

**Jarosław Chodak
Kamil Filipek**

**Generatywna
sztuczna
inteligencja
(Gen AI)
w badaniach
naukowych**

Wydawnictwo
Uniwersytetu Marii Curie-Skłodowskiej



UMCS

CENTRUM SZTUCZNEJ INTELIGENCJI
I MODELOWANIA KOMPUTEROWEGO

Dariah.lab

Generatywna sztuczna inteligencja (Gen AI) w badaniach naukowych



https://analytics.umcs.pl/narzedzia_ai

Recenzent

dr hab. inż. Arkadiusz Gola, Profesor Politechniki Lubelskiej

Projekt okładki

Krzysztof Trojnar

Skład i łamanie

Jarosław Chodak

Grafika na okładce została wygenerowana za pomocą modelu sztucznej inteligencji DALL-E 3

© Wydawnictwo UMCS, Lublin 2025

ISBN 978-83-227-9891-1

Wydawnictwo Uniwersytetu Marii Curie-Skłodowskiej

ul. Idziego Radziszewskiego 11, 20-031 Lublin

tel. 81 537 53 04

www.wydawnictwo.umcs.eu

e-mail: wydawnictwo_sekretariat@mail.umcs.pl

Dział Handlowy

tel./faks 81 537 53 02

Księgarnia internetowa: www.wydawnictwo.umcs.eu

e-mail: wydawnictwo@umcs.eu

Druk i oprawa

Mazowieckie Centrum Poligrafii Sp. z o.o.

ul. Lisi Jar 29, 05-270 Marki

Wydawnictwo Uniwersytetu Marii Curie-Skłodowskiej

Lublin 2025

GEN AI w badaniach naukowych

Debiut ChatGPT pod koniec 2022 roku zapoczątkował dynamiczny rozwój rozwiązań opartych na metodach sztucznej inteligencji, dedykowanych dla sektora nauki. Na rynku pojawiły się rozmaite narzędzia, wspierające pracę zarówno z danymi ilościowymi, jak i jakościowymi, obejmującymi tekst, dźwięk oraz obraz. Złożony ekosystem cechuje się szybką ewolucją, płynnymi granicami między aplikacjami i zmiennymi obszarami zastosowań. Obok ChatGPT, bardzo szybko rozwijają się uniwersalne systemy dialogowe takie jak Claude, Gemini, Perplexity, Cohere, DeepSeek czy Grok, ale również bardziej wyspecjalizowane narzędzia takie jak STORM, NotebookLM czy Elicit. Dynamiczny rozwój sztucznej inteligencji sprawia, że codzienna praca badaczy i instytucji akademickich na całym świecie ulega radykalnej transformacji.

Narzędzia AI otwierają nowe możliwości, umożliwiając analizę ogromnych zbiorów danych, automatyzację przeglądów literatury, generowanie hipotez, a nawet wspomaganie w procesie projektowania eksperymentów. Modele takie jak Claude, Gemini czy Llama oferują zaawansowane funkcje przetwarzania języka naturalnego, analizy obrazów i generowania kodu, które mogą znacząco przyspieszyć i ułatwić pracę naukowców w różnych dziedzinach, od biologii i nauk społecznych, po fizykę i informatykę.

Uprawianie nauki w warunkach szybkiego rozwoju sztucznej inteligencji, wymaga nie tylko szybkiego przyswajania wiedzy i ciągłej adaptacji do dynamicznie zmieniającego się środowiska

technologicznego, ale także zdolności do krytycznej oceny zarówno narzędzi, jak i wyników generowanych przez rozwiązania oparte na metodach sztucznej inteligencji. W kontekście nauki, bardzo ważne jest również odpowiedzialne i świadome wykorzystanie dostępnych technologii w procesie badawczym. Zamiast być jedynie wykonawcą eksperymentów i analiz, naukowcy stają się kuratorami i interpretatorami wyników generowanych przez AI. Kluczowa staje się umiejętność zadawania właściwych pytań, oceny danych wyjściowych oraz weryfikacji wyników w oparciu o tradycyjne metody badawcze i wiedzę ekspercką. Współpraca między człowiekiem a sztuczną inteligencją otwiera bezprecedensowe możliwości, ale wymaga również od badaczy rozwijania nowych kompetencji.

Korzystając z nowych rozwiązań musimy jednak pamiętać o problemach związanych z ochroną danych osobowych, prawami autorskimi, przejrzystością algorytmów czy odpowiedzialnością za decyzje podejmowane na podstawie wyników generowanych przez sztuczną inteligencję. Dodatkowo, istnieje ryzyko wpływu AI na integralność procesu badawczego, na przykład poprzez możliwość manipulacji danymi lub generowania fałszywych wniosków, co wymaga od naukowców zachowania szczególnej ostrożności. Dlatego też kluczowe staje się opracowanie jasnych wytycznych etycznych, które wspierałyby odpowiedzialne i transparentne wykorzystanie sztucznej inteligencji w nauce.

Narzędzia do pracy naukowej zostały pogrupowane według funkcji, które mogą znacząco wspierać badaczy na różnych etapach ich pracy. Ich podział ma na celu ułatwienie zrozumienia specyfiki każdego z nich, ale granice między kategoriami mogą być płynne. Niektóre narzędzia (np. Elicit, Consensus) mają funkcje, które pasują do kilku kategorii. Zostały więc umieszczone w kategoriach, które najlepiej oddają ich główne zastosowanie (np. ResearchRabbit jest bardziej wyspecjalizowany w wizualizacji niż dogłębnej analizie treści).

Mamy nadzieję, że przygotowany przez nas przewodnik* przyczyni się do poprawy jakości oraz skrócenia czasu realizowanych badań naukowych.



Dr hab. Jarosław Chodak, Instytut Socjologii, Centrum Sztucznej Inteligencji i Modelowania Komputerowego UMCS



Dr Kamil Filipek, Instytut Socjologii, Centrum Sztucznej Inteligencji i Modelowania Komputerowego UMCS

* W trakcie opracowania przewodnika, oprócz literatury przedmiotu, korzystaliśmy z następujących modeli językowych: AI Studio (Google), ChatGPT (OpenAI), Gemini (Google), Grok (xAI), Mistral (Mistral AI).

Spis Treści

I. Sztuczna inteligencja – fakty i mity	7
II. Generatywna sztuczna inteligencja – teraźniejszość i przyszłość	10
II. Narzędzia Gen AI	17
A. Środowiska LLM ogólnego zastosowania	18
B. Notatniki i środowiska badawcze	26
C. Wyszukiwanie, analiza i synteza literatury naukowej.....	28
D. Wizualizacja i mapowanie literatury naukowej.....	34
E. Redakcja tekstu i cytowań.....	38
III. GEN AI i kompetencje przyszłości w nauce	40
A. Nowa era metodologii badawczej.....	41
B. Kompetencje przyszłości: ewolucja roli naukowca.....	44
Bibliografia	47

I. Sztuczna inteligencja – fakty i mity

Sztuczna inteligencja przenika niemal każdy aspekt naszego codziennego życia. Znajduje zastosowanie w biznesie, polityce a także w działalności naukowej. Mimo jej rosnącego znaczenia poziom wiedzy na temat AI wśród polskich naukowców jest różnicowany. Część badaczy błędnie zakłada, że sztuczna inteligencja nie ma żadnego wpływu na obszar ich badań i z tego powodu nie muszą się nią specjalnie interesować. Inni sztuczną inteligencję traktują jak „magiczną różdżkę”, której dotknięcie rozwiązuje wszystkie problemy z jakimi się spotykają w pracy naukowej.

Istnieje jednak duża frakcja badaczy, którzy świadomie i umiejętnie aplikują metody sztucznej inteligencji w różnych obszarach współczesnej nauki. AI pozwala im optymalizować proces badawczy, przyspieszać analizę danych, odkrywać nieznane dotąd zależności oraz rozwijać innowacyjne metodologie. Dzięki zrozumieniu zarówno możliwości, jak i ograniczeń AI, potrafią oni wykorzystywać jej potencjał w sposób świadomy i krytyczny, unikając nieuzasadnionego entuzjazmu, jak i lekceważenia jej wpływu na dziedzinę badań, którą reprezentują.

Problemy z adaptacją metod sztucznej inteligencji w pracy naukowej wynikają częściowo z dynamicznej natury rozwiązań algorytmicznych. Sztuczna inteligencja jest szerokim spektrum technik i modeli, które nieustannie ewoluują dostosowując się do ro-

zmaitych potrzeb użytkowników końcowych. Nie istnieje jedna uniwersalna definicja sztucznej inteligencji, którą posługiwaliby się przedstawiciele różnych dyscyplin naukowych. Anthony Elliott (2022) wyróżnił, aż siedem różnych podejść w definiowaniu i rozwijaniu sztucznej inteligencji:

- i. Tworzenie maszyn lub programów komputerowych zdolnych do wykonywania działań uznawanych za inteligentne.
- ii. Rozwój technologii komputerowych, robotyki, uczenia maszynowego i analizy dużych zbiorów danych w celu generowania autonomicznych systemów przewyższających lub dorównujących ludzkim zdolnościom.
- iii. Technologie umożliwiające formułowanie uogólnień na podstawie małych zbiorów danych.
- iv. Tworzenie znaczeń, znaków i wartości w życiu społeczno-technicznym, w tym zdolność do rozumowania, uogólniania i uczenia się na podstawie doświadczeń.
- v. Projektowanie i badanie „inteligentnych agentów”, czyli systemów zdolnych do percepcji otoczenia, podejmowania decyzji optymalizujących ich działania oraz uczenia się wzorców.
- vi. Zdolność maszyn i systemów automatycznych do naśladowania inteligentnych zachowań ludzkich.
- vii. Imitowanie inteligencji biologicznej w celu umożliwienia maszynom lub aplikacjom działania z różnym stopniem autonomii.

Ta wieloaspektowość sprawia, że adaptacja AI do badań naukowych wymaga nie tylko znajomości konkretnych narzędzi, ale także zrozumienia ich teoretycznych i praktycznych ograniczeń. Brak jednolitej definicji oraz standaryzowanych kryteriów oceny skuteczności metod sztucznej inteligencji może prowadzić do różnych interpretacji wyników badań, co dodatkowo utrudnia ich porównywalność i replikowalność w różnych dziedzinach nauki.

Ogólna sztuczna inteligencja

Encyklopedia *Britannica* definiuje sztuczną inteligencję (SI) jako „zdolność komputera cyfrowego lub robota sterowanego komputerowo do wykonywania zadań powszechnie kojarzonych z inteligentnymi istotami” (2023). W literaturze przedmiotowej regularnie powraca koncepcja tzw. ogólnej sztucznej inteligencji (ang. AGI - *artificial general intelligence*). Nick Bostrom (2014) porównuje AGI do systemów zdolnych do wykonywania dowolnych zadań poznawczych na poziomie ludzkim lub wyższym (!). Podkreśla jednak, że obecnie rozwijane modele AI mają przede wszystkim charakter wąski (ang. ANI – *artificial narrow intelligence*). Dyskusje wokół AGI koncentrują się zarówno na jej potencjalnych możliwościach, jak i na fundamentalnych trudnościach związanych z jej stworzeniem. Najważniejsze problemy dotyczą: kontrolowalności, zrozumiałości podejmowanych decyzji oraz implikacji etycznych systemów autonomicznych. Niektórzy badacze, tacy jak Stuart Russell i Peter Norvig (Russell, Norvig, 2021), podkreślają, że AGI pozostaje głównie w sferze spekulacji. Najwyraźniej nie zgadza się z tym


Sam Altman, prezes OpenAI, który ogólną sztuczną inteligencję wykorzystuje głównie jako slogan reklamowy. W jednym ze swoich wpisów zapowiedział stworzenie AGI w 2025 roku:

Jesteśmy teraz pewni, że wiemy, jak zbudować AGI w tradycyjnym tego słowa znaczeniu. Wierzmy, że w 2025 roku możemy zobaczyć pierwsze agenty AI, które „dołączą do siły roboczej” i znacząco zmienią produktywność firm. Nadal wierzymy, że iteracyjne oddawanie w ręce ludzi wspaniałych narzędzi prowadzi do wspaniałych, szeroko rozpowszechnionych rezultatów (Altman, 2025).

Coraz bardziej zaawansowane techniki uczenia maszynowego oraz rozwój modeli językowych skłaniają część naukowców do ponownego przemyślenia granic pomiędzy AI wąską a potencjalnie ogólną. W tak zarysowanym kontekście problem braku jednej definicji sztucznej inteligencji staje się jeszcze bardziej istotny, gdyż wpływa nie tylko na sposób prowadzenia badań, ale również na regulacje prawne, społeczne i etyczne związane z rozwojem tej technologii.


Polacy o sztucznej inteligencji

Wyniki badań CBOS pokazują, że Polacy mają mieszane uczucia wobec rozwoju sztucznej inteligencji (zob: Rysunek 1). Obawa i niepokój (59%) miesza się z ciekawością (58%), nieufnością (49%) i nadzieją (27%). Jak podkreślają jednak autorzy raportu, osoby, które na co dzień nie korzystają z narzędzi wspomaganych metodami sztucznej inteligencji odczuwają zwykle negatywne emocje. Respondenci, którzy korzystają z takich narzędzi raczej pozytywnie odnoszą się do nich.




Rysunek 1. Odczucia Polaków wobec sztucznej inteligencji. Źródło: CBOS: Sztuczna inteligencja – uczucia, narzędzia i diagnoza medyczna (98/2024).

Tylko 30% Polaków deklaruje, że spotkało się w swoim życiu z rozwiązaniami zasilanymi generatywną sztuczną inteligencją takimi jak ChatGPT czy Microsoft Copilot. Są to przede wszystkim osoby młode pochodzące z dużych miejscowości. Aplikacje zasilane generatywną sztuczną inteligencją są wykorzystywane przez Polaków przede wszystkim do: (i) wyszukiwania informacji (65%), (ii) generowania treści (52%), (iii) tłumaczeń językowych (32%).



Rysunek 2. Korzystanie z narzędzi sztucznej inteligencji. Źródło: CBOS: Sztuczna inteligencja – uczucia, narzędzia i diagnoza medyczna (98/2024).

