

**JAN KINAL**

Uniwersytet WSB Merito w Poznaniu

Wydział Zamiejscowy w Chorzowie

<https://orcid.org/0009-0002-5840-0296>

e-mail: [chx106115@student.chorzow.merito.pl](mailto:chx106115@student.chorzow.merito.pl)

**PAWEŁ SZEWCZYK**

Uniwersytet WSB Merito w Poznaniu

Wydział Zamiejscowy w Chorzowie

<https://orcid.org/0009-0004-0981-8842>

e-mail: [pawel.szewczyk@chorzow.merito.pl](mailto:pawel.szewczyk@chorzow.merito.pl)

## **Polityki szkół wyższych wobec generatywnej sztucznej inteligencji w edukacji — analiza porównawcza wybranych uczelni z czterech regionów świata<sup>1</sup>**

**Streszczenie.** Artykuł przedstawia systematyczną analizę porównawczą polityk regulujących wykorzystanie generatywnej sztucznej inteligencji w 30 szkołach wyższych z czterech regionów geograficznych: Ameryki Północnej, Europy Zachodniej, Polski oraz Azji. Korpus 133 dokumentów instytucjonalnych poddano ustrukturyzowanej analizie treści prowadzonej z udziałem dwóch agentów sztucznej inteligencji, klasyfikując każdą politykę w siedmiu obszarach analitycznych, w tym na pięciostopniowej skali AIAS (Artificial Intelligence Assessment Scale). Z badania wyłaniają się cztery odrębne profile regulacyjne oraz centralna teza o systematycznej asymetrii między silnym wymiarem deklaracyjnym polityk a ich słabszym wymiarem operacyjnym. Polska wyróżnia się najwyższym konsensem deklaracyjnym (100% szkół wyższych wymaga ujawnienia użycia AI, 100% odwołuje się do koncepcji AI literacy), lecz najniższą operacjonalizacją egzekwowania i aktualizacji. Na tej podstawie sformułowano sześć rekomendacji dla polskiego szkolnictwa wyższego. Analizowana próba ma charakter celowy i nie stanowi reprezentatywnego przekroju światowego szkolnictwa wyższego, dlatego wnioski odnoszą się do badanych regionów, a nie do ogółu krajów.

**Słowa kluczowe:** : sztuczna inteligencja, generatywna AI, polityki uczelniane, szkolnictwo wyższe, integralność akademicka, AI literacy, analiza porównawcza

<https://doi.org/10.58683/dnswsb.2193>

---

<sup>1</sup> Artykuł został przygotowany na podstawie pracy magisterskiej *Analiza porównawcza polityk uczelni wyższych w zakresie wykorzystania sztucznej inteligencji w edukacji* napisanej pod kierunkiem prof. dr. hab. Pawła Szewczyka.

## 1. Wprowadzenie

Dynamiczny rozwój generatywnej sztucznej inteligencji, a w szczególności dużych modeli językowych, fundamentalnie zmienia krajobraz edukacji wyższej na całym świecie. Nowa technologia oferuje bezprecedensowe możliwości wspomagania procesu uczenia się, pisania prac akademickich, rozwiązywania problemów programistycznych czy analizy danych. Jednocześnie stawia przed środowiskiem akademickim szereg wyzwań dotyczących integralności akademickiej, oryginalności prac studenckich, sprawiedliwego oceniania oraz przygotowania absolwentów do funkcjonowania na rynku pracy, który sam ulega transformacji pod wpływem AI. W odpowiedzi szkoły wyższe na całym świecie podejmują próby regulowania wykorzystania generatywnej AI przez studentów i wykładowców, tworząc własne polityki, wytyczne i regulaminy.

Celem niniejszego artykułu jest przeprowadzenie kompleksowej analizy porównawczej polityk szkół wyższych w zakresie wykorzystania sztucznej inteligencji w edukacji. Główny problem badawczy można sformułować następująco: w jaki sposób szkoły wyższe w wybranych regionach świata podchodzą do regulowania wykorzystania sztucznej inteligencji w edukacji i jakie dobre praktyki można zidentyfikować na podstawie analizy porównawczej ich polityk? Artykuł poszukuje odpowiedzi na pytania szczegółowe: czy podejścia szkół wyższych różnią się znacząco między regionami geograficznymi i typami instytucji; czy niektóre uczelnie przyjmują stanowisko restrykcyjne, zakazując lub istotnie ograniczając wykorzystanie narzędzi AI, podczas gdy inne czynią przeciwnie; oraz jakie są obecnie dobre i warte naśladowania praktyki regulacyjne.

Artykuł powstaje z perspektywy polskiego szkolnictwa wyższego, dlatego polityki polskich uczelni potraktowano jako odrębną kategorię analityczną i opatrzono pogłębionym komentarzem, a całość rozważań zwieńczono rekomendacjami adresowanymi do rodzimych instytucji.

Zakres badania wymaga przy tym wyraźnego zastrzeżenia. Analizie poddano 30 celowo dobranych uczelni z czterech regionów, a nie reprezentatywną próbę światowego szkolnictwa wyższego. Dobór regionów odzwierciedla obszary, z których wywodzi się większość instytucji zajmujących czołowe miejsca w rankingach międzynarodowych, uzupełnione o Polskę jako punkt odniesienia wynikający z perspektywy badawczej artykułu. Poza zakresem badania pozostają między innymi Ameryka Łacińska, Afryka, Bliski Wschód, Azja Południowa oraz Europa Środkowo-Wschodnia poza Polską. Formułowane dalej profile regulacyjne i wnioski odnoszą się zatem do badanych regionów i nie powinny być skalowane ani na wszystkie kraje, ani na uczelnie o wyraźnie odmiennym profilu instytucjonalnym.

## 2. Przegląd literatury

Pojawienie się dużych modeli językowych zapoczątkowało okres bezprecedensowej transformacji w szkołach wyższych (Kasneci i in., 2023). W ciągu zaledwie kilku miesięcy od uruchomienia ChataGPT narzędzie to zyskało ponad sto milionów użytkowników, a jego wpływ na środowisko akademickie stał się przedmiotem intensywnej debaty naukowej. Skala wykorzystania narzędzi AI wśród studentów okazała się znacząca. Międzynarodowe badanie Ravšelj i in. (2025), opublikowane w „PLOS ONE” i przeprowadzone przez zespół około 150 naukowców, objęło 23 tysiące studentów ze 109 krajów. Najczęściej raportowane zastosowania ChataGPT to burza mózgów i generowanie pomysłów (29% badanych), streszczanie długich tekstów (27%) oraz wyszukiwanie informacji do prac naukowych (25%). Co istotne, około połowa badanych uznała, że szkoły wyższe powinny wydać oficjalne wytyczne dotyczące stosowania ChataGPT w pracy naukowej. Sygnał ten wynika z praktycznej potrzeby: studenci często nie wiedzą, jakie wykorzystanie AI jest dozwolone, a prowadzący zajęcia prezentują rozbieżne stanowiska wobec tego samego problemu. Polityki uczelniane stanowią próbę usunięcia tej niepewności po obu stronach relacji dydaktycznej.

Obok wymiernych korzyści coraz wyraźniej zarysowuje się problem kognitywnego kosztu nadmiernego polegania na narzędziach generatywnych. Badanie EEG przeprowadzone w MIT Media Lab (Kosmyna i in., 2025) wykazało, że studenci piszący eseje z pomocą ChataGPT przejawiali istotnie niższą aktywność neuronalną oraz słabszą pamięć własnych tekstów w porównaniu z grupą pracującą bez wsparcia AI; autorzy ukuli na to zjawisko termin „długu poznawczego” (*cognitive debt*). Jednocześnie Gruenhagen i in. (2024) ostrzegają, że znaczna część studentów korzystających z chatbotów przy realizacji zadań zaliczeniowych nie postrzega tego działania jako naruszenia zasad akademickich, co wskazuje na pilną potrzebę jasnego zdefiniowania granic dopuszczalnego wykorzystania AI.

