

ISSN 2719-6550
e-ISSN 2719-7417

**JOURNAL OF EDUCATION,
TECHNOLOGY AND COMPUTER SCIENCE**

No. 7(37)/2026

SPECIAL NUMBER / NUMER SPECJALNY
PART 1 / CZĘŚĆ 1

GENERATIVE ARTIFICIAL INTELLIGENCE
IN STUDY PRACTICES.
DIAGNOSIS OF SCALE, AREAS,
AND INSTITUTIONAL CONDITIONS
RESEARCH REPORT

GENERATYWNA SZTUCZNA INTELIGENCJA
W PRAKTYKACH STUDIOWANIA.
DIAGNOZA SKALI, OBSZARÓW
I UWARUNKOWAŃ INSTYTUCJONALNYCH
RAPORT Z BADAŃ

Journal of Education, Technology and Computer Science is a continuation of
“Edukacja – Technika – Informatyka. Education – Technology – Computer Science” Journal



**Rzeszów University Press
Rzeszow 2026**

INTERNATIONAL SCIENTIFIC COMMITTEE

Wojciech Walat – University of Rzeszów (Poland) – Chair of Scientific Committee
Waldemar Furmanek – University of Rzeszów (Poland) – Honorary Chairman
Waldemar Lib – University of Rzeszów (Poland) – Scientific Secretary
Mirosław Babiarczyk – Jan Kochanowski University in Kielce (Poland)
Eunika Baron-Polańczyk – University of Zielona Góra (Poland)
Henryk Bednarczyk – Institute for Sustainable Technologies in Radom (Poland)
Erik Bratland – Nord University (Norway)
Miroslav Chráska – Palacký University Olomouc (Czech Republic)
Stanisław Domoradzki – University of Rzeszów (Poland)
Milan Ďuriš – Matej Bel University in Banská Bystrica (Slovakia)
Maria Filina – Ivane Javakhishvili Tbilisi State University (Georgia)
Nazik Harutyunyan – Yerevan State University (Armenia)
Slavoljub Hilčenko – College of Vocational Studies for Teacher and Trainers Education in Subotica (Serbia)
Binbin Jiang – Kennesaw State University (USA)
Krzysztof Kraszewski – Pedagogical University of Cracow (Poland)
Stefan M. Kwiatkowski – Committee of Pedagogical Science Polish Academy of Sciences in Warsaw (Poland)
Oksana Nagomiuk – Institute of Agroecology and Environmental management NAAS of Ukraine (Ukraine)
Henryk Noga – Pedagogical University of Cracow (Poland)
Yuri Pelekh – University of Rzeszów (Poland)
Czesław Plewka – University of Technology Koszalin (Poland)
Natalia Ridei – National Pedagogical Dragomanov University (Ukraine)
Čestmír Serafin – Palacký University Olomouc (Czech Republic)
Anna Shlikhta – Rivne State University of Humanities (Ukraine)
Wiktoria Sobczyk – AGH University of Science and Technology (Poland)
Na Song – Tianjin Conservatory of Music (China)
Ján Stebila – Matej Bel University in Banská Bystrica (Slovakia)
Maciej Tanaś – Academy of Special Education of Marii Grzegorzewskiej (Poland)
Konstantinos Tatsis – University of Ioannina (Greece)
Judit Torgyik – Kodolanyi Janos University (KJU) (Hungary)
Jim Wright – Kennesaw State University (USA)

EDITORIAL OFFICE

Wojciech Walat (main editor), Waldemar Lib (v-ce editor)

CORRECT

Bernadeta Lekacz, Anna Dziama

TECHNICAL ELABORATION

Beata Nisztuk, Arkadiusz Nisztuk

Publikacja jest dostępna na licencji Creative Commons
(CC BY-NC-ND 4.0 International)



© Copyright by Rzeszów University Press, 2026

ADDRESS OF EDITORIAL OFFICE

University of Rzeszów	Center for Innovation and Transfer
Faculty of Pedagogy	of Natural Sciences and Engineering Knowledge
Department of General Education and Educational Systems	Laboratory of Information Society Problems
ks. Józefa Jąłowego 24 Street; 35-010 Rzeszów	prof. Stanisława Pigonia 1 Street; 35-310 Rzeszów
tel. +48 17 872 1833, e-mail: keti@ur.edu.pl , https://journals.ur.edu.pl/jetacomps	

ISSN 2719-6550 e-ISSN 2719-7417 DOI: 10.15584/jetacomps

ADDRESS OF PUBLISHER

Rzeszów University Press
prof. Stanisława Pigonia 6 Street, 35-959 Rzeszów; tel.: 17 872 13 69, tel.: 17 872 14 26 (office)
e-mail: wydawnictwo@ur.edu.pl; <https://wydawnictwo.ur.edu.pl>
Issue I; size B5; 7,5 publishing sheets, 7 printing sheets, order no. 61/2026

GENERATIVE ARTIFICIAL INTELLIGENCE
IN STUDY PRACTICES.
DIAGNOSIS OF SCALE, AREAS,
AND INSTITUTIONAL CONDITIONS
RESEARCH REPORT

GENERATYWNA SZTUCZNA INTELIGENCJA
W PRAKTYKACH STUDIOWANIA.
DIAGNOZA SKALI, OBSZARÓW
I UWARUNKOWAŃ INSTYTUCJONALNYCH
RAPORT Z BADAŃ

REDAKCJA NAUKOWA RAPORTU

Aleksander Cywiński
Wojciech Walat

ZESPÓŁ AUTORSKI

Oliwia Bator, Uniwersytet Szczeciński
Aleksander Cywiński, Uniwersytet Szczeciński
Marta Gliniecka, Politechnika Koszalińska
Jarosław Janio, Santa Anna College, USA
Anita Karyń, Uniwersytet Szczeciński
Waldemar Lib, Uniwersytet Rzeszowski
Edyta Łuc-Kowalczyk, Uniwersytet Szczeciński
Krzysztof Łuszczek, Uniwersytet Szczeciński
Elżbieta Perzycka-Borowska, Uniwersytet Szczeciński
Joanna Szumiło-Jackowska, Uniwersytet Szczeciński
Wojciech Walat, Uniwersytet Rzeszowski
Tomasz Warzocha, Uniwersytet Rzeszowski
Aneta Witosz, Uniwersytet Szczeciński

RECENZENCI

Prof. PhDr. Milan Klement, Ph.D.
Prof dr hab. Maciej Sysło

SPIS TREŚCI

Wprowadzenie – uzasadnienie prowadzonych badań (Aleksander Cywiński, Wojciech Walat)	7
---	---

CZĘŚĆ PIERWSZA

Generatywna sztuczna inteligencja jako środowisko praktyk studiowania	13
1. Transformacje środowiska kształcenia i rola narzędzi generatywnej AI (Marta Gliniecka)	13
2. Praktyki studiowania z wykorzystaniem narzędzi generatywnej AI (Oliwia Bator, Aneta Witosz)	19
3. Odpowiedzialność kompetencyjna i krytyczna weryfikacja treści pozyskanych za pomocą narzędzi generatywnej AI (Anita Karyń, Krzysztof Łuszczek)	21
4. Instytucjonalne uwarunkowania korzystania z narzędzi generatywnej AI (Joanna Szumiło-Jackowska)	26

CZĘŚĆ DRUGA

Założenia metodologiczne badań własnych dotyczących wykorzystania generatywnej sztucznej inteligencji przez studentów (Elżbieta Perzycka-Borowska)	31
1. Paradygmat badawczy i logika wyjaśniania	31
2. Przedmiot i cele badań	32
3. Problemy, hipotezy, zmienne i wskaźniki badań	32
4. Metody, techniki i narzędzia badawcze	36
5. Organizacja i przebieg badań	37

CZĘŚĆ TRZECIA

Analiza i interpretacja wyników badań empirycznych dotyczących stosowania generatywnej AI przez studentów	41
1. Preferencje narzędziowe i subskrypcje dotyczące korzystania z narzędzi AI – wskaźnik instrumentalny (Marta Gliniecka, Elżbieta Perzycka-Borowska)	41
2. Obszary dydaktyczne i zadaniowe użycia narzędzi AI, wskaźnik funkcjonalny (Jarosław Janio, Edyta Kowalczyk-Łuc)	54
3. Weryfikacja treści i strategie krytyczne wobec treści generowanych za pomocą narzędzi AI, wskaźnik aksjologiczno-poznawczy (Anita Karyń, Krzysztof Łuszczek)	67
4. Jawność użycia narzędzi AI, obawy oraz wsparcie uczelni, wskaźnik etyczno-instytucjonalny (Aleksander Cywiński, Joanna Szumiło-Jackowska)	74
5. Zmiany w sposobie studiowania po wdrożeniu narzędzi AI, wskaźnik bilansu studiowania (Oliwia Bator, Aneta Witosz)	99

CZĘŚĆ CZWARTA

**Synteza pięciu problemów badawczych oraz rekomendacje wdrożeniowe dotyczące
stosowania generatywnej AI przez studentów (Waldemar Lib, Wojciech Walat,**

Tomasz Warzocha) 105

Aneks – słowniczek pojęć związanych z posługiwaniem się narzędziami GenAI 111

WPROWADZENIE – UZASADNIENIE PROWADZONYCH BADAŃ

ALEKSANDER CYWIŃSKI, WOJCIECH WALAT

Pochodzenie grupy badawczej i poprzednie projekty. Jesteśmy grupą naukowców reprezentującą kilka ośrodków akademickich z Polski – Uniwersytety w Koszalinie, Rzeszowie, Szczecinie i Zielonej Górze – oraz placówki zagraniczne z Niemiec i Stanów Zjednoczonych. Choć skład naszej grupy ewoluuje – pojawiają się nowi członkowie, inni zaś czasowo przerywają pracę – nasze zaangażowanie we wspólne projekty badawcze pozostaje stałe.

Filar naszej działalności stanowiła inicjatywa profesor Elżbiety Perzyckiej-Borowskiej podjęta na początku pandemii COVID-19. Dzięki formule pracy online i regularnym spotkaniom odbywającym się co tydzień w godzinach wieczornych prowadziliśmy intensywne, wielogodzinne dyskusje seminaryjne. Sesje te pozwoliły nam na gruntowne rozważenie konsekwencji lockdownu dla edukacji i – szerzej – dla funkcjonowania społeczeństwa.

Owocem tych intensywnych rozważań była publikacja zbiorowa pt. *Dzienniki z pandemii. Autorefleksje nauczycieli akademickich i studentów w kontekście edukacji zdalnej w Polsce* (redakcja naukowa: Elżbieta Perzycka, Eunika Baron-Polańczyk, Marta Gliniecka, Waldemar Lib, 2022). Biorąc pod uwagę, że analizowaliśmy przede wszystkim własne doświadczenia (do projektu zaproszeni zostali także studenci), osadziliśmy naszą pracę metodologicznie w autoetnografii – podejściu umożliwiającemu rzetelne zbadanie osobistych przeżyć w szerszym kontekście społeczno-kulturowym.

Trajektoria zmian: od pandemii przez wojnę do sztucznej inteligencji. W lutym 2022 r., gdy pandemia przemieniła się w stan względnie ustabilizowany (świadomość faktu, że SARS-CoV-2 pozostanie trwałym elementem naszej rzeczywistości), światem wstrząsnęła tragedia – rosyjska inwazja na Ukrainę i rozpoczęcie pełnowymiarowej wojny. Ta sytuacja geopolityczna, choć fundamentalnie różna w swej naturze od kryzysu epidemiologicznego, równie mocno sprowokowała nas do refleksji nad kryzysem cywilizacyjnym, którego doświadczamy – kryzysem zagrażającym naszemu modelowi życia i systemowi wartości.

Podczas wieczornych spotkań seminaryjnych nie poprzestaliśmy na bieżącym komentowaniu sytuacji – systematycznie rozważaliśmy również potencjalne scenariusze przyszłości. Ponownie zdecydowaliśmy się na autoetnograficzny zapis naszych refleksji. Rezultatem była kolejna publikacja zbiorowa: *Troska, co*

wojna w Ukrainie nam zrobiła? Autoetnograficzne opowieści studentów i nauczycieli akademickich (redakcja naukowa: Aleksander Cywiński, Waldemar Lib, Lidia Marek, Elżbieta Perzycka-Borowska, 2023).

Wojna w Ukrainie trwa do dziś, jednak pojawienie się narzędzi ChatGPT 3.5 w listopadzie 2022 r., a następnie kolejnych wersji tego systemu oraz innych modeli językowych (LLM-ów) otworzyło przed nami nową przestrzeń analityczną. Zjawisko sztucznej inteligencji stało się naturalnym przedłużeniem naszych badań nad transformacją społeczno-edukacyjną. Konsekwentnie opublikowaliśmy trzecią książkę w naszym cyklu: *Relacje człowieka z generatywną sztuczną inteligencją. Autoetnografie nauczycieli i studentów* (redakcja naukowa: Elżbieta Perzycka-Borowska, Waldemar Lib, Lidia Marek, Aleksander Cywiński, 2025).

Kontekst obecnych badań: kryzysy i nadzieje. Trajektoría naszych zainteresowań naukowych zmusza nas do kontynuowania pracy badawczej i pogłębiania współpracy. Autoetnograficzny charakter naszego podejścia metodologicznego nakazuje nam przyglądać się doświadczaniu sztucznej inteligencji w specyficznym momencie historycznym – momencie charakteryzowanym zarówno przez perspektywę dalszych potencjalnych kryzysów epidemiologicznych (dysponujemy wiedzą, że kolejna pandemia jest tylko kwestią czasu), jak i przez głębokie perturbacje geopolityczne związane z rozpadem dotychczasowego porządku międzynarodowego.

Słowa kanadyjskiego premiera Marka Carneya wypowiedziane podczas Światowego Forum Ekonomicznego w Davos w styczniu 2026 r. stanowią wymowne podsumowanie naszych obserwacji: *Dawny porządek świata się załamuje* (Lach, 2026). Rozumiejąc skalę czasu i dramatu tego procesu, posługujemy się – zainspirowanymi tradycją biblijną – metaforą „siedmiu lat chudych”. Traktując to sformułowanie dosłownie, jeżeli przyjąć jako początek 2020 r., przed ludzkością jeszcze co najmniej jeden rok intensywnych wyzwań i potencjalnych kataklizmów.

Pomimo pesymizmu wynikającego z realistycznej oceny sytuacji kierujemy się nadzieją – nadzieją, że ludzkość zdoła nie tylko zmierzyć się z zagrożeniami epidemiologicznymi na płaszczyźnie medycznej, ale także społeczno-ekonomicznej; że konflikty zbrojne przeminą; że fenomen sztucznej inteligencji stanie się katalizatorem postępu naukowego i równomiernego, sprawiedliwego rozwoju rodzaju ludzkiego.

Uzasadnienie wyboru tematyki badań oraz perspektywy diagnostycznej w świetle aktualnych przemian cyfrowych. Edukacja akademicka funkcjonuje obecnie w warunkach intensywnej transformacji poznawczo-instytucjonalnej, związanej z upowszechnieniem narzędzi generatywnej sztucznej inteligencji, w szczególności modeli językowych typu LLM. Zjawisko to zmienia zarówno mikropraktyki studiowania, takie jak wyszukiwanie informacji, streszczanie, planowanie pracy i redakcja tekstu, jak i makropraktyki instytucjonalne, obejmu-

jące polityki uczelni, projektowanie oceniania oraz rozumienie integralności akademickiej (Win Bo, 2023; QAA, 2023–2025; TEQSA, 2025). W ostatnich badaniach sondażowych dotyczących studentów widoczny jest wyraźny wzrost użycia narzędzi generatywnej AI przy jednoczesnym zróżnicowaniu sposobów korzystania oraz napięciach wokół norm jawności i odpowiedzialności. Raport HEPI z 2025 r. wskazuje na wzrost deklarowanego wykorzystania narzędzi generatywnych wśród studentów i rosnący udział narzędzi AI w wielu obszarach pracy akademickiej (Freeman, 2025).

W refleksji nad kształceniem akademickim szczególnego znaczenia nabierają trzy zagadnienia. Pierwsze dotyczy delegowania operacji poznawczych do środowiska algorytmicznego oraz konsekwencji tego procesu dla samoregulacji uczenia się. Drugie odnosi się do odpowiedzialności za jakość i wiarygodność treści generowanych przez modele, obejmującej rozpoznawanie błędów faktograficznych, pozornych cytowań oraz niespójności argumentacji. Trzecie dotyczy warunków etyczno-instytucjonalnych użycia narzędzi AI w kulturze akademickiej, w tym norm jawności, ryzyka stygmatyzacji oraz zakresu wsparcia uczelni w obszarze alfabetyzacji AI (UNESCO, 2024; QAA, 2023–2025).

Ramy interpretacyjne badań oparto na podejściu kompetencyjnym oraz *human centred*, akcentującym sprawczość człowieka, przejrzystość i odpowiedzialność w użyciu narzędzi AI. Perspektywę tę dobrze porządkują ramy UNESCO dla studentów i nauczycieli, które ujmują kompetencje posługiwania się narzędziami AI jako triadę: wartości, wiedzy i umiejętności, z silnym naciskiem na etykę, rozumienie ograniczeń modeli oraz krytyczną ocenę treści (UNESCO, 2024). W kontekście europejskim rośnie także znaczenie standardów odpowiedzialnego użycia narzędzi generatywnej AI, formułowanych w dokumentach odnoszących się do przejrzystości, ryzyka, ochrony danych i rozliczalności, co przekłada się na oczekiwania wobec praktyk akademickich i badawczych (European Commission, 2025).

Projekt badawczy: doświadczenia studentów w pracy z narzędziami AI.

W tym kontekście postanowiliśmy skupić się na empirycznym zbadaniu, jak doświadczają sztucznej inteligencji polscy studenci. Pomysł na badania ankietowe wyłonił się naturalnie podczas jednego z naszych seminariów – w atmosferze naukowego „fermentu”, w toku burzy mózgów, w której uczestniczyli naukowcy o różnych światopoglądach i doświadczeniach życiowych. Wspólnie sformułowaliśmy jedenaście pytań badawczych:

1. Z jakich narzędzi lub programów AI korzystasz? Wymień ich nazwy.
2. Do jakich celów najczęściej wykorzystujesz narzędzia AI?
3. Czy korzystasz z płatnych wersji (subskrypcji) narzędzi AI? Jeśli tak – jakich?
4. W jaki sposób narzędzia AI pomagają Ci w uczeniu się na studiach?

5. Co zmieniło się w Twoim sposobie studiowania od momentu, gdy zacząłeś/zaczęłaś korzystać z AI? W czym AI najbardziej ułatwia Ci studiowanie?

6. Do jakich rodzajów zadań na studiach najczęściej używasz AI (np. pisanie prac, przygotowanie prezentacji, nauka do egzaminów)?

7. Jakie widzisz potrzeby szkoleniowe w zakresie korzystania z AI na uczelni (dla studentów i/lub wykładowców)?

8. Czy obawiasz się przyznać wykładowcom, że korzystasz z AI? Jeśli tak – dlaczego?

9. Czy sprawdzasz (weryfikujesz) informacje, które otrzymujesz od takich narzędzi, jak ChatGPT? Jeśli tak – w jaki sposób?

10. Jeśli nie sprawdzasz informacji, które otrzymujesz od AI, z czego to wynika?

11. Czy otrzymujesz wsparcie ze strony uczelni dotyczące korzystania z AI?

Ograniczenia badań. Należy zwrócić uwagę na kilka ograniczeń metodologicznych. Zamiast wyciągać wnioski na poziomie populacji, badanie ma na celu uzyskanie analitycznie uzasadnionych spostrzeżeń dotyczących doświadczenia studentów z narzędziami AI. Przeprowadziliśmy badania ankietowe wśród studentów, z którymi utrzymujemy bezpośredni kontakt poprzez prowadzone zajęcia. Świadomie wychodzimy naprzeciw zarzutowi dotyczącemu reprezentatywności próby – nie pretendujemy do generalizacji wyników na całą populację studentów polskich ani do formułowania twierdzeń o charakterze uniwersalnym. Dodatkowo intencjonalnie zdecydowaliśmy się na sformułowanie pytań otwartych pomimo ryzyka niejednoznaczności odpowiedzi, chcąc uniknąć tzw. niedbałych odpowiedzi, tj. ignorowania treści pytań i odpowiadania bez rzeczywistego przetwarzania informacji (Goldammer, Annen, Stöckli, Jonas, 2020).

Nasz wybór metodologiczny jest intencjonalny i głęboko zakorzeniony w perspektywie autoetnograficznej. Pragniemy konfrontować nasze własne przemyślenia, doświadczenia, obawy i nadzieje z autentycznymi głosami studentów, którzy rzeczywiście korzystają z narzędzi sztucznej inteligencji w codziennej praktyce akademickiej. W ten sposób głos badanego staje się nie biernym przedmiotem analizy, ale aktywnym partnerem w dialogu naukowym nad transformacją edukacji.

Przyszłe badania prowadzone na większych i bardziej zróżnicowanych próbach mogłyby poszerzyć zakres porównań, sprawdzić trwałość zidentyfikowanych tendencji oraz doprecyzować, w jakim stopniu obserwowane praktyki mają charakter szerszy niż kontekst badanych środowisk akademickich.

Literatura

Cywiński, A., Lib, W., Marek, L., Perzycka-Borowska, E. (red.) (2023). *Troska, co wojna w Ukrainie nam zrobiła? Autoetnograficzne opowieści studentów i nauczycieli akademickich*. Rzeszów: Wyd. UR.

- European Commission (2025). *Living guidelines on the responsible use of generative AI in research. Publications Office of the European Union*. Pobrano z: https://research-and-innovation.ec.europa.eu/document/download/2b6cf7e5-36ac-41cb-aab5-0d32050143dc_en?filename=ec_rtd_ai-guidelines.pdf (17.01.2026).
- Freeman, J. (2025). *Student Generative AI Survey 2025*. Pobrano z: <https://www.hepi.ac.uk/reports/student-generative-ai-survey-2025/> (24.02.2026).
- Goldammer, P., Annen, H., Stöckli, P.L., Jonas, K. (2020). Careless responding in questionnaire measures: Detection, impact, and remedies. *The Leadership Quarterly*, 31(4), 101384. <https://doi.org/10.1016/j.leaqua.2020.101384>
- Lach, A. (2026). „Siła bezsilnych” w Davos. Premier Kanady: czas przestać udawać. Dawny porządek świata się załamał. Pobrano z: <https://www.bankier.pl/wiadomosc/Sila-bezsilnych-w-Davos-Premier-Kanady-zas-przestac-udawac-Dawny-porzadek-swiata-sie-zalamal-9071364.html> (24.03.2026).
- Perzycka, E., Baron-Polańczyk, E., Gliniecka, M., Lib, W. (red.) (2022). *Dzienniki z pandemii. Autorefleksje nauczycieli akademickich i studentów w kontekście edukacji zdalnej w Polsce*. Rzeszów: Wyd. UR.
- Perzycka-Borowska, E., Lib, W., Marek, L., Cywiński, A. (red.) (2025). *Relacje człowieka z generatywną sztuczną inteligencją. Autoetnografie nauczycieli i studentów*. Szczecin: Wyd. Naukowe USz.
- QAA (2023–2025). *Maintaining quality and standards in the ChatGPT era: QAA advice on the opportunities and challenges posed by Generative Artificial Intelligence*. Pobrano z: https://www.qaa.ac.uk/docs/qaa/members/maintaining-quality-and-standards-in-the-chatgpt-era.pdf?sfvrsn=2408aa81_10 (17.01.2026).
- TEQSA (2025). *Generative AI, academic integrity and assessment reform. Tertiary Education Quality and Standards Agency*. Pobrano z: <https://www.teqsa.gov.au/guides-resources/higher-education-good-practice-hub/gen-ai-knowledge-hub/gen-ai-academic-integrity-and-assessment-reform> (17.01.2026).
- UNESCO (2024). *AI competency framework for students*. Paris. Pobrano z: <https://unesdoc.unesco.org/ark:/48223/pf0000391105> (20.03.2026).

CZĘŚĆ PIERWSZA

GENERATYWNA SZTUCZNA INTELIGENCJA JAKO ŚRODOWISKO PRAKTYK STUDIOWANIA

1. TRANSFORMACJE ŚRODOWISKA KSZTAŁCENIA I ROLA NARZĘDZI GENERATYWNEJ AI

MARTA GLINIECKA

Intensywny rozwój nowych technologii – w tym wielkich modeli językowych (*Large Language Models* – LLM) oraz algorytmów generatywnej AI – otwiera nowe możliwości w kontekście edukacji całonocnej. Narzędzia generatywnej AI stają się nieodłącznym elementem procesu samokształcenia oraz samodzielnego konstruowania wiedzy, co wpisuje się w założenia konektywizmu (Siemens, 2004). Jednocześnie wymagają one od użytkowników nabywania nowego typu kompetencji. Oprócz wyszukiwania informacji istotna staje się także umiejętność formułowania precyzyjnych promptów oraz stawiania określonych pytań i problemów do rozwiązania. Jak zauważa Kuruliszwili (2024, s. 128), „algorytm staje się partnerem, który interaktywnie i iteracyjnie pomaga nam znaleźć rozwiązanie. Nowa staje się również forma interakcji – możliwość komunikacji głosowej zmienia sposób, w jaki wykorzystujemy te narzędzia”, przekształcając pracę z algorytmem w proces współpracy pomiędzy użytkownikiem a maszyną.

Można zauważyć, że w ostatnich latach powstaje coraz więcej narzędzi generatywnej AI, które umożliwiają nie tylko generowanie danych tekstowych, ale również materiałów audiowizualnych – w tym grafik, ilustracji, wykresów, animacji, materiałów wideo i animacji (Raszyd, Wesołowska, Tomaszewska, 2024). Na poniższym schemacie graficznym zobrazowano przykładowe rodzaje narzędzi generatywnej AI, które mogą być wykorzystywane do różnych celów edukacyjnych. Zachodzące zmiany znajdują odzwierciedlenie w procesie nauczania i uczenia się na różnych etapach edukacyjnych.

Szkolnictwo wyższe funkcjonuje obecnie w warunkach intensywnej algorytmizacji procesów poznawczych, organizacyjnych i dydaktycznych, związanej

z szybkim upowszechnieniem narzędzi AI. Zmiana obejmuje zarówno mikropraktyki studiowania, takie jak wyszukiwanie informacji, streszczanie, planowanie pracy, redagowanie tekstów i przygotowanie do zajęć, jak i makropraktyki instytucjonalne, w tym polityki integralności akademickiej, projektowanie oceniania i redefinicję tego, co weryfikuje się jako efekt uczenia się (UNESCO, 2024). W literaturze podkreśla się, że generatywna AI różni się jakościowo od wcześniejszych narzędzi cyfrowych, ponieważ nie ogranicza się do selekcji zasobów, lecz aktywnie uczestniczy w wytwarzaniu treści, strukturyzowaniu argumentacji i modelowaniu wypowiedzi, co wpływa na tempo pracy oraz strategię uczenia się studentów (Luckin, Holmes, Griffiths, Forcier, 2023; Kasneci, 2023). Badania oparte na wypowiedziach studentów pokazują, że AI jest postrzegana zarówno jako wsparcie w procesie uczenia się, jak i źródło dylematów etycznych (Chan, Hu, 2023).

		
GENERATORY OBRAZU	GENERATORY TEKSTU	GENERATORY AUDIO
• tworzenie ilustracji, infografik, zdjęć • generowanie wideo, animacji • przygotowanie prezentacji (Prezi AI, Sora, Midjourney, Adobe Firefly, Canva AI i inne)	• tworzenie tekstów, podsumowań, raportów • analiza i porównanie danych (ChatGPT, Gemini AI, Perplexity, Microsoft Copilot, DeepSeek, DeepL Translate)	• tworzenie muzyki, narracji głosowych, podcastów, transkrypcji nagrań (ElevenLabs, Google NotebookLM, Turbo Scribe AI, Suno AI)

Rysunek 1. Rodzaje narzędzi generatywnej AI oraz możliwości ich zastosowania (opracowanie w programie Canva)

Źródło: archiwum własne.

Zachodzące zmiany skłaniają do stawiania pytań nie tylko o formy, ale także o cele wykorzystywania generatywnej AI w procesie kształcenia. Część badaczy (Chiu i in., 2022) proponuje trzy wiodące cele edukacji w zakresie zastosowania AI:

- a) przygotowanie młodych ludzi do życia w świecie algorytmów generatywnej AI;
- b) rozwijanie kreatywności w obszarze wykorzystania AI oraz

c) kształcenie przyszłych specjalistów z różnych dziedzin w zakresie integrowania AI z praktyką zawodową.

Refleksja nad praktykami edukacyjnymi z wykorzystaniem AI znajduje empiryczne potwierdzenie w badaniach prowadzonych w różnych kontekstach kulturowych. Przykładem może być projekt badań jakościowych zrealizowany w 2022 r. w szkołach średnich w Hongkongu (Yau i in., 2023). Jego celem było pokazanie, w jaki sposób nauczyciele postrzegają edukację z wykorzystaniem AI. Badacze zastosowali podejście fenomenograficzne, wyodrębniając sześć kategorii opisu, które stały się podstawą dla skonstruowania podmiotowych koncepcji znaczeń przypisywanych przez uczestników badań. Okazuje się, że nauczyciele, którzy na co dzień wykorzystują narzędzia cyfrowe w swojej pracy dydaktycznej, postrzegają generatywną AI jako cenny zasób. To dla nich m.in.: źródło wiedzy i kompetencji, narzędzie stymulacji rozwoju i zainteresowania uczniów, a także bodziec do refleksji i kształtowania postaw etycznych.

W skali światowej coraz silnie zaznacza się przejście od reakcji opartych na prostych zakazach ku podejściu, które integruje generatywną AI z celami kształcenia, wymaganiami dyscyplin oraz standardami zawodowymi. W tym nurcie rozwijane są ramy *human centred*¹ oraz kompetencyjne, akcentujące podmiotowość uczących się, przejrzystość procesów, rozliczalność i krytyczną weryfikację treści (UNESCO, 2024). Równolegle w politykach europejskich rośnie znaczenie standardów odpowiedzialnego użycia generatywnej AI, odnoszących się do przejrzystości, zarządzania ryzykiem czy ochrony danych, co pośrednio wpływa na oczekiwania wobec praktyk edukacyjnych i badawczych w szkolnictwie wyższym (European Commission, 2025).

Wyraźny i dobrze udokumentowany przykład tej transformacji stanowi kontekst australijski, gdzie rozwój generatywnej AI został szybko związany z reformą oceniania oraz uściśleniem zasad integralności oraz budowania ram instytucjonalnych. Funkcjonowanie AI na uczelniach australijskich ma charakter systemowy i jest osadzone w dynamicznie zmieniającym się kontekście normatywnym. Jak wskazują Smith i in. (2026), uczelnie pełnią aktywną rolę, wspomagając badaczy w odpowiedzialnym korzystaniu z narzędzi AI. Wdrażanie nowych praktyk wiąże się z transformacją organizacyjną uczelni obejmującą szkolenia, infrastrukturę oraz procedury instytucjonalne. Podkreśla się, że ocena akademicka w warunkach generatywności powinna silniej ujawniać proces, decyzje poznawcze, krytyczne uzasadnienia oraz praktyki zapewniania jakości. W Australii dąży się do tego, aby uczelnie budowały systemowe polityki AI oparte na:

- transparentności,

¹ *Human centred* – podejście projektowe i filozofia działania, która stawia potrzeby, emocje, zachowania i doświadczenia ludzi w centrum uwagi.

- odpowiedzialności,
- rzetelności.

Do kluczowych wymagań należy również ujawnianie użycia generatywnej AI oraz dokumentowanie procesu pracy z tymi narzędziami (Smith i in., 2026). Ważne jest też wprowadzanie zadań projektowych, aby zwiększyć zaangażowanie studentów. Dzięki temu generatywna AI staje się elementem środowiska pracy, ale kluczową kompetencją pozostaje krytyczna ocena rezultatów i odpowiedzialność za podejmowane decyzje (Shishavan, Homa, 2024).

Równolegle rozwijają się dokumenty i przewodniki, które łączą kwestie dydaktyczne z zasadami integralności akademickiej. Sieć *Australasian Academic Integrity Network* publikuje wytyczne oraz przeglądy odpowiedzi instytucjonalnych na generatywną AI, co wzmacnia perspektywę sektora i wskazuje na szybkie różnicowanie strategii uczelnianych (AAIN, 2023). Pojawiają się opracowania instytucjonalne dotyczące integralności akademickiej w kontekście generatywnej AI oraz praktyczne rekomendacje dla dydaktyki i oceniania, wskazujące na potrzebę jasnych norm jawności i edukacji w zakresie odpowiedzialnego użycia narzędzi (ICMS, 2023; Monash University, 2023; University of Wollongong in Dubai, 2023). W wielu dokumentach podkreśla się także rolę AI jako asystenta uczenia się, szczególnie w dyscyplinach o silnym komponencie praktycznym, gdzie AI może wspierać zadania pomocnicze, natomiast kryteria oceny muszą koncentrować się na rozumieniu, krytycznej analizie i zapewnianiu jakości (University of South Australia, 2024). W odpowiedzi na potrzebę standaryzacji podejmowane są również próby tworzenia ram użycia generatywnej AI dla pracowników, które porządkują poziomy wsparcia, jawność oraz odpowiedzialność za decyzje dydaktyczne (Charles Sturt University, 2025).

W tym ujęciu transformacja środowiska kształcenia polega na przesunięciu od weryfikacji samego artefaktu ku weryfikacji kompetencji, które ujawniają sposób działania w środowisku algorytmicznym, w tym zdolność krytycznej oceny, rozróżniania elementów podstawowych i niepodstawowych oraz odpowiedzialnego współdziałania z narzędziami generatywnymi (TEQSA, 2025). W dokumencie TEQSA (2025) akcentuje się, że odpowiedź sektora wymaga jednocześnie doprecyzowania norm integralności i reformy oceniania, tak aby ocena była spójna z rzeczywistością narzędzi generatywnych oraz wzmacniała uczenie się, a nie jedynie kontrolę produktu. Warto zauważyć, że rozwój tego typu ram wpisuje się w podejście socjotechniczne, w którym integracja AI wymaga uwzględnienia czynników technicznych i społecznych, a kompetencje akademickie obejmują również odpowiedzialność, przejrzystość i potencjalne czynniki ryzyka. Analizy Sullivan, Kelly’ego i McLaughlana (2023) wskazują na zróżnicowane odpowiedzi uczelni w kontekście globalnym oraz rosnącą potrzebę adaptacji metod oceniania i nauczania do warunków powszechnej dostępności AI.

Ten kontekst międzynarodowy stanowi istotne tło dla analiz prowadzonych w Polsce. W tym miejscu warto przywołać badania sondażowe zrealizowane przez Raszyd, Wesołowską i Tomaszewską (2024) na grupie 170 studentów Wydziału Inżynierii Zarządzania Politechniki Białostockiej. Wyniki wskazują na wysoki stopień integracji narzędzi AI w procesie kształcenia akademickiego. Najliczniejsza grupa respondentów (42,9%) deklaruje korzystanie z narzędzi generatywnej AI kilka razy w tygodniu, motywując to przede wszystkim ułatwieniem dostępu do zasobów edukacyjnych, poprawą efektywności nauki oraz wsparciem w rozumieniu złożonych zagadnień. Ponadto wykorzystanie technologii pozytywnie przekłada się na sferę psychologiczną i organizacyjną procesu studiowania, czego wyrazem jest fakt, iż ponad połowa respondentów (58,2%) odnotowała redukcję stresu związanego z nauką. Warto wspomnieć, że w ramach badań sondażowych przeprowadzono także wywiady z nauczycielami akademickimi w celu zidentyfikowania obaw respondentów związanych z nadmiernym korzystaniem z narzędzi AI. Zdaniem wykładowców podstawowe zagrożenia obejmują ograniczenie samodzielnego myślenia studentów oraz ryzyko nadmiernego uzależnienia od technologii. Badacze zwracają uwagę na bariery o charakterze instytucjonalnym, w szczególności brak wsparcia dydaktycznego ze strony wykładowców. Analiza materiału empirycznego prowadzi do wniosku, że niezbędne jest wypracowanie systemowej równowagi między odkrywaniem potencjału generatywnej AI a wspieraniem kreatywności i krytycznego myślenia u studentów. Przywołane dane empiryczne nie wyczerpują obrazu przemian zachodzących w przestrzeni akademickiej, ale wskazują na potrzebę prowadzenia dalszych, pogłębionych analiz w tym zakresie.

W polskim szkolnictwie wyższym obserwuje się rosnącą potrzebę diagnozowania skali, obszarów i motywacji korzystania z generatywnej AI, a także identyfikowania instytucjonalnych warunków, które wspierają odpowiedzialne praktyki studiowania. W tym sensie perspektywa diagnostyczna, przyjęta w raporcie, wpisuje się w światowy zwrot ku badaniom, które traktują generatywną AI jako trwały element środowiska uczenia się, wymagający zarówno kompetencji krytycznej weryfikacji treści, jak i wypracowania spójnych ram instytucjonalnych, sprzyjających jawności, zaufaniu i odpowiedzialności akademickiej (Fadlelmula, Qadhi, 2024; UNESCO, 2024).