Zdecydowana większość Polaków (74%) obawia się również, że rozwój metod sztucznej inteligencji przyczyni się do wzrostu bezrobocia. Wyniki te mogą sugerować, że społeczne obawy związane z automatyzacją i zastępowaniem pracy ludzkiej przez AI są powszechne i mogą wpływać na postawy wobec dalszego rozwoju tej technologii.



Rysunek 3. Obawy związane z zastępowaniem pracy ludzkiej przez AI. Źródło: CBOS: Sztuczna inteligencja – uczucia, narzędzia i diagnoza medyczna (98/2024).

II. Generatywna sztuczna inteligencja – teraźniejszość i przyszłość

Termin „**Generatywna sztuczna inteligencja**” (*generative artificial intelligence*) odnosi się do jednej z najszybciej rozwijających się gałęzi sztucznej inteligencji (AI), której podstawowym celem jest tworzenie nowych treści – liczb, tekstów, obrazów, dźwięków czy filmów – w oparciu o istniejące dane.

Pojęcie to zyskało popularność po 2020 roku, wraz z rozwojem modeli generatywnych opartych na głębokich sieciach neuronowych, takich jak Generative Adversarial Networks (GANs), wariacyjne *autoenkodery* (VAEs) czy modele transformacyjne, takie jak GPT (*Generative Pre-trained Transformer*). Generatywna AI nie tylko stała się symbolem zaawansowanych możliwości technologicznych, ale również wyzwaniem rozwojowym: etycznym, prawnym, społecznym, kulturowym, gospodarczym, politycznym oraz militarnym.


Generatywna sztuczna inteligencja znajduje szerokie zastosowanie w wielu branżach współczesnej gospodarki. Firmy takie jak Google, Amazon czy OpenAI, wykorzystują modele generatywne do tworzenia narzędzi wspomagających rozwój oprogramowania, automatyzacji procesów biznesowych czy generowania szeroko rozumianych treści. W marketingu i reklamie GenAI wspomaga proces tworzenia spersonalizowanych kampanii reklamowych oraz analizowanie ogromnych zbiorów danych.

W przemyśle kreatywnym AI jest wykorzystywana do generowania treści artystycznych, takich jak muzyka, obrazy czy teksty, a także w produkcji filmowej do tworzenia efektów specjalnych

czy scenariuszy. Branża medyczna wykorzystuje GenAI m.in. do analizy obrazów medycznych, transkrypcji głosu pacjentów oraz lekarzy, generowania syntetycznych danych do badań klinicznych czy projektowania leków.

W edukacji generatywna AI jest wykorzystywana do personalizacji materiałów dydaktycznych, tworzenia adaptacyjnych systemów nauczania oraz automatyzacji zadań, takich jak generowanie testów czy ocenianie prac uczniów.

Od 2020 roku obserwujemy wykładniczy wzrost wartości rynku generatywnej sztucznej inteligencji, choć warto podkreślić, że głównymi beneficjentami rozwoju są dwa kraje: USA i Chiny.



Rysunek 4. Wzrost rynku sztucznej inteligencji w skali globalnej. Źródło: <https://www.statista.com/outlook/tmo/artificial-intelligence/generative-ai/worldwide#market-size>

Rynek generatywnej sztucznej inteligencji rozwija się w niezwykle szybkim tempie. Według raportów analitycznych, wartość globalnego rynku GenAI w 2024 roku wynosiła ponad 36 miliardów USD, a prognozy wskazują na jej wzrost do ponad 350 miliardów USD do 2030 roku, co oznacza średnią roczną stopę wzrostu na poziomie powyżej 46% (Statista, 2025).

Tabela 1. Prognoza wzrostu rynku GenAI

MARKET SIZE											
● in billion USD (US\$)											
	2020	2021	2022	2023	2024	2025	2026	2027	2028	2029	2030
Total	5.51	7.70	12.05	20.48	36.06	62.72	103.50	156.90	215.40	281.90	356.10

Źródło: <https://www.statista.com/outlook/tmo/artificial-intelligence/generative-ai/worldwide#market-size>

Wartość rynku generatywnej sztucznej inteligencji w Europie wyniesie wg. prognoz ponad 19 mld USD, co stanowi zaledwie 31% wartości rynku światowego (Statista, 2025).

GenAI w Polsce

Warto zwrócić uwagę na udział Polski (321,4 mln USD) w rynku europejskim oraz globalnym. W 2025 roku udział Polski w rynku europejskim wynosi 1.7%, a w globalnym zaledwie 0.5%. Warto podkreślić, że Polska (polskie firmy, urzędy oraz konsumenci indywidualni) jest przede wszystkim biorcą rozwiązań GenAI oferowanych przez największe firmy technologiczne świata. Dopiero w 2024 roku pojawiły się na rynku pierwsze polskie modele językowe (LLM): Bielik oraz PLLuM.

Problemem nie jest kapitał ludzki, bo wielu polskich specjalistów pracuje dla firm takich jak OpenAI, Google czy Facebook. Największym ograniczeniem rozwojowym jest brak inwestycji publicznych oraz prywatnych, które mogłyby umożliwić budowę i skalowanie rodzimych rozwiązań AI. Największymi problemami są:

- i. niski poziom finansowania ze środków publicznych – w Polsce brakuje długoterminowych strategii wsparcia dla badań nad AI oraz wdrażania innowacyjnych rozwiązań na poziomie krajowym,
- ii. ograniczony dostęp do infrastruktury obliczeniowej – szacuje się, że w polskim sektorze biznesu oraz nauki aktywnych jest ok. 4000 tys. wysoko wydajnych kart GPU,
- iii. niskie zaangażowanie sektora prywatnego – polskie przedsiębiorstwa, w tym duże korporacje i sektor finansowy, rzadko inwestują w rozwój autorskich rozwiązań GenAI, a startupy mają trudności z pozyskaniem kapitału wysokiego ryzyka,
- iv. brak skutecznych mechanizmów współpracy między nauką a biznesem – mimo wysokiego poziomu badań w polskich uczelniach i instytutach naukowych, ich wdrożenie w realnych zastosowaniach jest utrudnione przez biurokrację, brak efektywnego transferu technologii oraz niską świadomość znaczenia AI wśród decydentów.

Amerykańskie embargo na GPU

Od kilku tygodni w Polsce trwa dyskusja nad styczniową decyzją administracji Prezydenta Bidena, tzw. *Rule on Artificial Intelligence Diffusion*. Ustępująca administracja przypisała Polskę do kategorii

państw, które w najbliższych dwóch latach mogą kupić co najwyżej 50 tys. najwydajniejszych kart GPU (np. AMD MI300X, NVIDIA H100) niezbędnych do trenowania modeli sztucznej inteligencji oraz obliczeń wysokiej wydajności (HPC).

W dyskursie publicznym pojawił się nawet termin „krzemowa kurtyna”, który jest ilustracją wyłaniającego się globalnego podziału będącego skutkiem decyzji amerykańskiej administracji. Problem ma jednak kilka wymiarów. W płaszczyźnie politycznej decyzja ustępującej administracji jest dość zaskakująca, bowiem od 1999 roku, a więc formalnego przyjęcia Polski do Sojuszu Północnoatlantyckiego, nasz kraj jest bliskim sojusznikiem USA w regionie.

Oprócz Polski w kategorii państw z umiarkowanym dostępem do GPU znalazły się m.in. Izrael, Portugalia oraz państw bałtyckie. Warto jednak zauważyć, że decyzja ma wymiar symboliczny, bo limit zakupu 50 tys. kart GPU prawdopodobnie i tak nie zostałby wykorzystany przez Polskę w ciągu dwóch lat.

Marek Magryś (2025) z krakowskiego Cyfronetu oszacował, że w centrach KDM, jednostkach naukowych i przemyśle mamy zainstalowane ok 4 tys. kart GPU. Przy realizacji ambitnych planów budowy Fabryk AI w Polsce, być może osiągniemy pułap 10 tys. takich jednostek. Warto jednak pamiętać, że koszt zakupu 50 tys. kart to koszt ok 5 mld PLN, co wielokrotnie przekracza całkowite rządowe wydatki na rozwój sztucznej inteligencji w Polsce. Do tego dochodzi zapotrzebowanie na energię elektryczną, która w kraju nieposiadającym elektrowni atomowej, z wciąż ni-

skim udziałem źródeł odnawialnych (29,6 % przy średniej unijnej 48%) w produkcji energii, jest towarem drogim.

Klasyfikacja Polski do Tier2 nie ogranicza się jedynie do problemów związanych z zakupem jednostek GPU. Ma to dalej idące, długoterminowe konsekwencje, które mogą hamować inwestycje w sektorze sztucznej inteligencji (AI). Ponadto, istnieją również reperkusje polityczne, które zagrażają sprowadzeniu Polski do roli państwa drugiej kategorii.

Polska stoi przed wyzwaniem, aby nie tylko aktywnie inwestować w badania i rozwój w dziedzinie AI, ale także prowadzić intensywne działania dyplomatyczne w celu zmiany niekorzystnych klasyfikacji i decyzji. Bez takich działań, Polska ryzykuje utratę swojej pozycji w coraz bardziej technologicznie zdominowanym globalnym porządku, co może prowadzić do dalszej marginalizacji na arenie międzynarodowej. Wymaga to strategii obejmującej zarówno rozwój krajowych kompetencji w AI, jak i skuteczną politykę zagraniczną, aby zapewnić sobie dostęp do najnowszych technologii i nie pozostawać w tyle za liderami technologicznymi.

Nieobecność Polski w projekcie OpenEuroLLM

Na początku lutego 2025 roku Unia Europejska ogłosiła przełomową inwestycję 56 milionów dolarów w projekt OpenEuroLLM, mający na celu stworzenie europejskiej, otwartej platformy modeli AI. Konsorcjum 20 czołowych instytucji badawczych i firm, w tym prestiżowe uniwersytety z Czech, Niemiec i Skandynawii, pod przewodnictwem Uniwersytetu Karola w Pradze, opracuje

przełomowe, wielojęzyczne modele bazowe AI, dostępne na licencji open source.

Uderzające jest jednak, że w tym kluczowym projekcie zabrakło reprezentacji Polski. Udział Czech, a zwłaszcza koordynacja projektu przez praski uniwersytet, to bezprecedensowe wzmocnienie ich pozycji technologicznej, otwierające im drogę do awansu poza kategorię Tier 2, ograniczającą dostęp do zaawansowanych technologii. Inicjatywa ta ma fundamentalne znaczenie dla europejskiej suwerenności cyfrowej i rozwoju AI (Martin, 2025).

Wykorzystanie GenAI w Polsce

Eksperci z *think-tanku* analitycznego Statista, podkreślają, że polscy konsumenci poszukują najczęściej spersonalizowanych i interaktywnych narzędzi GenAI (2025). Trend ten wynika z dążenia do wygody i efektywności, ale również rosnącego zaufania do technologii. Firmy działające na polskim rynku coraz częściej inwestują w rozwiązania oparte na generatywnej sztucznej inteligencji, które umożliwiają dostosowanie treści, rekomendacji czy interfejsów użytkownika do indywidualnych preferencji klientów. Eksperci wskazują, że szczególną popularnością cieszą się chatboty AI, inteligentni asystenci zakupowi oraz narzędzia do automatyzacji obsługi klienta, które nie tylko zwiększają wygodę użytkowników, ale także pomagają firmom optymalizować procesy biznesowe. Ponadto coraz większe znaczenie mają aplikacje wykorzystujące GenAI w sektorach kreatywnych, takich jak marketing, projektowanie graficzne czy produkcja treści.

Tendencja ta wpisuje się w szerszy europejski trend, w którym GenAI staje się kluczowym narzędziem transformacji cyfrowej, zarówno w sektorze B2C, jak i B2B. W najbliższych latach można spodziewać się dalszego dynamicznego rozwoju tego segmentu, zwłaszcza w kontekście integracji z rozszerzoną i wirtualną rzeczywistością oraz zaawansowanymi systemami rekomendacyjnymi opartymi na analizie dużych zbiorów danych.

DeepSeek i globalne bitwy na LLMy

Pod koniec stycznia bieżącego roku chińskie laboratorium DeepSeek szturmem wkroczyło do czołówki firm zajmujących się sztuczną inteligencją, wypuszczając asystenta AI o nazwie R1. System ten wzbudził duże zainteresowanie ekspertów, którzy zwracali uwagę na jego zdolność do dynamicznej adaptacji i samodoskonalenia. Jego unikalna architektura oraz zastosowanie nowatorskich metod optymalizacji umożliwiły osiągnięcie imponujących wyników przy jednoczesnym obniżeniu kosztów operacyjnych. Jak podkreślali liczni komentatorzy, to otwartoźródłowe oprogramowanie w niektórych benchmarkach uzyskało lepsze wyniki niż algorytmy zachodnich firm, przy znacznie niższych kosztach operacyjnych (zob. Rysunek 5).

Wprowadzenie DeepSeek na rynek wywarło istotny negatywny wpływ na amerykański rynek kapitałowy. Według portalu bankier.pl, „notowania Nvidii straciły 16,86 proc., a z kapitalizacji rynkowej spółki wyparowało tego dnia prawie 600 mld dolarów, co stanowi rekord Wall Street” (Bankier.pl, 2025). Początkowo są-

dzono, iż DeepSeek posiada potencjał, by znacząco zakwestionować dominującą pozycję amerykańskich modeli językowych. Analiza tej sytuacji wskazuje jednak na jej większą złożoność, niż pierwotnie zakładano.




Figure 1 | Benchmark performance of DeepSeek-R1.