Integracja AI rodzi szereg wyzwań, które można podzielić na cztery kategorie: integralność akademicka, niezawodność narzędzi detekcyjnych, ramy regulacyjne oraz fundamentalna niepewność dydaktyczna co do celów i metod kształcenia. Tradycyjne rozumienie plagiatu, oparte na przywłaszczeniu cudzego tekstu, okazuje się niewystarczające wobec treści generowanych przez AI, które z definicji nie posiadają ludzkiego autora w klasycznym sensie. Szczególnie istotnym problemem jest ograniczona skuteczność narzędzi do wykrywania tekstu generowanego przez AI. Weber-Wulff i in. (2023) wykazali znaczące ograniczenia dostępnych detektorów w zakresie czułości i dokładności, a Liang i in. (2023) udowodnili, że popularne detektory wykazują istotną stronniczość wobec tekstów pisanych przez osoby niebędące rodzimymi użytkownikami języka angielskiego — ich prace

bywały fałszywie klasyfikowane jako wygenerowane przez AI znacznie częściej. Odkrycie to ma poważne implikacje dla sprawiedliwości proceduralnej i podważa zasadność opierania się wyłącznie na automatycznej detekcji. Z tego względu coraz więcej szkół wyższych rezygnuje z polityk opartych na detekcji na rzecz polityk wymagających deklaracyjnego ujawnienia użycia AI.

W wymiarze prawnym kluczowe znaczenie ma europejski Akt o Sztucznej Inteligencji (EU AI Act) przyjęty w 2024 roku, który — choć nie reguluje bezpośrednio wykorzystania AI w edukacji wyższej — klasyfikuje określone zastosowania AI w edukacji — takie jak rekrutacja, ocenianie efektów uczenia się czy nadzór nad egzaminami — jako systemy wysokiego ryzyka, nakładając obowiązki w zakresie przejrzystości, dokumentacji i nadzoru ludzkiego. Różnice między europejskim podejściem regulacyjnym a amerykańskim modelem opartym na samoregulacji branżowej stanowią istotny kontekst dla zrozumienia zróżnicowania polityk poszczególnych uczelni.

Oprócz wyzwań etycznych i prawnych generatywna AI stawia przed szkołami wyższymi pytanie jeszcze bardziej fundamentalne: czego i jak uczyć w świecie, w którym maszyny potrafią wykonywać zadania dotychczas zarezerwowane dla ludzi. Bozkurt i in. (2024) w kolektywnym manifestie poświęconym nauczaniu w erze generatywnej AI podkreślają, że technologia ta nie jest neutralna ideologicznie ani kulturowo — kształtuje sposób, w jaki studenci przyswajają wiedzę, i wymaga świadomego, opartego na dowodach podejścia do jej integracji w procesie dydaktycznym. Szczególnie wyraźnie problem ten ujawnia się w edukacji informatycznej: jak zauważają Denny i in. (2024), tradycyjne zadania polegające na pisaniu kodu od podstaw mogą być dziś z łatwością rozwiązywane przez modele AI, co podważa fundamenty dotychczasowej dydaktyki programowania i stawia uczelnie przed dylematem — zakazywać czy integrować. Brak konsensusu w tej kwestii sam w sobie stanowi istotne ustalenie badawcze, znajdujące odzwierciedlenie w zróżnicowaniu analizowanych polityk uczelnianych.

W odpowiedzi na tę niepewność dydaktyczną w literaturze coraz częściej pojawia się koncepcja umiejętności związanych ze sztuczną inteligencją (*AI literacy*). Long i Magerko (2020) zdefiniowali ją jako zespół kompetencji umożliwiających krytyczną ocenę technologii AI, efektywną komunikację i współpracę z systemami AI oraz wykorzystanie AI jako narzędzia w różnych kontekstach. Chan (2023) zaproponował kompleksowe ramy polityki AI obejmujące wymiar etyczny, dydaktyczny i proceduralny. W literaturze podejmowano również próby bezpośredniego porównywania polityk między instytucjami: Eaton (2023–2025) zgromadził ponad 180 przykładów zapisów sylabusowych z uczelni całego świata, An i in. (2025) zbadali wytyczne instytucji szkolnictwa wyższego, Dabis i Csáki (2024) przeanalizowali pierwsze odpowiedzi uczelni na wyzwania etyczne AI, a Erhardt i in. (2025) opisali

doświadczenia uczelni szwedzkich. Istotnym wkładem metodologicznym jest skala AIAS (Artificial Intelligence Assessment Scale) zaproponowana przez Perkinsa i in. (2024), definiująca kontinuum od całkowitego zakazu do pełnej integracji AI. Żadne z dotychczasowych badań nie obejmuje jednak jednocześnie wszystkich kluczowych regionów geograficznych przy zastosowaniu jednolitej metodologii porównawczej i tę lukę niniejszy artykuł stara się wypełnić.

### 3. Metodologia badań

Badanie oparto na analizie dokumentów instytucjonalnych pozyskanych z 30 uczelni z czterech regionów geograficznych (Atlas Polityk AI Uczelni, 2026). Próbę badawczą skonstruowano w oparciu o celowy dobór szkół wyższych z Ameryki Północnej, Europy Zachodniej, Polski oraz Azji. Wybór tych regionów podyktowany był dążeniem do uchwycenia zróżnicowania cywilizacyjnego i regulacyjnego: każdy z nich reprezentuje odmienny kontekst prawny (europejski EU AI Act, amerykański model samoregulacji, azjatyckie modele państwowe), odrębną tradycję akademicką oraz różny stosunek do innowacji technologicznych. Polskę wyodrębniono jako osobną kategorię ze względu na perspektywę badawczą artykułu oraz specyficzny kontekst instytucjonalny i kulturowy. Przy doborze konkretnych uczelni przyjęto trzy kryteria: publiczna dostępność dokumentu regulującego wykorzystanie AI, rozpoznawalna pozycja instytucji w swoim regionie oraz dążenie do porównywalnej liczebności reprezentacji każdego regionu. Ostatecznie zgromadzono dokumenty z 10 uczelni Ameryki Północnej, 7 Europy Zachodniej, 7 Polski oraz 6 Azji — łącznie 133 pliki PDF różnej objętości.

Korpus poddano klasyfikacji typologicznej, identyfikując 15 kategorii źródeł według charakteru regulacyjnego, oraz przypisano dokumenty do czterech wag analitycznych odzwierciedlających ich znaczenie dla problemu badawczego: A (rdzeń analizy — formalne polityki i centralne wytyczne, 22 dokumenty), B (materiał pomocniczy, 55), C (kontekst i tło, 55) oraz D (inny dokument, 1). Analiza porównawcza opiera się przede wszystkim na dokumentach wagi A, uzupełnianych dokumentami niższych wag tam, gdzie dana uczelnia nie posiada źródła wagi A. Należy zaznaczyć, że tak dobrana próba nie jest reprezentatywna statystycznie dla ogółu uczelni; celem badania nie jest jednak generalizacja, lecz identyfikacja zróżnicowania podejść regulacyjnych i dobrych praktyk. Strukturę korpusu w podziale na regiony i wagi analityczne przedstawia tab. 1.

**Tabela 1.** Struktura korpusu badawczego według regionów i wag analitycznych

| Region           | Uczelnie | Dokumenty | Średnio na uczelnię | Waga A | Waga B | Waga C | Waga D |
|------------------|----------|-----------|---------------------|--------|--------|--------|--------|
| Ameryka Północna | 10       | 94        | 9,4                 | 9      | 43     | 42     | 0      |
| Europa Zachodnia | 7        | 14        | 2,0                 | 5      | 3      | 6      | 0      |
| Polska           | 7        | 17        | 2,4                 | 5      | 6      | 6      | 0      |
| Azja             | 6        | 8         | 1,3                 | 3      | 3      | 1      | 1      |
| Razem            | 30       | 133       | 4,4                 | 22     | 55     | 55     | 1      |

Źródło: Opracowanie własne na podstawie inwentarza korpusu. Wagi analityczne: A — rdzeń analizy (formalne polityki i centralne wytyczne), B — materiał pomocniczy, C — kontekst i tło, D — inny dokument.

