowe, które przy pomocy odpowiednich miarodajnych przykładów mogą w procesie uczenia się osiągnąć dość dobre wyniki oceny treści. Wypracowanie metod ochrony użytkowników przed dezinformacją wymaga jednak korzystania nie tylko z zaawansowanych technologii przetwarzania danych, ale również z wiedzy ekspertów i autorytetów w poszczególnych obszarach tematycznych i problemowych. Podczas realizacji przedstawionych w opracowaniu badań zebrano znaczącą grupę osób, które chętnie w nich uczestniczyły. Jest to potwierdzenie znaczącego zainteresowania tematem treści dezinformacyjnych. Jednocześnie opracowanie profilu użytkownika pokazało, iż żadna grupa badanych nie była w pełni odporna na dezinformację, co potwierdzają badania literaturowe. Analiza rzeczywistej dynamiki rozprzestrzeniania się fałszywych informacji w sieciach społecznościowych przedstawiona w opracowaniu [2] pokazuje przewagę zasięgów fake newsów nad wiadomościami prawdziwymi. Wyniki badań w opracowaniu [17] wskazują, że nawet ludzie o umiarkowanych poglądach politycznych mogą bezrefleksyjnie udostępnić nieprawdziwe treści z powodu braku krytycznego osądu informacji. Kompleksowy przegląd mechanizmów poznawczych uniemożliwiających całkowite wyeliminowanie treści dezinformacyjnych został przedstawiony w pozycji [18]. Dowód, iż czynniki demograficzne i ideologiczne jedynie wpływają na podatność na nieprawdziwe przekazy, lecz jej nie znoszą, zaprezentowali w czasopiśmie „Journal of Risk Research” Roozenbeek i in. [19]. Eksperymentalne potwierdzenie braku możliwości

manipulation. This points to the ongoing necessity of improving systems for protection against false content. Modern systems to combat fake news, based on advanced artificial intelligence algorithms and semantic analysis, are finding increasing use in commercial areas – from marketing and reputation management, where they verify content in real time to protect advertising campaigns from dangerous contexts, to the financial sector, where they monitor the web for unverified leaks and market rumours that could affect share prices, to e-commerce, where accurate moderation of reviews and opinions can detect both artificially inflated competitor ratings and malicious brand attacks. Information platforms and content aggregators utilize cloud solutions for instant classification of materials for veracity, and dedicated e-learning modules teach employees to recognize manipulation techniques, enhancing their information hygiene. Thanks to such systems, which maintain the transparency of operations, companies gain customer trust. They also mitigate the risk of regulatory liability in industries sensitive to disinformation and optimize costs associated with manual fact-checking. All of these factors make investing in the fight against disinformation not a luxury, but a necessity for any organization concerned with its reputation and operational efficiency. There are a number of technical solutions available on the market designed to combat disinformation and fake news. Examples of such systems include:

- 1) Hoaxy – a tool developed by Indiana University that enables the visualization of disinformation spread on social media. The system analyses both the sources of false information and the mechanisms of its sharing by users on platforms like Twitter. Hoaxy not only identifies content considered untrue but also allows for comparison with content from verified fact-checking services, such as Snopes or PolitiFact. A key function of the tool is to track information “pathways” and identify accounts playing a role in its dissemination [21].
- 2) FakeNewsNet is a comprehensive research platform designed to provide reliable and up-to-date datasets for training algorithms to automatically detect fake news. The system combines data from web-published content with an analysis of linguistic features, metadata, and user interaction information on social media. FakeNewsNet also integrates verification data from professional fact-checking portals, creating a standardized environment for testing and comparing the effectiveness of various detection models [22].

Contemporary disinformation detection systems vary in their technical architecture, data source approaches, and content evaluation methods. This article describes a proprietary fake news detection system that stands out with its hybrid method, combining neural network-based classification with expert user evaluation. Compared to existing systems like Hoaxy and FakeNewsNet, this approach possesses unique features. Hoaxy focuses on analysing the spread of information on social media (primarily Twitter). Its main function is to track the flow of disinformation and verifying content using graph analysis. The system does not directly classify content as true or false but visualizes its sharing network and helps identify accounts influencing the diffusion of