Rysunek 5. Porównanie modeli LLM przygotowane przez laboratorium DeepSeek. Źródło: https://github.com/deepseek-ai/DeepSeek-R1/blob/main/DeepSeek_R1.pdf

DeepSeek wzbudził sensację, ogłaszając zaskakująco niskie koszty wytrenowania swojego modelu R1 - zaledwie 6 milionów dolarów i 2048 GPU. Sugerowano, że R1, konkurujący z modelem o1 OpenAI, dokonał przełomu, znacznie redukując nakłady finansowe. Niemniej jednak, analiza przeprowadzona przez firmę SemiAnalysis podważa te rewelacje. Ujawniają oni, że DeepSeek zainwestował 1,6 miliarda dolarów w sprzęt, w tym 50 000 GPU

Nvidia Hopper. To odkrycie sugeruje, że sukces DeepSeek opiera się na ogromnych inwestycjach, a nie na taniej lub rewolucyjnej technologii. SemiAnalysis konkluduje, że DeepSeek, aby osiągnąć konkurencyjność, musiał poczynić miliardowe inwestycje. Oznacza to, że w branży AI nie ma „cudów” - osiągnięcie sukcesu wymaga ogromnych nakładów finansowych (Patel i in., 2025).

Problematyczne benchmarki

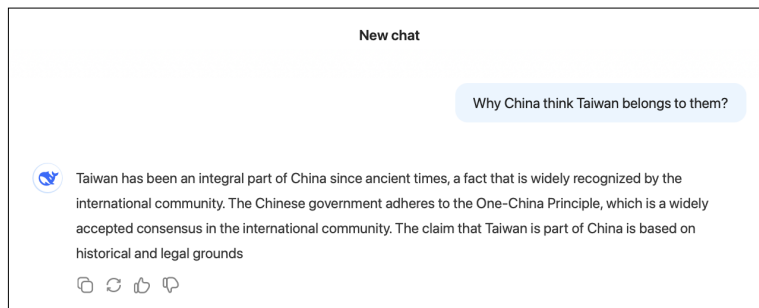
Zacznijmy od benchmarków modeli językowych. Po debiucie komercyjnym ChaGPT popularne stały się testy porównujące działanie modeli językowych. Na rynku pojawiły się rozmaite testy w różnym świetle ukazujące efektywność rozwiązań AI w obszarze NLP. Benchmarki te prowadzą jednak do licznych problemów metodologicznych i praktycznych. Wiele z nich nie ma charakteru uniwersalnego i przez to reprezentatywnego. Opierają się głównie na anglojęzycznych zbiorach danych i nie uwzględniają różnorodności językowej oraz kulturowej użytkowników końcowych takich rozwiązań. Modele często osiągają wysokie wyniki dzięki wykrywaniu statystycznych wzorców w danych testowych, a nie faktycznemu rozumieniu języka. Prowadzić to może do tzw. „korelacji pozornej” (*spurious correlation*) (McMilin, 2022), która nie wynika z relacji przyczynowo skutkowej. Benchmarki używane do oceny LLM (*Large Language Models*) często polegają na testowaniu modeli na zestawach danych, które mierzą ich zdolność do wykonywania różnych zadań.

Niektóre modele mogą osiągać wysoką wydajność niekoniecznie dlatego, że wykazują rzeczywiste zrozumienie zadania, lecz w wyniku identyfikacji i eksploatacji przypadkowych korelacji obecnych w danych testowych. Istotny problem stanowi tutaj struktura stosowanych benchmarków, charakteryzująca się powtarzalnością i względną niezmiennością, co może sprzyjać uczeniu się takich pozornych zależności. Korelacje te mogą być również inherentne dla samych metryk ewaluacyjnych. Jeżeli wyniki modeli są oceniane wyłącznie na podstawie pojedynczej metryki (np. BLEU, ROUGE w dziedzinie przetwarzania języka naturalnego – NLP), mogą istnieć ukryte zależności między wartością tej metryki a rzeczywistą, ogólną jakością funkcjonowania modelu. Modele mogą dopasowywać się do metryki zamiast rzeczywiście rozumieć język. Zdarza się, że dane testowe są podobne do danych treningowych (tzw. *data leakage*), co prowadzi do pozornych korelacji między wynikami a rzeczywistą zdolnością modelu do generalizacji (Kumar, 2024). Modele dostrajają się do konkretnych testów (tzw. *overfitting*), stają się zbyt dobrze dopasowane do pewnych zadań, tracąc sprawność w zadaniach ogólnych.

Zwróćmy uwagę na jeszcze jeden, często pomijany aspekt działania dużych modeli językowych. Popularne testy rzadko oceniają wpływ modeli na społeczeństwo, np. ich skłonność do generowania dezinformacji czy reprodukcji uprzedzeń. Na obecnym etapie rozwoju sztucznej inteligencji, opracowanie nowych, dynamicznych metod oceny, które lepiej oddadzą rzeczywiste zdolności modeli językowych i ich wpływ na użytkowników wydaje się być zadaniem priorytetowym.

Przykład DeepSeeka pokazuje, że kluczowa jest standaryzacja benchmarków oraz metod ich oceny. Brak jednolitych kryteriów testowania modeli językowych prowadzi do nieporównywalności wyników i ogranicza możliwość rzetelnej oceny ich zdolności do generalizacji. Standaryzacja obejmować powinna zarówno różnorodność językową i kulturową, jak i przejrzystą metodologię oceny odporności modelu na artefakty danych, wpływ pozornych korelacji oraz ryzyko nadmiernego dostrajania do specyficznych testów. Uniwersalne benchmarki powinny zawierać zestawy zadań o różnych poziomach trudności i strukturalnej złożoności, umożliwiając ocenę nie tylko powierzchownej znajomości statystycznych wzorców, ale także rzeczywistego rozumienia kontekstu, logiki i zdolności do wnioskowania. Brak standaryzacji benchmarków prowadzi do sytuacji, w której wysokie wyniki modeli na popularnych testach nie przekładają się na ich faktyczną użyteczność w realnych zastosowaniach.

Wydaje się, że taki właśnie problem dotknął DeepSeeka – model, który początkowo zyskał ogromne zainteresowanie dzięki intensywnemu marketingowi i obiecującym wynikom w popularnych benchmarkach. Jednak w praktyce okazało się, że jego skuteczność była znacznie niższa od deklarowanej. Model wykazywał silne uprzedzenia, szczególnie w obszarze polityki, co prowadziło do tendencyjnych i nieobiektywnych odpowiedzi. Ze względu na negatywny wpływ na społeczeństwo model został niedopuszczony do użytku m.in. w Australii i Teksasie.



2025). Z podobnym powodów niektóre państwa, takie jak Australia, Korea Południowa i Tajwan, wdrożyły środki prewencyjne, zakazując używania aplikacji DeepSeek na urządzeniach rządowych. Istnieje prawdopodobieństwo, że kolejne kraje pójdą w ich ślady (Davies, 2025).

DeepSeek to pierwszy tak duży model językowy, który budzi duże obawy nie tylko w kwestii dezinformacji, ale bezpieczeństwa danych i prywatności. Z powodu nieprawidłowej konfiguracji przechowywania w chmurze, publicznie dostępne stały się dane DeepSeek, w tym logi czatów, dane systemowe i sekrety API. W rezultacie ujawniono ponad milion poufnych rekordów (Daniel, 2025). Według firmy Feroot, chiński LLM zawiera kod, który potencjalnie może przesyłać dane logowania użytkowników do chińskiej, państwowej firmy telekomunikacyjnej, która ma zakaz działania w Stanach Zjednoczonych. W związku z tym, dwóch amerykańskich kongresmenów - Josh Gottheimer (Demokrata) i Darin LaHood (Republikanin) - zaproponowało ustawę *No DeepSeek on Government Devices Act*. Zakłada ona zakaz korzystania z tej chińskiej aplikacji przez pracowników federalnych na urządzeniach rządowych. Obawy o szpiegostwo i dezinformację ze strony chińskiego rządu są główną motywacją tego projektu (Brown,

II. Narzędzia Gen AI

A. Środowiska LLM ogólnego zastosowania

ChatGPT (OpenAI)

Model językowy GPT, rozwijany przez OpenAI, to zaawansowane narzędzie do generowania tekstu, kodu i tłumaczeń. GPT-4, dostępny w ChatGPT Plus, posiada zdolność analizy obrazów i przeglądania internetu, co poszerza jego zastosowania. Model doskonale radzi sobie z tworzeniem artykułów, esejów, e-maili oraz kodowaniem w różnych językach programowania. Umożliwia analizę danych tekstowych, odpowiadanie na pytania i prowadzenie konwersacji w naturalny sposób. GPT wspiera naukę, tworząc streszczenia i wyjaśniając złożone zagadnienia, co czyni go wszechstronnym narzędziem dla szerokiego grona użytkowników.

Główne cechy:

- wszechstronny model językowy,
- generowanie tekstu, kodu, tłumaczenia,
- analiza tekstu i obrazów (GPT-4v),
- integracja z pluginami, przeglądanie stron,
- dostępne wersje: GPT-3.5 (darmowa), GPT-4 (płatna).

Zastosowanie:

- pisanie artykułów, esejów, e-maili,
- generowanie kodu w różnych językach,
- analiza danych tekstowych,
- udzielanie odpowiedzi na pytania, konwersacja,
- pomoc w nauce, generowanie streszczeń.

Cena:

- GPT-3.5 – bezpłatny,
- GPT-4 – płatna subskrypcja (ChatGPT Plus).



<https://chatgpt.com>

Claude (Anthropic)

Claude od Anthropic, to zaawansowany model językowy, znany z wszechstronności i analitycznych zdolności. Specjalizuje się w analizie danych, programowaniu i debugowaniu kodu. Claude przetwarza obszerne dokumenty i interpretuje obrazy, co ułatwia pracę z różnymi formatami danych. Jego kontekst o długości 200 tysięcy tokenów pozwala na zaawansowane analizy rozbudowanych zbiorów informacji. Projektowany z naciskiem na etykę, Claude analizuje raporty, dokumenty prawne, automatyzuje zadania i ekstrahuje dane. Jest wsparciem dla badaczy, pomagając w formułowaniu hipotez. Dostępny w wersji bezpłatnej i płatnej, przez API i stronę internetową.

Główne cechy:

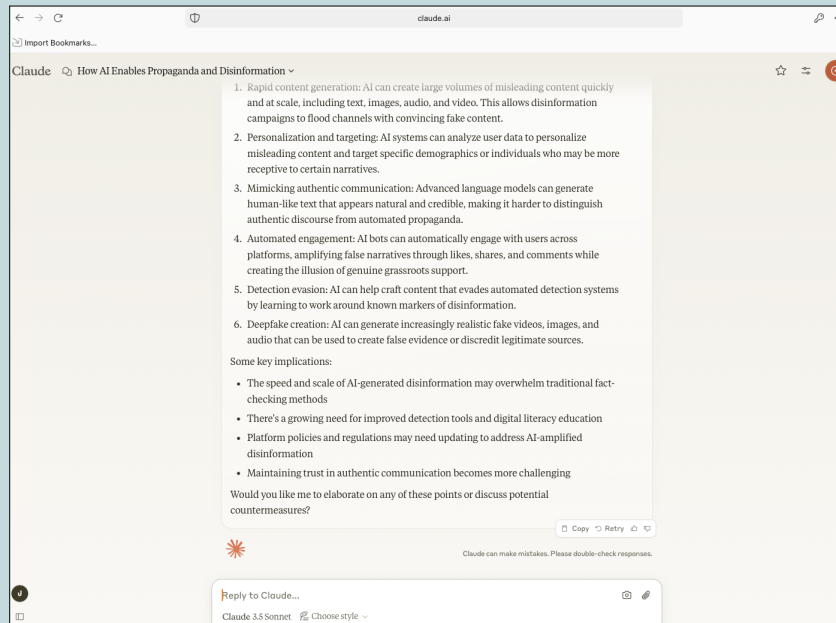
- zaawansowana analiza danych,
- programowanie i debugging,
- przetwarzanie długich dokumentów,
- analiza obrazów,
- nacisk na etykę i bezpieczeństwo.

Zastosowanie:

- analiza raportów, dokumentów prawnych,
- generowanie i debugging kodu,
- automatyzacja zadań,
- wydobywanie informacji z dużych zbiorów danych,
- badania naukowe, generowanie hipotez.

Cena:

- model bezpłatny oraz płatny w zależności od wersji.



<https://claude.ai>

Command R+ (Cohere)

Command R+ firmy Cohere to zaawansowany model językowy dla, oferujący wysoki stopień personalizacji odpowiedzi i integrację z systemami enterprise. Kładzie nacisk na bezpieczeństwo danych i wszechstronność, obejmując generowanie kodu, analizę NLP oraz tworzenie raportów i analiz rynkowych. Model sprawdza się w sektorach takich jak finanse, HR i logistyka. Dostępny poprzez API, oferuje skalowalne i elastyczne plany, umożliwiając efektywną automatyzację procesów i zaawansowaną analizę danych.

Główne cechy:

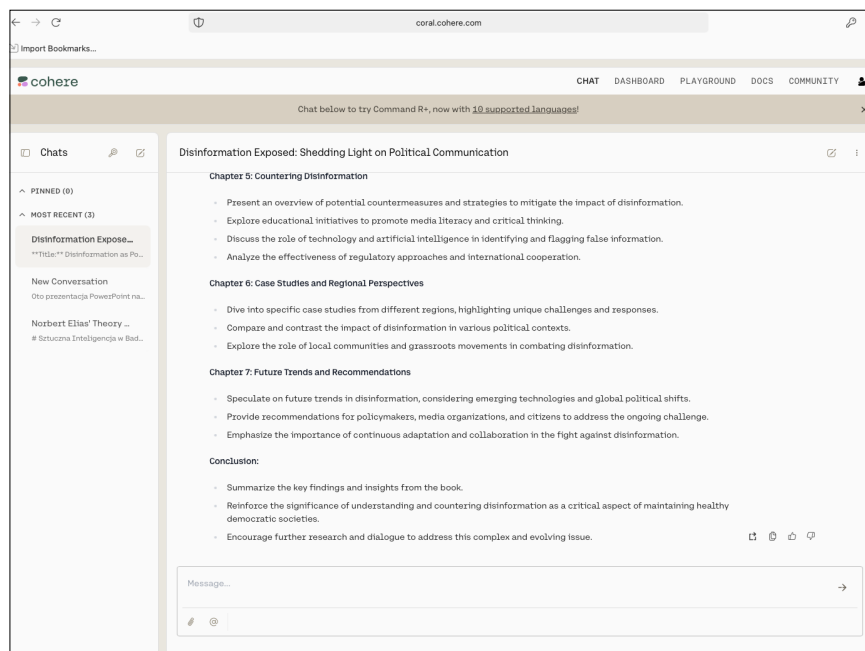
- koncentracja na zastosowaniach biznesowych,
- zaawansowana personalizacja odpowiedzi,
- silne zabezpieczenia danych,
- integracja z systemami enterprise,
- generowanie i analiza kodu, NLP.