Procedura analityczna obejmowała pięć etapów: zautomatyzowany preprocessing dokumentów PDF do bazy wiedzy w formacie Markdown z hierarchicznym podziałem na fragmenty (chunki), klasyfikację źródeł, detekcję podobieństw leksykalnych między politykami, interaktywną analizę zawartości każdej polityki oraz walidację i agregację wyników. Analizę treści realizowano w sesjach z dwoma agentami sztucznej inteligencji — Claude Cowork z modelem Opus 4.7 oraz Codex z modelem GPT-5.5 — co umożliwiło wzajemną kontrolę klasyfikacji oraz optymalizację kosztów obliczeniowych. Każda klasyfikacja musiała być uzasadniona cytatem z dokumentu z odwołaniem do konkretnego fragmentu bazy wiedzy, co zapewniało pełną ścieżkę audytową. Wiarygodność analizy poddano czterostopniowej weryfikacji: walidacji schematu odpowiedzi, kontroli krzyżowej między agentami na próbie dokumentów, ręcznej weryfikacji autora wobec oryginałów PDF oraz audytowi technicznemu sprawdzającemu, czy każdy cytowany fragment rzeczywiście istnieje w bazie wiedzy (kontrola halucynacji). Pełną treść ustandaryzowanego polecenia przekazywanego agentom AI, wraz ze strukturą wymaganej odpowiedzi i listą dopuszczalnych wartości klasyfikacyjnych, zawiera Aneks 1.

Osobnego omówienia wymaga procedura detekcji podobieństw leksykalnych, przeprowadzona przed właściwą analizą treści w celu sprawdzenia, czy polityki AI nie są powielane między instytucjami. Porównanie oparto na zbiorach pięciowyrazowych sekwencji wyrazowych (shingli), wyodrębnionych wyłącznie z tych fragmentów dokumentów, które na etapie preprocessingu zaklasyfikowano jako treść właściwą, z pominięciem elementów nawigacyjnych, stoppek i treści powtarzalnych. Teksty poddano normalizacji polegającej na sprowadzeniu do małych liter i wydzieleniu tokenów wyrazowych z zachowaniem znaków diakrytycznych; pominięto tokeny jednoznakowe niebędące cyframi. Dla każdej pary dokumentów oraz dla każdej pary uczelni obliczono dwie miary: współczynnik Jaccarda, czyli iloraz mocy części wspólnej i mocy sumy obu zbiorów, oraz współczynnik

nakładania (ang. *overlap coefficient*, znany również jako indeks Szymkiewicza-Simpsona), czyli iloraz mocy części wspólnej i mocy mniejszego z porównywanych zbiorów. Druga z tych miar pozwala wychwycić sytuację, w której krótszy dokument jest w całości zawarty w dłuższym, a więc przypadek, którego współczynnik Jaccarda nie sygnalizuje, ponieważ znaczna różnica objętości obu dokumentów z założenia obniża jego wartość. Za próg sygnalizujący istotne podobieństwo przyjęto wartość 0,08 dla współczynnika Jaccarda lub 0,35 dla współczynnika nakładania. Obliczenia objęły pełny korpus 133 dokumentów, obejmujący 1332 fragmenty treści właściwej i 206 762 tokeny po normalizacji. Szczegółowy opis procedury wraz z parametrami, progami i wynikami zbiorczymi zawiera Aneks 2, co umożliwia replikację tego etapu badania i porównanie własnych wyników z przedstawionymi tutaj.

Wynik tej procedury jest jednoznaczny i istotny dla interpretacji całości badania. Próg podobieństwa przekroczyło czternaście par dokumentów, przy czym wszystkie te pary pochodzą z tej samej uczelni: są to trzy pary dokumentów identycznych, wynikające z dwukrotnego pozyskania tego samego pliku (Princeton University oraz dwukrotnie UC Berkeley), oraz jedenaście par dokumentów pokrewnych, publikowanych przez tę samą instytucję w różnych wersjach lub kanałach. Żadna para dokumentów pochodzących z różnych uczelni nie przekroczyła progu — najwyższa wartość międzyuczelniana wynosi 0,0013 w mierze Jaccarda i 0,0482 w mierze nakładania. Na poziomie zagregowanym najwyższe podobieństwo między dwiema różnymi uczelniami wynosi zaledwie 0,0024 (European University Institute i University of Oxford). Oznacza to, że dosłowne kopiowanie polityk AI między uczelniami praktycznie nie występuje — instytucje formułują własne regulacje własnym językiem, nawet jeśli regulują te same obszary tematyczne. Ewentualne pokrewieństwo polityk rozpoznawane jest zatem na poziomie konceptów regulacyjnych, nie sformułowań językowych.

Główne ograniczenia metodologiczne badania to element subiektywności charakterystyczny dla dużych modeli językowych (mitygowany przez ustandaryzowany prompt, kontrolę krzyżową i wymóg cytowania) oraz dynamiczny charakter polityk uczelnianych, które mogły ulec zmianie po dacie ich pozyskania (12 maja 2026 roku).

## 4. Wyniki analizy porównawczej

Z analizy zagregowanej wyłania się centralna teza, stanowiąca oś interpretacyjną całego badania. Współczesne polityki uczelniane charakteryzuje systematyczna asymetria między wymiarem deklaratywnym a wymiarem operacyjnym. W war-

stwie deklaratywnej dominuje warunkowe dopuszczenie generatywnej AI: 28 z 30 szkół wyższych ma górną granicę na skali AIAS równą 4, czyli dopuszcza użycie AI do generowania treści przy wymogu ujawnienia wkładu narzędzia. Równolegle silne jest stanowisko proedukacyjne — dwadzieścia cztery szkoły wyższe odnoszą się do koncepcji *AI literacy*, a dwadzieścia wymaga ujawnienia użycia AI w pracach studenckich lub publikacjach. W warstwie operacyjnej obraz jest mniej spójny: stosunek do narzędzi detekcji pozostaje przemilczany w dziewiętnastu szkołach wyższych, sankcje za niedozwolone wykorzystanie AI są rzadko precyzowane, a mechanizmy aktualizacji, choć deklarowane przez dziewiętnaście szkół wyższych, w większości nie wskazują konkretnej daty przeglądu. Polityki AI są zatem mocne w deklaracji wartości i ogólnych zasad, ale słabe w operacjonalizacji egzekwowania i procedurach aktualizacji.

#### 4.1. Polityki szkół wyższych w Ameryce Północnej

Region reprezentuje w korpusie dziesięć uczelni amerykańskich z różnych klas instytucjonalnych: prywatne elitarne szkoły wyższe (Harvard, Princeton, Yale, Stanford, Columbia, Duke), techniczne (MIT, Caltech), stanowe (UC Berkeley) oraz prywatną jezuicką szkołę wyższą (Loyola University Chicago). Zgromadzono tu aż 94 dokumenty (średnio 9,4 na uczelnię), co wynika z amerykańskiej praktyki publikowania regulacji AI w formie zdecentralizowanej — przez wiele biur uczelnianych równocześnie. Dominującym modelem regulacyjnym jest model delegujący: pięć z dziesięciu szkół wyższych klasyfikuje swoje polityki jako zakres AIAS 1–4, świadomie rezygnując z jednolitego stanowiska na rzecz delegowania reguł do poziomu szkoły, departamentu lub poszczególnego prowadzącego. Stanford ujmuje tę logikę najzwięźlej, ustanawiając domyślny zakaz przy braku instrukcji prowadzącego i jednocześnie pełną swobodę prowadzącego w określaniu polityki kursowej:

Absent a clear statement from a course instructor, use of or consultation with generative AI shall be treated analogously to assistance from another person. [...] Individual course instructors are free to set their own policies regulating the use of generative AI tools in their courses, including allowing or disallowing some or all uses of such tools (Stanford University, 2023).

Wzorzec delegujący występuje też w skrajnej, metaregulacyjnej postaci w Harvardzie, którego polityka uniwersytecka celowo unika ustanawiania konkretnych reguł użycia AI w pracach studenckich, pozostawiając tę warstwę poszczególnym szkołom. MIT realizuje wariant pokrewny, lecz narzędziowy: w korpusie nie ma

centralnej polityki dydaktycznej, jest natomiast zestaw dokumentów o zatwierdzonych narzędziach AI i klasyfikacji danych instytucjonalnych.