Bibliografia

- Australasian Academic Integrity Network (2023). *Summary of institutional responses to the use of Generative Artificial Intelligence*. Pobrano z: <https://www.teqsa.gov.au/sites/default/files/2023-05/AAIN-Institutional-Responses-Generative-Artificial-Intelligence.pdf> (17.01.2026).
- Chan, C.K.Y., Hu, W. (2023). Students' voices on generative AI: perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20(1). DOI: 10.1186/s41239-023-00411-8

- Chiu, T.K.F., Meng, H., Chai, C.S., King, I., Wong, S., Yeung, Y. (2022). Creation and evaluation of a pre-tertiary Artificial Intelligence (AI) curriculum. *IEEE Transactions on Education*, 65(1), 30–39.
- European Commission (2025). *Living guidelines on the responsible use of generative AI in research*. Pobrano z: https://research-and-innovation.ec.europa.eu/document/download/2b6cf7e5-36ac-41cb-aab5-0d32050143dc_en?filename=ec_rtd_ai-guidelines.pdf (17.01.2026).
- Fadlelmula, F.K., Qadhi, S.M. (2024). A systematic review of research on artificial intelligence in higher education: Practice, gaps, and future directions in the GCC. *Journal of University Teaching and Learning Practice*, 21(6), 1–28. <https://doi.org/10.53761/pswgbw82>
- Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Katseli, A., Drigas, A. (2026). Humanities and social sciences students' views on the use of AI tools for academic purposes: Practices, benefits, challenges, and suggestions. *Advances in Mobile Learning Educational Research*, 6(1), 1699–1709. <https://doi.org/10.25082/>
- Kuruliszwili, S. (2024). Technologie generatywnej sztucznej inteligencji – nowe perspektywy i nowe wyzwania edukacyjne. *Forum Pedagogiczne*, 14(2.1), 123–135. <https://doi.org/10.21697/fp.2024.2.1.10>
- Luckin, R., Holmes, W., Griffiths, M., Forcier, L.B. (2023). *Artificial intelligence in education: Promise and implications for teaching and learning*. Pobrano z: https://www.researchgate.net/publication/332180327_Artificial_Intelligence_in_Education_Promise_and_Implications_for_Teaching_and_Learning (17.01.2026).
- Møgelvang, A., Bjelland, C., Grassini, S., Ludvigsen, K. (2024). Gender differences in the use of generative artificial intelligence chatbots in higher education: Characteristics and consequences. *Education Sciences*, 14(12), 1363. <https://www.mdpi.com/2227-7102/14/12/1363>
- Raszyd, K.I., Wesołowska, A., Tomaszewska, K. (2024). Sztuczna Inteligencja w nauce – jak studenci wykorzystują AI w edukacji wyższej, *Academy of Management*, 8, 373–400.
- Shishavan, H. (2024). AI in higher education: Guidelines on assessment design from Australian universities. *ASCILITE Publications*, 118–126. DOI: 10.14742/apubs.2024.1205
- Siemens, G. (2004). Connectivism: A Learning Theory for the Digital Age. *International Journal of Instructional Technology and Distance Learning*, 2(1), 3–10. Pobrano z: https://www.itdl.org/Journal/Jan_05/Jan_05.pdf?utm_source=chatgpt.com (14.04.2026).
- Smith, S.M., Tate, M., Freeman, K., Walsh, A., Ballsun-Stanton, B., Lane, M. (2026). A university framework for the responsible use of generative AI in research. *Journal of Higher Education Policy and Management*, 48(1), 17–36. <https://doi.org/10.1080/1360080X.2025.2509187>
- Sullivan, M., Kelly, A., McLaughlan, P. (2023). ChatGPT in higher education: Considerations for academic integrity and student learning. *Journal of Applied Learning & Teaching*, 6(1), 1–10. <https://doi.org/10.37074/jalt.2023.6.1.17>
- TEQSA (2025). *Generative AI, academic integrity and assessment reform*. Tertiary Education Quality and Standards Agency. Pobrano z: <https://www.teqsa.gov.au/guides-resources/higher-education-good-practice-hub/gen-ai-knowledge-hub/gen-ai-academic-integrity-and-assessment-reform> (17.01.2026).
- UNESCO (2024). *AI competency framework for students*. Paris. Pobrano z: <https://unesdoc.unesco.org/ark:/48223/pf0000391105> (15.04.2026).
- Yau, K.W., Chai, C.S., Chiu, T.K. (2023). A phenomenographic approach on teacher conceptions of teaching Artificial Intelligence (AI) in K-12 schools. *Education and Information Technologies*, 28, 1041–1064. <https://doi.org/10.1007/s10639-022-11161-x>

2. PRAKTYKI STUDIOWANIA Z WYKORZYSTANIEM NARZĘDZI GENERATYWNEJ AI

OLIWIA BATOR, ANETA WITOSZ

Praktyki studiowania rozumiane są jako względnie trwałe sposoby organizowania procesu uczenia się. Obejmują one strategię pracy z treściami, zarządzanie czasem i zasobami poznawczymi, relacje z wymaganiami instytucjonalnymi oraz sposoby regulowania własnej aktywności intelektualnej (Richardson, 2011; Zimmerman, 2002). W literaturze pedagogicznej podkreśla się, że kształtują się one na styku indywidualnych strategii uczenia się oraz warunków instytucjonalnych, w których przebiega proces kształcenia (Richardson, 2011). Badania nad wykorzystaniem generatywnej AI wskazują, że technologie te istotnie modyfikują codzienne praktyki studiowania, szczególnie w obszarze planowania pracy, porządkowania i syntezy materiału, redagowania tekstów akademickich oraz przygotowania do zaliczeń i egzaminów (Johnston, Eaton, Henry, Deeley, Parsons, 2025; Kasneci i in., 2023).

Empiryczne analizy pokazują, że sposoby włączania generatywnej AI do procesu studiowania są silnie zróżnicowane. W części przypadków narzędzia generatywne pełnią funkcję wspierającą: ułatwiają orientację w materiale, doprecyzowanie pojęć oraz organizację wiedzy, a tym samym mogą sprzyjać refleksji metapoznawczej i samoregulacji uczenia się (Kasneci i in., 2023). W takich praktykach generatywna AI wykorzystywana jest jako narzędzie pomocnicze, które może wzmacniać rozumienie treści, nie zastępując jednak kluczowych operacji poznawczych realizowanych przez studenta.

W innych sytuacjach generatywna AI przejmując znaczną część operacji poznawczych, takich jak analiza, synteza czy konstruowanie argumentacji. Oznacza to, że student ogranicza własną aktywność poznawczą do selekcji i akceptacji wygenerowanych treści, zamiast samodzielnego ich konstruowania. Prowadzi to do delegowania istotnych elementów pracy intelektualnej na system algorytmiczny, co zmienia charakter zaangażowania poznawczego studenta oraz sposób, w jaki realizowane są zadania akademickie. Badania i przeglądy literatury wskazują, że równolegle do deklarowanych korzyści (np. oszczędności czasu czy wsparcia w pisaniu) rośnie znaczenie napięć wokół samodzielnności oraz granic dopuszczalnego wsparcia (Chan, Hu, 2023; Dempere, Modugu, Hesham, Ramasamy, 2023). W tym kontekście jednym z kluczowych problemów staje się integralność akademicka oraz instytucjonalne sposoby reagowania na ryzyko nadużyć i „niejawnego” delegowania pracy na narzędzie (Bittle, El-Gayar, 2025).

Z tego względu w badaniach nad generatywną AI coraz częściej podkreśla się konieczność analizy nie tylko skali korzystania z narzędzi algorytmicznych,

lecz także jakości, intencji oraz kontekstu ich użycia. Takie podejście pozwala odróżnić praktyki, w których AI pełni funkcję wsparcia poznawczego, od praktyk substytucyjnych, w których zastępuje ona kluczowe działania intelektualne studenta. Rozróżnienie to ma istotne znaczenie z perspektywy dydaktyki akademickiej, ponieważ wiąże się bezpośrednio z celami kształcenia, projektowaniem oceniania oraz rozumieniem integralności akademickiej (Bittle, El-Gayar, 2025; Dempere i in., 2023). W konsekwencji praktyki studiowania z wykorzystaniem generatywnej AI należy postrzegać jako zjawisko relacyjne i sytuacyjne, zależne zarówno od indywidualnych strategii uczenia się, jak i od norm instytucjonalnych, kultury akademickiej oraz jasności komunikowanych zasad dotyczących użycia technologii (Chan, Hu, 2023).

Bibliografia

- Bittle, K., El-Gayar, O. (2025). Generative AI and academic integrity in higher education: A systematic review and research agenda. *Information*, 16(4), 296. <https://doi.org/10.3390/info16040296>
- Chan, C.K.Y., Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20, 43. <https://doi.org/10.1186/s41239-023-00411-8>
- Dempere, J., Modugu, K., Hesham, A., Ramasamy, L.K. (2023). The impact of ChatGPT on higher education. *Frontiers in Education*, 8, 1206936. <https://doi.org/10.3389/educ.2023.1206936>
- Johnston, C., Eaton, S., Henry, N., Deeley, S., Parsons, S. (2025). Discovering how students use generative artificial intelligence (GAI) tools for academic writing purposes. *Journal of Learning Development in Higher Education*, 34. <https://doi.org/10.47408/jldhe.vi34.1301>
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Richardson, J.T.E. (2011). Approaches to studying, conceptions of learning and learning styles in higher education. *Learning and Individual Differences*, 21(3), 288–293. <https://doi.org/10.1016/j.lindif.2010.11.015>
- Zimmerman, B.J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2

3. ODPOWIEDZIALNOŚĆ KOMPETENCYJNA I KRYTYCZNA WERYFIKACJA TREŚCI POZYSKANYCH ZA POMOCĄ NARZĘDZI GENERATYWNEJ AI

ANITA KARYŃ, KRZYSZTOF ŁUSZCZEK

Jednym z kluczowych pojęć porządkujących refleksję nad wykorzystaniem generatywnej AI w edukacji akademickiej jest odpowiedzialność kompetencyjna. Pojęcie to odnosi się do zdolności podmiotu uczącego się do świadomego i krytycznego zarządzania procesem korzystania z narzędzi algorytmicznych, obejmującego ocenę wiarygodności generowanych treści, rozpoznawanie ograniczeń technologicznych oraz podejmowanie decyzji dotyczących zakresu i celu delegowania operacji poznawczych do środowiska cyfrowego (Floridi, 2023; UNESCO, 2024). Współczesne analizy ujmują generatywne modele językowe jako specyficzny typ artefaktów poznawczych, wspierających zarówno wyszukiwanie sensu, jak i organizowanie znaczeń, wytwarzanie struktur argumentacyjnych oraz syntetyzowanie informacji, co bezpośrednio wpływa na style studiowania i na relacje między wysiłkiem własnym a wsparciem technologicznym (Heersmink, 2021; Kasneci i in., 2023).

W refleksji nad kształceniem akademickim odpowiedzialność kompetencyjna obejmuje umiejętność sprawdzania poprawności treści oraz refleksję nad funkcją, jaką generatywna AI pełni w procesie uczenia się. Oznacza to konieczność odróżniania sytuacji, w których narzędzie wspiera rozumienie, organizację wiedzy i refleksję metapoznawczą, od sytuacji, w których przejmuje ono kluczowe operacje poznawcze, takie jak analiza, synteza czy argumentowanie. Takie rozróżnienie staje się istotnym elementem kształcenia akademickiego, którego celem pozostaje rozwój samodzielności intelektualnej oraz zdolności krytycznego myślenia. Badania nad zależnością studentów od narzędzi generatywnej AI wskazują, że rosnące przywiązanie do wsparcia generatywnego współwystępuje z obniżeniem deklarowanego poziomu krytycznego myślenia, przy czym istotną rolę odgrywają mechanizmy zmęczenia poznawczego oraz przenoszenie obciążenia poznawczego na narzędzie, czyli zjawiska opisywane w literaturze jako obciążenie poznawcze² i błąd automatyzacji³ (Tian, Zhang, 2025; Gerlich, 2025). W tym sensie odpowiedzialność kompetencyjna obejmuje także umiejętność

² Obciążenie poznawcze (*cognitive load*) – ilość zasobów pamięci roboczej wykorzystywanej przez mózg w danym momencie do przetwarzania informacji i wykonywania zadań. Ponieważ pamięć robocza ma ograniczoną pojemność, zbyt duża ilość bodźców prowadzi do przeciążenia, frustracji i błędów. Optymalizacja tego obciążenia jest kluczowa w uczeniu się i UX.

³ Błąd automatyzacji (*automation bias*) – ludzka skłonność do nadmiernego polegania na automatyzowanych systemach i ufania sugestiom algorytmów bardziej niż własnemu osądowi, nawet gdy dowody przeczą twierdzeniom maszyny.

świadomego regulowania stopnia zależności od narzędzia, tak aby wsparcie sprzyjało uczeniu się, a nie zastępowało pracy interpretacyjnej.

Szczególne znaczenie w tej perspektywie zyskuje krytyczna weryfikacja treści. Generowane odpowiedzi często charakteryzuje wysoka spójność językowa i stylistyczna, co sprzyja poznawczej wiarygodności i ułatwia ich włączanie do notatek, konspektów oraz tekstów akademickich. Równocześnie literatura edukacyjna podkreśla ryzyko błędów faktograficznych, uproszczeń, niespójności argumentacyjnych oraz pozornych odwołań bibliograficznych, które imitują standardy naukowe (Kasneci i in., 2023). W konsekwencji ciężar odpowiedzialności za jakość wiedzy przesuwają się z etapu pozyskiwania informacji na etap jej interpretacji, krytycznej oceny i sprawdzania.

Krytyczna weryfikacja w warunkach generatywności wymaga zatem zestawu praktyk, które można opisać jako kompetencje proceduralne: porównywanie odpowiedzi z literaturą źródłową, sprawdzanie danych w wiarygodnych bazach, rekonstrukcja ciągu argumentacyjnego, ocena spójności pojęciowej oraz kontrola cytowań i przypisów. Istotne jest także rozpoznawanie, że poprawność językowa nie przesądza o poprawności epistemicznej, a perswazyjność odpowiedzi może wzmacniać efekt nadmiernej pewności użytkownika. W tym obszarze badania nad fałszywą informacją (tzw. *mis information*) i jej korektą w edukacji wskazują na rosnące znaczenie praktyk weryfikacyjnych oraz dydaktyk ukierunkowanych na korektę błędnych przekonań, co zyskuje nowe znaczenie w środowisku generatywnym (Fulsher, Pagkratidou, Kendeou, 2025; Rau, 2025). Przeglądy literatury dotyczące akademickiej integralności w dobie generatywnej AI pokazują dodatkowo, że granice między dopuszczalnym wsparciem a nadużyciem pozostają przedmiotem sporów normatywnych, a praktyki studentów silnie zależą od jasności reguł oraz od tego, czy instytucja tworzy warunki do uczenia się odpowiedzialnego użycia narzędzi (Bittle, El-Gayar, 2025; QAA, 2023–2025).

W tym sensie odpowiedzialność kompetencyjna ma charakter relacyjny i sytuacyjny. Kształtuje się w interakcji między dyspozycjami poznawczymi studenta, kulturą akademicką, oczekiwaniami kadry oraz dostępnością wsparcia w zakresie alfabetyzacji AI (*AI literacy* rozumianej jako podstawowe kompetencje używania AI). Ramy kompetencyjne podkreślają, że alfabetyzacja AI obejmuje wiedzę o zasadach działania systemów, umiejętność krytycznej oceny i weryfikacji treści, kompetencje etyczne oraz świadomość konsekwencji społecznych i instytucjonalnych użycia AI (UNESCO, 2024; Pretorius, 2024; Gu, Ericson, 2025). W praktyce dydaktycznej oznacza to przesunięcie akcentu z samej znajomości narzędzi w stronę kompetencji rozumienia, kontroli jakości i odpowiedzialnego raportowania sposobu użycia.

Rozwijanie odpowiedzialności kompetencyjnej stanowi zatem jedno z kluczowych wyzwań dydaktyki akademickiej i polityk jakości kształcenia. Wymaga ono jasnych ram instytucjonalnych, które porządkują zasady jawności, definiują

dopuszczalne formy wsparcia oraz projektują ocenianie w sposób uwzględniający realność powszechnego użycia narzędzi generatywnej AI. Wytyczne i zasoby instytucji zapewniania jakości wskazują na potrzebę równoczesnego wzmacniania kompetencji krytycznej weryfikacji oraz reformy oceniania, prowadzącej do projektowania zadań ukierunkowanych na autentyczność uczenia się i wykazywanie rozumienia, a nie tylko na finalny produkt tekstowy (TEQSA, 2023, 2025). W takim ujęciu odpowiedzialność kompetencyjna pozostaje ważnym ogniwem łączącym praktyki studiowania z kulturą akademicką i z instytucjonalnym wsparciem, co uzasadnia jej centralne miejsce w analizie wyników badań.

Opracowane przez UNESCO „Ramy kompetencji w zakresie narzędzi AI dla studentów” stanowią globalny punkt odniesienia, określając dwanaście kompetencji w czterech wymiarach: podejście skoncentrowane na człowieku, etyka wykorzystania narzędzi AI, techniki i zastosowania narzędzi AI oraz projektowanie systemów AI. Model ten podkreśla, że studenci nie powinni być biernymi użytkownikami, lecz odpowiedzialnymi współtwórcami, którzy potrafią krytycznie oceniać rozwiązania z zakresu AI i rozumieją odpowiedzialność obywatelską związaną z erą sztucznej inteligencji. Postęp w tych ramach – od rozumienia do stosowania i wreszcie tworzenia – odzwierciedla głębokość analizy wymaganej w środowisku akademickim (UNESCO, 2024).

Na poziomie instytucjonalnym ramy takie definiują umiejętność posługiwania się AI jako zdolność do oceny wyników, zapewnienia, że ludzie pozostają w centrum procesów obsługiwanych przez sztuczną inteligencję, oraz dostosowywania się do zmieniającego się krajobrazu technologicznego. Polega ona na identyfikowaniu błędnych informacji, rozpoznawaniu nieścisłości i stosowaniu logicznego rozumowania w celu zrozumienia, w jaki sposób AI generuje określone odpowiedzi (Digital Education Council, 2025).

Praktyczna implementacja tych ram często opiera się na modelu 4C – sumienności, współpracy, krytycyzmu i kreatywności (*conscientious, collaborative, critical, creative*). W tym kontekście komponent „krytyczny” ma kluczowe znaczenie dla oceny prac studenckich, ponieważ obejmuje analizę wyników AI pod kątem dokładności oraz weryfikację informacji w oparciu o wiarygodne źródła zewnętrzne (Chambers, 2025).

Współczesne spojrzenie na odpowiedzialność kompetencyjną w kontekście generatywnej AI obejmuje nie tylko zdolność do technicznej obsługi narzędzi sztucznej inteligencji, ale również umiejętność krytycznego ich używania, rozumienia ich ograniczeń i konsekwencji poznawczych. Autorzy badający pojęcie alfabetyzacji AI podkreślają, że kompetencja ta łączy wiedzę o zasadach działania systemów generatywnych, ocenę ryzyka algorytmicznego i krytyczną refleksję nad generowanymi treściami. W literaturze pojawia się koncepcja *responsible generative AI literacy*, czyli kompetencji wykraczających poza umiejętność

promptowania, obejmujących etyczny i krytyczny nadzór nad generatywną AI (Cox, 2024).

Badania pokazują, że narzędzia generatywnej AI dzięki wysokiej spójności językowej i perswazyjności mogą tworzyć iluzję kompetencji – użytkownicy często interpretują poprawność językową jako poprawność merytoryczną, co może prowadzić do niskiej jakości uczenia się i powierzchownej akceptacji treści bez krytycznej oceny. Ten mechanizm jest opisywany w kontekście halucynacji AI (tzw. AI *hallucinations*, czyli generowania wiarygodnie wyglądających, ale nieprawdziwych informacji), które stanowią kluczowy problem poznawczy w edukacji opartej na AI (Li, 2025)

Co więcej, badania empiryczne wskazują, że zależność studentów od narzędzi generatywnych koreluje ze spadkiem zaangażowania poznawczego oraz krytycznego myślenia – zjawiska te pośredniczą w degradacji aktywnego wysiłku poznawczego na rzecz automatycznego „przenoszenia obciążenia poznawczego” na narzędzie AI (Tian, Zhang, 2025).

Choć dane ilościowe nie precyzują metod, które służą do weryfikowania niebezpieczeństwa halucynacji AI, to na podstawie trendów już zbadanych i opisanych (np. Ji i in., 2022) można założyć, że respondenci stosują najczęściej następujące strategie: weryfikację krzyżową (np. sprawdzanie faktów w wyszukiwarce Google), *double-check* u źródła (np. szukanie konkretnych publikacji, aktów prawnych lub dokumentacji), test logiczny, tzn. porównywanie odpowiedzi z własną wiedzą ekspercką, i prompting zwrotny, czyli proszenie AI o podanie źródeł (choć to bywa ryzykowne, bo AI potrafi „wykreować” – halucynować, generując nieistniejącą bibliografię). Zapewne poszczególne sposoby weryfikacji są wykorzystywane w separacji (w zależności od osobistych doświadczeń studentów), jednak nie można wykluczyć, że przy poważniejszych wątpliwościach wykorzystuje się kilka narzędzi jednocześnie.

Przejsiecie w stronę rygorystycznej oceny sposobu wykorzystania materiałów AI oznacza, że sztuczna inteligencja nie jest już narzędziem peryferyjnym, lecz trwałym rozszerzeniem procesu poznawczego w szkolnictwie wyższym. Zmiana ta wymaga odejścia od defensywnych strategii „wykrywania” na rzecz proaktywnych strategii „oceniających”. Studenci muszą pełnić rolę arbitrów logiki i prawdy, dbając o to, aby procesy wspierane przez AI pozostały zorientowane na człowieka (Li, 2025). W takim środowisku podstawowe umiejętności akademickie – krytyczne myślenie, etyczne rozeznanie i umiejętność korzystania z informacji – staną się jeszcze bardziej pożądane a wręcz niezbędne a nie jedynie „dobrze widziane”.

Bibliografia

Bittle, K., El-Gayar, O. (2025). Generative AI and academic integrity in higher education: A systematic review and research agenda. *Information*, 16(4), 296. <https://doi.org/10.3390/info16040296>

- Chambers, K. (2025). *The 4 C's of AI literacy: Building a framework for student success*. Póbrano z: <https://schoolai.com/blog/ai-literacy-success-framework> (7.03.2026).
- Cox, A. (2024). Algorithmic literacy, AI literacy and responsible generative AI literacy. *Journal of Web Librarianship*, 18(3), 93–110. <https://doi.org/10.1080/19322909.2024.2395341>
- Digital Education Council (2025). USask AI Literacy Framework. Póbrano z: <https://ai.usask.ca/documents/faculty-usask-ai-literacy-framework.pdf> (7.03.2026).
- Floridi, L. (2023). *The Ethics of Artificial Intelligence: Principles, Challenges, and Opportunities*. Oxford: Oxford University Press.
- Fulsher, A., Pagkratidou, M., Kendeou, P. (2026). GenAI and misinformation in education: A systematic scoping review of opportunities and challenges. *AI & Society*, 41, 1373–1385. <https://doi.org/10.1007/s00146-025-02536-y>
- Gerlich, M. (2025). AI Tools in Society: Impacts on cognitive offloading and the future of critical thinking. *Societies*, 15(1), 6. <https://doi.org/10.3390/soc15010006>
- Gu, X., Ericson, B.J. (2025). AI Literacy in K-12 and Higher Education in the Wake of Generative AI: An Integrative Review. *Proceedings of the 2025 ACM Conference on International Computing Education Research*, 1, 3–20. <https://doi.org/10.1145/3702652.3744217>
- Heersmink, R. (2021). Varieties of artifacts: Embodied, perceptual, cognitive, and affective. *Topics in Cognitive Science*, 13(4), 573–596. <https://doi.org/10.1111/tops.12549>
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Yan, X., Ishii, E., Bang, Y., Madotto, A., Fung, P. (2023). Survey of Hallucination in Natural Language Generation. *ACM Comput. Surv.*, 1(1). <https://doi.org/10.48550/arXiv.2202.03629>
- Kasneci, E., Seßler, K., Küchemann, S., i in. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Li, Y. (2025). Addressing “hallucinations” in AI-generated content: Strategies for developing student fact-checking and information evaluation skills. *Artificial Intelligence Education Studies*, 1(2), 48–62. <https://doi.org/10.6914/aiese.010204>
- Pretorius, L., Cahusac de Caux, B. (2024). *The AI literacy framework for higher education: A grounded theory exploration of the foundational, social, conceptual, ethical and affective domains of AI literacy*. W: B. Cahusac de Caux, L. Pretorius, L. Macaulay (red.), *Research and Teaching in a Pandemic World: The Challenges of Establishing Academic Identities During Times of Crisis* (s. 35–51). Boca Raton: CRC Press. <https://doi.org/10.1201/9781003510635-3>
- QAA (2023). *Maintaining quality and standards in the ChatGPT era: QAA advice on the opportunities and challenges posed by Generative Artificial Intelligence*. Gloucester: The Quality Assurance Agency for Higher Education. Póbrano z: <https://www.qaa.ac.uk/docs/qaa/members/maintaining-quality-and-standards-in-the-chatgpt-era.pdf> (13.04.2026).
- Rau, M.A., Premo, A.E. (2025). Systematic Review of Educational Approaches to Misinformation. *Educational Psychology Review*, 37(2), 43. <https://doi.org/10.1007/s10648-025-10012-8>
- TEQSA Conference (2023). Póbrano z: <https://www.teqsa.gov.au/about-us/news-and-events/teqsa-events/teqsa-conference/teqsa-conference-2023> (13.04.2026).
- TEQSA Conference (2025). Póbrano z: <https://www.teqsa.gov.au/about-us/news-and-events/teqsa-events/teqsa-conference/teqsa-conference-2025> (13.04.2026).
- Tian, J., Zhang, R. (2025). Learners’ AI dependence and critical thinking: The psychological mechanism of fatigue and the social buffering role of AI literacy. *Acta Psychologica*, 260, 105725. <https://doi.org/10.1016/j.actpsy.2025.105725>
- UNESCO (2024). *The AI competency frameworks for teachers and students*. Póbrano z: <https://en.ichei.org/en/news/information/924.html> (7.03.2026).
- UNESCO (2024). *AI competency framework for students*. Paris. <https://doi.org/10.54675/JKJB9835>

4. INSTYTUCJONALNE UWARUNKOWANIA KORZYSTANIA Z NARZĘDZI GENERATYWNEJ AI

JOANNA SZUMIŁO-JACKOWSKA

Praktyki studiowania z wykorzystaniem generatywnej AI kształtują się w ścisłym związku z instytucjonalnym kontekstem funkcjonowania szkolnictwa wyższego. Oznacza to, że decyzje studentów dotyczące zakresu i sposobu korzystania z narzędzi generatywnych są współokreślane przez zasady integralności akademickiej, formy oceniania, komunikaty uczelni dotyczące dopuszczalnych praktyk oraz dostępność wsparcia w zakresie kompetencji z zakresu alfabetyzacji AI (QAA, 2023–2025; TEQSA, 2025). W tym sensie narzędzie generatywnej AI staje się elementem ekosystemu kształcenia, w którym spotykają się technologie, normy instytucjonalne, praktyki dydaktyczne oraz doświadczenia studentów. W naszym badaniu odnosimy się do koncepcji instytucji, która odwołuje się do szerokiego zakresu działań zarówno dydaktycznych, jak i społecznych, pojęć oraz struktur społecznych, ale również norm i wartości (Nowak, 2009). W dobie zmian społeczno-technologicznych oraz praktyki stosowania AI w szkolnictwie wyższym powstaje konieczność uregulowania i wprowadzenia zmian w wielu obszarach funkcjonowania uczelni w odniesieniu do praktyk stosowania sztucznej inteligencji. Zjawisko to wyjaśnia, dlaczego instytucje akademickie, działając w warunkach wysokiej niepewności technologicznej, dążą do upodabniania swoich struktur i regulacji do wzorców uznawanych za legitymizowane w polu szkolnictwa wyższego. Z jednej strony uczelnie przyjmują stanowisko, że narzędzia generatywnej AI są szansą – w szerokim ujęciu, z drugiej strony zakazują studentom korzystania z nich. W tym kontekście pojawia się izomorfizm instytucjonalny wynikający z teorii neoinstytucjonalizmu, którego przedstawicielami byli DiMaggio i Powell (1983). Uczelnie wyższe stanowią instytucje o wspólnym sposobie postrzegania danych sytuacji, w tym m.in. obecnej praktyki wykorzystywania narzędzi generatywnej AI. Występujący izomorfizm instytucjonalny wynika ze wspólnych doświadczeń obecności AI, ale również z działań podejmowanych przez uniwersytety zagraniczne. W tym miejscu spotykamy się ze swego rodzaju organizacją hipokryzji (Brunsson, 1989), w której działania instytucji, komunikaty i zachowania członków instytucji są sprzeczne.

W kontekście stosowania narzędzi generatywnej AI w szkolnictwie wyższym zjawisko izomorfizmu prezentuje się w trzech formach. Pierwszą z nich jest izomorfizm przymusowy (Marczewska, 2016), który wynika z konieczności dostosowania się uczelni do wprowadzanych aktów prawnych, np. *AI Act*, czy systemów antyplagiatowych. Kolejną formą jest izomorfizm normatywny wiążący się z przyjmowaniem przekonań kadry akademickiej – postrzeganej jako profesjoniści, którzy edukują się i powielają pewne wzorce. Trzecią formą jest

izomorfizm mimetyczny, który prezentuje się w zachowaniach członków instytucji w momencie pojawienia się sytuacji niepewności (Marczewska, 2016). W tym przypadku instytucja naśladuje sposoby działania innych uczelni wyższych, przede wszystkim tych, które traktowane są jako prestiżowe i odnoszące sukcesy. W kontekście AI można spotkać się z praktyką, gdzie uczelnie kopiują politykę *AI integrity*⁴ od pozostałych szkół wyższych.

W literaturze i dokumentach sektorowych podkreśla się, że uczelnie znajdują się obecnie w fazie intensywnego doprecyzowywania ram dla korzystania z narzędzi generatywnej AI. Wymaga to równoczesnego rozstrzygania kwestii normatywnych, dotyczących jawności i uczciwości akademickiej, oraz kwestii organizacyjnych, związanych z ocenianiem, projektowaniem zadań dydaktycznych i wsparciem kompetencyjnym (QAA, 2023–2025). Istotnym czynnikiem różnicującym praktyki studentów pozostaje stopień jasności regulacji. Tam, gdzie zasady są nieprecyzyjne lub niespójne, rośnie niepewność co do dopuszczalnych form użycia narzędzi generatywnej AI, co sprzyja strategiom ukrywania, minimalizowania jawności albo traktowania narzędzia jako „strefy ryzyka” w relacji z wykładowcą. W rezultacie kształtują się napięcia psychospołeczne obejmujące obawy przed stygmatyzacją oraz lęk przed oskarżeniem o naruszenie zasad integralności (QAA, 2023–2025). Strach i niepewność pojawiające się wśród studentów oraz pracowników wpływają na jakość funkcjonowania środowiska akademickiego. Buduje to konieczność uregulowania stałej infrastruktury, która nie tylko stworzy warunki do formalnych wytycznych korzystania z narzędzi AI, ale wyrówna też szanse akademickie w polu międzynarodowym. Dyskusja o obecności AI w szkolnictwie wyższym powinna zmierzać w kierunku dostępności narzędzi, aby nie determinować nierówności efektywnego studiowania. Uczelnia, która nie zapewnia studentom dostępu do narzędzi AI, w praktyce kreuje nowe zjawisko rozwarstwienia edukacyjnego i barier edukacyjnych. Instytucjonalne stosowanie AI, bez klarownych zasad, odbywać się będzie – jak ma to miejsce obecnie – w podziemiach szkolnictwa wyższego.

Obecność AI w instytucjach szkolnictwa wyższego stworzyła swego rodzaju nową transformację. Transformacja technologiczna zmusza uczelnie do przyjęcia nowych, innowacyjnych podejść, które często są opozycyjne do tradycyjnego postrzegania edukacji wyższej (Tabata, Johnsrud, 2008). Jednocześnie należy być świadomym tego, iż przyjęcie narzędzi AI i ich adaptacja w szkolnictwie wyższym jest procesem złożonym. Instytucje akademickie stoją przed wieloma wyzwaniami, które z uwagi m.in. na dynamiczny rozwój technologii powinny być rozwiązane możliwie jak najszybciej (Alordiah, 2023). W tym miejscu war-

⁴ *AI integrity* – odnosi się do etycznego opracowywania, wdrażania i wykorzystywania systemów AI gwarantującego, że są one godne zaufania, przejrzyste, sprawiedliwe i zgodne z wartościami ludzkimi. Obejmuje ona zarówno niezawodność techniczną modelu AI (zapewniającą, że działa on zgodnie z zamierzeniami), jak i implikacje etyczne, prawne i społeczne.

to również zwrócić uwagę na kulturę organizacyjną uczelni. Oprócz uwarunkowań formalnych dotyczących stosowania AI i określenia infrastruktury akademickiej istotne jest zwrócenie uwagi na postawy kadry akademickiej w dobie omawianej transformacji. Wspomniane wcześniej uczucie strachu i niepewności obecne wśród studentów jest wynikiem m.in. postaw wykładowców. W literaturze podkreślane są dwa rodzaje postaw obecnych wśród kadry akademickiej w odniesieniu do narzędzi generatywnej AI. Z jednej strony spotykamy się z postawą techno-optymistyczną, która zakłada, że postęp technologiczny przyczynia się do poprawy jakości życia i pomaga rozwiązywać kluczowe problemy (Danaher, 2022). Kadra akademicka prezentująca ten typ postaw wierzy, iż rozwój technologiczny jest kluczowy dla rozwoju wielu płaszczyzn naukowych. Z drugiej strony mamy postawę luddystycznego oporu, która opowiada się za minimalizmem technologicznym. Reprezentanci tej postawy sprzeciwiają się wprowadzaniu AI do praktyk akademickich oraz wykorzystywaniu jej w procesach dydaktycznych i uczenia się. Literatura przedmiotu podkreśla, że postawy prezentowane przez wykładowców mają silniejszy wpływ na działania studentów niż oficjalne dokumenty strategiczne (Selwyn, 2024). W sytuacji, kiedy instytucja akademicka wspiera innowacyjność wyłącznie z poziomu deklaratywnego, a codzienna praktyka dydaktyczna oparta jest na zakazach, sankcjach i nieufności wobec technologii, studenci wykorzystują strategię korzystania z narzędzi generatywnej AI w sposób niewidoczny. Tym sposobem kreuje się nowa kultura akademicka tworząca kolejne bariery.

Ważnym wymiarem uwarunkowań instytucjonalnych pozostaje sposób projektowania oceniania. Wskazuje się, że powszechna dostępność narzędzi generatywnych AI przyspiesza proces redefinicji zadań akademickich, ponieważ część tradycyjnych form pracy, opartych na produkcie tekstowym, staje się mniej diagnostyczna dla oceny rozumienia i samodzielności. W odpowiedzi instytucje zapewniania jakości rekomendują strategię obejmującą dywersyfikację form oceniania, większy nacisk na proces, uzasadnianie wyborów, krytyczną pracę ze źródłami oraz zadania o charakterze autentycznym i refleksyjnym, które ujawniają trajektorię myślenia studenta (Chan, Hu, 2023; TEQSA, 2025). Tego rodzaju reformy wpływają na praktyki studiowania, ponieważ zmieniają oczekiwania wobec tego, co podlega ocenie, a także wobec tego, jaką rolę narzędzie generatywnej AI może pełnić w przygotowaniu do zaliczeń.

Równolegle rośnie znaczenie instytucjonalnych działań wspierających rozwój alfabetyzacji w zakresie AI. Ramy kompetencyjne UNESCO (2024) akcentują, że przygotowanie studentów i nauczycieli do funkcjonowania w środowisku algorytmicznym obejmuje wiedzę o zasadach działania systemów, umiejętność krytycznej weryfikacji treści, rozpoznawanie ryzyka oraz postawy etyczne związane z odpowiedzialnym użyciem narzędzi. W tym ujęciu wsparcie uczelni w zakresie szkoleń, zasobów i komunikacji norm stanowi nie tylko element poli-

tyki edukacyjnej, lecz również realny moderator praktyk studentów wpływający na ich gotowość do jawności, nawyki weryfikacyjne oraz sposób rozumienia granic dopuszczalności. Znaczenie instytucjonalnego kontekstu wzmacniają także europejskie standardy odpowiedzialnego użycia narzędzi generatywnej AI, które podkreślają wagę przejrzystości, rozliczalności, ochrony danych oraz świadomego zarządzania ryzykiem w środowiskach badawczych i edukacyjnych (European Commission, 2025). W praktyce przekłada się to na potrzebę harmonizowania polityk uczelnianych z szerszymi ramami regulacyjnymi oraz na rozwijanie kultury organizacyjnej, w której technologiczne innowacje pozostają w relacji z wartościami akademickimi.

W konsekwencji instytucjonalne uwarunkowania korzystania z narzędzi generatywnej AI warto ujmować jako spłot trzech elementów: jasności zasad i norm jawności, adekwatności projektowania oceniania oraz dostępności wsparcia kompetencyjnego. To właśnie w tym splocie kształtują się doświadczenia studentów dotyczące bezpieczeństwa, sprawczości i odpowiedzialności w korzystaniu z narzędzi generatywnej AI, co uzasadnia włączenie tego wymiaru do perspektywy diagnostycznej badań. Ostatecznie uwarunkowania instytucjonalne tworzą złożoną sieć zależności: od odgórnych mechanizmów izomorfizmu, przez politykę dostępu do infrastruktury, aż po miękkie mechanizmy kultury akademickiej. Dopiero w tak zarysowanym polu możliwe jest zrozumienie konkretnych praktyk studiowania, które zostaną poddane analizie w dalszej części raportu. Instytucja nie jest tu jedynie tłem, lecz aktywnym moderatorem, który poprzez swoje zaniechania lub działania określa, czy narzędzie generatywnej AI stanie się narzędziem demokratyzacji wiedzy, czy też nowym instrumentem kontroli i wykluczenia.