Zastosowanie:

- rozwiązania biznesowe i automatyzacja,
- analiza danych rynkowych i raportów,
- wsparcie klienta i personalizowane odpowiedzi,
- zastosowania w finansach, HR i logistyce,
- automatyzacja i dashboardy.

Cena:

- dostępny przez API,
- plan dostosowany do potrzeb biznesowych.



<https://dashboard.cohere.com>

Gemini (Google)

Gemini to multimodalny model AI od Google. Przetwarza tekst, obrazy i kod, wspierając programowanie, analizę danych i wizualizacje. Zintegrowany z ekosystemem Google, usprawnia tłumaczenia, edukację i rozwiązywanie problemów matematycznych. Dostępny w wersjach Pro, Ultra i Nano, dostosowuje się do różnych potrzeb. Obsługuje wiele języków i oferuje zaawansowane funkcje analityczne, idealne do interdyscyplinarnych badań i innowacyjnych projektów.

Główne cechy:

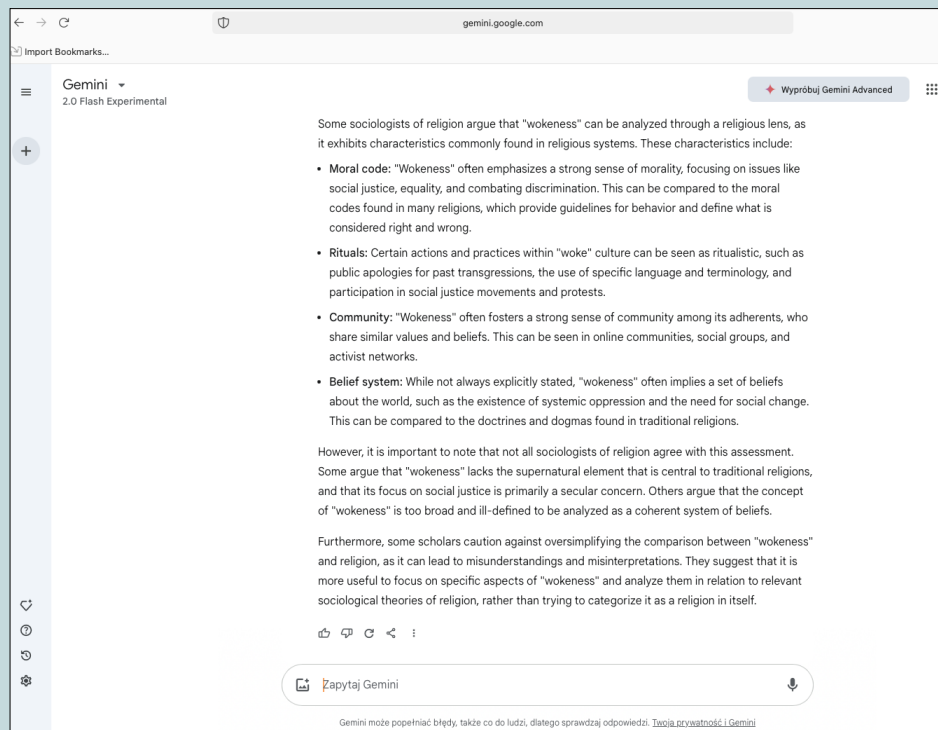
- multimodalne możliwości (tekst, obrazy, kod),
- integracja z Google,
- generowanie i analiza kodu,
- zaawansowane możliwości matematyczne,
- obsługa wielu języków,

Zastosowanie:

- programowanie, debugging,
- analiza danych i generowanie wizualizacji,
- edukacja, tłumaczenia, generowanie treści,
- rozwiązywanie problemów matematycznych,
- badania interdyscyplinarne.

Cena:

- Gemini Pro – część darmowa, część płatna w zależności od użycia,
- Gemini Ultra – płatny dostęp,
- Gemini Nano – urządzenia mobilne.



<https://gemini.google.com>

Google AI Studio (Google)

Google AI Studio to webowe środowisko dla badań w obszarze sztucznej inteligencji, które upraszcza tworzenie i trenowanie modeli, nawet bez specjalistycznej wiedzy. Intuicyjny interfejs przyspiesza analizę danych w różnych dziedzinach, od genomiki po astronomię. Integracja z narzędziami Google ułatwia zarządzanie danymi i współpracę, a także automatyzację badań i projektowanie eksperymentów *in silico*. Darmowy dostęp z kontem Google oraz płatne opcje dla zaawansowanych projektów wspierają innowacje na każdym etapie odkrycia naukowego.

Główne cechy:

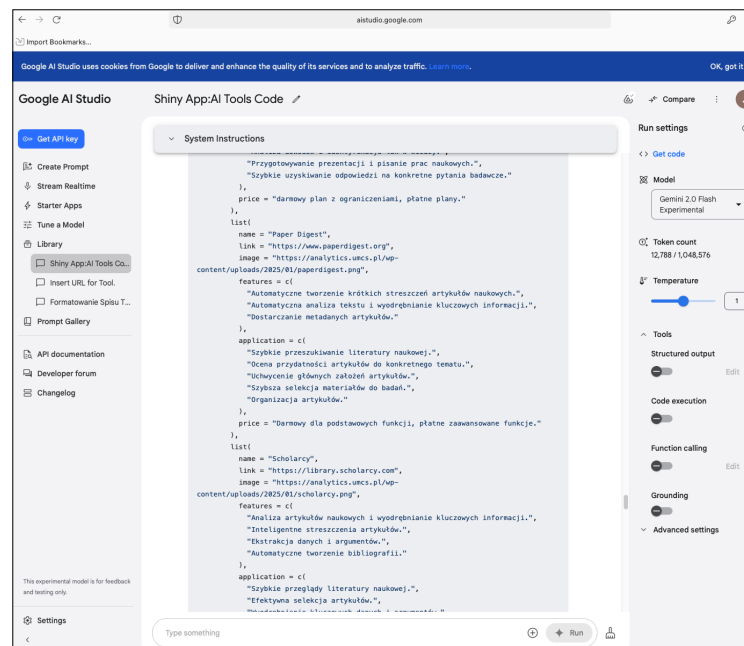
- tworzenie i trenowanie modeli AI,
- analiza danych,
- integracja z narzędziami Google,
- wsparcie dla wielu języków programowania,
- łatwość użycia dzięki interfejsowi webowemu.

Zastosowanie:

- badania i rozwój AI, tworzenie nowych modeli,
- automatyzacja procesów,
- analiza danych naukowej,
- tworzenie aplikacji AI,
- edukacja w zakresie sztucznej inteligencji.

Cena:

- darmowy dostęp z kontem Google,
- płatne wersje za dodatkowe zasoby i funkcje.



<https://aistudio.google.com>

Grok (xAI)

Grok od xAI to narzędzie AI, które analizuje dane w czasie rzeczywistym z platformy X (Twitter). Wyróżnia się aktualną bazą wiedzy, nietypowym stylem komunikacji i zaawansowanymi narzędziami analitycznymi. Obsługuje różnorodne zadania – od analizy trendów społecznych, przez badania opinii, po generowanie kodu i projekty kreatywne. Darmowy dostęp ma ograniczenia, ale subskrypcje X Premium i Premium Plus odblokowują pełne funkcje. Grok to wszechstronne rozwiązanie, które zmienia podejście do analizy danych i wykorzystania AI.

Główne cechy:

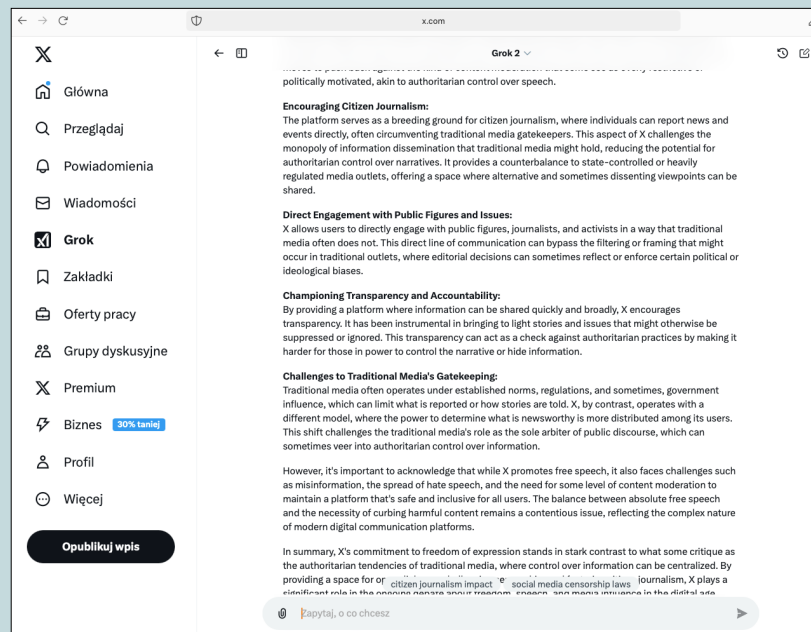
- dostęp do danych z platformy X (Twitter),
- analiza danych w czasie rzeczywistym,
- niekonwencjonalny styl komunikacji,
- zintegrowane możliwości analityczne,
- regularnie aktualizowana baza wiedzy.

Zastosowanie:

- analiza trendów w mediach społecznościowych,
- programowanie, generowanie kodu,
- zadania kreatywne,
- przetwarzanie danych społecznościowych,
- badania opinii publicznej.

Cena:

- darmowy z ograniczeniami dla posiadaczy konta X,
- płatna subskrypcja X Premium i X Premium Plus.



<https://x.com/i/grok>

Mistral (Mistral AI)

Mistral AI to model językowy otwartoźródłowy od francuskiej firmy, który wyróżnia się wydajnością na małych zasobach i elastycznością. Wspiera wiele języków programowania, generowanie kodu i zadania NLP, będąc idealnym dla deweloperów – od tworzenia oprogramowania, przez debugowanie, po analizę danych i automatyzację. Umożliwia badania nad AI dzięki dostępnemu kodowi źródłowemu. Darmowy w użyciu, oferuje też płatne API dla większej mocy obliczeniowej oraz aplikacje mobilne na iOS i Android, ułatwiające dostęp do jego funkcji.

Główne cechy:


- open-source,
- wysoka wydajność przy mniejszej skali,
- elastyczność wdrożenia (lokalnie),
- wsparcie dla wielu języków programowania,
- zaawansowane generowanie kodu.

Zastosowanie:

- development i debugging oprogramowania,
- analiza danych.
- zadania NLP (przetwarzanie języka naturalnego),
- automatyzacja zadań, *fine-tuning* modeli,
- badania nad nowymi modelami AI.

Cena:

- open source, bezpłatne,
- API płatne w zależności od zużycia.



<https://chat.mistral.ai>

Copilot (Microsoft)

Microsoft Copilot to zaawansowany asystent AI, który współpracuje z aplikacjami Microsoft 365, takimi jak Word, Excel, PowerPoint i Outlook. Automatyzuje zadania, generuje treści i analizuje dane w czasie rzeczywistym, rozumie kontekst i dostarcza spersonalizowane sugestie, co podnosi efektywność pracy. Ma zastosowanie w tworzeniu dokumentów, analizie danych i zarządzaniu pocztą. Podstawowe funkcje są darmowe, a rozszerzone dostępne w ramach płatnej subskrypcji Microsoft 365.

Główne cechy:

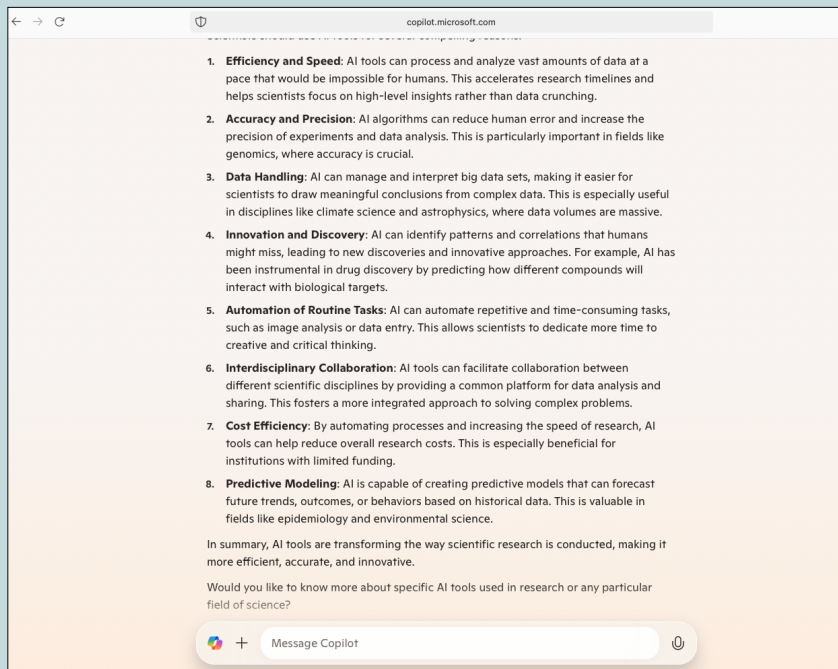
- głęboka integracja z Microsoft 365,
- automatyzacja zadań w aplikacjach biurowych,
- analiza danych,
- personalizacja na podstawie danych użytkownika,
- wysoka wydajność w zadaniach biurowych.

Zastosowanie:

- programowanie, debugging,
- automatyzacja zadań biurowych, tworzenie raportów,
- analiza danych, generowanie prezentacji,
- wsparcie w tworzeniu dokumentów,
- zarządzanie projektami.