Przeciwagą dla modelu delegującego są szkoły wyższe z pełną centralną polityką dydaktyczną i klasyfikacją AIAS 4 – przede wszystkim Loyola University Chicago, która definiuje cztery kategorie dopuszczalnego użycia AI, wymaga jawnego oświadczenia w pracach studenckich i podaje gotowe szablony klauzul sylabusowych, co czyni ją w korpusie szczególnie dobrze zoperacjonalizowaną. Region jest niejednorodny pod względem wymogu ujawnienia (cztery szkoły wyższe wymagają go jednoznacznie, dwie traktują jako zalecenie, jedna jako opcję, a trzy milczą lub delegują decyzję). Kwestia narzędzi detekcji jest w regionie stosunkowo często podejmowana wprost (cztery z dziesięciu szkół wyższych ograniczają lub warunkowo dopuszczają detektory, z czego trzy wskazują ich ograniczenia metodologiczne). Wspólnym mianownikiem regionu jest silne zorientowanie polityk na ochronę danych, zarządzanie ryzykiem informacyjnym i klasyfikację narzędzi zatwierdzonych instytucjonalnie.

#### 4.2. Polityki uczelni w Europie Zachodniej

Region reprezentuje siedem szkół wyższych z pięciu krajów: Wielkiej Brytanii (Oxford, Cambridge, Imperial College London), Niemiec (Berlin Universities Publishing), Szwajcarii (ETH Zurich), Szwecji (Uppsala Universitet) i Włoch (European University Institute). Zgromadzono czternaście dokumentów (średnio dwa na uczelnię). Niska średnia wynika z odmiennej strategii publikacyjnej: zachodnio-europejskie szkoły wyższe publikują najczęściej jeden lub dwa zwarte dokumenty centralne o wąsko zdefiniowanym zakresie tematycznym (publikacje, badania, administracja, bezpieczeństwo informacji), zamiast wielowarstwowego ekosystemu materiałów dydaktycznych charakterystycznego dla uczelni amerykańskich. Cechą wyróżniającą region jest silna obecność polityk dotyczących badań naukowych obok lub zamiast polityk dydaktycznych, co odzwierciedla tradycję nacisku na integralność badawczą. Najbardziej rozbudowaną klasyfikację zakresową ma Oxford, który w obszarze ocenianego dorobku studenckiego ustanawia domyślny zakaz (AIAS 1), a w obszarze badań przyjmuje bardziej liberalne stanowisko (AIAS 4).

W wymiarze wymogu ujawnienia region prezentuje silny konsensus: sześć z siedmiu szkół wyższych wymaga ujawnienia użycia AI, a forma ujawnienia jest często szczegółowo opisana, jak w wytycznych Berlin Universities Publishing (2024):

The use of AI tools in the creation of content in a submitted work [...] must be described transparently. It must be clear which content was generated using AI tools, which AI tools were used and how the AI tools were used.

Region wyróżnia się także jednoznacznością powściągliwością wobec narzędzi detekcji — sześć uczelni milczy na ten temat, a jedyna podejmująca go European University Institute wprost zakazuje stosowania detektorów ze względu na ich zawodność i stronniczość. Można interpretować to jako europejską strategię przesuwania ciężaru egzekwowania z technologicznej detekcji na deklarację autora i procedury integralności akademickiej. Region wykazuje również wysoką gotowość proceduralną: sześć szkół wyższych deklaruje mechanizm aktualizacji, a cztery (EUI, Oxford, Uppsala, Berlin) wskazują konkretną datę przeglądu dokumentu. Europa Zachodnia odgrywa rolę pomostu między modelem amerykańskim a polskim: czerpie z tradycji autonomii akademickiej, ale stosuje silniejsze niż w USA wymogi formalnej deklaracji użycia AI.

### 4.3. Polityki szkół wyższych w Polsce

Region polski reprezentuje siedem szkół wyższych o zróżnicowanym profilu: publiczna Akademia Nauk Stosowanych w Raciborzu, kierunkowa Szkoła Główna Handlowa, prywatna Akademia Leona Koźmińskiego oraz cztery publiczne uniwersytety klasyczne (Uniwersytet Jagielloński, Uniwersytet im. Adama Mickiewicza, Uniwersytet Szczeciński, Uniwersytet Warszawski). Zgromadzono siedemnaście dokumentów (średnio 2,4 na uczelnię). Dominującym wzorcem regulacyjnym jest scentralizowany dokument rdzeniowy w postaci zarządzenia rektora, regulaminu studiów lub uchwały uniwersyteckiej rady. Pod względem zakresu region jest najbardziej spójny ze wszystkich czterech: wszystkie siedem polityk to dokumenty ogólnouczelniane skierowane zarówno do studentów, jak i nauczycieli akademickich, a ich rdzeniem przedmiotowym są prace dyplomowe i zaliczeniowe. Zarządzenie Rektora UJ nr 115/2025 ustanawia regułę technologicznie neutralną, stosując się do narzędzi AI „niezależnie od ich rodzaju, sposobu dostępu i nazwy handlowej”, co odróżnia je od starszej generacji dokumentów rekomendacyjnych skupionych wprost na ChatGPT.

W wymiarze klasyfikacji AIAS region jest najbardziej skoncentrowany w całym korpusie: sześć z siedmiu szkół wyższych klasyfikuje politykę na poziomie AIAS 4, a tylko Uniwersytet Warszawski na zakres 1–4 (domyślny zakaz dla egzaminów pisemnych). Polska wykazuje przy tym najsilniejszy konsensus wokół wymogu ujawnienia: wszystkie siedem uczelni (100%) wymaga ujawnienia użycia AI w pracach studenckich, co przewyższa zarówno Europę Zachodnią (sześć z siedmiu), jak i wyraźnie Amerykę Północną (cztery z dziesięciu). Region wyróżnia się też najbardziej rozbudowanymi wymogami przejrzystości — UAM nakazuje oznaczanie nie tylko zdań, ale również akapitów, obrazów i tabel wraz z zastosowanymi komendami i danymi wyjściowymi, a UJ włącza do form ujawnienia także treść

promptu, co jest w skali całego korpusu rozwiązaniem unikatowym i wartościowym metodologicznie. Wszystkie siedem szkół wyższych odnosi się także do koncepcji *AI literacy* (100%) — wspólnym mianownikiem regionu jest ujęcie AI nie jako zagrożenia dla dydaktyki, lecz jako kompetencji przyszłości:

Osoby kształcące się na Uniwersytecie Jagiellońskim są zobowiązane [...] wyraźnie oznaczać te części pracy, które zostały wygenerowane z wykorzystaniem narzędzi opartych na SI (np. poprzez stosowne przypisy, komentarze lub inne adnotacje w tekście, zamieszczanie treści promptu) (Uniwersytet Jagielloński, 2025).

Mimo silnego konsensusu deklaratywnego region wykazuje wyraźne pęknięcia w warstwie operacyjnej. Sankcje za naruszenie określają jawnie tylko dwie szkoły wyższe (UJ, US), dwie wprost ich nie ustanawiają (ALK, UW), a trzy milczą — co daje najniższy odsetek operacjonalizacji sankcji w całym korpusie. Stosunek do detektorów jest najsilniej spolaryzowany: dwie szkoły wyższe (ANS, ALK) zalecają stosowanie detektorów bez omówienia ich ograniczeń, podczas gdy UJ dopuszcza je jedynie pomocniczo, UAM warunkowo — rekomendując triangulację kilku niezależnych narzędzi z uwzględnieniem ich ograniczeń, a US ogranicza ich rolę, jawnie ostrzegając przed fałszywie pozytywnymi wynikami. Kontrast między biegunem ANS/ALK a biegunem US/UAM jest najsilniejszą wewnątrzregionalną rozbieżnością w korpusie. Region wykazuje wreszcie najniższą gotowość proceduralną do aktualizacji — żadna z siedmiu polityk nie podaje konkretnej daty kolejnego przeglądu, co kontrastuje z Europą Zachodnią. Polskie polityki są więc spójne w warstwie deklaratywnej, ale niejednorodne w warstwie egzekucyjnej i procesowej.

#### 4.4. Polityki szkół wyższych w Azji

Region reprezentuje sześć szkół wyższych z czterech krajów Azji Wschodniej i Południowo-Wschodniej: Tajwanu (NTHU), Singapuru (NTU Singapore, NUS), Korei Południowej (Seoul National University) oraz Japonii (University of Tokyo, Waseda University). Zgromadzono osiem dokumentów (średnio 1,3 na uczelnię), czyli najniższą wartość ze wszystkich regionów. Region wyróżnia się największą heterogenicznością typologiczną źródeł — od pełnej polityki badawczej (NTU) i polityki klasowej (Tokyo) po komunikaty prasowe streszczające szersze wytyczne (NTHU, Seoul National University). W wymiarze klasyfikacji AIAS region jest najbardziej heterogeniczny: wśród sześciu uczelni występuje aż pięć różnych wariantów, od pełnego dopuszczenia AIAS 4 (NTHU, NTU) po skrajny lokalny zakaz pisania prac z użyciem AI w programie LL.M. Wasedy (AIAS 1). University of Tokyo reprezentuje model delegujący, pozostawiając decyzję prowadzącemu, ale pre-

cyzując, że samo skopiowanie wyjścia generatora nie powinno być akceptowane jako wynik pracy studenta.