Bibliografia

- Alordiah, C.O. (2023). Proliferation of Artificial Intelligence Tools: Adaptation Strategies in the Higher Education Sector. *Propellers Journal of Education*, 2(1), 53–65.
- Brunsson, N. (1989). *The Organization of Hypocrisy: Talk, Decisions and Actions in Organizations*. John Wiley & Sons.
- Chan, C.K.Y., Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20, 43. <https://doi.org/10.1186/s41239-023-00411-8>
- Danaher, J. (2022). Technooptimism: analiza, ocena i skromna obrona. *Science and Engineering Ethics*, 35, 54. <http://doi:10.1007/s13347-022-00550-2>
- DiMaggio, P.J., Powell, W.W. (1983) The Iron Cage Revisited: Institutional Isomorphism and Collective Rationality in Organizational Fields. *American Sociological Review*, 48, 147–160. <http://doi.org/10.2307/2095101>
- European Commission (2025). *Living guidelines on the responsible use of generative AI in research and higher education*. Pobrano z: https://research-and-innovation.ec.europa.eu/document/download/2b6cf7e5-36ac-41cb-aab5-0d32050143dc_en?filename=ec_rtd_ai-guidelines.pdf (1.04.2026).

- Marczewska, M. (2016). Teoria neoinstytucjonalna. W: K. Klincewicz (red.), *Zarządzanie, organizacje i organizowanie – przegląd perspektyw teoretycznych* (s. 186–192). Warszawa: Wyd. UW.
- Nowak, M. (2009). *Instytucjonalizmy w socjologii ekonomii. Problem i jego konceptualizacja*. Poznań: Wyd. UAM.
- QAA (2023–2025). *Maintaining quality and standards in the ChatGPT era: QAA advice on the opportunities and challenges posed by Generative Artificial Intelligence*. Pobrano z: https://www.qaa.ac.uk/docs/qaa/members/maintaining-quality-and-standards-in-the-chatgpt-era.pdf?sfvrsn=2408aa81_10 (20.06.2026).
- Selwyn, N. (2024). *Education in a Digital World: Global Perspectives on Technology and Education*. London: Routledge.
- Tabata, L.N., Johnsrud, L.K. (2008). The impact of faculty attitudes toward technology, distance education, and innovation. *Research in Higher Education*, 49, 625–646.
- TEQSA (2025). *Generative AI, academic integrity and assessment reform*. Pobrano z: <https://www.teqsa.gov.au/guides-resources/higher-education-good-practice-hub/gen-ai-knowledge-hub/gen-ai-academic-integrity-and-assessment-reform> (17.01.2026).
- UNESCO (2024). *AI competency framework for students*. Paris. <https://doi.org/10.54675/JKJB9835>

CZEŚĆ DRUGA

ZAŁOŻENIA METODOLOGICZNE BADAŃ WŁASNYCH DOTYCZĄCYCH WYKORZYSTANIA GENERATYWNEJ SZTUCZNEJ INTELIGENCJI PRZEZ STUDENTÓW

ELŻBIETA PERZYCKA-BOROWSKA

1. Paradygmat badawczy i logika wyjaśniania

Badanie osadzono w paradygmacie funkcjonalistycznym rozumianym jako dążenie do możliwie intersubiektywnego opisu regularności ujawniających się w praktykach edukacyjnych oraz w powiązanych z nimi uwarunkowaniach instytucjonalnych (Babbie, 2013; Nowak, 2010). Przyjęcie tej perspektywy pozwala ujmować praktyki studiowania z wykorzystaniem generatywnej AI jako element szerszego układu dydaktycznego, organizacyjnego i kulturowego, w którym jednostkowe działania studentów pozostają powiązane z normami akademickimi, strukturą kształcenia oraz warunkami instytucjonalnego wsparcia (OECD, 2023; Selwyn, 2019).

Wartość naukowa przyjętego ujęcia wyraża się w możliwości uchwycenia badanego zjawiska w perspektywie uporządkowanych praktyk osadzonych w określonym porządku dydaktycznym, organizacyjnym oraz aksjologiczno-poznawczym. Taka perspektywa otwiera drogę do analizy tego, w jaki sposób, w jakich obszarach oraz pod wpływem jakich warunków instytucjonalnych studenci włączają narzędzia generatywne do własnego warsztatu studiowania. W literaturze podkreśla się, że generatywna AI przekształca dostęp do wiedzy, a zarazem procesy jej wytwarzania, interpretowania i organizowania, co uzasadnia potrzebę analizy praktyk użytkowników w ich kontekście społecznym i edukacyjnym (Kasneci i in., 2023; Selwyn, 2019). Dzięki temu możliwe staje się rozpoznanie mechanizmów różnicujących style użycia AI, zakres krytycznej weryfikacji treści, poziom jawności korzystania z narzędzi oraz deklarowane zmiany w organizacji uczenia się, co pozostaje zgodne ze współczesnymi ujęciami badań nad środowiskami uczenia się w warunkach transformacji cyfrowej (OECD, 2023; Redecker, 2017).

2. Przedmiot i cele badań

Przedmiotem badań uczyniono opinie, postawy oraz zadeklarowane zachowania studentów polskich uczelni wyższych w zakresie wykorzystywania narzędzi generatywnej AI w toku studiów.

Celem głównym (poznawczym) była wieloaspektowa diagnoza zakresu, sposobów i uwarunkowań wykorzystania narzędzi generatywnej AI przez studentów, ze szczególnym uwzględnieniem ich znaczenia dla praktyk uczenia się, krytycznej pracy z treścią, organizacji studiowania oraz relacji z kulturą akademicką.

Celem praktycznym (wdrożeńiowym) było sformułowanie postulatów dotyczących polityki edukacyjnej uczelni oraz potrzeb szkoleniowych w zakresie krytycznego odbioru treści generowanych przez AI. Jak wskazuje Nowak (2010, s. 24–25), wartość badania społecznego mierzy się nie tylko poprawnością metodologiczną, ale i jego użytecznością społeczną.

3. Problemy, hipotezy, zmienne i wskaźniki badań

Zgodnie z klasycznym ujęciem problemu badawczego jako pytania, na które poszukuje się odpowiedzi na drodze postępowania naukowego, konstrukcja problematyki badawczej stanowi podstawę porządkowania całego procesu badania oraz wyznacza kierunek operacjonalizacji zjawiska (Sztumski, 1999; Nowak, 2010). Na podstawie analizy literatury przedmiotu sformułowano **problem główny**:

W jakim zakresie, w jakich obszarach oraz w jakich warunkach instytucjonalnych studenci wykorzystują narzędzia generatywnej AI w toku studiów i jakie znaczenie ma to dla ich praktyk uczenia się, krytycznej pracy z treścią oraz funkcjonowania w kulturze akademickiej?

Uszczegółowienie problemu głównego (Nowak, 2010) wymagało wyodrębnienia kluczowych wymiarów funkcjonowania studenta w środowisku cyfrowym, co pozwoliło na sformułowanie problemów szczegółowych.

Pierwszy problem szczegółowy dotyczył wymiaru instrumentalnego i koncentrował się na pytaniu: *Z jakich narzędzi generatywnej AI korzystają studenci, jak szeroki jest ich repertuar narzędziowy oraz czy występuje tendencja do korzystania z rozwiązań płatnych?*

Drugi problem szczegółowy odnosił się do wymiaru funkcjonalnego i obejmował pytanie: *W jakich obszarach aktywności akademickiej studenci korzystają z AI, do jakich celów włączają te narzędzia oraz jakie rodzaje zadań realizują przy ich wsparciu?*

Trzeci problem szczegółowy dotyczył wymiaru aksjologiczno-poznawczego i obejmował pytanie: *W jakim stopniu studenci podejmują krytyczną weryfikację treści generowanych przez AI, jakie strategie w tym celu stosują oraz jakie uzasadnienia towarzyszą rezygnacji z tej praktyki?*

Czwarty problem szczegółowy odnosił się do wymiaru etyczno-instytucjonalnego i koncentrował się na pytaniu: *Czy studenci odczuwają obawy związane z ujawnianiem korzystania z AI wobec kadry akademickiej oraz jak oceniają wsparcie instytucjonalne uczelni w tym zakresie?*

Piąty problem szczegółowy dotyczył wymiaru efektywnościowego i obejmował pytanie: *Jakie zmiany w sposobie studiowania, organizacji pracy oraz odczuwanej użyteczności AI dostrzegają badani od momentu włączenia tych narzędzi do własnego warsztatu pracy?*

Hipotezy. Uwzględniając charakter danych oraz rozpoznania dotyczące AI w edukacji wyższej i integralności akademickiej (Freeman, 2025; QAA, 2023–2025; TEQSA, 2025), przyjęto hipotezy kierunkowe:

H1. Użycie płatnych subskrypcji narzędzi AI wiąże się z szerszym repertuarem zastosowań sztucznej inteligencji w zadaniach akademickich w porównaniu z osobami korzystającymi wyłącznie z wersji bezpłatnych.

H2. Osoby deklarujące częstsze użycie AI w zadaniach związanych z wytwarzaniem tekstu akademickiego częściej deklarują obawy przed ujawnieniem użycia sztucznej inteligencji wobec wykładowców.

H3. Deklarowanie praktyk weryfikacji treści generowanych przez AI wiąże się z bardziej refleksyjnym opisem zmian w studiowaniu i wyższą oceną użyteczności sztucznej inteligencji jako narzędzia wspierającego uczenie się, w porównaniu z opisami opartymi na prostym przyspieszaniu pracy.

H4. Pozytywne ocenianie wsparcia uczelni w zakresie AI wiąże się ze słabszym nasileniem obaw instytucjonalnych oraz większą gotowością do jawności użycia sztucznej inteligencji.

H5. Zmienne kontekstowe, w szczególności poziom studiów i tryb studiów, różnicują style użycia AI, zakres zadań oraz typ racjonalizacji opisanych w odpowiedziach otwartych.

Zmienne badawcze, w tym zmienne kontekstowe, zgodne z danymi empirycznymi. W badaniu przyjęto, że opis praktyk studiowania z użyciem generatywnej AI wymaga równoczesnego uwzględnienia zmiennych kontekstowych oraz zmiennych merytorycznych odnoszących się do sposobów, celów i konsekwencji korzystania z narzędzi sztucznej inteligencji. Zmienne zostały zdefiniowane operacyjnie wprost na podstawie pól kwestionariusza ankiety, co oznacza, że ich zakres semantyczny i możliwości analityczne są zakorzenione w realnie zebranym materiale empirycznym. Zbiór danych obejmuje 414 rekordów, przy czym w części pól występują braki odpowiedzi, które zostały uwzględnione na etapie procedur analitycznych.

Zmienne kontekstowe, socjodemograficzne i akademickie. Pierwszą grupę stanowią zmienne kontekstowe pełniące funkcję różnicującą i kontrolną. Ich włączenie pozwala interpretować praktyki użycia generatywnej AI jako zjawisko zróżnicowane instytucjonalnie, dyscyplinarnie i biograficznie, a nie jako jednorodny wzorzec studencki.

Wiek respondenta ujęto jako zmienną ilościową wyrażoną w latach; w danych występuje zakres od 18 do 45. Płeć potraktowano jako zmienną nominalną o trzech kategoriach odpowiedzi: kobieta, mężczyzna, wolę nie odpowiadać. Poziom studiów ma charakter nominalny i obejmuje studia pierwszego stopnia, studia drugiego stopnia, jednolite studia magisterskie oraz szkołę doktorską. Rok studiów posiada charakter porządkowy, przy czym w materiale empirycznym widoczne są zarówno zapisy słowne, jak i arabskie, co wymaga ujednolicenia do spójnej skali porządkowej na etapie przygotowania danych. Tryb studiów występuje jako zmienna nominalna z kategoriami: stacjonarne oraz niestacjonarne. Kierunek studiów i uczelnia zostały zebrane w postaci pól otwartych, co wymaga dwóch równoległych procedur porządkujących: kategoryzacji kierunków do szerszych obszarów kształcenia oraz standaryzacji nazw uczelni ze względu na warianty zapisu tej samej instytucji.

Tak skonstruowany zestaw zmiennych kontekstowych umożliwia testowanie hipotez różnicujących style korzystania z narzędzi AI ze względu na poziom i tryb studiów, a także pozwala ostrożnie rekonstruować możliwe efekty środowiskowe związane z kulturą instytucjonalną oraz profilem dyscyplinarnym.

Zmienne merytoryczne opisujące korzystanie z narzędzi AI. Drugą grupę stanowiły zmienne merytoryczne, które opisują treść i logikę użycia narzędzi AI w studiowaniu. Przyjęto tu, że kluczowym konstruktem analitycznym jest styl i zakres użycia narzędzi AI rekonstruowany z zestawu odpowiedzi dotyczących instrumentarium, celów, praktyk oraz deklarowanych konsekwencji.

W wymiarze instrumentalnym badanie obejmuje identyfikację narzędzi używanych przez studentów, pozyskaną w polu otwartym, co pozwala uchwycić zarówno dominujące rozwiązania, jak i praktyki hybrydowe, obejmujące połączenie kilku systemów. W tym samym obszarze ujęto korzystanie z subskrypcji płatnych jako zmienną dychotomiczną, z możliwością doprecyzowania nazwy narzędzia w polu otwartym. Taki zapis pozwala traktować płatny dostęp jako istotny kontekst intensywności i jakości użycia narzędzi AI oraz jako potencjalny czynnik różnicujący repertuar zastosowań.

W wymiarze intencjonalnym i funkcjonalnym uchwyciono cele użycia generatywnej AI oraz sposoby, w jakie narzędzia sztucznej inteligencji wspierają uczenie się, a także rodzaje zadań akademickich, w których respondenci deklarują korzystanie z narzędzi generatywnych. Te elementy mają w kwestionariuszu charakter otwarty, co umożliwia późniejszą kategoryzację wypowiedzi i rekonstrukcję typów praktyk, np. użycia wspierającego organizację uczenia się, użycia służącego syntezie materiału, użycia redakcyjnego, translacyjnego lub substytucyjnego w wytwarzaniu tekstu.

W wymiarze refleksyjno-rozwojowym uwzględniono opis zmiany sposobu studiowania po wdrożeniu AI do własnego warsztatu pracy. Zmienna ta jest

istotna, ponieważ stanowi pomost między prostą diagnozą częstotliwości użycia narzędzi a jakościową rekonstrukcją przeobrażeń w samoregulacji, planowaniu, tempie pracy i poczuciu sprawczości.

W wymiarze kompetencyjno-poznawczym ujęto weryfikację treści generowanych przez AI jako zmienną dychotomiczną z pogłębieniem opisowym w polu otwartym. W przypadku deklaracji braku weryfikacji aktywowane jest dodatkowe pole otwarte, pozwalające zrekonstruować racjonalizacje oraz czynniki sprzyjające rezygnacji z kontroli jakości, takie jak zaufanie do narzędzia, presja czasu lub przekonanie o wystarczającej poprawności generowanych treści. Włączenie tej pary zmiennych umożliwia przejście od deklaracji do analizy strategii, a tym samym pozwala interpretować weryfikację jako wskaźnik odpowiedzialności poznawczej.

W wymiarze etyczno-instytucjonalnym badanie obejmuje obawy przed ujawnieniem użycia AI wobec wykładowców jako zmienną dychotomiczną wraz z uzasadnieniem w polu otwartym. Zmienna ta pozwala analizować napięcia normatywne w kulturze akademickiej, w tym lęk przed stygmatyzacją lub podejrzeniem o naruszenie zasad integralności akademickiej. Równolegle ujęto ocenę wsparcia uczelni w zakresie AI jako zmienną nominalną, obejmującą odpowiedzi: „tak”, „nie” oraz „inne” z możliwością doprecyzowania. Dzięki temu można badać relacje między oceną wsparcia instytucjonalnego a gotowością do jawności użycia narzędzi, a także zrekonstruować oczekiwania studentów wobec regulacji i szkoleń.

Wreszcie, w wymiarze wdrożeniowym ujęto potrzeby szkoleniowe studentów w formie pola otwartego. Zmienna ta została włączona ze względu na praktyczny cel badań, ponieważ umożliwia sformułowanie postulatów dotyczących działań uczelnianych, zwłaszcza w zakresie *AI literacy*, krytycznej weryfikacji treści oraz zasad jawności.

Tak zbudowany zestaw zmiennych pozwala zarówno na analizy opisowe, jak i testowanie zależności, a równocześnie na jakościową rekonstrukcję sensów, racjonalizacji i napięć, które towarzyszą studentom przy korzystaniu z generatywnej AI.

Wskaźniki badań. Na potrzeby niniejszych badań pojęcie *wykorzystanie narzędzi AI w procesie kształcenia* zdefiniowano operacyjnie poprzez wyodrębnienie pięciu kluczowych wskaźników, które poddano pomiarowi w narzędziu badawczym:

1. Wskaźnik instrumentalny (preferencje narzędziowe): zdefiniowany jako rodzaj i dywersyfikacja oprogramowania wykorzystywanego przez studenta (modele tekstowe, graficzne, analityczne) oraz charakter dostępu (wersje bezpłatne *open source* vs. subskrypcje płatne).

2. Wskaźnik funkcjonalny (obszary zastosowań): rozumiany jako konkretne czynności akademickie, w których student deleguje zadania algorytmom.

Wskaźnik ten obejmuje takie kategorie, jak: kwerenda biblioteczna, generowanie struktury prac dyplomowych, synteza treści (streszczenia) czy tłumaczenia tekstów naukowych.

3. Wskaźnik aksjologiczny (weryfikacja wartości wiedzy): zdefiniowany jako poziom krytycyzmu poznawczego studenta wobec halucynacji AI. Mierzony jest poprzez deklarowane strategie sprawdzania faktów (*cross-checking* z literaturą, weryfikacja w *Google*, brak weryfikacji) oraz zaufanie do generowanych treści.

4. Wskaźnik etyczny (psychospołeczny i instytucjonalny) zdefiniowany jako subiektywne odczucia studenta związane z jawnym wykorzystaniem AI w środowisku akademickim (lęk przed stygmatyzacją, obawa przed oskarżeniem o plagiat) oraz ocena wsparcia systemowego ze strony uczelni (dostępność szkoleń, jasność regulacji).

5. Wskaźnik bilansu studiowania (stymulacja procesu): określony jako bilans zysków i strat w osobistej ekonomii uczenia się. Obejmuje ocenę oszczędności czasu, zmianę jakości przygotowywanych materiałów oraz refleksję nad ewentualnym zanikiem własnej kreatywności lub motywacji („rozleniwienie intelektualne”).

Taka procedura odpowiada współczesnym zaleceniom, aby w badaniach nad generatywną AI odróżniać użycie wspierające uczenie się od użycia substytucyjnego oraz analizować warunki instytucjonalne jako istotny moderator zachowań studentów (TEQSA, 2025; European Commission, 2024).

4. Metody, techniki i narzędzia badawcze

W badaniu przyjęto strategię ilościową z komponentem jakościowym osadzonym w odpowiedziach otwartych. Taki wybór wynika z charakteru problemu badawczego, w którym kluczowe pozostają z jednej strony rozkłady i zależności dotyczące skali oraz form użycia narzędzi generatywnej AI, z drugiej zaś językowe racjonalizacje studentów odnoszące się do weryfikacji treści, jawności użycia generatywnej sztucznej inteligencji oraz doświadczeń instytucjonalnych. W konsekwencji zastosowano podejście zbliżone do ugruntowanych metod mieszanych (*embedded mixed methods*), w którym dane jakościowe pełnią funkcję wyjaśniającą i interpretacyjną wobec wyników ilościowych.

Jako metodę badań empirycznych zastosowano sondaż diagnostyczny. Metoda ta pozwala diagnozować opinie, postawy oraz deklarowane zachowania badanej zbiorowości w określonym momencie czasu, a zarazem umożliwia analizę różnicowań wewnątrz populacji ze względu na cechy kontekstowe, takie jak poziom studiów, tryb studiowania czy profil kierunku. Technika badawcza przyjęła postać ankiety internetowej realizowanej w formule CAWI, co pozostaje spójne z badaniem populacji o wysokiej sprawności cyfrowej oraz z dystrybucją narzędzia w środowiskach komunikacji studenckiej.

Narzędziem badawczym był autorski kwestionariusz ankiety obejmujący część metryczkową oraz zestaw pytań merytorycznych dotyczących użycia narzędzi generatywnej AI. Jego struktura łączy pytania zamknięte, w tym pytania dychotomiczne, z pytaniami otwartymi, które umożliwiają rekonstrukcję kategorii znaczeniowych i uzasadnień. Dzięki temu możliwe staje się ujęcie zjawiska zarówno w perspektywie wskaźnikowej, jak i w interpretacyjnej, powiązanej z doświadczeniem uczenia się w środowisku algorytmicznym.

Analiza materiału empirycznego przebiega dwutorowo. W części ilościowej zastosowano statystykę opisową w postaci rozkładów liczbowych i procentowych, a następnie analizy zależności pomiędzy zmiennymi, adekwatne do ich poziomu pomiaru. Dla zmiennych nominalnych i dychotomicznych przewidziano analizę zależności w tabelach krzyżowych oraz testy istotności statystycznej, natomiast w przypadku zmiennych porządkowych uwzględniono procedury umożliwiające porównania grup oraz analizę współwystępowania trendów. Dobór procedur analitycznych zostanie każdorazowo dostosowany do rozkładów danych oraz liczebności kategorii.

W części jakościowej odpowiedzi otwarte poddano analizie treści ukierunkowanej na kategoryzację semantyczną. Procedura obejmuje etap wstępnego kodowania otwartego, następnie porządkowanie kodów w kategorie tematyczne oraz opracowanie definicji kategorii wraz z przykładami wypowiedzi. Wątek szczególnie ważny stanowią uzasadnienia dotyczące weryfikacji lub rezygnacji z weryfikacji treści generowanych przez AI, a także racjonalizacje obaw przed ujawnieniem użycia narzędzi. Taka procedura umożliwia powiązanie danych jakościowych z wynikami ilościowymi, wspierając interpretację zależności i budowę typologii stylów użycia narzędzi AI.

W efekcie przyjęte rozwiązanie metodologiczne pozwala zachować równowagę między diagnozą skali zjawiska a rekonstrukcją sensów i napięć, które organizują praktyki studiowania w warunkach upowszechnienia narzędzi generatywnej AI.

5. Organizacja i przebieg badań

Badania właściwe zrealizowano w okresie od 3 grudnia 2025 r. do 15 stycznia 2026 r. Proces badawczy obejmował dystrybucję kwestionariusza w środowisku cyfrowym (media społecznościowe, grupy studenckie, kanały komunikacji uczelnianej).

Terenem badań były polskie uczelnie wyższe. Analiza surowych danych bazowała na udziale studentów z wiodących ośrodków akademickich, m.in.:

- Uniwersytetu Szczecińskiego (dominująca frakcja),
- Uniwersytetu Rzeszowskiego,
- Uniwersytetu Jagiellońskiego,
- Uniwersytetu w Białymstoku,

– Politechniki Koszalińskiej,

W badaniach zastosowano dobór celowy. Kryterium włączenia do badania był status studenta studiów pierwszego stopnia, drugiego stopnia, jednolitych studiów magisterskich albo szkoły doktorskiej. Próba została utworzona z osób osiągalnych dla badaczy w środowisku akademickim i cyfrowym, co jest częstym rozwiązaniem w badaniach eksploracyjnych dotyczących zjawisk związanych z technologią cyfrową (Frankfort-Nachmias, Nachmias, 2001).

Zgromadzony materiał empiryczny obejmuje 457 wypełnionych kwestionariuszy. Struktura grupy badawczej przedstawia się następująco:

1. Profil edukacyjny: badani reprezentują szerokie spektrum dyscyplin, od nauk humanistycznych i społecznych (pedagogika, psychologia, filologie), przez nauki ścisłe (informatyka, matematyka), aż po nauki medyczne i o zdrowiu.

2. Status akademicki: w badaniu udział wzięli studenci wszystkich roczników z zauważalną reprezentacją studentów ostatniego roku (przed egzaminem dyplomowym) oraz słuchacze szkół doktorskich, co podnosi walor poznawczy badań (doświadczenie w procesie studiowania).

Zastosowanie triangulacji metodologicznej poprzez łączenie danych ilościowych z jakościową analizą wypowiedzi otwartych (np. uzasadnień braku weryfikacji informacji) pozwoliło na uzyskanie wielowymiarowego obrazu badanego zjawiska.

Badania przeprowadzono zgodnie z zasadami etyki naukowo-badawczej. Ze względu na fakt, iż wszyscy respondenci byli osobami pełnoletnimi (studentami), przeprowadzenie badań nie wymagało zgody komisji etycznej ds. badań z udziałem ludzi. Mimo to zachowano najwyższe standardy:

a) udział w badaniu nie był obligatoryjny i nie wpływał na ocenę z przedmiotu;

b) narzędzie nie zbierało danych wrażliwych ani osobowych umożliwiających identyfikację (adresy IP, nazwiska);

c) uczestnicy zostali poinformowani o naukowym celu gromadzenia danych.

Autorzy mają świadomość ograniczeń wynikających z przyjętej metody doboru próby (próba nieprobabilistyczna). Wyniki badań nie powinny być uogólniane na całą populację studentów w Polsce, lecz traktowane jako diagnoza trendów w badanych środowiskach akademickich.

Bibliografia

Babbie, E. (2013). *The practice of social research*. Cengage Learning.

European Commission (2024). *Guidelines on the responsible use of generative AI in research oraz komunikat w serwisie DG RTD*.

Frankfort-Nachmias, C., Nachmias, D. (2001). *Metody badawcze w naukach społecznych*. Poznań: Zysk i S-ka.

Freeman, J. (2025). *Student Generative AI Survey 2025*. Pobrano z: <https://www.hepi.ac.uk/reports/student-generative-ai-survey-2025/> (4.2026).

- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Nowak, S. (2010). *Metodologia badań społecznych*. Warszawa: Wyd. Naukowe PWN.
- OECD (2023). *OECD Digital Education Outlook 2023: Towards an effective digital education ecosystem, Emerging governance of generative AI in education*. Pobrano z: https://www.oecd.org/en/publications/oecd-digital-education-outlook-2023_c74f03de-en.html (4.2026).
- QAA (2023–2025). *Advice and resources on Generative AI, zasoby dotyczące standardów i integralności akademickiej*. Pobrano z: https://www.qaa.ac.uk/docs/qaa/members/maintaining-quality-and-standards-in-the-chatgpt-era.pdf?sfvrsn=2408aa81_10 (4.2026).
- Redecker, C. (2017). *European framework for the digital competence of educators: DigCompEdu*. Pobrano z: <https://op.europa.eu/en/publication-detail/-/publication/fcc33b68-d581-11e7-a5b9-01aa75ed71a1/language-en> (4.2026).
- Selwyn, N. (2019). *Should robots replace teachers? AI and the future of education*. Polity Press.
- Sztumski, J. (1999). *Wstęp do metod i technik badań społecznych*. Katowice: Wyd. Śląsk.
- TEQSA (2025). *Gen AI academic integrity and assessment reform, zasoby dobrej praktyki*.

CZĘŚĆ TRZECIA

ANALIZA I INTERPRETACJA WYNIKÓW BADAŃ EMPIRYCZNYCH DOTYCZĄCYCH STOSOWANIA GENERATYWNEJ AI PRZEZ STUDENTÓW

1. PREFERENCJE NARZĘDZIOWE I SUBSKRYPCJE DOTYCZĄCE KORZYSTANIA Z NARZĘDZI AI – WSKAŹNIK INSTRUMENTALNY

MARTA GLINIECKA, ELŻBIETA PERZYCKA-BOROWSKA

Wskaźnik instrumentalny opisuje zaplecze narzędziowe, na którym studenci opierają praktyki studiowania z wykorzystaniem generatywnej AI. W logice pierwszego problemu badawczego celem tej części jest identyfikacja dominujących narzędzi AI oraz rozpoznanie skali korzystania z rozwiązań płatnych. Oprócz rozkładów częstości uwzględniono również analizy różnicujące według zmiennych kontekstowych, aby ocenić, czy preferencje narzędziowe i subskrypcje wykazują zróżnicowanie związane z profilem studiów, poziomem studiów, trybem studiowania, płcią oraz wiekiem.

1.1. Narzędzia AI wskazane przez studentów


Odpowiedź na pytanie o preferencje narzędziowe przedstawiono w tabeli 3.1.1 i na wykresie 3.1.1.

Tabela 3.1.1. Narzędzia AI wskazane przez studentów (liczba wzmianek respondentów),
N = 457

Kategoria (narzędzia AI)	N	%
<i>I</i>	2	3
ChatGPT	395	86,4
Gemini	122	26,7
Copilot	28	6,1
Google Notebook LM	15	3,3
Perplexity	14	3,1
Gamma AI	11	2,4
DeepSeek	10	2,2
Grok AI	9	2,0
Canva	8	1,7

1	2	3
Google AI	6	1,3
Claude	4	0,9
Suno AI	3	0,7
Aria AI	3	0,7
DeepL	2	0,4
Nie korzystam z narzędzi AI	20	4,4
Brak danych	40	8,8

Źródło: badania własne.



Wykres 3.1.1. Narzędzia AI wskazane przez studentów, rozkład liczebności, N = 457

Źródło: badania własne (respondenci mogli wskazać więcej niż jedno narzędzie, dlatego odsetki nie sumują się do 100).

Analiza. Najczęściej wskazywanym narzędziem był ChatGPT wymieniony przez 395 osób, co stanowi 86,4% respondentów. Na drugim miejscu znalazł się Gemini wskazany przez 122 osoby, czyli 26,7% badanych. Wyraźnie rzadziej pojawiały się Copilot (28 osób; 6,1%), Google Notebook LM (15 osób; 3,3%) oraz Perplexity (14 osób; 3,1%). Pozostałe narzędzia, takie jak Gamma AI, DeepSeek, Grok AI, Canva, Claude czy Suno AI, występowały sporadycznie. Z żadnych narzędzi AI nie korzystało 20 osób, co odpowiada 4,4% próby, natomiast 40 respondentów (8,8%) nie udzieliło odpowiedzi na to pytanie.

Rozkład odpowiedzi wskazuje na silną koncentrację praktyk narzędziowych wokół jednego dominującego rozwiązania konwersacyjnego. W badanej grupie wyraźnie dominują chatboty tekstowe, podczas gdy narzędzia wykorzystywane do tworzenia materiałów wizualnych, muzycznych lub innych treści multimedialnych pojawiają się zdecydowanie rzadziej. W zebranych materiałach nie odnotowano także wskazań narzędzi służących do generowania wideo i animacji, co

może świadczyć o relatywnie słabej obecności tego typu rozwiązań w codziennych praktykach studiowania.

Interpretacja i weryfikacja. Analiza odpowiedzi wskazuje, że w badanej grupie studentów najwyższą popularnością cieszą się chatboty tekstowe, podczas gdy narzędzia generatywnej AI wykorzystywane do tworzenia treści multimedialnych pojawiają się znacznie rzadziej. Jedynie nieliczni respondenci deklarowali korzystanie z programów wspierających projektowanie wizualne, takich jak Canva AI czy Gamma AI, a także z narzędzi służących do generowania muzyki, takich jak Suno AI. W materiale badawczym nie odnotowano natomiast wskazań odnoszących się do narzędzi przeznaczonych do generowania wideo i animacji, takich jak Sora.

Taki rozkład odpowiedzi można wiązać z odmiennym progiem dostępności poszczególnych typów narzędzi. Korzystanie z aplikacji tekstowych jest zwykle prostsze, szybsze i bliższe codziennym praktykom studiowania obejmującym wyszukiwanie informacji, streszczanie, redagowanie wypowiedzi oraz porządkowanie materiału. Z kolei narzędzia służące do tworzenia treści wizualnych i audialnych wymagają częściej bardziej złożonych kompetencji, związanych z planowaniem treści, kompozycją wizualną, projektowaniem komunikatów medialnych oraz bardziej świadomym formułowaniem poleceń kierowanych do systemu (Ramalia, 2023). Można zatem przyjąć, że koncentracja studentów na narzędziach tekstowych pozostaje częściowo związana z większą użytecznością tych rozwiązań w dominujących zadaniach akademickich.

Wyraźna dominacja ChatGPT może również pozostawać w związku ze specyfiką studiowanych kierunków. W badanej próbie licznie reprezentowani byli studenci pedagogiki, psychologii, filologii oraz edukacji artystycznej, a więc kierunków, w których zasadniczą rolę odgrywa praca z tekstem, interpretacją, komunikacją i opracowywaniem treści. W mniejszym stopniu reprezentowane były kierunki matematyczno-przyrodnicze, takie jak oceanografia, biologia, matematyka czy informatyka. Zbieżne rozpoznania pojawiają się w badaniach prowadzonych w innych krajach. Katseli i Drigas (2026) wskazują, że wśród studentów nauk humanistycznych i społecznych chatboty są wykorzystywane przede wszystkim do tworzenia streszczeń, redagowania wypowiedzi oraz wyszukiwania informacji. Również badania porównawcze prowadzone w szkolnictwie wyższym pokazują, że ChatGPT pozostaje narzędziem pierwszego wyboru, przy czym sposoby użycia oraz postawy wobec tego typu rozwiązań różnicują się w zależności od pola studiów i poziomu edukacji (Stöhr, Ou, Malmström, 2024).

Uzyskane wyniki pozostają także zgodne z ustaleniami badań krajowych. W sondażu przeprowadzonym wśród studentów Politechniki Białostockiej ChatGPT został wskazany jako preferowane narzędzie AI przez 92,9% respondentów, natomiast drugą pozycję zajęły programy wykorzystywane do tworzenia materiałów wizualnych, takie jak Canva, Beautiful.ai oraz Durable AI (Raszyd,

Wesołowska, Tomaszewska, 2024). W szerszej perspektywie adopcji technologii wzorzec ten można łączyć z rolą nawyku użytkowania oraz z oczekiwaną użytecznością narzędzia, które należą do istotnych predyktorów korzystania z aplikacji opartych na generatywnej AI (Strzelecki, 2024).

Na uwagę zasługuje też fakt, że część studentów zadeklarowała całkowitą rezygnację z korzystania z narzędzi AI. W wypowiedziach tej grupy pojawiały się argumenty odnoszące się do obaw o ograniczanie samodzielnego myślenia, ryzyka generowania informacji nieprawdziwych oraz nadmiernej obecności mechanizmów algorytmicznych w codziennym obiegu informacyjnym. Tego rodzaju stanowiska można interpretować jako przejaw ostrożności poznawczej oraz krytycznego dystansu wobec nowych technologii. W tym kontekście warto odwołać się do badań prowadzonych w Norwegii, które wskazują, że część studentów, szczególnie kobiet, wykazuje podwyższony poziom lęku wobec narzędzi AI, co może współwystępować z rzadszym korzystaniem z tych technologii (Møgelvang, Bjelland, Grassini, Ludvigsen, 2024).

Analiza materiału empirycznego ujawniła również pojedyncze wypowiedzi krytyczne związane z troską o środowisko. Niektórzy respondenci formułowali opinie o wysokim ładunku emocjonalnym, wskazując na znaczne zużycie energii i wody przez technologie AI oraz wyrażając sprzeciw wobec ich dalszego rozwoju i instytucjonalnego wspierania. Chociaż głosy te występowały rzadko, stanowią ważny sygnał obecności refleksji ekologicznej wśród części badanych studentów. Podobne rozpoznania pojawiają się też w badaniach międzynarodowych. Dun-go, Beltran, Declaro, Dela Cruz i Viray (2025) pokazują, że studenci kierunków związanych z ochroną środowiska oraz technologią medyczną częściej uwzględniają ekologiczne konsekwencje wykorzystania generatywnej AI, podczas gdy u studentów innych kierunków świadomość materialnych kosztów rozwoju tych technologii, obejmujących m.in. zużycie energii i wody, pozostaje słabiej rozwinięta.


1.2. Dywersyfikacja repertuaru narzędzi

Ważnym dopełnieniem analizy preferencji narzędziowych jest rozpoznanie, jak szeroki repertuar narzędzi AI wykorzystują poszczególni respondenci. Zróżnicowanie liczby narzędzi AI wskazanych przez badanych przedstawiono w tabeli 3.1.2 oraz na wykresie 3.1.2.

Tabela 3.1.2. Liczba narzędzi AI wskazanych przez jednego respondenta, N = 457

Kategoria	N	%
0	20	4,4
1	290	63,46
2	104	22,8
3	30	6,56
4	13	2,84

Źródło: badania własne.



Wykres 3.1.2. Dywersyfikacja narzędzi AI na osobę, N = 457

Źródło: badania własne.

Analiza. Dominującym stylem korzystania z narzędzi AI pozostaje użycie jednego narzędzia. Taki sposób organizowania praktyk studiowania deklarowało 290 osób, co stanowi 63,46% badanych. Korzystanie z dwóch narzędzi wskazały 104 osoby (22,8%), z trzech narzędzi korzysta 30 osób (6,56%), natomiast z czterech narzędzi – 13 osób (2,84%). Niekorzystanie z narzędzi AI zadeklarowało 20 respondentów (4,4%). Rozkład ten wskazuje, że praktyki studiowania z wykorzystaniem AI najczęściej koncentrują się wokół jednego dominującego rozwiązania, natomiast szerszy repertuar narzędzi pojawia się rzadziej. Można to interpretować jako współwystępowanie dwóch stylów pracy: bardziej ustabilizowanego, opartego na jednym podstawowym narzędziu, oraz bardziej zróżnicowanego, w którym dobór aplikacji pozostaje powiązany z typem realizowanego zadania.