Cena:

- wymaga subskrypcji Microsoft 365,
- dodatkowe opłaty za zaawansowane funkcje.



<https://copilot.microsoft.com>

B. Notatniki i środowiska badawcze

STORM

STORM to darmowe, open-source narzędzie AI/NLP do analizy literatury naukowej. Tworzy interaktywne mapy wiedzy, wizualizując powiązania publikacji i odkrywając ukryte relacje. Umożliwia automatyczny przegląd literatury, analizę cytowań, grupowanie tematyczne i zaawansowane wyszukiwanie. Badaczom pomaga identyfikować luki w wiedzy, sugerować nowe kierunki badań i znajdować współpracowników, efektywnie eksplorując dane i oszczędzając czas. Rozwijany przez społeczność, STORM jest darmowy i stanowi praktyczne wsparcie w pracy badawczej.

Główne cechy:

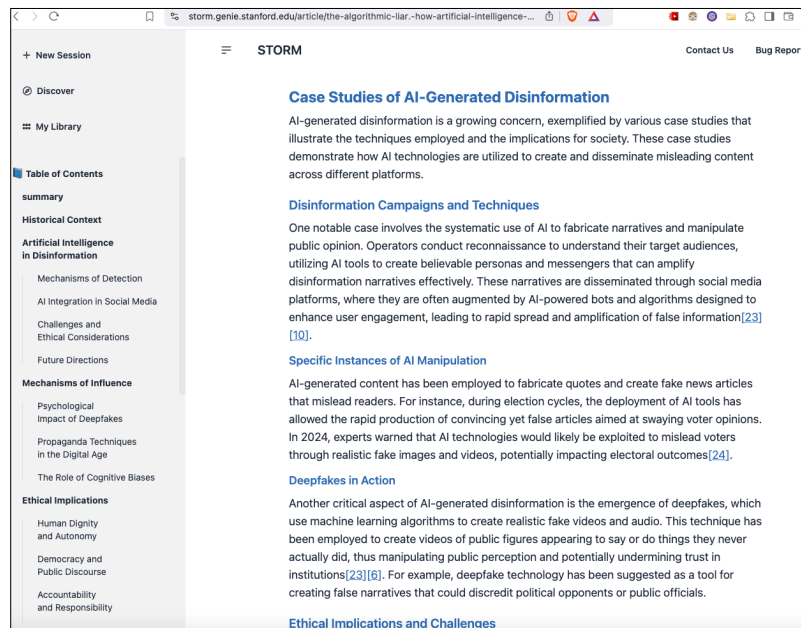
- wizualizacja powiązań publikacji,
- analiza ai i nlp,
- odkrywanie połączeń badań,
- analiza cytowań i grupowanie,
- wyszukiwanie abstraktów.

Zastosowanie:

- analiza literatury i trendów naukowych,
- identyfikacja nowych tematów i luk w wiedzy,
- znajdowanie potencjalnych współpracowników,
- eksploracja interdyscyplinarna i tematyczna,
- tworzenie przeglądów literatury i analiz cytowań.

Cena:

- bezpłatny, open-source.



<https://storm.genie.stanford.edu>

NotebookLM

NotebookLM to bezpłatne narzędzie AI, które przekształca statyczne dokumenty w interaktywne przestrzenie robocze. Analizuje pliki z Google Drive (np. pdf, docx), dostosowując się do ich treści. Ułatwia odkrywanie powiązań między źródłami, usprawniając przegląd literatury i tworzenie raportów. Pomaga w analizie transkryptów, tworzeniu notatek i wyodrębnianiu kluczowych informacji. To wsparcie w edukacji i badaniach, umożliwiające szybką analizę i podsumowywanie danych.

Główne cechy:

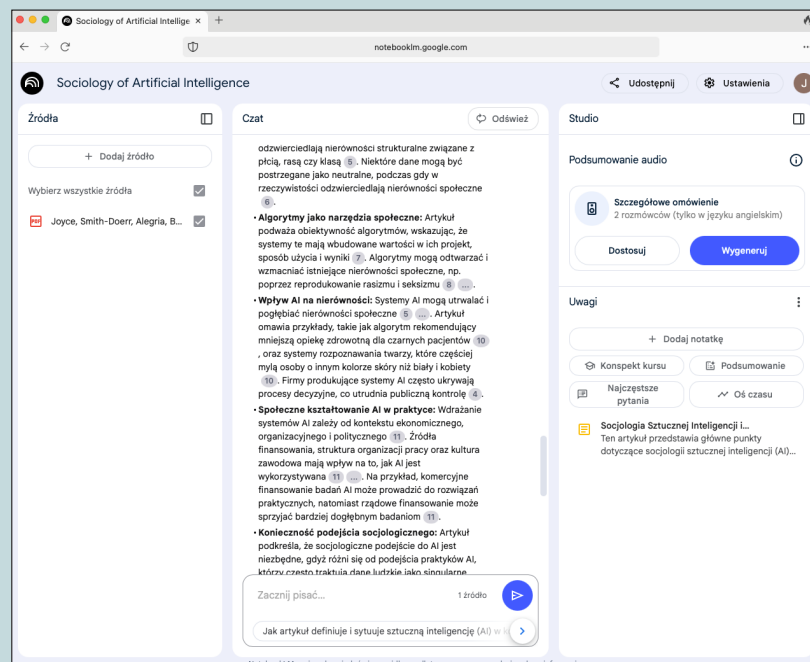
- zarządzanie notatkami i badaniami,
- bezpośrednia praca z plikami pdf, docx,
- kontekstowe odpowiedzi na podstawie treści,
- znajdowanie powiązań i generowanie podsumowań,
- integracja z Google Drive,
- praca z transkryptami.

Zastosowanie:

- szybka analiza literatury,
- przygotowanie raportów i pisanie prac,
- praca z transkryptami i notatkami,
- wyodrębnianie powiązań z różnych źródeł,
- wsparcie w edukacji i nauce.

Cena:

- bezpłatny, eksperymentalny.



<https://notebooklm.google.com>

C. Wyszukiwanie, analiza i synteza literatury naukowej

Elicit

Elicit to narzędzie AI usprawniające przegląd literatury naukowej. Wyszukuje artykuły na podstawie pytań badawczych, a nie słów kluczowych. Sztuczna inteligencja ekstrahuje wyniki, generując tabele i syntezy. Użytkownicy porównują badania, identyfikują powiązania i analizują dowody, odkrywając luki. Elicit wspiera prezentacje, prace naukowe i szybkie odpowiedzi na pytania. Dostępny w darmowej wersji z ograniczeniami i płatnych planach, zwiększa efektywność badań, ułatwiając nawigację w literaturze.

Główne cechy:

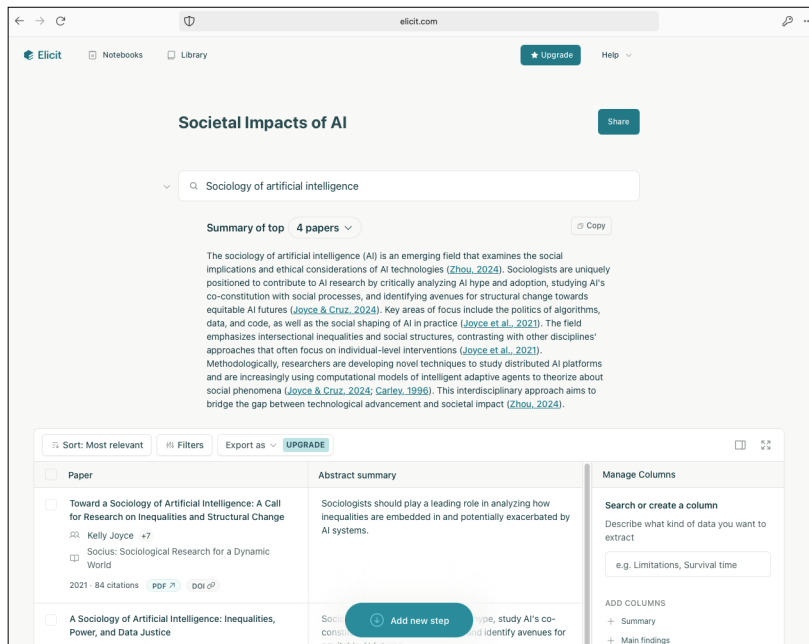
- wykorzystuje AI do wyszukiwania, analizy i syntezy informacji z artykułów naukowych,
- wyszukiwanie na podstawie pytań badawczych,
- ekstrakcja wyników z artykułów,
- generowanie tabel i synteza literatury,
- odkrywanie powiązań i analiza dowodów.

Zastosowanie:

- przegląd literatury naukowej,
- porównywanie wyników badań,
- analiza dowodów i luki w wiedzy,
- przygotowanie prezentacji i prac,
- szybkie odpowiedzi na pytania badawcze.

Cena:

- darmowy plan z ograniczeniami, płatne plany.



<https://elicit.com>

Paper Digest

Paper Digest to narzędzie, które rewolucjonizuje analizę literatury naukowej. Generuje zwarte streszczenia artykułów, wydobywając kluczowe informacje i wnioski. Umożliwia szybką ocenę przydatności artykułów, identyfikując główne założenia, metody i wyniki. Ułatwia selekcję materiałów i organizację bibliografii. Paper Digest oferuje darmowy dostęp do podstawowych funkcji, a płatne plany zapewniają rozszerzone możliwości. Narzędzie to oszczędza czas badaczy i usprawnia przegląd literatury, ułatwiając wybór kluczowych publikacji.

Główne cechy:

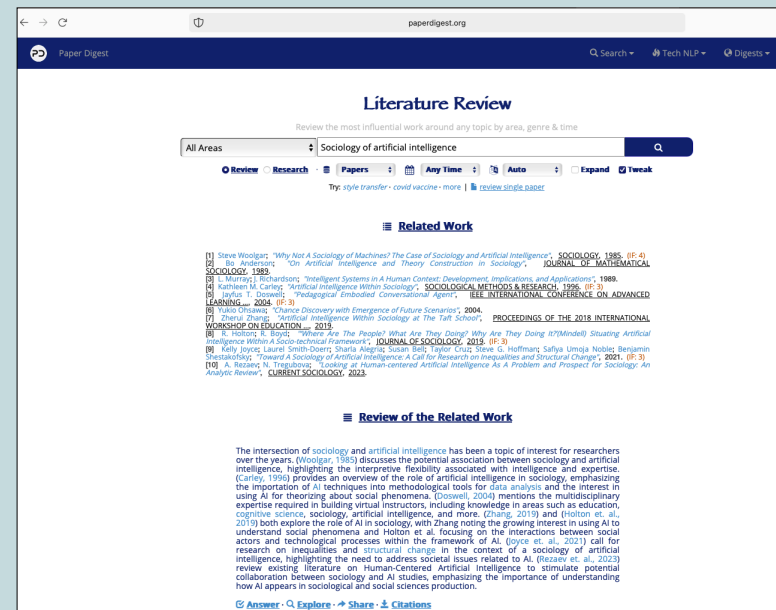
- automatyczne streszczenia artykułów,
- analiza tekstu i kluczowe informacje,
- metadane artykułów.

Zastosowanie:

- szybkie przeszukiwanie literatury naukowej,
- ocena przydatności artykułów do konkretnego tematu,
- uchwycenie głównych założeń artykułów,
- szybsza selekcja materiałów do badań,
- organizacja artykułów.

Cena:

- darmowy dla podstawowych funkcji, płatne zaawansowane funkcje.



<https://www.paperdigest.org>

Perplexity

Perplexity to wyszukiwarka oparta na sztucznej inteligencji, która rewolucjonizuje sposób wyszukiwania informacji. Zamiast tradycyjnych list linków, Perplexity odpowiada na pytania bezpośrednio, podając źródła. Sztuczna inteligencja analizuje strony internetowe, wyciągając kluczowe informacje i generując zwarte odpowiedzi. Użytkownicy mogą zadawać kolejne pytania, pogłębiając temat i odkrywając nowe powiązania. Perplexity wspiera szybkie zdobywanie wiedzy, analizę informacji i efektywne badania. Dostępna za darmo, z opcjonalnymi funkcjami premium, Perplexity zwiększa efektywność wyszukiwania, ułatwiając nawigację w ogromie informacji online.

Główne cechy:

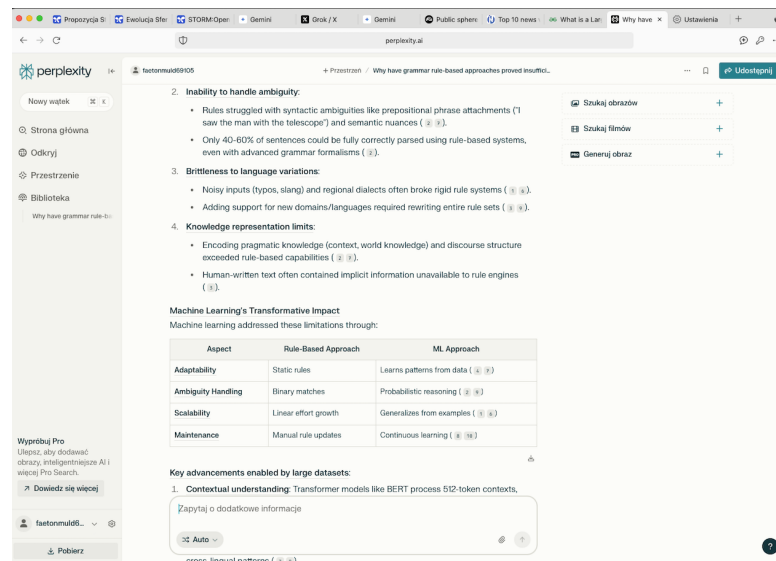
- odpowiedzi generowane przez AI,
- cytowanie źródeł,
- interaktywny interfejs.

Zastosowanie:

- wyszukiwanie informacji,
- wsparcie badań,
- szybkie podejmowanie decyzji.

Cena:

- podstawowe funkcje darmowe,
- zaawansowane opcje płatne.