Mimo niskiej średniej liczby dokumentów region wykazuje wysoką obecność koncepcji *AI literacy* (pięć z sześciu uczelni). Najsilniej rozwiniętą warstwę dydaktyczną prezentuje NTHU z dwoma pełnymi programami kształcenia w zakresie AI o wymiarze 19 i 21 punktów kredytowych — konkretnością programową wyjątkową w całym korpusie. NTU Singapore (2023) formalizuje natomiast wymóg ujawnienia w polityce badawczej, precyzując treść wymaganego oświadczenia:

This would include acknowledging the use of any AI tools in their research proposals, manuscripts, and scholarly works through a statement specifying the tool's full name and version, its purpose of use, and how it was used.

Wymóg ten — obejmujący pełną nazwę narzędzia, jego wersję, cel oraz sposób użycia — odpowiada metodologicznemu wymogowi powtarzalności badań. Region jest najmocniej milczący wobec narzędzi detekcji (pięć z sześciu uczelni nie podejmuje tematu), a jedyne krytyczne stanowisko zajmuje University of Tokyo. Ze względu na to, że tylko jedna szkoła wyższa z tego regionu (NTU Singapore) reprezentowana jest w korpusie przez pełną politykę uczelnianą w ścisłym sensie, wnioski regionalne wymagają szczególnej ostrożności w generalizacji.

## 5. Synteza: profile regionalne i trendy ogólne


Zestawienie czterech regionów w siedmiu obszarach analitycznych (tab. 2) pozwala uchwycić ich odrębne profile regulacyjne. Wartości wyrażono jako odsetek uczelni regionu, dla których dana kategoria została sklasyfikowana pozytywnie, lub jako kategorię dominującą tam, gdzie rozkład jest jednorodny. Graficzne zestawienie pięciu wskaźników najsilniej różnicujących regiony przedstawia rys. 1.

**Tabela 2.** Profile regionalne polityk AI — zestawienie czterech regionów w siedmiu obszarach analitycznych

| Obszar                     | USA (n=10)       | Europa Zach. (n=7) | Polska (n=7)   | Azja (n=6)  |
|----------------------------|------------------|--------------------|----------------|-------------|
| AIAS modalny               | zakres 1–4 (50%) | poziom 4 (57%)     | poziom 4 (86%) | rozproszone |
| AIAS jako zakres           | 80%              | 43%                | 14%            | 50%         |
| Polityka ogólnouczelniana  | 90%              | 71%                | 100%           | 67%         |
| Wymóg ujawnienia: wymagane | 40%              | 86%                | 100%           | 50%         |
| Sankcje określone          | 60%              | 71%                | 29%            | 67%         |
| AI literacy obecna         | 70%              | 71%                | 100%           | 83%         |

| Obszar                    | USA (n=10) | Europa Zach. (n=7) | Polska (n=7) | Azja (n=6) |
|---------------------------|------------|--------------------|--------------|------------|
| Detektory omawiane wprost | 40%        | 14%                | 71%          | 17%        |
| Mechanizm aktualizacji    | 90%        | 86%                | 29%          | 33%        |

Źródło: Opracowanie własne na podstawie agregatu 30 analiz. AIAS (Artificial Intelligence Assessment Scale) Perkinsa i in. (2024): 1 — całkowity zakaz, 2 — planowanie i ideacja, 3 — asystent edycyjny, 4 — współautorstwo z deklaracją, 5 — pełna integracja. „Zakres” oznacza polityki świadomie różnicowane wedle typu zadania, dyscypliny lub decyzji prowadzącego.




**Rys. 1.** Profil regulacyjny polityk AI w czterech regionach. Odsetek uczelni w regionie.  
Źródło: Opracowanie własne na podstawie agregatu 30 analiz. Wartości wyrażono jako odsetek uczelni w regionie, dla których dana kategoria została sklasyfikowana pozytywnie.

Z porównania regionów wyłaniają się cztery wyraźne profile regulacyjne. Stany Zjednoczone łączą wysoką operacjonalizację (sankcje, mechanizmy aktualizacji) z najsłabszym konsensusem wokół ujawnienia i dominacją modelu delegującego, zakorzenionego w tradycji kodeksów honorowych i autonomii prowadzącego. Europa Zachodnia prezentuje równowagę między silnym konsensusem deklaratywnym (ujawnienie 86%, aktualizacja 86%) a specjalizacją tematyczną polityk i powściągliwością wobec detektorów. Polska wykazuje największą koncentrację regulacyjną w warstwie deklaratywnej (AIAS 4 dla 86%, ujawnienie 100%, *AI literacy* 100%, centralizacja 100%) przy jednoczesnej najsłabszej operacjonalizacji (sankcje 29%, mechanizm aktualizacji 29%) — co najdobitniej potwierdza central-

ną tezę o asymetrii między wymiarem deklaracyjnym a operacyjnym. Azja jest regionem heterogeniczności bez jednego wzorca, w którym współistnieją skrajnie restrykcyjne polityki jednostkowe i wąskie polityki badawcze.

Szczegółnej uwagi wymaga paradoks Polski. Mimo najsilniejszego w korpusie konsensusu wokół wymogu ujawnienia (100%), Polska wykazuje najniższy odsetek polityk jawnie określających sankcje (29%), podczas gdy pozostałe regiony oscylują w zakresie 60–71%. Polskie polityki są zatem mocne w warstwie deklaratywnej (co należy ujawnić), lecz słabe w warstwie egzekucyjnej (co grozi za nieujawnienie). Drugi polski paradoks dotyczy detektorów: Polska jest jedynym regionem szeroko podejmującym ten temat (71% omawia go wprost), ale zarazem najbardziej spolaryzowanym wewnątrznie. Skalę rozejścia się obu warstw w każdym z regionów pokazuje rys. 2.



Rys. 2. Łuka między warstwą deklaracyjną a operacyjną polityk AI według regionów. Odsetek uczelni w regionie.


Źródło: Opracowanie własne na podstawie agregatu 30 analiz. Punkt wypełniony oznacza wskaźnik warstwy deklaratywnej, punkt pusty — odpowiadający mu wskaźnik warstwy operacyjnej; długość łącznika odpowiada wielkości luki.

Zaobserwowany gradient wymogu ujawnienia — rosnący od Ameryki Północnej (40%) przez Azję (50%) i Europę Zachodnią (86%) aż po Polskę (100%) — można interpretować jako odzwierciedlenie szerszego kontekstu regulacyjnego. Silniejsza obecność wymogu przejrzystości w regionach związanych z europejskimi ramami prawnymi, w tym z EU AI Act ustanawiającym zasady przejrzystości systemów AI, kontrastuje z jego słabszą obecnością w regionach o tradycji samoregulacji branżowej. Polskie szkoły wyższe, działające w ramach scentralizowanego modelu

zarządzania szkolnictwem wyższym, w którym senat lub rektor wydają wiążące akty wewnętrzne, łatwiej osiągają pełną centralizację i jednorodność wymogów deklaracyjnych niż uczelnie amerykańskie, w których tradycja kodeksów honorowych premiuje autonomię prowadzącego. Kontekst instytucjonalny i prawny okazuje się zatem silniejszym predyktorem profilu regulacyjnego niż jakiegokolwiek bezpośrednie zapożyczenia między politykami — co potwierdza wcześniejsze ustalenie o praktycznym braku dosłownego kopiowania regulacji między uczelniami.