Dodatkowa analiza, wiek i dywersyfikacja. Korelacja rang Spearmana między wiekiem respondentów a liczbą wskazanych narzędzi AI wyniosła $\rho = 0,097$, $p = 0,041$, przy $N = 448$. Analiza objęła osoby w wieku 18–45 lat, w przypadku których dostępne były kompletne dane w obu zmiennych. Otrzymany wynik wskazuje na bardzo słabą dodatnią zależność, co oznacza, że wraz ze wzrostem wieku liczba deklarowanych narzędzi zwiększa się jedynie w bardzo niewielkim stopniu. Zależność ta ma ograniczone znaczenie praktyczne i powinna być traktowana przede wszystkim jako sygnał diagnostyczny. Może to sugerować, że starsi respondenci dysponują nieco szerszym repertuarem narzędzi, jednak skala tej różnicy pozostaje niewielka i nie uzasadnia daleko idących uogólnień.

1.3. Korzystanie z płatnych wersji narzędzi AI


Ważnym dopełnieniem analizy preferencji narzędziowych jest także rozpoznanie, w jakim stopniu studenci korzystają z płatnych wersji narzędzi AI. Pozwala to uchwycić, czy praktyki studiowania z wykorzystaniem generatywnej AI opierają się przede wszystkim na rozwiązaniach ogólnodostępnych, czy też

obejmują również dostęp do funkcji rozszerzonych, związanych z subskrypcją. Rozkład deklaracji dotyczących korzystania z płatnych wersji narzędzi AI przedstawiono w tabeli 3.1.3 oraz na wykresie 3.1.3.

Tabela 3.1.3. Korzystanie z płatnych wersji narzędzi AI, N = 457

Kategoria	N	Odsetek %
Nie	390	85,3
Tak	48	10,5
Tak, dostęp promocyjny (np. darmowy dostęp dla studentów przez rok)	11	2,4
Brak danych	8	1,75

Źródło: badania własne.



Wykres 3.1.3. Korzystanie z płatnych wersji narzędzi AI, N = 457

Źródło: badania własne.

Analiza. Z analizowanych danych wynika, że respondenci zdecydowanie częściej korzystają z bezpłatnych wersji narzędzi AI niż z ich odpowiedników subskrypcyjnych. Brak korzystania z płatnych wersji zadeklarowało 390 osób, co stanowi 85,3% badanych. Z płatnych subskrypcji korzystało 48 respondentów, czyli 10,5% próby, natomiast 11 osób (2,4%) wskazało na dostęp promocyjny obejmujący np. czasowy pakiet bezpłatny dla studentów. Brak danych odnotowano w przypadku 8 respondentów (1,75%).

Rozkład ten wskazuje, że praktyki studiowania z wykorzystaniem AI opierają się przede wszystkim na narzędziach ogólnodostępnych. Korzystanie z wersji płatnych pozostaje wyraźnie rzadsze, co można wiązać zarówno z kosztami finansowymi, jak i z faktem, że dla wielu studentów funkcje dostępne w wersjach bezpłatnych okazują się wystarczające w realizacji codziennych zadań akademickich. W odpowiedziach otwartych respondenci wskazywali również konkretne narzędzia objęte płatną subskrypcją. Najczęściej wymieniano płatną wersję ChatGPT, rzadziej Gemini, Perplexity, Canva oraz Claude.


Uzyskany wynik pozostaje zbieżny z rozpoznaniem obecnymi w literaturze. W badaniach zagranicznych studenci również częściej sięgają po bezpłatne wersje narzędzi AI, a płatne subskrypcje mają charakter bardziej selektywny. Miah i in. (2025) wskazują, że wśród studentów kierunków inżynierskich dominują bezpłatne wersje aplikacji, co ogranicza zakres korzystania z funkcji rozszerzonych, dostępnych jedynie w modelu subskrypcyjnym. Z perspektywy równości dostępu można zatem uznać, że zróżnicowanie ekonomiczne może przekładać się na nierówny dostęp do bardziej zaawansowanych funkcji narzędziowych, a tym samym na zróżnicowanie możliwości pracy akademickiej.

Dodatkowa analiza, subskrypcja a obszar kierunku. Różnice w odsetku osób deklarujących korzystanie z płatnych subskrypcji w poszczególnych obszarach kierunków przedstawiono w tabeli 3.1.4 oraz na wykresie 3.1.4. Zastosowany test chi kwadrat wykazał istotność statystyczną zależności, $p = 0,0026$, przy wartości współczynnika Craméra $V = 0,211$, co można interpretować jako efekt mały, zbliżający się do umiarkowanego.

Tabela 3.1.4. Subskrypcja Tak, odsetek w grupie według dziedziny – kierunku studiów

Kierunek studiów (nazwa kierunku)	N	Subskrypcja Tak %
Ekonomia, zarządzanie i prawo	20	25,0
STEM i inżynierskie	57	19,3
Sztuka i kultura	6	16,7
Humanistyczne i społeczne	211	8,1
Interdyscyplinarne	148	4,1
Zdrowie i medyczne	2	0,0
Środowisko i przyroda	9	0,0
Bez wskazania kierunku	4	0,0

Źródło: badania własne.



Wykres 3.1.4. Subskrypcja Tak, odsetek według obszaru kierunku, N = 457

Źródło: badania własne (analiza obejmuje wyłącznie osoby z kompletnymi danymi dotyczącymi obszaru kierunku studiów i deklaracji subskrypcji).

Interpretacja i weryfikacja. Uzyskane wyniki sugerują, że skłonność do korzystania z płatnych wersji narzędzi AI nie rozkłada się równomiernie między obszarami kształcenia. Wyższe odsetki subskrypcji odnotowano w grupach związanych z ekonomią, zarządzaniem i prawem oraz w obszarze STEM i kierunków inżynierskich, natomiast niższe wśród studentów kierunków humanistycznych i społecznych oraz w grupach określonych jako inne. Interpretacja tych różnic powinna jednak uwzględniać liczebność poszczególnych kategorii, ponieważ w niektórych obszarach grupy były nieliczne, co ogranicza siłę uogólnień.

Wynik ten można odczytywać w kontekście zróżnicowanych kultur studiowania, odmiennych potrzeb zadaniowych oraz nierówności w dostępie do zasobów cyfrowych. W literaturze podkreśla się, że polityki instytucjonalne dotyczące wdrażania AI powinny uwzględniać kwestie równości dostępu, aby ograniczać ryzyko powstawania nowych nierówności narzędziowych między studentami i obszarami kształcenia (Jin, Yan, Echeverria, Gašević, Martinez-Maldonado, 2025). Z tego punktu widzenia subskrypcja narzędzi AI może być interpretowana nie tylko jako indywidualny wybór użytkownika, lecz również jako wskaźnik szerszych uwarunkowań instytucjonalnych i ekonomicznych.

1.4. Preferencje narzędziowe a zmienne kontekstowe, analizy uzupełniające

Analiza danych empirycznych wskazuje, że struktura badanej próby była silnie zdominowana przez studentów reprezentujących dziedzinę nauk społecznych, którzy stanowili 68,1% wszystkich badanych (311 osób). Na kolejnych pozycjach znalazły się dziedzina nauk ścisłych i przyrodniczych (16,8%) oraz dziedzina nauk humanistycznych (7,9%). Pozostałe dziedziny miały wyraźnie mniejszy udział liczbowy (tabela 3.1.5, wykres 3.1.5).


Tabela 3.1.5. Użycie narzędzi GenAI ze względu na dziedzinę – kierunek studiów

Dziedzina – kierunek studiów	N	%	Liczba wskazań używanych narzędzi AI	Brak wskazań używanych narzędzi AI
Dziedzina nauk społecznych	311	68,1	454	4
Dziedzina nauk ścisłych i przyrodniczych	77	16,8	137	4
Dziedzina nauk humanistycznych	36	7,9	36	10
Dziedzina sztuki	13	2,8	17	2
Dziedzina nauk medycznych i nauk o zdrowiu	8	1,8	12	0
Dziedzina nauk inżynieryjno-technicznych	7	1,5	14	0
Bez wskazania kierunku	5	1,1	2	4
Razem	457	100,0	672	24

Źródło: badania własne.

Łącznie odnotowano 672 wskazania różnych narzędzi AI przy 457 osobach badanych, co oznacza średnio 1,47 wskazania narzędzia na osobę w całej próbie. Wskaźnik ten różnicował się jednak pomiędzy dziedzinami. Największą bez-

względną liczbę wskazań narzędzi AI odnotowano w dziedzinie nauk społecznych (454), co pozostaje bezpośrednio związane z dominacją liczebną tej grupy w strukturze próby. Sama wartość tej liczby nie oznacza jeszcze najwyższej intensywności korzystania z narzędzi, lecz przede wszystkim odzwierciedla udział tej dziedziny w badaniu.



Wykres 3.1.5. Użycie aplikacji GenAI ze względu na dziedzinę – kierunek studiów


Źródło: badania własne.

W analizach uzupełniających sprawdzono, czy użycie trzech najczęściej wskazywanych narzędzi AI różnicuje się ze względu na obszar kierunku studiów. Analiza ta pozwala rozpoznać, czy preferencje narzędziowe pozostają jednakowe w całej badanej grupie, czy też wykazują związek z profilem kształcenia. Wyniki przedstawiono w tabeli 3.1.6 oraz na wykresie 3.1.6.

Tabela 3.1.6. Użycie aplikacji ChatGPT ze względu na dziedzinę – kierunek studiów

Kierunek studiów (nazwa kierunku)	N	Tak %
Ekonomia, zarządzanie i prawo	20	90,0
STEM i inżynieryjne	57	84,2
Humanistyczne i społeczne	211	81,0
Inne	148	77,7
Sztuka i kultura	6	66,7
Środowisko i przyroda	9	66,7
Zdrowie i medyczne	2	50,0
Bez wskazania kierunku	4	0,0

Źródło: badania własne.



Wykres 3.1.6. Użycie ChatGPT ze względu na obszar kierunku studiów, N = 457


Źródło: badania własne.

Analiza. Odsetek respondentów deklarujących użycie aplikacji ChatGPT był wysoki we wszystkich analizowanych obszarach kierunków studiów. Najwyższe wartości odnotowano w grupie ekonomia, zarządzanie i prawo (90,0%) oraz w grupie STEM i kierunki inżynieryjne (84,2%). W obszarze humanistycznym i społecznym wskaźnik ten wyniósł 81,0%, a w grupie inne – 77,7%. Niższe odsetki odnotowano w grupach sztuka i kultura oraz środowisko i przyroda (po 66,7%) oraz zdrowie i medyczne (50,0%). Test chi kwadrat nie wykazał jednak statystycznie istotnej zależności między użyciem aplikacji ChatGPT a obszarem kierunku studiów, $p = 0,5027$, przy wartości współczynnika Craméra $V = 0,108$. Oznacza to, że mimo pewnych różnic procentowych użycie ChatGPT pozostaje w badanej próbie relatywnie równomiernie rozpowszechnione i nie wykazuje istotnego zróżnicowania ze względu na profil kierunku.

Tabela 3.1.7. Użycie aplikacji Gemini ze względu na obszar kierunku studiów

Kierunek studiów (nazwa kierunku)	N	Tak %
Ekonomia, zarządzanie i prawo	20	60,0
STEM i inżynieryjne	57	52,6
Zdrowie i medyczne	2	50,0
Inne	148	21,6
Humanistyczne i społeczne	211	20,9
Sztuka i kultura	6	16,7
Środowisko i przyroda	9	11,1
Bez wskazania kierunku	4	0,0

Źródło: badania własne (kolumna „Tak %” przedstawia odsetek respondentów deklarujących korzystanie z aplikacji Gemini w obrębie każdej kategorii kierunku studiów, dlatego wartości procentowe nie sumują się do 100).



Wykres 3.1.7. Użycie aplikacji Gemini ze względu na obszar kierunku studiów, N = 457


Źródło: badania własne.

Analiza. W przypadku aplikacji Gemini widoczne jest wyraźniejsze zróżnicowanie między obszarami kierunków studiów (tabela 3.1.7 i wykres 3.1.7). Najwyższy odsetek użytkowników odnotowano w grupie ekonomia, zarządzanie i prawo (60,0%) oraz w grupie STEM i kierunki inżynieryjne (52,6%). W grupie zdrowie i medyczne odsetek ten wyniósł 50,0%, jednak wynik ten należy interpretować bardzo ostrożnie ze względu na bardzo małą liczebność tej kategorii. Znacznie niższe wartości pojawiły się w grupach inne (21,6%), humanistyczne i społeczne (20,9%), sztuka i kultura (16,7%) oraz środowisko i przyroda (11,1%). Test chi kwadrat wykazał statystycznie istotną zależność między użyciem aplikacji Gemini a obszarem kierunku studiów, $p < 0,001$, przy wartości współczynnika Craméra $V = 0,292$. Wynik ten można interpretować jako zależność o umiarkowanej sile, co wskazuje, że preferencje dotyczące tego narzędzia pozostają wyraźniej powiązane z profilem kształcenia.

Tabela 3.1.8. Użycie aplikacji Copilot ze względu na obszar kierunku studiów

Kierunek studiów (nazwa kierunku)	N	Tak %
Zdrowie i medyczne	2	50,0
STEM i inżynieryjne	57	24,6
Sztuka i kultura	6	16,7
Humanistyczne i społeczne	211	3,8
Inne	148	2,7
Ekonomia, zarządzanie i prawo	20	0,0
Środowisko i przyroda	9	0,0
Brak odpowiedzi	4	0,0

Źródło: badania własne.



Wykres 3.1.8. Użycie aplikacji Copilot ze względu na obszar kierunku studiów, N = 457

Źródło: badania własne (kategoria „Brak odpowiedzi” odnosi się do respondentów, którzy nie podali informacji o kierunku studiów, dlatego nie mogli zostać przypisani do żadnego z wyodrębnionych obszarów kształcenia).

Analiza. Najwyższe odsetki użycia aplikacji Copilot odnotowano w grupie STEM i kierunki inżynieryjne (24,6%) oraz w grupie sztuka i kultura (16,7%) (tabela 3.1.8 i wykres 3.1.8). W grupie zdrowie i medyczne odsetek wyniósł 50,0%, jednak podobnie jak wcześniej wynik ten wymaga bardzo ostrożnej interpretacji ze względu na liczebność $N = 2$. W grupie humanistycznej i społecznej użycie Copilot zadeklarowało 3,8% badanych, a w grupie inne – 2,7%. W obszarach ekonomia, zarządzanie i prawo oraz środowisko i przyroda nie odnotowano wskazań tego narzędzia. Test chi kwadrat wykazał statystycznie istotną zależność między użyciem aplikacji Copilot a obszarem kierunku studiów, $p < 0,001$, przy wartości współczynnika Craméra $V = 0,326$. Wynik ten wskazuje na zależność o umiarkowanej sile i sugeruje, że użycie Copilot jest silniej związane z określonym profilem kształcenia niż użycie ChatGPT.

Interpretacja i weryfikacja. Uzyskane wyniki wskazują, że preferencje narzędziowe studentów nie są całkowicie jednorodne i w części przypadków wskazują związek z profilem kierunku studiów. ChatGPT pozostaje narzędziem szeroko rozpowszechnionym we wszystkich obszarach kształcenia, co potwierdza jego pozycję jako podstawowego rozwiązania wspierającego codzienne praktyki studiowania. Z kolei użycie Gemini i Copilot wyraźniej różnicuje się między obszarami kierunków, co można łączyć z odmiennymi wymaganiami zadaniowymi, kulturą pracy akademickiej oraz specyfiką kompetencji rozwijanych w poszczególnych dyscyplinach.

Takie rozpoznanie pozostaje zgodne z ustaleniami badań międzynarodowych, które wskazują, że użycie narzędzi opartych na generatywnej AI oraz postawy wobec nich zmieniają się w zależności od pola studiów i poziomu kształcenia (Stöhr i in., 2024). W perspektywie praktycznej oznacza to, że polityka uczelni oraz działania wspierające odpowiedzialne wykorzystanie AI powin-

ny uwzględniać profil dyscypliny i zróżnicowanie potrzeb studentów, zamiast opierać się na założeniu jednorodnego modelu adopcji technologii.

Podsumowując, wskaźnik instrumentalny ujawnia dominację narzędzi konwersacyjnych oraz przewagę korzystania z wersji bezpłatnych, a analizy uzupełniające pokazują, że część preferencji narzędziowych wykazuje zróżnicowanie kontekstowe. Ustalenia te stanowią ważną podstawę interpretacyjną dla kolejnego rozdziału, poświęconego celom i typom zadań realizowanych z wykorzystaniem narzędzi generatywnej AI.

Bibliografia

- Dungo, C.A.B., Beltran, Z.L.E., Declaro, B.C., Dela Cruz, J.J.C., Viray, R.U. (2025). Students' level of awareness on the environmental implications of generative AI. *Journal of Education in Science, Environment and Health*, 11(2), 93–107. <https://doi.org/10.55549/jesch.777>
- Jin, Y., Yan, L., Echeverria, V., Gašević, D., Martinez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>
- Katseli, A., Drigas, A. (2026). Humanities and social sciences students' views on the use of AI tools for academic purposes: Practices, benefits, challenges, and suggestions. *Advances in Mobile Learning Educational Research*, 6(1), 1699–1709. <https://doi.org/10.25082/>
- Møgelvang, A., Bjelland, C., Grassini, S., Ludvigsen, K. (2024). Gender differences in the use of generative artificial intelligence chatbots in higher education: Characteristics and consequences. *Education Sciences*, 14(12), 1363. <https://www.mdpi.com/2227-7102/14/12/1363>
- Miah, A.S.M., Tusher, M.R., Hossain, M., Hamid, E., Islam, S., Shin, J. (2025). ChatGPT in research and education: A SWOT analysis of its academic impact. *Computer Modeling in Engineering & Sciences*, 143(3), 2573–2614. <https://doi.org/10.32604/cmes.2025.064168>
- Ramalia, T. (2023). Digital Storytelling in Higher Education: Highlighting the Making Process. *Journal on Education*, 6, 7307–7319, E-ISSN: 2654-5497, P-ISSN: 2655-1365. <https://doi.org/10.31004/joe.v6i1.3993>
- Raszyd, K.I., Wesołowska, A., Tomaszewska, K. (2024), Sztuczna Inteligencja w nauce – jak studenci wykorzystują AI w edukacji wyższej. *Academy of Management*, 8, 373–400. <https://doi.org/10.24427/az-2024-0053>
- Stöhr, C., Ou, A.W., Malmström, H. (2024). Perceptions and usage of AI chatbots among students in higher education across genders, academic levels and fields of study. *Computers and Education: Artificial Intelligence*, 7, 100259. <https://doi.org/10.1016/j.caeai.2024.100259>
- Strzelecki, A. (2024). Students' Acceptance of ChatGPT in Higher Education: An Extended Unified Theory of Acceptance and Use of Technology. *Innovative Higher Education*, 49, 223–245. <https://doi.org/10.1007/s10755-023-09686-1>

2. OBSZARY DYDAKTYCZNE I ZADANIOWE UŻYCIA NARZĘDZI AI, WSKAŹNIK FUNKCJONALNY

JAROSŁAW JANIO, EDYTA KOWALCZYK-ŁUC

Wskaźnik funkcjonalny służy rekonstrukcji obszarów zastosowań generatywnej AI w praktykach studiowania, a więc tego, do jakich celów i zadań studenci wykorzystują narzędzia sztucznej inteligencji w kontekście akademickim. W logice drugiego problemu badawczego celem analizy jest uchwycenie tych sfer dydaktycznych, w których wsparcie oferowane przez narzędzia AI okazuje się najsilniejsze, oraz identyfikacja dominujących typów zadań i mechanizmów pomocy w uczeniu się. Odpowiedzi udzielone w polach otwartych poddano kodowaniu semantycznemu w układzie wieloetykietowym, ponieważ pojedyncza wypowiedź mogła odnosić się równocześnie do kilku funkcji narzędzi AI.

2.1. Cele użycia narzędzi AI

Pierwszym krokiem analizy było rozpoznanie celów, dla których studenci sięgają po narzędzia AI w toku studiów. Odpowiedź na nie przedstawiono w tabeli 3.2.1 oraz na wykresie 3.2.1.


Tabela 3.2.1. Cele użycia narzędzi AI, kodowanie semantyczne odpowiedzi otwartych, N = 457

Kategoria	N (respondenci mogli udzielić więcej niż 1 odpowiedzi)	%
Nauka, zaliczenia, powtórki	151	33,0
Wyszukiwanie informacji i źródeł	106	23,2
Pisanie i redakcja	61	13,3
Streszczenia i notatki	31	6,8
Prezentacje	26	5,7
Rozwiązywanie zadań i obliczenia	22	4,8
Organizacja pracy	20	4,4
Rozrywka	20	4,4
Wyjaśnianie i rozumienie	18	3,9
Kreatywność i obrazy	18	3,9
Pomoc techniczna i IT	17	3,7
Tłumaczenia	1	0,2

Źródło: badanie własne.

Analiza. Na pytanie otwarte odpowiedziały 453 osoby, co stanowi 99,1% badanej próby. Co najmniej jedną kategorię semantyczną przypisano 332 wypowiedziom, czyli 72,6% całego zbioru (wykres 3.2.1). Najczęściej wskazywanymi celami użycia narzędzi AI były: nauka, zaliczenia, powtórki (51 osób; 33,0%), wyszukiwanie informacji i źródeł (106 osób; 23,2%), pisanie i redak-

cja (61 osób; 13,3%), streszczenia i notatki (31 osób; 6,8%) oraz prezentacje (26 osób; 5,7%). Rozkład odpowiedzi wskazuje na dominację zastosowań związanych z przygotowaniem do zaliczeń, pracą z tekstem oraz pracą z informacją i źródłami.



Wykres 3.2.1. Cele użycia narzędzi AI, rozkład liczebności odpowiedzi według poszczególnych kategorii, N = 457

Źródło: badanie własne.

Uzyskany obraz pokazuje, że zasadniczym celem użycia AI przez studentów pozostaje wsparcie procesu uczenia się obejmujące przygotowanie do egzaminów, utrwalanie materiału oraz porządkowanie treści. Wynik ten wpisuje się w obecny w literaturze sposób ujmowania generatywnej AI jako narzędzia wspierającego procesy poznawcze, szczególnie w obszarze organizacji wiedzy, redukcji złożoności materiału i wspomagania bieżących zadań edukacyjnych (Kasneci i in., 2023).

Interpretacja i weryfikacja. Uzyskane wyniki pozostają zgodne z badaniami prowadzonymi w szkolnictwie wyższym. W globalnym badaniu Ravšelj i in. (2025) obejmującym ponad 23 tysiące studentów do najczęstszych zastosowań generatywnej AI należały: burza mózgów, streszczanie i podsumowywanie oraz wyszukiwanie artykułów naukowych, a więc funkcje bliskie kategoriom wyłonionym w niniejszym materiale empirycznym. Również przeglądy badań nad zastosowaniem dużych modeli językowych wskazują, że przewaga celów tekstowych i informacyjnych jest charakterystyczna dla wczesnych faz adaptacji narzędzi AI w edukacji wyższej, a zarazem otwiera pytania o granice samodzielności, sprawiedliwość oceniania oraz ryzyko nadmiernej zależności od technologii (Shi, Yu, Dong, Chen, 2025).

W ujęciu ogólnym cele deklarowane przez respondentów można interpretować jako przejaw pragmatycznego, zadaniowego i edukacyjnie ukierunkowanego wykorzystania generatywnej AI. Narzędzia te pełnią przede wszystkim funk-

cję wsparcia poznawczego i organizacyjnego, obejmującą przyspieszanie pracy, porządkowanie materiału, syntezę informacji oraz pomoc w redagowaniu treści. Z perspektywy funkcjonalnej generatywna AI jawi się więc przede wszystkim jako asystent procesu studiowania wspomagający realizację zadań akademickich zgodnie z bieżącymi potrzebami studentów.

Zróżnicowanie celów użycia AI. Analiza wypowiedzi otwartych wskazuje też na zróżnicowanie celów użycia AI w zależności od profilu kształcenia. W przypadku studentów pedagogiki, zwłaszcza pedagogiki przedszkolnej i wczesnoszkolnej, częściej pojawiały się zastosowania związane z generowaniem pomysłów metodycznych, tworzeniem scenariuszy zajęć, projektowaniem materiałów dydaktycznych oraz upraszczaniem bardziej złożonych treści teoretycznych na potrzeby praktyki edukacyjnej. Tego rodzaju użycie można interpretować jako formę organizacji materiału dydaktycznego oraz wspierania pracy poznawczej i metodycznej (Zawacki-Richter, Marín, Bond, Gouverneur, 2019).

U studentów kierunków technicznych i ścisłych częściej pojawiały się odniesienia do wsparcia procesów algorytmicznych, debugowania kodu, wyjaśniania logiki programistycznej, rozwiązywania złożonych zadań matematycznych oraz pracy z bazami danych. W obszarze kierunków humanistycznych i filologicznych wypowiedzi koncentrowały się częściej wokół zastosowań lingwistycznych i redakcyjnych, takich jak tłumaczenie tekstów, korekta stylistyczna, wyszukiwanie synonimów oraz przygotowywanie streszczeń. Z kolei w wypowiedziach studentów kierunków medycznych i przyrodniczych pojawiała się potrzeba wyjaśniania terminologii specjalistycznej oraz porządkowania rozproszonej wiedzy z literatury fachowej.

W analizie jakościowej można także dostrzec pewne różnice związane z płcią i wiekiem, choć ich interpretacja wymaga ostrożności. Zarówno kobiety, jak i mężczyźni wykorzystywali narzędzia AI przede wszystkim do wyszukiwania informacji i wspierania nauki. W wypowiedziach kobiet częściej pojawiały się zastosowania organizacyjne, redakcyjne i estetyczno-dydaktyczne, natomiast w wypowiedziach mężczyzn relatywnie częściej wybrzmiewały zastosowania techniczne i zadaniowe.

W odniesieniu do wieku można zauważyć, że młodsi respondenci, mieszcący się w przedziale wczesnej dorosłości, częściej opisywali użycie AI w kontekście bieżącej obsługi procesu dydaktycznego, np. przygotowania do kolokwium, generowania quizów i fiszek czy szybkiego wyszukiwania informacji. Starsi studenci i uczestnicy szkół doktorskich częściej wiąжали AI z redakcją tekstów naukowych, analizą danych oraz zadaniami o bardziej profesjonalnym charakterze. W tej części warto zachować zgodność z wcześniej przyjętym zakresem wieku respondentów, czyli 18–45 lat.

Podsumowując, cele wykorzystania narzędzi AI przez studentów wykazują wyraźny pragmatyzm edukacyjny. Generatywna AI jest włączana do praktyk studiowania przede wszystkim w celu wspierania uczenia się, redukcji trudności

poznawczych, przyspieszania pracy oraz porządkowania i przetwarzania informacji. Materiał empiryczny wskazuje również, że charakter zadań powierzanych narzędziom AI pozostaje powiązany ze specyfiką kształcenia, co świadczy o postępującej adaptacji tych technologii do zróżnicowanych wymagań akademickich.


2.2. Mechanizmy wsparcia uczenia się

Drugi etap analizy dotyczy sposobów, w jakie narzędzia AI wspierają uczenie się studentów, a więc mechanizmów pomocy deklarowanych w odpowiedziach otwartych. Analiza ta pozwala uchwycić, czy generatywna AI jest wykorzystywana przede wszystkim do porządkowania materiału, przyspieszania pracy, wyjaśniania treści, wzmacniania samokontroli uczenia się, czy też do redukcji napięcia towarzyszącego studiowaniu. Wyniki przedstawiono w tabeli 3.2.2 oraz na wykresie 3.2.2.

Tabela 3.2.2. Mechanizmy wsparcia uczenia się przez narzędzia AI, kodowanie semantyczne, N = 457

Kategoria	N	%
Streszczenia i porządkowanie materiału	140	30,6
Wyjaśnianie i doprecyzowanie treści	105	22,9
Ćwiczenia, pytania i testowanie wiedzy	68	14,8
Oszczędność czasu i usprawnienie pracy	59	12,9
Inne: wątpliwości i ambiwalencja	44	9,6
Wyszukiwanie i wskazywanie źródeł	17	3,7
Wsparcie pisania i języka	14	3,0
Brak odpowiedzi	7	1,5
Wsparcie emocjonalne i redukcja stresu	3	0,6

Źródło: badanie własne.



Wykres 3.2.2. Mechanizmy wsparcia uczenia się przez narzędzia AI, rozkład liczebności kategorii, N = 457

Źródło: badanie własne.

Analiza. Na pytanie otwarte odpowiedziało 451 osób, co stanowi 98,7% badanej próby. Co najmniej jedną kategorię semantyczną przypisano 289 wypowiedziom, czyli 63,2% całej próby. Najczęściej wskazywanymi mechanizmami wsparcia były: streszczenia i porządkowanie materiału (140 osoby; 30,6%), wyjaśnianie i doprecyzowanie treści (105 osób; 22,9%), ćwiczenia, pytania i testowanie wiedzy (68 osób; 14,8%), oszczędność czasu i usprawnienie pracy (59 osób; 12,9%) oraz wyszukiwanie i wskazywanie źródeł (17 osób; 3,7%). Rzadziej pojawiały się takie formy wsparcia, jak Pomoc w pisaniu (14 osób; 3,0%) oraz wsparcie emocjonalne i redukcja stresu (3 osoby; 0,6%).

Rozkład odpowiedzi wskazuje, że w badanej grupie dominują dwa typy wsparcia. Pierwszy ma charakter poznawczy i obejmuje streszczenie, porządkowanie materiału, wyjaśnianie treści oraz wspomaganie samosprawdzania wiedzy. Drugi ma charakter organizacyjny i wiąże się z oszczędnością czasu oraz usprawnieniem pracy. Oznacza to, że studenci korzystają z narzędzi AI przede wszystkim po to, aby zmniejszyć złożoność materiału, szybciej dotrzeć do jego struktury oraz sprawniej przygotować się do wymagań akademickich.

Interpretacja i weryfikacja. Wyniki są spójne z przeglądami badań, które wskazują, że aplikacja ChatGPT i pokrewne narzędzia zwiększają dostęp do wiedzy i oferują wsparcie poznawcze oraz emocjonalne, przy jednoczesnym ryzyku obniżenia niezależnego uczenia się w przypadku nadużyć. Systematyczny przegląd zastosowań narzędzi AI wykonany przez Abdallah i in. (2025) pokazuje, że obok korzyści w postaci dostępności i wsparcia poznawczego pojawia się możliwość technostresu⁵ oraz osłabienia samoregulacji uczenia się. Z perspektywy dydaktycznej oznacza to potrzebę projektowania zadań, w których wymagane są uzasadnienia, porównania źródeł i refleksja nad procesem, ponieważ te elementy ograniczają substytucję pracy poznawczej.

Analiza zgromadzonego materiału empirycznego w zakresie pytania „W jaki sposób narzędzia AI pomagają Ci w uczeniu się na studiach?” pozwala na sformułowanie wieloaspektowej typologii mechanizmów wsparcia, które studenci implementują w swoim procesie dydaktycznym. W dyskursie akademickim zjawisko to można określić jako instrumentalizację AI w celu optymalizacji kapitału poznawczego oraz redukcji obciążeń operacyjnych.

Generatywna AI wspiera proces uczenia się poprzez kilka kluczowych mechanizmów deklarowanych przez studentów.

Pierwszy z nich można określić jako mechanizm redukcji złożoności poznawczej. Najczęściej deklarowanym sposobem wsparcia była translacja skomplikowa-

⁵ Technostres to negatywne obciążenie psychiczne i poznawcze wynikające z korzystania z technologii, przejawiające się m.in. przeciążeniem informacyjnym (zbyt wiele treści generowanych przez AI, trudność w ich selekcji), presją użycia narzędzi (poczucie, że „trzeba” używać AI, żeby nadążyć za innymi) oraz spadkiem poczucia kontroli nad procesem uczenia się (poleganie na AI zamiast samodzielnego myślenia może powodować frustrację lub niepewność).

nego dyskursu naukowego na język naturalny i przystępny. To odpowiada modelowi generatywnej AI jako „inteligentnego tutora” (Zawacki-Richter i in., 2019). Narzędzia AI pełnią rolę pośrednika w procesie egzegezy tekstów poprzez:

a) upraszczanie terminologii: studenci wskazują na pomoc w zrozumieniu „trudnych i złożonych zagadnień” oraz „zawiłych definicji”;

b) wyjaśnianie „łopatologiczne”: narzędzia AI tłumaczą nowe tematy w sposób uproszczony, co jest kluczowe przy napotykananiu barier w literaturze przedmiotu;

c) wsparcie neuroróżnorodności: respondenci z diagnozą Aspergera podkreślają, że narzędzia AI umożliwiają im głębszą interpretację pojęć, których standardowy przekaz akademicki nie wyjaśnia w sposób dla nich zrozumiały.

Drugi mechanizm dotyczy kondensacji i syntezy danych (ekonomia informacyjna). W obliczu przeładowania informacyjnego⁶ (*information overload*) narzędzia AI stają się instrumentem do zarządzania gęstością materiału dydaktycznego poprzez:

a) streszczanie i skracanie: narzędzia AI są wykorzystywane do generowania abstraktów z długich artykułów, książek oraz notatek, co pozwala na błyskawiczną identyfikację kluczowych tez;

b) selekcję istotnych treści: algorytmy pomagają w „wyciąganiu najważniejszych informacji” i uporządkowaniu chaosu w notatkach własnych;

c) nawigację bibliograficzną: studenci deklarują, że narzędzia AI wskazują konkretne rozdziały w „grubych książkach”, gdzie znajdują się poszukiwane informacje, co znacząco skraca fazę researchu.

Trzeci mechanizm można opisać jako wsparcie procesów metapoznawczych i samokontroli uczenia się. Zgodnie z literaturą narzędzia generatywnej AI mogą wzmacniać strategie samoregulacji uczenia się – o ile jest używana refleksyjnie (Xia, Liu, Tlili, Chiu, 2026). Wsparcie przez narzędzia AI wykracza poza bierną analizę tekstu, obejmując aktywną weryfikację takich kompetencji, jak:

a) generowanie narzędzi ewaluacyjnych: studenci wykorzystują narzędzia AI do tworzenia quizów, testów wyboru (ABCD) oraz fiszek na podstawie dostarczonych materiałów;

b) symulacja egzaminacyjna: narzędzia AI służą do przeprowadzania „testów wiedzy” i odpytywania z zagadnień, co przekształca naukę z biernej w aktywną;

c) weryfikacja błędów: w naukach ścisłych i technicznych narzędzia AI analizują kody programistyczne lub obliczenia matematyczne, wskazując błędy w logicznym rozumowaniu studenta.

⁶ Przeładowanie informacyjne (*information overload*) – psychiczny stan charakteryzujący jednostkę, która przeżywa stres – negatywne odczucia spowodowane faktem, że rozwiązywanie problemów zawodowych lub osobistych jest istotnie utrudnione z powodu nadmiaru dostępnych informacji.

Czwarty mechanizm dotyczy wsparcia strukturalno-redakcyjnego (*scaffolding*⁷). Generatywna AI pełni funkcję „szkieletu poznawczego”, pomagając w organizacji procesów twórczych:

a) strukturyzacja prac pisemnych: pomaga w budowaniu konspektów, planów prezentacji oraz „szkieletów prac”, na których student następnie nadbudowuje treść merytoryczną;

b) korekta stylistyczno-językowa: narzędzia te są implementowane do poprawy gramatyki, stylistyki oraz szukania synonimów, co nadaje pracom bardziej profesjonalny, akademicki charakter;

c) przełamywanie barier twórczych: w sytuacjach braku „weny” AI podsuwa inspiracje, pomysły na zabawy (pedagogika) lub wstępne sformułowania myśli.

Piąty mechanizm odnosi się do optymalizacji operacyjnej (automatyzacji researchu). Studenci traktują narzędzia AI jako wysoce wydajną wyszukiwarkę i asystenta technicznego:

a) szybkość dostępu do danych: zamiast wielogodzinnego przeglądania baz danych studenci otrzymują „skondensowane informacje na tacy”;

b) tłumaczenia symultaniczne: narzędzia AI wspierają procesy uczenia się poprzez precyzyjne tłumaczenia literatury obcojęzycznej, która bez tego wsparcia pozostawałaby niedostępna poznawczo.

Wątpliwości i ambiwalencja. W materiale pojawiały się też odpowiedzi wyrażające dystans wobec narzędzi AI. To właśnie tutaj warto pozostawić dosłowne głosy studentów, które nadają analizie jakościowej wyrazistość, np. „Nie pomagają”, „Bardziej przeszkadzają”, „Straciłam motywację”, „Staram się nie korzystać” czy „Zwątpiłam w krytyczne myślenie”. Wypowiedzi te ujawniają, że wsparcie oferowane przez generatywną AI ma charakter ambiwalentny. Obok korzyści poznawczych i organizacyjnych obecne jest również ryzyko powierzchownego uczenia się, osłabienia samodzielnego przetwarzania treści oraz przenoszenia części wysiłku poznawczego na narzędzie. Tego rodzaju napięcia są mocno obecne w literaturze poświęconej przemianom uczenia się i integralności akademickiej w epoce powszechnego stosowania narzędzi ChatGPT (Cotton, Cotton, Shipway, 2023).