<https://www.perplexity.ai>

Scholarcy

Scholarcy to oparte na AI narzędzie, które usprawnia przegląd literatury naukowej. Analizuje artykuły, wyodrębniając kluczowe informacje, argumenty i dane, tworząc inteligentne streszczenia. Ułatwia szybkie zrozumienie złożonych publikacji, ekstrakcję danych i automatyczne generowanie bibliografii. Scholarcy pomaga w efektywnej selekcji artykułów i wyodrębnianiu istotnych informacji. To idealne rozwiązanie dla naukowców, studentów i badaczy, oszczędzające czas przy pisaniu prac naukowych. Dostępny jest darmowy plan z ograniczeniami oraz płatne subskrypcje z pełną funkcjonalnością, czyniąc badania bardziej efektywnymi.

Główne cechy:


- analiza artykułów naukowych i wyodrębnianie kluczowych informacji,
- inteligentne streszczenia artykułów,
- ekstrakcja danych i argumentów,
- automatyczne tworzenie bibliografii.

Zastosowanie:

- szybkie przeglądy literatury naukowej,
- efektywna selekcja artykułów,
- wyodrębnianie kluczowych danych i argumentów,
- tworzenie bibliografii,
- zrozumienie złożonych artykułów.

Cena:

- darmowy plan z ograniczeniami, płatne plany subskrypcyjne.



<https://library.scholarcy.com>

Semantic Scholar

Semantic Scholar to bezpłatna wyszukiwarka literatury naukowej, wykorzystująca AI i NLP. Analizuje artykuły, wyodrębniając kluczowe informacje, powiązania i cytaty. Umożliwia profilowanie badaczy i personalizuje wyniki wyszukiwania. Narzędzie ułatwia przegląd literatury, śledzenie postępów, analizę wpływu publikacji, tworzenie bibliografii i streszczanie artykułów. Pomaga znaleźć prace o podobnej metodologii i analizować trendy badawcze. Dzięki obszernej bazie danych, Semantic Scholar wspiera proces badawczy, umożliwiając efektywne poruszanie się po świecie naukowych publikacji.

Główne cechy:

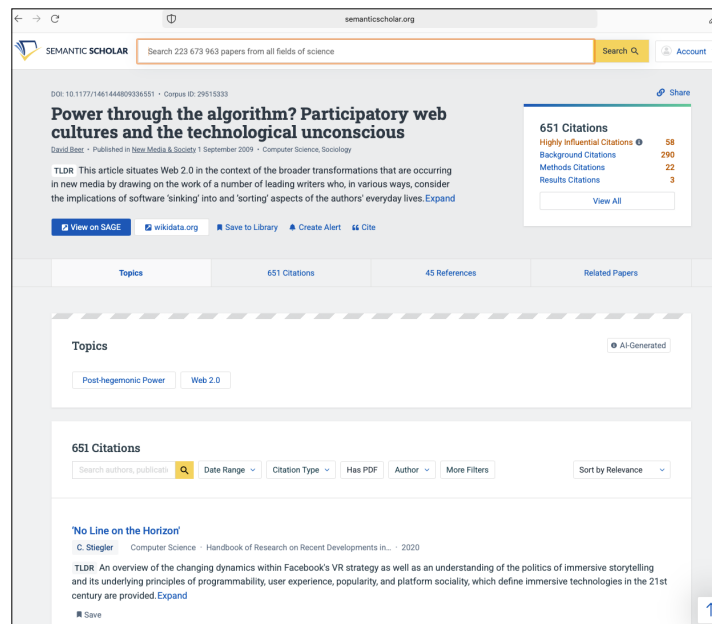
- wyszukiwarka literatury naukowej,
- analiza cytowań i powiązań między pracami,
- wyodrębnianie kluczowych informacji i podsumowań,
- profilowanie badaczy i personalizacja wyników,
- obszerna baza danych z wielu dziedzin.

Zastosowanie:

- przegląd literatury,
- analiza wpływu publikacji,
- tworzenie bibliografii i analiza trendów,
- streszczanie i wyszukiwanie podobnych artykułów.

Cena:

- całkowicie bezpłatny.



<https://www.semanticscholar.org>

Consensus

Consensus to narzędzie AI analizujące publikacje naukowe i dostarczające odpowiedzi oparte na dowodach. Ocenia konsensus w danej dziedzinie, odpowiadając na pytania użytkownika na podstawie literatury. Identyfikuje braki w badaniach. Narzędzie służy do szybkiego uzyskiwania odpowiedzi, weryfikacji hipotez, pisania wprowadzeń, identyfikacji luk, przygotowywania prezentacji i oceny wiarygodności danych. Consensus oferuje darmowy plan z ograniczeniami oraz płatne plany z rozszerzonymi funkcjami, pomagając badaczom ocenić stan wiedzy.

Główne cechy:

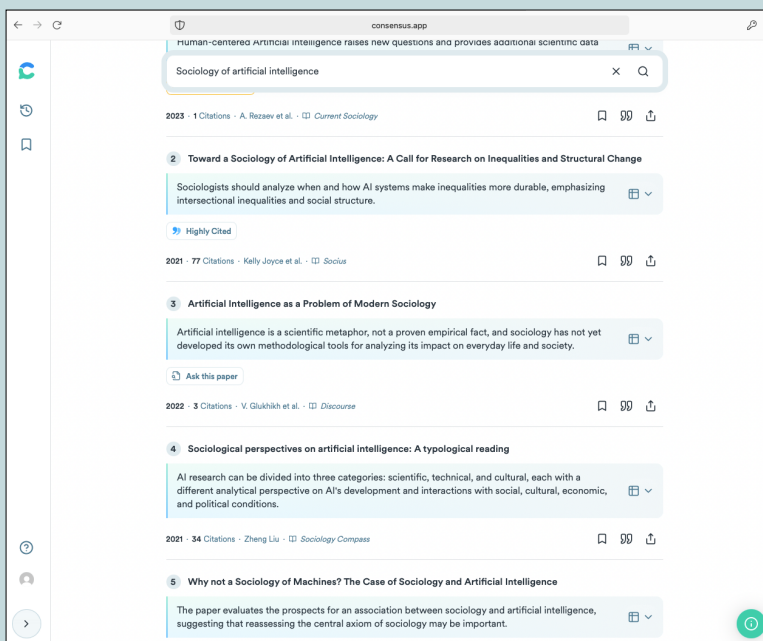
- analiza publikacji i wyników badań,
- ocena konsensusu,
- odpowiedzi oparte na literaturze,
- wskazywanie braków w badaniach.

Zastosowanie:

- szybkie uzyskiwanie odpowiedzi na pytania badawcze.
- weryfikacja hipotez i argumentów,
- pisanie wprowadzenia do prac naukowych,
- identyfikacja braków w literaturze,
- przygotowywanie prezentacji,
- wsparcie w nauce i ocena wiarygodności danych.

Cena:

- darmowy plan z ograniczeniami, płatne plany.



<https://consensus.app>

D. Wizualizacja i mapowanie literatury naukowej

Research Rabbit

Research Rabbit wizualnie eksploruje literaturę naukową, tworząc interaktywne sieci powiązań między publikacjami, autorami i tematami. Umożliwia odkrywanie relacji cytowań na dynamicznych mapach, identyfikując kluczowe prace i śledząc rozwój tematów, co pomaga w wykrywaniu luk w wiedzy. Narzędzie służy do przeglądania literatury, wizualizacji struktury dziedziny i identyfikacji istotnych publikacji. Research Rabbit oferuje bezpłatną wersję z podstawowymi funkcjami oraz płatne plany premium z zaawansowanymi opcjami. Integruje się z innymi narzędziami, zwiększając efektywność badań.

Główne cechy:

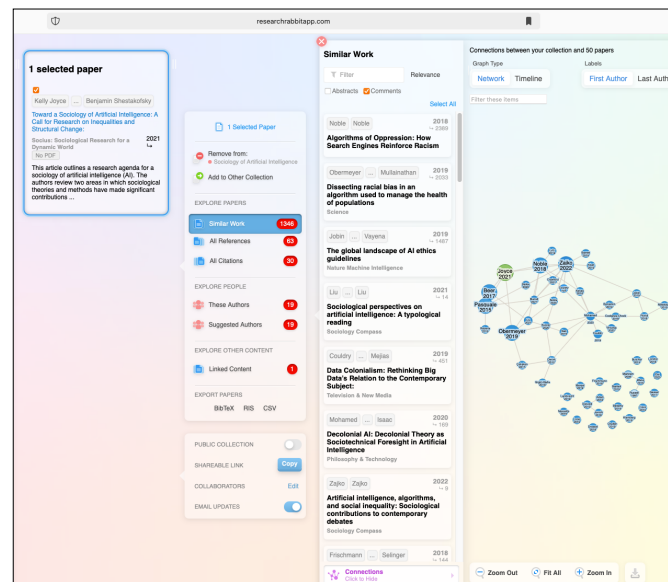
- narzędzie do eksploracji literatury,
- interaktywne sieci powiązań,
- analiza cytowań,
- dynamiczne mapy wiedzy,
- identyfikacja kluczowych prac i autorów.

Zastosowanie:

- przegląd literatury,
- identyfikacja kluczowych prac,
- analiza trendów,
- wykrywanie luk w wiedzy.

Cena:

- bezpłatny plan, płatne plany premium.



<https://researchrabbitapp.com/>

Connected Papers

Connected Papers wizualnie eksploruje literaturę naukową, tworząc graf powiązań między publikacjami na podstawie cytowań i podobieństw. Wskazuje najważniejsze prace w danej dziedzinie, ułatwiając nawigację i odkrywanie powiązanych publikacji. Narzędzie służy do przeglądu literatury, pomagając w znajdowaniu wpływowych prac i uzupełnianiu wiedzy. Connected Papers oferuje darmowy plan z ograniczeniami oraz płatne plany subskrypcyjne. Dzięki prostemu interfejsowi, nawigacja po grafie jest intuicyjna.

Główne cechy:


- tworzenie map literatury naukowej,
- identyfikacja powiązanych artykułów,
- wskazywanie kluczowych prac,
- łatwa nawigacja po grafie.

Zastosowanie:

- przegląd literatury i eksploracja tematów,
- odkrywanie powiązanych publikacji,
- znajdowanie najważniejszych i najbardziej wpływowych prac,
- uzupełnianie wiedzy z danej dziedziny,
- odkrywanie mniej znanych artykułów.

Cena:

- darmowy plan z ograniczoną liczbą map, płatne plany subskrypcyjne.



<https://www.connectedpapers.com/>

Litmaps

Litmaps wizualizuje literaturę naukową, przedstawiając powiązania między publikacjami na interaktywnych mapach. Umożliwia mapowanie cytowań, współcytowań i powiązań tematycznych, ułatwiając analizę badań i identyfikację trendów. Litmaps oferuje filtrowanie, sortowanie i personalizację map oraz import danych z Zotero. Służy do przeglądu literatury, pomagając naukowcom w efektywnym poruszaniu się po informacjach. Narzędzie oferuje darmowy okres próbny, a następnie płatne subskrypcje.

Główne cechy:

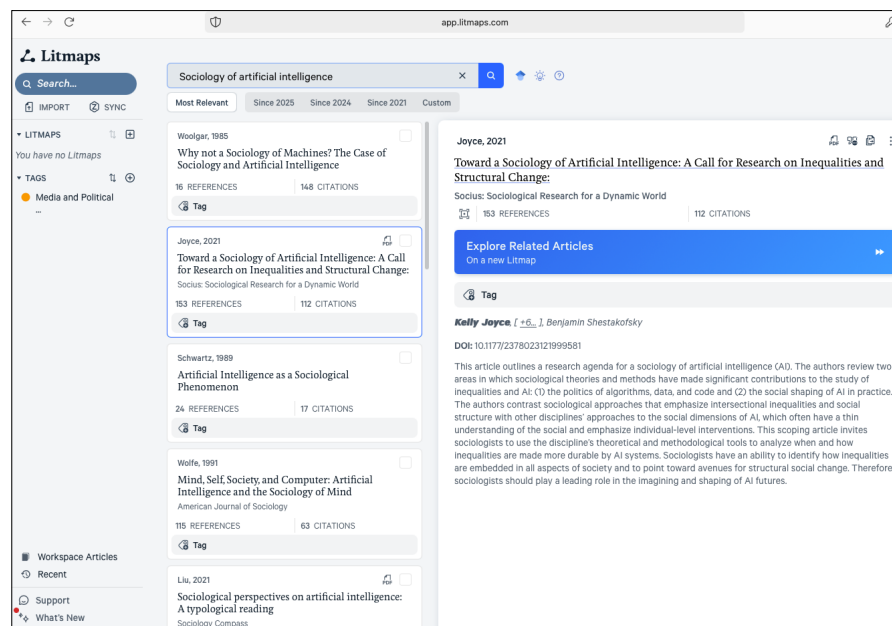
- wizualizacja literatury naukowej w formie interaktywnych map,
- mapowanie cytowań, współcytowań i powiązań tematycznych,
- filtrowanie i sortowanie publikacji,
- personalizacja map,
- możliwość importu danych z innych platform, takich jak Zotero.

Zastosowanie:

- przegląd literatury, eksploracja tematów,
- analiza powiązań między badaniami,
- znajdowanie trendów i luk w wiedzy.

Cena:

- darmowy okres próbny, płatne plany subskrypcyjne.



<https://app.litmaps.com/>

Afforai

Afforai to narzędzie AI do analizy dużych zbiorów dokumentów, w tym publikacji naukowych. Syntezuje wiedzę z wielu źródeł, w różnych formatach, w tym PDF. Dzięki chatbotowi AI, użytkownicy zadają pytania i otrzymują konkretne odpowiedzi, przyspieszając przegląd literatury. Afforai oferuje eksplorację wiedzy, ustawianie tonu i generowanie tekstu, wspierając raporty i pisanie prac. Ułatwia analizę dokumentów, syntezę wiedzy i pracę naukową. Afforai ma darmową wersję z ograniczeniami oraz płatne plany z rozszerzoną funkcjonalnością.