## 5.1. Trendy ogólne

Z analizy 30 polityk wyłaniają się cztery trendy obecne w co najmniej trzech regionach lub w ponad 70% szkół wyższych korpusu. Po pierwsze, AIAS 4 jako górna granica dopuszczalności: 28 z 30 szkół wyższych (93%) dopuszcza użycie generatywnej AI do tworzenia treści przy wymogu ujawnienia, żadna nie osiąga poziomu pełnej integracji (AIAS 5) ani nie ustanawia całkowitego zakazu jako jedyne go trybu. Integralność akademicka jest więc chroniona przez wymóg przejrzystości, a nie przez zakaz technologii. Po drugie, *AI literacy* jako uniwersalny cel regulacyjny: dwadzieścia cztery szkoły wyższe (80%) odnoszą się do kompetencji cyfrowych w kontekście AI, niezależnie od regionu, co sugeruje szybki międzynarodowy konsensus wokół tej koncepcji. Rozkład klasyfikacji AIAS w poszczególnych regionach przedstawia rys. 3.



Rys. 3. Klasyfikacja polityk na skali AIAS według regionów

Źródło: Opracowanie własne na podstawie agregatu 30 analiz. AIAS (Artificial Intelligence Assessment Scale) Perkinsa i in. (2024): poziom 4 oznacza dopuszczenie generowania treści przy wymogu ujawnienia. Kategoria „zakres” obejmuje polityki świadomie różnicowane wedle typu zadania, dyscypliny lub decyzji prowadzącego.

Po trzecie, powściągliwość wobec detektorów AI: dziewiętnaście szkół wyższych (63%) milczy na ich temat, a wśród omawiających dominuje stanowisko ograniczające lub zakazujące; tylko dwie szkoły wyższe zalecają stosowanie detektorów bez omówienia ograniczeń. Trend ten odzwierciedla rosnącą świadomość zawodności narzędzi detekcyjnych, szczególnie ich tendencji do fałszywych klasyfikacji wobec autorów piszących w języku innym niż angielski. Po czwarte, asymetria deklaratywne/operacyjne: dwadzieścia szkół wyższych wymaga ujawnienia (67%), ale tylko siedemnaście (57%) określa sankcje; dziewiętnaście deklaruje mechanizm aktualizacji (63%), lecz tylko siedem (23%) wskazuje konkretną datę przeglądu. Trend ten jest szczególnie wyraźny w polskim regionie.

Analiza pozwala także wskazać wzorcowe praktyki regulacyjne. W obszarze świadomego różnicowania klasyfikacji AIAS wzorem są University of Oxford (zakaz w ocenianiu, dopuszczenie w badaniach) oraz Uniwersytet Szczeciński (trzy ścieżki regulacyjne do wyboru prowadzącego). W obszarze precyzyjnego ujawnienia wyróżniają się Uniwersytet im. Adama Mickiewicza (oznaczanie zdań, akapitów, obrazów i tabel) oraz Uniwersytet Jagielloński (treść promptu jako element dokumentacji). W obszarze sankcji wzorem jest Loyola University Chicago, łącząca kategorie klauzul sylabusowych z procedurą egzekwowania. W obszarze *AI literacy* wyróżnia się NTHU z dwoma pełnymi programami AI, a w obszarze stosunku do detektorów — European University Institute (jawny zakaz), Uniwersytet Szczeciński (ostrzeżenie przed fałszywie pozytywnymi wynikami) i UAM (rekomendacja triangulacji). W obszarze mechanizmów aktualizacji wzorcem są EUI, Oxford, Uppsala i Berlin Universities Publishing, podające konkretne daty przeglądu.

## 6. Rekomendacje dla polskiego szkolnictwa wyższego

Polskie polityki AI znajdują się w fazie zaawansowanej dojrzałości deklaratywnej, ale ograniczonej operacjonalizacji. Polska wyprzedza inne regiony pod względem konsensusu wokół wartości regulacyjnych (wymóg ujawnienia, *AI literacy*, centralizacja), lecz pozostaje w tyle w warstwie egzekucyjnej i proceduralnej. Na podstawie zidentyfikowanych trendów i profilu regionalnego Polski formułujemy sześć rekomendacji, których celem nie jest zmiana kierunku regulacyjnego, lecz uzupełnienie istniejących polityk o elementy, które w pozostałych regionach stanowią standard.

Po pierwsze, należy zoperacjonalizować sankcje za nieuprawnione użycie AI — obecnie tylko 29% polskich szkół wyższych jawnie je określa, podczas gdy w pozostałych regionach odsetek ten wynosi 60–71%. Wzorem mogą być rozwiązania

Uniwersytetu Jagiellońskiego (odesłanie do odpowiedzialności dyscyplinarnej) i Uniwersytetu Szczecińskiego (powiązanie z Regulaminem Studiów).

Po drugie, należy wprowadzić formalny mechanizm aktualizacji polityki z konkretną datą przeglądu — obecnie żadna polska szkoła wyższa takiej daty nie podaje, podczas gdy cztery z siedmiu zachodnioeuropejskich szkół wyższych tę praktykę stosują.

Po trzecie, należy zrewidować stanowiska prodetektoryczne (ANS, ALK) w świetle aktualnego stanu wiedzy o zawodności narzędzi detekcyjnych, wzorując się na metodologicznie dojrzałych stanowiskach Uniwersytetu Szczecińskiego i UAM.

Po czwarte, należy poszerzyć zakres przedmiotowy polityk o wymiar badawczy i publikacyjny — polskie polityki dotyczą obecnie głównie dydaktyki, podczas gdy NTU Singapore i Berlin Universities Publishing oferują wzory dla integralności badawczej i publikowania.

Po piąte, należy zoperacjonalizować *AI literacy* w postaci konkretnych programów rozwoju kompetencji studentów i pracowników — obecnie 100% polskich szkół wyższych deklaruje *AI literacy*, ale konkretne curricula (na wzór dwóch programów NTHU) są zapisywane jedynie sporadycznie.

Po szóste, warto rozważyć adaptację rozwiązania UJ z § 4 zarządzenia 115/2025 (zamieszczanie treści promptu jako elementu ujawnienia) jako standardu polskiego, ponieważ wzorzec ten jest w korpusie unikatowy i ma wartość metodologiczną dla powtarzalności procesu twórczego. Adaptacja tych elementów nie wymaga rewolucji regulacyjnej, lecz dopisania konkretnych procedur egzekwowania, dat przeglądu i programów rozwoju kompetencji do dokumentów już funkcjonujących w polskich szkołach wyższych.

## 7. Zakończenie

Niniejszy artykuł podjął problem zróżnicowania polityk szkół wyższych w zakresie wykorzystania generatywnej sztucznej inteligencji w edukacji, przeprowadzając systematyczną analizę porównawczą polityk 30 instytucji z czterech regionów geograficznych przy zastosowaniu jednolitej metodologii. Badanie wykazało, że podejścia uczelni różnią się istotnie między regionami, układając się w cztery odrębne profile regulacyjne, odpowiadające odmiennym tradycjom akademickim i kontekstom prawnym. Mimo tych różnic dominuje wspólny kierunek: warunkowe dopuszczenie AI z wymogiem przejrzystości (AIAS 4 jako górna granica dla 93% szkół wyższych) oraz traktowanie *AI literacy* jako uniwersalnego celu regulacyjnego (80% szkół wyższych).

Centralnym ustaleniem badania jest systematyczna asymetria między silnym wymiarem deklaratywnym polityk a ich słabszym wymiarem operacyjnym — uczelnie chętniej deklarują wartości i zasady ogólne, niż precyzują procedury egzekwowania i aktualizacji. Asymetria ta jest najwyraźniejsza w polskim regionie, który łączy najwyższy w korpusie konsensus deklaratywny z najniższą operacjonalizacją. Sformułowane rekomendacje wskazują, że polskie szkolnictwo wyższe może wzmocnić swoje polityki nie poprzez zmianę kierunku regulacyjnego, lecz przez dopisanie konkretnych procedur egzekwowania, dat przeglądu oraz programów rozwoju kompetencji. Wartością dodaną zastosowanej metodologii jest również wykazanie użyteczności ustrukturyzowanej analizy treści z udziałem agentów AI, opatrzonej pełną ścieżką audytową i kontrolą halucynacji, jako narzędzia systematycznego porównywania dużych korpusów dokumentów regulacyjnych.