Kategoria „brak odpowiedzi” odnosi się do respondentów, którzy nie podali informacji o mechanizmach wsparcia, dlatego nie mogli zostać przypisani do żadnego z wyodrębnionych mechanizmów.

⁷ Technologiczne rusztowanie (*scaffolding*) oznacza sposób wykorzystania narzędzi AI jako wsparcia poznawczego, które pomaga studentowi wykonywać zadania, ale go nie zastępuje. Narzędzia AI pełnią rolę spersonalizowanego korepetytora, który tłumaczy trudne pojęcia, generuje pytania testowe, dostosowuje poziom wyjaśnień do użytkownika. To pokazuje, że AI działa jak „rusztowanie” wokół procesu uczenia się – tak jak w budownictwie rusztowanie nie jest celem samym w sobie, tylko wspiera konstrukcję bez zastępowania własnego myślenia (tu: proces uczenia się), może być stopniowo „zdejmowane”, gdy kompetencje rosną. Zatem narzędzia AI przejmują część funkcji, które wcześniej pełnił nauczyciel: tłumacza, naprowadzają, strukturyzują wiedzę, dostosowują poziom trudności.

Podsumowując, mechanizmy wsparcia uczenia się deklarowane przez studentów koncentrują się wokół porządkowania materiału, oszczędności czasu, samosprawdzania wiedzy oraz wyjaśniania trudnych treści. Generatywna AI jest zatem wykorzystywana przede wszystkim jako narzędzie wspierające organizację pracy i procesy poznawcze, a w mniejszym stopniu jako źródło wsparcia emocjonalnego. Zgromadzony materiał pokazuje zarazem, że rola studenta ulega stopniowej zmianie. Coraz częściej staje się on selekcjonerem, interpretatorem i weryfikatorem treści wygenerowanych przez narzędzia AI, a mniej wykonawcą działań odtwórczych. Jednocześnie w wypowiedziach respondentów obecna jest świadomość, że AI pełni funkcję pomocy wstępnej i punktu wyjścia wymagającego dalszej kontroli poznawczej i merytorycznej.


2.3. Typy zadań akademickich realizowanych z wykorzystaniem narzędzi AI

W dalszej kolejności analizie poddano konkretne typy zadań akademickich, w których studenci najczęściej wykorzystują narzędzia AI. Pozwala to uchwycić, do jakich działań dydaktycznych generatywna AI jest włączana najczęściej oraz które obszary pracy akademickiej pozostają szczególnie podatne na wsparcie algorytmiczne. Odpowiedź na to pytanie przedstawiono w tabeli 3.2.3 oraz na wykresie 3.2.3.

Tabela 3.2.3. Typy zadań realizowanych z wykorzystaniem narzędzi AI, kodowanie semantyczne, N = 457

Kategoria	N (respondenci mogli udzielić więcej niż 1 odpowiedzi)	%
Nauka do egzaminów i zaliczeń	218	47,7
Prezentacje	160	35,0
Pisanie prac i tekstów	83	18,2
Notatki i streszczenia	29	6,3
Wyszukiwanie literatury	16	3,5
Programowanie	10	2,2
Analiza danych i statystyka	4	0,9

Źródło: badanie własne.



Wykres 3.2.3. Typy zadań realizowanych z wykorzystaniem narzędzi AI, rozkład liczebności kategorii, N = 457

Źródło: badanie własne (respondenci mogli wskazać więcej niż jeden typ zadania, dlatego odsetki nie sumują się do 100).

Analiza. Na pytanie odpowiedziało 446 osób, co stanowi 97,6% badanej próby. Co najmniej jedną kategorię semantyczną przypisano 363 wypowiedziom, czyli 79,4% całej próby. Najczęściej kodowanymi typami zadań były: nauka do egzaminów i zaliczeń (218 osób; 47,7%), prezentacje (160 osób; 35,0%), pisanie prac i tekstów (83 osoby; 18,2%), notatki i streszczenia (29 osób; 6,3%) oraz wyszukiwanie literatury (16 osób; 3,5%). Rzadziej pojawiały się takie zadania, jak programowanie (10 osób; 2,2%) oraz analiza danych i statystyka (4 osoby; 0,9%). Rozkład odpowiedzi wskazuje, że narzędzia AI są najczęściej włączane do zadań o istotnym znaczeniu dydaktycznym, zwłaszcza do przygotowania do egzaminów i zaliczeń, opracowywania prezentacji oraz pisania prac i innych tekstów. Oznacza to, że zastosowanie AI koncentruje się przede wszystkim wokół działań związanych z przyswajaniem treści, ich porządkowaniem, prezentowaniem oraz przetwarzaniem w formę wypowiedzi akademickiej. Obecność kategorii notatek, streszczeń i wyszukiwania literatury dodatkowo wzmacnia obraz intensywnej pracy z tekstem, informacją i kondensacją treści.

Interpretacja i weryfikacja. Koncentracja użycia AI na zadaniach ocenianych jest powtarzalnym wynikiem w badaniach edukacji wyższej i stanowi punkt ciężkości debat o integralności akademickiej i projektowaniu ocen. W przeglądzie empirycznych zastosowań dużych modeli językowych Shi, Yu, Dong i Chen (2025) jako kluczowe wyzwania wskazano ryzyko nadmiernej zależności, sprawiedliwość oceniania oraz prywatność, co koresponduje z obserwacją, że narzędzia AI są używane w zadaniach mających wpływ na ocenę końcową. W kontekście niniejszych danych interpretacja prowadzi do postulatu przesunięcia akcentu z kontroli produktu na ocenę procesu, argumentacji i pracy ze źródłami, a także na budowanie jawności użycia narzędzi.

Podsumowując, wskaźnik funkcjonalny pokazuje, że narzędzia AI są używane głównie do pracy z treścią, przygotowania do zaliczeń oraz realizacji zadań tekstowych i prezentacyjnych, przy równoczesnym doświadczeniu wsparcia wyjaśniającego i organizacyjnego. Ustalenia te prowadzą do rozdziału 3.3, w którym analizowana jest krytyczna weryfikacja treści generowanych przez AI, ponieważ w obszarach wysokiej stawki dydaktycznej ryzyko błędów i halucynacji ma szczególne znaczenie.

Analiza zgromadzonego materiału badawczego pozwala na precyzyjną identyfikację obszarów instrumentalizacji AI w procesie akademickim. Respondenci wskazują na szerokie spektrum zadań, które można sklasyfikować w cztery główne domeny funkcjonalne: produkcję tekstową, wsparcie wizualno-prezentacyjne, optymalizację przygotowań egzaminacyjnych oraz zadania specjalistyczne (kierunkowe).

Typologia zadań akademickich realizowanych przy wsparciu narzędzi AI:

1. „Produkcja” i redakcja tekstów akademickich

Dominującym obszarem wykorzystania narzędzi generatywnych jest szeroko pojęte pisanie akademickie. Studenci delegują do generatywnej AI zadania o różnym stopniu złożoności – od prostych komunikatów po strukturyzację prac dyplomowych:

- a) tworzenie tekstów ciągłych: narzędzia AI są wykorzystywane do pisania esejów, referatów, sprawozdań oraz prac zaliczeniowych;
- b) wsparcie prac dyplomowych: respondenci wskazują na użycie narzędzi AI w procesie pisania pracy licencjackiej lub magisterskiej, szczególnie w zakresie budowania struktury (szkieletu) pracy oraz formułowania bibliografii;
- c) korekta i redakcja: ważnym zadaniem jest poprawa stylistyczna, gramatyczna oraz redagowanie własnych tekstów w celu nadania im bardziej profesjonalnego brzmienia.

2. Projektowanie materiałów dydaktycznych i wizualnych

Kolejnym kluczowym obszarem jest wsparcie procesów prezentacyjnych, gdzie narzędzia AI pełnią rolę asystenta kreatywnego:

- a) przygotowanie prezentacji multimedialnych: jest to jedno z najczęściej wymienianych zadań – studenci używają narzędzi AI do generowania treści slajdów, planowania agendy wystąpienia oraz dobierania oprawy graficznej;
- b) generowanie zasobów wizualnych: szczególnie na kierunkach pedagogicznych i artystycznych narzędzia AI służą do tworzenia ilustracji, grafik oraz obrazków niezbędnych do projektów edukacyjnych.

3. Optymalizacja przygotowań do egzaminów i kolokwii

W sferze samokształcenia i ewaluacji wiedzy narzędzia AI są implementowane jako instrumenty wspierające procesy zapamiętywania i rozumienia:

- a) synteza materiałów: skracanie tekstów, streszczanie lektur oraz opracowywanie notatek z wykładów w celu szybszej nauki;
- b) aktywne testowanie: generowanie quizów, pytań testowych (ABCD) oraz fiszek na podstawie dostarczonych materiałów, co pozwala na symulację warunków egzaminacyjnych;
- c) eksplikacja zagadnień: wyjaśnianie trudnych pojęć, definicji oraz procesów matematycznych, które sprawiają studentom trudność.

4. Zadania specjalistyczne i kierunkowe

Analiza wykazuje też specyficzne typy zadań, determinowane profilem kształcenia (Fosner, 2024):

- a) nauki techniczne i ścisłe: rozwiązywanie zadań matematycznych, pisanie i debugowanie kodów programistycznych oraz tworzenie algorytmów;
- b) pedagogika: projektowanie scenariuszy zajęć, konspektów lekcji oraz wymyślanie kreatywnych zabaw dla dzieci;
- c) filologie i lingwistyka: tłumaczenie literatury przedmiotu z języków obcych oraz analiza struktur gramatycznych.

Podsumowując, współczesny student traktuje narzędzia AI nie jako substytut wysiłku intelektualnego (choć głosy krytyczne o „lenistwie” również się pojawiają), lecz jako technologiczne rusztowanie (*scaffolding*) pozwalające na efektywniejsze zarządzanie zasobami czasu i uwagi.

1. Redefinicja zadań: narzędzia AI przejmują zadania o charakterze mechanicznym, odtwórczym i żmudnym (np. formatowanie, streszczanie), pozwalając studentom na teoretyczną koncentrację na aspektach analitycznych i koncepcyjnych.

2. Personalizacja procesu nauki: dzięki możliwości generowania indywidualnych testów i wyjaśnień „krok po kroku” narzędzia AI stają się formą całodobowego, spersonalizowanego korepetytora.

3. Wielofunkcyjność: zadania realizowane z wykorzystaniem narzędzi AI przenikają się – proces pisania pracy jest nierozzerwalnie związany z researchem źródłowym i redakcją językową, co czyni z AI narzędzie o charakterze holistycznym w ekosystemie akademickim.

2.4. Wzorce częstotliwości korzystania z narzędzi AI

Analiza zgromadzonego materiału empirycznego, ze szczególnym uwzględnieniem odpowiedzi na pytanie: „Do jakich rodzajów zadań na studiach najczęściej używasz AI?” oraz kontekstu całego badania, pozwala na rekonstrukcję wzorców częstotliwości wykorzystania narzędzi AI przez studentów. Częstotliwość ta nie jest wartością stałą, lecz wykazuje charakter nieliniowy i nieciągły (przerywany), ściśle skorelowany z dynamiką roku akademickiego oraz subiektywną oceną trudności zadań poznawczych.

Poniżej przedstawia się naukową analizę częstotliwości użytkowania narzędzi AI w podziale na zidentyfikowane typologie.

1. Model rutynowy i systematyczny (wysoka częstotliwość)

Część respondentów deklaruje integrację AI z codziennymi procesami uczenia się, co sugeruje wysoką, niemal codzienną częstotliwość użytkowania:

a) codzienna asystencja: niektórzy studenci wskazują na wykorzystanie narzędzi AI „do codziennego życia” oraz bieżącej nauki;

b) bieżąca obsługa dydaktyczna: narzędzia te są implementowane „na bieżąco”, w celu streszczania tekstów zadawanych z zajęć na zajęcia, co wymusza regularność interakcji z algorytmem;

c) zadania o charakterze ciągłym: w przypadku studentów kierunków technicznych, takich jak informatyka, narzędzia AI służą do bieżącej weryfikacji kodu i rozwiązywania problemów matematycznych, co implikuje częste sięganie po te nie w toku studiowania.

2. Model periodyczny i akcydentalny (częstotliwość średnia/zmienna)

Najliczniejsza grupa studentów wykazuje zmienną częstotliwość użytkowania, determinowaną przez „ekonomię czasu” oraz spiętrzenie obowiązków akademickich:

a) intensyfikacja w okresie sesji: studenci deklarują, że częstotliwość wzrasta wykładniczo w czasie przygotowań do egzaminów i kolokwium – narzędzia AI są wtedy używane do generowania materiałów powtórkowych (fiszki, quizy) pod presją czasu;

b) użytkowanie zadaniowe: narzędzia AI są uruchamiane selektywnie w odpowiedzi na konkretne, czasochłonne zadania, takie jak przygotowanie prezentacji czy pisanie prac, co sprawia, że częstotliwość jest rzadsza w okresach bez prac zaliczeniowych.

3. Model sporadyczny i kryzysowy (niska częstotliwość)

W tej grupie narzędzia AI są traktowane jako instrumenty *ultima ratio*, wykorzystywane jedynie w sytuacjach przekroczenia indywidualnych barier poznawczych:

a) interwencja kryzysowa: niektórzy respondenci używają narzędzi AI rzadko lub tylko w kryzysowych sytuacjach, gdy tradycyjne źródła informacji okazują się niewystarczające;

b) niskie nasycenie procesów: padają sformułowania o używaniu narzędzi AI „raz na ruski rok” lub rzadko, np. wyłącznie do wyszukiwania niszowych artykułów;

c) ograniczony zakres zaufania: studenci, którzy podchodzą do narzędzi AI z dużą dozą sceptycyzmu, ograniczają częstotliwość do „szczątkowego” ich wykorzystania, obawiając się o rzetelność danych.

4. Model absencyjny i bojkotowy (brak użytkowania)

Analiza wykazuje też istnienie grupy studentów, którzy deklarują zerową częstotliwość użytkowania, motywowaną przesłankami etycznymi lub ekologicznymi:

a) bojkot ideologiczny: studenci aktywnie unikają narzędzi AI ze względu na jej wpływ na środowisko lub „ogłupiający” charakter;

b) preferencja metod tradycyjnych: osoby te deklarują, że wolą „używać własnego umysłu” i nie odczuwają potrzeby wsparcia technologicznego.

Konkluzje. Z perspektywy naukowej częstotliwość używania narzędzi AI przez studentów można określić jako funkcję zapotrzebowania na optymalizację wysiłku intelektualnego. Dominujący wzorzec to użytkowanie epizodyczne, ale intensywne, skoncentrowane wokół kluczowych momentów ewaluacji wiedzy (egzaminy) oraz zadań wymagających syntezy dużej ilości danych. Widoczna jest tendencja do przechodzenia od użytkowania sporadycznego do coraz bardziej systematycznego w miarę wzrostu kompetencji studentów w zakresie tworzenia zapytań (*prompt engineering*) oraz wzrostu złożoności materiału dydaktycznego na wyższych latach studiów.

Bibliografia

Abdallah, N., Katmah, R., Khalaf, K., Jelinek, H.F. (2025). Systematic review of ChatGPT in higher education: Navigating impact on learning, wellbeing, and collaboration. *Social Sciences & Humanities Open*, 12, 101866. <https://doi.org/10.1016/j.ssaho.2025.101866>

- Cotton, D.R.E., Cotton, P.A., Shipway, J.R. (2024). Chatting and cheating: Ensuring academic integrity in the era of ChatGPT. *Higher Education Pedagogies*, 9(1), 1–12. <https://doi.org/10.1080/14703297.2023.2190148>
- Fosner, A. (2024). University Students' Attitudes and Perceptions towards AI Tools: Implications for Sustainable Educational Practices. *Sustainability*, 16(19), 8668. <https://doi.org/10.3390/su16198668>
- Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Kasneci, G. (2023). *ChatGPT for good? On opportunities and challenges of large language models for education. Learning and Individual Differences*, 103. <https://doi.org/10.1016/j.lindif.2023.102274>
- Ravšelj, D., Keržič, D., Tomaževič, N., Umek, L., Brezovar, N., Iahad, N.A., i in. (2025). Higher education students' perceptions of ChatGPT: A global study of early reactions. *PLoS ONE*, 20(2), e0315011. <https://doi.org/10.1371/journal.pone.0315011>
- Shi, Y., Yu, K., Dong, Y., Chen, F. (2025). Large language models in education: a systematic review of empirical applications, benefits, and challenges. *Computers and Education: Artificial Intelligence*, 10, 100529. <https://doi.org/10.1016/j.caeai.2025.100529>
- Xia, Q., Liu, Q., Tlili, A., Chiu, R.K.F. (2026). *A systematic literature review on designing self-regulated learning using generative artificial intelligence and its future research directions. Computers and Educations*, 240, 105465. <https://doi.org/10.1016/j.compedu.2025.105465>
- Zawacki-Richter, O., Marín, V.I., Bond, M., Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education: Where are the educators? *International Journal of Educational Technology in Higher Education*, 16, 39. <https://doi.org/10.1186/s41239-019-0171-0>

3. WERYFIKACJA TREŚCI I STRATEGIE KRYTYCZNE WOBEK TREŚCI GENEROWANYCH ZA POMOCĄ NARZĘDZI AI, WSKAŹNIK AKSJOLOGICZNO-POZNAWCZY

ANITA KARYŃ, KRZYSZTOF ŁUSZCZEK

Wskaźnik aksjologiczno-poznawczy opisuje, w jakim stopniu studenci utrzymują krytyczny nadzór nad treściami generowanymi przez narzędzia AI. Jego rdzeń stanowi napięcie między wygodą i płynnością odpowiedzi generatywnych a ryzykiem błędów i halucynacji. Rozdział obejmuje rozkład deklaracji weryfikacji, strategie sprawdzania oraz racjonalizację braku weryfikacji, a następnie pokazuje zróżnicowania kontekstowe w obrębie badanej próby. W niniejszym badaniu wskaźnik aksjologiczno-epistemiczny nie jest traktowany jako pojedyncza zmienna ilościowa, lecz jako konstrukcja interpretacyjna opisująca relację między deklarowanymi praktykami weryfikacji a sposobami uzasadniania zaufania wobec narzędzi generatywnej AI. Obejmuje on trzy wymiary analityczne: 1) deklarację weryfikacji informacji; 2) strategie sprawdzania treści oraz 3) racjonalizację braku weryfikacji. Tak zdefiniowany wskaźnik pozwala uchwycić zarówno poziom epistemicznej czujności użytkowników, jak i aksjologiczne uzasadnienia praktyk poznawczych związanych z wykorzystaniem narzędzi AI (Sperber i in., 2010). W kontekście generatywnej AI mechanizmy epistemicznej czujności nabierają szczególnego znaczenia, ponieważ modele językowe mogą generować treści o wysokiej płynności językowej, które nie zawsze są zgodne z faktami.

3.1. Deklaracja weryfikacji informacji pozyskiwanej za pomocą narzędzi AI

Pierwszym krokiem jest ustalenie, jak często studenci deklarują weryfikowanie informacji uzyskanych za pomocą narzędzi generatywnych. Odpowiedź znajdują się w tabeli 3.3.1 oraz na wykresie 3.3.1.


Tabela 3.3.1. Deklaracja weryfikacji informacji pozyskiwa za pomocą narzędzi AI, N = 457

Kategoria	N	%
Tak	396	86,9
Trudno określić	8	1,7
Nie	39	8,6
Brak danych	14	2,8

Źródło: badania własne.

Analiza. W próbie 457 respondentów 397 (86,9%) deklaruje weryfikowanie informacji, natomiast brak weryfikacji zgłosiło 39 osób (8,6%). Odpowiedzi trudne do jednoznacznego zaklasyfikowania udzieliło 8 osób (1,7%), a braki

danych dotyczyły 14 ankietowanych (2,8%). Rozkład ujawnia znaczącą obecność praktyk krytycznych, przy jednoczesnym segmencie użytkowników, którzy nie traktują weryfikacji jako stałego elementu pracy. Użytkownicy nie traktują modeli językowych jako nieomyłnej wyroczni, lecz raczej jako narzędzie wymagające nadzoru i weryfikacji. Niski odsetek odpowiedzi „trudno określić” (1,7%) oraz braku odpowiedzi (2,8%) sugeruje, że pytanie dotyczyło kwestii, co do której większość ludzi ma już wyrobione zdanie. Proces weryfikacji informacji stał się integralną częścią korzystania z technologii AI.



Wykres 3.3.1. Deklaracja weryfikacji informacji pozyskiwanej za pomocą narzędzi AI, N = 457

Źródło: badania własne.

Interpretacja i weryfikacja. Konfrontacja z badaniami jakościowymi pokazuje, że praktyki weryfikacyjne są silnie zależne od kontekstu zadania i presji czasu. Badanie Yeunga Chowa, Wonga i Lau (2026) opisuje mechanizmy zauważania i nadużyć, wskazując, że aplikacja ChatGPT bywa wykorzystywana jako narzędzie odciążenia poznawczego⁸, a zaufanie może utrzymywać się mimo świadomości błędów, co odpowiada mechanizmowi *automation bias*. W praktyce dydaktycznej oznacza to potrzebę wbudowania weryfikacji w strukturę zadań i kryteria oceniania.

Koncepcja ta jest zbliżona do pojęcia *epistemic vigilance*⁹ zaproponowanego przez Sperbera i in. (2010), które opisuje mechanizmy poznawcze odpowiedzialne za ocenę wiarygodności informacji i źródeł. W kontekście narzędzi generatywnej AI mechanizm ten ulega częściowej automatyzacji, co może prowadzić do osłabienia krytycznej oceny treści i zwiększenia podatności na tzw. *automation bias*, czyli tendencję do nadmiernego polegania na systemach automatycznych nawet w sytuacji, gdy mogą one generować błędne informacje (Parasuraman, Riley, 1997; Mosier, Skitka, Heers, Burdick, 1998).

⁸ Odciążenie poznawcze (*cognitive relief*) – strategia minimalizowania wysiłku umysłowego (ładunku poznawczego) potrzebnego do przetwarzania informacji i wykonywania zadań. Polega na upraszczaniu interfejsów (UX), automatyzacji czynności oraz selekcji bodźców, co zapobiega przeciążeniu pamięci roboczej, zwiększa efektywność uczenia się, redukuje stres i poprawia koncentrację.

⁹ *Epistemic vigilance* (czujność epistemiczna) – opisuje szereg adaptacji psychologicznych, które chronią przed tymi manipulacjami, w tym tendencje do oceniania informacji społecznych na podstawie uczciwości lub kompetencji źródła lub samej treści informacji (Sperber i in., 2010).

3.2. Strategie weryfikacji informacji pozyskiwanej za pomocą narzędzi AI


Drugim krokiem jest rekonstrukcja strategii weryfikacji opisywanych przez studentów. Odpowiedź znajduje się w tabeli 3.3.2 oraz na wykresie 3.3.2 (odpowiedzi udzieliło 397 osób).

Tabela 3.3.2. Strategie weryfikacji informacji pozyskiwanych za pomocą narzędzi AI, N = 397

Kategoria	N	%
Źródła i cytowania	160	40,4
Cross checking w internecie	107	26,8
Literatura i podręczniki	75	18,7
Porównanie wielu odpowiedzi i narzędzi	35	8,8
Konsultacja z prowadzącym	15	3,8
Własna wiedza i doświadczenie	5	1,5

Źródło: badania własne.

Analiza. Najczęściej wskazywane strategie to: źródła i cytowania” (160 osób; 40,4%), *cross checking* w internecie (107 osób; 26,8%), literatura i podręczniki (75 osób; 18,7%), porównanie wielu odpowiedzi i narzędzi (35 osób; 8,8%), konsultacja z prowadzącym (15 osób; 3,8%). Wzorzec wskazuje na dominację *cross checking* w internecie i pracy ze źródłami, a także na porównywanie wielu odpowiedzi oraz odwołanie do wiedzy własnej. Pięć osób (1,5%) ma zaufanie do własnej wiedzy.



Wykres 3.3.2. Strategie weryfikacji informacji pozyskiwanych za pomocą narzędzi AI, N = 457

Źródło: badania własne.

Interpretacja i weryfikacja. Strategie te są zgodne z kierunkiem rekomendacji instytucjonalnych i polityk uczelnianych, które akcentują rozwój alfabetyzacji AI (*AI literacy*) poprzez sprawdzanie źródeł, świadomość ograniczeń modeli i jawność użycia. W analizie polityk przeprowadzonej przez Jina, Yana, Echeverrię, Gaševića i Martinezę-Maldonada (2025) podkreślono, że najczęst-

szymi elementami ram wdrożeniowych są zasady integralności akademickiej oraz zasoby szkoleniowe uczące krytycznej oceny treści.

Strategie treści dostarczanych przez narzędzia AI wskazują na kilka ciekawych tendencji. Książka i w ogóle słowo drukowane zachowały przynajmniej w pewnej grupie studentów wysoki autorytet akademicki oraz wiarygodność. Studenci generalnie są krytyczni wobec materiałów wygenerowanych przez AI. Chociaż niektórzy starają się reagować promptami zwrotnymi, wierząc, że mogą „zmotywować” dane narzędzie AI do większej prawdziwości („pytam go, czy na pewno mówi prawdę”), lub proszą model językowy o udostępnienie źródeł. Należy również odnotować grupę respondentów, która w ogóle nie ma zaufania do materiałów dostarczanych przez AI („nie ufam niczemu, co napisze AI”).


3.3. Racjonalizacje braku weryfikacji informacji pozyskiwanych za pomocą narzędzi AI

Trzecim krokiem jest analiza racjonalizacji braku weryfikacji wśród osób deklarujących odpowiedź „nie”. Odpowiedź znajduje się w tabeli 3.3.3 oraz na wykresie 3.3.3 (odpowiedzi udzieliło tylko 69 osób).

Tabela 3.3.3. Powody braku weryfikacji informacji pozyskiwanych za pomocą narzędzi AI, N = 59

Kategoria	N	%
Lenistwo	25	42,5
Zaufanie do własnej wiedzy	13	21,9
Brak czasu i pośpiech	10	16,4
Nie używam AI	5	9,6
Ufam AI	3	5,5
AI jako narzędzie pomocnicze	2	2,7
Brak istotnych informacji do sprawdzenia	1	1,4

Źródło: badania własne.



Wykres 3.3.3. Powody braku weryfikacji informacji pozyskiwanych za pomocą narzędzi AI, N = 59

Źródło: badania własne.

Analiza. Najczęściej wskazywane racjonalizacje braku weryfikacji informacji pozyskiwanych za pomocą narzędzi AI to: lenistwo (25 osób; 42,5%), zaufanie do własnej wiedzy (13 osób; 21,9%), brak czasu i pośpiech (10 osób; 16,4%). Dominują zatem dwie linie uzasadnień: przyczyny psychospołeczne oraz presja czasu.

Interpretacja i weryfikacja. Wynik można interpretować jako przejaw ekonomii wysiłku, gdzie weryfikacja jest kosztem, który bywa pomijany w zadaniach postrzeganych jako niskiego ryzyka. Badania przeprowadzone przez Yeunga i in. (2026) pokazują, że tryb obciążenia oraz presja efektywności sprzyjają utrwalaniu zaufania do narzędzi AI mimo świadomości błędów. Być może narzędzia AI służą raczej do redakcji lub streszczeń, a więc są traktowane jako narzędzie językowe, a nie źródło faktów.


3.4. Zróżnicowania praktyk weryfikacji informacji pozyskiwanych za pomocą narzędzi AI, zmienne kontekstowe

Czwarty krok dotyczy zróżnicowań między grupami. Studenci zostali pogrupowani w zależności od dziedziny nauki, jaką studiują. Odpowiedź przedstawiono w tabeli 3.3.4a oraz na wykresie 3.3.4a.

Tabela 3.3.4a. Studenci weryfikujący informacje pozyskiwane za pomocą narzędzi AI według dziedziny nauk, N = 398

Dziedziny nauki	N	%
Dziedzina nauk społecznych	287	72,1
Dziedzina nauk ścisłych i przyrodniczych	73	18,3
Dziedzina nauk humanistycznych	25	6,3
Dziedzina nauk medycznych i nauk o zdrowiu	8	2,0
Dziedzina nauk inżynieryjno-technicznych	5	1,3

Źródło: badania własne.



Wykres 3.3.4a. Weryfikacja informacji pozyskiwanych za pomocą narzędzi AI według dziedziny nauk, N = 398


Źródło: badania własne.

Osobno dokonano rozróżnienia w zależności od poziomu studiów, jaki realizują studenci. Odpowiedź przedstawiono w tabeli 3.3.4b oraz na wykresie 3.3.4b.

Tabela 3.3.4b. Studenci weryfikujący informacje pozyskiwane za pomocą narzędzi AI według poziomu studiów, N = 398

Poziom studiów	N	%
Studia I stopnia	131	32,9
Studia II stopnia i jednolite studia magisterskie	256	64,3
Studia III stopnia	11	2,8

Źródło: badania własne.



Wykres 3.3.4b. Weryfikacja informacji pozyskiwanych za pomocą narzędzi AI według poziomu studiów, N = 398

Źródło: badania własne.

Analiza. Porównania ujawniają różnice odsetka weryfikacji pomiędzy obszarami dziedzin nauk i poziomami studiów. Interpretacja powinna uwzględniać liczebności w grupach, ponieważ mniejsze grupy mogą dawać bardziej wrażliwe odchylenia procentowe.

Interpretacja i weryfikacja. Zróżnicowania między grupami są spójne z badaniami przeprowadzonymi przez Stöhra, Ou i Malmström (2024), które wskazują, że użycie i percepcja chatbotów w edukacji wyższej różnicują się ze względu na pole i poziom studiów. W konsekwencji uczelniane programy alfabetyzacji AI powinny uwzględniać profil dyscypliny i typy zadań, zamiast przyjmować jednolity model dla całej populacji studenckiej.

Podsumowując, wskaźnik aksjologiczno-epistemiczny pokazuje, że praktyki weryfikacyjne są znaczącą częścią doświadczeń studentów, a repertuar strategii obejmuje zarówno *cross checking* i pracę ze źródłami, jak i porównywanie wielu odpowiedzi. Jednocześnie istnieje grupa, która weryfikacji nie praktykuje, uzasadniając to zaufaniem, prostotą pytań lub presją czasu.

Bibliografia

Jin, Y., Yan, L., Echeverria, V., Gašević, D., Martinez-Maldonado, R. (2025). *Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. Computers & Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>

- Mosier, K. L., Skitka, L. J., Heers, S., Burdick, M. (1998). Automation bias: Decision making and performance in high-tech cockpits. *The International Journal of Aviation Psychology*, 8(1), 47–63. https://doi.org/10.1207/s15327108ijap0801_3
- Parasuraman, R., Riley, V. (1997). Humans and automation: Use, misuse, disuse, abuse. *Human Factors*, 39(2), 230–253. <https://doi.org/10.1518/001872097778543886>
- Sperber, D., Clément, F., Heintz, C., Mascaro, O., Mercier, H., Origg, G., Wilson, D. (2010). *Epistemic Vigilance*. <https://doi.org/10.1111/j.1468-0017.2010.01394.x>
- Stöhr, C., Ou, A.W., Malmström, H. (2024). Perceptions and usage of AI chatbots among students in higher education across genders, academic levels and fields of study. *Computers and Education: Artificial Intelligence*, 7, 100259. <https://doi.org/10.1016/j.cacai.2024.100259>
- Yeung, L.K.C., Chow, D.P.L., Wong, P.H., Lau, S.S.S. (2026). In ChatGPT they trust: A study of students' perceptions and misuse of ChatGPT in higher education. *AI and Ethics*, 6, 11. <https://doi.org/10.1007/s43681-025-00855-w>

4. JAWNOŚĆ UŻYCIA NARZĘDZI AI, OBawy ORAZ WSPARCIE UCZELNI, WSKAŹNIK ETYCZNO-INSTITUCJONALNY

ALEKSANDER CYWIŃSKI, JOANNA SZUMIŁO-JACKOWSKA

W niniejszym rozdziale skupiamy się na trzech kwestiach: czy studenci otwarcie przyznają się do używania tych narzędzi, czego się obawiają w związku z reakcją wykładowców oraz czy uczelnia oferuje jasne wytyczne i wsparcie. W rozdziale pokazano, na ile studenci ukrywają swoje praktyki i dlaczego, a także jakie szkolenia byłyby potrzebne, by korzystanie z generatywnej AI przebiegało w sposób zorganizowany i transparentny.

4.1. Przegląd literatury

Dynamiczny rozwój generatywnej AI (narzędzi generatywnej AI), zwłaszcza takich narzędzi, jak: ChatGPT, Grammarly czy QuillBot, znacząco przekształcił praktyki akademickie studentów na całym świecie, jednocześnie generując nowe wyzwania etyczne, społeczne i instytucjonalne. Szczególnie istotnym problemem są obawy studentów przed ujawnianiem korzystania z narzędzi generatywnej AI w pracach akademickich, uwarunkowane niejasnym statusem regulacyjnym stosowania tych narzędzi, lękiem przed sankcjami oraz presją społeczną. Sytuacja ta ściśle wiąże się z postawami wykładowców, które stanowią znaczący element środowiska instytucjonalnego i tym samym bezpośrednio wpływają na jawność lub zatajenie praktyk studenckich. Z jednej strony tworzy się zespół jawności i otwartości, który sprzyja traktowaniu narzędzi generatywnej AI jako instrumentu dodatkowego (wspierającego) proces kształcenia. W takich warunkach studenci skłonni są do ustalania granic wykorzystywania narzędzi generatywnej AI. Z drugiej strony pojawia się zespół restrykcji i zakazów, w którym tworzone jest środowisko podejrzliwości i braku zaufania do pracy studenta. W tej sytuacji można przywołać wcześniej przytoczoną metaforę podziemia – kiedy student korzysta z narzędzi generatywnej AI i z powodu strachu nie przyznaje się do stosowanych praktyk.

Niniejszy przegląd literatury systematyzuje dotychczasowe ustalenia dotyczące uwarunkowań obaw, skali i kontekstów korzystania z narzędzi generatywnej AI, skuteczności metod wykrywania, luk w politykach instytucjonalnych oraz rekomendacji dla szkolnictwa wyższego.

Badania podkreślają wielowymiarowy charakter obaw studentów przed ujawnianiem korzystania z narzędzi generatywnej AI. Reina Marín, Cruz Caro i Rituay (2025a) identyfikują kluczowe wyzwania etyczne związane z wykorzystaniem narzędzi generatywnej AI w edukacji uniwersyteckiej, obejmujące kwestie prywatności danych, odpowiedzialności za treści generowane przez narzędzia

generatywnej AI oraz ryzyko naruszenia integralności akademickiej. Triyanto i Handayani (2025) wskazują, że studenci doświadczają rozterek etycznych związanych z granicami dopuszczalnego wykorzystania tych narzędzi. Brak klarownych wytycznych powoduje, że znajdują się oni w zawieszeniu. Z jednej strony chcą optymalizacji i akceptacji wsparcia nowych technologii, z drugiej strony stoją przed uczuciem lęku i strachu przed naruszeniem niedopracowanych zasad.

Jak zaleca Eaton (2023), szkolnictwo wyższe powinno zmienić politykę karania na rzecz polityki kształcenia. Dzięki opracowaniu jasnych i rzetelnych zasad studenci przestaną stosować metody etycznych improwizacji. Istotnym czynnikiem potęgującym obawy jest lęk przed utratą autonomii intelektualnej i kreatywności. Boillos i Idoiaga-Mondragon (2026) pokazały, że studenci postrzegają nadmierne poleganie na narzędziach generatywnej AI jako zagrożenie dla samodzielnego myślenia i oryginalności prac akademickich. Podobnie Pisca, Ioan, Bucur, Popa i Zaharia (2024) odnotowali u studentów rumuńskich obawy dotyczące uzależnienia od narzędzi generatywnej AI i erozji kompetencji krytycznego myślenia.

Presja społeczna stanowi kolejny istotny wymiar obaw. Hasan i in. (2024) wskazali, że strach przed negatywną oceną ze strony wykładowców i rówieśników zniechęca studentów do ujawniania korzystania z omawianych narzędzi generatywnej AI. Ling (2026) podkreśla, że obawa przed stygmatyzacją jako „oszustów” sprzyja ukrywaniu rzeczywistych praktyk. Obawy te są wzmacniane przez nieufność wobec narzędzi detekcji wykorzystania narzędzi generatywnej AI. Ma, Wanpen i Kaewmanee (2025) wykazali, że lęk przed fałszywym oskarżeniem o generowanie tekstu przez narzędzia generatywnej AI jest istotnym predyktorem niepokoju wśród studentów kierunków pedagogicznych, a Angeles i in. (2024) potwierdzili obawy studentów przed niesprawiedliwymi konsekwencjami błędów systemów detekcji. Wspomniane lęki przed utratą autonomii intelektualnej i presja społeczna budują swoisty opór psychologiczny. W połączeniu z systemami detekcji, a przede wszystkim z ich zawodnością, studenci postrzegają praktykę korzystania z narzędzi generatywnej AI jako strefę ryzyka. Przez te obawy kształtuje się postawa długotrwałej niepewności, która związana jest również z funkcjonowaniem systemowym. W ten sposób należy wrócić do poprzednich refleksji dotyczących regulacji instytucjonalnej.