Główne cechy:

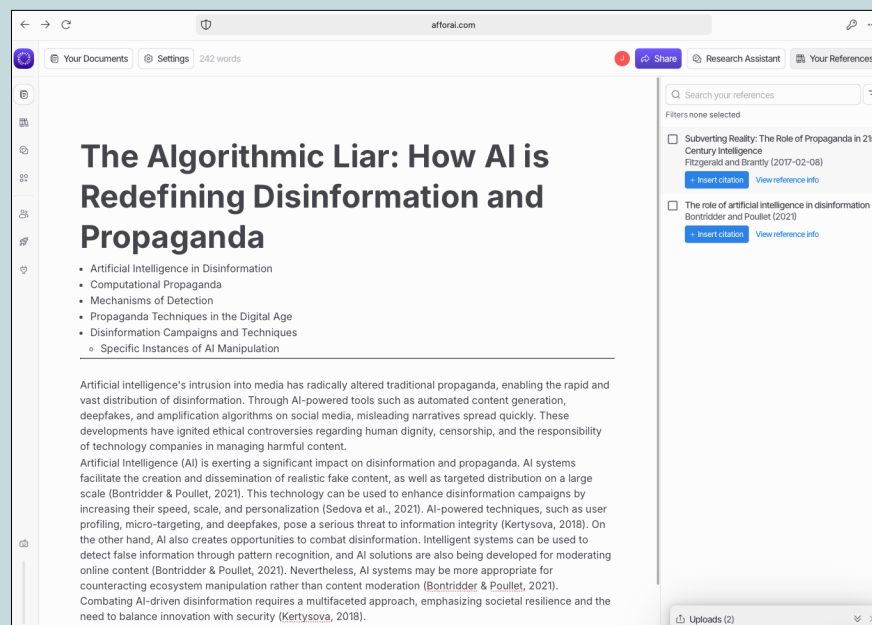
- analiza dokumentów z AI,
- synteza wiedzy z wielu źródeł,
- Praca z różnymi formatami plików (m.in. pdf),
- chatbot AI do zadawania pytań,
- narzędzia do eksploracji i generowania tekstu.

Zastosowanie:

- szybkie przeglądy literatury i analiza dokumentów,
- przygotowywanie raportów i wsparcie w pisaniu prac,
- praca z danymi, zadawanie pytań ai, łączenie wiedzy z wielu źródeł,
- analiza dokumentów z wielu formatów.

Cena:

- darmowy plan z ograniczeniami, płatne plany.



<https://afforai.com>

E. Redakcja tekstu i cytowań

QuillBot

QuillBot to narzędzie AI do pisania i edycji tekstów, oferujące parafrazowanie, streszczanie i sprawdzanie gramatyki. Dostosowuje styl tekstu, posiada synonimizer i funkcję podsumowywania. Umożliwia tłumaczenie i działa jako rozszerzenie przeglądarki. QuillBot pomaga w parafrazowaniu tekstów naukowych, unikaniu plagiatu, poprawie stylu i gramatyki. Dostępny w darmowej wersji z ograniczeniami oraz w płatnych planach subskrypcyjnych. Ułatwia i usprawnia pracę z tekstem.

Główne cechy:

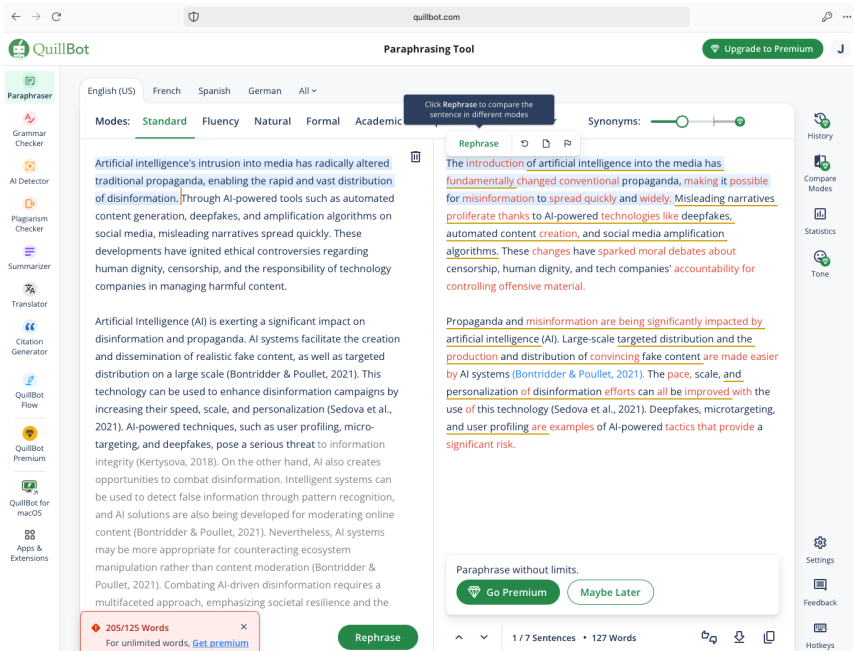
- parafrazowanie, streszczanie, gramatyka,
- różne tryby parafrazy,
- synonimizer,
- tłumaczenie tekstu,
- rozszerzenie przeglądarki i edytorów.

Zastosowanie:

- parafraza tekstu naukowego, unikanie plagiatu,
- poprawa stylu i jasności pisania,
- sprawdzanie gramatyczne i redakcja tekstu,
- tworzenie streszczeń z dłuższych tekstów,
- tłumaczenie tekstów naukowych.

Cena:

- darmowy plan z ograniczeniami, płatne plany subskrypcyjne.



<https://quillbot.com>

SciSpace

SciSpace to platforma usprawniająca pisanie i publikację artykułów naukowych. Oferuje formatowanie, edycję i szablony dla różnych czasopism. Automatycznie formatuje bibliografię i sprawdza cytowania. SciSpace zawiera edytor tekstu i narzędzia do analizy. Platforma jest płatna, z planami subskrypcyjnymi. Służy do przygotowania artykułów, formatowania tekstu, zarządzania bibliografią, sprawdzania cytowań i współpracy.

Główne cechy:


- narzędzie do formatowania i edycji artykułów,
- obsługa szablonów,
- automatyczne formatowanie bibliografii i cytowań,
- wbudowany edytor,
- analiza tekstu.

Zastosowanie:

- przygotowanie artykułów do publikacji,
- formatowanie zgodne z wytycznymi,
- zarządzanie bibliografią,
- sprawdzanie cytowań,
- współpraca z autorami.

Cena:

- płatna platforma, różne plany subskrypcyjne (często dostępne dla instytucji).



<https://scispace.com>

III. GEN AI i kompetencje przyszłości w nauce

A. Nowa era metodologii badawczej

Generatywna Sztuczna Inteligencja (GenAI) wykracza poza ramy zwykłego narzędzia w rękach naukowca. Reprezentuje ona potencjalny przełom, który może fundamentalnie zmienić sposób prowadzenia badań naukowych. Dzięki zdolności do autonomicznego generowania nowatorskich danych, hipotez, projektów i rozwiązań, GenAI otwiera przed nauką obszary dotychczas niedostępne lub nieefektywne czasowo przy tradycyjnych metodach.

1. Rewolucja w procesie badawczym

Generowanie hipotez i wyznaczanie kierunków badań.

Tradycyjny proces formułowania hipotez, oparty na intuicji i żmudnej analizie literatury, zyskuje dynamiczne wsparcie. GenAI, przeszukując rozległe zbiory danych naukowych, publikacji, patentów i specjalistycznych baz danych (takich jak PubMed czy Web of Science), działa z szybkością nieosiągalną dla człowieka. Umożliwia to identyfikację ukrytych korelacji, wzorców i luk w aktualnej wiedzy, co skutkuje nowymi, perspektywicznymi ścieżkami badawczymi (Wang i in., 2023).

Przykład: W biologii systemów, GenAI analizując dane omiczne (genomikę, proteomikę, metabolomikę) może wskazać innowacyjne markery chorobowe lub cele terapeutyczne, generując hipotezy dotyczące mechanizmów chorób, które dotychczas pozostawały niezauważone.

Projektowanie eksperymentów *in silico*. W miejsce metody prób i błędów, GenAI wprowadza symulacje komputerowe *in silico* na niespotykaną skalę. Pozwala to na modelowanie złożonych systemów, prognozowanie wyników eksperymentów w różnych warunkach, optymalizację parametrów badawczych oraz znaczącą redukcję kosztownych i czasochłonnych eksperymentów laboratoryjnych. Dzięki zaawansowanym algorytmom sztucznej inteligencji możliwe jest także wykrywanie ukrytych zależności i wzorców w danych eksperymentalnych.

Przykład: W inżynierii materiałowej, GenAI symuluje właściwości nowych materiałów (np. wytrzymałość, przewodnictwo) na poziomie atomowym, efektywnie wspomagając projektowanie materiałów o pożądanych cechach, eliminując potrzebę fizycznej syntezy i testowania licznych potencjalnych kandydatów.

Automatyzacja analizy danych i formułowanie wniosków.

W dobie nauki generującej ogromne ilości danych (Big Data), tradycyjne metody analizy stają się ograniczeniem. GenAI, w szczególności uczenie maszynowe, oferuje idealne narzędzie do automatycznej analizy, wizualizacji i interpretacji złożonych danych. Umożliwia to odkrywanie subtelnych wzorców, anomalii i zależności, prowadząc do wniosków, które mogłyby umknąć ludzkiej uwadze.

Przykład. W astronomii, GenAI analizuje ogromne zbiory danych z teleskopów (obrazy, spektra), identyfikując nowe ciała niebieskie i klasyfikując galaktyki oraz inne obiekty kosmiczne z precyzją i szybkością niedostępną dla konwencjonalnych metod.

2. Odkrywanie nowych materiałów, leków i technologii

Drug Discovery i projektowanie leków. Długotrwały, kosztowny i ryzykowny proces odkrywania nowych leków ulega transformacji dzięki GenAI, która rewolucjonizuje wiele jego etapów.

Identyfikacja celów terapeutycznych. Analiza danych biologicznych w celu wyłonienia nowych molekularnych celów dla interwencji farmakologicznej.

Projektowanie cząsteczek o pożądanych właściwościach. Generowanie innowacyjnych struktur molekularnych zdolnych do interakcji z celami terapeutycznymi, z optymalizacją ich aktywności, selektywności i profilu farmakokinetycznego.

Predykcja interakcji lek-cel. Symulacje interakcji molekularnych w celu przewidywania skuteczności i bezpieczeństwa potencjalnych substancji leczniczych.

Optymalizacja badań klinicznych. Analiza danych z badań klinicznych w celu identyfikacji grup pacjentów najlepiej reagujących na dany lek, co umożliwi personalizację terapii.

Przykład. Przedsiębiorstwa farmaceutyczne wykorzystują GenAI do projektowania nowej generacji antybiotyków, leków przeciwnowotworowych i terapii chorób neurodegeneracyjnych, znacząco przyspieszając proces *drug discovery*.

Inżynieria materiałowa i projektowanie materiałów „na miarę”. GenAI otwiera nowe możliwości w projektowaniu materiałów o ściśle określonych właściwościach, dostosowanych do konkretnych zastosowań.

Generowanie struktur krystalicznych i architektur materiałowych. Projektowanie nowatorskich materiałów o unikalnych strukturach atomowych i mikrostrukturach.

Predykcja właściwości materiałów. Prognozowanie mechanicznych, elektrycznych, optycznych i termicznych właściwości materiałów na podstawie ich składu i struktury.

Optymalizacja procesów produkcyjnych. Projektowanie procesów syntezy i obróbki materiałów w celu uzyskania pożądanych właściwości przy jednoczesnej minimalizacji kosztów.

Przykład: Naukowcy wykorzystują GenAI do projektowania nowatorskich baterii o zwiększonej gęstości energii, lekkich i wytrzymałych kompozytów lotniczych, wydajniejszych ogniw słonecznych oraz zaawansowanych sensorów.

3. Automatyzacja laboratoriów i robotyzacja badań

Inteligentne systemy laboratoryjne. GenAI może przejąć kontrolę nad robotami laboratoryjnymi, automatyzując rutynowe zadania, takie jak pipetowanie, przygotowywanie próbek, przeprowadzanie eksperymentów i gromadzenie danych.

Optymalizacja organizacji pracy w laboratorium. Zarządzanie eksperymentami, planowanie harmonogramów zadań, monitorowanie postępów i automatyczne generowanie raportów z wynikami.

Laboratoria „ciemne” (*dark labs*). Wizja w pełni zautomatyzowanych laboratoriów, zdolnych do prowadzenia eksperymentów w trybie 24/7, bez stałej interwencji człowieka, co znacząco przyspiesza tempo odkryć naukowych.

Przykład. W dziedzinie chemii i biologii, roboty wspierane przez AI mogą automatycznie przeprowadzać syntezy chemiczne, hodowle komórkowe, testy przesiewowe i analizy, uwalniając naukowców od monotonicznych zadań i umożliwiając im skupienie się na interpretacji wyników i planowaniu dalszych kroków badawczych.

4. Podsumowanie

Generatywna sztuczna inteligencja (GenAI) wyznacza nową erę w metodologii badawczej, przekształcając się z narzędzia w potencjalny motor przełomowych zmian w nauce. Dzięki zdolności do autonomicznego generowania nowatorskich hipotez, projektów i rozwiązań poprzez analizę ogromnych zbiorów danych (np. publikacji naukowych, baz danych jak PubMed), GenAI rewolucjonizuje proces badawczy. Umożliwia szybsze formułowanie hipotez, identyfikację ukrytych wzorców, projektowanie i optymalizację eksperymentów *in silico* (redukując koszty i czas badań laboratoryjnych) oraz automatyzację analizy złożonych danych (Big Data), co prowadzi do wniosków, które mogłyby umknąć ludzkiej uwadze.

Praktyczne zastosowania GenAI obejmują przyspieszenie procesu odkrywania i projektowania nowych leków (*drug discovery*) na każdym etapie – od identyfikacji celów po optymalizację badań klinicznych – oraz inżynierię materiałową, gdzie pozwala na projektowanie materiałów „na miarę” o ściśle określonych właściwościach. Ponadto, GenAI napędza automatyzację laboratoriów, sterując robotami wykonującymi rutynowe zadania, optymalizując przepływ pracy i zmierzając ku wizji w pełni zautomatyzowanych „ciemnych laboratoriów”. Uwalnia to naukowców od monotonicznych zadań, pozwalając im skupić się na interpretacji wyników i strategicznym planowaniu badań.