całkowitego wyeliminowania dezinformacji ukazano również w opracowaniu [20]. Powyższe przykłady pokazują, iż nawet osoby o wysokich kompetencjach cyfrowych i medialnych oraz zaawansowane systemy weryfikacji nie eliminują całkowicie ryzyka błędnej identyfikacji manipulacji. Wskazuje to na dalszą konieczność udoskonalania systemów ochrony przed fałszywymi treściami. Nowoczesne systemy walki z fake newsami, oparte na zaawansowanych algorytmach sztucznej inteligencji i analizie semantycznej, znajdują coraz szersze zastosowanie w obszarach komercyjnych – od marketingu i zarządzania reputacją, gdzie w czasie rzeczywistym weryfikują treści, by chronić kampanie reklamowe przed niebezpiecznymi kontekstami, przez sektor finansowy, gdzie monitorują sieć pod kątem niezweryfikowanych przecieków i plotek rynkowych mogących wpływać na kursy akcji, aż po e-commerce, w którym trafna moderacja recenzji i opinii pozwala wykrywać zarówno sztucznie napompowane oceny konkurencji, jak i złośliwe ataki na markę. Platformy informacyjne i agregatory treści wykorzystują chmurowe rozwiązania do natychmiastowej klasyfikacji materiałów pod kątem prawdziwości, a dedykowane moduły e-learningowe uczące pracowników rozpoznawać techniki manipulacji wzmacniają ich higienę informacyjną. Dzięki takim systemom pozwalającym utrzymać transparentność działań firmy zyskują zaufanie klientów. Ograniczają również ryzyko odpowiedzialności regulacyjnej w branżach wrażliwych na dezinformację oraz optymalizują koszty związane z ręcznym sprawdzaniem faktów. Wszystko to czyni inwestycję w walkę z dezinformacją nie tyle luksusem, co koniecznością dla każdej organizacji dbającej o reputację i efektywność operacyjną. Na rynku istnieje szereg rozwiązań technicznych, których zadaniem jest walka z dezinformacją i fake newsami. Przykładem takich systemów są między innymi:

- 1) Hoaxy – narzędzie opracowane przez Indiana University, które umożliwia wizualizację rozprzestrzeniania się dezinformacji w mediach społecznościowych. System analizuje zarówno źródła fałszywych informacji, jak i mechanizmy ich udostępniania przez użytkowników platform takich jak Twitter. Hoaxy nie tylko identyfikuje treści uznawane za nieprawdziwe, ale również umożliwia porównanie ich z treściami pochodzącymi ze zweryfikowanych serwisów fact-checkingowych, takich jak Snopes czy PolitiFact. Kluczową funkcją narzędzia jest śledzenie „ścieżek” informacji i identyfikacja kont odgrywających rolę w ich rozpowszechnianiu [21].
- 2) FakeNewsNet to kompleksowa platforma badawcza, której celem jest udostępnienie wiarygodnych i aktualnych zbiorów danych umożliwiających trenowanie algorytmów do automatycznej detekcji fake newsów. System łączy dane z treści publikowanych w sieci z analizą cech lingwistycznych, metadanych oraz informacji o interakcjach użytkowników w mediach społecznościowych. FakeNewsNet integruje również dane weryfikacyjne z profesjonalnych portali fact-checkingowych, tworząc standaryzowane środowisko do testowania i porównywania skuteczności różnych modeli detekcji [22].

Współczesne systemy wykrywania dezinformacji różnią się zarówno pod względem architektury technicznej, jak i podejścia do źródeł danych oraz sposobu oceny treści. W prezentowanym

fake news [21]. In contrast, FakeNewsNet is a research platform that integrates article content, social context, and temporal and geographical data [22]. Its dataset is derived from fact-checking portals (GossipCop, PolitiFact), aiming to enable model training in a supervised environment. FakeNewsNet also includes information on community reactions (e.g., likes, comments), which serve as auxiliary features in classification. The proprietary system presented in this article introduces a different approach to content evaluation. It includes text classification using linguistic complexity indicators (FOG, Pisarek, Flesch), neural network-based analysis, and the integration of subjective user ratings that consider their knowledge level and specialization. Key elements also include dynamic user profiling, content selection for evaluation based on interests, and a balanced rating scale. Unlike Hoaxy, which focuses on network analysis, and FakeNewsNet, which focuses on training models on static data, this hybrid system utilizes dynamic and multilayered data, combining artificial intelligence with expert judgment. Additionally, it enables the evaluation of information quality by leveraging context and linguistic difficulty, which represents a new contribution to the field of fake news detection. In summary, the presented system offers significant flexibility, adaptability to specific users, and a complex approach to content evaluation.