Brak jasnych, spójnych wytycznych dotyczących korzystania z narzędzi generatywnej AI jest konsekwentnie wskazywany jako jeden z głównych czynników potęgujących obawy studentów. Nez-Valdés, Sepúlveda-Irribarra, Villegas-Dianta i Castillo-Paredes (2025) podkreślają, że nieprecyzyjne polityki prowadzą do trudności w odróżnieniu dozwolonego i niedozwolonego korzystania z narzędzi generatywnej AI. Le. Doan i Vu Van (2025) pokazali, że niejasność regulacji przekłada się bezpośrednio na wzrost lęku i niepewności studentów. Adelhardt i Eberle (2025), badając niemieckie szkolnictwo średnie, wykazali, że

brak egzekwowania polityk dotyczących narzędzi generatywnej AI prowadzi do powszechnego, lecz ukrytego korzystania z tych narzędzi. Jiang, Xie i Cao (2025) wskazują, że fragmentaryczność i niespójność polityk między wydziałami pogłębia dezorientację studentów. Gonsalves (2025) zwraca uwagę na rozbieżności między deklaracjami a praktykami studentów, argumentując, że nieskuteczne mechanizmy ujawniania podważają integralność akademicką. Z kolei McCusker i Michalak (2025) identyfikują istotne luki w zaangażowaniu bibliotek w kształtowanie i wdrażanie polityk dotyczących korzystania z narzędzi generatywnej AI na amerykańskich uniwersytetach. Tsao (2025) analizuje trajektorie polityk wdrażania narzędzi AI w szkolnictwie wyższym, wskazując na rozbieżności między oficjalnymi dyskursami a praktykami studentów i nauczycieli.

Przytoczone wyniki badań potwierdzają, że zarówno niespójność występująca na gruncie instytucjonalnym, jak i nieobecność jasnych zasad i granic dla narzędzi generatywnej AI zatrzymują innowacyjne szanse studentów, a ich praktyki z wykorzystaniem tych narzędzi stają się ukryte. Brak wyraźnie przedstawionych granic pomiędzy możliwą pomocą technologiczną a zabronionym naruszeniem integralności instytucjonalnej powoduje, że każde naruszenie związane z wykorzystaniem generatywnej AI jest utożsamiane z zagrożeniem dla statusu studenta. Przedstawione postrzeganie ryzyka wynika z formalnych ujęć instytucjonalnych oraz systemu przekonań kulturowych, bowiem to uwarunkowania kulturowe wpływają na to, co w danej społeczności akademickiej zostanie uznane za akceptowalne przy wsparciu technologicznym (Ling, 2026).

Kontekst kulturowy odgrywa istotną rolę w kształtowaniu obaw i praktyk ujawniania korzystania z narzędzi generatywnej AI. Ahmad, Han i Alam (2023) pokazują, że wpływ korzystania z tych narzędzi na procesy decyzyjne i bezpieczeństwo w edukacji różni się w zależności od kontekstu kulturowego. Zhai, Wibowo i Li (2023) odnotowali zróżnicowane poziomy wrażliwości studentów na kwestie etyczne i prywatności w systemach dialogowych narzędzi generatywnej AI. Viberg i in. (2024) wykazali istotne różnice kulturowe w poziomie troski o dane osobowe między studentami z Niemiec, Korei Południowej, Hiszpanii, Szwecji i Stanów Zjednoczonych. Xue, Chinapah i Zhu (2025) porównali narracje medialne dotyczące prywatności AI w Chinach i krajach zachodnich, wskazując na odmienne ramy interpretacyjne i poziomy obaw. W krajach azjatyckich oryginalność tekstu i pracy studenta ustępuje miejsca skuteczności przekazu. Kluczowe jest, aby student potrafił operować nowymi narzędziami. Umiejętności korzystania z narzędzi generatywnej AI są cenione i postrzegane jako zalety w procesie transformacji edukacyjnej (Ahmad, Han, Alam, 2023).

Istotnym, choć nie zawsze wspomnianym elementem są czynniki klasowo-ekonomiczne. Wymiar ten różnicuje praktyki korzystania z narzędzi generatywnej AI przez pryzmat kapitału technologicznego, do którego student ma dostęp. Znaczenie czynników społeczno-ekonomicznych i infrastrukturalnych podkre-

śla, że nierówności cyfrowe wpływają na dostępność narzędzi generatywnej AI i poziom obaw studentów (Poh, Tan, Lee, Tan, 2026). Shubha, Vaidya, Ali i Lund (2025) wykazali, że studenci o wyższym statusie społeczno-ekonomicznym przejawiają większą pewność w korzystaniu z narzędzi generatywnej AI. Sun, Yang, Yu i Suen (2026) opisują regionalne zróżnicowanie wsparcia AI w chińskim szkolnictwie wyższym, wskazując na nierównomierny dostęp do infrastruktury cyfrowej. Dla osób, które pochodzą z grup o wysokim statusie ekonomicznym i kulturowym, AI staje się naturalnym sposobem na wydłużenie sprawczości praktyki studenckiej, bowiem narzędzia generatywnej sztucznej inteligencji traktowane są jako zasoby, którymi studenci i pracownicy akademicy muszą potrafić właściwie zarządzać, aby efektywnie operować własnym potencjałem. Niezależnie od zasobów, które posiada student, lub barier, z którymi się spotyka, dynamika korzystania z narzędzi AI nabrała globalnego charakteru. Mimo że w dalszym ciągu motywacje i poczucie bezpieczeństwa studentów pozostają zróżnicowane, dotychczasowe dane empiryczne potwierdzają, że narzędzia generatywnej AI nie są już niedostępną nowością.

Obecnie narzędzie generatywnej AI stały się innowacją – często nieoficjalną i ukrytą, obecną we współczesnej praktyce studiowania. Są one szeroko wykorzystywane przez studentów na różnych poziomach edukacji oraz w zróżnicowanych kontekstach akademickich. Luthfi, Prasetyo, Sari, Waldi i Muttaqin (2025) zebrali dane dotyczące adopcji, oczekiwań i motywacji studentów wobec narzędzi generatywnej AI, potwierdzając powszechność korzystania z tych narzędzi. Vázquez, Pérez Parejo, Jaraz-Cabanillas i Gómez Caballero (2025) odnotowali szerokie wykorzystanie narzędzi generatywnej AI w zadaniach pisemnych i dydaktycznych wśród studentów edukacji na Uniwersytecie Estremadury. Hershkovitz, Tabach i Lurie (2025), stosując analizę zadaniową, opisali zróżnicowane zastosowania narzędzi generatywnej AI – od pisanie esejów po analizę danych.

Przedstawione informacje dowodzą, że powszechność stosowania AI wymusza na instytucjach zmianę sposobu myślenia na temat tych narzędzi. Pytanie zamknięte, czy instytucje szkolnictwa wyższego powinny stosować AI, powinniśmy zamienić na pytanie otwarte, jak integrować narzędzia sztucznej inteligencji w dzisiejszym procesie kształcenia akademickiego. Fakt, że studenci wykorzystują narzędzia generatywnej AI w szerokim spektrum uczenia się, świadczy o tym, że technologia sztucznej inteligencji stała się nowym standardem uczenia się. W związku z tym należy poddać refleksji i redefinicji tradycyjne metody weryfikowania osiągnięć studentów. Różnice dyscyplinarne i poziom kształcenia wpływają na wzorce korzystania z AI. Jereb i Urh (2024) wykazali zróżnicowanie wykorzystania narzędzi generatywnej AI w zależności od kierunku studiów. Shakib Kotamjani, Shirinova, Muratova i Sharma (2025) analizowali perspektywy studentów w Uzbekistanie, a Anani, Nyamekye i Bafour-Koduah (2025) w Gha-

nie, wskazując regionalne różnice w sposobach użycia narzędzi do pisania akademickiego. Rahman i in. (2025) potwierdzili powszechność stosowania narzędzi generatywnej AI jako narzędzi edukacyjnych na różnych poziomach edukacji.

Kluczowym wyzwaniem jest równoważenie wsparcia AI z niezależnością intelektualną. Patac i Patac (2025) pokazali, że studenci wykorzystują narzędzi ChatGPT głównie do zarządzania obciążeniem poznawczym¹⁰. Black i Tomlinson (2025) opisują, jak studenci adaptują AI do pisania i badań w ramach kursu ogólnokształcącego. Hajihassankhansary i Gilanlioglu (2025) podkreślają znaczenie krytycznego myślenia jako kluczowej kompetencji w erze AI. Yang, Deng i Jiang (2025) wskazują na ryzyko ograniczenia kreatywności (innowacyjności) studentów w wyniku nadmiernej zależności od AI.

Podsumowując przytoczone analizy, istotna jest zmiana kierunku od instytucjonalnego nadzoru pracy studenta ku wsparciu elastyczności intelektualnej. Wobec tego uczelnie nie stoją przed wyzwaniem ograniczenia dostępu do narzędzi AI, lecz innowacyjnego projektowania procesów dydaktycznych. W tym rozumieniu szkolnictwo wyższe stoi przed zadaniem stworzenia ram, w których korzystanie z AI będzie służyć do ćwiczenia funkcji kognitywnych, a nie sprzyjać intelektualnej zależności, ograniczając w ten sposób kreatywność studentów. Skuteczność narzędzi służących do wykrywania (detekcji) AI jest ważnym kontekstem obaw studentów. Perkins, Roe, Postma, Mcgaughran i Hickerson (2024) wykazali istotne ograniczenia narzędzi służących do wykrywania tekstów generowanych przez aplikację GPT-4, nawet przy łączeniu oceny akademickiej z oprogramowaniem detekcyjnym. Huaman i Tocto (2024) analizowali możliwości uczenia maszynowego w wykrywaniu monografii generowanych przez AI. Hyatt, Bienenstock, Firetto, Woods i Robert (2025) wskazują, że połączenie wyników z kilku detektorów AI może pomóc zmniejszyć liczbę błędnych oznaczeń (tzw. fałszywych pozytywów) w pracach pisanych przez studentów kierunków STEM. Deep, Edgington, Ghosh i Rahaman (2025) podkreślają wysokie ryzyko fałszywych pozytywów oraz istotne implikacje etyczne stosowania detekcji AI w szkolnictwie wyższym. Ibrahim, AlOtaibi i Sibai (2025) wykazali ograniczoną skuteczność wykrywania tekstów przez Turnitin AI Content Detector wobec tekstów parafrazowanych. Problem fałszywych pozytywów jest szczególnie dotkliwy w odniesieniu do studentów wielojęzycznych. Mizumoto, Yasuda i Tamura (2024) porównali „odciski lingwistyczne” tekstów generowanych przez aplikację ChatGPT i pisanych przez studentów EFL (osoby uczące się języka angielskiego jako języka obcego), identyfikując różnice mogące prowadzić do błędnych klasyfikacji. Ghimire (2025) zwraca uwagę na transnaro-

¹⁰ Obciążenie poznawcze – wysiłek umysłowy podejmowany podczas uczenia się, rozwiązywania problemów lub wykonywania zadań. Wiąże się z całkowitym wykorzystywaniem pamięci operacyjnej podczas procesów myślowych. Przypisywane jest teorii Swellera, australijskiego psychologa edukacyjnego (Pappas, 2024).

dową perspektywę i ryzyko dyskryminacji użytkowników języka angielskiego jako drugiego przez systemy detekcji. Altunel (2026) analizuje problem równości w regulacjach AI wobec uczniów wielojęzycznych na poziomie K-12.

Reakcje instytucji szkolnictwa wyższego na wykryte użycie narzędzi AI są zróżnicowane – od podejścia edukacyjnego po restrykcyjne sankcje. Stevkovska (2024) proponuje zmianę zadań pisemnych jako alternatywę dla czysto represyjnych strategii. Wersją alternatywną mogą być krótkie wypowiedzi studentów podczas zajęć dydaktycznych. Torres-Gastel, Lagunes, Lagunes Domínguez i Nava-Dominguez (2025) dokumentują spektrum reakcji instytucjonalnych w systematycznym przeglądzie wpływu narzędzi AI na studentów. Fisk (2025) przedstawia praktyczne strategie identyfikacji i reagowania na użycie narzędzi AI w pracach studenckich. Overoye i Ditta (2025) wykazali, że stosowanie oświadczeń o wykorzystaniu narzędzi AI sprzyja rozwijaniu umiejętności przyszłych psychologów w sferze etycznej oraz weryfikacji faktów. Sergeeva, Zheltukhina i Demir (2025) porównują rolę narzędzi AI w komunikacji akademickiej w kampusach rosyjskich i tureckich, ujawniając różnice w podejściu instytucjonalnym.

Wszystkie wymienione uwarunkowania funkcjonowania instytucjonalnego w kontekście stosowania narzędzi generatywnej AI w szkolnictwie wyższym łączą się w punkcie krytycznym, którym jest interakcja pomiędzy studentami a kadrami akademicką. Mimo że obie grupy funkcjonują w tej samej przestrzeni instytucjonalnej, ich postrzeganie celowości i etyki używania narzędzi AI najczęściej pozostają rozbieżne. W wyniku diametralnie różnych podejść uniwersytet staje się przestrzenią, w której podejmowane są negocjacje wobec nowych znaczeń stosowania narzędzi AI. Tradycyjny model akademicki relacji nauczyciel–student jest sprzeczny z codzienną praktyką cyfrowych pragmatyków. Skalę tego zjawiska przedstawiają liczne badania porównawcze. Reina Marín i in. (2025b) wykazali, że kadra postrzega narzędzi AI głównie jako instrument wspomagający, podczas gdy studenci widzą w nim szerszy potencjał dydaktyczny. Ghalia i in. (2024) dokumentują znaczące różnice w ocenie korzyści i ryzyka związanego z narzędzi AI między studentami a pracownikami akademickimi na Uniwersytecie Jarmouk. Marshik, McCracken, Kopp i O'Marrah (2025) potwierdzają rozbieżność percepcji i praktyk korzystania z AI, która utrudnia wypracowanie wspólnych polityk wdrożeniowych. Stone (2025) opisuje postawy studentów wobec narzędzi generatywnej AI jako niepewne i doraźne (merkantylne), podkreślając wewnętrzną sprzeczność (ambiwalencję) wobec tych nich. W konsekwencji tego stajemy przed asymetrią oczekiwań wobec roli narzędzi generatywnej AI, jaką ma pełnić w kształceniu akademickim.

Badania prowadzone w różnych kontekstach kulturowych pokazują, że studenci wykazują wysokie zainteresowanie uczeniem się z wykorzystaniem narzędzi AI, ale uczeniem się o nich samych, przy jednocześnie silnie zróżnicowanym poziomie kompetencji. Lee, Oh i Hong (2024) wykazali, że studenci z doświad-

czeniu w programowaniu charakteryzują się wyższą wiedzą na temat narzędzi AI niż pozostali. Hornberger, Bewersdorff i Nerdel (2023), opracowując test kompetencji wykorzystania narzędzi AI dla studentów niemieckich uczelni, odnotowali duże zróżnicowanie alfabetyzacji AI w zależności od kierunku studiów i wcześniejszych doświadczeń. Gke, Topal, Geçer i Dilek Eren (2025), wykorzystując analizę drzew decyzyjnych (algorytm CHAID), potwierdzili, że ogólny poziom kompetencji wykorzystania narzędzi AI przez studentów jest przeciętny, a rozumienie techniczne niskie, przy czym kluczowymi predyktorami są częstotliwość korzystania z narzędzi AI oraz kierunek studiów. W odpowiedzi na te wyzwania uczelnie rozwijają ramy kształcenia w zakresie *AI literacy*. Nahar i in. (2025) proponują czterostopniowy model kompetencji korzystania z narzędzi AI (przygotowanie, zrozumienie, zastosowanie, odpowiedzialne użycie), oparty na badaniach mieszanych i analizie istniejących ram kompetencyjnych. Rojas-Contreras, Quintana, Villamizar Carrillo i Villamizar Carrillo (2025) wskazują na potrzebę dalszej operacjonalizacji i integracji ram *AI literacy* z programami studiów technicznych i humanistycznych. Chen, Tallant i Selig (2025) pokazują, że włączenie i etyczna ewaluacja generatywnej AI zależą od wyjściowego poziomu kompetencji cyfrowych. Shi, Liu i Hu (2025) wykazali, że alfabetyzacja AI i samoregulacja uczenia się pozytywnie korelują z wynikami prac pisemnych oraz dobrostanem psychicznym studentów korzystających z generatywnej AI. Ngoveni (2025) podkreśla, że brak systemowych rozwiązań w tym obszarze może pogłębiać nierówności edukacyjne. Alfabetyzacja AI stwarza nowy fundament rzetelności i buduje kompetencje w zakresie stosowania narzędzi AI. Daje możliwość uczciwego korzystania z narzędzi sztucznej inteligencji poprzez uczenie zbioru kompetencji, takich jak rozumienie, poddawanie krytycznej ocenie i etyczne korzystanie z narzędzi AI. W kontekście instytucjonalnym kluczowe jest to, aby zdobywać informacje dotyczące tego, czym realnie jest AI, jak ją wykorzystywać, w jaki sposób zachować krytyczną analizę proponowanych treści.

Podsumowując, alfabetyzacja korzystania z AI nie może być ujmowana jedynie jako umiejętność techniczna. Obecnie jest to kluczowa kompetencja składająca się z kilku komponentów, które budują rzetelność akademicką. Alfabetyzacja korzystania z AI odnosi się nie tylko do funkcjonalnego operowania narzędziami, ale jest to przede wszystkim zdolność do krytycznego myślenia odnośnie do pracy algorytmów. Efektem tego jest zachowanie etyczno-społecznych zasad korzystania z narzędzi generatywnej AI. *AI literacy* ma na celu przygotowanie do świadomego korzystania z algorytmów, przy zachowaniu autonomii poznawczej. Zatem jest to fundament obecności narzędzi generatywnej AI w przestrzeni instytucjonalnej. Potrzeba jasnych i spójnych regulacji instytucjonalnych dotyczących korzystania z narzędzi AI jest silnie akcentowana w literaturze. Smit, Wagner i Bond-Barnard (2025) pokazują, że niejednoznaczne regulacje instytucjonalne mogą prowadzić do relatywizmu moralnego wśród

studentów; aż 94 respondentów domagało się wyraźnych polityk wdrożeniowych dotyczących AI. Cerkinsi i in. (2025) oraz Ngoveni (2025) potwierdzają, że brak klarownych wytycznych generuje dezorientację i obawy przed korzystaniem z narzędzi AI. Wang, Dang, Wu i Mac (2024) identyfikują zróżnicowane modele regulacyjne – od pełnej swobody decyzji wykładowców, przez polityki warunkowe z obowiązkiem cytowania, po restrykcyjne zakazy. Ehmke, Bridges i Patel (2025) oraz Ritter, Uhey i Saxena (2025) podkreślają, że dobrze zaprojektowane polityki wzmacniają wiedzę kadry i ułatwiają wypracowanie spójnych zasad etycznych. Shen i Cui (2024) wykazali, że postrzegane wsparcie instytucjonalne (dostęp do platform opartych na AI, inteligentnych systemów nauczania, wirtualnych asystentów) pośredniczy między zaspokojeniem potrzeb psychologicznych a alfabetyzacją w zakresie narzędzi AI. Segovia-García (2024) dokumentuje rosnącą rolę chatbotów AI w obsłudze administracyjnej i indywidualnym wsparciu procesu uczenia się. Luckin, Cukurova, Kent i Du Boulay (2022) argumentują, że skuteczne wdrożenie AI w edukacji wymaga przygotowania kadry (*AI-readiness*) obejmującego szkolenia, mentoring i integrację narzędzi AI z praktyką dydaktyczną. Nurtanto i in. (2025), opierając się na modelach TPB, UTAUT i TAM¹¹, wykazali, że infrastruktura technologiczna i wsparcie organizacyjne są istotnymi predyktorami intencji korzystania z narzędzi AI i wyników akademickich studentów w Indonezji. Li, Ng, Cheung i Lee (2025) podkreślają konieczność ciągłej adaptacji edukacyjnych narzędzi AI do szybko zmieniającego się środowiska technologicznego. Zhao, An i Liu (2025) pokazali, że wsparcie instytucjonalne zwiększa zaangażowanie studentów – szczególnie tych o niskiej początkowej pewności siebie – a efekt ten jest wynikiem złożenia alfabetyzacji multimodalnej (tzw. multimodalnej *literacy*)¹² oraz poczucia własnej skuteczności.

Badania prowadzone w latach 2022–2025 rysują spójny obraz wielowymiarowego wsparcia uczelni dla studentów w zakresie narzędzi AI, z dużą zgodnością wyników uzyskanych w różnych regionach i typach instytucji. Najbardziej efektywne strategie łączą infrastrukturę technologiczną, programy szkoleniowe, jasne regulacje i rozwój zawodowy kadry akademickiej, współtworząc zintegrowany ekosystem narzędzi AI, który sprzyja odpowiedzialnemu i świadomemu korzystaniu z nich przez studentów. Pomimo szybko rosnącej liczby badań literatura ujawnia istotne luki w tym zakresie. Na przykład López, Castellanos-Ramírez, Niño-Carrasco i Parra-Encinas (2025) wskazują na niedostatek badań podłuż-

¹¹ TPB, UTAUT, TAM – modele służące wyjaśnieniu, dlaczego ludzie podejmują pewne zachowania lub przyjmują nowe rozwiązania techniczne. Wchodzą one w zakres psychologii społecznej i technologii.

¹² Multimodalna *literacy* – w kontekście omawianego zagadnienia to mechanizm adaptacyjny ujmowany jako narzędzie mediacji, który wsparcie ze strony uczelni przekłada na rzeczywiste zaangażowanie studenta. Student nabywa zdolność do poruszania się w środowisku informacyjnym. W konsekwencji tego zdobywa pewność siebie dzięki wsparciu instytucjonalnym.

nych nad postawami studentów wobec narzędzi AI. Z kolei Mukhamedkari-mova i Umurkulova (2025) identyfikują potrzebę dalszych badań porównaw-czych dotyczących akceptacji narzędzi AI przez studentów, a Truylol, Queza-da-Espinoza, Zavala i Bascur (2025) podkreślają konieczność kontekstualizacji badań w specyficznych uwarunkowaniach instytucjonalnych i kulturowych.

Kluczowe obszary wymagające dalszych badań obejmują:

- a) badania podłużne nad zmianą postaw studentów w czasie;
- b) porównania międzykulturowe i międzyinstytucjonalne praktyki ujawniania powodów (motywacji) i sposobów korzystania z narzędzi AI;
- c) ewaluację skuteczności programów alfabetyzacji w zakresie korzystania z narzędzi AI;
- d) analizę wpływu czynników społeczno-ekonomicznych na dostęp do narzędzi AI i obawy związane z ujawnianiem stosowania tego typu programów wspierających pisanie prac kontrolnych;
- e) rozwój bardziej precyzyjnych i sprawiedliwych narzędzi wykrywania ko-rzystania z rozwiązań AI, uwzględniających potrzeby studentów wielojęzycznych.

Powyższy przegląd literatury przedstawia dynamiczny proces adaptacji na-rzędzi generatywnej AI w szkolnictwie wyższym mimo wciąż niespójnego przedmiotu badań. Kluczowym wyzwaniem jest zidentyfikowanie i uzupełnienie luk badawczych, przy czym szczególnie istotnym wyzwaniem zdaje się być próba zrozumienia, w jaki sposób uwarunkowania instytucjonalne regulują lęki studentów i wpływają na strategie ujawniania korzystania z AI.


4.2. Obawa ujawnienia korzystania z narzędzi AI

Kluczowym elementem diagnozy zachowań studentów związanych ze sto-sowaniem AI jest zrozumienie barier psychologicznych i instytucjonalnych, które związane są z przejrzystością ich działań akademickich. Głównym punk-tem analizy w tym obszarze jest ustalenie, w jakim stopniu studenci odczuwają obawę przed ujawnieniem korzystania z narzędzi generatywnej AI wobec osób prowadzących zajęcia. Pytanie to daje możliwość weryfikacji, czy teoretycznie zakładana strefa ryzyka wykorzystania AI faktycznie istnieje w odczuciach badanej grupy. Analiza odpowiedzi na to pytanie stanowi punkt wyjścia do dalszych rozważań nad przyczynami ewentualnego lęku. Poniżej przedstawi-o-no rozkład odpowiedzi studentów w tym zakresie (tabela 3.4.1 i wykres 3.4.1).

Tabela 3.4.1. Obawa ujawnienia korzystania z narzędzi AI, rozkład odpowiedzi, N = 457

Kategoria	N	%
Nie	276	60,4
Tak	125	27,4
Trudno określić	43	9,4
Brak danych	13	2,8

Źródło: badanie własne.



Wykres 3.4.1. Obawa ujawnienia korzystania z narzędzi AI, N = 457

Źródło: badanie własne.

Analiza. Obawę ujawnienia korzystania z narzędzi AI wobec nauczycieli akademickich deklaruje 125 osób (27,4%), podczas gdy brak obawy wskazało 276 osób (60,4%); odpowiedzi niejednoznaczne stanowią 9,4%, a braki danych – 2,8% próby. Rozkład ten wskazuje, że jawność korzystania z narzędzi generatywnych nie jest neutralnym elementem praktyk studiowania, lecz wiąże się z przewidywaniem (antycypowaniem) konsekwencji zarówno na poziomie formalnego oceniania, jak i moralnej oceny ze strony nauczycieli oraz rówieśników. Interpretując wyniki w świetle literatury, można zauważyć, że poziom deklarowanych obaw wpisuje się w opisywany szeroko w badaniach „wielowymiarowy” charakter lęku studentów przed ujawnianiem użycia narzędzi generatywnej AI. Reina Marín i in. (2025a) pokazują, że obawy te splatają się z kwestiami prywatności danych, odpowiedzialności za treści generowane przez AI oraz ryzykiem naruszenia integralności kultury akademickiej, co prowadzi do napięcia między pragmatycznym wykorzystywaniem narzędzi a obawą przed możliwymi sankcjami. Podobnie Triyanto i Handayani (2025) wskazują na rozterki etyczne studentów związane z niepewnymi granicami dopuszczalnego wykorzystania AI, co może sprzyjać strategiom „prewencyjnego” ukrywania rzeczywistych praktyk.

Interpretacja i weryfikacja. Uzyskany w niniejszym badaniu odsetek osób deklarujących obawę jawności można rozumieć jako wskaźnik napięcia między rosnącą normalizacją korzystania z narzędzi generatywnej AI w codziennych zadaniach akademickich (co potwierdzają badania nad powszechnością użycia narzędzi generatywnej AI, m.in. Luthfi, Prasetyo, Sari, Walidi, Muttaqin, 2025; Rahman i in., 2025) a brakiem stabilnych, rozpoznawalnych ram normatywnych. Podkreślają oni, że presja społeczna i obawa przed etykietą „oszustwa” są kluczowym czynnikiem zniechęcającym do jawnego przyznawania się do użycia narzędzi generatywnej AI w pracach akademickich. Z tego punktu widzenia odsetek osób odczuwających obawy jawności można traktować nie jako prosty wskaźnik „technofobii”, lecz jako przejaw racjonalnej reakcji na niejednoznaczne otoczenie regulacyjne i komunikacyjne. Wyniki są spójne z analizami Karakoulou i Sayegh (2025), którzy wykazali, że studenci postrzegają apli-

kacje ChatGPT ambiwalentnie – jako zasób wspierający uczenie się, ale również jako potencjalne źródło naruszeń uczciwości akademickiej w sytuacji braku klarownych zasad. Tego typu ambiwalencja pojawia się także w badaniach nad deklaracjami ujawniania korzystania z narzędzi generatywnej AI (Ramos, 2025; Overoye i Ditta, 2025), gdzie przejrzyste mechanizmy ujawniania zmniejszają niepokój studentów, jednocześnie wzmacniając ich autorefleksję. W perspektywie instytucjonalnej prezentowane wyniki można zatem odczytać jako argument za potrzebą opracowania i komunikowania jasnych zasad jawności oraz wdrażania narzędzi deklaracyjnych, które przenoszą ciężar z ukrywania praktyk na ich negocjowanie w ramach uzgodnionych norm.


4.3. Powody obaw przed ujawnieniem korzystania z narzędzi AI

Kolejnym etapem analizy jest rekonstrukcja specyficznych motywacji stojących za deklarowanym lękiem. Skupienie uwagi na grupie osób udzielającej odpowiedzi twierdzącej pozwala zidentyfikować główne bariery hamujące otwartość studenta o mówieniu korzystania z narzędzi generatywnej AI oraz zrozumieć, jakie czynniki studenci postrzegają jako najbardziej zagrażające. W tabeli 3.4.2 oraz na wykresie 3.4.2 przedstawiono rekonstrukcję uzasadnień obaw wśród osób, które odpowiedziały twierdząco.

Tabela 3.4.2. Powody obaw przed ujawnieniem korzystania z narzędzi AI, kodowanie semantyczne, podzbiór odpowiedzi „Tak” wraz z uzasadnieniem, N = 45

Kategoria	N	%
Konsekwencje oceniania i sankcje	24	19,2
Autonomia i niesamodzielność	20	16,0
Normy i postawy prowadzących	1	0,8

Źródło: badanie własne.



Wykres 3.4.2. Powody obaw przed ujawnieniem korzystania z narzędzi AI, podzbiór odpowiedzi „Tak”, N = 125

Źródło: badanie własne.

Analiza. Wśród osób deklarujących obawę przed ujawnieniem korzystania z AI najczęściej kodowane powody odnoszą się do kategorii: konsekwencje oceniania i sankcje (19,2%) oraz autonomia i niesamodzielność (16,0%), natomiast normy i postawy prowadzących pojawiają się rzadziej (0,8%). Uzasadnienia koncentrują się zatem wokół dwóch powiązanych wymiarów: lęku przed zakwestionowaniem samodzielności pracy oraz obawy przed negatywnymi skutkami decyzji oceniających, w tym oskarżeniami o nieuczciwość akademicką. Struktura tych kategorii potwierdza tezę, że obawa jawności ma przede wszystkim charakter normatywno-instytucjonalny, a nie czysto technologiczny.

Literatura podkreśla, że studenci nie tyle boją się samego narzędzia, ile konsekwencji przypisania mu statusu naruszenia zasad. Badania dotyczące wykrywania wykorzystania AI w pracach studenckich pokazują, że wysokie ryzyko fałszywych pozytywów¹³, a więc sytuacji, w których błędnie zostanie przypisane autorstwo narzędziom AI (Perkins, Roe, Postma, Mcgaughran, Hickerson, 2024; Deep, Edgington, Ghosh, Rahaman, 2025), oraz ograniczona skuteczność narzędzi, szczególnie wobec tekstów parafrazowanych (Ibrahim, AlOtaibi, Sibai., 2025), prowadzą do lęku przed niesprawiedliwym oskarżeniem. Ma i in. (2025) identyfikują lęk przed wykryciem jako istotny predyktor niepokoju wśród studentów, a Angeles i in. (2024) wskazują na obawy przed błędami systemów wykrywania użytych narzędzi AI stosowanych przez kadrę akademicką. W tym kontekście kategoria „konsekwencje oceniania i sankcje” stanowi lokalny odpowiednik globalnie opisywanego problemu użycia narzędzi wykrywania AI w warunkach niepełnej ich przejrzystości dla studentów. Kategoria „autonomia i niesamodzielność” koresponduje z wątkiem utraty autonomii intelektualnej, który pojawia się w badaniach Boillosa i Idoiaga-Mondragon (2026) oraz Pisicy i in. (2024), gdzie studenci wyrażają obawę, że nadmierne poleganie na AI podważa sens samodzielnego studiowania i upośledza kompetencje krytycznego myślenia. Wyniki niniejszego badania sugerują, że część studentów internalizuje normy integralności w sposób silnie spersonalizowany – lęk przed „niesamodzielnością” dotyczy nie tylko reakcji instytucji, lecz także własnej autooceny etycznej. Tym samym obawa jawności staje się formą „normatywnej racjonalizacji”, w której studenci przewidują oceny moralne oraz prawne konsekwencje swoich praktyk, działając w sytuacji niepewności co do linii demarkacyjnej między dopuszczalnym a niedopuszczalnym użyciem narzędzi generatywnej AI.

Literatura poświęcona politykom uczelnianym podkreśla, że taka niepewność jest wzmacniana przez brak spójnych i precyzyjnych wytycznych. Nez-

¹³ *Falszywy pozytyw* – błędne przypisanie autorstwa narzędziom AI.

-Valdés i in. (2025), Nascimento i in. (2025) oraz Le i in. (2025) wskazują, że niejasne regulacje utrudniają studentom odróżnienie dozwolonych form wsparcia przez narzędzia AI (np. pomoc w redakcji tekstu) od form traktowanych jako oszustwo (np. generowanie całości prac). Jin, Yan, Echeverria, Gašević i Martinez-Maldonado (2025) proponują, aby polityki instytucjonalne *explicite* definiowały zakres dopuszczalnego użycia narzędzi AI w różnych typach zadań oraz zasady ujawniania wkładu narzędzi, co odpowiada bezpośrednio na strukturę uzasadnień zidentyfikowanych w niniejszej próbie. Zestawienie wyników z tymi rekomendacjami pozwala wnioskować, że obawa jawności może być zredukowana przede wszystkim poprzez doprecyzowanie i upowszechnienie zasad, a nie jedynie przez deklaratywne wzmacnianie dyskursu dotyczącego autonomii i niesamodzielności.

Interpretacja i weryfikacja. Struktura uzasadnień wskazuje, że obawa jawności jest w znacznym stopniu racjonalizacją normatywną, a nie tylko lękiem przed technologią. Wyniki te wzmacniają wnioski z badań dotyczących polityk uczelnianych mówiące o tym, że ramy instytucjonalne powinny jednoznacznie definiować dopuszczalne użycie AI w typach zadań i w ocenianiu, a także określać zasady ujawniania wkładu wykorzystanych narzędzi AI (Jin, Yan, Echeverria, Gašević, Martinez-Maldonado, 2025).


4.4. Wsparcie uczelni w zakresie AI

Kolejnym etapem niniejszej sekcji jest weryfikacja stopnia zaangażowania instytucji w proces adaptacji studentów do nowych realiów technologicznych. Przede wszystkim istotne jest ustalenie, czy studenci deklarują otrzymywanie realnego wsparcia ze strony uczelni w zakresie korzystania z narzędzi AI. W tym miejscu można również ustalić, w jakim stopniu deklaratywne polityki uniwersyteckie przekładają się na konkretne działania edukacyjne. Pytanie to jest istotne, ponieważ pozwala zrozumieć, czy proces budowania alfabetyzacji w zakresie AI jest wspierany systemowo, czy studenci wystawieni są na próbę samodzielnego wdrażania tych narzędzi. Zatem trzecim krokiem jest sprawdzenie, czy studenci deklarują otrzymywanie wsparcia ze strony uczelni w zakresie korzystania z AI. Odpowiedzi przedstawiono w tabeli 3.4.3 oraz na wykresie 3.4.3.

Tabela 3.4.3. Wsparcie uczelni w zakresie wykorzystania narzędzi AI, rozkład odpowiedzi, N = 457

Kategoria	N	%
Nie	250	54,7
Brak danych	127	27,8
Trudno określić	45	9,8
Tak	35	7,7

Źródło: badanie własne.



Wykres 3.4.3. Wsparcie uczelni w zakresie wykorzystania narzędzi AI, N = 457
 Źródło: badanie własne.

Analiza. Wsparcie uczelni w zakresie korzystania z narzędzi AI deklaruje 39 osób (8,5%), natomiast brak wsparcia – 276 osób (60,4%); 9,0% badanych wybiera odpowiedź „trudno określić”, a w 22,1% przypadków występują braki danych. Oznacza to, że z perspektywy studentów wsparcie instytucjonalne jest w niewielkim stopniu rozpoznawalne, a znaczna część badanych nie potrafi jednoznacznie ocenić, jakie formy wsparcia istnieją.

Interpretacja i weryfikacja. Literatura potwierdza, że tego typu „niewidzialność” wsparcia jest zjawiskiem częstym. Analizy polityk uczelnianych wskazują, że instytucje koncentrują się przede wszystkim na ochronie integralności akademickiej i dotychczasowych ramach oceniania, podczas gdy kwestie wdrożenia, komunikacji i budowy zasobów szkoleniowych dla studentów i kadry pozostają mniej dopracowane. Jin i in. (2025), Jiang i in. (2025) oraz McCusker i Michalak (2025) w swoich badaniach pokazują, że polityki dotyczące wykorzystania narzędzi generatywnej AI są często fragmentaryczne, zróżnicowane między wydziałami i słabo powiązane z praktyką dydaktyczną, co z perspektywy studentów generuje obraz niespójnego, mało przewidywalnego otoczenia instytucjonalnego.

Niskie rozpoznanie wsparcia uczelni w niniejszym badaniu wpisuje się również w wyniki prac podkreślających znaczenie otwartości na wykorzystanie przez studentów narzędzi AI kadry akademickiej oraz infrastruktury jako warunku realnego wsparcia (Luckin, Holmes, Griffiths, Forcier, 2022; Nurtanto i in., 2025; Li i in., 2025). Badania przeprowadzone przez Sham Shen i Cui (2024) pokazują, że postrzegane wsparcie instytucjonalne – ujmowane szeroko – jako dostęp do platform opartych na AI, inteligentnych systemów nauczania i wirtualnych asystentów – pośredniczy między zaspokojeniem potrzeb psychologicznych studentów a ich alfabetyzacją w zakresie AI. Z kolei Zhao i in. (2025) wskazują, że wsparcie uczelni zwiększa zaangażowanie studentów, szczególnie tych o niższej początkowej pewności siebie, poprzez wzmacnianie poczucia własnej skuteczności. W świetle tych ustaleń niski odsetek deklarowa-

nego wsparcia w naszej próbie można interpretować jako czynnik potencjalnie ograniczający zarówno rozwój kompetencji korzystania z narzędzi AI, jak i redukcję lęku związanego z jawnością. Wynik ten jest ponadto zgodny z diagnozami Ngoveniego (2025) oraz Cerkiniego i in. (2025), którzy akcentują lukę między rosnącą obecnością narzędzi AI w praktykach studenckich a brakiem systemowych rozwiązań w zakresie szkoleń, doradztwa i jasnych procedur. W ujęciu instytucjonalnym uzyskane dane można więc traktować jako wskaźnik „deficytu widoczności” polityk i działań uczelni: nie tyle braku formalnych dokumentów, ile niedostatecznego przełożenia ich na praktykę oraz komunikację, co prowadzi do subiektywnego poczucia pozostawienia studentów z AI samym sobie.