## Bibliografia

- An, Y., Yu, J.H., & James, S. (2025). Investigating the higher education institutions' guidelines and policies regarding the use of generative AI in teaching, learning, research, and administration. *International Journal of Educational Technology in Higher Education*, 22. <https://doi.org/10.1186/s41239-025-00507-3>
- Atlas Polityk AI Uczelni (2026). Interaktywna baza porównawcza 30 uczelni i 133 dokumentów instytucjonalnych z klasyfikacją AIAS. <https://atlaspolityk.kinal.pl/>
- Berlin Universities Publishing (2024). *Guideline for Dealing with Artificial Intelligence*. <https://www.berlin-universities-publishing.de/en/ueber-uns/policies/ki-leitlinie/index.html>
- Bozkurt, A., Xiao J., Farrow R. i in. (2024). The manifesto for teaching and learning in a time of generative AI: A critical collective stance to better navigate the future. *Open Praxis*, 16(4), 487–513. <https://doi.org/10.55982/openpraxis.16.4.777>
- Broder, A.Z. (1997). On the resemblance and containment of documents. W: *Proceedings of the Compression and Complexity of Sequences 1997*. IEEE.
- Chan, C.K.Y. (2023). A comprehensive AI policy education framework for university teaching and learning. *International Journal of Educational Technology in Higher Education*, 20, 38. <https://doi.org/10.1186/s41239-023-00408-3>
- Dabis, A., & Csáki, C. (2024). AI and ethics: Investigating the first policy responses of higher education institutions to the challenge of generative AI. *Humanities and Social Sciences Communications*, 11(1), 1106. <https://doi.org/10.1057/s41599-024-03526-z>
- Denny, P., Prather, J., Becker, B.A. i in. (2024). Computing education in the era of generative AI. *Communications of the ACM*, 67(2), 56–67. <https://doi.org/10.1145/3624720>
- Erhardt, C., Kullenberg, H., Grigoriadis, A., i Kumar, A. (2025). From policy to practice: the regulation and implementation of generative AI in Swedish higher education institutes. *International Journal for Educational Integrity*, 21, 21. <https://doi.org/10.1007/s40979-025-00195-6>
- Eaton, L. (2023–2025). *Syllabi Policies for AI Generative Tools*. AI + Education = Simplified. <https://aiedusimplified.substack.com/p/ai-syllabi-policies-a-look-at-the>
- Gruenhagen, J.H., Sinclair, P.M., Carroll, J.-A., Baker, P.R.A., Wilson, A. i Demant, D. (2024). The rapid rise of generative AI and its implications for academic integrity: Students' perceptions and use of chatbots for assistance with assessments. *Computers and Education: Artificial Intelligence*, 7, 100273. <https://doi.org/10.1016/j.caeai.2024.100273>

- 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. <https://doi.org/10.1016/j.lindif.2023.102274>
- Kosmyna, N., Hauptmann, E., Yuan, Y.T. (2025). *Your Brain on ChatGPT: Accumulation of cognitive debt when using an AI assistant for essay writing task*. <https://arxiv.org/abs/2506.08872v2>
- Liang, W., Yuksekgonul, M., Mao, Y., Wu, E. i Zou J. (2023). GPT detectors are biased against non-native English writers. *Patterns*, 4(7). <https://arxiv.org/abs/2304.02819v3>
- Long, D., & Magerko, B. (2020). What is AI literacy? Competencies and design considerations. W: *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems (CHI '20)*. ACM.
- NTU Singapore (2023). Policy on the Use of Generative Artificial Intelligence in Research. Nanyang Technological University. <https://www.ntu.edu.sg/research/resources/use-of-gai-in-research>
- Perkins, M., Furze L., Roe, J. i MacVaugh, J. (2024). The Artificial Intelligence Assessment Scale (AIAS): A framework for ethical integration of generative AI in educational assessment. *Journal of University Teaching and Learning Practice*, 21(6). <https://doi.org/10.53761/q3azde36>
- Ravšelj, D., Keržič, D., Tomažević, N. i in. (2025). Higher education students' perceptions of ChatGPT: A global study of early reactions. *PLOS ONE*, 20(2). <https://doi.org/10.1371/journal.pone.0349691>
- Stanford University (2023). Generative AI Policy Guidance. Office of Community Standards. <https://communitystandards.stanford.edu/generative-ai-policy-guidance>
- Uniwersytet Jagielloński (2025). Zarządzenie nr 115 Rektora Uniwersytetu Jagiellońskiego z dnia 27 listopada 2025 r. w sprawie wykorzystywania w dydaktyce narzędzi opartych na sztucznej inteligencji. [https://bip.uj.edu.pl/documents/1384597/159749054/zarz\\_115\\_2025.pdf](https://bip.uj.edu.pl/documents/1384597/159749054/zarz_115_2025.pdf)
- Weber-Wulff, D., Anohina-Naumeca, A., Bjelobaba, S. i in. (2023). Testing of detection tools for AI-generated text. *International Journal for Educational Integrity*, 19(1). <https://doi.org/10.1007/s40979-023-00146-z>

## University Policies on Generative Artificial Intelligence in Education — A Comparative Analysis of Selected Universities from Four World Regions

**Abstract.** This article presents a systematic comparative analysis of policies regulating the use of generative artificial intelligence at thirty higher education institutions across four geographic regions: North America, Western Europe, Poland and Asia. A corpus of 133 institutional documents underwent structured content analysis with two AI agents, classifying each policy across seven analytical dimensions, including the five-point AIAS (Artificial Intelligence Assessment Scale). The study reveals four distinct regulatory profiles and a systematic asymmetry between the strong declarative layer of policies and their weaker operational layer. Poland stands out with the highest declarative consensus (100% require disclosure of AI use, 100% refer to AI literacy) but the lowest operationalisation of enforcement and updating. The sample is purposive and does not represent global higher education, so the findings apply to the regions studied rather than to all countries. Six recommendations for Polish higher education are formulated.

**Keywords:** artificial intelligence, generative AI, university policies, higher education, academic integrity, AI literacy, comparative analysis

## Aneks 1. Ustandaryzowane polecenie analityczne

Poniżej przedstawiono pełną treść polecenia przekazywanego agentom analitycznym przy analizie każdej polityki. Polecenie było identyczne dla obu agentów i dla wszystkich 30 uczelni. Jego zamieszczenie ma umożliwić replikację badania oraz ocenę, czy sformułowania polecenia nie wprowadzają obciążenia wpływającego na wyniki klasyfikacji.

### Szablon analizy polityki AI – wersja 1.0 (12 maja 2026)

#### Instrukcje dla agenta analitycznego

Przeczytaj uważnie cały dokument polityki w formacie markdown. Następnie wypełnij wszystkie poniższe pola, zachowując następujące zasady:

1. Cytuj zawsze. Każde wnioskowanie musi mieć uzasadnienie w postaci cytatu z dokumentu (1–3 zdania). Cytat oznaczaj znakiem cytatu blokowego i podaj breadcrumb fragmentu, z którego pochodzi (np. Harvard University > Guidelines for Using ChatGPT > Privacy).

2. Bądź konkretny. Klasyfikacje kategoryczne (typu „wymagane”, „opcjonalne”, „milczy”) wybieraj z list dopuszczalnych wartości podanych w każdej sekcji. Nie wymyślaj nowych klas.

3. Oznaczaj niepewność. Jeśli dokument nie odnosi się jasno do konkretnego obszaru, zapisz „milczy” (nie zgaduj). Jeśli sformułowanie jest dwuznaczne, zaznacz to w polu „Uwagi”.

4. Zachowaj ścieżkę audytową. Lista fragmentów, z których pochodzą cytaty, zapisana w polu „Fragmenty źródłowe”, umożliwia weryfikację każdego ustalenia.

5. Jeśli polityka jest podzielona na wiele dokumentów wagi A, wykonaj jedną analizę zbiorczą obejmującą wszystkie te dokumenty, wskazując dla każdej obserwacji, który dokument jest jej źródłem.

#### 1. Skala AIAS (Perkins i in., 2024)

Klasyfikacja: [1 | 2 | 3 | 4 | 5], gdzie 1 — całkowity zakaz wykorzystania AI w zadaniach akademickich; 2 — ograniczone planowanie i ideacja (AI jako narzędzie do burzy mózgów, ale nie do generowania finalnych treści); 3 — asystent edycyjny (AI dopuszczalna do korekty, parafrazowania, sprawdzania); 4 — współautorstwo z deklaracją (AI dopuszczalna do generowania treści przy wyraźnym oznaczeniu wkładu); 5 — pełna integracja AI jako narzędzia roboczego (bez ograniczeń).