artykule opisano autorski system detekcji fake newsów, który wyróżnia się hybrydową metodą łączącą klasyfikację opartą na sieciach neuronowych oraz ocenę ekspercką użytkowników. W porównaniu z istniejącymi systemami, takimi jak Hoaxy i FakeNewsNet, podejście to posiada unikalne cechy. Hoaxy skupia się na analizie rozpowszechniania informacji w mediach społecznościowych (głównie na Twitterze). Jego główną funkcją jest śledzenie przepływu dezinformacji i treści weryfikujących, przy użyciu analizy grafów. System nie wykonuje bezpośredniej klasyfikacji treści jako prawdziwych lub fałszywych, lecz wizualizuje sieć ich udostępniania i pozwala zidentyfikować konta, które mają wpływ na dyfuzję fake newsów. Z kolei FakeNewsNet to platforma badawcza integrująca treści artykułów, kontekst społeczny oraz dane czasowe i geograficzne. Tworzony zbiór danych pochodzi z portali fact-checkingowych (GossipCop, PolitiFact), a jego celem jest umożliwienie trenowania modeli detekcji w środowisku nadzorowanym. FakeNewsNet zawiera także informacje o reakcjach społeczności (np. polubienia, komentarze), które służą jako cechy pomocnicze w klasyfikacji. Autorski system przedstawiony w artykule wprowadza odmienne podejście do oceny treści. Obejmuje on klasyfikację tekstów z wykorzystaniem wskaźników złożoności językowej (FOG, Pisarka, Flesch), analizę opartą na sieci neuronowej oraz integrację subiektywnych ocen użytkowników, które uwzględniają poziom ich wiedzy i specjalizacji. Kluczowym elementem jest również dynamiczne profilowanie użytkownika, dobór treści do oceny na podstawie zainteresowań oraz wyważona skala oceny. W przeciwieństwie do Hoaxy, który koncentruje się na analizie sieciowej, oraz FakeNewsNet, który skupia się na uczeniu modeli na statycznych danych, system hybrydowy wykorzystuje dane dynamiczne i wielowarstwowe, łącząc sztuczną inteligencję z osądem eksperckim. Dodatkowo umożliwia ocenę jakości informacji, wykorzystując kontekst i poziom trudności językowej, co stanowi nowy wkład w dziedzinę detekcji fake newsów. Podsumowując, prezentowany system oferuje znaczną elastyczność, możliwość dostosowania do konkretnego użytkownika oraz złożone podejście do oceny treści.

## Literature / Literatura

- [1] Allcott H., Gentzkow M., *Social Media and Fake News in the 2016 Election*, „Journal of Economic Perspectives” 2017, 31(2), 211–236, <https://doi.org/10.1257/jep.31.2.211>.
- [2] Vosoughi S., Roy D., Aral S., *The spread of true and false news online*, „Science” 2018, 359(6380), 1146–1151, <https://doi.org/10.1126/science.aap9559>.
- [3] Shu K., Sliva A., Wang S., Tang J., Liu H., *Fake News Detection on Social Media: A Data Mining Perspective*, „ACM SIGKDD Explorations Newsletter” 2017, 19(1), 22–36, <https://doi.org/10.1145/3137597.3137600>.
- [4] Goodfellow I., Bengio Y., Courville A., *Deep Learning*, MIT Press 2016.
- [5] Gelfert A., *Fake News: A Definition*, „Informal Logic” 2018, 38(1), 84–117, <https://doi.org/10.22329/IL.V38I1.5068>.
- [6] Morelli M., Grignolio A., Tamietto M., *Why is fake news so fascinating to the brain?*, „European Journal of Neuroscience” 2022, 56, 6961–6971, <https://doi.org/10.1111/ejn.15844>.
- [7] Theofilos M., *Disinformation: more than fake news*, „Moldoscopia” 2022, 2(97), 145–152, [https://doi.org/10.52388/1812-2566.2022.2\(97\).14](https://doi.org/10.52388/1812-2566.2022.2(97).14).
- [8] Araujo J., Barredo-Ibáñez D., Wihbey J., *Beyond Fake News and Fact-Checking: A Special Issue to Understand the Political, Social and Technological Consequences of the Battle against Misinformation and Disinformation*, „Journalism and Media” 2022, 3(2), 254–256, <https://doi.org/10.3390/journalmedia3020019>.
- [9] Hamilton K., *Towards an Ontology for Propaganda Detection in News Articles*, „The Semantic Web: ESWC 2021 Satellite Events – Lecture Notes in Computer Science” 2021, 12739,