4.5. Potrzeby szkoleniowe w zakresie korzystania z narzędzi AI


Istotnym punktem niniejszej analizy jest identyfikacja konkretnych oczekiwań i braków kompetencyjnych zgłaszanych przez osoby studiujące. Zrozumienie potrzeb szkoleniowych w zakresie AI umożliwia odejście od intuicyjnych działań dydaktycznych na rzecz strategii opartej na dowodach. Wyniki zaprezentowane poniżej wskazują, które obszary techniczne, etyczne, merytoryczne wymagają interwencji ze strony instytucji. Analiza ta jest kluczowa w celu sformułowania rekomendacji dotyczących budowania efektywnego środowiska *AI literacy*. W tym miejscu została przedstawiona identyfikacja potrzeb szkoleniowych w zakresie korzystania z AI na uczelni. Odpowiedź przedstawiono w tabeli 3.4.4 oraz na wykresie 3.4.4.

Tabela 3.4.4. Potrzeby szkoleniowe w zakresie korzystania z narzędzi AI, kodowanie semantyczne, N = 457

Kategoria	N	%
Weryfikacja i wiarygodność	55	12,0
Promptowanie i praktyka	35	7,7
Bezpieczeństwo danych	20	4,4
Etyka i zasady	7	1,5
Zastosowania dydaktyczne	4	0,9
Szkolenia dla kadry	2	0,4
Brak odpowiedzi lub deklaracja braku potrzeby wsparcia	334	73

Źródło: badanie własne.

Najczęściej wskazywane potrzeby szkoleniowe dotyczą: weryfikacji i wiarygodności (12,0%), promptowania i praktyki (7,7%), bezpieczeństwa danych (4,4%), etyki i zasad (1,5%) oraz zastosowań dydaktycznych (0,9%). Dominacja kategorii związanej z weryfikacją i wiarygodnością treści wskazuje, że studenci lokują główny problem w obszarze krytycznej oceny odpowiedzi AI, a nie wyłącznie w zakresie sprawności technicznej obsługi narzędzi.



Wykres 3.4.4. Potrzeby szkoleniowe w zakresie korzystania z narzędzi AI, N = 457

Źródło: badanie własne.

Interpretacja i weryfikacja. Zestawiając te wyniki z literaturą, można założyć wyraźną zbieżność z rosnącym naciskiem na alfabetyzację w zakresie posługiwania się narzędziami AI rozumianą jako kompetencje krytyczno-refleksyjne obejmujące umiejętność oceny jakości, stronniczości i wiarygodności generowanych treści. Badania przeprowadzone przez Chena i in. (2025), Hornbergera i in. (2023) oraz Gke i in. (2025) pokazują, że wiedza techniczna studentów na temat narzędzi AI jest przeciętna lub niska, natomiast częstotliwość korzystania z nich nie przekłada się automatycznie na zdolność krytycznej analizy uzyskanych odpowiedzi. Z kolei ramy proponowane przez Naharę i in. (2025) czy Rojas-Contrerasa i in. (2025) wskazują, że edukacja w zakresie wykorzystania narzędzi generatywnej AI powinna obejmować zarówno zrozumienie działania modeli, jak i rozpoznawanie ograniczeń, wystąpienia możliwego ryzyka oraz wymiarów etycznych. W niniejszej próbie potrzeba szkolenia z weryfikacji i wiarygodności łączy się z oczekiwaniem wsparcia w zakresie promptowania i praktyki, co sugeruje, że studenci chcą uczyć się zarówno tego, jak zadawać pytania narzędziom generatywnej AI, jak i jak oceniać adekwatność oraz rzetelność uzyskiwanych odpowiedzi. Blahopoulou i Ortiz-Bonnin (2025) opisują podobną ambiwalencję: z jednej strony studenci doceniają korzyści w zakresie oszczędności czasu i dostępności, z drugiej – dostrzegają ryzyko deprecjacji edukacji oraz spadku jakości prac, jeśli narzędzia generatywnej AI są wykorzystywane bezrefleksyjnie. Wyniki naszego badania potwierdzają tę diagnozę, wskazując, że studenci trafnie formułują swoje obawy wobec używania narzędzi generatywnej AI oraz potrzeby szkoleniowe w kategoriach kompetencji krytycznego użytkownika, a nie pasywnego odbiorcy usług sztucznej inteligencji.

Relatywnie rzadkie odwołania do kategorii „etyka i zasady” oraz „zastosowania dydaktyczne” można interpretować dwojako. Po pierwsze, może to od-

zwierciedlać fakt, że studenci przede wszystkim doświadczają problemów na poziomie praktycznej pracy z narzędziami i weryfikacji treści, podczas gdy kwestie etyczno-regulacyjne są dla nich mniej uchwytne, abstrahując od bezpośrednich konsekwencji w ocenianiu. Po drugie, może to sygnalizować brak wyobrażenia sobie możliwych modeli „odpowiedzialnej integracji” narzędzi AI w dydaktyce – zgodnie z obserwacjami Stone’a (2025) i Vanka, Yorulmaza i Dobrovskiej (2025), którzy opisują postawy studentów wobec narzędzi generatywnej AI jako niepewne i często merkantylne, pozbawione szerszego zakorzenienia w refleksji pedagogicznej. W perspektywie wdrożeniowej wyniki sugerują potrzebę realizacji modułowych programów szkoleniowych, które łączą: 1) weryfikację i krytyczną ocenę treści; 2) praktyczne strategie promptowania; 3) bezpieczeństwo danych i prywatność oraz 4) zasady jawności i integralności akademickiej. Tego typu programy odpowiadają zarówno rekomendacjom dotyczącym alfabetyzacji w zakresie posługiwania się narzędziami AI (Efthymiou i in., 2025), jak i diagnozom o konieczności systemowego wsparcia instytucjonalnego studentów i kadry dydaktycznej (Ngoveni, 2025).

4.6. Wsparcie uczelni a obawa ujawnienia użycia narzędzi AI

Ostatnim elementem prezentowanej analizy jest sprawdzenie, czy deklarowane wsparcie uczelni wiąże się ze słabszym nasileniem obaw instytucjonalnych, zgodnie z hipotezą H4. Weryfikacja tej zależności pozwala odpowiedzieć na pytanie o to, czy systemowe budowanie kompetencji i jasna komunikacja ze strony instytucji redukuje niepewność normatywną – swego rodzaju stan zawieszenia pomiędzy niejasnymi zasadami. Wyniki tej analizy przedstawiono w tabeli 3.4.5 oraz na wykresie 3.4.5.


Tabela 3.4.5. Wsparcie uczelni a obawa ujawnienia użycia narzędzi AI

Wsparcie uczelni	Obawa – Tak	Obawa – Nie
Tak	8	27
Nie	90	160

Źródło: badanie własne.

Analiza. Określenie zależności między deklarowanym wsparciem uczelni a obawą ujawnienia korzystania z narzędzi AI oparte na teście Fishera ($p = 0,1340$) oraz wskaźniku Craméra V ($0,091$) wskazuje na słabą siłę związku w badanej próbie ($N = 285$). Odsetek obawy „tak” pozostaje porównywalny wśród osób deklarujących wsparcie i jego brak, co sugeruje, że samo istnienie (lub jego brak) wsparcia na poziomie deklaratywnym nie przekłada się wprost na redukcję lęku instytucjonalnego. Zgodnie z literaturą dotyczącą polityk stosowania narzędzi AI w szkolnictwie wyższym taki wynik można interpretować jako dowód na to, że kluczowe znaczenie ma nie tylko „posiadanie” polityki czy

formalnych mechanizmów wsparcia, lecz ich jakość, spójność i stopień zakorzenienia w praktyce dydaktycznej. Badania przeprowadzone przez Jina i in. (2025), Tsao (2025) oraz Wanga i in. (2024) pokazują, że polityki stosowania narzędzi generatywnej AI często pozostają w sprzeczności z rzeczywistymi praktykami studentów i nauczycieli, a ich oddziaływanie zależy od tego, czy są one: 1) jasno sformułowane; 2) konsekwentnie egzekwowane; 3) komunikowane w sposób zrozumiały dla studentów oraz 4) powiązane z konkretnymi narzędziami i zasobami wsparcia. W tym sensie brak istotnego statystycznie związku w naszej próbie można odczytać jako wskaźnik „płytkiego wdrożenia” – formalne lub częściowo rozpoznane wsparcie nie przekłada się jeszcze na zmianę subiektywnego poczucia bezpieczeństwa studentów.



Wykres 3.4.5. Wsparcie uczelni a obawa ujawnienia użycia narzędzi AI, N = 285

Źródło: badanie własne.

Interpretacja i weryfikacja. Badania nad alfabetyzacją dotyczącą stosowania narzędzi AI i dobrostanem studentów (Shi, Liu, Hu, 2025; Ho, Le, 2026) sugerują, że redukcja lęku i wzrost pewności korzystania z narzędzi AI zależą od kombinacji następujących czynników: kompetencji technicznych, krytycznego rozumienia działania tych narzędzi, wsparcia psychologicznego oraz zaufania do instytucjonalnych ram ochrony przed niesprawiedliwymi konsekwencjami. Z kolei prace Shena i Cui (2024) oraz Zhao i in. (2025) podkreślają, że postrzegane wsparcie uczelni działa poprzez mediujące mechanizmy – m.in. poczucie autonomii, kompetencji i relacyjności – a nie jako prosty „czynnik ochronny”. Na tym tle uzyskany wynik sugeruje, że wsparcie opisane przez badanych studentów nie spełnia jeszcze tych warunków, aby skutecznie osłabiać lęk przed jawnością. Analiza korelacji między deklarowanym wsparciem a poziomem lęku studentów pozwala na głębszą dekonstrukcję mechanizmów zarządzania technologią na uczelni. Zebrane dane empiryczne zderzają (konfrontują) nas z rzeczy-

wistością, w której same procedury formalne okazują się niewystarczające do budowania klimatu zaufania. W świetle uzyskanych wyników staje się jasne, że relacja między instytucją a studentem w czasach powszechnego stosowania narzędzi AI opiera się na komunikacji i realnej użyteczności narzędzi pomocowych.

W konsekwencji interpretacja hipotezy H4 powinna zostać przeformułowana: nie wystarczy zakładać, że „istnienie wsparcia” jako takiego prowadzi do redukcji obaw; istotne jest raczej, czy wsparcie to jest widoczne, dostępne, responsywne na formułowane przez studentów potrzeby (zwłaszcza w zakresie weryfikacji treści i jasności zasad) oraz powiązane z praktyką dydaktyczną i mechanizmami ujawniania korzystania z narzędzi AI. Wyniki niniejszego badania wskazują, że bez takiego jakościowego ugruntowania wsparcia formalne polityki pozostają „niemym” elementem otoczenia instytucjonalnego, nierozkładającym się wprost na doświadczenie bezpieczeństwa i zaufania studentów.

Podsumowując, wskaźnik etyczno-instytucjonalny odsłania konfigurację doświadczeń studentów, w której obawy przed ujawnieniem korzystania z narzędzi generatywnej AI współwystępują z niską rozpoznawalnością wsparcia uczelni oraz wyraźnie artykułowanymi potrzebami szkoleniowymi w obszarze krytycznej weryfikacji treści, bezpieczeństwa danych i jasnych zasad etycznych. Wyniki te wpisują się w globalne ustalenia, zgodnie z którymi niepewność regulacyjna, fragmentaryczność polityk i ograniczona komunikacja instytucjonalna sprzyjają strategiom ukrywania praktyk stosowania narzędzi generatywnej AI i wzmacniają lęk przed sankcjami, szczególnie w kontekście zawodnej detekcji i ryzyka fałszywych oskarżeń. Jednocześnie, podobnie jak w badaniach nad alfabetyzacją w zakresie korzystania z narzędzi AI, studenci w badanej próbie nie odrzucają stosowania narzędzi AI jako takich, lecz domagają się ram umożliwiających odpowiedzialne, refleksyjne korzystanie z nich – ram łączących infrastrukturę, szkolenia, mechanizmy jawności oraz przewidywalne procedury oceniania. Z perspektywy analizy literatury (López, Castellanos-Ramírez, Niño-Carrasco, Parra-Encinas, 2025; Mukhamedkarimova, Umurkulova, 2025; Truyol, Quezada-Espinoza, Zavala, Bascur, 2025) rezultaty te potwierdzają potrzebę dalszych badań podłużnych i porównawczych, które pozwolą uchwycić dynamikę postaw wobec stosowania narzędzi w AI szkole wyższej w dłuższym czasie.

Bibliografia

- Adelhardt, Z., Eberle, T. (2025). Compliance and enforcement of AI text generator usage policies in German grammar schools: Insights from teenagers. *International Journal of Information and Education Technology*, 15(2), 233–239. <https://doi.org/10.18178/ijiet.2025.15.2.2233>
- Ahmad, S.F., Han, H., Alam, M.M., Rehmet, M.K., Irshad, M., Arraño-Muñoz, M., Ariza-Montes, A. (2023). Impact of artificial intelligence on human loss in decision making, laziness and safety in education. *Humanities and Social Sciences Communications*, 10, 114. <https://doi.org/10.1057/s41599-023-01787-8>

- Altunel, V. (2026). Invisible learners: An analysis of state K-12 artificial intelligence governance and English learner equity. *Social Sciences & Humanities Open*, 13, 102609. <https://doi.org/10.1016/j.ssaho.2026.102609>
- Anani, G.E., Nyamekye, E., Bafour-Koduah, D. (2025). Using artificial intelligence for academic writing in higher education: The perspectives of university students in Ghana. *Discover Education*, 4, 43–54. <https://doi.org/10.1007/s44217-025-00434-5>
- Angeles, C.N., Samson, B.D., Mama, B.R.Z.I., Luriaga, R.L., Delizo, J.P.D., Ching, M.R.D. (2024). Students' perception of the use of AI detector system by faculty members in determining the originality of submitted academic requirements. W: *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3675585.3675587>
- Black, R.W., Tomlinson, B. (2025). University students describe how they adopt AI for writing and research in a general education course. *Scientific Reports*, 15, 92937. <https://doi.org/10.1038/s41598-025-92937-2>
- Blahopoulou, J., Ortiz-Bonnin, S. (2025). Student perceptions of ChatGPT: benefits, costs, and attitudinal differences between users and non-users toward AI integration in higher education. *Education and Information Technologies*, 30, 19741–19764. <https://doi.org/10.1007/s10639-025-13575-9>
- Boillos, M.M., Idoiaga-Mondragon, N. (2026). Students' negative perceptions of the use of artificial intelligence in academic writing: Didactic implications for higher education. *Educación XXI*, 29(1), 439–443. <https://doi.org/10.5944/educxx1.43943>
- Cerkini, B., Bajraktari, K., Çibukçiu, B., Ramadani, F., Havolli, Y., Hajdini, L. (2025). Artificial intelligence in higher education: Student perspectives on practices, challenges, and policies in a transitional context. *Frontiers in Education*, 10, 1700056. <https://doi.org/10.3389/feduc.2025.1700056>
- Chen, K., Tallant, A.C., Selig, I. (2025). Exploring generative AI literacy in higher education: Student adoption, interaction, evaluation and ethical perceptions. *Information and Learning Sciences*, 126(1–2), 132–148. <https://doi.org/10.1108/ILS-10-2023-0160>
- Deep, P.D., Edgington, W.D., Ghosh, N., Rahaman, M.S. (2025). Evaluating the effectiveness and ethical implications of AI detection tools in higher education. *Information*, 16(10), 905. <https://doi.org/10.3390/info16100905>
- Eaton, S.E. (2023). Postplagiarism: transdisciplinary ethics and integrity in the age of artificial intelligence and neurotechnology. *Int J Educ Integr*, 19, 23. <https://doi.org/10.1007/s40979-023-00144-1>
- Efthymiou, L., Epaminonda, E., Ktoridou, D., Michailidis, M., Papakyriakou, A., Charalambos, C. (2025). Ethical considerations and responsible use of AI in education: A students' perspective. W *IEEE Global Engineering Education Conference (EDUCON)*. <https://doi.org/10.1109/EDUCON62633.2025.11016462>
- Ehmke, S.D., Bridges, J., Patel, S.E. (2025). Self-perceived knowledge, skills, and attitude of nursing faculty on generative artificial intelligence in nursing education: A descriptive, cross-sectional study. *Teaching and Learning in Nursing*, 20(3), 222–227. <https://doi.org/10.1016/j.teln.2025.01.029>
- Fisk, G.D. (2025). AI or human? Finding and responding to artificial intelligence in student work. *Teaching of Psychology*, 52(2), 251–255. <https://doi.org/10.1177/00986283241251855>
- Ghalia, N., Isami, E., Bsoul, M., Aabed, S., salh Haeb, R., Mustafa, M. (2024). Impact of artificial intelligence in education: Insights from students and faculty members at Yarmouk University. *Journal of Ecohumanism*, 3(8), 48–70. <https://doi.org/10.62754/joe.v3i8.4807>
- Ghimire, A. (2025). Utilizing ChatGPT to integrate world English and diverse knowledge: A transnational perspective in critical artificial intelligence (AI) literacy. *Computers and Composition*, 75, 102913. <https://doi.org/10.1016/j.compcom.2024.102913>

- Gke, A., Topal, D.A., Geçer, A., Dilek Eren, C. (2025). Investigating the level of artificial intelligence literacy of university students using decision trees. *Education and Information Technologies*, 30(5), 6765–6784. <https://doi.org/10.1007/s10639-024-13081-4>
- Gonsalves, C. (2025). Addressing student non-compliance in AI use declarations: Implications for academic integrity and assessment in higher education. *Assessment & Evaluation in Higher Education*, 50(3), 2415654. <https://doi.org/10.1080/02602938.2024.2415654>
- Hajihasanikhansary, L., Gilanlioglu, I. (2025). Critical thinking as a key to empowering graduate students' English learning in the AI era. *SAGE Open*, 15(2), 1399104. <https://doi.org/10.1177/21582440251399104>
- Hasan, S., Amin, A., Tanim, S.H.J., Zhu, G., Hongbin, M. (2024). Perspectives on artificial intelligence integration in higher education: Moral implications and data privacy concerns. W: *Proceedings of the IEEE International Conference on Computer and Communications (ICCC)*. <https://doi.org/10.1109/ICCC62609.2024.10942029>
- Hershkovitz, A., Tabach, M., Lurie, L. (2025). Task-centered analysis of higher education students' uses of generative artificial intelligence. *Education Sciences*, 15(12), 1676. <https://doi.org/10.3390/educsci15121676>
- Ho, N.T.T., Le, H.V. (2026). Empowered by AI: Exploring the link between literacy, self-efficacy, and career expectations. *Acta Psychologica*, 243, 106408. <https://doi.org/10.1016/j.actpsy.2026.106408>
- Hornberger, M., Bewersdorff, A., Nerdel, C. (2023). What do university students know about artificial intelligence? Development and validation of an AI literacy test. *Computers and Education: Artificial Intelligence*, 5, 100165. <https://doi.org/10.1016/j.caeai.2023.100165>
- Huaman, G.T., Tocto, P.M. (2024). Detect if an academic monograph was made by an artificial intelligence system using machine learning. W: *Proceedings of the LACCEI International Multi-conference for Engineering, Education and Technology*. <https://doi.org/10.18687/LACCEI2024.1.1.1021>
- Hyatt, J.-P.K., Bienenstock, E.J., Firetto, C.M., Woods, E.R., Robert, R.C. (2025). Using aggregated AI detector outcomes to eliminate false positives in STEM student writing. *Advances in Physiology Education*, 49(1), 23–35. <https://doi.org/10.1152/advan.00235.2024>
- Ibrahim, K.H.S., AlOtaibi, D., Sibai, F.N. (2025). The robustness of AI-classifiers in the face of AI-assisted plagiarism: The case of Turnitin AI content detector. *International Journal of Computer-Assisted Language Learning and Teaching*, 15(1), 375–428. <https://doi.org/10.4018/IJCALLT.375428>
- Jereb, E., Urh, M. (2024). The use of artificial intelligence among students in higher education. *Organizacija*, 57(4), 324–333. <https://doi.org/10.2478/orga-2024-0024>
- Jiang, Y., Xie, L., Cao, X. (2025). Exploring the effectiveness of institutional policies and regulations for generative AI usage in higher education. *Higher Education Quarterly*, 79(2), 70054. <https://doi.org/10.1111/hequ.70054>
- Jin, Y., Yan, L., Echeverria, V., Gašević, D., Martinez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>
- Karkoulouian, S., Sayegh, N., Sayegh, N. (2025). ChatGPT Unveiled: Understanding Perceptions of Academic Integrity in Higher Education: A Qualitative Approach. *Journal of Academic Ethics*, 23, 117–1188. <https://doi.org/10.1007/s10805-024-09543-6>
- Le, T.T.Q., Doan, C.T., Vu Van, T.V. (2025). University student attitudes towards artificial intelligence integration into their academic performance. *Indian Journal of Information Sources and Services*, 15(4), 03–12. <https://doi.org/10.51983/ijiss-2025.IJISS.15.4.03>
- Lee, Y.-J., Oh, J., Hong, C. (2024). Exploratory research on understanding university students' artificial intelligence literacy in a Korean university. *Online Journal of Communication and Media Technologies*, 14(3), e202440. <https://doi.org/10.30935/ojcm/14711>

- Li, S.-F., Ng, S.K.-K., Cheung, S.K.S., Lee, L.-K. (2025). Integrating AI learning in higher education: The role of educational AI tools and the need for continuous adaptation. *International Journal of Innovation and Learning*, 37(3), 338–353. <https://doi.org/10.1504/IJIL.2025.148431>
- Ling, M. (2026). Navigating AI in learning: Communication, ethics, and the student voice. W: *AI as Help and Hindrance in Education* (s. 133–155). IGI Global. <https://doi.org/10.4018/979-8-3373-6018-8.ch007>
- López, M.L., Castellanos-Ramírez, J.C., Niño-Carrasco, S.A., Parra-Encinas, K.L. (2025). A systematic review of studies on AI: Approaches from the perspective of students. *European Public and Social Innovation Review*, 10(1), 17–40. <https://doi.org/10.31637/epsir-2025-1704>
- Luckin, R., Cukurova, M., Kent, C., Du Boulay, B. (2022). Empowering educators to be AI-ready. *Computers and Education: Artificial Intelligence*, 3, 100076. <https://doi.org/10.1016/j.caeai.2022.100076>
- Luthfi, Z.F., Prasetyo, W.H., Sari, B.I. Walid, A., Muttaqin, A. (2025). Dataset of AI adoption, usage, expectations, attitudes, perceptions, and motivations for learning in higher education. *Data in Brief*, 59, 112106. <https://doi.org/10.1016/j.dib.2025.112106>
- Ma, B., Wanpen, S., Kaewmanee, T. (2025). AI detection in academic writing: A quantitative study on anxiety predictors among pre-service teachers in higher education. *Educational Sciences: Theory and Practice*, 25(1), 07–24. <https://doi.org/10.12738/jestp.2025.1.07>
- Marshik, T., McCracken, C., Kopp, B., O'Marrah, M. (2025). Student and instructor perceptions and uses of artificial intelligence in higher education. *Teaching of Psychology*, 52(1), 1299745. <https://doi.org/10.1177/009862832412999745>
- McCusker, E., Michalak, R. (2025). AI policies in U.S. universities: A critical analysis of policy gaps and library involvement. *Journal of Library Administration*, 65(3), 2560268. <https://doi.org/10.1080/01930826.2025.2560268>
- Mizumoto, A., Yasuda, S., Tamura, Y. (2024). Identifying ChatGPT-generated texts in EFL students' writing: Through comparative analysis of linguistic fingerprints. *Applied Corpus Linguistics*, 4, 100106. <https://doi.org/10.1016/j.acorp.2024.100106>
- Mukhamedkarimova, D.F., Umurkulova, M.M. (2025). Factors contributing to higher education students' acceptance of artificial intelligence: A systematic review. *European Journal of Educational Research*, 14(4), 1373–1395. <https://doi.org/10.12973/eu-jer.14.4.1373>
- Nahar, N., Howard, D., Akeren, K., Ngele, E., Hollins, P., Prescott, G. (2025). Cultivating AI literacy in higher education students: A four-step conceptual framework. W: A.I. Cristea, E. Walker, Y. Lu, O. C. Santos, S. Isotani (red.), *Artificial Intelligence in Education: 26th International Conference, AIED 2025, Proceedings, Part III* (s. 16–29). Springer. https://doi.org/10.1007/978-3-031-98420-4_2
- Nez-Valdés, K.P., Sepúlveda-Irribarra, C.A., Villegas-Dianta, C.A., Castillo-Paredes, A.J. (2025). Artificial intelligence and professor training: Analysis of student perceptions. *Formación Universitaria*, 18(4), 001–012. <https://doi.org/10.4067/S0718-50062025000400001>
- Ngoveni, M. (2025). Bridging the AI knowledge gap: The urgent need for AI literacy and institutional support. *International Journal of Technologies in Learning*, 32(2), 83–100. <https://doi.org/10.18848/2327-0144/CGP/v32i02/83-100>
- Nurtanto, M., Nawanksari, S., Sutrisno, V.L.P., Syahrudin, H., Kholifah, N., Rohmanto, D., Utami, I.S., Farid Mutohhari, F., Hamid M.A. (2025). Determinants of behavioral intentions and their impact on student performance in the use of AI technology in higher education in Indonesia: A SEM-PLS analysis based on TPB, UTAUT, and TAM frameworks. *Social Sciences and Humanities Open*, 11, 101638. <https://doi.org/10.1016/j.ssaho.2025.101638>
- Overoye, A.L., Ditta, A.S. (2025). The use of AI disclosure statements in teaching: Developing skills for psychologists of the future. *Teaching of Psychology*, 52(2), 1275664. <https://doi.org/10.1177/00986283241275664>

- Pappas, C. (2024). *7 tips to reduce cognitive overload in eLearning*. Pobrano z: <https://elearningindustry.com/7-tips-reduce-cognitive-overload-elearning> (30.03.2025).
- Patac, L.P., Patac, A.V. (2025). Using ChatGPT for academic support: Managing cognitive load and enhancing learning efficiency – A phenomenological approach. *Social Sciences & Humanities Open*, 11, 101301. <https://doi.org/10.1016/j.ssaho.2025.101301>
- Perkins, M., Roe, J., Postma, D., Mcgaughran, J., Hickerson, D. (2024). Detection of GPT-4 generated text in higher education: Combining academic judgement and software to identify generative AI tool misuse. *Journal of Academic Ethics*, 22, 493–513. <https://doi.org/10.1007/s10805-023-09492-6>
- Pisica, A.I., Ioan, R., Bucur, L.M., Popa, A., Zaharia, R.M. (2024), Romanian Students' Opinions on Implementing Artificial Intelligence in Higher Education: A Qualitative Approach. *Transformations in Business & Economics*, 23, 2(62), 21–35.
- Poh, R., Tan, B.W., Lee, H.W., Tan, K.L. (2026). Bridging the digital divide: Socioeconomic equity in AI-assisted hybrid learning. *SN Computer Science*, 7, 4593. <https://doi.org/10.1007/s42979-025-04593-y>
- Rahman, M.M., Chung, C.C., Shanana, A., Hua, S.A.S.C., Thiviyashree, Elleyajasmin (2025). Utilization of generative artificial intelligence technologies as learning tools among university students: A cross-sectional study. *International Journal of Online and Biomedical Engineering*, 21(7), 54–227. <https://doi.org/10.3991/ijoe.v21i07.54227>
- Ramos, G.J. (2025). Development and introduction of a document disclosing AI-use: Exploring self-reported student rationales for artificial intelligence use in coursework – A brief research report. *Frontiers in Education*, 10, 1654805. <https://doi.org/10.3389/educ.2025.1654805>
- Reina Marin, Y., Cruz Caro, O., Maicelo Rubio, Y.D.C., Tuesta, J.N.A., Bardales, E.S., Rituay, A.M.C., Santos, R.C. (2025b). Artificial intelligence as a teaching tool in university education. *Frontiers in Education*, 10, 1578451. <https://doi.org/10.3389/educ.2025.1578451>
- Reina Marin, Y.R., Cruz Caro, O.C., Rituay, A.M.C., Llanos, K.A.G., Perez, D.T., Bardales, E.S., Tuesta, J.N.A., Santos, R.C. (2025a). Ethical challenges associated with the use of artificial intelligence in university education. *Journal of Academic Ethics*, 23, 660–678. <https://doi.org/10.1007/s10805-025-09660-w>
- Ritter, L., Uhey, A.D., Saxena, A. (2025). Knowledge, attitudes, and practices of forestry professionals towards artificial intelligence (AI). *Forest Policy and Economics*, 173, 103626. <https://doi.org/10.1016/j.forpol.2025.103626>
- Rojas-Contreras, M., Quintana, L.C., Villamizar Carrillo, O.A., Villamizar Carrillo, L. (2025). Frameworks for artificial intelligence literacy in higher education. W: *Proceedings of the LACCEI International Multi-Conference for Engineering, Education and Technology*. <https://doi.org/10.18687/LACCEI2025.1.1.1620>
- Segovia-García, N. (2024). Optimizing student support: A review of the use of AI chatbots in higher education. *European Public and Social Innovation Review*, 9, 1–20. <https://doi.org/10.31637/epsir-2024-324>
- Sergeeva, O.V., Zheltukhina, M.R., Demir, S. (2025). From assistance to integrity: Exploring the role of AI in academic communication across Russian and Turkish campuses. *Frontiers in Communication*, 10, 1479813. <https://doi.org/10.3389/fcomm.2025.1479813>
- Shakib Kotamjani, S., Shirinova, S., Muratova, K., Sharma, M. (2025). Exploring students' perspectives on generative AI for academic purposes in Uzbekistan's higher education. W: *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3726122.3726266>
- Shen, Y., Cui, W. (2024). Perceived support and AI literacy: The mediating role of psychological needs satisfaction. *Frontiers in Psychology*, 15, 1415248. <https://doi.org/10.3389/fpsyg.2024.1415248>

- Shi, J., Liu, W., Hu, K. (2025). Exploring how AI literacy and self-regulated learning relate to student writing performance and well-being in generative AI-supported higher education. *Behavioral Sciences*, 15(5), 705. <https://doi.org/10.3390/bs15050705>
- Shubha, T.A., Vaidya, P., Ali, P.M.N., Lund, B.D. (2025). Integration of AI-based applications in education: How students feel about the ChatGPT era? *Global Knowledge, Memory and Communication*, 74(3), 227–244. <https://doi.org/10.1108/GKMC-04-2024-0227>
- Smit, M., Wagner, R.F., Bond-Barnard, T.J. (2025). Ambiguous regulations for dealing with AI in higher education can lead to moral hazards among students. *Project Leadership and Society*, 6, 100187. <https://doi.org/10.1016/j.plas.2025.100187>
- Stevkovska, M. (2024). Redesigning academic writing assignments in the age of AI-generated content. W: *Reimagining Intelligent Computer-Assisted Language Education* (s. 145–168). IGI Global. <https://doi.org/10.4018/979-8-3693-4310-4.ch007>
- Stone, B.W. (2025). Generative AI in higher education: Uncertain students, ambiguous use cases, and mercenary perspectives. *Teaching of Psychology*, 52(1), 1305398. <https://doi.org/10.1177/00986283241305398>
- Sun, Y., Yang, H., Yu, H.K., Suen, R. (2026). Exploring AI-driven learning assistance in Chinese higher education: A multidisciplinary and regional analysis of professional coursework. *Internet and Higher Education*, 62, 101075. <https://doi.org/10.1016/j.iheeduc.2026.101075>
- Torres-Gastelú, C.A., Lagunes, A., Lagunes Domínguez, P., Nava-Domínguez, B.J. (2025). Artificial intelligence in higher education: A systematic review of student impact. W: *Lecture Notes in Educational Technology* (s. 89–104). Springer. https://doi.org/10.1007/978-981-95-4689-3_6
- Triyanto, N., Handayani, R.D. (2025). Ethical considerations in the use of artificial intelligence (AI) among university students. *The New Educational Review*, 80(2), 07–25. <https://doi.org/10.15804/tner.2025.80.2.07>
- Truyol, M.E., Quezada-Espinoza, M., Zavala, G., Bascur, C. (2025). WIP: Exploring stakeholder perspectives on the integration of AI: Challenges and opportunities at a university in Chile. W: *ASEE Annual Conference and Exposition, Conference Proceedings*. <https://doi.org/10.18260/1-2--55908>
- Tsao, J. (2025). Trajectories of AI policy in higher education: Interpretations, discourses, and enactments of students and teachers. *Computers and Education: Artificial Intelligence*, 8, 100496. <https://doi.org/10.1016/j.caeai.2025.100496>
- Vanek, D., Yorulmaz, Y.I., Dobrovská, D. (2025). A holistic exploration of student attitudes toward AI use in higher education: An international comparison. *Cogent Education*, 12(1), 2571691. <https://doi.org/10.1080/2331186X.2025.2571691>
- Vázquez, J., Pérez Parejo, R., Jaraz-Cabanillas, F.J., Gómez Caballero, M. (2025). Perceptions of education students on artificial intelligence: The case of the University of Extremadura, Spain. *Educação e Pesquisa*, 51, 295334. <https://doi.org/10.1590/S1678-4634202551295334en>
- Viberg, O., Kizilcec, R.F., Jivet, I., Monés, A.M., Oh, A., Mutimukwe, C., Hrastinski, S., Scheffel, M. (2024). Cultural differences in students' privacy concerns in learning analytics across Germany, South Korea, Spain, Sweden, and the United States. *Computers in Human Behavior Reports*, 14, 100416. <https://doi.org/10.1016/j.chbr.2024.100416>
- Wang, H., Dang, A., Wu, Z., Mac, S. (2024). Generative AI in higher education: Seeing ChatGPT through universities' policies, resources, and guidelines. *Computers and Education: Artificial Intelligence*, 7, 100326. <https://doi.org/10.1016/j.caeai.2024.100326>
- Xue, Y., Chinapah, V., Zhu, C. (2025). A comparative analysis of AI privacy concerns in higher education: News coverage in China and Western countries. *Education Sciences*, 15(6), 650. <https://doi.org/10.3390/educsci15060650>
- Yang, Z., Deng, H., Jiang, N. (2025). The impact mechanism of artificial intelligence dependence on college students' innovation capability: An empirical study from China. *Frontiers in Psychology*, 16, 1732837. <https://doi.org/10.3389/fpsyg.2025.1732837>

- Zhai, C., Wibowo, S., Li, L.D. (2023). Ethical and privacy concerns in artificial intelligence dialogue systems: Do students in higher education really care about them? W: *31st International Conference on Computers in Education (ICCE 2023) Proceedings* (s. 110–120). <https://doi.org/10.58459/icce.2023.1464>
- Zhao, Z., An, Q., Liu, J. (2025). Exploring AI tool adoption in higher education: Evidence from a PLS-SEM model integrating multimodal literacy, self-efficacy, and university support. *Frontiers in Psychology*, 16, 1619391. <https://doi.org/10.3389/fpsyg.2025.1619391>

5. ZMIANY W SPOSOBIE STUDIOWANIA PO WDROŻENIU NARZĘDZI AI, WSKAŹNIK BILANSU STUDIOWANIA

OLIWIA BATOR, ANETA WITOSZ

Wskaźnik bilansu studiowania opisuje zestawienie zysków i strat w osobistej ekonomii uczenia się po włączeniu narzędzi generatywnej AI do praktyk studiowania. W logice piątego problemu badawczego analizie poddano zmiany dostrzegane przez studentów w obszarze organizacji pracy, oszczędności czasu, rozumienia treści oraz doświadczenia obciążenia i stresu, a także pojawianie się sygnałów ryzyka spadku samodzielności. W literaturze dotyczącej stosowania narzędzi generatywnej AI w szkolnictwie wyższym podkreśla się, że skutki użycia takich narzędzi, jak aplikacja ChatGPT, mają charakter wewnętrznie sprzeczny – obok korzyści w zakresie wsparcia poznawczego i usprawnienia pracy pojawiają się wątki ryzyka związanego z jakością treści, dobrostanem oraz autonomią uczenia się (Abdallah, Katmah, Khalaf, Jelinek, 2025; Shi, Yu, Dong, Chen, 2025). Jednocześnie podkreśla się znaczenie kompetencji w zakresie stosowania AI, praktyk krytycznej oceny treści oraz norm jawności jako kluczowych warunków odpowiedzialnego wykorzystywania narzędzi generatywnych w edukacji i badaniach naukowych (Miao, Holmes, 2023).

W tej części przedstawiono rekonstrukcję kategorii zmian na podstawie odpowiedzi otwartych (kodowanie semantyczne), jakościową agregację stylów ich opisu oraz weryfikację zależności między deklaracją praktyk weryfikacyjnych a stylem opisu zmiany, zgodnie z hipotezą H3.