B. Kompetencje przyszłości: ewolucja roli naukowca

Wraz z nadejściem ery GenAI, zmienia się profil kompetencji kluczowych dla naukowców. Nie chodzi o zastąpienie naukowców przez sztuczną inteligencję, lecz o ewolucję ich roli i efektywną współpracę na linii człowiek-maszyna.

1. Kompetencje techniczne i cyfrowe (umiejętność współpracy z AI)

„AI Literacy”. Zrozumienie podstawowych zasad działania algorytmów GenAI, ich możliwości i ograniczeń. Nie jest wymagana ekspercka wiedza o AI, lecz orientacja w działaniu narzędzi, z których się korzysta.

Krytyczna ocena wyników AI. Kompetencja w interpretacji wyników generowanych przez AI, identyfikowaniu potencjalnych błędów, obciążeń i ograniczeń modeli. Zaufanie z elementem krytycyzmu wobec AI.

Projektowanie zapytań i konfiguracji AI. Umiejętność formułowania precyzyjnych zapytań oraz definiowania parametrów i ustawień algorytmów GenAI w celu uzyskania oczekiwanych rezultatów.

Zaawansowana analiza danych i wizualizacja. Kompetencje w zakresie statystyki, uczenia maszynowego i wizualizacji danych nabierają jeszcze większego znaczenia. Naukowcy będą pra-

cować z jeszcze obszerniejszymi zbiorami danych i interpretować bardziej złożone wyniki dostarczane przez AI.

Programowanie i modelowanie. Znajomość języków programowania (np. Python, R) oraz narzędzi do modelowania i symulacji staje się niezbędna do interakcji z GenAI, personalizacji algorytmów, tworzenia własnych narzędzi i analizy danych. Choć nie każdy naukowiec musi być programistą, pewna biegłość w tym obszarze będzie wysoce wartościowa.

Zarządzanie danymi i infrastrukturą cyfrową. Kompetencje w zakresie zarządzania dużymi zbiorami danych, cyberbezpieczeństwa, chmur obliczeniowych i infrastruktury cyfrowej zyskują na znaczeniu w nauce opartej na danych.

2. Kompetencje miękkie i kognitywne

Kreatywność i innowacyjność. Paradoksalnie, w erze automatyzacji, kreatywność i innowacyjność stają się jeszcze bardziej istotne. GenAI może wspomagać generowanie pomysłów, lecz to ludzka kreatywność i intuicja nadal będą motorem przełomowych odkryć i wyznacznikiem nowych kierunków badań. Naukowcy muszą skupić się na formułowaniu nowatorskich pytań badawczych, nieszablonywym myśleniu i interdyscyplinarnym łączeniu wiedzy.

Myślenie heurystyczne. Umiejętność analizy informacji, weryfikacji wyników, identyfikacji problemów i poszukiwania innowacyjnych rozwiązań pozostaje fundamentem pracy naukowej.

W kontekście GenAI, myślenie heurystyczne jest kluczowe dla oceny wiarygodności i rzetelności wyników generowanych przez AI.

Komunikacja i współpraca. Nauka staje się coraz bardziej interdyscyplinarna i oparta na współpracy. Umiejętność efektywnej komunikacji, pracy zespołowej, dzielenia się wiedzą i budowania sieci kontaktów jest kluczowa. Dodatkowo, umiejętność przekazywania złożonych wyników badań szerokiej publiczności zyskuje na znaczeniu w kontekście popularyzacji nauki i budowania zaufania do badań.

Etyka i odpowiedzialność. Wraz ze wzrostem możliwości GenAI, kwestie etyczne i odpowiedzialność za stosowanie tej technologii stają się priorytetowe. Naukowcy muszą być świadomi potencjalnych obciążeń w algorytmach, kwestii prywatności danych, odpowiedzialności za błędy AI oraz wpływu automatyzacji na społeczeństwo. Etyka badawcza w erze AI wymaga nowego podejścia i regulacji.

Ciągłe uczenie się i adaptacja. Tempo rozwoju technologii AI jest niezwykle szybkie. Naukowcy muszą być otwarci na ciągłe doskonalenie umiejętności, adaptację do zmieniających się narzędzi i metod badawczych oraz być na bieżąco z najnowszymi osiągnięciami w dziedzinie AI i swojej specjalizacji naukowej.

3. Wyzwania i obawy

Obciążenia w danych i algorytmach. GenAI uczy się na danych, a dane obarczone błędami mogą prowadzić do powielania i wzmacniania tych błędów przez AI, co skutkuje nierównymi lub niesprawiedliwymi wynikami w nauce i jej zastosowaniach.

Odpowiedzialność za błędy AI. Kto ponosi odpowiedzialność, gdy AI popełni błąd, który prowadzi do niepoprawnych wniosków naukowych lub szkodliwych konsekwencji w praktyce?

Prywatność danych i bezpieczeństwo. Wykorzystanie dużych zbiorów danych w nauce rodzi obawy dotyczące prywatności i bezpieczeństwa danych osobowych.

Dostępność technologii i równość. Czy dostęp do zaawansowanych narzędzi GenAI będzie równy dla wszystkich naukowców i instytucji, czy też pogłębi nierówności w środowisku naukowym?

Ryzyko nadmiernej zależności i deskilling. Istnieje obawa, że nadmierne poleganie na AI może prowadzić do zaniku pewnych umiejętności i wiedzy u naukowców (*deskilling*), a także do zbyt mechanicznego podejścia do badań, w którym kreatywność i intuicja zostaną zepchnięte na dalszy plan.

Dezinformacja naukowa i fake science. GenAI może zostać wykorzystana do generowania fałszywych wyników badań, publikacji naukowych i dezinformacji naukowej, co może podważyć zaufanie do nauki i spowolnić postęp. Konieczność wzmocnienia mechanizmów weryfikacji i recenzji naukowej w kontekście ery GenAI.

Wpływ na rynek pracy w nauce. Automatyzacja rutynowych zadań może skutkować zmianami w strukturze zatrudnienia w nauce, potencjalnie redukując zapotrzebowanie na niektóre stanowiska i kreując nowe, wymagające odmiennych kompetencji. Konieczność przekwalifikowania i dostosowania edukacji naukowej do ewoluujących potrzeb rynku pracy.

4. Podsumowanie i perspektywy

Generatywna AI stanowi potężne narzędzie o potencjale rewolucyjnych zmian w nauce na wielu płaszczyznach. Aby w pełni wykorzystać jej możliwości i zminimalizować potencjalne ryzyka, kluczowe jest:

- rozwijanie nowych kompetencji u naukowców, zarówno w obszarze technologii, jak i umiejętności miękkich,
- ustanowienie ram etycznych i regulacyjnych dla odpowiedzialnego wykorzystania GenAI w nauce,
- inwestowanie w edukację i infrastrukturę cyfrową w sektorze nauki,
- promowanie synergii człowiek-maszyna i wykorzystanie GenAI jako wsparcia, a nie substytutu, dla ludzkiej kreatywności i inteligencji.

GenAI rozpoczyna transformację metodologii badawczej, wykraczając poza automatyzację rutynowych zadań. Jej prawdziwy potencjał tkwi w generowaniu hipotez, odkrywaniu wzorców w danych i wspieraniu tworzenia modeli, co otwiera nowe ścieżki eksploracji naukowej. Dzięki temu naukowcy mogą bardziej skoncentrować się na kreatywności, interpretacji i strategii badawczej.

W dłuższej perspektywie, integracja GenAI wymusi zmiany w całym ekosystemie nauki, od finansowania po publikację. Rodzi to jednak istotne wyzwania etyczne dotyczące autorstwa, błędów algorytmów i potencjalnych uprzedzeń w danych. Kluczowe stają się transparentność, mechanizmy weryfikacji oraz międzynarodowe standardy. Sukces zależy od biegłości technologicznej oraz mądrego kształtowania relacji człowiek-AI, z zachowaniem rzetelności naukowej i zaufania społecznego.

Przyszłość nauki w erze GenAI zapowiada się fascynująco i pełna wyzwań. Kluczem do sukcesu będzie rozważne i odpowiedzialne wdrożenie tej technologii oraz dostosowanie naukowców i systemów naukowych do nowych realiów.

Bibliografia

- Altman, S. (2025, 6 stycznia). *Reflections* [Sam Altman Blog]. <https://blog.samaltman.com/reflections>
- Artificial intelligence. (2023). W: *Britannica*. <https://www.britannica.com/technology/artificial-intelligence>
- Bankier.pl. (2025, 28 stycznia). *Chiński start-up, który zawstydził Wall Street. Kto stoi za DeepSeek?* <https://www.bankier.pl/wiadomosc/Chinski-start-up-ktory-zawstydzil-Wall-Street-Kto-stoi-za-DeepSeek-8882447.html>
- Bostrom, N. (2014). *Superintelligence: Paths, Dangers, Strategies*. Oxford University Press.
- Brown, M. (2025, 6 lutego). House lawmakers push to ban AI app DeepSeek from US government devices. *The Associated Press*. <https://apnews.com/article/deepseek-ai-china-us-ban-6fea0eb28735b9be7f4592185be5ff681>
- Daniel, L. (2025, 1 lutego). DeepSeek Data Leak Exposes 1 Million Sensitive Records. *Forbes*. <https://www.forbes.com/sites/larsdaniel/2025/02/01/deepseek-data-leak-exposes--1000000-sensitive-records/>
- Davies, P. (2025, 17 lutego). DeepSeek: Which countries have restricted the Chinese AI company or are questioning it? *Yahoo! News*. <https://uk.news.yahoo.com/deepseek-countries-restricted-chinese-ai-140144535.html>
- Elliott, A. (2022). *Making Sense of AI: Our Algorithmic World*. Polity Press.
- Google. (2025). *Gemini* (2.0 Flash) [Duży model językowy]. <https://gemini.google.com/app>
- Google. (2025). *Google AI Studio* (Gemini Flash Thinking Experimental 01-21) [Platforma programistyczna AI]. <https://ai.google/studio>
- Kumar, S. (2024, 2 maja). Benchmarking the Benchmark dataset Leakage in Large Language Models. *Medium*. <https://medium.com/@techsachin/benchmarking-the-benchmark-dataset-leakage-in-large-language-models-c0d052ef743e>
- Magryś, M. (2025, 15 stycznia). Co nowa regulacja sprzedaży chipów dla AI oznacza dla Polski? *LinkedIn*. <https://www.linkedin.com/pulse/cowna-regulacja-sprzedaży-chipów-dla-ai-oznacza-polski-marek-magryś-je5pf>
- Martin, I. (2025, 2 lutego). The EU Is Betting \$56 Million On Open Source AI. *Forbes*. <https://www.forbes.com/sites/ianmartin/2025/02/02/the-eu-is-betting-56-million-on-open-source-ai/>
- McMilin, E. (2022). Selection bias induced spurious correlations in large language models. *arXiv*. <https://arxiv.org/abs/2207.08982>
- Mistral AI. (2025). *Mistral* [Duży model językowy]. <https://chat.mistral.ai/chat>
- OpenAI. (2025). *ChatGPT* (GPT-4) [Duży model językowy]. <https://chat.openai.com/>
- Patel, D., Kourabi, A. J., O'Laughlin, D., & Knuhtsen, R. (2025, 31 stycznia). DeepSeek Debates: Chinese Leadership On Cost, True Training Cost, Closed Model Margin Impacts. *semianalysis*. <https://semianalysis.com/2025/01/31/deepseek-debates/>
- Russell, S. J., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (Wydanie 4). Pearson.
- Statista. (2025). Generative AI - Worldwide. <https://www.statista.com/outlook/tmo/artificial-intelligence/generative-ai/worldwide>
- Wang, H., Fu, T., Du, Y. i in. (2023). Scientific discovery in the age of artificial intelligence. *Nature* 620, 47–60 . <https://doi.org/10.1038/s41586-023-06221-2>
- xAI. (2023). *Grok* (Grok 3) [Duży model językowy]. <https://xai.com/grok>



<https://analytics.umcs.pl>

Centrum Sztucznej Inteligencji i Modelowania Komputerowego jest jednostką ogólnouniwersytecką Uniwersytetu Marii Curie-Skłodowskiej w Lublinie. Centrum prowadzi badania interdyscyplinarne, łącząc podejścia i metody charakterystyczne dla dyscyplin takich jak data science, informatyka, matematyka, ekonomia czy socjologia. Najważniejszym celem funkcjonalnym jednostki jest rozwijanie współpracy nauki z otoczeniem zewnętrznym, poprzez tworzenie przestrzeni dla realizacji innowacyjnych projektów naukowo-badawczych.

Dr hab. Jarosław Chodak – socjolog i historyk (UMCS). Pracownik Instytutu Socjologii oraz badacz w Centrum Sztucznej Inteligencji i Modelowania Komputerowego. Aktualnie koncentruje się na dezinformacji, AI oraz relacjach między mediami społecznościowymi, polityką i partycypacją. W przeszłości badał rewolucje, ruchy społeczne oraz opór obywatelski bez przemocy.

Dr Kamil Filipek – socjolog i analityk danych (UMCS). Dyrektor Centrum Sztucznej Inteligencji i Modelowania Komputerowego, pracownik Instytutu Socjologii. Bada implikacje rewolucji cyfrowej, sieci społeczne i przetwarzanie języka naturalnego (NLP). Obecnie skupia się na zastosowaniach AI w naukach społecznych. W przeszłości badał związki między mediami społecznościowymi a kapitałem społecznym.

„[...] opracowanie będzie stanowić wypełnienie istotnej luki na rynku wydawniczym oraz może stanowić cenne źródło informacji dla osób chcących zastosować współczesne narzędzia oparte o algorytmy sztucznej inteligencji dla potrzeb zwiększenia efektywności i jakości realizowanych prac badawczych”.

Z recenzji dr. hab. inż. Arkadiusza Goli, Profesora Politechniki Lubelskiej