- 230–241, [https://doi.org/10.1007/978-3-030-80418-3\\_35](https://doi.org/10.1007/978-3-030-80418-3_35).
- [10] Boyd-Barrett O., *Fake news and 'RussiaGate' discourses: Propaganda in the post-truth era*, „Journalism” 2019, 20(1), 87–91, <https://doi.org/10.1177/1464884918788323>.
- [11] Zhou X., Zafarani R., *A Survey of Fake News: Fundamental Theories, Detection Methods, and Opportunities*, „ACM Computing Surveys (CSUR)” 2020, 53(5), 1–40, <https://doi.org/10.1145/3395046>.
- [12] Floridi L., *Fake news and a 400-year-old problem: We need to resolve the “epistemic crisis”*, „The Guardian” 2016.
- [13] Gorwa R., Guilbeault D., *Unpacking the Social Media Bot: A Typology to Guide Research and Policy*, „Policy & Internet” 2020, 12(2), 225–248, <https://doi.org/10.1002/poi3.210>.
- [14] Pennycook G., Rand D.G., *The Implied Truth Effect: Attaching Warnings to a Subset of Fake News Stories Increases Perceived Accuracy of Stories Without Warnings*, „Management Science” 2019, 66(11), 4944–4957, <https://doi.org/10.1287/mnsc.2019.3478>.
- [15] Nguyen V.-T., Sugiyama K., Nakov P., Kan M.-Y., FANG: *Leveraging Social Context for Fake News Detection Using Graph Representation*, w: *Proceedings of the 29th ACM International Conference on Information & Knowledge Management (CIKM)* 2020, 1165–1174, <https://doi.org/10.1145/3340531.3411981>.
- [16] Pennycook G., Rand D.G., *Lazy, not biased: Susceptibility to partisan fake news is better explained by lack of reasoning than by motivated reasoning*, „Cognition” 2019, 188, 39–50, <https://doi.org/10.1016/j.cognition.2018.06.011>.
- [17] Lewandowsky S., Ecker U.K.H., Cook J., *Beyond misinformation: Understanding and coping with the “post-truth” era*, „Journal of Applied Research in Memory and Cognition” 2017, 6(4), 353–369, <https://doi.org/10.1016/j.jarmac.2017.07.008>.
- [18] Flynn D.J., Nyhan B., Reifler J., *The nature and origins of misperceptions: Understanding false and unsupported beliefs about politics*, „Political Psychology” 2017, 38(S1), 127–150, <https://doi.org/10.1111/pops.12394>.
- [19] Roozenbeek J., van der Linden S., *The fake news game: actively inoculating against the risk of misinformation*, „Journal of Risk Research” 2018, 22(5), 570–580, <https://doi.org/10.1080/13669877.2018.1443491>.
- [20] Pennycook G., McPhetres J., Zhang Y., Lu J.G., Rand D.G., *Fighting COVID-19 Misinformation on Social Media: Experimental Evidence for a Scalable Accuracy-Nudge Intervention*, „Psychological Science” 2020, 31(7), 770–780, <https://doi.org/10.1177/0956797620939054>.
- [21] Shao C., Ciampaglia G., Flammini A., Menczer F., *Hoaxy: A Platform for Tracking Online Misinformation*, w: *WWW '16 Companion: Proceedings of the 25th International Conference Companion on World Wide Web* 2016, 745–750, <https://doi.org/10.1145/2872518.2890098>.
- [22] Shu K., Mahudeswaran D., Wang S., Lee D., Liu H., *FakeNewsNet: A Data Repository with News Content, Social Context and Spatial-temporal Information for Studying Fake News on Social Media*, arXiv 2018, <https://doi.org/10.48550/arXiv.1809.01286>.