Uzasadnienie: [tekst, 2–4 zdania]. Cytat źródłowy wraz ze wskazaniem fragmentu. Czy polityka różnicuje AIAS w zależności od typu zadania lub dyscypliny? [tak | nie]. Jeśli tak, opisz różnicowanie.

## 2. Zakres i charakter regulacji

Typ polityki: [ogólnouczelniana | wydziałowa | jednostkowa]. Adresaci: [studenci | pracownicy | obie grupy]. Zakres przedmiotowy (zaznacz wszystkie, które dotyczą): prace dyplomowe; egzaminy; zadania zaliczeniowe; praca badawcza; publikacje naukowe; praca administracyjna; inne. Cytat źródłowy wraz ze wskazaniem fragmentu.

## 3. Wymogi dotyczące przejrzystości

Czy polityka wymaga ujawnienia użycia AI? [wymagane | zalecane | opcjonalne | milczy]. Forma ujawnienia (jeśli dotyczy): oświadczenie; opis w pracy (sekcja metodologiczna lub przypis); załącznik z logiem lub historią użycia; konsultacja z opiekunem przed użyciem; inne. Cytat źródłowy wraz ze wskazaniem fragmentu.

## 4. Konsekwencje naruszenia

Czy polityka określa sankcje za niedozwolone wykorzystanie AI? [tak | nie | milczy]. Charakter sankcji: [proporcjonalne do zawinienia | automatyczne | dyskrecjonalne | inne]. Konkretnie sankcje wymienione (jeśli dotyczy): obniżenie oceny; niezaliczenie pracy lub przedmiotu; postępowanie dyscyplinarne; skreślenie z listy studentów; inne. Cytat źródłowy wraz ze wskazaniem fragmentu.

## 5. Wymiar dydaktyczny i kompetencyjny

Czy polityka odnosi się do celów kształcenia w kontekście AI? [tak | nie | milczy]. Czy wspomina o *AI literacy* lub kompetencjach AI? [tak | nie | milczy]. Czy proponuje zmianę metod dydaktycznych? [tak | nie | milczy]. Czy proponuje zmianę form oceniania? [tak | nie | milczy]. Cytat źródłowy wraz ze wskazaniem fragmentu.

## 6. Stosunek do narzędzi detekcji AI

Klasyfikacja: [zaleca stosowanie | dopuszcza warunkowo | ogranicza | zakazuje | milczy]. Czy polityka odnosi się do ograniczeń detektorów AI, na przykład do ich zawodności lub obciążenia wobec osób niebędących rodzimymi użytkownika-

mi języka angielskiego? [tak | nie | milczy]. Cytat źródłowy wraz ze wskazaniem fragmentu.

## **7. Mechanizmy aktualizacji**

Czy polityka przewiduje mechanizm aktualizacji? [tak | nie | milczy]. Czy wskazuje datę przeglądu lub kolejnej wersji? [tak | nie | milczy]. Data publikacji polityki (jeśli wskazana w dokumencie): [RRRR-MM-DD lub „nieokreślona”]. Cytat źródłowy wraz ze wskazaniem fragmentu.

## **Podsumowanie syntetyczne**

Charakterystyka polityki w 3–5 zdaniach.

## **Uwagi i niejednoznaczności**

Wszystkie wątpliwości interpretacyjne, sformułowania dwuznaczne, brakujące informacje, ewentualne sprzeczności między dokumentami wagi A.

## **Fragmenty źródłowe (ścieżka audytowa)**

Lista fragmentów bazy wiedzy, do których odwołują się cytaty powyżej, w formacie: [uczelnia] > [dokument] > [sekcja] (identyfikator fragmentu).

## **Metadane techniczne**

Czas analizy; liczba przeanalizowanych dokumentów wagi A; liczba przejranych fragmentów klasy „treść właściwa”; komentarze do procesu.

Kontrola krzyżowa objęła dziesięć procent dokumentów wagi A, analizowanych niezależnie przez obu agentów; wyniki obu analiz porównywano ręcznie. Skrypt agregujący parsował wszystkie pliki analiz po ustalonych nagłówkach i flagował analizy niekompletne w którymkolwiek z siedmiu obszarów lub pozbawione cytatów źródłowych.

## Aneks 2. Procedura detekcji podobieństw leksykalnych

Celem procedury było sprawdzenie, czy polityki AI są powielane między instytucjami, a zatem czy obserwowane zbieżności regulacyjne wynikają z zapożyczeń tekstowych, czy z niezależnej konwergencji koncepcji. Procedurę przeprowadzono w całości lokalnie, bez udziału modeli językowych, na tym samym korpusie, który stanowił podstawę analizy treści.

**Jednostka porównania.** Zbiory pięciowyrazowych sekwencji wyrazowych (shingli) wyodrębnionych z tekstu każdego dokumentu.

**Zakres tekstu.** Wyłącznie fragmenty zaklasyfikowane na etapie preprocessingu jako treść właściwa; pominięto elementy nawigacyjne, stopki, metadane i treści powtarzalne.

**Normalizacja.** Sprowadzenie do małych liter, wydzielenie tokenów wyrazowych wyrażeniem regularnym obejmującym znaki alfanumeryczne wraz z polskimi znakami diakrytycznymi, odrzucenie tokenów jednoznakowych niebędących cyframi.

**Miary.** Współczynnik Jaccarda, czyli iloraz mocy części wspólnej i mocy sumy zbiorów, oraz współczynnik nakładania (ang. *overlap coefficient*, indeks Szymkiewicza-Simpsona), czyli iloraz mocy części wspólnej i mocy mniejszego ze zbiorów. Formalnie:  $J(A, B) = |A \cap B| / |A \cup B|$  oraz  $O(A, B) = |A \cap B| / \min(|A|, |B|)$ . Druga miara wychwytuje sytuację, w której krótszy dokument jest w całości zawarty w dłuższym, a więc przypadek, którego współczynnik Jaccarda nie sygnalizuje. Miara ta jest symetryczna i nie należy jej mylić z niesymetryczną miarą *containment* w ujęciu Brodera (1997), w której mianownikiem jest moc zbioru pierwszego z porównywanych dokumentów.

**Próg zgłoszenia pary.** Wartość 0,08 dla współczynnika Jaccarda lub 0,35 dla współczynnika nakładania.

**Poziomy agregacji.** Porównanie prowadzono na dwóch poziomach: para dokumentów oraz para uczelni, przy czym na drugim poziomie zbiory shingli wszystkich dokumentów danej uczelni łączono w jeden zbiór.

**Zakres obliczeń.** 133 dokumenty, 1332 fragmenty treści właściwej, 206 762 tokeny po normalizacji, 8778 par dokumentów i 435 par uczelni.

Wyniki zbiorcze przedstawia tab. 3.

**Tabela 3.** Wyniki detekcji podobieństw leksykalnych w korpusie

| Miara                                                                         | Wartość |
|-------------------------------------------------------------------------------|---------|
| Pary dokumentów powyżej progu                                                 | 14      |
| w tym pary z różnych uczelni                                                  | 0       |
| Pary dokumentów identycznych (współczynnik nakładania równy 1)                | 3       |
| Najwyższy współczynnik Jaccarda między dokumentami różnych uczelni            | 0,0013  |
| Najwyższy współczynnik nakładania między dokumentami różnych uczelni          | 0,0482  |
| Najwyższy współczynnik Jaccarda między dwiema uczelniami (poziom zagregowany) | 0,0024  |

Źródło: Opracowanie własne. Trzy pary dokumentów identycznych to skutek dwukrotnego pozyskania tego samego pliku w obrębie jednej uczelni (Princeton University oraz dwukrotnie UC Berkeley), nie zaś powielenia treści między instytucjami.

Wniosek z procedury jest jednoznaczny: żadna para dokumentów pochodzących z różnych uczelni nie przekroczyła progu podobieństwa. Wszystkie czternaście par zgłoszonych przez procedurę pochodzi z tej samej instytucji i obejmuje albo duplikaty pozyskania, albo różne wersje tego samego dokumentu wewnętrznego. Zbieżności regulacyjne opisane w artykule mają zatem charakter konwergencji koncepcyjnej, nie zapożyczeń tekstowych.