5.1. Deklarowane zmiany w studiowaniu po wprowadzeniu narzędzi AI

Pierwszym etapem analizy była rekonstrukcja treści zmian deklarowanych przez studentów w odpowiedziach na pytanie otwarte dotyczące tego, co zmieniło się w sposobie studiowania po wdrożeniu narzędzi AI. Zastosowano kodowanie semantyczne (treściowe), w którym pojedyncza wypowiedź mogła otrzymać więcej niż jeden kod, jeśli zawierała kilka wątków (np. oszczędność czasu i lepsze rozumienie). W konsekwencji suma punktów procentowych nie musi wynosić 100% (tabela 3.5.1 i wykres 3.5.1).

Tabela 3.5.1. Zmiany w studiowaniu po wdrożeniu narzędzi AI – kodowanie semantyczne, N = 457

Kategoria	N	%
Oszczędność czasu i efektywność	187	40,9
Brak zmian	142	31,1
Lepsze rozumienie i uczenie aktywne	66	14,4
Lepsza organizacja pracy	47	10,3
Redukcja stresu	11	2,4
Ryzyko spadku samodzielności	4	0,9

Źródło: badania własne.



Wykres 3.5.1. Zmiany w studiowaniu po wdrożeniu narzędzi AI, N = 457

Źródło: badania własne.

Analiza. Z punktu widzenia korzyści efektywnościowych najczęściej studenci opisywali AI jako narzędzie skracające czas pracy i nauki, przyspieszające wykonanie zadań oraz ułatwiające opracowanie materiałów. Druga w kolejności kategoria dotyczyła braku zmian, co można interpretować jako brak odczuwalnego wpływu narzędzi AI na studiowanie lub niewielką intensywność użycia. Istotnym, choć mniej licznym nurtem wypowiedzi było lepsze rozumienie i uczenie aktywne: narzędzia AI były przedstawiane jako wsparcie wyjaśniania trudnych zagadnień, porządkowania wiedzy i budowania zrozumienia. Oddzielny komponent stanowiły wypowiedzi o lepszej organizacji pracy (tworzenie notatek, porządkowanie informacji, przygotowanie do zaliczeń), a także redukcja stresu rozumiana jako obniżenie napięcia związanego z planowaniem i uczeniem się. Najbardziej wrażliwą interpretacyjnie kategorią było ryzyko spadku samodzielności: pojawiały się sygnały wskazujące na ograniczenie wysiłku poznawczego, spadek zaangażowania oraz tendencję do wyręczania w działaniach, które wcześniej wymagały samodzielnej pracy.

Interpretacja i weryfikacja. W literaturze badacze potwierdzają, że korzyści w zakresie oszczędności czasu i organizacji pracy należą do najczęściej raportowanych efektów użycia aplikacji ChatGPT w edukacji wyższej, ale równolegle wskazuje się koszty w postaci ryzyka spadku samodzielności, napięć związanych z jakością treści oraz konsekwencji dla dobrostanu i obciążenia poznawczego (Abdallah i in., 2025; Shi i in., 2025). Badania empiryczne podkreślają również, że wysoka użyteczność narzędzia w wymiarze szybkości działania może sprzyjać utrwalaniu nawykowego korzystania oraz skłonności do nadmiernego polegania na systemie, nawet przy jednoczesnej świadomości jego ograniczeń (Yeung, Chow, Wong, Lau, 2026). W kontekście niniejszych danych oznacza to, że efektywność ma charakter dwoisty: może odnosić się do usprawnienia procesu uczenia się, ale może też oznaczać wyłącznie skrócenie drogi do wyniku, co wymaga dalszego różnicowania w analizie jakościowej.

5.2. Styl opisu zmiany, agregacja jakościowa wynikająca ze stosowania narzędzi AI

Drugim etapem analizy była jakościowa agregacja stylu, w jakim respondenci opisywali doświadczaną zmianę. Celem było rozróżnienie narracji koncentrujących się na samym procesie uczenia się od tych, które akcentowały przede wszystkim oszczędność czasu i sprawność działania.


Każdej wypowiedzi przypisano jeden dominujący styl opisu, odpowiadający jej głównemu sensowi. Wyodrębniono styl instrumentalny – w którym narzędzia AI przedstawiane są jako instrumenty przyspieszające pracę i skracające czas nauki – oraz styl refleksyjny, gdzie akcent pada na wsparcie rozumienia, porządkowanie treści i organizację procesu uczenia się.

Dodatkowo wyróżniono kategorie obejmujące wypowiedzi trudne do jednoznacznej klasyfikacji („inne lub brak danych”), deklaracje braku wpływu („brak zmian”), sygnały ryzyka ograniczenia samodzielności oraz odniesienia do redukcji stresu (tabela 3.5.2 i wykres 3.5.2).

Tabela 3.5.2. Styl opisu zmiany w studiowaniu, agregacja jakościowa wynikająca ze stosowania AI, N = 457

Kategoria	N	%
Inne lub brak danych	187	40,9
Głównie tempo i oszczędność czasu	142	31,1
Refleksyjne, organizacja i rozumienie	66	14,4
Brak zmian	47	10,3
Ryzyko spadku samodzielności	11	2,4
Redukcja stresu	4	0,9

Źródło: badania własne.



Wykres 3.5.2. Styl opisu zmiany w studiowaniu po wdrożeniu narzędzi AI, N = 457

Źródło: badania własne.

Analiza. Wyniki badań ujawniają współwystępowanie dwóch dominujących sposobów opisu zmiany: instrumentalnego – koncentrującego się na przyspieszeniu pracy i oszczędności czasu – oraz refleksyjnego, w którym narzędzia AI wspierają organizację uczenia się i pogłębione rozumienie treści.

Relatywnie wysoki udział kategorii „inne lub brak danych” wynika ze specyfiki odpowiedzi otwartych. Część wypowiedzi ma charakter skrótowy („ułatwia”, „pomaga”) i nie dostarcza wystarczających przesłanek do jednoznacznego przypisania ich do stylu instrumentalnego lub refleksyjnego.

Obecność kategorii „ryzyko spadku samodzielności” pokazuje natomiast, że część badanych dostrzega potencjalne konsekwencje nadmiernego polegania na narzędziach AI. W tych wypowiedziach narzędzie nie tylko wspiera, lecz może również ograniczać inicjatywę i wysiłek poznawczy, przesuując praktykę studiowania w kierunku zastępowania uczenia się, a nie wspomagania działania.

Kategoria „redukcja stresu”, choć nieliczna, wprowadza dodatkowy wymiar interpretacyjny. W niektórych narracjach narzędzia AI pojawiają się jako czynnik obniżający napięcie związane z organizacją uczenia się i realizacją zadań, co wskazuje na jej potencjalny wpływ na dobrostan studenta.

Interpretacja. Układ ten można odczytać jako istniejące napięcie między użyciem narzędzi AI wspierającym proces uczenia się a użyciem nastawionym przede wszystkim na szybkie uzyskanie rezultatu. Literatura przeglądowa wskazuje, że obok korzyści związanych ze sprawnością działania i wsparciem poznawczym pojawia się także ryzyko dotyczące ograniczenia samodzielności, obniżenia jakości treści oraz sposobu praktykowania uczenia się (Abdallah i in., 2025; Shi i in., 2025).

Badania empiryczne pokazują ponadto, że zysk czasu może wzmacniać rutynowe korzystanie z narzędzia oraz rosnące zaufanie do jego odpowiedzi w trybie zadaniowym, co sprzyja nadmiernemu poleganiu na systemie (Yeung i in., 2026).

W kontekście niniejszych wyników oznacza to, że wskaźnik efektywnościowy nie ma charakteru jednowymiarowego. Obejmuje zarówno korzyści sprawnościowe, jak i jakościowe (rozumienie, organizację procesu uczenia się), ale też potencjalne koszty w postaci osłabienia samodzielności.

5.3. Weryfikacja a styl opisu zmiany wynikającej ze stosowania narzędzi AI


Trzecim etapem analizy była weryfikacja hipotezy H3, zgodnie z którą deklarowanie praktyk weryfikacji treści generowanych przez narzędzia AI wiąże się z bardziej refleksyjnym opisem zmian w studiowaniu oraz z wyższą oceną użyteczności AI jako narzędzia wspierającego uczenie się, w porównaniu z narracjami koncentrującymi się wyłącznie na przyspieszeniu pracy.

W tym etapie analizy sprawdzono tę część hipotezy, która dotyczy związku między deklaracją weryfikacji a stylem opisu zmiany. Analiza objęła podzbiór danych zawierający dwie kategorie deklaracji weryfikacji („tak”, „nie”) oraz dwa dominujące style opisu: „refleksyjne: organizacja i rozumienie” oraz „głównie tempo i oszczędność czasu”. Łączna liczebność analizowanego podzbioru wyniosła $N = 174$ (tabela 3.5.3 i wykres 3.5.3).

Tabela 3.5.3. Weryfikacja informacji a styl opisu zmiany wynikającej ze stosowania narzędzi AI

Weryfikacja	Refleksyjne, organizacja i rozumienie	Głównie tempo i oszczędność czasu
Tak	43	108
Nie	10	13

Źródło: badania własne.



Wykres 3.5.3. Weryfikacja informacji a styl opisu zmiany uwarunkowany korzystaniem z narzędzi AI, N = 174

Źródło: badania własne.

Ze względu na niewielkie liczebności w części komórek zastosowano dokładny test Fishera, który nie wykazał istotnej statystycznie zależności ($p = 0,1524$). Wielkość efektu była mała (Cramér $V = 0,092$).

Odsetek wypowiedzi refleksyjnych był niższy w grupie osób deklarujących weryfikację informacji i wynosił 28,5%, podczas gdy w grupie osób niedeklarujących weryfikacji osiągnął 43,5%. Różnica między grupami wyniosła zatem 15 pp. Wynik ten nie osiągnął jednak poziomu istotności statystycznej, co oznacza, że w analizowanym podzbiorze hipoteza o związku między weryfikacją a refleksyjnością opisu zmian nie znajduje potwierdzenia.

Wynik ten sugeruje, że relacja między praktykami weryfikacyjnymi a sposobem korzystania z narzędzi AI może mieć charakter wieloczynnikowy i ujawniać się w zależności od kontekstu zadaniowego oraz sposobu rozumienia samej weryfikacji. Literatura podkreśla, że wykorzystanie dużych modeli językowych w edukacji wiąże się z równoczesnym współwystępowaniem korzyści i ryzyka, a praktyki krytycznej oceny treści zależą od typu zadań, norm instytucjonalnych oraz poziomu wsparcia dydaktycznego (Shi i in., 2025; Abdallah i in., 2025). Badania wskazujące na wysokie zaufanie do aplikacji ChatGPT oraz możliwość nadmiernego polegania na nim w szkolnictwie wyższym pokazują ponadto, że

sama deklaracja „weryfikacji” nie musi oznaczać refleksyjnego zakorzenienia w procesie uczenia się (Yeung i in., 2026).

W konsekwencji wyniki weryfikacji hipotezy H3 wskazują na brak prostego związku między deklarowaną weryfikacją a stylem opisu zmiany. Wzmacnia to potrzebę interpretowania praktyk weryfikacyjnych w powiązaniu z typem użycia narzędzi AI (wspierającym lub zastępującym działanie) oraz kontekstem dydaktycznym.

Podsumowanie. Wskaźnik efektywnościowy pokazuje, że po wdrożeniu narzędzi generatywnej AI studenci najczęściej dostrzegają korzyści w postaci oszczędności czasu i wzrostu sprawności działania – jest to dominujący wymiar deklarowanych zmian. Równolegle pojawiają się jednak wypowiedzi wskazujące na lepsze rozumienie treści, uczenie aktywne oraz poprawę organizacji pracy, co sugeruje, że część badanych wykorzystuje narzędzia AI w trybie wspierającym proces uczenia się. W danych obecny jest także wątek dobrostanowy w postaci redukcji stresu, choć występuje rzadziej niż korzyści sprawnościowe. Jednocześnie odnotowano sygnały ryzyka spadku samodzielności, które mimo niewielkiej liczebności mają istotne znaczenie interpretacyjne, ponieważ dotyczą jakości uczenia się i granicy między wsparciem a wyręczaniem.

Kumulacja (agregacja) jakościowa stylu opisu zmiany ujawniła współwystępowanie dwóch dominujących narracji: instrumentalnej, skoncentrowanej na szybkości i efektywności, oraz refleksyjnej, akcentującej organizację i rozumienie. Weryfikacja hipotezy H3, oparta na podziale deklaracji weryfikacji na „tak” i „nie”, nie wykazała istotnego statystycznie związku między deklarowaną weryfikacją a stylem opisu zmiany, a siła zależności była mała.

Wyniki te wskazują, że relacja między praktykami weryfikacyjnymi a sposobami korzystania z narzędzi AI nie ma charakteru prostego i może zależeć od kontekstu zadaniowego oraz od sposobu rozumienia samej weryfikacji. Tym samym rozdział 3.5 zamyka część sprawozdawczą wskaźnika efektywnościowego i tworzy podstawę do dalszej syntezy problemów badawczych oraz formułowania rekomendacji dotyczących wspierania refleksyjnego użycia AI w procesie studiowania.

Bibliografia

- Abdallah, N., Katmah, R., Khalaf, K., Jelinek, H.F. (2025). Systematic review of ChatGPT in higher education: Navigating impact on learning, wellbeing, and collaboration. *Social Sciences & Humanities Open*, 12, 101866. <https://doi.org/10.1016/j.ssaho.2025.101866>
- Miao, F., Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO. <https://doi.org/10.54675/EWZM9535>
- Shi, Y., Yu, K., Dong, Y., Chen, F. (2025). Large language models in education: a systematic review of empirical applications, benefits, and challenges. *Computers and Education: Artificial Intelligence*, 10, 100529. <https://doi.org/10.1016/j.caeai.2025.100529>
- Yeung, L.K.C., Chow, D.P.L., Wong, P.H., Lau, S.S.S. (2026). In ChatGPT they trust: a study of students' perceptions and misuse of ChatGPT in higher education. *AI and Ethics*, 6, 11. <https://doi.org/10.1007/s43681-025-00855-w>

CZĘŚĆ CZWARTA

SYNTEZA PIĘCIU PROBLEMÓW BADAWCZYCH ORAZ REKOMENDACJE WDROŻENIOWE DOTYCZĄCE STOSOWANIA GENERATYWNEJ AI PRZEZ STUDENTÓW

WALDEMAR LIB, WOJCIECH WALAT, TOMASZ WARZOCHA

Niniejsza synteza domyka część sprawozdawczą, integrując ustalenia z pięciu rozdziałów analitycznych w logice pięciu problemów badawczych. Tekst łączy opis wyników z weryfikacją w świetle badań porównawczych publikowanych w wysoko ocenianych czasopismach oraz z dokumentami rekomendacyjnymi dla szkolnictwa wyższego. Na końcu wskazano luki poznawcze oraz kierunki kolejnych badań.

Problem 1: narzędzia AI i tendencja do ich subskrypcji – wskaźnik instrumentalny

Wyniki wskazują koncentrację użycia wokół dominującego narzędzia konwersacyjnego, przy relatywnie mniejszej dywersyfikacji pozostałych rozwiązań. Oznacza to, że w praktykach studiowania aplikacja generatywnej AI funkcjonuje często jako domyślna infrastruktura pracy z treścią, a nie jako zestaw wyspecjalizowanych narzędzi dobieranych zadaniowo. Taki wzorec jest spójny z badaniami porównawczymi, w których aplikacja ChatGPT pozostaje narzędziem pierwszego wyboru, a użycie i postawy różnicują się w zależności od kierunku (pola) i poziomu studiów (Stöhr, Ou, Malmström, 2024).

Wersja (warstwa) subskrypcyjna ma oczywiście znaczenie dostępnościowe, lecz sama w sobie nie przesądza o wielości zastosowań danej narzędzi. W badanej próbie związek między subskrypcją a różnorodnością repertuaru zadań okazał się słaby, co sugeruje, że o wzorcach użycia w większym stopniu decydują nawyk, oczekiwana użyteczność, kontekst zadania i presja czasu. Warto zwrócić uwagę, iż w przypadku subskrypcji studenci korzystają z wersji najtańszych. Być może gdyby te narzędzia były dostępne nieodpłatnie, ten związek okazałby się silny. W przypadku, kiedy za każde narzędzie należy dokonać opłaty, nawet najmniejszej, studenci wybierają najprostsze rozwiązania spełniające podstawo-

we potrzeby. Tę wieloczynnikowość potwierdzają badania oparte na UTAUT2, w których nawyk i oczekiwana wydajność należą do najsilniejszych powodów (predyktorów) użycia narzędzi ChatGPT (Strzelecki, 2024), oraz przeglądy literatury wskazujące na złożone konfiguracje determinant włączania (adopcji) do procesów uczenia się przez studentów (Baig, Yadegaridehkordi, 2024).

Problem 2: obszary dydaktyczne i zadaniowe użycia narzędzi AI – wskaźnik funkcjonalny

Wskaźnik funkcjonalny pokazuje dominację zastosowań związanych z pracą nad treścią: opracowanie prezentacji, przygotowanie do zaliczeń i egzaminów, wyjaśnianie pojęć, streszczanie i porządkowanie materiału, opracowywanie notatek, wsparcie językowe (tłumaczenie tekstów z języków obcych), przekład (upraszczanie) trudnych zdaniem studentów materiałów naukowych na język prosty – zbliżony do popularnonaukowego, a być może nawet do potocznego, głębsza interpretacji pojęć, których standardowy przekaz akademicki nie wyjaśnia w sposób wystarczająco zrozumiały, inspiracja, pisanie i redakcja tekstów oraz wyszukiwanie informacji i źródeł. Oznacza to przesunięcie części kosztów poznawczych¹⁴ i organizacyjnych na narzędzie, co wzmacnia sprawność wejścia w temat i selekcji informacji. Wzorzec ten jest zgodny z wynikami ogólnymi, w których studenci najczęściej deklarują wykorzystanie: burzy mózgów, streszczanie i wyszukiwanie artykułów (Ravšelj i in., 2025).

Ciekawą formą wykorzystania AI przez studentów podczas przygotowywania się do egzaminów jest opracowywanie testów i quizów jako materiałów do samokształcenia i utrwalania nabytej wiedzy.

Jednocześnie literatura empiryczna akcentuje kluczowe wsparcie poznawcze, które może przechodzić w substytucję pracy poznawczej¹⁵, zwłaszcza gdy zadania i ocenianie koncentrują się na „produkcji” tekstowym. Systematyczne przeglądy zastosowań LLM w edukacji wskazują jako główne rodzaje ryzyka m.in. nadmierną zależność od AI, kwestie sprawiedliwości oceniania i prywatności, a jako rekomendowany kierunek – wzmacnianie ocen procesowych i autentycznych (Shi, Yu, Dong, Chen, 2025).

Problem 3: weryfikacja treści i strategie krytyczne stosowania narzędzi AI – wskaźnik aksjologiczno-epistemiczny

Wskaźnik aksjologiczno-epistemiczny ujawnia znaczącą obecność deklaracji weryfikowania informacji oraz zróżnicowany repertuar strategii: *cross-checking*

¹⁴ Koszt poznawczy to koszt wynikający z rozbieżnych sposobów myślenia. Mogą to być koszty wynikające z konfliktów bazujących na niezgodnych światopoglądach lub koszty wynikające z uczenia się w celu zbliżenia odmiennych wzorców myślowych i wiedzy.

¹⁵ Subskrypcja pracy poznawczej – działanie oparte na płatnym dostępie do aplikacji GenAI, dzięki której człowiek czuje odciążenie poznawcze.

w internecie, praca ze źródłami i literaturą, porównywanie odpowiedzi, odwołanie do wiedzy własnej, a czasem konsultacje z prowadzącymi. Jednocześnie istnieje grupa studentów, którzy nie weryfikują treści, uzasadniając to lenistwem, zaufaniem do narzędzia, prostotą zadań lub presją czasu. Takie działanie jest wątpliwe z punktu widzenia dydaktycznego, ponieważ pokazuje, że krytycyzm poznawczy nie jest automatyczną konsekwencją użycia generatywnej AI, lecz wymaga socjalizacji akademickiej i osadzenia w zadaniach.

Wyniki badań wskazują, że nawet świadomość halucynacji nie musi redukować zależności od narzędzia, jeśli jest ono używane w trybie odciążenia poznawczego (podania gotowej odpowiedzi), a wysiłek związany z weryfikacją jest postrzegany jako zbyt wysoki. Analiza nadużyć i zaufania do aplikacji ChatGPT pokazuje mechanizmy utrwalania zaufania i tzw. *automation bias*¹⁶ w warunkach presji efektywności (Yeung, Chow, Wong, Lau, 2026).

Wyniki przeprowadzonych badań pokazały, że przynajmniej w pewnej grupie studentów są oni nadal krytyczni wobec materiałów wygenerowanych przez sztuczną inteligencję: niektórzy starają się reagować promptami zwrotnymi, wierząc, że mogą zmotywować AI do większej „prawdopodobności”. Brak weryfikacji odpowiedzi AI można interpretować jako przejaw ekonomii wysiłku¹⁷, gdzie weryfikacja jest kosztem, który bywa pomijany w zadaniach postrzeganych jako niskiego ryzyka.

Problem 4: jawność użycia narzędzi AI, obawy i wsparcie uczelni w tym zakresie – wskaźnik etyczno-instytucjonalny

Wyniki badań wskazują, że jawność użycia AI często jest obciążona obawą, która koncentruje się wokół lęku przed naruszeniem integralności dotychczasowej kultury akademickiej, ryzyka sankcji oceniania, przewidywanych negatywnych reakcji kadry oraz niepewności zasad etycznych w tym zakresie. Oznacza to, że kluczowy problem ma charakter normatywny i instytucjonalny, a nie wyłącznie technologiczny. Badania jakościowe dotyczące integralności akademickiej potwierdzają ambiwalencję postaw, w której korzyści współwystępują z obawami o normy i sankcje, a niejednoznaczność granic dopuszczalnego użycia wzmacnia napięcia etyczno-moralne (Karkoulis, Sayegh, Sayegh, 2025).

W obszarze wsparcia instytucjonalnego pojawia się typowa luka wdrożeniowa polegająca na tym, że mimo istnienia uczelnianych systemów wdrażania AI (polityki wdrożeniowe) mogą one pozostawać słabo rozpoznawalne przez

¹⁶ *Automation bias* – ludzka skłonność do nadmiernego polegania na zautomatyzowanych systemach i ufania sugestiom algorytmów bardziej niż własnemu osądowi, nawet gdy dowody przeczą twierdzeniom maszyny.

¹⁷ Ekonomia wysiłku – ograniczenie własnego wkładu intelektualnego w analizę i interpretację otrzymanych odpowiedzi z aplikacji GenAI – poleganie na pierwszej odpowiedzi na prompt.

środowisko akademickie lub niespójnie egzekwowane. Analiza uczelnianych strategii wdrożeniowych pokazuje, że instytucje najczęściej akcentują dotychczasową integralność akademicką, projektowanie systemów oceniania i rozwój kompetencji, ale wdrożenia różnią się spójnością, a luki dotyczą m.in. prywatności i równości dostępu do stosowania narzędzi generatywnej AI (Jin, Yan, Echeverria, Gašević, Martinez-Maldonado, 2025). Dodatkowo badania percepcji kosztów i korzyści wskazują różnice postaw między użytkownikami i nie-użytkownikami, co sugeruje potrzebę segmentacji wsparcia i komunikacji w zakresie dopuszczalnych rozwiązań w zakresie stosowania narzędzi generatywnej AI (Blahopoulou, Ortiz-Bonnin, 2025).

Zaobserwowano ze strony badanych zaskakująco niską potrzebę szkoleń w zakresie weryfikacji i wiarygodności uzyskiwanych informacji od narzędzi AI (12,0%), promptowania (7,7%) oraz bezpieczeństwa danych (4,4%). Może to być spowodowane brakiem wiedzy u studentów o możliwościach wykorzystania narzędzi AI. Jej używanie przez badanych ogranicza się do podstawowych funkcji lub cechuje ich nadmierna pewność, że wiedzą wszystko na jej temat i wykorzystują optymalnie jej możliwości.

Problem 5: zmiany w sposobie studiowania z wykorzystaniem narzędzi AI – wskaźnik efektywnościowy

Wskaźnik efektywnościowy pokazuje dominację korzyści w postaci oszczędności czasu i lepszej organizacji pracy, przy współwystępowaniu wątków lepszego rozumienia oraz redukcji stresu, a rzadziej sygnałów ryzyka spadku samodzielności. Wynik ten jest zgodny z przeglądami badań, które opisują równoczesność korzyści sprawnościowych i ryzyka związanego z niezależnością uczenia się oraz pojawiającym się technostresem (Abdallah, Katmah, Khalaf, Jelinek, 2025).

Kluczowym mechanizmem pozostaje ekonomia uczenia się: część kosztów poznawczych i organizacyjnych jest delegowana na narzędzie, co zwiększa sprawność, ale może obniżać sprawczość poznawczą – jeśli zadania i ocenianie nie wymagają rekonstrukcji rozumowania, pracy ze źródłami i refleksji, pojawia się tu tzw. dług poznawczy¹⁸. Badania nad nadużyciami pojawiającymi się w związku ze stosowaniem aplikacji ChatGPT wskazują, że zysk czasu może stać się dominującą wartością, a wówczas rośnie ryzyko użycia substytucyjnego (Yeung i in., 2026).

¹⁸ Dług poznawczy – korzystanie z generatywnej AI jest szybkie i wygodne, ale w dłuższej perspektywie może skutkować osłabieniem zdolności analitycznych i refleksyjnych, spadkiem pamięci operacyjnej i uwagi, a w skrajnych przypadkach również mniejszą sprawczością intelektualną (<https://www.wz.uni.lodz.pl/zespol-ekspertow/komentarze/komentarz/cena-wygody-i-dlug-poznawczy-czyli-o-tym-jak-sztuczna-inteligencja-wplywa-na-nasz-mozg>).

Rekomendacje wdrożeniowe wynikające z przeprowadzonych badań

1. Wbudowanie weryfikacji w ocenianie prac: procedura sprawdzania źródeł, porównanie odpowiedzi i uzasadnienie wyboru informacji jako elementy kryteriów oceny.
2. Modyfikacja sposobu oceniania: większy udział form procesowych i autentycznych (*portfolio, log pracy*¹⁹, uzasadnienie decyzji, obrona ustna, decyzje poznawcze itp.) zamiast koncentracji na produkcie tekstowym.
3. Polityka jawności: prosta deklaracja użycia narzędzi AI w pracach (do czego użyto, w jakim zakresie, jak zweryfikowano odpowiedzi, odpowiedzialność za wygenerowane treści).
4. *AI literacy* modułowe: różnicowanie programów według dyscyplin i etapów studiów, z naciskiem na weryfikację odpowiedzi, etykę wykorzystania, prywatność i równość dostępu.
5. Komunikacja i spójność wdrożenia: zasady i praktyki powinny być obecne na poziomie kursów i kryteriów oceny, a nie wyłącznie w dokumentach centralnych.

Luki poznawcze w przeprowadzonych badaniach

1. Brak miary intensywności i częstotliwości użycia narzędzi AI: obecne dane ujmują funkcje i racjonalizację, ale słabiej różnicują profile użycia.
2. Deklaracja weryfikacji nie opisuje jakości weryfikacji: potrzebne są wskaźniki proceduralne, co i jak było sprawdzane oraz jakie źródła wykorzystano.
3. Brak jednoznacznej operacjonalizacji użycia wspierającego i substytucyjnego na poziomie konkretnego zadania.
4. Brak pomiaru efektów uczenia się: dane są percepcyjne i powierzchowne (często deklaratywne), a potrzebne są miary transferu, trwałości uczenia się i jakości argumentacji.
5. Luka instytucjonalna: brakuje mapowania konkretnych form wsparcia i kanałów komunikacji oraz rozbieżności między polityką a doświadczeniem studentów.

Kierunki kolejnych badań wykorzystania narzędzi AI w praktykach studiowania

1. Badania longitudinalne w kilku falach, aby uchwycić zmianę praktyk, narastanie nawyku i przesunięcie od użycia eksperymentalnego do rutynowego (por. potrzeby wskazywane w przeglądach).

¹⁹ Log pracy – rejestrowanie czasu pracy, zwane również śledzeniem czasu pracy lub *Time Tracking*, odnosi się do procesu dokumentowania ilości czasu, jaki pracownik poświęca na wykonanie określonych zadań, projektów lub działalności.

2. Badania zadaniowe z protokołami pracy: analiza konkretnych zadań wraz z logami promptów, procedurą weryfikacji i oceną jakości produktu oraz procesu.

3. Segmentacja użytkowników: typologie profili (refleksyjny, efektywnościowy, substytucyjny) i test moderacji, który sprawdza, na ile są one modyfikowane przez obszar studiów i formy oceniania.

4. Badania porównawcze polityk i praktyk uczelnianych: zestawienie tego, co instytucje deklarują, z tym, co studenci rozpoznają i jak to wpływa na jawność, obawy i weryfikację rozwiązań z zakresu zastosowań AI (Jin i in., 2025).

5. Eksperymenty dydaktyczne: weryfikacja zakresu, w jakim wbudowanie procedur sprawdzania wykorzystania narzędzi AI w kryteria oceny podnosi jakość uczenia się bez obniżenia motywacji i dobrostanu.

Bibliografia

- Abdallah, N., Katmah, R., Khalaf, K., Jelinek, H.F. (2025). Systematic review of ChatGPT in higher education: Navigating impact on learning, wellbeing, and collaboration. *Social Sciences & Humanities Open*, 12, 101866. <https://doi.org/10.1016/j.ssaho.2025.101866>
- Baig, M.I., Yadegaridehkordi, E. (2024). ChatGPT in the higher education: A systematic literature review and research challenges. *International Journal of Educational Research*, 127, 102411. <https://doi.org/10.1016/j.ijer.2024.102411>
- Blahopoulou, J., Ortiz-Bonnin, S. (2025). Student perceptions of ChatGPT: benefits, costs, and attitudinal differences between users and non-users toward AI integration in higher education. *Education and Information Technologies*, 30, 19741–19764. <https://doi.org/10.1007/s10639-025-13575-9>
- Jin, Y., Yan, L., Echeverria, V., Gašević, D., Martinez-Maldonado, R. (2025). Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. *Computers and Education: Artificial Intelligence*, 8, 100348. <https://doi.org/10.1016/j.caeai.2024.100348>
- Karkoulis, S., Sayegh, N., Sayegh, N. (2025). ChatGPT Unveiled: Understanding Perceptions of Academic Integrity in Higher Education: A Qualitative Approach. *Journal of Academic Ethics*, 23, 1171–1188. <https://doi.org/10.1007/s10805-024-09543-6>
- Ravšelj, D., Keržič, D., Tomažević, N., Umek, L., Brezovar, N., Iahad, N.A., i in. (2025). Higher education students' perceptions of ChatGPT: A global study of early reactions. *PLoS ONE*, 20(2), e0315011. <https://doi.org/10.1371/journal.pone.0315011>
- Shi, Y., Yu, K., Dong, Y., Chen, F. (2025). Large language models in education: a systematic review of empirical applications, benefits, and challenges. *Computers and Education: Artificial Intelligence*, 10, 100529. <https://doi.org/10.1016/j.caeai.2025.100529>
- Stöhr, C., Ou, A.W., Malmström, H. (2024). Perceptions and usage of AI chatbots among students in higher education across genders, academic levels and fields of study. *Computers and Education: Artificial Intelligence*, 7, 100259. <https://doi.org/10.1016/j.caeai.2024.100259>
- Strzelecki, A. (2024). Students' Acceptance of ChatGPT in Higher Education: An Extended Unified Theory of Acceptance and Use of Technology. *Innovative Higher Education*, 49, 223–245. <https://doi.org/10.1007/s10755-023-09686-1>
- Yeung, L.K.C., Chow, D.P.L., Wong, P.H., Lau, S.S.S. (2026). In ChatGPT they trust: a study of students' perceptions and misuse of ChatGPT in higher education. *AI and Ethics*, 6, 11. <https://doi.org/10.1007/s43681-025-00855-w>

Aneks – słowniczek pojęć związanych z posługiwania się narzędziami GenAI

AI integrity – odnosi się do etycznego opracowywania, wdrażania i wykorzystywania systemów sztucznej inteligencji gwarantującego, że są one godne zaufania, przejrzyste, sprawiedliwe i zgodne z wartościami ludzkimi. Obejmuje ona zarówno niezawodność techniczną modelu AI (zapewniającą, że działa on zgodnie z zamierzeniami), jak i implikacje etyczne, prawne i społeczne.

Automation bias (błąd automatyzacji) – ludzka skłonność do nadmiernego polegania na zautomatyzowanych systemach i ufania sugestiom algorytmów bardziej niż własnemu osądowi, nawet gdy dowody przeczą twierdzeniom maszyny.

Dług poznawczy – korzystanie z generatywnej SI jest szybkie i wygodne, ale w dłuższej perspektywie może skutkować osłabieniem zdolności analitycznych i refleksyjnych, spadkiem pamięci operacyjnej i uwagi, a w skrajnych przypadkach również mniejszą sprawczością intelektualną (<https://www.wz.uni.lodz.pl/zespol-ekspertow/komentarze/komentarz/cena-wygody-i-dlug-poznawczy-czyli-o-tym-jak-sztuczna-inteligencja-wplywa-na-nasz-mozg>).

Ekonomia wysiłku – ograniczenie własnego wkładu intelektualnego w analizę i interpretację otrzymanych odpowiedzi z aplikacji GenAI – poleganie na pierwszej odpowiedzi na prompt.

Epistemic vigilance (czujność epistemiczna) – opisuje szereg adaptacji psychologicznych, które chronią przed tymi manipulacjami, w tym tendencje do oceniania informacji społecznych na podstawie uczciwości lub kompetencji źródła lub samej treści informacji.

Falszywy pozytywny – błędne przypisanie autorstwa narzędziom AI.

Human centred – podejście projektowe i filozofia działania, która stawia potrzeby, emocje, zachowania i doświadczenia ludzi w centrum uwagi.

Koszt poznawczy – koszt wynikający z rozbieżnych sposobów myślenia. Mogą to być koszty wynikające z konfliktów bazujących na niezgodnych światopoglądach lub koszty wynikające z uczenia się w celu zbliżenia odmiennych wzorców myślowych i wiedzy.

Log pracy – rejestrowanie czasu pracy, zwane również śledzeniem czasu pracy lub *Time Tracking*, odnosi się do procesu dokumentowania ilości czasu, jaki pracownik poświęca na wykonanie określonych zadań, projektów lub działalności.

Multimodalna literacy – mechanizm adaptacyjny ujmowany jako narzędzie mediacji, który wsparcie ze strony uczelni przekłada na rzeczywiste zaangażowanie studenta. Student nabywa zdolność do poruszania się w środowisku informacyjnym. Zdobywa pewność siebie dzięki wsparciu instytucjonalnym.

Obciążenie poznawcze – wysiłek umysłowy podejmowany podczas uczenia się, rozwiązywania problemów lub wykonywania zadań. Wiąże się z całkowitym wykorzystywaniem pamięci operacyjnej podczas procesów myślowych. Przypisywane jest teorii Johna Swellera, australijskiego psychologa edukacyjnego.

Przeładowanie informacyjne (*information overload*) – psychiczny stan charakteryzujący jednostkę, która przeżywa stres – negatywne odczucia spowodowane faktem, że rozwiązywanie problemów zawodowych lub osobistych jest istotnie utrudnione z powodu nadmiaru dostępnych informacji.

Subskrypcja pracy poznawczej – działanie oparte na płatnym dostępie do aplikacji GenAI, dzięki której człowiek czuje odciążenie poznawcze.

Technologiczne rusztowanie (*scaffolding*) – sposób wykorzystania narzędzi AI jako **wsparcia poznawczego**, które pomagają studentowi wykonywać zadania, ale go nie zastępuje. Narzędzia AI pełnią rolę **spersonalizowanego korepetytora**, który: tłumaczy trudne pojęcia, generuje pytania testowe, dostosowuje poziom wyjaśnień do użytkownika. To pokazuje, że AI działa jak „**rusztowanie**” wokół procesu uczenia się – tak jak w budownictwie rusztowanie nie jest celem samym w sobie, tylko wspiera konstrukcję bez zastępowania własnego myślenia (tu: proces uczenia się), może być stopniowo „zdejmowane”, gdy kompetencje rosną. Zatem narzędzia AI przejmują część funkcji, które wcześniej pełnił nauczyciel: tłumaczą, naprowadzają, strukturyzują wiedzę, dostosowują poziom trudności.

Technostres – negatywne obciążenie psychiczne i poznawcze wynikające z korzystania z technologii, przejawiające się m.in. przeciążeniem informacyjnym (zbyt wiele treści generowanych przez AI, trudność w ich selekcji), presją użycia narzędzi (poczucie, że „trzeba” używać AI, żeby nadążyć za innymi) oraz spadkiem poczucia kontroli nad procesem uczenia się (poleganie na AI zamiast samodzielnego myślenia może powodować frustrację lub niepewność).

Technostres – negatywna reakcja psychologiczna wynikająca z interakcji między ludźmi a wprowadzaniem nowych technologii. Podczas gdy ergonomia bada fizyczne reakcje człowieka na maszyny oraz jego dostosowanie do nich, technostres wynika ze zmian w zachowaniach, które są wywołane użytkowaniem nowoczesnych technologii.

TPB, *UTAUT*, *TAM* – modele, które służą wyjaśnieniu, dlaczego ludzie podejmują pewne zachowania lub przyjmują nowe rozwiązania techniczne. Wchodzą one w zakres psychologii społecznej i technologii.