**PAWEŁ BUCHWALD, PH.D. ENG.** – specialist in the area of IT and ICT systems security engineering, research and teaching employee of the WSB Academy in Dąbrowa Górnicza and deputy head of the Department of Transport and Information Technology. He is a lecturer who teaches at the WSB Academy and the Silesian University of Technology, where he shares his knowledge of modern information technology. His research interests include ICT systems security engineering, distributed data processing and acquisition systems, computer graphics, as well as mobile device applications and computer management systems. He works actively with IT companies in the areas of design, implementation and deployment of modern software for business, industry and education.

**KAROL JĘDRASIAK, PH.D.** – academic teacher, didactician and manager, author of over 88 scientific publications, including 3 scientific monographs with high citability. The author’s scientific experience includes participation in 26 research and development projects, also as a manager. Active participant in more than 30 scientific conferences and symposia. Expert of the WSL2014-2020 ROP, member of the Steering Committee of the Game INN Sector Program and the Society for Image Processing. As a result of his previous work and cooperation with industry, he participated in the development of 32 claims of intellectual property rights (6 granted patents, 8 patent applications, 18 design registration rights). Specialist in computer

**DR INŻ. PAWEŁ BUCHWALD** – specjalista w dziedzinie informatyki i inżynierii bezpieczeństwa systemów teleinformatycznych, pracownik naukowo-dydaktyczny Akademii WSB w Dąbrowie Górniczej oraz zastępca kierownika Katedry Transportu i Informatyki. Jest wykładowcą prowadzącym zajęcia w Akademii WSB i Politechnice Śląskiej, gdzie dzieli się swoją wiedzą z zakresu nowoczesnych technologii informatycznych. Jego zainteresowania naukowe obejmują inżynierię bezpieczeństwa systemów teleinformatycznych, rozproszone systemy przetwarzania i akwizycji danych, grafikę komputerową, a także zastosowanie urządzeń mobilnych i komputerowe systemy zarządzania. Współpracuje aktywnie z firmami z branży IT w obszarach projektowania, implementacji i wdrażania nowoczesnego oprogramowania dla biznesu, przemysłu i edukacji.

**DR INŻ. KAROL JĘDRASIAK** – pracownik akademicki, dydaktyk i menadżer, autor ponad 88 publikacji naukowych, w tym trzech monografii naukowych, o wysokiej cytowalności. Jego doświadczenie naukowe obejmuje udział w 26 projektach badawczo-rozwojowych, w tym w charakterze kierownika projektu. Aktywny uczestnik w ponad 30 konferencjach i sympozjach. Ekspert RPO WSL/POIR, członek Komitetu Sterującego Programu Sektorowego GameINN, członkiem Towarzystwa Przetwarzania Obrazów. W rezultacie dotychczasowej pracy oraz współpracy z przemysłem powstało 32 zastrzeżeń prawa własności intelektualnej (6 przyznanych patentów, 8 zgł. patentowych, 18 praw z rejestracji wzoru przemysłowego). Specjalista

vision, computer graphics, artificial intelligence tools, computer, database and sensor system development. Since 2008, he has held management positions in private companies. For many years he was CEO of VR Technology, a company developing algorithms in the area of data analysis, commercializing innovative solutions in virtual reality technology and simulation as well as coaching systems. In 2024, he was awarded the Medal of the National Education Commission and a certificate of appreciation for his exceptional contribution to the successful implementation of the “e-Instructor Certification Programme” by NATO Assistant Secretary General for Operations Tom Goffus.

w zakresie wizji komputerowej, wirtualnej rzeczywistości, narzędzi sztucznej inteligencji, wytwarzania systemów informatycznych, bazodanowych i sensorycznych. Od 2008 piastował stanowiska kierownicze w przedsiębiorstwach prywatnych. Przez wiele lat był Prezesem Zarządu spółki VRTechnology zajmującej się opracowywaniem algorytmów z zakresu analizy danych oraz komercjalizacją innowacyjnych rozwiązań z zakresu technologii wirtualnej rzeczywistości oraz profesjonalnych systemów symulacyjnych i trenażerowych. W 2024 został uhonorowany Medalem Komisji Edukacji Narodowej oraz certyfikatem uznania za wyjątkowy wkład w pomyślną realizację „Programu Certyfikacji e-Instruktorów”, nadanym przez Asystenta Sekretarza Generalnego NATO ds. Operacji Toma Goffusa.